Linux内核完全注释

内核版本0.11(0.95)

修正版 V1.9.6

赵　炯　著

www.oldlinux.org　　gohigh@sh163.net

Linux 内核 0.11 完全注释

A Heavily Commented Linux Kernel Source Code
Linux Version 0.11

修正版 1.9.6
（Revision 1.9.6）

赵炯
Zhao Jiong

gohigh@sh163.net

www.plinux.org
www.oldlinux.org

2004-10-26

内容简介

本书对 Linux 早期操作系统内核(v0.11)全部代码文件进行了详细全面的注释和说明，旨在使读者能够在尽量短的时间内对 Linux 的工作机理获得全面而深刻的理解，为进一步学习和研究 Linux 系统打下坚实的基础。虽然所选择的版本较低，但该内核已能够正常编译运行，其中已经包括了 LINUX 工作原理的精髓，通过阅读其源代码能快速地完全理解内核的运作机制。书中首先以 Linux 源代码版本的变迁历史为主线，详细介绍了 Linux 系统的发展历史，着重说明了各个内核版本之间的重要区别和改进方面，给出了选择 0.11(0.95)版作为研究的对象的原因。另外介绍了内核源代码的组织结构及相互关系，同时还说明了编译和运行该版本内核的方法。然后本书依据内核源代码的组织结构对所有内核程序和文件进行了注释和详细说明。每章的安排基本上分为具体研究对象的概述、每个文件的功能介绍、代码内注释、代码中难点及相关资料介绍、与当前版本的主要区别等部分。最后一章内容总结性地介绍了继续研究 Linux 系统的方法和着手点。

“RTFSC – Read The F**king Source Code ☺!”

-Linus Benedict Torvalds

目录

序言

本书是一本有关 Linux 操作系统内核基本工作原理的入门读物。

本书的主要目标

本书的主要目标是使用尽量少的篇幅或在有限的篇幅内，对完整的 Linux 内核源代码进行解剖，以期对操作系统的基本功能和实际实现方式获得全方位的理解。做到对 linux 内核有一个完整而深刻的理解，对 linux 操作系统的基本工作原理真正理解和入门。

本书读者群的定位是一些知晓 Linux 系统的一般使用方法或具有一定的编程基础，但比较缺乏阅读目前最新内核源代码的基础知识，又急切希望能够进一步理解 UNIX 类操作系统内核工作原理和实际代码实现的爱好者。这部分读者的水平应该界于初级与中级水平之间。目前，这部分读者人数在 Linux 爱好者中所占的比例是很高的，而面向这部分读者以比较易懂和有效的手段讲解内核的书籍资料不多。

现有书籍不足之处

目前已有的描述 Linux 内核的书籍，均尽量选用最新 Linux 内核版本（例如 Redhat 7.0 使用的 2.2.16 稳定版等）进行描述，但由于目前 Linux 内核整个源代码的大小已经非常得大（例如 2.2.20 版具有 268 万行代码!），因此这些书籍仅能对 Linux 内核源代码进行选择性地或原理性地说明，许多系统实现细节被忽略。因此并不能给予读者对实际 Linux 内核有清晰而完整的理解。

Scott Maxwell 著的一书《Linux 内核源代码分析》（陆丽娜等译）基本上是面对 Linux 中级水平的读者，需要较为全面的基础知识才能完全理解。而且可能是由于篇幅所限，该书并没有对所有 Linux 内核代码进行注释，略去了很多内核实现细节，例如其中内核中使用的各个头文件(*.h)、生成内核代码映像文件的工具程序、各个 make 文件的作用和实现等均没有涉及。因此对于处于初中级水平之间的读者来说阅读该书有些困难。

浙江大学出版的《Linux 内核源代码情景分析》一书，也基本有这些不足之处。甚至对于一些具有较高 Linux 系统应用水平的计算机本科高年级学生，由于该书篇幅问题以及仅仅选择性地讲解内核源代码，也不能真正吃透内核的实际实现方式，因而往往刚开始阅读就放弃了。这在本人教学的学生中基本都会出现这个问题。该书刚面市时，本人曾极力劝说学生购之阅读，并在二个月后调查阅读学习情况，基本都存在看不下去或不能理解等问题，大多数人都放弃了。

John Lions 著的《莱昂氏 UNIX 源代码分析》一书虽然是一本学习 UNIX 类操作系统内核源代码很好的书籍，但是由于其采用的是 UNIX V6 版，其中系统调用等部分代码是用早已废弃的 PDP-11 系列机的汇编语言编制的，因此在阅读和理解与硬件部分相关的源代码时就会遇到较大的困难。

A.S.Tanenbaum 的书《操作系统：设计与实现》是一本有关操作系统内核实现很好的入门书籍，但该书所叙述的 MINIX 系统是一种基于消息传递的内核实现机制，与 Linux 内核的实现有所区别。因此在学习该书之后，并不能很顺利地即刻着手进一步学习较新的 Linux 内核源代码实现。

在使用这些书籍进行学习时会有一种“盲人摸象”的感觉，不能真正理解 Linux 内核系统具体实现的整体概念，尤其是对那些 Linux 系统初学者或刚学会如何使用 Linux 系统的人在使用那些书学习内核

原理时，内核的整体运作结构并不能清晰地在脑海中形成。这在本人多年的 Linux 内核学习过程中也深有体会。在 1991 年 10 月份，Linux 的创始人 Linus Torvalds 在开发出 Linux 0.03 版后写的一篇文章中也提到了同样的问题。在这篇题为“LINUX--a free unix-386 kernel”[1]的文章中，他说：“开发 Linux 是为了那些操作系统爱好者和计算机科学系的学生使用、学习和娱乐”。“自由软件基金会的 GNU Hurd 系统如果开发出来就已经显得太庞大而不适合学习和理解。”而现今流行的 Linux 系统要比当年 GNU 的 Hurd 系统更为庞大和复杂，因此同样也已经不适合作为操作系统初学者的入门学习起点。这也是作者基于 Linux 早期内核版本写作本书的动机之一。

为了填补这个空缺，本书的主要目标是使用尽量少的篇幅或在有限的篇幅内，对完整的 Linux 内核源代码进行全面解剖，以期对操作系统的基本功能和实际实现方式获得全方位的理解。做到对 Linux 内核有一个完整而深刻的理解，对 Linux 操作系统的基本工作原理真正理解和入门。

阅读早期内核的其他好处

目前，已经出现不少基于 Linux 早期内核而开发的专门用于嵌入式系统的内核版本，如 DJJ 的 x86 操作系统、Uclinux 等（在 www.linux.org 上有专门目录），世界上也有许多人认识到通过早期 Linux 内核源代码学习的好处，目前国内也已经有人正在组织人力注释出版类似本文的书籍。因此，通过阅读 Linux 早期内核版本的源代码，的确是学习 Linux 系统的一种行之有效的途径，并且对研究和应用 Linux 嵌入式系统也有很大的帮助。

在对早期内核源代码的注释过程中，作者发现，早期内核源代码几乎就是目前所使用的较新内核的一个精简版本。其中已经包括了目前新版本中几乎所有的基本功能原理的内容。正如《系统软件：系统编程导论》一书的作者 Leland L. Beck 在介绍系统程序以及操作系统设计时，引入了一种极其简化的简单指令计算机(SIC)系统来说明所有系统程序的设计和实现原理，从而既避免了实际计算机系统的复杂性，又能透彻地说明问题。这里选择 Linux 的早期内核版本作为学习对象，其指导思想与 Leland 的一致。这对 Linux 内核学习的入门者来说，是最理想的选择之一。能够在尽可能短的时间内深入理解 Linux 内核的基本工作原理。

对于那些已经比较熟悉内核工作原理的人，为了能让自己在实际工作中对系统的实际运转机制不产生一种空中楼阁的感觉，因此也有必要阅读内核源代码。

当然，使用早期内核作为学习的对象也有不足之处。所选用的 Linux 早期内核版本不包含对虚拟文件系统 VFS 的支持、对网络系统的支持、仅支持 a.out 执行文件和对其他一些现有内核中复杂子系统的说明。但由于本书是作为 Linux 内核工作机理实现的入门教材，因此这也正是选择早期内核版本的优点之一。通过学习本书，可以为进一步学习这些高级内容打下扎实的基础。

阅读完整源代码的重要性和必要性

正如 Linux 系统的创始人在一篇新闻组投稿上所说的，要理解一个软件系统的真正运行机制，一定要阅读其源代码（RTFSC – Read The Fucking Source Code）。系统本身是一个完整的整体，具有很多看似不重要的细节存在，但是若忽略这些细节，就会对整个系统的理解带来困难，并且不能真正了解一个实际系统的实现方法和手段。

虽然通过阅读一些操作系统原理经典书籍（例如 M.J.Bach 的《UNIX 操作系统设计》）能够对 UNIX 类操作系统的工作原理有一些理论上的指导作用，但实际上对操作系统的真正组成和内部关系实现的理解仍不是很清晰。正如 AST 所说的，“许多操作系统教材都是重理论而轻实践”，“多数书籍和课程为调

[1] 原文可参见：http://oldlinux.org/Linus/

度算法耗费大量的时间和篇幅而完全忽略 I/O，其实，前者通常不足一页代码，而后者往往要占到整个系统三分之一的代码总量。”内核中大量的重要细节均未提到。因此并不能让读者理解一个真正的操作系统实现的奥妙所在。只有在详细阅读过完整的内核源代码之后，才会对系统有一种豁然开朗的感觉，对整个系统的运作过程有深刻的理解。以后再选择最新的或较新内核源代码进行学习时，也不会碰到大问题，基本上都能顺利地理解新代码的内容。

如何选择要阅读的内核代码版本

那么，如何选择既能达到上述要求，又不被太多的内容而搞乱头脑，选择一个适合的 Linux 内核版本进行学习，提高学习的效率呢？作者通过对大量内核版本进行比较和选择后，最终选择了与目前 Linux 内核基本功能较为相近，又非常短小的 0.11 版内核作为入门学习的最佳版本。下图是对一些主要 Linux 内核版本行数的统计。

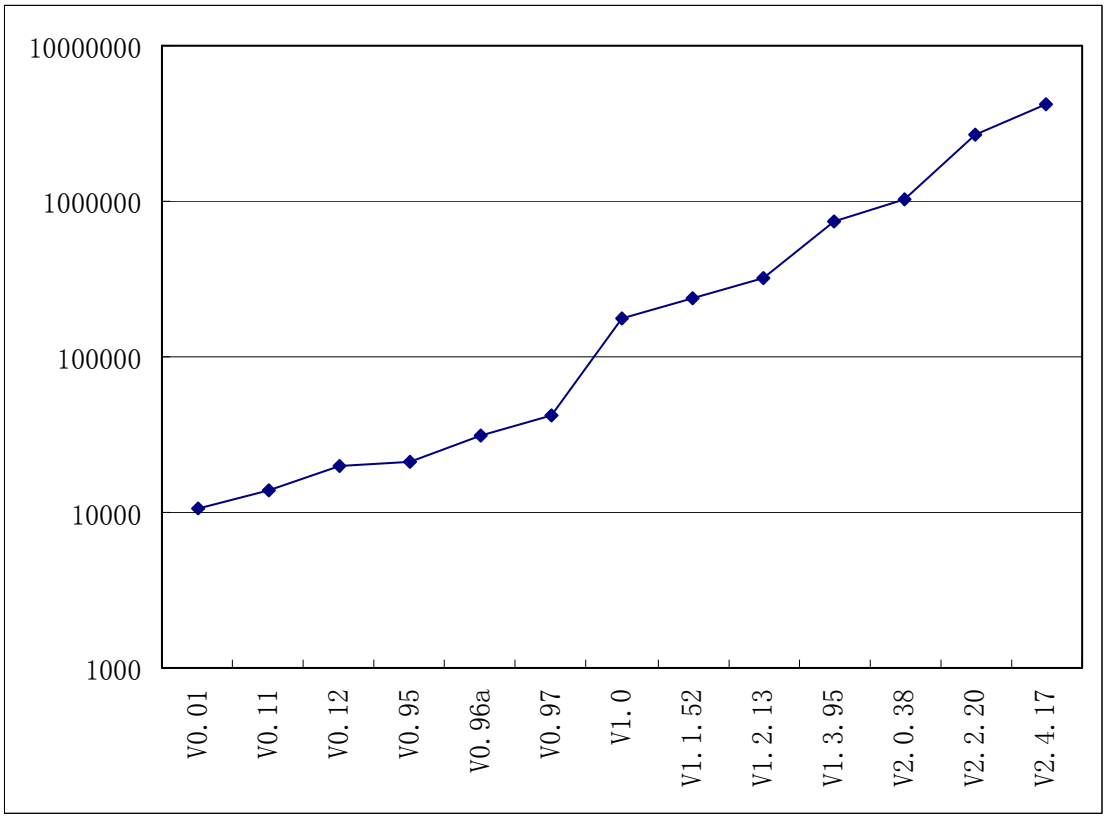

目前的 Linux 内核源代码量都在几百万行的数量上，极其庞大，对这些版本进行完全注释和说明几乎是不可能的，而 0.11 版内核不超过 2 万行代码量，因此完全可以在一本书中解释和注释清楚。麻雀虽小，五脏俱全。为了对所研究的系统有感性的了解，并能利用实验来加深对原理的理解，作者还专门重建了基于该内核的可运行的 Linux 0.11 系统。由于其中含有 GNU gcc 编译环境，因此使用该系统也能做一些简单的开发工作。

另外，使用该版本可以避免使用现有较新内核版本中已经变得越来越复杂得各子系统部分的研究（如虚拟文件系统 VFS、ext2 或 ext3 文件系统、网络子系统、新的复杂的内存管理机制等）。

阅读本书需具备的基础知识

在阅读本书时，希望读者具备以下一些基础知识或者有相关的参考书籍在身边。其一是有关 80x86 处理器结构和编程的知识或资料。例如可以从网上下载的 80x86 编程手册（INTEL 80386 Programmer's Reference Manual）；其二是有关 80x86 硬件体系结构和接口编程的知识或资料。有关这方面的资料很多；其三还应具备初级使用 Linux 系统的简单技能。

另外，由于 Linux 系统内核实现最早是根据 M.J.Bach 的《UNIX 操作系统设计》一书的基本原理开发的，源代码中许多变量或函数的名称都来自该书，因此在阅读本书时若能适当参考该书，会更易于理解内核源代码。

Linus 在最初开发 Linux 操作系统时，参照了 MINIX 操作系统。例如，最初的 Linux 内核版本完全照搬了 MINIX 1.0 文件系统。因此，在阅读本书时，A.S.Tanenbaum 的书《操作系统：设计与实现》也具有较大的参考价值。但 Tanenbaum 的书描述的是一种基于消息传递在内核各模块之间进行通信（信息交换），这与 Linux 内核的工作机制不一样。因此可以仅参考其中有关一般操作系统工作原理章节和文件系统实现的内容。

使用早期版本是否过时？

表面看来本书对 Linux 早期内核版本注释的内容犹如 Linux 操作系统刚公布时 Tanenbaum 就认为其已经过时的（Linux is obsolete）想法一样，但通过学习本书内容，你就会发现，利用本书学习 Linux 内核，由于内核源代码量短小而精干，因此会有极高的学习效率，能够做到事半功倍，快速入门。并且对继续进一步选择新内核部分源代码的学习打下坚实的基础。在学习完本书之后，你将对系统的运作原理有一个非常完整而实际的概念，这种完整概念能使人很容易地进一步选择和学习新内核源代码中的任何部分，而不需要再去啃读代码量巨大的新内核中完整的源代码。

Ext2 文件系统与 MINIX 文件系统

目前 Linux 系统上所使用的 Ext2（或最新的 Ext3）文件系统是在内核 1.x 之后开发的。其功能详尽并且性能也非常完整和稳固，是目前 Linux 操作系统上默认的标准文件系统。但是，作为对 Linux 操作系统完整工作原理入门学习所使用的部分，原则上是越精简越好。为了达到对一个操作系统有完整的理解，并且能不被其中各子系统中复杂和过多的细节所喧宾夺主，在选择学习剖析用的内核版本时，只要系统的部分代码内容能说明实际工作原理，就越简单越好。

Linux 内核 0.11 版上当时仅包含最为简单的 MINIX 1.0 文件系统，对于理解一个操作系统中文件系统的实际组成和工作原理已经足够。这也是选择 Linux 早期内核版本进行学习的主要原因之一。

在完整阅读完本书之后，相信您定会发出这样的感叹：“对于 Linux 内核系统，我现在终于入门了！”。此时，您应该有十分的把握去进一步学习最新 Linux 内核中各部分的工作原理和过程了。

另外，本书印刷版已由机械工业出版社于 2004 年 9 月份出版，书号是 ISBN 7-111-14968-8，定价为 42 元。若您觉得电子版阅读起来不方便可以到书店购买纸版书。或者到本书的专门网站论坛中求购。网站域名是 www.oldlinux.org。

同济大学
赵炯 博士
2004.10

第1章 概述

本章首先回顾了 Linux 操作系统的诞生、开发和成长过程，由此可以理解本书为什么会选择 Linux 系统早期版本作为学习对象的一些原因。然后具体说明了选择早期 Linux 内核版本进行学习的优点和不足之处以及如何开始进一步学习。最后对各章的内容进行了简要介绍。

1.1 Linux 的诞生和发展

Linux 操作系统是 UNIX 操作系统的一种克隆系统。它诞生于 1991 年的 10 月 5 日（这是第一次正式向外公布的时间）。此后借助于 Internet 网络，经过全世界各地计算机爱好者的共同努力，现已成为当今世界上使用最多的一种 UNIX 类操作系统，并且使用人数还在迅猛增长。

Linux 操作系统的诞生、发展和成长过程依赖于以下五个重要支柱：UNIX 操作系统、MINIX 操作系统、GNU 计划、POSIX 标准和 Internet 网络。下面根据这五个基本线索来追寻一下 Linux 的开发历程、它的酝酿过程以及最初的发展经历。首先分别介绍其中的四个基本要素，然后根据 Linux 的创始人 Linus Torvalds 从对计算机感兴趣而自学计算机知识、到心里开始酝酿编制一个自己的操作系统、到最初 Linux 内核 0.01 版公布以及从此如何艰难地一步一个脚印地在全世界 hacker 的帮助下最后推出比较完善的 1.0 版本这段时间的发展经过，也即对 Linux 的早期发展历史进行详细介绍。

当然，目前 Linux 内核版本已经开发到了 2.5.52 版。而大多数 Linux 系统中所用到的内核是稳定的 2.4.20 版内核（其中第 2 个数字若是奇数则表示是正在开发的版本，不能保证系统的稳定性）。对于 Linux 的一般发展史，许多文章和书籍都有介绍，这里就不重复。

1.1.1 UNIX 操作系统的诞生

Linux 操作系统是 UNIX 操作系统的一个克隆版本。UNIX 操作系统是美国贝尔实验室的 Ken.Thompson 和 Dennis Ritchie 于 1969 年夏在 DEC PDP-7 小型计算机上开发的一个分时操作系统。

Ken Thompson 为了能在闲置不用的 PDP-7 计算机上运行他非常喜欢的星际旅行（Space travel）游戏，于是在 1969 年夏天乘他夫人回家乡加利福尼亚渡假期间，在一个月内开发出了 UNIX 操作系统的原型。当时使用的是 BCPL 语言（基本组合编程语言），后经 Dennis Ritchie 于 1972 年用移植性很强的 C 语言进行了改写，使得 UNIX 系统在大专院校得到了推广。

1.1.2 MINIX 操作系统

MINIX 系统是由 Andrew S. Tanenbaum（AST）开发的。AST 是在荷兰 Amsterdam 的 Vrije 大学数学与计算机科学系统工作，是 ACM 和 IEEE 的资深会员(全世界也只有很少人是两会的资深会员)。共发表了 100 多篇文章，5 本计算机书籍。

AST 虽出生在美国纽约，但却是荷兰侨民(1914 年他的祖辈来到美国)。他在纽约上的中学、M.I.T 上的大学、加洲大学 Berkeley 分校念的博士学位。由于读博士后的缘故，他来到了家乡荷兰。从此就与家乡一直有来往。后来就在 *Vrije* 大学开始教书、带研究生。荷兰首都 Amsterdam 是个常年阴雨绵绵的城市，但对于 AST 来说，这最好不过了，因为在这样的环境下他就可以经常待在家中摆弄他的计算机了。

MINIX 是他 1987 年编制的，主要用于学生学习操作系统原理。到 1991 年时版本是 1.5。目前主要有两个版本在使用：1.5 版和 2.0 版。当时该操作系统在大学使用是免费的，但其他用途则不是。当然目

前 MINIX 系统已经是免费的，可以从许多 FTP 上下载。

对于 Linux 系统，他后来曾表示对其开发者 Linus 的称赞。但他认为 Linux 的发展很大原因是由于他为了保持 MINIX 的小型化，能让学生在一个学期内就能学完，因而没有接纳全世界许多人对 MINIX 的扩展要求。因此在这样的前提下激发了 Linus 编写 Linux 系统。当然 Linus 也正好抓住了这个好时机。

作为一个操作系统，MINIX 并不是优秀者，但它同时提供了用 C 语言和汇编语言编写的系统源代码。这是第一次使得有抱负的程序员或 hacker 能够阅读操作系统的源代码。在当时，这种源代码是软件商们一直小心守护着的秘密。

1.1.3 GNU 计划

GNU 计划和自由软件基金会 FSF(the Free Software Foundation)是由 Richard M. Stallman 于 1984 年一手创办的。旨在开发一个类似 UNIX 并且是自由软件的完整操作系统：GNU 系统（GNU 是"GNU's Not Unix"的递归缩写，它的发音为"guh-NEW"）。各种使用 Linux 作为核心的 GNU 操作系统正在被广泛的使用。虽然这些系统通常被称作"Linux"，但是 Stallman 认为，严格地说，它们应该被称为 GNU/Linux 系统。

到上世纪 90 年代初，GNU 项目已经开发出许多高质量的免费软件，其中包括有名的 emacs 编辑系统、bash shell 程序、gcc 系列编译程序、gdb 调试程序等等。这些软件为 Linux 操作系统的开发创造了一个合适的环境。这是 Linux 能够诞生的基础之一，以至于目前许多人都将 Linux 操作系统称为“GNU/Linux”操作系统。

1.1.4 POSIX 标准

POSIX（Portable Operating System Interface for Computing Systems）是由 IEEE 和 ISO/IEC 开发的一簇标准。该标准是基于现有的 UNIX 实践和经验，描述了操作系统的调用服务接口。用于保证编制的应用程序可以在源代码一级上在多种操作系统上移植和运行。它是在 1980 年早期一个 UNIX 用户组(usr/group)的早期工作基础上取得的。该 UNIX 用户组原来试图将 AT&T 的 System V 操作系统和 Berkeley CSRG 的 BSD 操作系统的调用接口之间的区别重新调和集成。并于 1984 年定制出了/usr/group 标准。

1985 年，IEEE 操作系统技术委员会标准小组委员会（TCOS-SS）开始在 ANSI 的支持下责成 IEEE 标准委员会制定有关程序源代码可移植性操作系统服务接口正式标准。到了 1986 年 4 月，IEEE 制定出了试用标准。第一个正式标准是在 1988 年 9 月份批准的（IEEE 1003.1-1988），也既以后经常提到的 POSIX.1 标准。

到 1989 年，POSIX 的工作被转移至 ISO/IEC 社团，并由 15 工作组继续将其制定成 ISO 标准。到 1990 年，POSIX.1 与已经通过的 C 语言标准联合，正式批准为 IEEE 1003.1-1990（也是 ANSI 标准）和 ISO/IEC 9945-1:1990 标准。

POSIX.1 仅规定了系统服务应用程序编程接口（API），仅概括了基本的系统服务标准。因此工作组期望对系统的其他功能也制定出标准。这样 IEEE POSIX 的工作就开始展开了。刚开始有十个批准的计划在进行，有近 300 多人参加每季度为期一周的会议。着手的工作有命令与工具标准(POSIX.2)、测试方法标准（POSIX.3）、实时 API（POSIX.4）等。到了 1990 年上半年已经有 25 个计划在进行，并且有 16 个工作组参与了进来。与此同时，还有一些组织也在制定类似的标准，如 X/Open，AT&T，OSF 等。

在 90 年代初，POSIX 标准的制定正处在最后投票敲定的时候，那是 1991-1993 年间。此时正是 Linux 刚刚起步的时候，这个 UNIX 标准为 Linux 提供了极为重要的信息，使得 Linux 能够在标准的指导下进行开发，并能够与绝大多数 UNIX 操作系统兼容。在最初的 Linux 内核源代码中（0.01 版、0.11 版）就已经为 Linux 系统与 POSIX 标准的兼容做好了准备工作。在 Linux 0.01 版内核的/include/unistd.h 文件中就已经定义了几个有关 POSXI 标准要求的符号常数，而且 Linus 在注释中已写道：“OK，这也许是个玩笑，但我正在着手研究它呢”。

1991 年 7 月 3 日在 comp.os.minix 上发布的 post 上就已经提到了正在搜集 POSIX 的资料。其中透露了他正在着手一个操作系统的开发，并且在开发之初已经想到要实现与 POSIX 相兼容的问题了。

1.1.5 Linux 操作系统的诞生

在 1981 年，IBM 公司推出了享誉全球的微型计算机 IBM PC。在 1981-1991 年间，MS-DOS 操作系统一直是微型计算机操作系统的主宰。此时计算机硬件价格虽然逐年下降，但软件价格仍然居高不下。当时 Apple 的 MACs 操作系统可以说是性能最好的，但是其天价使得没人能够轻易靠近。

当时的另一个计算机技术阵营就是 UNIX 世界。但是 UNIX 操作系统就不仅是价格昂贵的问题了。为了寻求高利润率，UNIX 经销商们把价格抬得极高，PC 小用户根本不能靠近它。曾经一度收到 Bell Labs 许可而能在大学中用于教学的 UNIX 源代码也一直被小心地守卫着不许公开。对于广大的 PC 用户，软件行业的大型供应商们始终没有给出有效的解决这个问题的手段。

正在此时，出现了 MINIX 操作系统，并且有一本描述其设计实现原理的书同时发行。由于 AST 的这本书写的非常详细，并且叙述得有条有理，于是几乎全世界的计算机爱好者都开始看这本书，以期能理解操作系统的工作原理。其中也包括 Linux 系统的创始者 Linus Benedict Torvalds。

当时(1991 年)，Linus Benedict Torvalds 是赫尔辛基大学计算机科学系的二年级学生，也是一个自学的计算机 hacker。这个 21 岁的芬兰年轻人喜欢鼓捣他的计算机，测试计算机的性能和限制。但当时他所缺乏的就是一个专业级的操作系统。

在同一年间，GNU 计划已经开发出了许多工具软件。其中最受期盼的 GNU C 编译器已经出现，但还没有开发出免费的 GNU 操作系统。即使是教学使用的 MINIX 操作系统也开始有了版权，需要购买才能得到源代码。虽然 GNU 的操作系统 HURD 一直在开发之中，但在当时看来不能在几年内完成。

为了能更好地学习计算机知识（或许也只是为了兴趣☺），Linus 使用圣诞节的压岁钱和贷款购买了一台 386 兼容电脑，并从美国邮购了一套 MINIX 系统软件。就在等待 MINIX 软件期间，Linus 认真学习了有关 Intel 80386 的硬件知识。为了能通过 Modem 拨号连接到学校的主机上，他使用汇编语言并利用 80386 CPU 的多任务特性编制出一个终端仿真程序。此后为了将自己一台老式电脑上的软件复制到新电脑上，他还为软盘驱动器、键盘等硬件设备编制出相应的驱动程序。

通过编程实践，并在学习过程中认识到 MINIX 系统的诸多限制（MINIX 虽然很好，但只是一个用于教学目的简单操作系统，而不是一个强有力的实用操作系统），而且通过上述实践 Linus 已经有了一些类似于操作系统硬件设备驱动程序的代码，于是他开始有了编制一个新操作系统的想法。此时 GNU 计划已经开发出许多工具软件，其中最受期盼的 GNU C 编译器已经出现。虽然 GNU 的免费操作系统 HURD 正在开发中。但 Linus 已经等不急了。

从 1991 年 4 月份起，他通过修改终端仿真程序和硬件驱动程序，开始编制起自己的操作系统来。刚开始，他的目的很简单，只是为了学习 Intel 386 体系结构保护模式运行方式下的编程技术。但后来 Linux 的发展却完全改变了初衷。根据 Linus 在 comp.os.minix 新闻组上发布的消息，我们可以知道他逐步从学习 MINIX 系统阶段发展到开发自己的 Linux 系统的过程。

Linus 第 1 次向 comp.os.minix 投递消息是在 1991 年 3 月 29 日。所发帖子的题目是“gcc on minix-386 doesn't optimize”,是有关 gcc 编译器在 MINIX-386 系统上运行优化的问题（MINIX-386 是一个由 Bruce Evans 改进的利用 Intel 386 特性的 32 位 MINIX 系统）。由此可知，Linus 在 1991 年初期就已经开始深入研究了 MINIX 系统，并在这段时间有了改进 MINIX 操作系统的思想。在进一步学习 MINIX 系统之后，这个想法逐步演变成想重新设计一个基于 Intel 80386 体系结构的新操作系统的构思。

他在回答有人提出 MINIX 上的一个问题时，所说的第一句话就是“阅读源代码”（“RTFSC (Read the F**ing Source Code :-)”）。他认为答案就在源程序中。这也说明了对于学习系统软件来说，我们不光需要懂得系统的工作基本原理，还需要结合实际系统，学习实际系统的实现方法。因为理论毕竟是理论，其中省略了许多枝节，而这些枝节问题虽然没有太多的理论含量，但却是一个系统必要的组成部分，就象麻雀身上的一根羽毛。

从 1991 年 4 月份开始，Linus 几乎花费了全部时间研究 MINIX-386 系统(Hacking the kernel)，并且尝试着移植 GNU 的软件到该系统上(GNU gcc、bash、gdb 等)。并于 4 月 13 日在 comp.os.minix 上发布说自己已经成功地将 bash 移植到了 MINIX 上，而且已经爱不释手、不能离开这个 shell 软件了。

第一个与 Linux 有关的消息是在 1991 年 7 月 3 日在 comp.os.minix 上发布的（当然，那时还不存在 Linux 这个名称，当时 Linus 脑子里想的名称可能是 FREAX ☺，FREAX 的英文含义是怪诞的、怪物、异想天开等）。其中透露了他正在进行 Linux 系统的开发，并且已经想到要实现与 POSIX 兼容的问题了。

在 Linus 另一个发布的消息中(1991 年 8 月 25 日 comp.os.minix)，他向所有 MINIX 用户询问“What would you like to see in minix?”(“你最想在 MINIX 系统中见到什么？”)，在该消息中他首次透露出正在开发一个(免费的)386(486)操作系统，并且说只是兴趣而已，代码不会很大，也不会象 GNU 的那样专业。希望大家反馈一些对于 MINIX 系统中喜欢哪些特色不喜欢什么等信息，并且说明由于实际和其他一些原因，新开发的系统刚开始与 MINIX 很象（并且使用了 MINIX 的文件系统）。并且已经成功地将 bash(1.08 版)和 gcc(1.40 版)移植到了新系统上，而且在过几个月就可以实用了。

最后，Linus 声明他开发的操作系统没有使用一行 MINIX 的源代码；而且由于使用了 386 的任务切换特性，所以该操作系统不好移植（没有可移植性），并且只能使用 AT 硬盘。对于 Linux 的移植性问题，Linus 当时并没有考虑。但是目前 Linux 几乎可以运行在任何一种硬件体系结构上。

到了 1991 年的 10 月 5 日，Linus 在 comp.os.minix 新闻组上发布消息，正式向外宣布 Linux 内核系统的诞生（Free minix-like kernel sources for 386-AT）。这段消息可以称为 Linux 的诞生宣言，并且一直广为流传。因此 10 月 5 日对 Linux 社区来说是一个特殊的日子，许多后来 Linux 的新版本发布时都选择了这个日子。所以 RedHat 公司选择这个日子发布它的新系统也不是偶然的。

1.1.6 Linux 操作系统版本的变迁

Linux 操作系统从诞生到 1.0 版正式出现，共发布了表 1－1 中所示的一些主要版本。

表 1－1 内核的主要版本

版本号	发布日期	说明
0.00	(1991.2-4)	两个进程，分别在屏幕上显示’AAA’和’BBB’。
0.01	(1991.8)	第一个正式向外公布的 Linux 内核版本。多线程文件系统、分段和分页内存管理。
0.02	(1991.10.5)	该版本以及 0.03 版是内部版本，目前已经无法找到特点同上。
0.10	(1991.10)	由 Ted Ts’o 发布的 Linux 内核版本。增加了内存分配库函数。
0.11	(1991.12.8)	基本可以正常运行的内核版本。至此硬盘和软驱驱动。
0.12	(1992.1.15)	主要增加了数学协处理器的软件模拟程序，增加了作业控制、虚拟控制台、文件符号链接和虚拟内存对换功能。
0.95(0.13)	(1992.3.8)	加入虚拟文件系统支持，增加了登录功能。改善了软盘驱动程序和文件系统的性能。改变了硬盘编号方式。支持 CDROM。
0.96	(1992.5.12)	开始加入网络支持。改善了串行驱动、高速缓冲、内存管理的性能，支持动态链接库，并能运行 X-Windows 程序。
0.97	(1992.8.1)	增加了对新的 SCSI 驱动程序的支持。
0.98	(1992.9.29)	改善了对 TCP/IP（0.8.1）网络的支持，纠正了 extfs 的错误。
0.99	(1992.12.13)	重新设计进程对内存的使用分配，每个进程有 4G 线性空间。
1.0	(1994.3.14)	第一个正式版。

将 Linux 系统 0.13 版内核直接改称 0.95 版，Linus 的意思是让大家不要觉得离 1.0 版还很遥远。同时，从 0.95 版开始，对内核的许多改进之处(补丁程序的提供)均以其他人为主了，而 Linus 的主要任务开始变成对内核的维护和决定是否采用某个补丁程序。到现在为止，最新的内核版本是 2003 年 12 月 18 日公布的 2.6.2 版。其中包括大约 15000 个文件，而且使用 gz 压缩后源代码软件包也有 40MB 左右！到现在为止，最新版见表 1–2 所示。

表 1－2 新内核源代码字节数

内核版本号	发布日期	源代码大小(经 gz 压缩后)
2.4.22	2004.2.4	35MB
2.6.5	2004.4.4	41MB

1.1.7 Linux 名称的由来

Linux 操作系统刚开始时并没有被称作 Linux，Linus 给他的操作系统取名为 FREAX，其英文含义是怪诞的、怪物、异想天开等意思。在他将新的操作系统上载到 ftp.funet.fi 服务器上时，管理员 Ari Lemke 很不喜欢这个名称。他认为既然是 Linus 的操作系统就取其谐音 Linux 作为该操作系统的目录吧，于是 Linux 这个名称就开始流传下来。

在 Linus 的自传《Just for Fun》一书中，Linus 解释说[2]：

“坦白地说，我从来没有想到过要用 Linux 这个名称发布这个操作系统，因为这个名字有些太自负了。而我为最终发布版准备的是什么名字呢？Freax。实际上，内核代码中某些早期的 Makefile - 用于描述如何编译源代码的文件 - 文件中就已经包含有“Freax”这个名字了，大约存在了半年左右。但其实这也没什么关系，在当时还不需要一个名字，因为我还没有向任何人发布过内核代码。”

“而 Ari Lemke，他坚持要用自己的方式将内核代码放到 ftp 站点上，并且非常不喜欢 Freax 这个名字。他坚持要用现在这个名字(Linux)，我承认当时我并没有跟他多争论。但这都是他取的名字。所以我可以光明正大地说我并不自负，或者部分坦白地说我并没有本位主义思想。但我想好吧，这也是个好名字，而且以后为这事我总能说服别人，就象我现在做的这样。”

1.1.8 早期 Linux 系统开发的主要贡献者

从 Linux 早期源代码中可以看出，Linux 系统的早期主要开发人员除了 Linus 本人以外，最著名的人员之一就是 Theodore Ts'o (Ted Ts'o)。他于 1990 年毕业于 MIT 计算机科学专业。在大学时代他就积极参加学校中举办的各种学生活动。他喜欢烹饪、骑自行车，当然还有就是 Hacking on Linux。后来他开始喜欢起业余无线电报运动。目前他在 IBM 工作从事系统编程及其他重要事务。他还是国际网络设计、操作、销售和研究者开放团体 IETF 成员。

Linux 在世界范围内的流行也有他很大的功劳。早在 Linux 操作系统刚问世时，他就怀着极大的热情为 linux 的发展提供了 Maillist，几乎是在 Linux 刚开始发布时起，他就一直在为 Linux 做出贡献。他也是最早向 Linux 内核添加程序的人（Linux 内核 0.10 版中的虚拟盘驱动程序 ramdisk.c 和内核内存分配程序 kmalloc.c)。直到目前为止他仍然从事着与 Linux 有关的工作。在北美洲地区他最早设立了 Linux 的 ftp 站点（tsx-11.mit.edu），而且该站点至今仍然为广大 Linux 用户提供服务。他对 Linux 作出的最大贡献之一是提出并实现了 ext2 文件系统。该文件系统现已成为 Linux 世界中事实上的文件系统标准。最近他又推出了 ext3 文件系统。该系统大大提高了文件系统的稳定性和访问效率。作为对他的推崇，第 97 期（2002 年 5 月）的 Linux Journal 期刊将他作为了封面人物，并对他进行了采访。目前，他为 IBM Linux

[2] Linus Torvalds《Just for fun》第 84-88 页。

技术中心工作，并从事着有关 Linux 标准规范 LSB(Linux Standard Base)等方面的工作。

Linux 社区中另一位著名人物是 Alan Cox。他原工作于英国威尔士斯旺西大学(Swansea University College)。刚开始他特别喜欢玩电脑游戏，尤其是 MUD（Multi-User Dungeon or Dimension，多用户网络游戏）。在 90 年代早期 games.mud 新闻组的 posts 中你可以找到他发表的大量帖子。他甚至为此还写了一篇 MUD 的发展史(rec.games.mud 新闻组，1992 年 3 月 9 日，A history of MUD)。

由于 MUD 游戏与网络密切相关，慢慢地他开始对计算机网络着迷起来。为了玩游戏并提高电脑运行游戏的速度以及网络传输速度，他需要选择一个最为满意的操作平台。于是他开始接触各种类型的操作系统。由于没钱，即使是 MINIX 系统他也买不起。当 Linux 0.11 和 386BSD 发布时，他考虑良久总算购置了一台 386SX 电脑。由于 386BSD 需要数学协处理器支持，而采用 Intel 386SX CPU 的电脑是不带数学协处理器的，所以他安装了 Linux 系统。于是他开始学习带有免费源代码的 Linux，并开始对 Linux 系统产生了兴趣，尤其是有关网络方面的实现。在关于 Linux 单用户运行模式问题的讨论中，他甚至赞叹 Linux 实现得巧妙(beautifully)。

Linux 0.95 版发布之后，他开始为 Linux 系统编写补丁程序（修改程序）（记得他最早的两个补丁程序，都没有被 Linus 采纳），并成为 Linux 系统上 TCP/IP 网络代码的最早使用人之一。后来他逐渐加入了 Linux 的开发队伍，并成为维护 Linux 内核源代码的主要负责人之一，也可以说成为 Linux 社团中继 Linus 之后最为重要的人物。以后 Microsoft 公司曾经邀请他加盟，但他却干脆地拒绝了。从 2001 年开始，他负责维护 Linux 内核 2.4.x 的代码。而 Linus 主要负责开发最新开发版内核的研制(奇数版，比如 2.5.x 版)。

《内核黑客手册》（The Linux Kernel Hackers' Guide）一书的作者 Michael K. Johnson 也是最早接触 Linux 操作系统的人之一(从 0.97 版)。他还是著名 Linux 文档计划（Linux Document Project - LDP）的发起者之一。曾经在 Linux Journal 杂志社工作，现在 RedHat 公司工作。

Linux 系统并不是仅有这些中坚力量就能发展成今天这个样子的，还有许多计算机高手对 Linux 做出了极大的贡献，这里就不一一列举了。主要贡献者的具体名单可参见 Linux 内核中的 CREDITS 文件，其中以字母顺序列出了对 Linux 做出较大贡献的近 400 人的名单列表，包括他们的 email 地址和通信地址、主页以及主要贡献事迹等信息。

通过上述说明，我们可以对上述 Linux 的五大支柱归纳如下：

UNIX 操作系统 -- UNIX 于 1969 年诞生在 Bell 实验室。Linux 就是 UNIX 的一种克隆系统。UNIX 的重要性就不用多说了。

MINIX 操作系统 -- MINIX 操作系统也是 UNIX 的一种克隆系统，它于 1987 年由著名计算机教授 Andrew S. Tanenbaum 开发完成。由于 MINIX 系统的出现并且提供源代码(只能免费用于大学内)在全世界的大学中刮起了学习 UNIX 系统旋风。Linux 刚开始就是参照 MINIX 系统于 1991 年才开始开发。

GNU 计划-- 开发 Linux 操作系统，以及 Linux 上所用大多数软件基本上都出自 GNU 计划。Linux 只是操作系统的一个内核，没有 GNU 软件环境(比如说 bash shell)，则 Linux 将寸步难行。

POSIX 标准 -- 该标准在推动 Linux 操作系统以后朝着正规路上发展起着重要的作用。是 Linux 前进的灯塔。

INTERNET -- 如果没有 Intenet 网，没有遍布全世界的无数计算机黑客的无私奉献，那么 Linux 最多只能发展到 0.13(0.95)版的水平。

1.2 内容综述

本文将主要对 Linux 的早期内核 0.11 版进行详细描述和注释。Linux-0.11 版本是在 1991 年 12 月 8

日发布的。在发布时包括以下文件：

bootimage.Z	- 具有美国键盘代码的压缩启动映像文件；
rootimage.Z	- 以 1200kB 压缩的根文件系统映像文件；
linux-0.11.tar.Z	- 内核源代码文件。大小为 94KB，展开后也仅有 325KB；
as86.tar.Z	- Bruce Evans'二进制执行文件。是 16 位的汇编程序和装入程序；
INSTALL-0.11	- 更新过的安装信息文件。

bootimage.Z 和 rootimage.Z 是压缩的软盘映像（Image）文件。bootimage 是启动引导 Image 文件，其中主要包括内核执行代码。rootimage 是根文件系统，其中包括操作系统最起码的一些配置文件和命令程序。这两个盘合起来就相当于一张可启动的 DOS 盘片。as86.tar.Z 是 16 位汇编器链接程序软件包。linux-0.11.tar.Z 是压缩的 Linux 0.11 内核源代码。INSTALL-0.11 是 Linux 0.11 系统的简单安装说明文档。

目前除了原来的 rootimage.Z 文件，其他四个文件均能找到。不过作者已经利用 Internet 上的资源为 Linux 0.11 重新制作出了一个完全可以使用的 rootimage-0.11 根文件系统。并重新为其编译出能在 0.11 环境下使用的 gcc 1.40 编译器，配置出可用的实验开发环境。目前，这些文件均可以从 oldlinux.org 网站上下载。具体下载目录位置是：

- http://oldlinux.org/Linux.old/images/ 该目录中含有已经制作好的内核映像文件 bootimage 和根文件系统映像文件 rootimage。
- http://oldlinux.org/Linux.old/kernels/ 该目录中含有内核源代码程序，包括本书所描述的 Linux 0.11 内核源代码程序。
- http://oldlinux.org/Linux.old/bochs/ 该目录中含有已经设置好的运行在计算机仿真系统 bochs 下的 Linux 系统。
- http://oldlinux.org/Linux.old/Linux-0.11/ 该目录中含有可以在 Linux 0.11 系统中使用的其他一些工具程序和原来发布的一些安装说明说明文档。

本文主要详细分析 linux-0.11 内核中的所有源代码程序，对每个源程序文件都进行了详细注释，包括对 Makefile 文件的注释。分析过程主要是按照计算机启动过程进行的。因此分析的连贯性到初始化结束内核开始调用 shell 程序为止。其余的各个程序均针对其自身进行分析，没有连贯性，因此可以根据自己的需要进行阅读。但在分析时还是提供了一些应用实例。

所有的程序在分析过程中如果遇到作者认为是较难理解的语句时，将给出相关知识的详细介绍。比如，在阅读代码头一次遇到 C 语言内嵌汇编码时，将对 GNU C 语言的内嵌汇编语言进行较为详细的介绍；在遇到对中断控制器进行输入/输出操作时，将对 Intel 中断控制器（8259A）芯片给出详细的说明，并列出使用的命令和方法。这样做有助于加深对代码的理解，又能更好的了解所用硬件的使用方法，作者认为这种解读方法要比单独列出一章内容来总体介绍硬件或其他知识要效率高得多。

拿 Linux 0.11 版内核来“开刀”是为了提高我们认识 Linux 运行机理的效率。Linux-0.11 版整个内核源代码只有 325K 字节左右，其中包括的内容基本上都是 Linux 的精髓。而目前最新的 2.5.XX 版内核非常大，将近有 188 兆字节，即使你花一生的经历来阅读也未必能全部都看完。也许你要问“既然要从简入手，为什么不分析更小的 Linux 0.01 版内核源代码呢？它只有 240K 字节左右”主要原因是因为 0.01 版的内核代码有太多的不足之处，甚至还没有包括对软盘的驱动程序，也没有很好地涉及数学协处理器的使用以及对登陆程序的说明。并且其引导启动程序的结构也与目前的版本不太一样，而 0.11 版的引导启动程序结构则与现在的基本上是一样的。另外一个原因是可以找到 0.11 版早期的已经编译制作好的内核映像文件(bootimage)，可以用来进行引导演示。如果再配上简单的根文件系统映像文件(rootimage)，那么它就可以进行正常的运行了。

拿 Linux 0.11 版进行学习也有不足之处。比如该内核版本中尚不包括有关专门的进程等待队列、TCP/IP 网络等方面的一些当前非常重要的代码，对内存的分配和使用与现今的内核也有所区别。但好在 Linux 中的网络代码基本上是自成一体的，与内核机制关系不是非常大，因此可以在了解了 Linux 工作的基本原理之后再去分析这些代码。

本文对 Linux 内核中所有的代码都进行了说明。为了保持结构的完整性，对代码的说明是以内核中源代码的组成结构来进行的，基本上是以每个源代码中的目录为一章内容进行介绍。介绍的源程序文件的次序可参见前面的文件列表索引。整个 Linux 内核源代码的目录结构如下列表 1.1 所示。所有目录结构均是以 linux 为当前目录。

列表 1-1 Linux/目录

名称	大小	最后修改日期(GMT)	说明
boot/		1991-12-05 22:48:49	
fs/		1991-12-08 14:08:27	
include/		1991-09-22 19:58:04	
init/		1991-12-05 19:59:04	
kernel/		1991-12-08 14:08:00	
lib/		1991-12-08 14:10:00	
mm/		1991-12-08 14:08:21	
tools/		1991-12-04 13:11:56	
Makefile	2887 bytes	1991-12-06 03:12:46	

本书内容可以分为三个部分。第 1 章至第 4 章是描述内核引导启动和 32 位运行方式的准备阶段，作为学习内核的初学者应该全部进行阅读。第二部分从第 5 章到第 10 章是内核代码的主要部分。其中第 5 章内容可以作为阅读本部分后续章节的索引来进行。第 11 章到第 13 章是第三部分内容，可以作为阅读第二部分代码的参考信息。

第 2 章概要地描述了 Linux 操作系统的体系结构、内核源代码文件放置的组织结构以及每个文件大致功能。还介绍了 Linux 对物理内存的使用分配方式、内核的几种堆栈及其使用方式和虚拟线性地址的使用分配。最后开始注释内核程序包中 Linux/目录下的所看到的第一个文件，也即内核代码的总体 Makefile 文件的内容。该文件是所有内核源程序的编译管理配置文件，供编译管理工具软件 make 使用。

第 3 章将详细注释 boot/目录下的三个汇编程序，其中包括磁盘引导程序 bootsect.s、获取 BIOS 中参数的 setup.s 汇编程序和 32 位运行启动代码程序 head.s。这三个汇编程序完成了把内核从块设备上引导加载到内存的工作，并对系统配置参数进行探测，完成了进入 32 位保护模式运行之前的所有工作。为内核系统执行进一步的初始化工作做好了准备。

第 4 章主要介绍 init/目录中内核系统的初始化程序 main.c。它是内核完成所有初始化工作并进入正常运行的关键地方。在完成了系统所有的初始化工作后，创建了用于 shell 的进程。在介绍该程序时将需要查看其所调用的其他程序，因此对后续章节的阅读可以按照这里调用的顺序进行。由于内存管理程序的函数在内核中被广泛使用，因此该章内容应该最先选读。当你能真正看懂直到 main.c 程序为止的所有程序时，你应该已经对 Linux 内核有了一定的了解，可以说已经有一半入门了☺，但你还需要对文件系统、系统调用、各种驱动程序等进行更深一步的阅读。

第 5 章主要介绍 kenel/目录中的所有程序。其中最重要的部分是进程调度函数 schedule()、sleep_on()

函数和有关系统调用的程序。此时你应该已经对其中的一些重要程序有所了解。

第 6 章对 kernel/dev_blk/目录中的块设备程序进行了注释说明。该章主要含有硬盘、软盘等块设备的驱动程序，主要用来与文件系统和高速缓冲区打交道，含有较多与硬件相关的内容。因此，在阅读这章内容时需参考一些硬件资料。最好能首先浏览一下文件系统的章节。

第 7 章对 kernel/dev_chr/目录中的字符设备驱动程序进行注释说明。这一章中主要涉及串行线路驱动程序、键盘驱动程序和显示器驱动程序。这些驱动程序构成了 0.11 内核支持的串行终端和控制台终端设备。因此本章也含有较多与硬件有关的内容。在阅读时需要参考一下相关硬件的书籍。

第 8 章介绍 kernel/math/目录中的数学协处理器的仿真程序。由于本书所注释的内核版本，还没有真正开始支持协处理器，因此本章的内容较少，也比较简单。只需有一般性的了解即可。

第 9 章介绍内核源代码 fs/目录中的文件系统程序，在看这章内容时建议你能够暂停一下而去阅读 Andrew S. Tanenbaum 的《操作系统设计与实现》一书中有关 MINIX 文件系统的章节，因为最初的 Linux 系统是只支持 MINIX 一种文件系统，Linux 0.11 版也不例外。

第 10 章解说 mm/目录中的内存管理程序。要透彻地理解这方面的内容，需要对 Intel 80X86 微处理器的保护模式运行方式有足够的理解，因此本章在适当的地方包含有较为完整的有关 80X86 保护模式运行方式的说明，这些知识基本上都可以参考 Intel 80386 程序员编程手册(Intel 80386 Programmer's Reference Manual)。但在此章中，以源代码中的运用实例为对象进行解说，应该可以更好地理解它的工作原理。

现有的 Linux 内核分析书籍都缺乏对内核头文件的描述，因此对于一个初学者来讲，在阅读内核程序时会碰到许多障碍。本书的第 11 章对 include/目录中的所有头文件进行了详细说明，基本上对每一个定义、每一个常量或数据结构都进行了详细注释。为了便于在阅读时参考查阅，本书在附录中还对一些经常要用到的重要的数据结构和变量进行了归纳注释，但这些内容实际上都能在这一章中找到。虽然该章内容主要是为阅读其他章节中的程序作参考使用的，但是若想彻底理解内核的运行机制，仍然需要了解这些头文件中的许多细节。

第 12 章介绍了 Linux 0.11 版内核源代码 lib/目录中的所有文件。这些库函数文件主要向编译系统等系统程序提供了接口函数，对以后理解系统软件会有较大的帮助。由于这个版本较低，所以这里的内容并不是很多，可以很快地看完。这也是我们为什么选择 0.11 版的原因之一。

第 13 章介绍 tools/目录下的 build.c 程序。这个程序并不会包括在编译生成的内核映像(image)文件中，它仅用于将内核中的磁盘引导程序块与其他主要内核模块连接成一个完整的内核映像（kernel image）文件。

第 14 章介绍了学习内核源代码时的实验环境以及实验方法。主要介绍了在 Bochs 仿真系统下使用和编译 Linux 内核的方法以及磁盘镜象文件的制作方法。还说明了如何修改 Linux 0.11 源代码的语法使其能在 RedHat 9 系统下顺利编译出正确的内核来。

最后是附录和索引。附录中给出了 Linux 内核中的一些常数定义和基本数据结构定义，以及保护模式运行机制的简明描述。

为了便于查阅，在本书的附录中还单独列出了内核中要用到的有关 PC 机硬件方面的信息。在参考文献中，我们仅给出了在阅读源代码时可以参考的书籍、文章等信息，并没有包罗万象地给出一大堆的繁杂凌乱的文献列表。比如在引用 Linux 文档项目 LDP（Linux Document Project）中的文件时，我们会明确地列出具体需要参考哪一篇 HOWTO 文章，而并不是仅仅给出 LDP 的网站地址了事。

Linus 在最初开发 Linux 操作系统内核时，主要参考了 3 本书。一本是 M. J. Bach 著的《UNIX 操作系统设计》，该书描述了 UNIX System V 内核的工作原理和数据结构。Linus 使用了该书中很多函数的算法，Linux 内核源代码中很多重要函数的名称都取自该书。因此，在阅读本书时，这是一本必不可少的内核工作原理方面的参考书籍。另一本是 John H. Crawford 等编著的《Programming the 80386》，是讲解 80x86 下保护模式编程方法的好书。还有一本就是 Andrew S.Tanenbaum 著的《MINIX 操作系统设计与实

现》一书的第 1 版。Linus 主要使用了该书中描述的 MINIX 文件系统 1.0 版，而且在早期的 Linux 内核中也仅支持该文件系统，所以在阅读本书有关文件系统一章内容时，文件系统的工作原理方面的知识完全可以从 Tanenbaum 的书中获得。

在对每个程序进行解说时，我们首先简单说明程序的主要用途和目的、输入输出参数以及与其他程序的关系，然后列出程序的完整代码并在其中对代码进行详细注释，注释时对原程序代码或文字不作任何方面的改动或删除，因为 C 语言是一种英语类语言，程序中原有的少量英文注释对常数符号、变量名等也提供了不少有用的信息。在代码之后是对程序更为深入的解剖，并对代码中出现的一些语言或硬件方面的相关知识进行说明。如果在看完这些信息后回头再浏览一遍程序，你会有更深一层的体会。

对于阅读本书所需要的一些基本概念知识的介绍都散布在各个章节相应的地方，这样做主要是为了能够方便的找到，而且在结合源代码阅读时，对一些基本概念能有更深的理解。

最后要说明的是当你已经完全理解了本文所解说的一切时，并不代表你已经成为一个 Linux 行家了，你只是刚刚踏上 Linux 的征途，具有了一定的成为一个 Linux GURU 的初步知识。这时你应该去阅读更多的源代码，最好是循序渐进地从 1.0 版本开始直到最新的正在开发中的奇数编号的版本。在撰写这本书时最新的 Linux 内核是 2.5.44 版。当你能快速理解这些开发中的最新版本甚至能提出自己的建议和补丁（patch）程序时，我也甘拜下风了☺。

1.3 本章小结

首先阐述了 Linux 诞生和发展不可缺少的五个支柱：UNIX 最初的开放原代码版本为 Linux 提供了实现的基本原理和算法、Richard Stallman 的 GNU 计划为 Linux 系统提供了丰富且免费的各种实用工具、POSIX 标准的出现为 Linux 提供了实现与标准兼容系统的参考指南、A.S.T 的 MINIX 操作系统为 Linux 的诞生起到了不可忽缺的参考、Internet 是 Linux 成长和壮大的必要环境。最后本章概述了书中的基本内容。

第2章 Linux 内核体系结构

本章首先概要介绍了 Linux 内核的编制模式和体系结构，然后详细描述了 Linux 内核源代码目录中组织形式以及子目录中各个代码文件的主要功能以及基本调用的层次关系。接下来就直接切入正题，从内核源文件 Linux/目录下的第一个文件 Makefile 开始，对每一行代码进行详细注释说明。本章内容可以看作是对内核源代码的总结概述，可以作为阅读后续章节的参考信息。

一个完整可用的操作系统主要由 4 部分组成：硬件、操作系统内核、操作系统服务和用户应用程序，见图 2-1 所示。用户应用程序是指那些字处理程序、Internet 浏览器程序或用户自行编制的各种应用程序；操作系统服务程序是指那些向用户提供的服务被看作是操作系统部分功能的程序。在 Linux 操作系统上，这些程序包括 X 窗口系统、shell 命令解释系统以及那些内核编程接口等系统程序；操作系统内核程序即是本书所感兴趣的部分，它主要用于对硬件资源的抽象和访问调度。

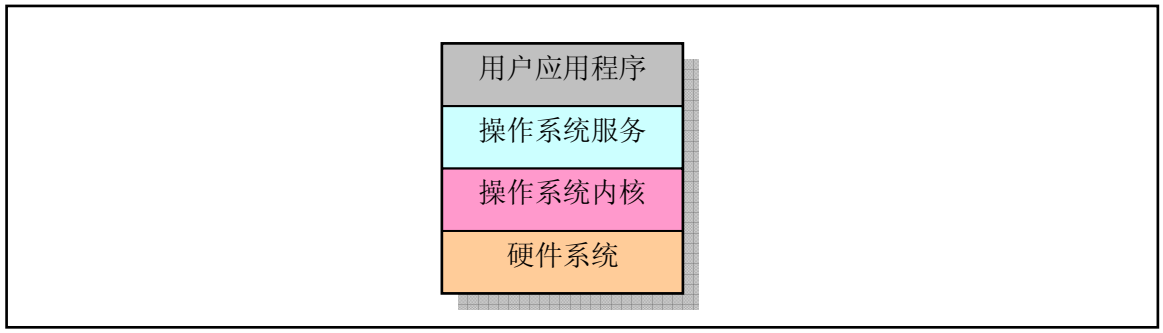

图 2-1 操作系统组成部分。

Linux 内核的主要用途就是为了与计算机硬件进行交互，实现对硬件部件的编程控制和接口操作，调度对硬件资源的访问，并为计算机上的用户程序提供一个高级的执行环境和对硬件的虚拟接口。
在本章内容中，我们首先基于 Linux 0.11 版的内核源代码，简明地描述 Linux 内核的基本体系结构、主要构成模块。然后对源代码中出现的几个重要数据结构进行说明。最后描述了构建 Linux 0.11 内核编译实验环境的方法。

2.1 Linux 内核模式

目前，操作系统内核的结构模式主要可分为整体式的单内核模式和层次式的微内核模式。而本书所注释的 Linux 0.11 内核，则是采用了单内核模式。单内核模式的主要优点是内核代码结构紧凑、执行速度快，不足之处主要是层次结构性不强。

在单内核模式的系统中，操作系统所提供服务的流程为：应用主程序使用指定的参数值执行系统调用指令(int x80)，使 CPU 从用户态（User Mode）切换到核心态（Kernel Model），然后操作系统根据具体的参数值调用特定的系统调用服务程序，而这些服务程序则根据需要再调用底层的一些支持函数以完成特定的功能。在完成了应用程序所要求的服务后，操作系统又使 CPU 从核心态切换回用户态，从而返回到应用程序中继续执行后面的指令。因此概要地讲，单内核模式的内核也可粗略地分为三个层次：调用

服务的主程序层、执行系统调用的服务层和支持系统调用的底层函数。见图 2-2 所示。

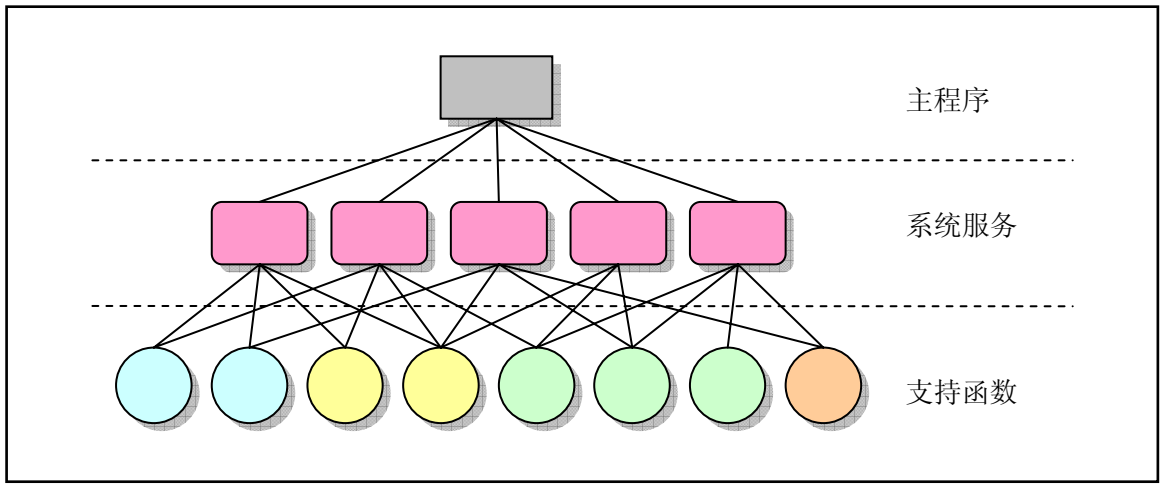

图 2-2 单内核模式的简单结构模型

2.2 Linux 内核系统体系结构

Linux 内核主要由 5 个模块构成，它们分别是：进程调度模块、内存管理模块、文件系统模块、进程间通信模块和网络接口模块。

进程调度模块用来负责控制进程对 CPU 资源的使用。所采取的调度策略是各进程能够公平合理地访问 CPU，同时保证内核能及时地执行硬件操作。内存管理模块用于确保所有进程能够安全地共享机器主内存区，同时，内存管理模块还支持虚拟内存管理方式，使得 Linux 支持进程使用比实际内存空间更多的内存容量。并可以利用文件系统把暂时不用的内存数据块交换到外部存储设备上去，当需要时再交换回来。文件系统模块用于支持对外部设备的驱动和存储。虚拟文件系统模块通过向所有的外部存储设备提供一个通用的文件接口，隐藏了各种硬件设备的不同细节。从而提供并支持与其他操作系统兼容的多种文件系统格式。进程间通信模块子系统用于支持多种进程间的信息交换方式。网络接口模块提供对多种网络通信标准的访问并支持许多网络硬件。

这几个模块之间的依赖关系见图 2-3 所示。其中的连线代表它们之间的依赖关系，虚线和虚框部分表示 Linux 0.11 中还未实现的部分（从 Linux 0.95 版才开始逐步实现虚拟文件系统，而网络接口的支持到 0.96 版才有）。

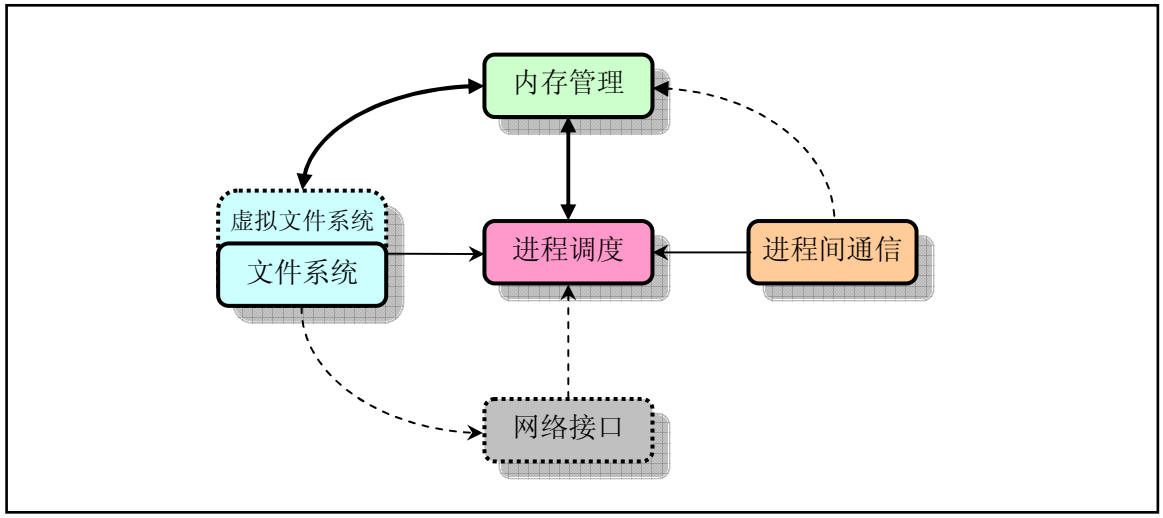

图 2-3Linux 内核系统模块结构及相互依赖关系

由图可以看出，所有的模块都与进程调度模块存在依赖关系。因为它们都需要依靠进程调度程序来挂起（暂停）或重新运行它们的进程。通常，一个模块会在等待硬件操作期间被挂起，而在操作完成后才可继续运行。例如，当一个进程试图将一数据块写到软盘上去时，软盘驱动程序就可能在启动软盘旋转期间将该进程置为挂起等待状态，而在软盘进入到正常转速后再使得该进程能继续运行。另外 3 个模块也是由于类似的原因而与进程调度模块存在依赖关系。

其他几个依赖关系有些不太明显，但同样也很重要。进程调度子系统需要使用内存管理器来调整一特定进程所使用的物理内存空间。进程间通信子系统则需要依靠内存管理器来支持共享内存通信机制。这种通信机制允许两个进程访问内存的同一个区域以进行进程间信息的交换。虚拟文件系统也会使用网络接口来支持网络文件系统（NFS），同样也能使用内存管理子系统来提供内存虚拟盘（ramdisk）设备。而内存管理子系统也会使用文件系统来支持内存数据块的交换操作。

若从单内核模式结构模型出发，我们还可以根据 Linux 0.11 内核源代码的结构将内核主要模块绘制成图 2-4 所示的框图结构。

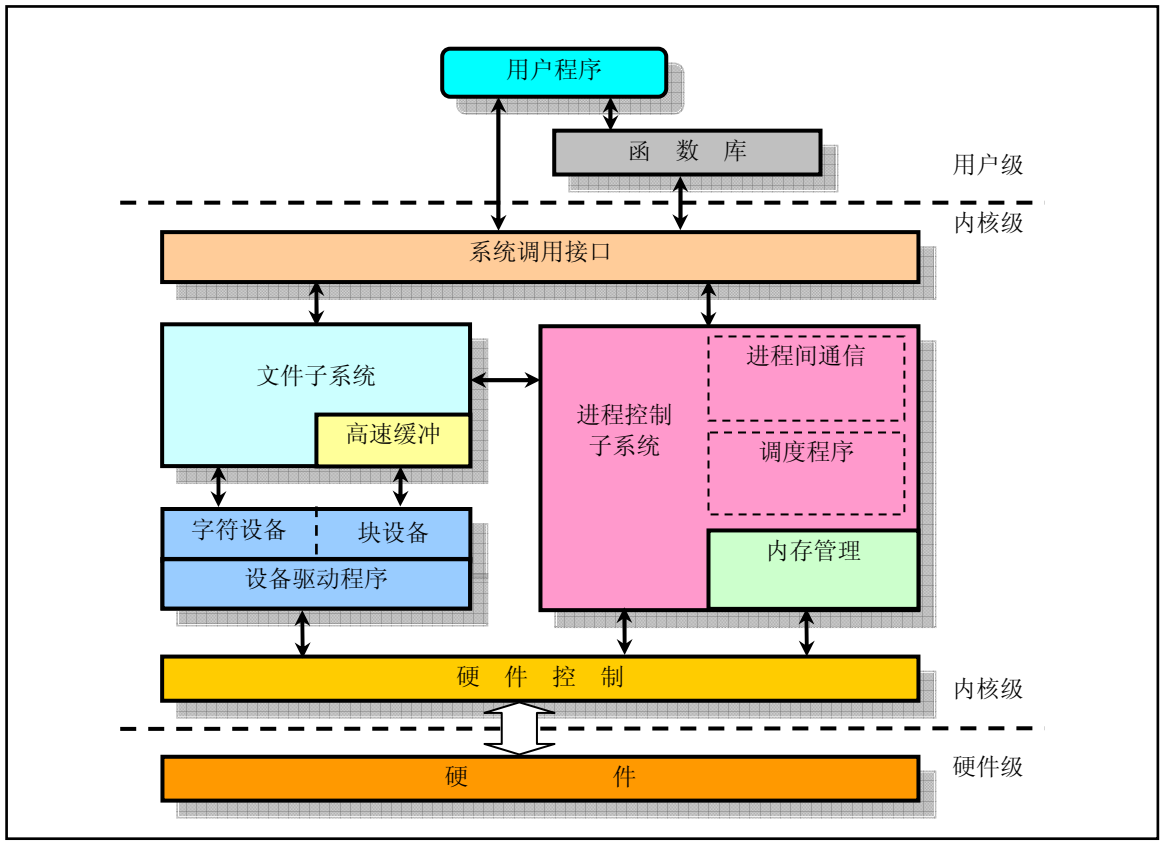

图 2-4 内核结构框图

其中内核级中的几个方框，除了硬件控制方框以外，其他粗线方框分别对应内核源代码的目录组织结构。

除了这些图中已经给出的依赖关系以外，所有这些模块还会依赖于内核中的通用资源。这些资源包括内核所有子系统都会调用的内存分配和收回函数、打印警告或出错信息函数以及一些系统调试函数。

2.3 中断机制

在使用 80X86 组成的 PC 机中，采用了两片 8259A 可编程中断控制芯片。每片可以管理 8 个中断源。通过多片的级联方式，能构成最多管理 64 个中断向量的系统。在 PC/AT 系列兼容机中，使用了两片 8259A 芯片，共可管理 15 级中断向量。其级连示意图见图 2-5 所示。其中从芯片的 INT 引脚连接到主芯片的 IR2 引脚上。主 8259A 芯片的端口基地址是 0x20，从芯片是 0xA0。

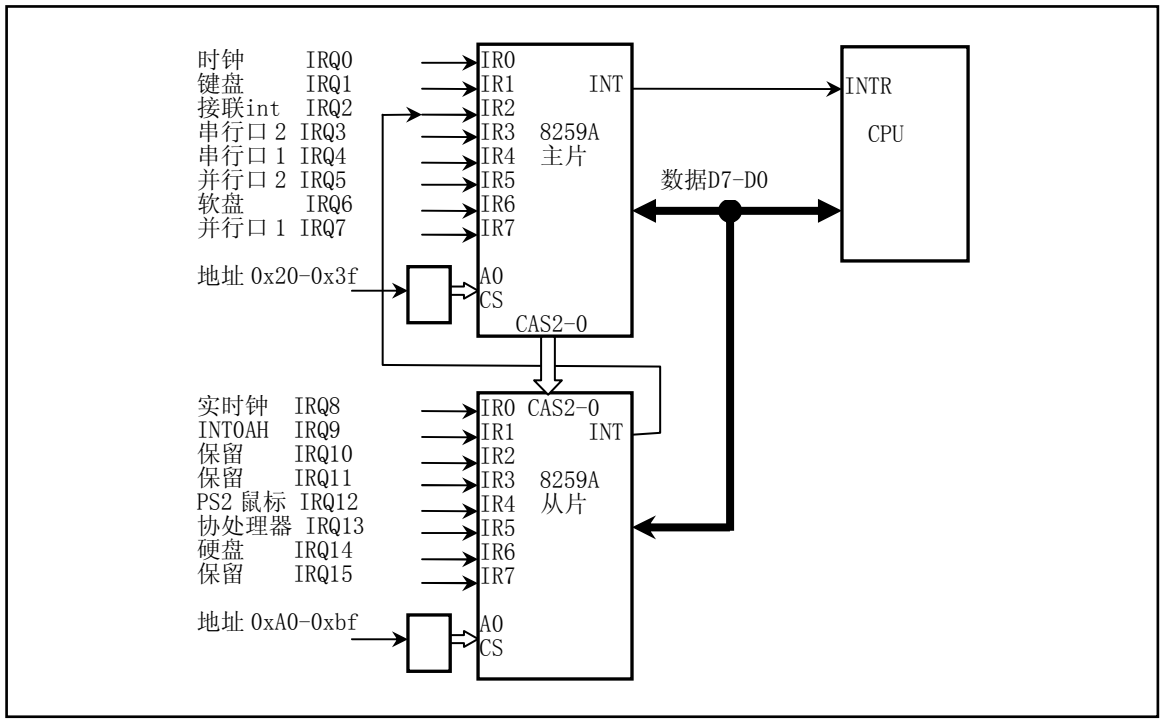

图 2-5 PC/AT 微机级连式 8259 控制系统

在总线控制器控制下，8259A 芯片可以处于编程状态和操作状态。编程状态是 CPU 使用 IN 或 OUT 指令对 8259A 芯片进行初始化编程的状态。一旦完成了初始化编程，芯片即进入操作状态，此时芯片即可随时响应外部设备提出的中断请求（IRQ0 – IRQ15）。通过中断判优选择，芯片将选中当前最高优先级的中断请求作为中断服务对象，并通过 CPU 引脚 INT 通知 CPU 外中断请求的到来，CPU 响应后，芯片从数据总线 D7-D0 将编程设定的当前服务对象的中断号送出，CPU 由此获取对应的中断向量值，并执行中断服务程序。

对于 Linux 内核来说，中断信号通常分为两类：硬件中断和软件中断(异常)。每个中断是由 0-255 之间的一个数字来标识。对于中断 int0--int31(0x00--0x1f)，每个中断的功能由 Intel 公司固定设定或保留用, 属于软件中断，但 Intel 公司称之为异常。因为这些中断是在 CPU 执行指令时探测到异常情况而引起的。通常还可分为故障(Fault)和陷阱(traps)两类。中断 int32--int255 (0x20--0xff)可以由用户自己设定。在 Linux 系统中，则将 int32--int47(0x20--0x2f)对应于 8259A 中断控制芯片发出的硬件中断请求信号 IRQ0-IRQ15，并把程序编程发出的系统调用(system_call)中断设置为 int128(0x80)。

在系统初始化时，内核在 head.s 程序中首先使用一个哑中断向量（中断描述符）对中断描述符表（Interrupt Descriptor Table - IDT）中所有 256 个描述符进行了默认设置（boot/head.s，78）。这个哑中断向量指向一个默认的“无中断”处理过程（boot/head.s，150）。当发生了一个中断而又没有重新设置过该中断向量时就会显示信息“未知中断（Unknown interrupt)”。因此，对于系统需要使用的一些中断，内核必须在其继续初始化的处理过程中（init/main.c）重新设置这些中断的中断描述符项，让它们指向对应的实际处理过程。通常，硬件异常中断处理过程（int0 --int 31）都在 traps.c 的初始化函数中进行了重新设置（kernl/traps.c，181）。而系统调用中断 int128 则在调度程序初始化函数中进行了重新设置（kernel/sched.c，385）。

2.4 系统定时

在 Linux 0.11 内核中，PC 机的可编程定时芯片 Intel 8253 被设置成每隔 10 毫秒就发出一个时钟中断

（IRQ0）信号。这个时间节拍就是系统运行的脉搏，我们称之为 1 个系统滴答。因此每经过 1 个滴答系统就会调用一次时钟中断处理程序（timer_interrupt）。该处理程序主要用来通过 jiffies 变量来累计自系统启动以来经过的时钟滴答数。每当发生一次时钟中断该值就增 1。然后从被中断程序的段选择符中取得当前特权级 CPL 作为参数调用 do_timer()函数。

do_timer()函数则根据特权级对当前进程运行时间作累计。如果 CPL=0，则表示进程是运行在内核态时被中断，因此把进程的内核运行时间统计值 stime 增 1，否则把进程用户态运行时间统计值增 1。如果程序添加过定时器，则对定时器链表进行处理。若某个定时器时间到（递减后等于 0），则调用该定时器的处理函数。然后对当前进程运行时间进行处理，把当前进程运行时间片减 1。如果此时当前进程时间片还大于 0，表示其时间片还没有用完，于是就退出 do_timer()继续运行当前进程。如果此时进程时间片已经递减为 0，表示该进程已经用完了此次使用 CPU 的时间片，于是程序就会根据被中断程序的级别来确定进一步处理的方法。若被中断的当前进程是工作在用户态的（特权级别大于 0），则 do_timer()就会调用调度程序 schedule()切换到其他进程去运行。如果被中断的当前进程工作在内核态，也即在内核程序中运行时被中断，则 do_timer()会立刻退出。因此这样的处理方式决定了 Linux 系统在内核态运行时不会被调度程序切换。进程在内核态程序中运行时是不可抢占的[1]，但当处于用户态程序中运行时则是可以被抢占的。

2.5 Linux 进程控制

程序是一个可执行的文件，而进程（process）是一个执行中的程序实例。利用分时技术，在 Linux 操作系统上同时可以运行多个进程。分时技术的基本原理是把 CPU 的运行时间划分成一个个规定长度的时间片(time slice)，让每个进程在一个时间片内运行。当进程的时间片用完时系统就利用调度程序切换到另一个进程去运行。因此实际上对于具有单个 CPU 的机器来说某一时刻只能运行一个进程。但由于每个进程运行的时间片很短（例如 15 个系统滴答=150 毫秒），所以表面看来好象所有进程在同时运行着。

对于 Linux 0.11 内核来讲，系统最多可有 64 个进程同时存在。除了第一个进程是“手工”建立以外，其余的都是进程使用系统调用 fork 创建的新进程，被创建的进程称为子进程（child process），创建者，则称为父进程（parent process）。内核程序使用进程标识号（process ID，pid）来标识每个进程。进程由可执行的指令代码、数据和堆栈区组成。进程中的代码和数据部分分别对应一个执行文件中的代码段、数据段。每个进程只能执行自己的代码和访问自己的数据及堆栈区。进程之间的通信需要通过系统调用来进行。对于只有一个 CPU 的系统，在某一时刻只能有一个进程正在运行。内核通过调度程序分时调度各个进程运行。

Linux 系统中，一个进程可以在内核态（kernel mode）或用户态（user mode）下执行，因此，Linux 内核堆栈和用户堆栈是分开的。用户堆栈用于进程在用户态下临时保存调用函数的参数、局部变量等数据。内核堆栈则含有内核程序执行函数调用时的信息。

2.5.1 任务数据结构

内核程序通过进程表对进程进行管理，每个进程在进程表中占有一项。在 Linux 系统中，进程表项是一个 task_struct 任务结构指针。任务数据结构定义在头文件 include/linux/sched.h 中。有些书上称其为进程控制块 PCB（Process Control Block）或进程描述符 PD（Processor Descriptor）。其中保存着用于控制和管理进程的所有信息。主要包括进程当前运行的状态信息、信号、进程号、父进程号、运行时间累计值、正在使用的文件和本任务的局部描述符以及任务状态段信息。该结构每个字段的具体含义如下所示。

[1] 从 Linux 2.4 内核起，Robert Love 开发出了可抢占式的内核升级包。这使得在内核空间低优先级的进程也能被高优先级的进程抢占，从而能使系统响应性能最大提高 200%。参见 Robert Love 编著的《Linux 内核开发》一书。

```
struct task_struct {
        long state                      //任务的运行状态（-1 不可运行，0 可运行(就绪)，>0 已停止）。
        long counter                    // 任务运行时间计数(递减)（滴答数），运行时间片。
        long priority                   // 运行优先数。任务开始运行时 counter=priority，越大运行越长。
        long signal                     // 信号。是位图，每个比特位代表一种信号，信号值=位偏移值+1。
        struct sigaction sigaction[32]  // 信号执行属性结构，对应信号将要执行的操作和标志信息。
        long blocked                    // 进程信号屏蔽码（对应信号位图）。
        int exit_code                   // 任务执行停止的退出码，其父进程会取。
        unsigned long start_code        // 代码段地址。
        unsigned long end_code          // 代码长度（字节数）。
        unsigned long end_data          // 代码长度 + 数据长度（字节数）。
        unsigned long brk               // 总长度（字节数）。
        unsigned long start_stack       // 堆栈段地址。
        long pid                        // 进程标识号(进程号)。
        long father                     // 父进程号。
        long pgrp                       // 父进程组号。
        long session                    // 会话号。
        long leader                     // 会话首领。
        unsigned short uid              // 用户标识号（用户 id）。
        unsigned short euid             // 有效用户 id。
        unsigned short suid             // 保存的用户 id。
        unsigned short gid              // 组标识号（组 id）。
        unsigned short egid             // 有效组 id。
        unsigned short sgid             // 保存的组 id。
        long alarm                      // 报警定时值（滴答数）。
        long utime                      // 用户态运行时间（滴答数）。
        long stime                      // 系统态运行时间（滴答数）。
        long cutime                     // 子进程用户态运行时间。
        long cstime                     // 子进程系统态运行时间。
        long start_time                 // 进程开始运行时刻。
        unsigned short used_math        // 标志：是否使用了协处理器。
        int tty                         // 进程使用 tty 的子设备号。-1 表示没有使用。
        unsigned short umask            // 文件创建属性屏蔽位。
        struct m_inode * pwd            // 当前工作目录 i 节点结构。
        struct m_inode * root           // 根目录 i 节点结构。
        struct m_inode * executable     // 执行文件 i 节点结构。
        unsigned long close_on_exec     // 执行时关闭文件句柄位图标志。（参见 include/fcntl.h）
        struct file * filp[NR_OPEN]     // 文件结构指针表，最多 32 项。表项号即是文件描述符的值。
        struct desc_struct ldt[3]   // 任务局部描述符表。0-空，1-代码段 cs，2-数据和堆栈段 ds&ss。
        struct tss_struct tss           // 进程的任务状态段信息结构。
};
```

当一个进程在执行时，CPU 的所有寄存器中的值、进程的状态以及堆栈中的内容被称为该进程的上下文。当内核需要切换（switch）至另一个进程时，它就需要保存当前进程的所有状态，也即保存当前进程的上下文，以便在再次执行该进程时，能够恢复到切换时的状态执行下去。在 Linux 中，当前进程上下文均保存在进程的任务数据结构中。在发生中断时，内核就在被中断进程的上下文中，在内核态下执行中断服务例程。但同时会保留所有需要用到的资源，以便中断服务结束时能恢复被中断进程的执行。

2.5.2 进程运行状态

一个进程在其生存期内，可处于一组不同的状态下，称为进程状态。见图 2-6 所示。进程状态保存

在进程任务结构的 state 字段中。当进程正在等待系统中的资源而处于等待状态时，则称其处于睡眠等待状态。在 Linux 系统中，睡眠等待状态被分为可中断的和不可中断的等待状态。

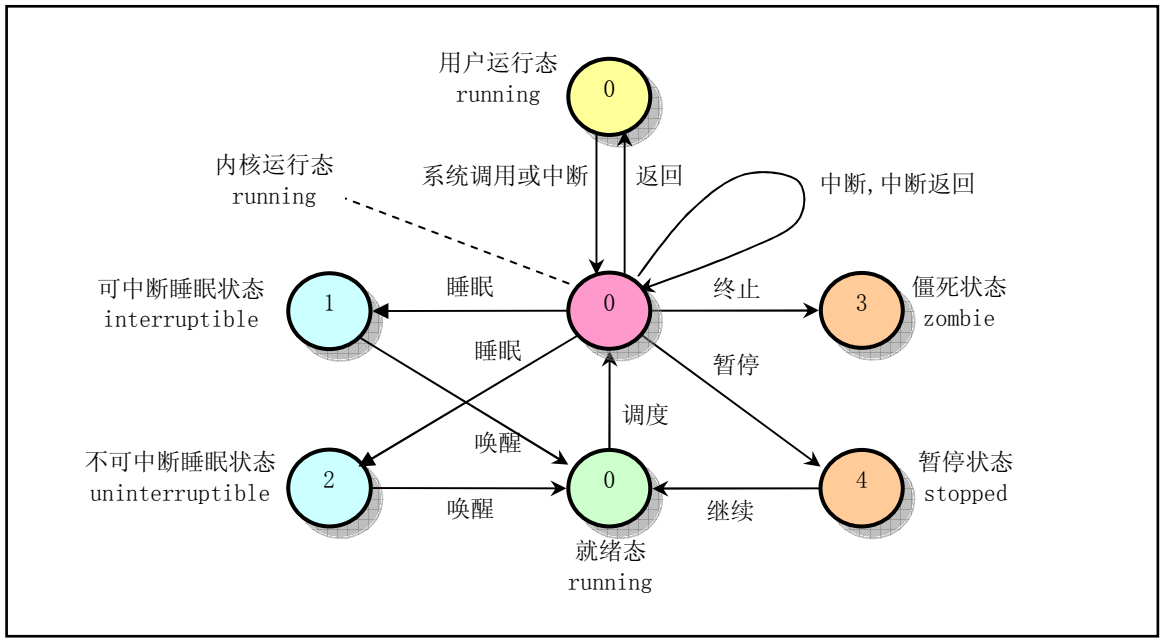

图 2-6 进程状态及转换关系

◆运行状态（TASK_RUNNING）

当进程正在被 CPU 执行，或已经准备就绪随时可由调度程序执行，则称该进程为处于运行状态（running）。若此时进程没有被 CPU 执行，则称其处于就绪运行状态。见图 2-6 中标号为 0 的状态。进程可以在内核态运行，也可以在用户态运行。当一个进程在内核代码中运行时，我们称其处于内核运行态，或简称为内核态；当一个进程正在执行用户自己的代码时，我们称其为处于用户运行态（用户态）。当系统资源已经可用时，进程就被唤醒而进入准备运行状态，该状态称为就绪态。这些状态（图中中间一列）在内核中表示方法相同，都被成为处于 TASK_RUNNING 状态。

◆可中断睡眠状态（TASK_INTERRUPTIBLE）

当进程处于可中断等待状态时，系统不会调度该进程执行。当系统产生一个中断或者释放了进程正在等待的资源，或者进程收到一个信号，都可以唤醒进程转换到就绪状态（运行状态）。

◆不可中断睡眠状态（TASK_UNINTERRUPTIBLE）

与可中断睡眠状态类似。但处于该状态的进程只有被使用 wake_up()函数明确唤醒时才能转换到可运行的就绪状态。

◆暂停状态（TASK_STOPPED）

当进程收到信号 SIGSTOP、SIGTSTP、SIGTTIN 或 SIGTTOU 时就会进入暂停状态。可向其发送 SIGCONT 信号让进程转换到可运行状态。在 Linux 0.11 中，还未实现对该状态的转换处理。处于该状态的进程将被作为进程终止来处理。

◆僵死状态（TASK_ZOMBIE）

当进程已停止运行，但其父进程还没有询问其状态时，则称该进程处于僵死状态。

当一个进程的运行时间片用完，系统就会使用调度程序强制切换到其他的进程去执行。另外，如果进程在内核态执行时需要等待系统的某个资源，此时该进程就会调用 sleep_on()或 sleep_on_interruptible()自愿地放弃 CPU 的使用权，而让调度程序去执行其他进程。进程则进入睡眠状态

（TASK_UNINTERRUPTIBLE 或 TASK_INTERRUPTIBLE）。

只有当进程从“内核运行态”转移到“睡眠状态”时，内核才会进行进程切换操作。在内核态下运行的进程不能被其他进程抢占，而且一个进程不能改变另一个进程的状态。为了避免进程切换时造成内核数据错误，内核在执行临界区代码时会禁止一切中断。

2.5.3 进程初始化

在 boot/目录中，引导程序把内核从磁盘上加载到内存中，并让系统进入保护模式下运行后，就开始执行系统初始化程序 init/main.c。该程序首先确定如何分配使用系统物理内存，然后调用内核各部分的初始化函数分别对内存管理、中断处理、块设备和字符设备、进程管理以及硬盘和软盘硬件进行初始化处理。在完成了这些操作之后，系统各部分已经处于可运行状态。此后程序把自己“手工”移动到任务 0（进程 0）中运行，并使用 fork()调用首次创建出进程 1。在进程 1 中程序将继续进行应用环境的初始化并执行 shell 登录程序。而原进程 0 则会在系统空闲时被调度执行，此时任务 0 仅执行 pause()系统调用，并又会调用调度函数。

“移动到任务 0 中执行”这个过程由宏 move_to_user_mode（include/asm/system.h）完成。它把 main.c 程序执行流从内核态（特权级 0）移动到了用户态（特权级 3）的任务 0 中继续运行。在移动之前，系统在对调度程序的初始化过程（sched_init()）中，首先对任务 0 的运行环境进行了设置。这包括人工预先设置好任务 0 数据结构各字段的值（include/linux/sched.h）、在全局描述符表中添入任务 0 的任务状态段（TSS）描述符和局部描述符表（LDT）的段描述符，并把它们分别加载到任务寄存器 tr 和局部描述符表寄存器 ldtr 中。

这里需要强调的是，内核初始化是一个特殊过程，内核初始化代码也即是任务 0 的代码。从任务 0 数据结构中设置的初始数据可知，任务 0 的代码段和数据段的基址是 0、段限长是 640KB。而内核代码段和数据段的基址是 0、段限长是 16MB，因此任务 0 的代码段和数据段分别包含在内核代码段和数据段中。内核初始化程序 main.c 也即是任务 0 中的代码，只是在移动到任务 0 之前系统正以内核态特权级 0 运行着 main.c 程序。宏 move_to_user_mode 的功能就是把运行特权级从内核态的 0 级变换到用户态的 3 级，但是仍然继续执行原来的代码指令流。

在移动到任务 0 的过程中，宏 move_to_user_mode 使用了中断返回指令造成特权级改变的方法。该方法的主要思想是在堆栈中构筑中断返回指令需要的内容，把返回地址的段选择符设置成任务 0 代码段选择符，其特权级为 3。此后执行中断返回指令 iret 时将导致系统 CPU 从特权级 0 跳转到外层的特权级 3 上运行。参见图 2-7 所示的特权级发生变化时中断返回堆栈结构示意图。

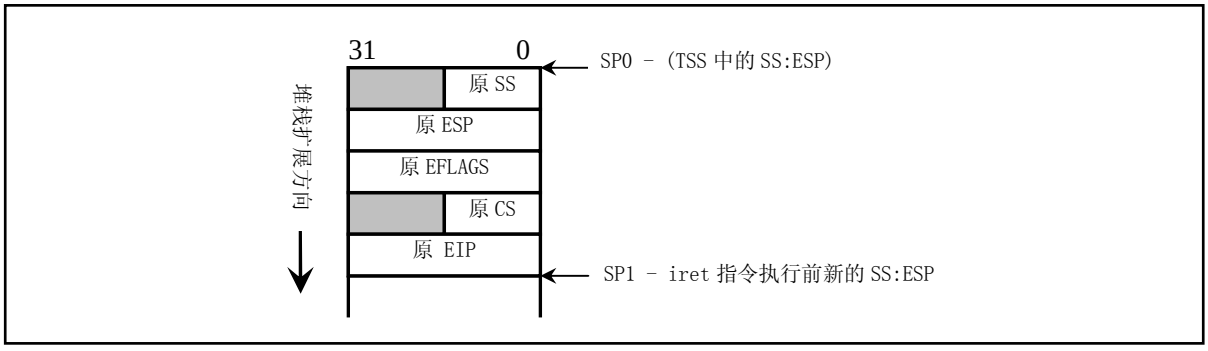

图 2-7 特权级发生变化时中断返回堆栈结构示意图

宏 move_to_user_mode 首先往内核堆栈中压入任务 0 数据段选择符和内核堆栈指针。然后压入标志寄存器内容。最后压入任务 0 代码段选择符和执行中断返回后需要执行的下一条指令的偏移位置。该偏移位置是 iret 后的一条指令处。

当执行 iret 指令时，CPU 把返回地址送入 CS:EIP 中，同时弹出堆栈中标志寄存器内容。由于 CPU 判断出目的代码段的特权级是 3，与当前内核态的 0 级不同。于是 CPU 会把堆栈中的堆栈段选择符和堆栈指针弹出到 SS:ESP 中。由于特权级发上了变化，段寄存器 DS、ES、FS 和 GS 的值变得无效，此时 CPU 会把这些段寄存器清零。因此在执行了 iret 指令后需要重新加载这些段寄存器。此后，系统就开始以特权级 3 运行在任务 0 的代码上。所使用的用户态堆栈还是原来在移动之前使用的堆栈。而其内核态堆栈则被指定为其任务数据结构所在页面的顶端开始（PAGE_SIZE + (long)&init_task）。由于以后在创建新进程时，需要复制任务 0 的任务数据结构，包括其用户堆栈指针，因此要求任务 0 的用户态堆栈在创建任务 1（进程 1）之前保持“干净”状态。

2.5.4 创建新进程

Linux 系统中创建新进程使用 fork()系统调用。所有进程都是通过复制进程 0 而得到的，都是进程 0 的子进程。

在创建新进程的过程中，系统首先在任务数组中找出一个还没有被任何进程使用的空项（空槽）。如果系统已经有 64 个进程在运行，则 fork()系统调用会因为任务数组表中没有可用空项而出错返回。然后系统为新建进程在主内存区中申请一页内存来存放其任务数据结构信息，并复制当前进程任务数据结构中的所有内容作为新进程任务数据结构的模板。为了防止这个还未处理完成的新建进程被调度函数执行，此时应该立刻将新进程状态置为不可中断的等待状态（TASK_UNINTERRUPTIBLE）。

随后对复制的任务数据结构进行修改。把当前进程设置为新进程的父进程，清除信号位图并复位新进程各统计值，并设置初始运行时间片值为 15 个系统滴答数（150 毫秒）。接着根据当前进程设置任务状态段（TSS）中各寄存器的值。由于创建进程时新进程返回值应为 0，所以需要设置 tss.eax = 0。新建进程内核态堆栈指针 tss.esp0 被设置成新进程任务数据结构所在内存页面的顶端，而堆栈段 tss.ss0 被设置成内核数据段选择符。tss.ldt 被设置为局部表描述符在 GDT 中的索引值。如果当前进程使用了协处理器，把还需要把协处理器的完整状态保存到新进程的 tss.i387 结构中。

此后系统设置新任务的代码和数据段基址、限长，并复制当前进程内存分页管理的页表。注意，此时系统并不为新的进程分配实际的物理内存页面，而是让它共享其父进程的内存页面。只有当父进程或新进程中任意一个有写内存操作时，系统才会为执行写操作的进程分配相关的独自使用的内存页面。这种处理方式称为写时复制（Copy On Write）技术。

随后，如果父进程中有文件是打开的，则应将对应文件的打开次数增 1。接着在 GDT 中设置新任务的 TSS 和 LDT 描述符项，其中基地址信息指向新进程任务结构中的 tss 和 ldt。最后再将新任务设置成可运行状态并返回新进程号。

2.5.5 进程调度

由前面描述可知，Linux 进程是抢占式的。被抢占的进程仍然处于 TASK_RUNNING 状态，只是暂时没有被 CPU 运行。进程的抢占发生在进程处于用户态执行阶段，在内核态执行时是不能被抢占的。

为了能让进程有效地使用系统资源，又能使进程有较快的响应时间，就需要对进程的切换调度采用一定的调度策略。在 Linux 0.11 中采用了基于优先级排队的调度策略。

2.5.5.1 调度程序

schedule()函数首先扫描任务数组。通过比较每个就绪态（TASK_RUNNING）任务的运行时间递减滴答计数 counter 的值来确定当前哪个进程运行的时间最少。哪一个的值大，就表示运行时间还不长，于是就选中该进程，并使用任务切换宏函数切换到该进程运行。

如果此时所有处于 TASK_RUNNING 状态进程的时间片都已经用完，系统就会根据每个进程的优先权值 priority，对系统中所有进程（包括正在睡眠的进程）重新计算每个任务需要运行的时间片值 counter。计算的公式是：

$$counter = \frac{counter}{2} + priority$$

然后 schdeule()函数重新扫描任务数组中所有处于 TASK_RUNNING 状态，重复上述过程，直到选择出一个进程为止。最后调用 switch_to()执行实际的进程切换操作。

如果此时没有其他进程可运行，系统就会选择进程 0 运行。对于 Linux 0.11 来说，进程 0 会调用 pause()把自己置为可中断的睡眠状态并再次调用 schedule()。不过在调度进程运行时，schedule()并不在意进程 0 处于什么状态。只要系统空闲就调度进程 0 运行。

2.5.5.2 进程切换

执行实际进程切换的任务由 switch_to()宏定义的一段汇编代码完成。在进行切换之前，switch_to()首先检查要切换到的进程是否就是当前进程，如果是则什么也不做，直接退出。否则就首先把内核全局变量 current 置为新任务的指针，然后长跳转到新任务的任务状态段 TSS 组成的地址处，造成 CPU 执行任务切换操作。此时 CPU 会把其所有寄存器的状态保存到当前任务寄存器 TR 中 TSS 段选择符所指向的当前进程任务数据结构的 tss 结构中，然后把新任务状态段选择符所指向的新任务数据结构中 tss 结构中的寄存器信息恢复到 CPU 中，系统就正式开始运行新切换的任务了。这个过程可参见图 2-8 所示。

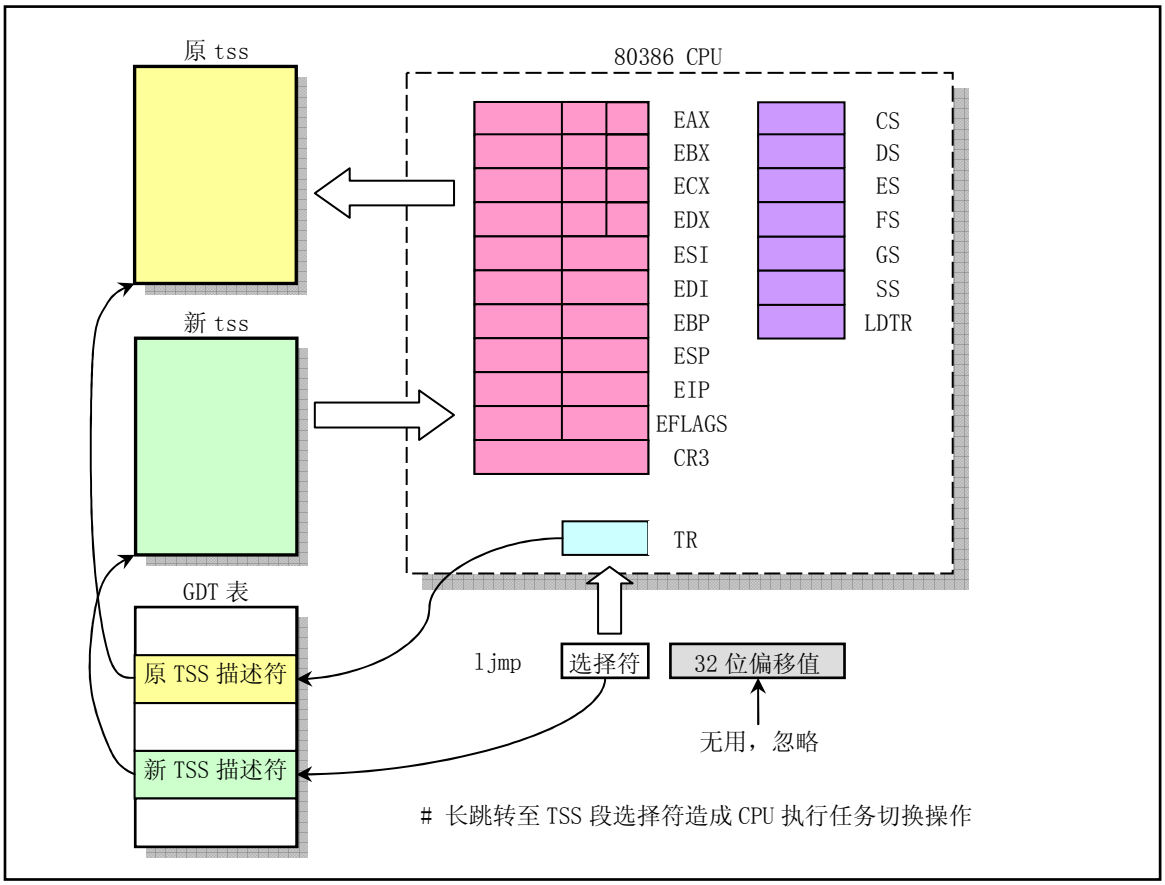

图 2-8 任务切换操作示意图

2.5.6 终止进程

当一个进程结束了运行或在半途中终止了运行，那么内核就需要释放该进程所占用的系统资源。这

包括进程运行时打开的文件、申请的内存等。

当一个用户程序调用 exit()系统调用时，就会执行内核函数 do_exit()。该函数会首先释放进程代码段和数据段占用的内存页面，关闭进程打开着的所有文件，对进程使用的当前工作目录、根目录和运行程序的 i 节点进行同步操作。如果进程有子进程，则让 init 进程作为其所有子进程的父进程。如果进程是一个会话头进程并且有控制终端，则释放控制终端，并向属于该会话的所有进程发送挂断信号 SIGHUP，这通常会终止该会话中的所有进程。然后把进程状态置为僵死状态 TASK_ZOMBIE。并向其原父进程发送 SIGCHLD 信号，通知其某个子进程已经终止。最后 do_exit()调用调度函数去执行其他进程。由此可见在进程被终止时，它的任务数据结构仍然保留着。因为其父进程还需要使用其中的信息。

在子进程在执行期间，父进程通常使用 wait()或 waitpid()函数等待其某个子进程终止。当等待的子进程被终止并处于僵死状态时，父进程就会把子进程运行所使用的时间累加到自己进程中。最终释放已终止子进程任务数据结构所占用的内存页面，并置空子进程在任务数组中占用的指针项。

2.6 Linux 内核对内存的使用方法

本节首先说明 Linux 0.11 系统中比较直观的物理内存的使用情况，然后分别描述内存的分段和分页管理机制以及 CPU 多任务和保护方式。最后我们再综合说明 Linux 0.11 系统中内核代码和数据以及各个任务的代码和数据在虚拟地址、线性地址和物理地址之间的对应关系。若能充分理解本节的内容，则说明我们对 Intel 80X86 CPU 的内存管理技术已经吃透。

2.6.1 物理内存

在 Linux 0.11 内核中，为了有效地使用机器中的物理内存，内存被划分成几个功能区域，见下图 2-9 所示。

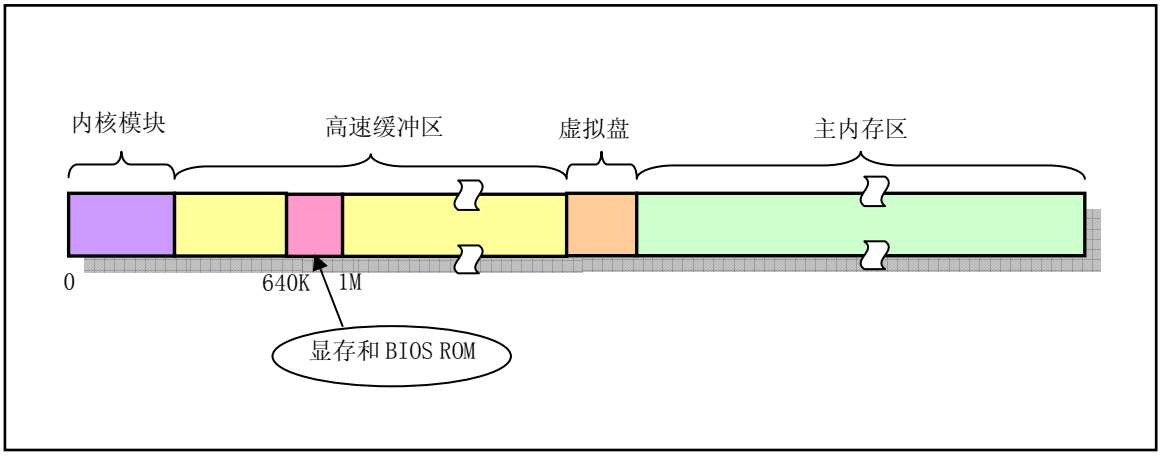

图 2-9 物理内存使用的功能分布图

其中，Linux 内核程序占据在物理内存的开始部分，接下来是用于供硬盘或软盘等块设备使用的高速缓冲区部分。当一个进程需要读取块设备中的数据时，系统会首先将数据读到高速缓冲区中；当有数据需要写到块设备上去时，系统也是先将数据放到高速缓冲区中，然后由块设备驱动程序写到设备上。最后部分是供所有程序可以随时申请使用的主内存区部分。内核程序在使用主内存区时，也同样要首先向内核的内存管理模块提出申请，在申请成功后方能使用。对于含有 RAM 虚拟盘的系统，主内存区头部还要划去一部分，供虚拟盘存放数据。

由于计算机系统中所含的实际物理内存容量是有限的，因此 CPU 中通常都提供了内存管理机制对系

统中的内存进行有效的管理。在 Intel CPU 中，提供了两种内存管理（变换）系统：内存分段系统（Segmentation System）和分页系统（Paging System）。而分页管理系统是可选择的，由系统程序员通过编程来确定是否采用。为了能有效地使用这些物理内存，Linux 系统同时采用了 Intel CPU 的内存分段和分页管理机制。

2.6.2 内存分段机制

在 Linux 0.11 内核中，在进行地址映射时，我们需要首先分清 3 种地址以及它们之间的变换概念：a. 程序（进程）的逻辑地址；b. CPU 的线性地址；c. 实际物理内存地址。

虚拟地址（Virtual Address）是指由程序产生的由段选择符和段内偏移地址两个部分组成的地址。因为这两部分组成的地址并没有直接用来访问物理内存，而是需要通过分段地址变换机制处理或映射后才对应到物理内存地址上，因此这种地址被称为虚拟地址。虚拟地址空间由 GDT 映射的全局地址空间和由 LDT 映射的局部地址空间组成。选择符的索引部分由 13 个比特位表示，加上区分 GDT 和 LDT 的 1 个比特位，因此 Intel 80X86 CPU 共可以索引 16384 个选择符。若每个段的长度都取最大值 4G，则最大虚拟地址空间范围是 16384 * 4G = 64T。

逻辑地址（Logical Address）是指由程序产生的与段相关的偏移地址部分。在 Intel 保护模式下即是指程序执行代码段限长内的偏移地址（假定代码段、数据段完全一样）。应用程序员仅需与逻辑地址打交道，而分段和分页机制对他来说是完全透明的，仅由系统编程人员涉及。

线性地址（Linear Address）是逻辑地址到物理地址变换之间的中间层，是处理器可寻址的内存空间（称为线性地址空间）中的地址。程序代码会产生逻辑地址，或者说是段中的偏移地址，加上相应段的基地址就生成了一个线性地址。如果启用了分页机制，那么线性地址可以再经变换以产生一个物理地址。若没有启用分页机制，那么线性地址直接就是物理地址。Intel 80386 的线性地址空间容量为 4G。

物理地址（Physical Address）是指出现在 CPU 外部地址总线上的寻址物理内存的地址信号，是地址变换的最终结果地址。如果启用了分页机制，那么线性地址会使用页目录和页表中的项变换成物理地址。如果没有启用分页机制，那么线性地址就直接成为物理地址了。

虚拟内存（Virtual Memory）是指计算机呈现出要比实际拥有的内存大得多的内存量。因此它允许程序员编制并运行比实际系统拥有的内存大得多的程序。这使得许多大型项目也能够在具有有限内存资源的系统上实现。一个很恰当的比喻是：你不需要很长的轨道就可以让一列火车从上海开到北京。你只需要足够长的铁轨（比如说 3 公里）就可以完成这个任务。采取的方法是把后面的铁轨立刻铺到火车的前面，只要你的操作足够快并能满足要求，列车就能象在一条完整的轨道上运行。这也就是虚拟内存管理需要完成的任务。在 Linux 0.11 内核中，给每个程序（进程）都划分了总容量为 64MB 的虚拟内存空间。因此程序的逻辑地址范围是 0x0000000 到 0x4000000。

有时我们也把逻辑地址称为虚拟地址。因为与虚拟内存空间的概念类似，逻辑地址也是与实际物理内存容量无关的。

在内存分段系统中，一个程序的逻辑地址是通过分段机制自动地映射（变换）到中间层的线性地址上。每次对内存的引用都是对内存段中内存的引用。当程序引用一个内存地址时，通过把相应的段基址加到程序员看得见的逻辑地址上就形成了一个对应的线性地址。此时若没有启用分页机制，则该线性地址就被送到 CPU 的外部地址总线上，用于直接寻址对应的物理内存。见图 2-10 所示。

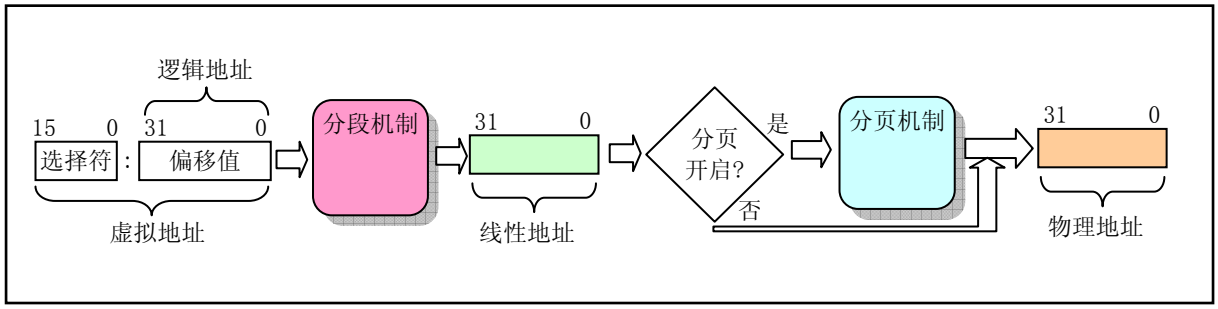

图 2-10 虚拟地址（逻辑地址）到物理地址的变换过程

若采用了分页机制，则此时线性地址只是一个中间结果，还需要使用分页机制进行变换，再最终映射到实际物理内存地址上。与分段机制类似，分页机制允许我们重新定向（变换）每次内存引用，以适应我们的特殊要求。使用分页机制最普遍的场合是当系统内存实际上被分成很多凌乱的块时,它可以建立一个大而连续的内存空间的映像，好让程序不用操心和管理这些分散的内存块。分页机制增强了分段机制的性能。页地址变换是建立在段变换基础之上的。任何分页机制的保护措施并不会取代段变换的保护措施而只是进行更进一步的检查操作。

因此，CPU 进行地址变换（映射）的主要目的是为了解决虚拟内存空间到物理内存空间的映射问题。虚拟内存空间的含义是指一种利用二级或外部存储空间，使程序能不受实际物理内存量限制而使用内存的一种方法。通常虚拟内存空间要比实际物理内存量大得多。

那么虚拟内存空间管理是怎样实现的呢？原理与上述列车运行的比喻类似。首先，当一个程序需要使用一块不存在的内存时（也即在内存页表项中已标出相应内存页面不在内存中），CPU 就需要一种方法来得知这个情况。这是通过 80386 的页错误异常中断来实现的。当一个进程引用一个不存在页面中的内存地址时，就会触发 CPU 产生页出错异常中断，并把引起中断的线性地址放到 CR2 控制寄存器中。因此处理该中断的过程就可以知道发生页异常的确切地址，从而可以把进程要求的页面从二级存储空间（比如硬盘上）加载到物理内存中。如果此时物理内存已经被全部占用，那么可以借助二级存储空间的一部分作为交换缓冲区（Swapper）把内存中暂时不使用的页面交换到二级缓冲区中，然后把要求的页面调入内存中。这也就是内存管理的缺页加载机制，在 Linux 0.11 内核中是在程序 mm/memory.c 中实现。

Intel CPU 使用段（Segment）的概念来对程序进行寻址。每个段定义了内存中的某个区域以及访问的优先级等信息。而每个程序都可有若干个内存段组成。程序的逻辑地址（或称为虚拟地址）即是用于寻址这些段和段中具体地址位置。在 Linux 0.11 中，程序逻辑地址到线性地址的变换过程使用了 CPU 的全局段描述符表 GDT 和局部段描述符表 LDT。由 GDT 映射的地址空间称为全局地址空间，由 LDT 映射的地址空间则称为局部地址空间，而这两者构成了虚拟地址的空间。具体的使用方式见图 2-11 所示。

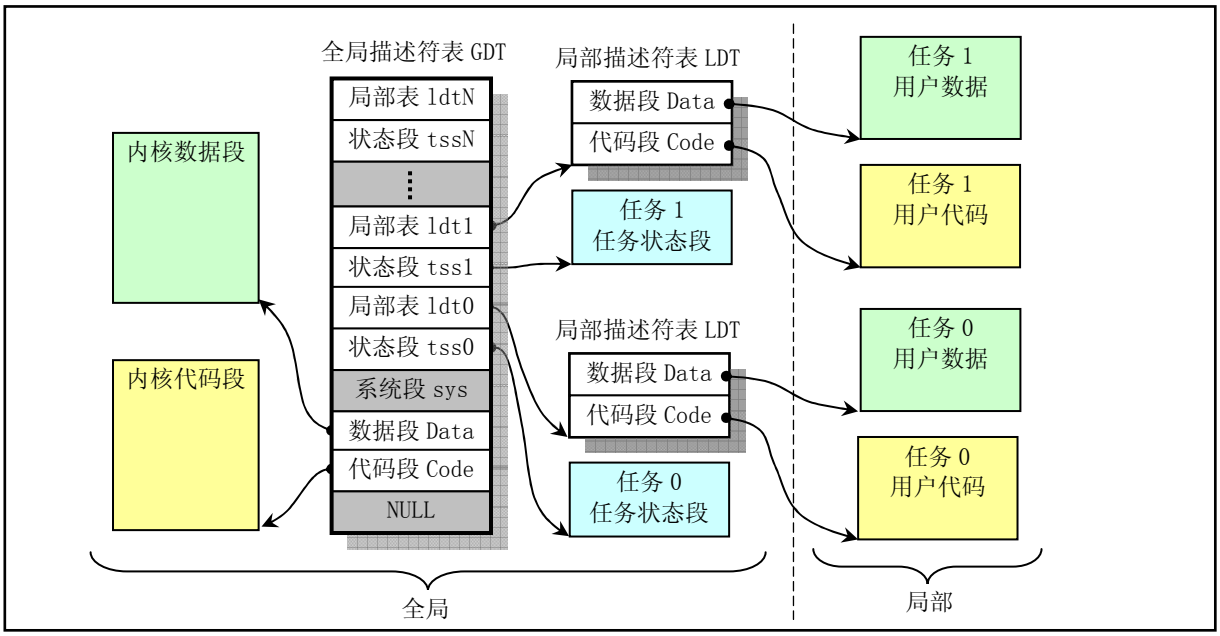

图 2-11 Linux 系统中虚拟地址空间分配图

图中画出了具有两个任务时的情况。对于中断描述符表 idt，它是保存在内核代码段中的。由于在 Linux 0.11 内核中，内核和各任务的代码段和数据段都分别被映射到线性地址空间中相同基址处，且段限长也一样，因此内核和任务的代码段和数据段都分别是重叠的。另外，Linux 0.11 内核中没有使用系统段描述符。

2.6.3 内存分页管理

内存分页管理的基本原理是将整个主内存区域划分成 4096 字节为一页的内存页面。程序申请使用内存时，就以内存页为单位进行分配。

在使用这种内存分页管理方法时，每个执行中的进程（任务）可以使用比实际内存容量大得多的连续地址空间。对于 Intel 80386 系统，其 CPU 可以提供多达 4G 的线性地址空间。对于 Linux 0.11 内核，系统设置全局描述符表 GDT 中的段描述符项数最大为 256，其中 2 项空闲、2 项系统使用，每个进程使用两项。因此，此时系统可以最多容纳(256-4)/2 + 1=127 个任务，并且虚拟地址范围是 ((256-4)/2)* 64MB 约等于 8G。但 0.11 内核中人工定义最大任务数 NR_TASKS = 64 个，每个进程虚拟地址范围是 64M，并且各个进程的虚拟地址起始位置是(任务号-1)*64MB。因此所使用的虚拟地址空间范围是 64MB*64 =4G，见图 2-12 所示。内核代码段和数据段占用线性地址空间的开始 16MB 部分，并且代码和数据段完全相重叠。而第 1 个任务（任务 0）是包含在内核代码和数据中的，因此该任务所占用的线性地址空间范围比较特殊。任务 0 的代码段和数据段的长度是从线性地址 0 开始的 640KB 范围，其代码和数据段也是完全重叠的，并且与内核代码段和数据段有重叠的部分。因此实际上任务 0 的线性地址范围与图中所示有差异。任务 1 的线性地址空间范围也只有从 64MB 开始的 640KB 长度。它们之间的详细对应关系见后面说明。由于 4G 这个范围正好与 CPU 的线性地址空间范围或物理地址空间范围相同，因此在 0.11 内核中比较容易混淆三种地址概念。

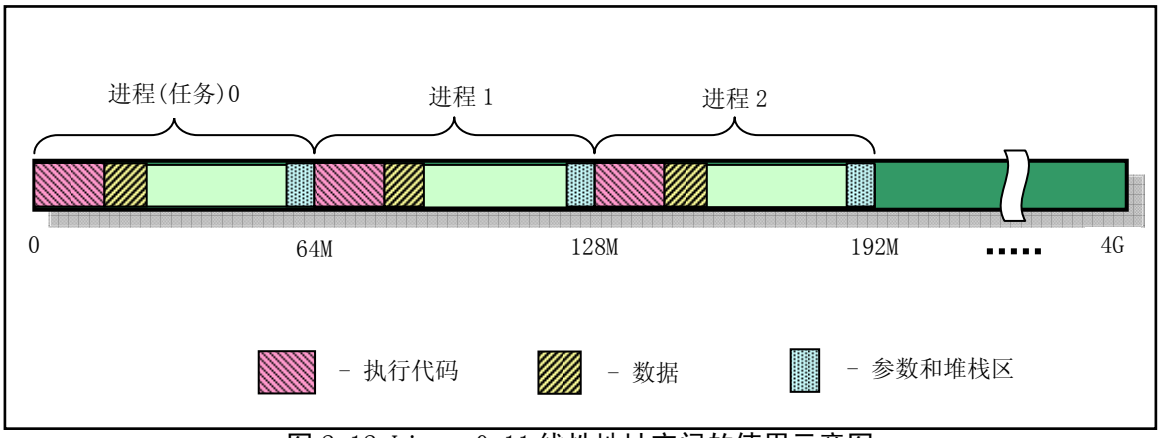

图 2-12 Linux 0.11 线性地址空间的使用示意图

进程的虚拟地址需要首先通过其局部段描述符变换为 CPU 整个线性地址空间中的地址，然后再使用页目录表 PDT（一级页表）和页表 PT（二级页表）映射到实际物理地址页上。因此两种变换不能混淆。

为了使用实际物理内存，每个进程的线性地址通过二级内存页表动态地映射到主内存区域的不同内存页上。因此每个进程最大可用的虚拟内存空间是 64MB。每个进程的逻辑地址通过加上任务号*64M，即可转换为线性空间中的地址（线性地址）。不过在注释中，我们通常将进程中的此类地址简单地称为线性地址。有关内存分页管理的详细信息，请参见第 10 章开始部分的有关说明，或参见附录。

2.6.4 CPU 多任务和保护方式

Intel 80X86 CPU 共分 4 个保护级，0 级具有最高优先级，而 3 级优先级最低。Linux 0.11 操作系统使用了 CPU 的 0 和 3 两个保护级。内核代码本身会由系统中的所有任务共享。而每个任务则都有自己的代码和数据区，这两个区域保存于局部地址空间，因此系统中的其他任务是看不见的（不能访问的）。而内核代码和数据是由所有任务共享的，因此它保存在全局地址空间中。图 2-13 给出了这种结构的示意图。图中同心圆代表 CPU 的保护级别（保护层），这里仅使用了 CPU 的 0 级和 3 级。而径向射线则用来区分系统中的各个任务。每条径向射线指出了各任务的边界。除了每个任务虚拟地址空间的全局地址区域，任务 1 中的地址与任务 2 中相同地址处是无关的。

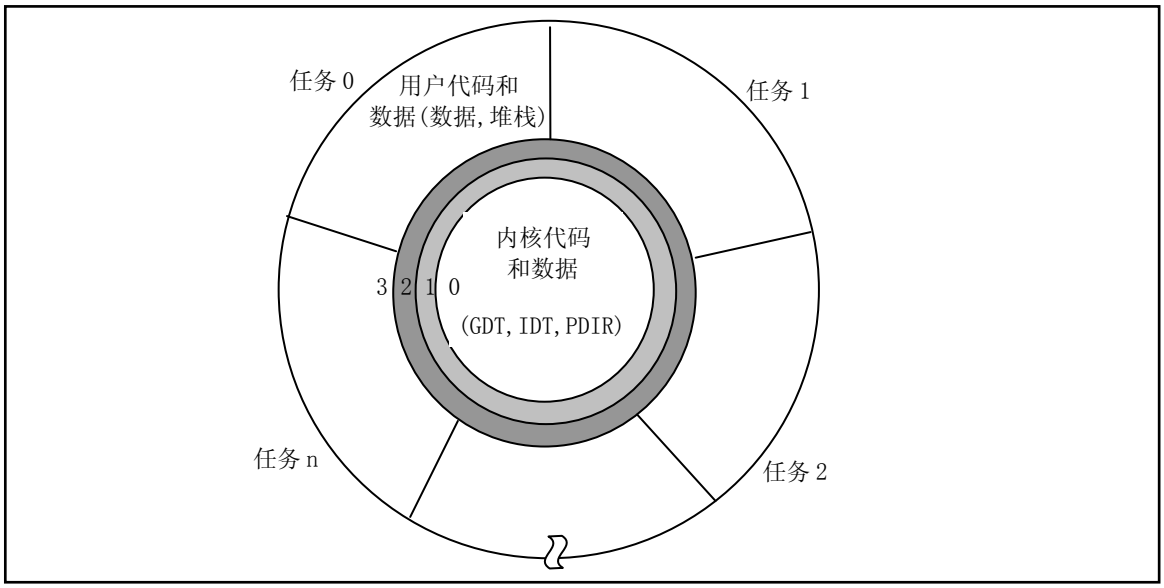

图 2-13 多任务系统

2.6.5 虚拟地址、线性地址和物理地址之间的关系

前面我们根据内存分段和分页机制详细说明了 CPU 的内存管理方式。现在我们以 Linux 0.11 系统为例，详细说明内核代码和数据以及各任务的代码和数据在虚拟地址空间、线性地址空间和物理地址空间中的对应关系。由于任务 0 和任务 1 的生成或创建过程比较特殊，我们将对它们分别进行描述。

2.6.5.1 内核代码和数据的地址

对于 Linux 0.11 内核代码和数据来说，在 head.s 程序的初始化操作中已经把内核代码段和数据段都设置成为长度为 16MB 的段。在线性地址空间中这两个段的范围重叠，都是从线性地址 0 开始到地址 0xFFFFFF 共 16MB 地址范围。在该范围中含有内核所有的代码、内核段表（GDT、IDT、TSS）、页目录表和内核的二级页表、内核局部数据以及内核临时堆栈（将被用作第 1 个任务（任务 0）的用户堆栈）。其页目录表和二级页表已设置成把 0--16MB 的线性地址空间一一对应到物理地址上。因此对于内核代码或数据的地址来说，我们可以直接把它们看作是物理内存中的地址。此时内核的虚拟地址空间、线性地址空间和物理地址空间三者之间的关系可用图 2-14 来表示。

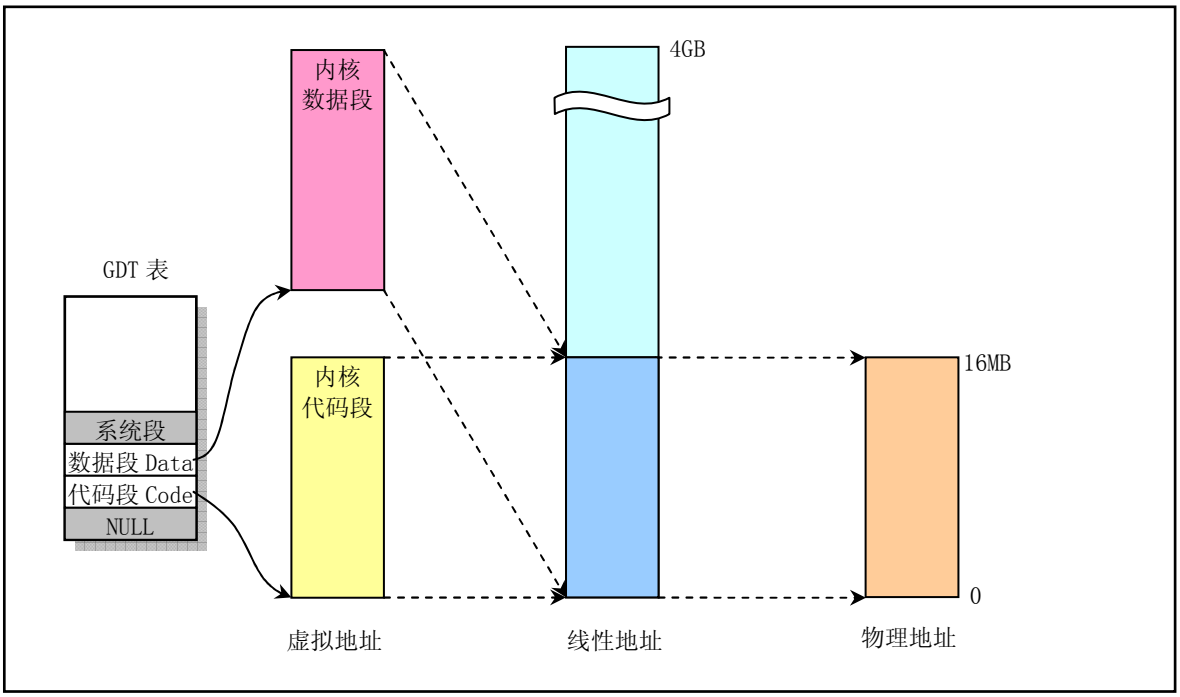

图 2-14 内核代码和数据段在三种地址空间中的关系

默认情况下，Linux 0.11 内核可管理 16MB 的物理内存，共有 4096 个物理页面（页帧），每个页面 4KB。通过上述分析可以看出：①内核代码段和数据段区域在线性地址空间和物理地址空间中是一样的。这样设置可以大大简化内核的初始化操作。②GDT 和 IDT 在内核数据段中，因此它们的线性地址也同样等于它们的物理地址。否则的话，在进入保护模式和开启分页机制时这两个表就需要被重新建立或移动位置，描述符也需要重新加载。③除任务 0 以外的其他任务所需要的物理内存页面与线性地址中的不同，因此内核需要动态地在主内存区中为它们作映射操作，动态地建立页目录项和页表项。

2.6.5.2 任务 0 的地址对应关系

任务 0 是系统中一个人工启动的第一个任务。它的代码段和数据段长度被设置为 640KB。该任务的代码和数据直接包含在内核代码和数据中，是从线性地址 0 开始的 640KB 内容，因此可以它直接使用内核代码已经设置好的页目录和页表进行分页地址变换。同样它的代码和数据段在线性地址空间中也是重

叠的。对应的任务状态段 TSS0 也是手工预设置好的，并且位于任务 0 数据结构信息中，参见 sched.h 第 113 行开始的数据。TSS0 段位于内核 sched.c 程序的代码中，长度为 104 字节，参见图 2-18 所示。三个地址空间中的对应关系见图 2-15 所示。

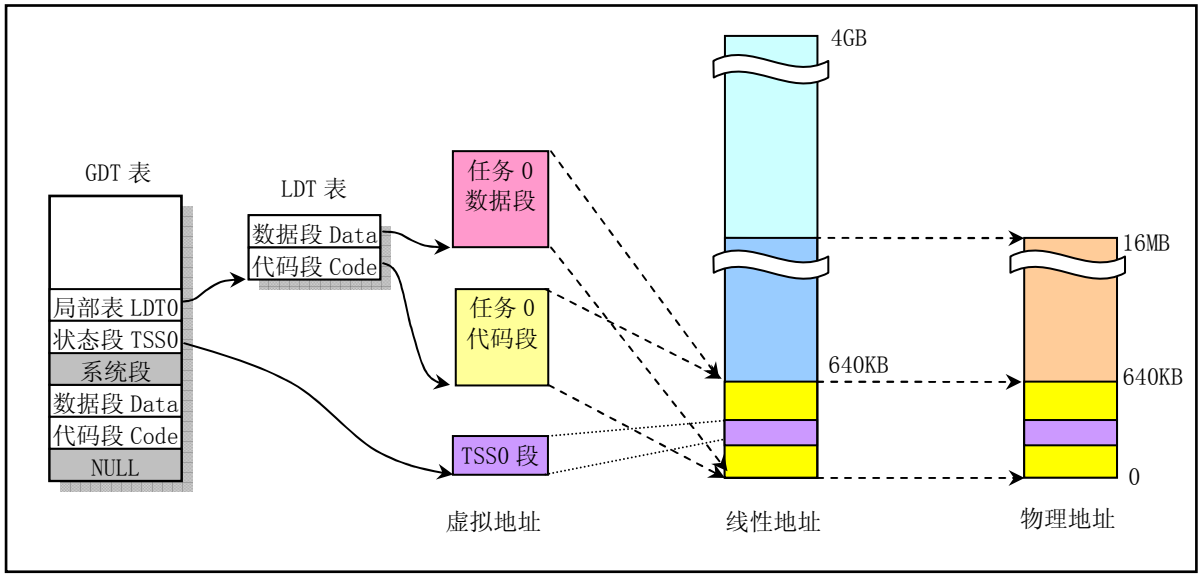

图 2-15 任务 0 在三个地址空间中的相互关系

由于任务 0 直接被包含在内核代码中，因此不需要为其再另外分配内存页。它运行时所需要的内核态堆栈和用户态堆栈空间都在内核代码区中，用户态堆栈将与任务 1 共享使用，但用户态堆栈将全部留给任务 1 使用。见下节中的说明。

2.6.5.3 任务 1 的地址对应关系

与任务 0 类似，任务 1 也是一个特殊的任务。它的代码也在内核代码区域中。与任务 0 不同的是在线性地址空间中，系统在使用 fork()创建任务 1（init 进程）时为任务 1 的二级页表在主内存区申请了一页内存来存放，并复制了父进程（任务 0）的页目录和二级页表项。因此任务 1 的长度也是 640KB，并且其代码段和数据段相重叠。另外，在 fork()创建任务 1 时，系统还会为任务 1 在主内存申请一页内存用来存放它的任务数据结构和用作任务 1 的内核堆栈空间。任务数据结构信息中包括任务 1 的 TSS 段结构信息。见图 2-16 所示。

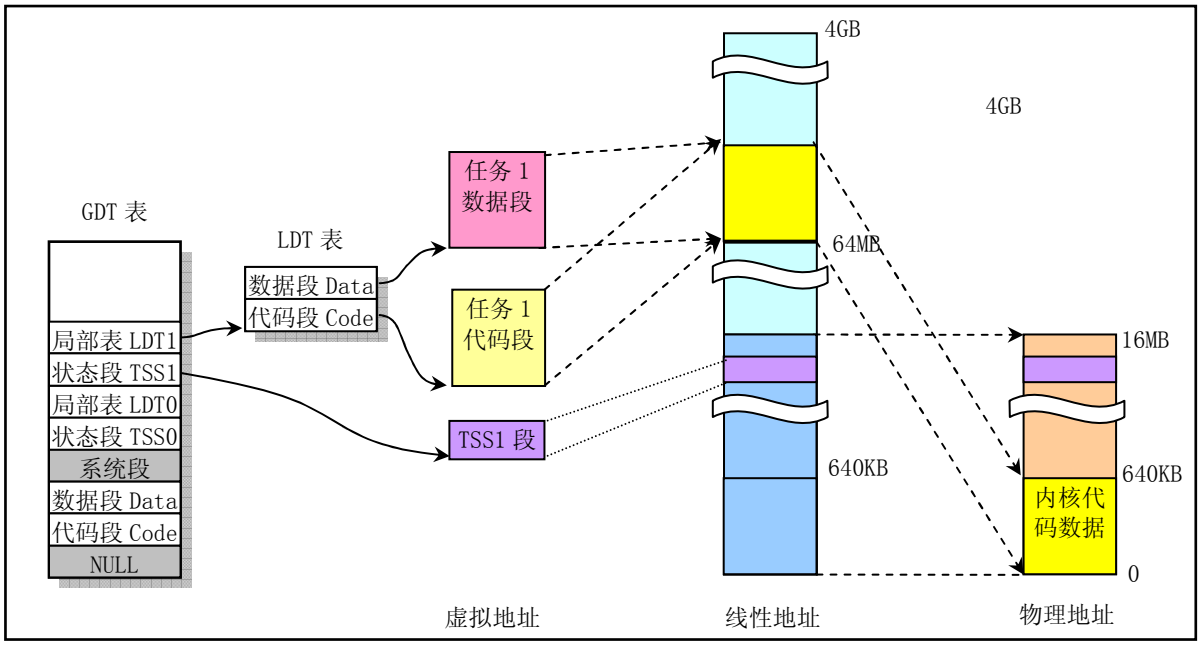

图 2-16 任务 1 在三种地址空间中的关系

任务 1 的用户态堆栈空间将直接使用处于内核代码和数据区域（线性地址 0--640KB）中任务 0 的用户态堆栈空间。

2.6.5.4 其他任务的地址对应关系

这里，其他任务指的是被创建的从任务 2 开始的任务。它们的父进程都是 init 进程。在 Linux 0.11 系统中共可以有 64 个进程同时存在。下面以任务 2 为例来说明其他任何任务对地址空间的使用情况。

从任务 2 开始，如果任务号以 nr 来表示，那么任务 nr 在线性地址空间中的起始位置将被设定在 nr*64MB 处。例如任务 2 的开始位置= nr*64MB = 2 * 64MB = 128MB。任务代码段和数据段的最大长度被设置为 64MB，因此任务 2 占有的线性地址空间范围是 128MB--192MB。虚拟空间中任务代码段和数据段都被映射到线性地址空间相同的范围，因此它们也完全重叠。图 2-17 显示出了任务 2 的代码段和数据段在三种地址空间中的对应关系。

在 Linux 0.11 系统中，任务 2 在被创建出来之后，将运行 execve()函数来执行 shell 程序。图 2-17 给出的是任务 2 原先复制任务 1 的代码和数据被 shell 的代码段和数据段替换后的情况。这里请注意的是，在执行 execve()函数时，系统虽然在线性地址空间为任务 2 分配了 64MB 的空间，但是并不会立刻为其分配物理内存页面。只有当任务 2 开始执行时由于发生缺页而引起异常时才会由内存管理程序为其在主内存区中分配并映射一页物理内存到线性地址空间中。图中显示出映射了一页物理内存页的情况。

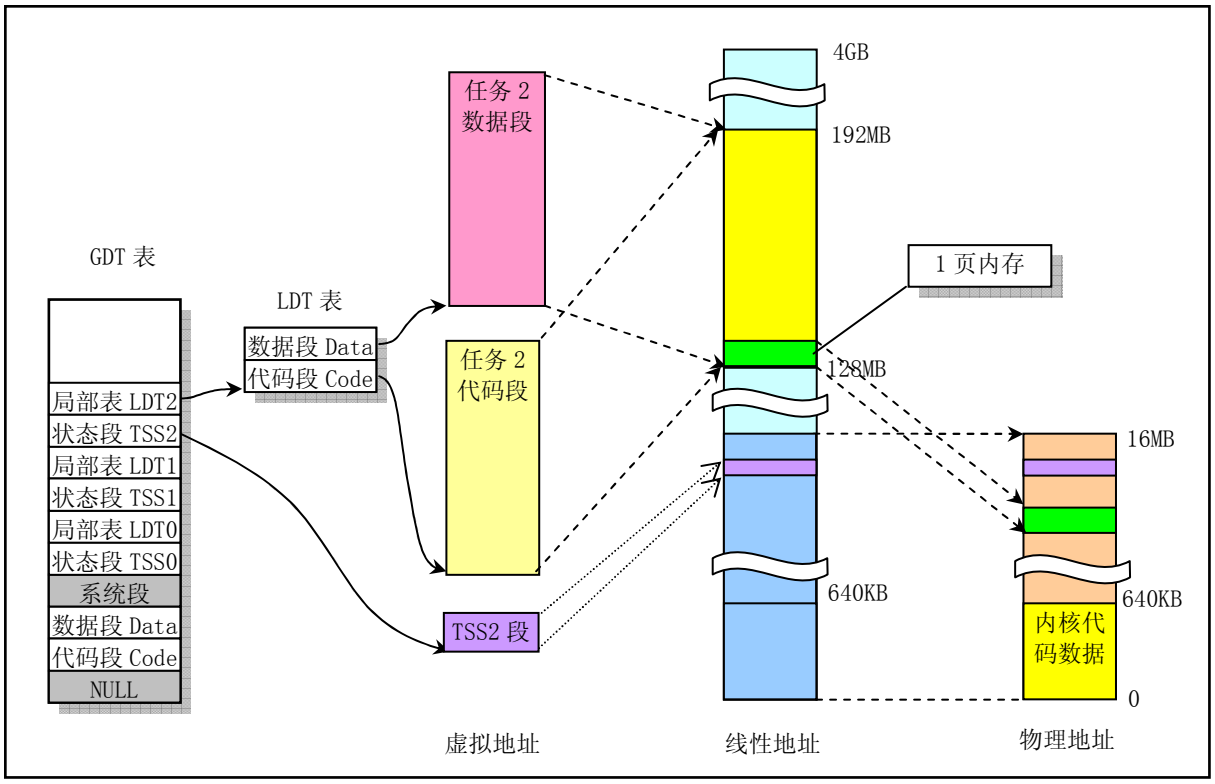

图 2-17 其他任务地址空间中的对应关系

从 Linux 内核 0.99 版以后，对内存空间的使用方式发生了变化。每个进程可以单独享用整个 4G 的地址空间范围。由于篇幅所限，这里对此不再说明。

2.7 Linux 系统中堆栈的使用方法

本节内容概要描述了 Linux 内核从开机引导到系统正常运行过程中对堆栈的使用方式。这部分内容的说明与内核代码关系比较密切，可以先跳过。在开始阅读相应代码时再回来仔细研究。

Linux 0.11 系统中共使用了四种堆栈。一种是系统初始化时临时使用的堆栈；一种是供内核程序自己使用的堆栈（内核堆栈），只有一个，位于系统地址空间固定的位置，也是后来任务 0 的用户态堆栈；另一种是每个任务通过系统调用，执行内核程序时使用的堆栈，我们称之为任务的内核态堆栈，每个任务都有自己独立的内核态堆栈；最后一种是任务在用户态执行的堆栈，位于任务（进程）地址空间的末端。下面分别对它们进行说明。

2.7.1 初始化阶段

开机初始化时(bootsect.s，setup.s)

当 bootsect 代码被 ROM BIOS 引导加载到物理内存 0x7c00 处时，并没有设置堆栈段，当然程序也没有使用堆栈。直到 bootsect 被移动到 0x9000:0 处时，才把堆栈段寄存器 SS 设置为 0x9000，堆栈指针 esp 寄存器设置为 0xff00，也即堆栈顶端在 0x9000:0xff00 处，参见 boot/bootsect.s 第 61、62 行。setup.s 程序中也沿用了 bootsect 中设置的堆栈段。这就是系统初始化时临时使用的堆栈。

进入保护模式时(head.s)

从 head.s 程序起，系统开始正式在保护模式下运行。此时堆栈段被设置为内核数据段（0x10），堆栈指针 esp 设置成指向 user_stack 数组的顶端（参见 head.s，第 31 行），保留了 1 页内存（4K）作为堆栈使用。user_stack 数组定义在 sched.c 的 67--72 行，共含有 1024 个长字。它在物理内存中的位置可参

见下图 2-18 所示。此时该堆栈是内核程序自己使用的堆栈。

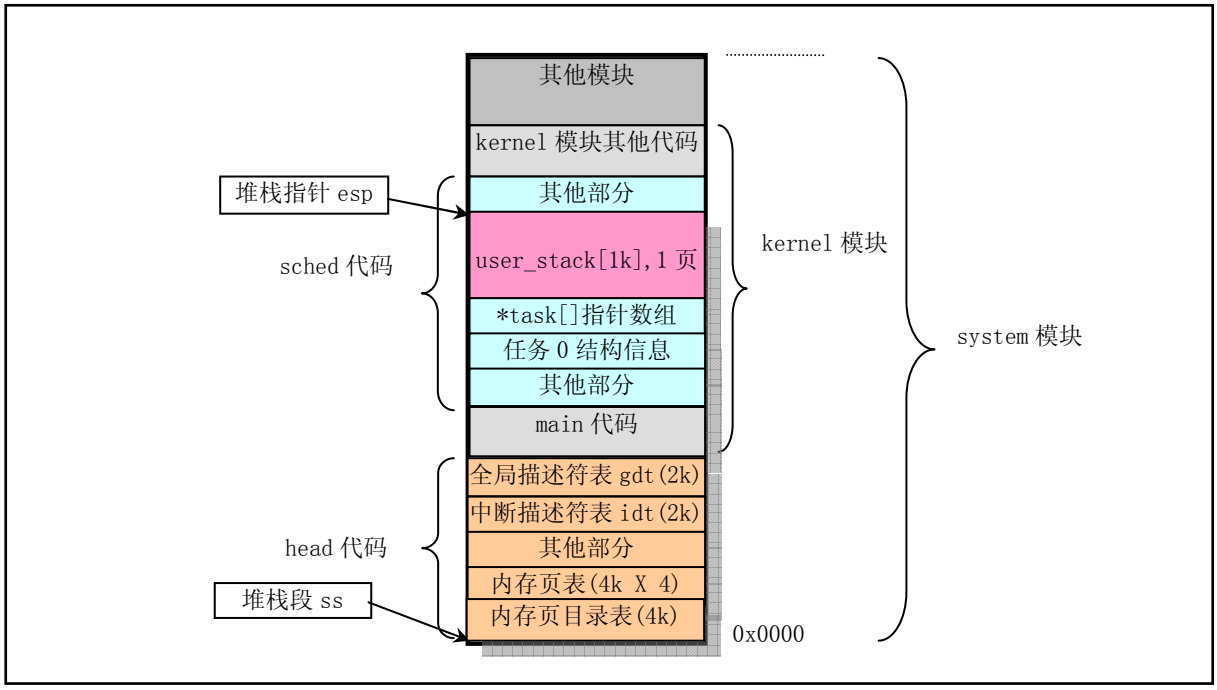

图 2-18 刚进入保护模式时内核使用的堆栈示意图

初始化时(main.c)

在 main.c 中，在执行 move_to_user_mode()代码之前，系统一直使用上述堆栈。而在执行过 move_to_user_mode()之后，main.c 的代码被“切换”成任务 0 中执行。通过执行 fork()系统调用，main.c 中的 init()将在任务 1 中执行，并使用任务 1 的堆栈。而 main()本身则在被“切换”成为任务 0 后，仍然继续使用上述内核程序自己的堆栈作为任务 0 的用户态堆栈。关于任务 0 所使用堆栈的详细描述见后面说明。

2.7.2 任务的堆栈

每个任务都有两个堆栈，分别用于用户态和内核态程序的执行，并且分别称为用户态堆栈和内核态堆栈。这两个堆栈之间的主要区别在于任务的内核态堆栈很小，所保存的数据量最多不能超过（4096 – 任务数据结构）个字节，大约为 3K 字节。而任务的用户态堆栈却可以在用户的 64MB 空间内延伸。

在用户态运行时

每个任务（除了任务 0 和任务 1）有自己的 64MB 地址空间。当一个任务（进程）刚被创建时，它的用户态堆栈指针被设置在其地址空间的靠近末端（64MB 顶端）部分。实际上顶端部分还要包括执行程序的参数和环境变量，然后才是用户堆栈空间。应用程序在用户态下运行时就一直使用这个堆栈。堆栈实际使用的物理内存则由 CPU 分页机制确定。由于 Linux 实现了写时复制功能（Copy on Write），因此在进程被创建后，若该进程及其父进程没有使用堆栈，则两者共享同一堆栈对应的物理内存页面。而进程 0 和进程 1 的用户堆栈比较特殊，见后面说明。

在内核态运行时

每个任务有其自己的内核态堆栈。任务的内核态堆栈被设置成位于其任务数据结构所在页面的末端，即与每个任务的任务数据结构（task_struct）放在同一页面内。这是在建立新任务时，fork()程序在任务 tss 段的内核级堆栈字段(tss.esp0 和 tss.ss0)中设置的，参见 kernel/fork.c，93 行：

```
    p->tss.esp0 = PAGE_SIZE + (long)p;
    p->tss.ss0 = 0x10;
```

其中 p 是新任务的任务数据结构指针，tss 是任务状态段结构。内核为新任务申请内存用作保存其 task_struct 结构数据，而 tss 结构（段）是 task_struct 中的一个字段。该任务的内核堆栈段值 tss.ss0 也被设置成为 0x10（即内核数据段），而 tss.esp0 则指向保存 task_struct 结构页面的末端。见图 2-19 所示。

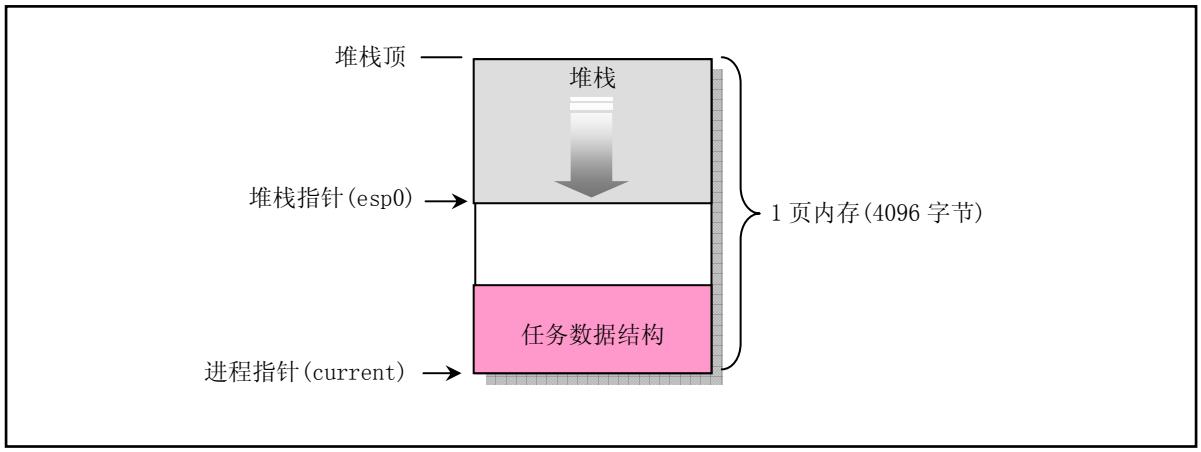

图 2-19 进程的内核态堆栈示意图

为什么通过内存管理程序从主内存区分配得来的用于保存任务数据结构的一页内存也能被设置成内核数据段中的数据呢，也即 tss.ss0 为什么能被设置成 0x10 呢？这要从内核代码段的长度范围来说明。在 head.s 程序的末端，分别设置了内核代码段和数据段的描述符。其中段的长度被设置成了 16MB。这个长度值是 Linux 0.11 内核所能支持的最大物理内存长度（参见 head.s，110 行开始的注释）。因此，内核代码可以寻址到整个物理内存范围中的任何位置，当然也包括主内存区。到 Linux 0.98 版后内核段的限长被修改成了 1GB。

每当任务执行内核程序而需要使用其内核栈时，CPU 就会利用 TSS 结构把它的内核态堆栈设置成由这两个值构成。在任务切换时，老任务的内核栈指针(esp0)不会被保存。对 CPU 来讲，这两个值是只读的。因此每当一个任务进入内核态执行时，其内核态堆栈总是空的。

任务 0 和任务 1 的堆栈

任务 0（idle 进程）和任务 1（init 进程）的堆栈比较特殊，需要特别予以说明。

任务 0 和任务 1 的代码段和数据段相同，段基地址都是从 0 开始，限长也都是 640KB。这个地址范围也就是内核代码和基本数据所在的地方。在执行了 move_to_user_mode()之后，任务 0 和任务 1 的内核态堆栈位于各自任务数据结构所在页面的末端，而它们的用户态堆栈就是前面进入保护模式后所使用的堆栈，也即 sched.c 的 user_stack 数组的位置，任务 0 和任务 1 使用着相同的用户堆栈空间。

任务 0 的内核态堆栈是在其人工设置的初始化任务数据结构中指定的，而它的用户态堆栈是在执行 movie_to_user_mode()时，在模拟 iret 返回之前的堆栈中设置的。任务 1 则在创建时复制了任务 0 的用户堆栈。在该堆栈中，esp 仍然是 user_stack 中原来的位置，而 ss 被设置成 0x17，也即用户态局部表中的数据段，也即从内存地址 0 开始并且限长为 640KB 的段。参见图 2-7 所示。

由于在内核代码空间中没有使用写时复制机制[2]，因此在内核任务 0 和任务 1 的运行过程中不会为它们另外开辟相互独立的用户堆栈空间，它们一直共同使用着位于 sched.c 代码的 user_stack 数组处的空间位置。因此为了让这两个任务不相互干扰，在内核代码中就要求任务 0 不要使用用户堆栈。这是通过严格限制任务 0 不调用任何函数来做到的。

[2] 关于写时复制（Copy on Write）技术的说明请参见第 10 章内存管理，10.2 节。

2.7.3 任务内核态堆栈与用户态堆栈之间的切换

任务调用系统调用时就会进入内核，执行内核代码。此时内核代码就会使用该任务的内核态堆栈进行操作。当进入内核程序时，由于优先级别发生了改变（从用户态转到内核态），用户态堆栈的堆栈段和堆栈指针以及 eflags 会被保存在任务的内核态堆栈中。而在执行 iret 退出内核程序返回到用户程序时，将恢复用户态的堆栈和 eflags。这个过程见图 2-20 所示。

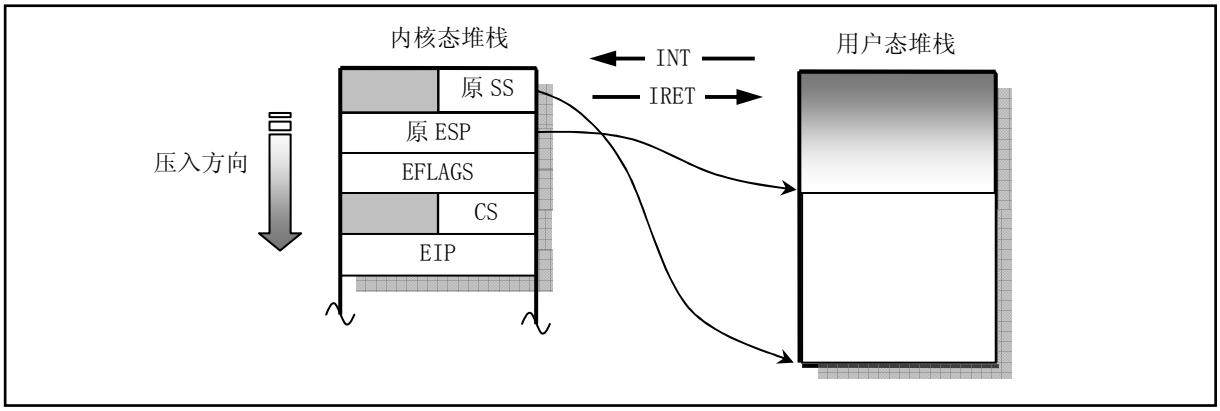

图 2-20 内核态和用户态堆栈的切换

2.8 Linux 内核源代码的目录结构

由于 Linux 内核是一种单内核模式的系统，因此，内核中所有的程序几乎都有紧密的联系，它们之间的依赖和调用关系非常密切。所以在阅读一个源代码文件时往往需要参阅其他相关的文件。因此有必要在开始阅读内核源代码之前，先熟悉一下源代码文件的目录结构和安排。

这里我们首先列出 Linux 内核完整的源代码目录，包括其中的子目录。然后逐一介绍各个目录中所包含程序的主要功能，使得整个内核源代码的安排形式能在我们的头脑中建立起一个大概的框架，以便于下一章开始的源代码阅读工作。

当我们使用 tar 命令将 linux-0.11.tar.gz 解开时，内核源代码文件被放到了 linux/目录中。其中的目录结构见图 2-21 所示：

```
linux
├── boot            系统引导汇编程序
├── fs              文件系统
├── include         头文件(*.h)
│   ├── asm         与 CPU 体系结构相关的部分
│   ├── linux       Linux 内核专用部分
│   └── sys         系统数据结构部分
├── init            内核初始化程序
├── kernel          内核进程调度、信号处理、系统调用等程序
│   ├── blk_drv     块设备驱动程序
│   ├── chr_drv     字符设备驱动程序
│   └── math        数学协处理器仿真处理程序
├── lib             内核库函数
├── mm              内存管理程序
└── tools           生成内核 Image 文件的工具程序
```

图 2-21 Linux 内核源代码目录结构

该内核版本的源代码目录中含有 14 个子目录，总共包括 102 个代码文件。下面逐个对这些子目录中的内容进行描述。

2.8.1 内核主目录 linux

linux 目录是源代码的主目录，在该主目录中除了包括所有的 14 个子目录以外，还含有唯一的一个 Makefile 文件。该文件是编译辅助工具软件 make 的参数配置文件。make 工具软件的主要用途是通过识别哪些文件已被修改过，从而自动地决定在一个含有多个源程序文件的程序系统中哪些文件需要被重新编译。因此，make 工具软件是程序项目的管理软件。

linux 目录下的这个 Makefile 文件还嵌套地调用了所有子目录中包含的 Makefile 文件，这样，当 linux 目录（包括子目录）下的任何文件被修改过时，make 都会对其进行重新编译。因此为了编译整个内核所有的源代码文件，只要在 linux 目录下运行一次 make 软件即可。

2.8.2 引导启动程序目录 boot

boot 目录中含有 3 个汇编语言文件，是内核源代码文件中最先被编译的程序。这 3 个程序完成的主要功能是当计算机加电时引导内核启动，将内核代码加载到内存中，并做一些进入 32 位保护运行方式前的系统初始化工作。其中 bootsect.s 和 setup.s 程序需要使用 as86 软件来编译，使用的是 as86 的汇编语言格式（与微软的类似），而 head.s 需要用 GNU as 来编译，使用的是 AT&T 格式的汇编语言。这两种汇编语言在下一章的代码注释里以及代码列表后面的说明中会有简单的介绍。

bootsect.s 程序是磁盘引导块程序，编译后会驻留在磁盘的第一个扇区中（引导扇区，0 磁道（柱面），0 磁头，第 1 个扇区）。在 PC 机加电 ROM BIOS 自检后，将被 BIOS 加载到内存 0x7C00 处进行执行。

setup.s 程序主要用于读取机器的硬件配置参数，并把内核模块 system 移动到适当的内存位置处。

head.s 程序会被编译连接在 system 模块的最前部分，主要进行硬件设备的探测设置和内存管理页面的初始设置工作。

2.8.3 文件系统目录 fs

Linux 0.11 内核的文件系统采用了 1.0 版的 MINIX 文件系统，这是由于 Linux 是在 MINIX 系统上开发的，采用 MINIX 文件系统便于进行交叉编译，并且可以从 MINIX 中加载 Linux 分区。虽然使用的是 MINIX 文件系统，但 Linux 对其处理方式与 MINIX 系统不同。主要的区别在于 MINIX 对文件系统采用单线程处理方式，而 Linux 则采用了多线程方式。由于采用了多线程处理方式，Linux 程序就必须处理多线程带来的竞争条件、死锁等问题，因此 Linux 文件系统代码要比 MINIX 系统的复杂得多。为了避免竞争条件的发生，Linux 系统对资源分配进行了严格地检查，并且在内核模式下运行时，如果任务没有主动睡眠（调用 sleep()），就不让内核切换任务。

fs/目录是文件系统实现程序的目录，共包含 17 个 C 语言程序。这些程序之间的主要引用关系见图 2-22 所示图中每个方框代表一个文件，从上到下按基本按引用关系放置。其中各文件名均略去了后缀.c，虚框中是的程序文件不属于文件系统，带箭头的线条表示引用关系，粗线条表示有相互引用关系。

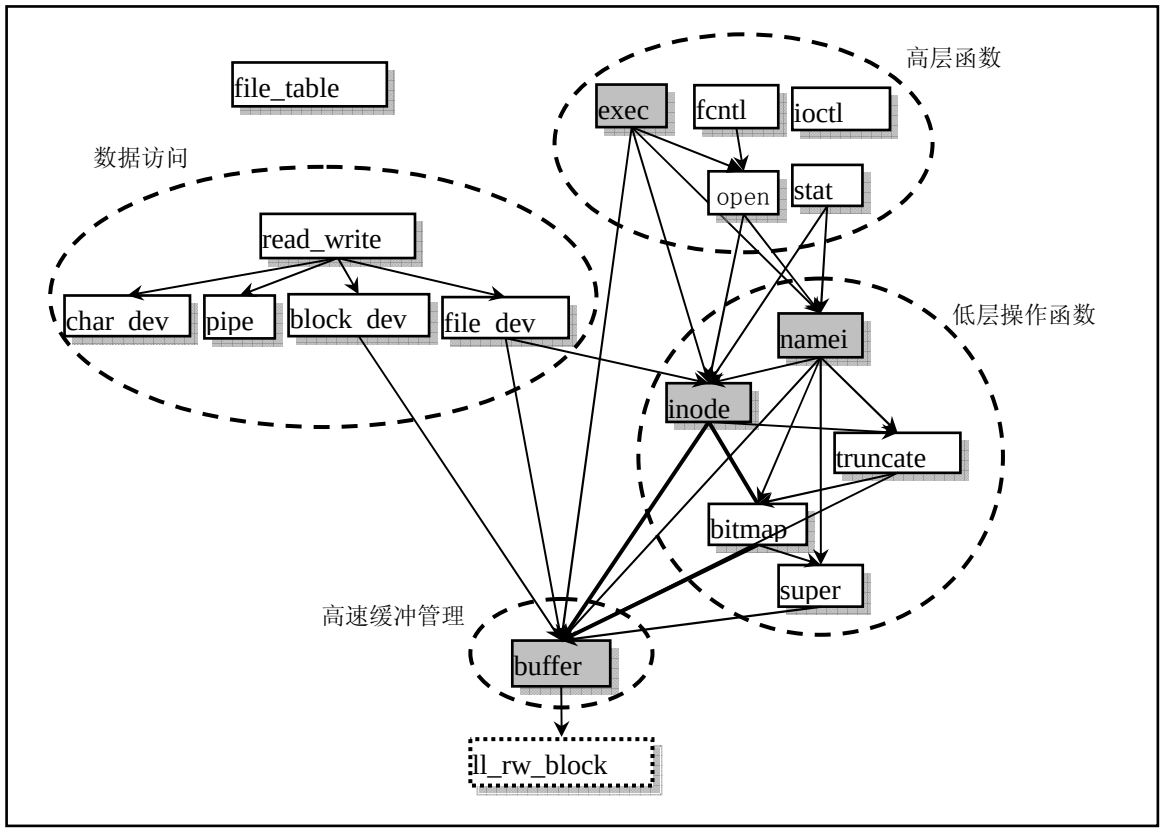

图 2-22 fs 目录中各程序中函数之间的引用关系。

由图可以看出，该目录中的程序可以划分成四个部分：高速缓冲区管理、低层文件操作、文件数据访问和文件高层函数，在对本目录中文件进行注释说明时，我们也将分成这四个部分来描述。

对于文件系统，我们可以将它看成是内存高速缓冲区的扩展部分。所有对文件系统中数据的访问，都需要首先读取到高速缓冲区中。本目录中的程序主要用来管理高速缓冲区中缓冲块的使用分配和块设备上的文件系统。管理高速缓冲区的程序是 buffer.c，而其他程序则主要都是用于文件系统管理。

在 file_table.c 文件中，目前仅定义了一个文件句柄（描述符）结构数组。ioctl.c 文件将引用 kernel/chr_drv/tty.c 中的函数，实现字符设备的 io 控制功能。exec.c 程序主要包含一个执行程序函数 do_execve()，它是所有 exec()函数簇中的主要函数。fcntl.c 程序用于实现文件 i/o 控制的系统调用函数。read_write.c 程序用于实现文件读/写和定位三个系统调用函数。stat.c 程序中实现了两个获取文件状态的系统调用函数。open.c 程序主要包含实现修改文件属性和创建与关闭文件的系统调用函数。

char_dev.c 主要包含字符设备读写函数 rw_char()。pipe.c 程序中包含管道读写函数和创建管道的系统调用。file_dev.c 程序中包含基于 i 节点和描述符结构的文件读写函数。namei.c 程序主要包括文件系统中目录名和文件名的操作函数和系统调用函数。block_dev.c 程序包含块数据读和写函数。inode.c 程序中包含针对文件系统 i 节点操作的函数。truncate.c 程序用于在删除文件时释放文件所占用的设备数据空间。bitmap.c 程序用于处理文件系统中 i 节点和逻辑数据块的位图。super.c 程序中包含对文件系统超级块的处理函数。buffer.c 程序主要用于对内存高速缓冲区进行处理。虚框中的 ll_rw_block 是块设备的底层读函数，它并不在 fs 目录中，而是 kernel/blk_drv/ll_rw_block.c 中的块设备读写驱动函数。放在这里只是让我们清楚的看到，文件系统对于块设备中数据的读写，都需要通过高速缓冲区与块设备的驱动程序（ll_rw_block()）来操作来进行，文件系统程序集本身并不直接与块设备的驱动程序打交道。

在对程序进行注释过程中，我们将另外给出这些文件中各个主要函数之间的调用层次关系。

2.8.4 头文件主目录 include

头文件目录中总共有 32 个.h 头文件。其中主目录下有 13 个，asm 子目录中有 4 个，linux 子目录中有 10 个，sys 子目录中有 5 个。这些头文件各自的功能见如下简述，具体的作用和所包含的信息请参见对头文件的注释一章。

<a.out.h>　　a.out 头文件，定义了 a.out 执行文件格式和一些宏。
<const.h>　　常数符号头文件，目前仅定义了 i 节点中 i_mode 字段的各标志位。
<ctype.h>　　字符类型头文件。定义了一些有关字符类型判断和转换的宏。
<errno.h>　　错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
<fcntl.h>　　文件控制头文件。用于文件及其描述符的操作控制常数符号的定义。
<signal.h>　　信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
<stdarg.h>　　标准参数头文件。以宏的形式定义变量参数列表。主要说明了-个类型（va_list）和三个宏（va_start, va_arg 和 va_end），用于 vsprintf、vprintf、vfprintf 函数。
<stddef.h>　　标准定义头文件。定义了 NULL, offsetof(TYPE, MEMBER)。
<string.h>　　字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
<termios.h>　　终端输入输出函数头文件。主要定义控制异步通信口的终端接口。
<time.h>　　时间类型头文件。其中最主要定义了 tm 结构和一些有关时间的函数原形。
<unistd.h>　　Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。如定义了__LIBRARY__，则还包括系统调用号和内嵌汇编_syscall0()等。
<utime.h>　　用户时间头文件。定义了访问和修改时间结构以及 utime()原型。

2.8.4.1 体系结构相关头文件子目录 include/asm

这些头文件主要定义了一些与 CPU 体系结构密切相关的数据结构、宏函数和变量。共 4 个文件。

<asm/io.h>　　io 头文件。以宏的嵌入汇编程序形式定义对 io 端口操作的函数。
<asm/memory.h>　　内存拷贝头文件。含有 memcpy()嵌入式汇编宏函数。
<asm/segment.h>　　段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
<asm/system.h>　　系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。

2.8.4.2 Linux 内核专用头文件子目录 include/linux

<linux/config.h>　内核配置头文件。定义键盘语言和硬盘类型（HD_TYPE）可选项。
<linux/fdreg.h>　　软驱头文件。含有软盘控制器参数的一些定义。
<linux/fs.h>　　文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
<linux/hdreg.h>　　硬盘参数头文件。定义访问硬盘寄存器端口，状态码，分区表等信息。
<linux/head.h>　　head 头文件，定义了段描述符的简单结构，和几个选择符常量。
<linux/kernel.h>　内核头文件。含有一些内核常用函数的原形定义。
<linux/mm.h>　　内存管理头文件。含有页面大小定义和一些页面释放函数原型。
<linux/sched.h>　　调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
　　还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
<linux/sys.h>　　系统调用头文件。含有 72 个系统调用 C 函数处理程序,以'sys_'开头。
<linux/tty.h>　　tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。

2.8.4.3 系统专用数据结构子目录 include/sys

<sys/stat.h>　　文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
<sys/times.h>　　定义了进程中运行时间结构 tms 以及 times()函数原型。
<sys/types.h>　　类型头文件。定义了基本的系统数据类型。
<sys/utsname.h>　系统名称结构头文件。
<sys/wait.h>　　等待调用头文件。定义系统调用 wait()核 waitpid()及相关常数符号。

2.8.5 内核初始化程序目录 init

该目录中仅包含一个文件 main.c。用于执行内核所有的初始化工作，然后移到用户模式创建新进程，并在控制台设备上运行 shell 程序。

程序首先根据机器内存的多少对缓冲区内存容量进行分配，如果还设置了要使用虚拟盘，则在缓冲区内存后面也为它留下空间。之后就进行所有硬件的初始化工作，包括人工创建第一个任务（task 0），并设置了中断允许标志。在执行从核心态移到用户态之后，系统第一次调用创建进程函数 fork()，创建出一个用于运行 init()的进程，在该子进程中，系统将进行控制台环境设置，并且在生成一个子进程用来运行 shell 程序。

2.8.6 内核程序主目录 kernel

linux/kernel 目录中共包含 12 个代码文件和一个 Makefile 文件，另外还有 3 个子目录。所有处理任务的程序都保存在 kernel/目录中，其中包括象 fork、exit、调度程序以及一些系统调用程序等。还包括处理中断异常和陷阱的处理过程。子目录中包括了低层的设备驱动程序，如 get_hd_block 和 tty_write 等。由于这些文件中代码之间调用关系复杂，因此这里就不详细列出各文件之间的引用关系图，但仍然可以进行大概分类，见图 2-23 所示。

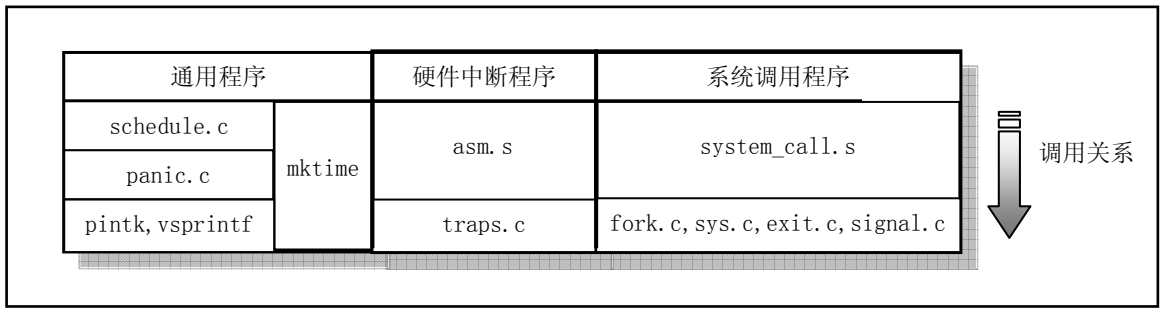

图 2-23 各文件的调用层次关系

asm.s 程序是用于处理系统硬件异常所引起的中断，对各硬件异常的实际处理程序则是在 traps.c 文件中，在各个中断处理过程中，将分别调用 traps.c 中相应的 C 语言处理函数。

exit.c 程序主要包括用于处理进程终止的系统调用。包含进程释放、会话（进程组）终止和程序退出处理函数以及杀死进程、终止进程、挂起进程等系统调用函数。

fork.c 程序给出了 sys_fork()系统调用中使用了两个 C 语言函数：find_empty_process()和 copy_process()。

mktime.c 程序包含一个内核使用的时间函数 mktime()，用于计算从 1970 年 1 月 1 日 0 时起到开机当日的秒数，作为开机秒时间。仅在 init/main.c 中被调用一次。

panic.程序包含一个显示内核出错信息并停机的函数 panic()。

printk.c 程序包含一个内核专用信息显示函数 printk()。

sched.c 程序中包括有关调度的基本函数(sleep_on、wakeup、schedule 等)以及一些简单的系统调用函数。另外还有几个与定时相关的软盘操作函数。

signal.c 程序中包括了有关信号处理的 4 个系统调用以及一个在对应的中断处理程序中处理信号的函数 do_signal()。

sys.c 程序包括很多系统调用函数，其中有些还没有实现。

system_call.s 程序实现了 Linux 系统调用（int 0x80）的接口处理过程，实际的处理过程则包含在各系统调用相应的 C 语言处理函数中，这些处理函数分布在整个 Linux 内核代码中。

vsprintf.c 程序实现了现在已经归入标准库函数中的字符串格式化函数。

2.8.6.1 块设备驱动程序子目录 kernel/blk_drv

通常情况下，用户是通过文件系统来访问设备的，因此设备驱动程序为文件系统实现了调用接口。在使用块设备时，由于其数据吞吐量大，为了能够高效率地使用块设备上的数据，在用户进程与块设备之间使用了高速缓冲机制。在访问块设备上的数据时，系统首先以数据块的形式把块设备上的数据读入到高速缓冲区中，然后再提供给用户。blk_drv 子目录共包含 4 个 c 文件和 1 个头文件。头文件 blk.h 由于是块设备程序专用的，所以与 C 文件放在一起。这几个文件之间的大致关系，见图 2-24 所示。

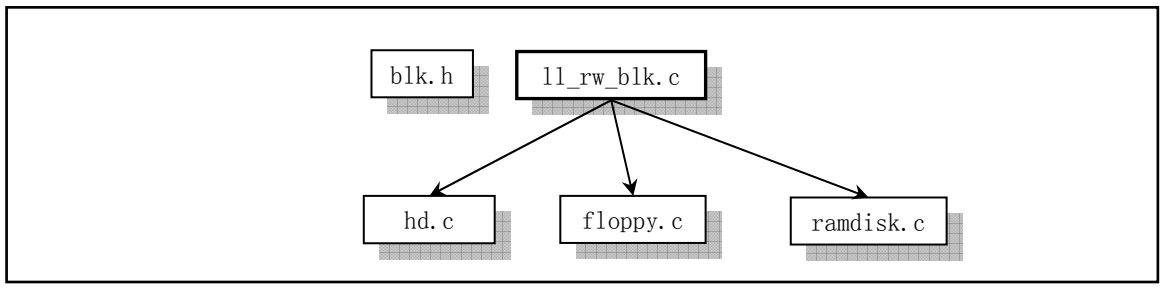

图 2-24 blk_drv 目录中文件的层次关系。

blk.h 中定义了 3 个 C 程序中共用的块设备结构和数据块请求结构。hd.c 程序主要实现对硬盘数据块进行读/写的底层驱动函数，主要是 do_hd__request()函数；floppy.c 程序中主要实现了对软盘数据块的读/写驱动函数，主要是 do_fd_request()函数。ll_rw_blk.c 中程序实现了低层块设备数据读/写函数 ll_rw_block()，内核中所有其他程序都是通过该函数对块设备进行数据读写操作。你将看到该函数在许多访问块设备数据的地方被调用，尤其是在高速缓冲区处理文件 fs/buffer.c 中。

2.8.6.2 字符设备驱动程序子目录 kernel/chr_drv

字符设备程序子目录共含有 4 个 C 语言程序和 2 个汇编程序文件。这些文件实现了对串行端口 rs-232、串行终端、键盘和控制台终端设备的驱动。图 2-25 是这些文件之间的大致调用层次关系。

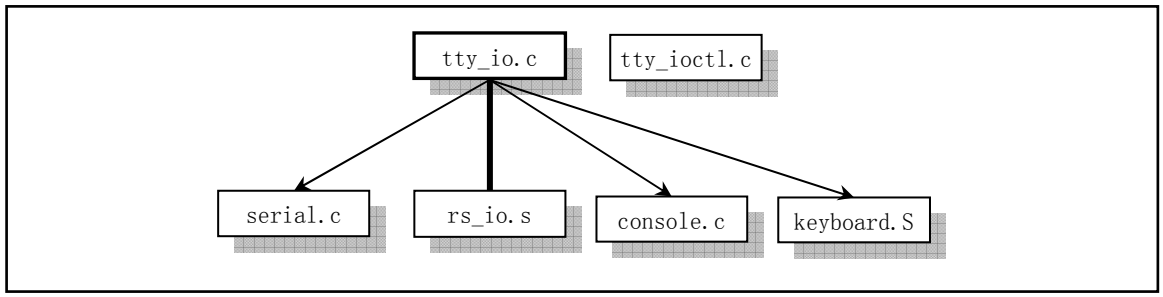

图 2-25 字符设备程序之间的关系示意图

tty_io.c 程序中包含 tty 字符设备读函数 tty_read()和写函数 tty_write()，为文件系统提供了上层访问接口。另外还包括在串行中断处理过程中调用的 C 函数 do_tty_interrupt()，该函数将会在中断类型为读字符的处理中被调用。

console.c 文件主要包含控制台初始化程序和控制台写函数 con_write()，用于被 tty 设备调用。还包含对显示器和键盘中断的初始化设置程序 con_init()。

rs_io.s 汇编程序用于实现两个串行接口的中断处理程序。该中断处理程序会根据从中断标识寄存器（端口 0x3fa 或 0x2fa）中取得的 4 种中断类型分别进行处理，并在处理中断类型为读字符的代码中调用 do_tty_interrupt()。

serial.c 用于对异步串行通信芯片 UART 进行初始化操作，并设置两个通信端口的中断向量。另外还

包括 tty 用于往串口输出的 rs_write()函数。

tty_ioctl.c 程序实现了 tty 的 io 控制接口函数 tty_ioctl()以及对 termio(s)终端 io 结构的读写函数，并会在实现系统调用 sys_ioctl()的 fs/ioctl.c 程序中被调用。

keyboard.S 程序主要实现了键盘中断处理过程 keyboard_interrupt。

2.8.6.3 协处理器仿真和操作程序子目录 kernel/math

该子目录中目前仅有一个 C 程序 math_emulate.c。其中的 math_emulate()函数是中断 int7 的中断处理程序调用的 C 函数。当机器中没有数学协处理器，而 CPU 却又执行了协处理器的指令时，就会引发该中断。因此，使用该中断就可以用软件来仿真协处理器的功能。本书所讨论的内核版本还没有包含有关协处理器的仿真代码。本程序中只是打印一条出错信息，并向用户程序发送一个协处理器错误信号 SIGFPE。

2.8.7 内核库函数目录 lib

内核库函数用于为内核初始化程序 init/main.c 运行在用户态的进程（进程 0、1）提供调用支持。它与普通静态库的实现方法完全一样。读者可从中了解一般 libc 函数库的基本组成原理。在 lib/目录中共有 12 个 C 语言文件，除了一个由 tytso 编制的 malloc.c 程序较长以外，其他的程序很短，有的只有一二行代码，实现了一些系统调用的接口函数。

这些文件中主要包括有退出函数_exit()、关闭文件函数 close(fd)、复制文件描述符函数 dup()、文件打开函数 open()、写文件函数 write()、执行程序函数 execve()、内存分配函数 malloc()、等待子进程状态函数 wait()、创建会话系统调用 setsid()以及在 include/string.h 中实现的所有字符串操作函数。

2.8.8 内存管理程序目录 mm

该目录包括 2 个代码文件。主要用于管理程序对主内存区的使用，实现了进程逻辑地址到线性地址以及线性地址到主内存区中物理内存地址的映射，通过内存的分页管理机制，在进程的虚拟内存页与主内存区的物理内存页之间建立了对应关系。

Linux 内核对内存的处理使用了分页和分段两种方式。首先是将 386 的 4G 虚拟地址空间分割成 64 个段，每个段 64MB。所有内核程序占用其中第一个段，并且物理地址与该段线性地址相同。然后每个任务分配一个段使用。分页机制用于把指定的物理内存页面映射到段内，检测 fork 创建的任何重复的拷贝，并执行写时复制机制。

page.s 文件包括内存页面异常中断（int 14）处理程序，主要用于处理程序由于缺页而引起的页异常中断和访问非法地址而引起的页保护。

memory.c 程序包括对内存进行初始化的函数 mem_init()，由 page.s 的内存处理中断过程调用的 do_no_page()和 do_wp_page()函数。在创建新进程而执行复制进程操作时，即使用该文件中的内存处理函数来分配管理内存空间。

2.8.9 编译内核工具程序目录 tools

该目录下的 build.c 程序用于将 Linux 各个目录中被分别编译生成的目标代码连接合并成一个可运行的内核映像文件 image。其具体的功能可参见下一章内容。

2.9 内核系统与用户程序的关系

在 Linux 系统中，内核为应用程序提供了两方面的接口。其一是系统调用接口（在第 5 章中说明），也即中断调用 int 0x80；另一方面是通过内核库函数（在第 12 章中说明）与内核进行信息交流。内核库函数是基本 C 函数库 libc 的组成部分。许多系统调用是作为基本 C 语言函数库的一部分实现的。

系统调用主要是提供给系统软件直接使用或用于库函数的实现。而一般用户开发的程序则是通过调

用象 libc 等库中的函数来访问内核资源。通过调用这些库中的程序，应用程序代码能够完成各种常用工作，例如，打开和关闭对文件或设备的访问、进行科学计算、出错处理以及访问组和用户标识号 ID 等系统信息。

系统调用是内核与外界接口的最高层。在内核中，每个系统调用都有一个序列号（在 include/unistd.h 头文件中定义），并常以宏的形式实现。应用程序不应该直接使用系统调用，因为这样的话，程序的移植性就不好了。因此目前 Linux 标准库 LSB（Linux Standard Base）和许多其他标准都不允许应用程序直接访问系统调用宏。系统调用的有关文档可参见 Linux 操作系统的在线手册的第 2 部分。

库函数一般包括 C 语言没有提供的执行高级功能的用户级函数，例如输入/输出和字符串处理函数。某些库函数只是系统调用的增强功能版。例如，标准 I/O 库函数 fopen 和 fclose 提供了与系统调用 open 和 close 类似的功能，但却是在更高的层次上。在这种情况下，系统调用通常能提供比库函数略微好一些的性能，但是库函数却能提供更多的功能，而且更具检错能力。系统提供的库函数有关文档可参见操作系统的在线手册第 3 部分。

2.10 linux/Makefile 文件

从本节起，我们开始对内核源代码文件进行注释。首先注释 linux 目录下遇到的第一个文件 Makefile。后续章节将按照这里类似的描述结构进行注释。

2.10.1 功能描述

Makefile 文件相当于程序编译过程中的批处理文件。是工具程序 make 运行时的输入数据文件。只要在含有 Makefile 的当前目录中键入 make 命令，它就会依据 Makefile 文件中的设置对源程序或目标代码文件进行编译、连接或进行安装等活动。

make 工具程序能自动地确定一个大程序系统中那些程序文件需要被重新编译，并发出命令对这些程序文件进行编译。在使用 make 之前，需要编写 Makefile 信息文件，该文件描述了整个程序包中各程序之间的关系，并针对每个需要更新的文件给出具体的控制命令。通常，执行程序是根据其目标文件进行更新的，而这些目标文件则是由编译程序创建的。一旦编写好一个合适的 Makefile 文件，那么在你每次修改过程序系统中的某些源代码文件后，执行 make 命令就能进行所有必要的重新编译工作。make 程序是使用 Makefile 数据文件和代码文件的最后修改时间(last-modification time)来确定那些文件需要进行更新，对于每一个需要更新的文件它会根据 Makefile 中的信息发出相应的命令。在 Makefile 文件中，开头为'#'的行是注释行。文件开头部分的'='赋值语句定义了一些参数或命令的缩写。

这个 Makefile 文件的主要作用是指示 make 程序最终使用独立编译连接成的 tools/目录中的 build 执行程序将所有内核编译代码连接和合并成一个可运行的内核映像文件 image。具体是对 boot/中的 bootsect.s、setup.s 使用 8086 汇编器进行编译，分别生成各自的执行模块。再对源代码中的其他所有程序使用 GNU 的编译器 gcc/gas 进行编译，并连接成模块 system。再用 build 工具将这三块组合成一个内核映像文件 image. 基本编译连接/组合结构如图 2-26 所示。

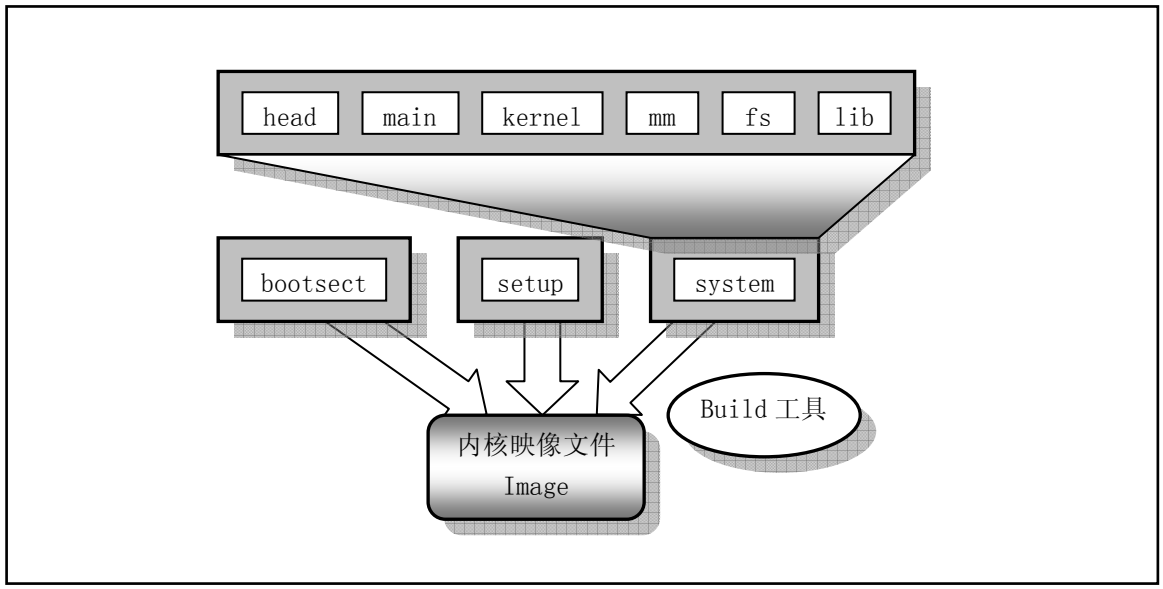

图 2-26 内核编译连接/组合结构

2.10.2 代码注释

程序 2-1 linux/Makefile 文件

```
 1 #
 2 # if you want the ram-disk device, define this to be the # 如果你要使用 RAM 盘设备的话，就
 3 # size in blocks.                                       # 定义块的大小。
 4 #
 5 RAMDISK = #-DRAMDISK=512
 6
 7 AS86    =as86 -0 -a        # 8086 汇编编译器和连接器，见列表后的介绍。后带的参数含义分别
 8 LD86    =ld86 -0           # 是：-0 生成 8086 目标程序；-a 生成与 gas 和 gld 部分兼容的代码。
 9
10 AS      =gas               # GNU 汇编编译器和连接器，见列表后的介绍。
11 LD      =gld
12 LDFLAGS =-s -x -M          # GNU 连接器 gld 运行时用到的选项。含义是：-s 输出文件中省略所
                              # 有的符号信息；-x 删除所有局部符号；-M 表示需要在标准输出设备
                              # (显示器)上打印连接映像(link map)，是指由连接程序产生的一种
                              # 内存地址映像，其中列出了程序段装入到内存中的位置信息。具体
                              # 来讲有如下信息：
                              # • 目标文件及符号信息映射到内存中的位置；
                              # • 公共符号如何放置；
                              # • 连接中包含的所有文件成员及其引用的符号。
13 CC      =gcc $(RAMDISK)    # gcc 是 GNU C 程序编译器。对于 UNIX 类的脚本(script)程序而言，
                              # 在引用定义的标识符时，需在前面加上$符号并用括号括住标识符。
14 CFLAGS  =-Wall -O -fstrength-reduce -fomit-frame-pointer \
15 -fcombine-regs -mstring-insns  # gcc 的选项。前一行最后的'\'符号表示下一行是续行。
                                  # 选项含义为：-Wall 打印所有警告信息；-O 对代码进行优化；
                                  # -fstrength-reduce 优化循环语句；-mstring-insns 是
                                  # Linus 在学习 gcc 编译器时为 gcc 增加的选项，用于 gcc-1.40
                                  # 在复制结构等操作时使用 386 CPU 的字符串指令，可以去掉。
16 CPP     =cpp -nostdinc -Iinclude  # cpp 是 gcc 的前(预)处理程序。-nostdinc -Iinclude 的含
                                     # 义是不要搜索标准的头文件目录中的文件，而是使用-I
                                     # 选项指定的目录或者是在当前目录里搜索头文件。
```

```
17
18 #
19 # ROOT_DEV specifies the default root-device when making the image.
20 # This can be either FLOPPY, /dev/xxxx or empty, in which case the
21 # default of /dev/hd6 is used by 'build'.
22 #
23 ROOT_DEV=/dev/hd6   # ROOT_DEV 指定在创建内核映像(image)文件时所使用的默认根文件系统所
                      # 在的设备，这可以是软盘(FLOPPY)、/dev/xxxx 或者干脆空着，空着时
                      # build 程序（在 tools/目录中）就使用默认值/dev/hd6。
24
25 ARCHIVES=kernel/kernel.o mm/mm.o fs/fs.o  # kernel 目录、mm 目录和 fs 目录所产生的目标代
                                            # 码文件。为了方便引用在这里将它们用
                                            # ARCHIVES（归档文件）标识符表示。
26 DRIVERS =kernel/blk_drv/blk_drv.a kernel/chr_drv/chr_drv.a  # 块和字符设备库文件。.a 表
                                # 示该文件是个归档文件，也即包含有许多可执行二进制代码子程
                                # 序集合的库文件，通常是用 GNU 的 ar 程序生成。ar 是 GNU 的二进制
                                # 文件处理程序，用于创建、修改以及从归档文件中抽取文件。
27 MATH    =kernel/math/math.a          # 数学运算库文件。
28 LIBS    =lib/lib.a                   # 由 lib/目录中的文件所编译生成的通用库文件。
29
30 .c.s:                        # make 老式的隐式后缀规则。该行指示 make 利用下面的命令将所有的
                                # .c 文件编译生成.s 汇编程序。':'表示下面是该规则的命令。
31         $(CC) $(CFLAGS) \
32         -nostdinc -Iinclude -S -o $*.s $<  # 指使 gcc 采用前面 CFLAGS 所指定的选项以及
                                # 仅使用 include/目录中的头文件，在适当地编译后不进行汇编就
                                # 停止（-S），从而产生与输入的各个 C 文件对应的汇编语言形式的
                                # 代码文件。默认情况下所产生的汇编程序文件是原 C 文件名去掉.c
                                # 而加上.s 后缀。-o 表示其后是输出文件的形式。其中$*.s（或$@）
                                # 是自动目标变量，$<代表第一个先决条件，这里即是符合条件
                                # *.c 的文件。
33 .s.o:                           # 表示将所有.s 汇编程序文件编译成.o 目标文件。下一条是实
                                   # 现该操作的具体命令。
34         $(AS) -c -o $*.o $<  # 使用 gas 编译器将汇编程序编译成.o 目标文件。-c 表示只编译
                                # 或汇编，但不进行连接操作。
35 .c.o:                                   # 类似上面，*.c 文件-→*.o 目标文件。
36         $(CC) $(CFLAGS) \
37         -nostdinc -Iinclude -c -o $*.o $<  # 使用 gcc 将 C 语言文件编译成目标文件但不连接。
38
39 all:     Image            # all 表示创建 Makefile 所知的最顶层的目标。这里即是 Image 文件。
                              # 这里生成的 Image 文件即是引导启动盘映像文件 bootimage。若将其
                              # 写入软盘就可以使用该软盘引导 Linux 系统了。在 Linux 下将 Image
                              # 写入软盘的命令参见 46 行。DOS 系统下可以使用软件 rawrite.exe。
40
41 Image: boot/bootsect boot/setup tools/system tools/build  # 说明目标（Image 文件）是由
                              # 分号后面的 4 个元素产生，分别是 boot/目录中的 bootsect 和
                              # setup 文件、tools/目录中的 system 和 build 文件。
42         tools/build boot/bootsect boot/setup tools/system $(ROOT_DEV) > Image
43         sync             # 这两行是执行的命令。第一行表示使用 tools 目录下的 build 工具
                              # 程序（下面会说明如何生成）将 bootsect、setup 和 system 文件
                              # 以$(ROOT_DEV)为根文件系统设备组装成内核映像文件 Image。
                              # 第二行的 sync 同步命令是迫使缓冲块数据立即写盘并更新超级块。
44
45 disk: Image                              # 表示 disk 这个目标要由 Image 产生。
```

```
46          dd bs=8192 if=Image of=/dev/PS0  # dd 为 UNIX 标准命令：复制一个文件，根据选项
                                             # 进行转换和格式化。bs=表示一次读/写的字节数。
                                             # if=表示输入的文件，of=表示输出到的文件。
                                             # 这里/dev/PS0 是指第一个软盘驱动器(设备文件)。
                                             # 在 Linux 系统下使用/dev/fd0。
47
48 tools/build: tools/build.c            # 由 tools 目录下的 build.c 程序生成执行程序 build。
49          $(CC) $(CFLAGS) \
50          -o tools/build tools/build.c  # 编译生成执行程序 build 的命令。
51
52 boot/head.o: boot/head.s               # 利用上面给出的.s.o 规则生成 head.o 目标文件。
53
54 tools/system:   boot/head.o init/main.o \
55                  $(ARCHIVES) $(DRIVERS) $(MATH) $(LIBS)  # 表示 tools 目录中的 system 文件
                                                            # 要由分号右边所列的元素生成。
56          $(LD) $(LDFLAGS) boot/head.o init/main.o \
57          $(ARCHIVES) \
58          $(DRIVERS) \
59          $(MATH) \
60          $(LIBS) \
61          -o tools/system > System.map   # 生成 system 的命令。最后的 > System.map 表示
                                           # gld 需要将连接映像重定向存放在 System.map 文件中。
                                           # 关于 System.map 文件的用途参见注释后的说明。
62
63 kernel/math/math.a:                   # 数学协处理函数文件 math.a 由下一行上的命令实现。
64          (cd kernel/math; make)       # 进入 kernel/math/目录；运行 make 工具程序。
                                         # 下面从 66--82 行的含义与此处的类似。
65
66 kernel/blk_drv/blk_drv.a:             # 块设备函数文件 blk_drv.a
67          (cd kernel/blk_drv; make)
68
69 kernel/chr_drv/chr_drv.a:             # 字符设备函数文件 chr_drv.a
70          (cd kernel/chr_drv; make)
71
72 kernel/kernel.o:                      # 内核目标模块 kernel.o
73          (cd kernel; make)
74
75 mm/mm.o:                              # 内存管理模块 mm.o
76          (cd mm; make)
77
78 fs/fs.o:                              # 文件系统目标模块 fs.o
79          (cd fs; make)
80
81 lib/lib.a:                            # 库函数 lib.a
82          (cd lib; make)
83
84 boot/setup: boot/setup.s                          # 这里开始的三行是使用 8086 汇编和连接器
85          $(AS86) -o boot/setup.o boot/setup.s     # 对 setup.s 文件进行编译生成 setup 文件。
86          $(LD86) -s -o boot/setup boot/setup.o    # -s 选项表示要去除目标文件中的符号信息。
87
88 boot/bootsect:  boot/bootsect.s                   # 同上。生成 bootsect.o 磁盘引导块。
89          $(AS86) -o boot/bootsect.o boot/bootsect.s
90          $(LD86) -s -o boot/bootsect boot/bootsect.o
```

```
91
    # 下面 92--95 行的作用是在 bootsect.s 文本程序开始处添加一行有关 system 模块文件长度信息，
    # 在把 system 模块加载到内存期间用于指明系统模块的长度。添加该行信息的方法是首先生成只含
    # 有“SYSSIZE = system 文件实际长度”一行信息的 tmp.s 文件，然后将 bootsect.s 文件添加在其后。
    # 取得 system 长度的方法是：首先利用命令 ls 对编译生成的 system 模块文件进行长列表显示，用
    # grep 命令取得列表行上文件字节数字段信息，并定向保存在 tmp.s 临时文件中。cut 命令用于剪切
    # 字符串，tr 用于去除行尾的回车符。其中：(实际长度 + 15)/16 用于获得用‘节’表示的长度信息，
    # 1 节=16 字节。
    # 注意：这是 Linux 0.11 之前的内核版本（0.01--0.10）获取 system 模块长度并添加到 bootsect.s
    # 程序中使用的方法。从 0.11 版内核开始已不是这个方法，而是直接在 bootsect.s 程序开始处给出
    # system 模块的一个最大默认长度值。因此这个规则现在已经不起作用。
92  tmp.s:  boot/bootsect.s tools/system
93          (echo -n "SYSSIZE = (";ls -l tools/system | grep system \
94                  | cut -c25-31 | tr '\012' ' '; echo "+ 15 ) / 16") > tmp.s
95          cat boot/bootsect.s >> tmp.s
96
97  clean:  # 当执行'make clean'时，就会执行 98--103 行上的命令，去除所有编译连接生成的文件。
            # 'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
98          rm -f Image System.map tmp_make core boot/bootsect boot/setup
99          rm -f init/*.o tools/system tools/build boot/*.o
100         (cd mm;make clean)      # 进入 mm/目录；执行该目录 Makefile 文件中的 clean 规则。
101         (cd fs;make clean)
102         (cd kernel;make clean)
103         (cd lib;make clean)
104
105 backup: clean   # 该规则将首先执行上面的 clean 规则，然后对 linux/目录进行压缩，生成
                    # backup.Z 压缩文件。'cd .. '表示退到 linux/的上一级（父）目录；
                    # 'tar cf - linux'表示对 linux/目录执行 tar 归档程序。-cf 表示需要创建
                    # 新的归档文件 '| compress -'表示将 tar 程序的执行通过管道操作('|')
                    # 传递给压缩程序 compress，并将压缩程序的输出存成 backup.Z 文件。
106         (cd .. ; tar cf - linux | compress - > backup.Z)
107         sync    # 迫使缓冲块数据立即写盘并更新磁盘超级块。
108
109 dep:
    # 该目标或规则用于各文件之间的依赖关系。创建的这些依赖关系是为了给 make 用来确定是否需要要
    # 重建一个目标对象的。比如当某个头文件被改动过后，make 就通过生成的依赖关系，重新编译与该
    # 头文件有关的所有*.c 文件。具体方法如下：
    # 使用字符串编辑程序 sed 对 Makefile 文件（这里即是自己）进行处理，输出为删除 Makefile
    # 文件中'### Dependencies'行后面的所有行（下面从 118 开始的行），并生成 tmp_make
    # 临时文件（也即 110 行的作用）。然后对 init/目录下的每一个 C 文件（其实只有一个文件
    # main.c）执行 gcc 预处理操作，-M 标志告诉预处理程序输出描述每个目标文件相关性的规则，
    # 并且这些规则符合 make 语法。对于每一个源文件，预处理程序输出一个 make 规则，其结果
    # 形式是相应源程序文件的目标文件名加上其依赖关系--该源文件中包含的所有头文件列表。
    # 111 行中的$$i 实际上是$($i)的意思。这里$i 是这句前面的 shell 变量的值。
    # 然后把预处理结果都添加到临时文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。
110         sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
111         (for i in init/*.c;do echo -n "init/";$(CPP) -M $$i;done) >> tmp_make
112         cp tmp_make Makefile
113         (cd fs; make dep)       # 对 fs/目录下的 Makefile 文件也作同样的处理。
114         (cd kernel; make dep)
115         (cd mm; make dep)
116
117 ### Dependencies:
```

```
118 init/main.o : init/main.c include/unistd.h include/sys/stat.h \
119   include/sys/types.h include/sys/times.h include/sys/utsname.h \
120   include/utime.h include/time.h include/linux/tty.h include/termios.h \
121   include/linux/sched.h include/linux/head.h include/linux/fs.h \
122   include/linux/mm.h include/signal.h include/asm/system.h include/asm/io.h \
123   include/stddef.h include/stdarg.h include/fcntl.h
```

2.10.3 其他信息

2.10.3.1 Makefile 简介

makefile 文件是 make 工具程序的配置文件。Make 工具程序的主要用途是能自动地决定一个含有很多源程序文件的大型程序中哪个文件需要被重新编译。makefile 的使用比较复杂，这里只是根据上面的 makefile 文件作些简单的介绍。详细说明请参考 GNU make 使用手册。

为了使用 make 程序，你就需要 makefile 文件来告诉 make 要做些什么工作。通常，makefile 文件会告诉 make 如何编译和连接一个文件。当明确指出时，makefile 还可以告诉 make 运行各种命令（例如，作为清理操作而删除某些文件）。

make 的执行过程分为两个不同的阶段。在第一个阶段，它读取所有的 makefile 文件以及包含的 makefile 文件等，记录所有的变量及其值、隐式的或显式的规则，并构造出所有目标对象及其先决条件的一幅全景图。在第二阶段期间，make 就使用这些内部结构来确定哪个目标对象需要被重建，并且使用相应的规则来操作。

当 make 重新编译程序时，每个修改过的 C 代码文件必须被重新编译。如果一个头文件被修改过了，那么为了确保正确，每一个包含该头文件的 C 代码程序都将被重新编译。每次编译操作都产生一个与源程序对应的目标文件(object file)。最终，如果任何源代码文件被编译过了，那么所有的目标文件不管是刚编译完的还是以前就编译好的必须连接在一起以生成新的可执行文件。

简单的 makefile 文件含有一些规则，这些规则具有如下的形式：

```
目标(target)... : 先决条件(prerequisites)...
                  命令(command)
                  ...
                  ...
```

其中'目标'对象通常是程序生成的一个文件的名称；例如是一个可执行文件或目标文件。目标也可以是所要采取活动的名字，比如'清除'('clean')。'先决条件'是一个或多个文件名，是用作产生目标的输入条件。通常一个目标依赖几个文件。而'命令'是 make 需要执行的操作。一个规则可以有多个命令，每一个命令自成一行。请注意，你需要在每个命令行之前键入一个制表符！这是粗心者常常忽略的地方。

如果一个先决条件通过目录搜寻而在另外一个目录中被找到，这并不会改变规则的命令；它们将被如期执行。因此，你必须小心地设置命令，使得命令能够在 make 发现先决条件的目录中找到需要的先决条件。这就需要通过使用自动变量来做到。自动变量是一种在命令行上根据具体情况能被自动替换的变量。自动变量的值是基于目标对象及其先决条件而在命令执行前设置的。例如，'$^'的值表示规则的所有先决条件，包括它们所处目录的名称；'$<'的值表示规则中的第一个先决条件；'$@'表示目标对象；另外还有一些自动变量这里就不提了。

有时，先决条件还常包含头文件，而这些头文件并不愿在命令中说明。此时自动变量'$<'正是第一个先决条件。例如：

```
foo.o : foo.c defs.h hack.h
```

```
        cc -c $(CFLAGS) $< -o $@
```

其中的'$<'就会被自动地替换成 foo.c，而$@则会被替换为 foo.o

为了让 make 能使用习惯用法来更新一个目标对象，你可以不指定命令，写一个不带命令的规则或者不写规则。此时 make 程序将会根据源程序文件的类型（程序的后缀）来判断要使用哪个隐式规则。

后缀规则是为 make 程序定义隐式规则的老式方法。(现在这种规则已经不用了，取而代之的是使用更通用更清晰的模式匹配规则)。下面例子就是一种双后缀规则。双后缀规则是用一对后缀定义的：源后缀和目标后缀。相应的隐式先决条件是通过使用文件名中的源后缀替换目标后缀后得到。因此，此时下面的'$<'值是*.c 文件名。而正条 make 规则的含义是将*.c 程序编译成*.s 代码。

```
.c.s:
        $(CC) $(CFLAGS) \
        -nostdinc -Iinclude -S -o $*.s $<
```

通常命令是属于一个具有先决条件的规则，并在任何先决条件改变时用于生成一个目标(target)文件。然而，为目标而指定命令的规则也并不一定要有先决条件。例如，与目标'clean'相关的含有删除(delete)命令的规则并不需要有先决条件。此时，一个规则说明了如何以及何时来重新制作某些文件，而这些文件是特定规则的目标。make 根据先决条件来执行命令以创建或更新目标。一个规则也可以说明如何及何时执行一个操作。

一个 makefile 文件也可以含有除规则以外的其他文字，但一个简单的 makefile 文件只需要含有适当的规则。规则可能看上去要比上面示出的模板复杂得多，但基本上都是符合的。

makefile 文件最后生成的依赖关系是用于让 make 来确定是否需要重建一个目标对象。比如当某个头文件被改动过后，make 就通过这些依赖关系，重新编译与该头文件有关的所有*.c 文件。

2.10.3.2 as86,ld86 简介

as86 和 ld86 是由 Bruce Evans 编写的 Intel 8086 汇编编译程序和连接程序。它完全是一个 8086 的汇编编译器，但却可以为 386 处理器编制 32 位的代码。Linux 使用它仅仅是为了创建 16 位的启动扇区(bootsector)代码和 setup 二进制执行代码。该编译器的语法与 GNU 的汇编编译器的语法是不兼容的，但近似于 Intel 的汇编语言语法（如操作数的次序相反等）。

Bruce Evans 是 minix 操作系统 32 位版本的主要编制者，他与 Linux 的创始人 Linus Torvalds 是很好的朋友。Linus 本人也从 Bruce Evans 那里学到了不少有关 UNIX 类操作系统的知识，minix 操作系统的不足之处也是两个好朋友互相探讨得出的结果，这激发了 Linus 在 Intel 386 体系结构上开发一个全新概念的操作系统，因此 Linux 操作系统的诞生与 Bruce Evans 也有着密切的关系。

有关这个编译器和连接器的源代码可以从 FTP 服务器 ftp.funet.fi 上或从我的网站(www.oldlinux.org)上下载。

这两个程序的使用方法和选项如下：

as 的使用方法和选项：

```
as [-03agjuw] [-b [bin]] [-lm [list]] [-n name] [-o obj] [-s sym] src
```

默认设置（除了以下默认值以外，其他选项默认为关闭或无；若没有明确说明 a 标志，则不会有输出）：
-03　　32 位输出；
list　　在标准输出上显示；
name　　源文件的基本名称（也即不包括“.“后的扩展名）；
选项含义：

```
-0  从 16 比特代码段开始；
-3  从 32 比特代码段开始；
-a  开启与 as、ld 的部分兼容性选项；
-b  产生二进制文件，后面可以跟文件名；
-g  在目标文件中仅存入全局符号；
-j  使所有跳转语句均为长跳转；
-l  产生列表文件，后面可以跟随列表文件名；
-m  在列表中扩展宏定义；
-n  后面跟随模块名称（取代源文件名称放入目标文件中）；
-o  产生目标文件，后跟目标文件名；
-s  产生符号文件，后跟符号文件名；
-u  将未定义符号作为输入的未指定段的符号；
-w  不显示警告信息；
```

```
ld 连接器的使用语法和选项：
对于生成 Minix a.out 格式的版本：
ld [-03Mims[-]]  [-T textaddr] [-llib_extension] [-o outfile] infile...

对于生成 GNU-Minix 的 a.out 格式的版本：
ld [-03Mimrs[-]] [-T textaddr] [-llib_extension] [-o outfile] infile...

默认设置(除了以下默认值以外，其他选项默认为关闭或无):
-03      32 位输出；
outfile      a.out 格式输出；

-0  产生具有 16 比特魔数的头结构，并且对-lx 选项使用 i86 子目录；
-3  产生具有 32 比特魔数的头结构，并且对-lx 选项使用 i386 子目录；
-M  在标准输出设备上显示已链接的符号；
-T  后面跟随文本基地址（使用适合于 strtoul 的格式)；
-i  分离的指令与数据段（I&D）输出；
-lx 将库/local/lib/subdir/libx.a 加入链接的文件列表中；
-m  在标准输出设备上显示已链接的模块；
-o  指定输出文件名，后跟输出文件名；
-r  产生适合于进一步重定位的输出；
-s  在目标文件中删除所有符号。
```

2.10.3.3 System.map 文件

System.map 文件用于存放内核符号表信息。符号表是所有符号及其对应地址的一个列表。随着每次内核的编译，就会产生一个新的对应 System.map 文件。当内核运行出错时，通过 System.map 文件中的符号表解析，就可以查到一个地址值对应的变量名，或反之。

利用 System.map 符号表文件，在内核或相关程序出错时，就可以获得我们比较容易识别的信息。符号表的样例如下所示：

```
c03441a0 B dmi_broken
c03441a4 B is_sony_vaio_laptop
c03441c0 b dmi_ident
c0344200 b pci_bios_present
c0344204 b pirq_table
```

可以看出名称为 dmi_broken 的变量位于内核地址 c03441a0 处。

System.map 位于使用它的软件(例如内核日志记录后台程序 klogd)能够寻找到的地方。在系统启动

时，如果没有以一个参数的形式为 klogd 给出 System.map 的位置，则 klogd 将会在三个地方搜寻 System.map。依次为：

```
/boot/System.map
/System.map
/usr/src/linux/System.map
```

尽管内核本身实际上不使用 System.map，但其他程序，象 klogd，lsof，ps 以及其他许多软件，象 dosemu，都需要有一个正确的 System.map 文件。利用该文件，这些程序就可以根据已知的内存地址查找出对应的内核变量名称，便于对内核的调试工作。

2.11 本章小结

本章概述了 Linux 早期操作系统的内核模式和体系结构。给出了 Linux 0.11 内核源代码的目录结构形式，并详细地介绍了各个子目录中代码文件的基本功能和层次关系。然后介绍了在 RedHat 9 系统下编译 Linux 0.11 内核时，对代码需要进行修改的地方。最后从 Linux 内核主目录下的 makefile 文件着手，开始对内核源代码进行注释。

第3章 引导启动程序（boot）

3.1 概述

本章主要描述 boot/目录中的三个汇编代码文件，见列表 3-1 所示。正如在前一章中提到的，这三个文件虽然都是汇编程序，但却使用了两种语法格式。bootsect.s 和 setup.s 采用近似于 Intel 的汇编语言语法，需要使用 Intel 8086 汇编编译器和连接器 as86 和 ld86，而 head.s 则使用 GNU 的汇编程序格式，并且运行在保护模式下，需要用 GNU 的 as 进行编译。这是一种 AT&T 语法的汇编语言程序。

使用两种编译器的主要原因是由于对于 Intel x86 处理器系列来讲，GNU 的编译器仅支持 i386 及以后出的 CPU。不支持生成运行在实模式下的程序。

列表 3-1 linux/boot/目录

	文件名	长度(字节)	最后修改时间(GMT)	说明
	bootsect.s	5052 bytes	1991-12-05 22:47:58	
	head.s	5938 bytes	1991-11-18 15:05:09	
	setup.s	5364 bytes	1991-12-05 22:48:10	

阅读这些代码除了需要知道一些一般 8086 汇编语言的知识以外，还要了解一些采用 Intel 80X86 微处理器的 PC 机的体系结构以及 80386 32 位保护模式下的编程原理。所以在开始阅读源代码之前可以先大概浏览一下附录中有关 PC 机硬件接口控制编程和 80386 32 位保护模式的编程方法，在阅读代码时再就事论事地针对具体问题参考附录中的详细说明。

3.2 总体功能

这里先总体说明一下 Linux 操作系统启动部分的主要执行流程。当 PC 的电源打开后，80x86 结构的 CPU 将自动进入实模式，并从地址 0xFFFF0 开始自动执行程序代码，这个地址通常是 ROM-BIOS 中的地址。PC 机的 BIOS 将执行某些系统的检测，并在物理地址 0 处开始初始化中断向量。此后，它将可启动设备的第一个扇区（磁盘引导扇区，512 字节）读入内存绝对地址 0x7C00 处，并跳转到这个地方。启动设备通常是软驱或是硬盘。这里的叙述是非常简单的，但这已经足够理解内核初始化的工作过程了。

Linux 的最最前面部分是用 8086 汇编语言编写的(boot/bootsect.s)，它将由 BIOS 读入到内存绝对地址 0x7C00(31KB)处，当它被执行时就会把自己移到绝对地址 0x90000(576KB)处，并把启动设备中后 2KB 字节代码(boot/setup.s)读入到内存 0x90200 处，而内核的其他部分（system 模块）则被读入到从地址 0x10000 开始处，因为当时 system 模块的长度不会超过 0x80000 字节大小（即 512KB），所以它不会覆盖在 0x90000 处开始的 bootsect 和 setup 模块。后面 setup 程序将会把 system 模块移动到内存起始处，这样 system 模块中代码的地址也即等于实际的物理地址，便于对内核代码和数据的操作。图 3-1 清晰地显示出 Linux 系统启动时这几个程序或模块在内存中的动态位置。其中，每一竖条框代表某一时刻内存中

各程序的映像位置图。在系统加载期间将显示信息"Loading..."。然后控制权将传递给 boot/setup.s 中的代码，这是另一个实模式汇编语言程序。

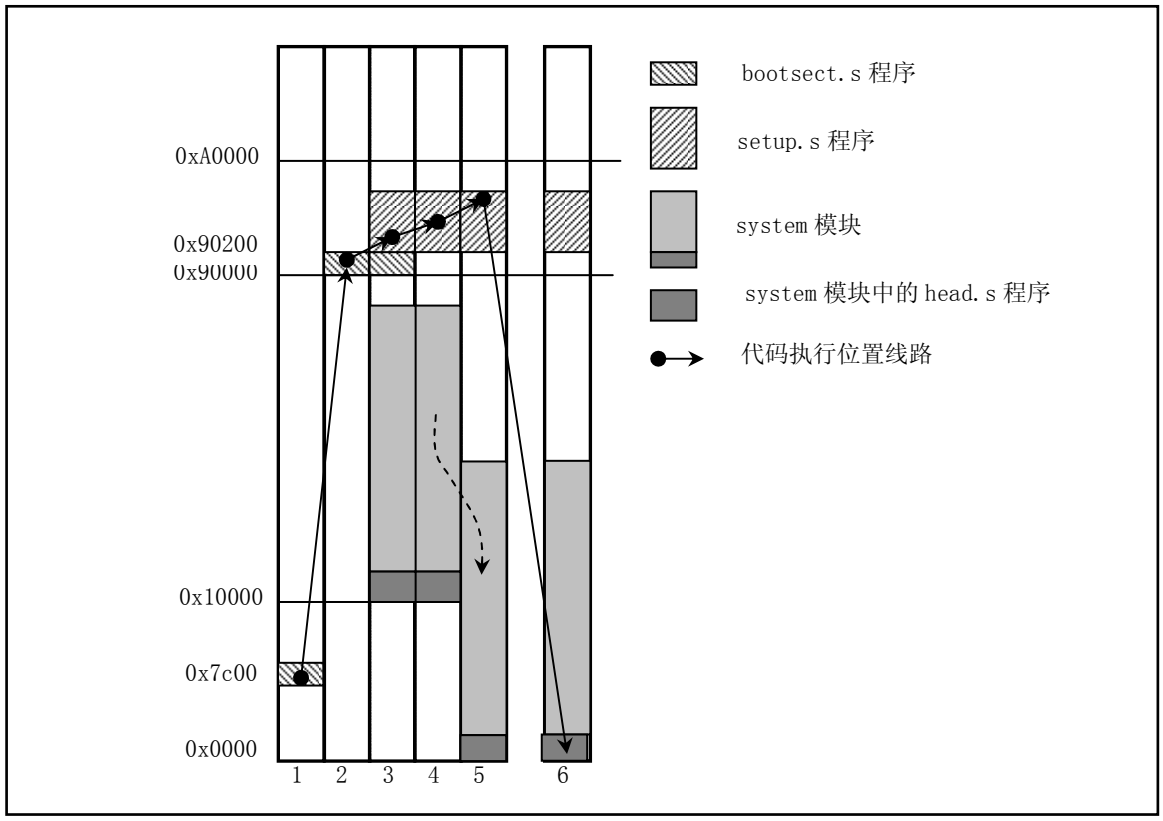

图 3-1 启动引导时内核在内存中的位置和移动后的位置情况

启动部分识别主机的某些特性以及 VGA 卡的类型。如果需要，它会要求用户为控制台选择显示模式。然后将整个系统从地址 0x10000 移至 0x0000 处，进入保护模式并跳转至系统的余下部分（在 0x0000 处）。此时所有 32 位运行方式的设置启动被完成: IDT、GDT 以及 LDT 被加载，处理器和协处理器也已确认，分页工作也设置好了；最终调用 init/main.c 中的 main()程序。上述操作的源代码是在 boot/head.s 中的，这可能是整个内核中最有诀窍的代码了。注意如果在前述任何一步中出了错，计算机就会死锁。在操作系统还没有完全运转之前是处理不了出错的。

为什么不把系统模块直接加载到物理地址 0x0000 开始处而要在 setup 程序中再进行移动呢？这是因为在 setup 程序代码开始部分还需要利用 ROM BIOS 中的中断调用来获取机器的一些参数（例如显示卡模式、硬盘参数表等）。当 BIOS 初始化时会在物理内存开始处放置一个大小为 0x400 字节(1KB)的中断向量表，因此需要在使用完 BIOS 的中断调用后才能将这个区域覆盖掉。

3.3 bootsect.s 程序

3.3.1 功能描述

bootsect.s 代码是磁盘引导块程序，驻留在磁盘的第一个扇区中（引导扇区，0 磁道（柱面），0 磁头，第 1 个扇区）。在 PC 机加电 ROM BIOS 自检后，ROM BIOS 会把引导扇区代码 bootsect 加载到内存 0x7C00 处并执行之。在 bootsect 代码执行期间，它会将自己移动到内存绝对地址 0x90000 开始处并继续执行。该程序的主要作用是首先将 setup 模块（由 setup.s 编译成）从磁盘加载到内存，紧接着 bootsect 的后面

位置（0x90200）,然后利用 BIOS 中断 0x13 取磁盘参数表中当前启动引导盘的参数，接着在屏幕上显示“Loading system...”字符串。再者将 system 模块从磁盘上加载到内存 0x10000 开始的地方。随后确定根文件系统的设备号，若没有指定，则根据所保存的引导盘的每磁道扇区数判别出盘的类型和种类（是 1.44M A 盘吗？）并保存其设备号于 root_dev(引导块的 508 地址处)，最后长跳转到 setup 程序的开始处（0x90200）执行 setup 程序。

3.3.2 代码注释

程序 3-1 linux/boot/bootsect.s

```
1  !
2  ! SYS_SIZE is the number of clicks (16 bytes) to be loaded.
3  ! 0x3000 is 0x30000 bytes = 196kB, more than enough for current
4  ! versions of linux
   ! SYS_SIZE 是要加载的节数（16 字节为 1 节）。0x3000 共为
   ! 0x30000 字节=196 kB（若以 1024 字节为 1KB 计，则应该是 192KB），对于当前的版本空间已足够了。
5  !
6  SYSSIZE = 0x3000     ! 指编译连接后 system 模块的大小。参见程序 2-1 中第 92 行的说明。
                        ! 这里给出了一个最大默认值。
7  !
8  !      bootsect.s              (C) 1991 Linus Torvalds
9  !
10 ! bootsect.s is loaded at 0x7c00 by the bios-startup routines, and moves
11 ! iself out of the way to address 0x90000, and jumps there.
12 !
13 ! It then loads 'setup' directly after itself (0x90200), and the system
14 ! at 0x10000, using BIOS interrupts.
15 !
16 ! NOTE! currently system is at most 8*65536 bytes long. This should be no
17 ! problem, even in the future. I want to keep it simple. This 512 kB
18 ! kernel size should be enough, especially as this doesn't contain the
19 ! buffer cache as in minix
20 !
21 ! The loader has been made as simple as possible, and continuos
22 ! read errors will result in a unbreakable loop. Reboot by hand. It
23 ! loads pretty fast by getting whole sectors at a time whenever possible.
   !
   ! 以下是前面这些文字的翻译：
   !     bootsect.s              (C) 1991 Linus Torvalds 版权所有
   !
   ! bootsect.s 被 bios-启动子程序加载至 0x7c00 (31KB)处，并将自己
   ! 移到了地址 0x90000 (576KB)处，并跳转至那里。
   !
   ! 它然后使用 BIOS 中断将'setup'直接加载到自己的后面(0x90200)(576.5KB)，
   ! 并将 system 加载到地址 0x10000 处。
   !
   ! 注意! 目前的内核系统最大长度限制为(8*65536)(512KB)字节，即使是在
   ! 将来这也应该没有问题的。我想让它保持简单明了。这样 512KB 的最大内核长度应该
   ! 足够了，尤其是这里没有象 minix 中一样包含缓冲区高速缓冲。
   !
   ! 加载程序已经做得够简单了，所以持续的读出错将导致死循环。只能手工重启。
   ! 只要可能，通过一次读取所有的扇区，加载过程可以做得很快。
```

```
24
25 .globl begtext, begdata, begbss, endtext, enddata, endbss  ! 定义了 6 个全局标识符;
26 .text                          ! 文本段;
27 begtext:
28 .data                          ! 数据段;
29 begdata:
30 .bss                           ! 未初始化数据段(Block Started by Symbol);
31 begbss:
32 .text                          ! 文本段;
33
34 SETUPLEN = 4                              ! nr of setup-sectors
                                             ! setup 程序的扇区数(setup-sectors)值;
35 BOOTSEG  = 0x07c0                         ! original address of boot-sector
                                             ! bootsect 的原始地址（是段地址，以下同）;
36 INITSEG  = 0x9000                         ! we move boot here - out of the way
                                             ! 将 bootsect 移到这里 -- 避开;
37 SETUPSEG = 0x9020                         ! setup starts here
                                             ! setup 程序从这里开始;
38 SYSSEG   = 0x1000                         ! system loaded at 0x10000 (65536).
                                             ! system 模块加载到 0x10000（64 KB）处;
39 ENDSEG   = SYSSEG + SYSSIZE               ! where to stop loading
                                             ! 停止加载的段地址;
40
41 ! ROOT_DEV:     0x000 - same type of floppy as boot.
   !                      根文件系统设备使用与引导时同样的软驱设备;
42 !               0x301 - first partition on first drive etc
   !                      根文件系统设备在第一个硬盘的第一个分区上，等等;
43 ROOT_DEV = 0x306   ! 指定根文件系统设备是第 2 个硬盘的第 1 个分区。这是 Linux 老式的硬盘命名
                     ! 方式,具体值的含义如下:
                     ! 设备号=主设备号*256 + 次设备号（也即 dev_no = (major<<8) + minor ）
                     ! （主设备号：1-内存,2-磁盘,3-硬盘,4-ttyx,5-tty,6-并行口,7-非命名管道）
                     ! 0x300 - /dev/hd0 - 代表整个第 1 个硬盘;
                     ! 0x301 - /dev/hd1 - 第 1 个盘的第 1 个分区;
                     !  …
                     ! 0x304 - /dev/hd4 - 第 1 个盘的第 4 个分区;
                     ! 0x305 - /dev/hd5 - 代表整个第 2 个硬盘;
                     ! 0x306 - /dev/hd6 - 第 2 个盘的第 1 个分区;
                     !  …
                     ! 0x309 - /dev/hd9 - 第 2 个盘的第 4 个分区;
                     ! 从 linux 内核 0.95 版后已经使用与现在相同的命名方法了。
44
45 entry start       ! 告知连接程序，程序从 start 标号开始执行。
46 start:                          ! 47--56 行作用是将自身(bootsect)从目前段位置 0x07c0(31KB)
                                   ! 移动到 0x9000(576KB)处，共 256 字（512 字节），然后跳转到
                                   ! 移动后代码的 go 标号处，也即本程序的下一语句处。
47         mov     ax,#BOOTSEG     ! 将 ds 段寄存器置为 0x7C0;
48         mov     ds,ax
49         mov     ax,#INITSEG     ! 将 es 段寄存器置为 0x9000;
50         mov     es,ax
51         mov     cx,#256         ! 移动计数值=256 字;
52         sub     si,si           ! 源地址    ds:si = 0x07C0:0x0000
53         sub     di,di           ! 目的地址 es:di = 0x9000:0x0000
54         rep                     ! 重复执行，直到 cx = 0
```

```
55          movw                    ! 移动 1 个字；
56          jmpi    go,INITSEG      ! 段间跳转（Jump Intersegment）。这里 INITSEG 指出跳转到的
                                    ! 段地址，标号 go 是段内偏移地址。
                                    ! 从下面开始，CPU 执行已移动到 0x9000 段处的代码。
57 go:      mov     ax,cs           ! 将 ds、es 和 ss 都置成移动后代码所在的段处(0x9000)。
58          mov     ds,ax           ! 由于程序中有堆栈操作(push,pop,call)，因此必须设置堆栈。
59          mov     es,ax
60 ! put stack at 0x9ff00.          ! 将堆栈指针 sp 指向 0x9ff00(即 0x9000:0xff00)处
61          mov     ss,ax
62          mov     sp,#0xFF00              ! arbitrary value >>512
                                    ! 由于代码段移动过了，所以要重新设置堆栈段的位置。
                                    ! sp 只要指向远大于 512 偏移（即地址 0x90200）处
                                    ! 都可以。因为从 0x90200 地址开始处还要放置 setup 程序，
                                    ! 而此时 setup 程序大约为 4 个扇区，因此 sp 要指向大
                                    ! 于（0x200 + 0x200 * 4 + 堆栈大小）处。
63
64 ! load the setup-sectors directly after the bootblock.
65 ! Note that 'es' is already set up.
   ! 在 bootsect 程序块后紧根着加载 setup 模块的代码数据。
   ! 注意 es 已经设置好了。（在移动代码时 es 已经指向目的段地址处 0x9000）。
66
67 load_setup:
     ! 68--77 行的用途是利用 BIOS 中断 INT 0x13 将 setup 模块从磁盘第 2 个扇区
     ! 开始读到 0x90200 开始处，共读 4 个扇区。如果读出错，则复位驱动器，并
     ! 重试，没有退路。INT 0x13 的使用方法如下：
     ! 读扇区：
     ! ah = 0x02 - 读磁盘扇区到内存；al = 需要读出的扇区数量；
     ! ch = 磁道(柱面)号的低 8 位；    cl = 开始扇区(位 0-5)，磁道号高 2 位(位 6-7)；
     ! dh = 磁头号；                   dl = 驱动器号（如果是硬盘则位 7 要置位）；
     ! es:bx →指向数据缓冲区；   如果出错则 CF 标志置位。
68          mov     dx,#0x0000              ! drive 0, head 0
69          mov     cx,#0x0002              ! sector 2, track 0
70          mov     bx,#0x0200              ! address = 512, in INITSEG
71          mov     ax,#0x0200+SETUPLEN     ! service 2, nr of sectors
72          int     0x13                    ! read it
73          jnc     ok_load_setup           ! ok - continue
74          mov     dx,#0x0000
75          mov     ax,#0x0000              ! reset the diskette
76          int     0x13
77          j       load_setup
78
79 ok_load_setup:
80
81 ! Get disk drive parameters, specifically nr of sectors/track
   ! 取磁盘驱动器的参数，特别是每道的扇区数量。
   ! 取磁盘驱动器参数 INT 0x13 调用格式和返回信息如下：
   ! ah = 0x08      dl = 驱动器号（如果是硬盘则要置位 7 为 1）。
   ! 返回信息：
   ! 如果出错则 CF 置位，并且 ah = 状态码。
   ! ah = 0,  al = 0,          bl = 驱动器类型（AT/PS2）
   ! ch = 最大磁道号的低 8 位，cl = 每磁道最大扇区数(位 0-5)，最大磁道号高 2 位(位 6-7)
   ! dh = 最大磁头数，          dl = 驱动器数量，
   ! es:di -→ 软驱磁盘参数表。
```

```
 82
 83         mov     dl,#0x00
 84         mov     ax,#0x0800              ! AH=8 is get drive parameters
 85         int     0x13
 86         mov     ch,#0x00
 87         seg cs                          ! 表示下一条语句的操作数在 cs 段寄存器所指的段中。
 88         mov     sectors,cx              ! 保存每磁道扇区数。对于软盘来说（dl=0），其最大磁道号不
                                            ! 会超过 256，ch 已经足够表示它，因此 cl 的位 6-7 肯定为 0。
 89         mov     ax,#INITSEG
 90         mov     es,ax                   ! 因为上面取磁盘参数中断改掉了 es 的值，这里重新改回。
 91
 92 ! Print some inane message     ! 显示一些信息('Loading system ...'回车换行，共 24 个字符)。
 93
 94         mov     ah,#0x03                ! read cursor pos
 95         xor     bh,bh                   ! 读光标位置。
 96         int     0x10
 97
 98         mov     cx,#24                  ! 共 24 个字符。
 99         mov     bx,#0x0007              ! page 0, attribute 7 (normal)
100         mov     bp,#msg1                ! 指向要显示的字符串。
101         mov     ax,#0x1301              ! write string, move cursor
102         int     0x10                    ! 写字符串并移动光标。
103
104 ! ok, we've written the message, now
105 ! we want to load the system (at 0x10000)  ! 现在开始将 system 模块加载到 0x10000(64KB)处。
106
107         mov     ax,#SYSSEG
108         mov     es,ax           ! segment of 0x010000   ! es = 存放 system 的段地址。
109         call    read_it         ! 读磁盘上 system 模块，es 为输入参数。
110         call    kill_motor      ! 关闭驱动器马达，这样就可以知道驱动器的状态了。
111
112 ! After that we check which root-device to use. If the device is
113 ! defined (!= 0), nothing is done and the given device is used.
114 ! Otherwise, either /dev/PS0 (2,28) or /dev/at0 (2,8), depending
115 ! on the number of sectors that the BIOS reports currently.
    ! 此后，我们检查要使用哪个根文件系统设备（简称根设备）。如果已经指定了设备(!=0)
    ! 就直接使用给定的设备。否则就需要根据 BIOS 报告的每磁道扇区数来
    ! 确定到底使用/dev/PS0 (2,28) 还是 /dev/at0 (2,8)。
        ! 上面一行中两个设备文件的含义：
        ! 在 Linux 中软驱的主设备号是 2(参见第 43 行的注释)，次设备号 = type*4 + nr，其中
        ! nr 为 0-3 分别对应软驱 A、B、C 或 D；type 是软驱的类型（2→1.2MB 或 7→1.44MB 等）。
        ! 因为 7*4 + 0 = 28，所以 /dev/PS0 (2,28)指的是 1.44MB A 驱动器,其设备号是 0x021c
        ! 同理 /dev/at0 (2,8)指的是 1.2MB A 驱动器，其设备号是 0x0208。
116
117         seg cs
118         mov     ax,root_dev         ! 取 508,509 字节处的根设备号并判断是否已被定义。
119         cmp     ax,#0
120         jne     root_defined
121         seg cs
122         mov     bx,sectors          ! 取上面第 88 行保存的每磁道扇区数。如果 sectors=15
                                        ! 则说明是 1.2MB 的驱动器；如果 sectors=18，则说明是
                                        ! 1.44MB 软驱。因为是可引导的驱动器，所以肯定是 A 驱。
123         mov     ax,#0x0208          ! /dev/ps0 - 1.2MB
```

```
124         cmp     bx,#15              ! 判断每磁道扇区数是否=15
125         je      root_defined        ! 如果等于，则 ax 中就是引导驱动器的设备号。
126         mov     ax,#0x021c          ! /dev/PS0 - 1.44MB
127         cmp     bx,#18
128         je      root_defined
129 undef_root:                          ! 如果都不一样，则死循环（死机）。
130         jmp undef_root
131 root_defined:
132         seg cs
133         mov     root_dev,ax         ! 将检查过的设备号保存起来。
134
135 ! after that (everyting loaded), we jump to
136 ! the setup-routine loaded directly after
137 ! the bootblock:
    ! 到此，所有程序都加载完毕，我们就跳转到被
    ! 加载在 bootsect 后面的 setup 程序去。
138
139         jmpi    0,SETUPSEG          ! 跳转到 0x9020:0000(setup.s 程序的开始处)。
                                        !!!! 本程序到此就结束了。!!!!
    ! 下面是两个子程序。
140
141 ! This routine loads the system at address 0x10000, making sure
142 ! no 64kB boundaries are crossed. We try to load it as fast as
143 ! possible, loading whole tracks whenever we can.
144 !
145 ! in:   es - starting address segment (normally 0x1000)
146 !
    ! 该子程序将系统模块加载到内存地址 0x10000 处，并确定没有跨越 64KB 的内存边界。我们试图尽快
    ! 地进行加载，只要可能，就每次加载整条磁道的数据。
    ! 输入：es - 开始内存地址段值（通常是 0x1000）
147 sread:  .word 1+SETUPLEN        ! sectors read of current track
                                    ! 当前磁道中已读的扇区数。开始时已经读进 1 扇区的引导扇区
                                    ! bootsect 和 setup 程序所占的扇区数 SETUPLEN。
148 head:   .word 0                 ! current head   !当前磁头号。
149 track:  .word 0                 ! current track  !当前磁道号。
150
151 read_it:
    ! 测试输入的段值。从盘上读入的数据必须存放在位于内存地址 64KB 的边界开始处，否则进入死循环。
    ! 清 bx 寄存器，用于表示当前段内存放数据的开始位置。
152         mov ax,es
153         test ax,#0x0fff
154 die:    jne die                 ! es must be at 64kB boundary ! es 值必须位于 64KB 地址边界!
155         xor bx,bx               ! bx is starting address within segment ! bx 为段内偏移位置。
156 rp_read:
    ! 判断是否已经读入全部数据。比较当前所读段是否就是系统数据末端所处的段(#ENDSEG)，如果不是就
    ! 跳转至下面 ok1_read 标号处继续读数据。否则退出子程序返回。
157         mov ax,es
158         cmp ax,#ENDSEG          ! have we loaded all yet? ! 是否已经加载了全部数据?
159         jb ok1_read
160         ret
161 ok1_read:
    ! 计算和验证当前磁道需要读取的扇区数，放在 ax 寄存器中。
    ! 根据当前磁道还未读取的扇区数以及段内数据字节开始偏移位置，计算如果全部读取这些未读扇区，
```

```
    ! 所读总字节数是否会超过 64KB 段长度的限制。若会超过，则根据此次最多能读入的字节数(64KB - 
    ! 段内偏移位置)，反算出此次需要读取的扇区数。
162         seg cs
163         mov ax,sectors          ! 取每磁道扇区数。
164         sub ax,sread            ! 减去当前磁道已读扇区数。
165         mov cx,ax               ! cx = ax = 当前磁道未读扇区数。
166         shl cx,#9               ! cx = cx * 512 字节。
167         add cx,bx               ! cx = cx + 段内当前偏移值(bx)
                                    !    = 此次读操作后，段内共读入的字节数。
168         jnc ok2_read            ! 若没有超过 64KB 字节，则跳转至 ok2_read 处执行。
169         je ok2_read
170         xor ax,ax               ! 若加上此次将读磁道上所有未读扇区时会超过 64KB，则计算
171         sub ax,bx               ! 此时最多能读入的字节数(64KB - 段内读偏移位置)，再转换
172         shr ax,#9               ! 成需要读取的扇区数。
173 ok2_read:
174         call read_track
175         mov cx,ax               ! cx = 该次操作已读取的扇区数。
176         add ax,sread            ! 当前磁道上已经读取的扇区数。
177         seg cs
178         cmp ax,sectors          ! 如果当前磁道上的还有扇区未读，则跳转到 ok3_read 处。
179         jne ok3_read
    ! 读该磁道的下一磁头面(1 号磁头)上的数据。如果已经完成，则去读下一磁道。
180         mov ax,#1
181         sub ax,head             ! 判断当前磁头号。
182         jne ok4_read            ! 如果是 0 磁头，则再去读 1 磁头面上的扇区数据。
183         inc track               ! 否则去读下一磁道。
184 ok4_read:
185         mov head,ax             ! 保存当前磁头号。
186         xor ax,ax               ! 清当前磁道已读扇区数。
187 ok3_read:
188         mov sread,ax            ! 保存当前磁道已读扇区数。
189         shl cx,#9               ! 上次已读扇区数*512 字节。
190         add bx,cx               ! 调整当前段内数据开始位置。
191         jnc rp_read             ! 若小于 64KB 边界值，则跳转到 rp_read(156 行)处，继续读数据。
                                    ! 否则调整当前段，为读下一段数据作准备。
192         mov ax,es
193         add ax,#0x1000          ! 将段基址调整为指向下一个 64KB 内存开始处。
194         mov es,ax
195         xor bx,bx               ! 清段内数据开始偏移值。
196         jmp rp_read             ! 跳转至 rp_read(156 行)处，继续读数据。
197
    ! 读当前磁道上指定开始扇区和需读扇区数的数据到 es:bx 开始处。参见第 67 行下对 BIOS 磁盘读中断
    ! int 0x13，ah=2 的说明。
    ! al - 需读扇区数；es:bx - 缓冲区开始位置。
198 read_track:
199         push ax
200         push bx
201         push cx
202         push dx
203         mov dx,track            ! 取当前磁道号。
204         mov cx,sread            ! 取当前磁道上已读扇区数。
205         inc cx                  ! cl = 开始读扇区。
206         mov ch,dl               ! ch = 当前磁道号。
```

```
207         mov dx,head             ! 取当前磁头号。
208         mov dh,dl               ! dh = 磁头号。
209         mov dl,#0               ! dl = 驱动器号(为 0 表示当前 A 驱动器)。
210         and dx,#0x0100          ! 磁头号不大于 1。
211         mov ah,#2               ! ah = 2，读磁盘扇区功能号。
212         int 0x13
213         jc bad_rt               ! 若出错，则跳转至 bad_rt。
214         pop dx
215         pop cx
216         pop bx
217         pop ax
218         ret
    ! 执行驱动器复位操作（磁盘中断功能号 0），再跳转到 read_track 处重试。
219 bad_rt: mov ax,#0
220         mov dx,#0
221         int 0x13
222         pop dx
223         pop cx
224         pop bx
225         pop ax
226         jmp read_track
227
228 /*
229  * This procedure turns off the floppy drive motor, so
230  * that we enter the kernel in a known state, and
231  * don't have to worry about it later.
232  */
    ! 这个子程序用于关闭软驱的马达，这样我们进入内核后它处于已知状态，以后也就无须担心它了。
233 kill_motor:
234         push dx
235         mov dx,#0x3f2       ! 软驱控制卡的驱动端口，只写。
236         mov al,#0           ! A 驱动器，关闭 FDC，禁止 DMA 和中断请求，关闭马达。
237         outb                ! 将 al 中的内容输出到 dx 指定的端口去。
238         pop dx
239         ret
240
241 sectors:
242         .word 0                         ! 存放当前启动软盘每磁道的扇区数。
243
244 msg1:
245         .byte 13,10                     ! 回车、换行的 ASCII 码。
246         .ascii "Loading system ..."
247         .byte 13,10,13,10               ! 共 24 个 ASCII 码字符。
248
249 .org 508                               ! 表示下面语句从地址 508(0x1FC)开始，所以 root_dev
                                           ! 在启动扇区的第 508 开始的 2 个字节中。
250 root_dev:
251         .word ROOT_DEV                  ! 这里存放根文件系统所在设备号(init/main.c 中会用)。
252 boot_flag:
253         .word 0xAA55                    ! 硬盘有效标识。
254
255 .text
256 endtext:
```

```
257 .data
258 enddata:
259 .bss
260 endbss:
```

3.3.3 其他信息

对 bootsect.s 这段程序的说明和描述，在互连网上可以搜索到大量的资料。其中 Alessandro Rubini 著而由本人翻译的《Linux 内核源代码漫游》一篇文章(http://oldlinux.org/Linux.old/docs/)比较详细地描述了内核启动的详细过程，很有参考价值。由于这段程序是在 386 实模式下运行的，因此相对来将比较容易理解。若此时阅读仍有困难，那么建议你首先再复习一下 80x86 汇编及其硬件的相关知识（可参阅参考文献[1]和[16]），然后再继续阅读本书。

对于最新开发的 Linux 内核，这段程序的改动也很小，基本保持了与 0.11 版的模样。

3.4 setup.s 程序

3.4.1 功能描述

setup 程序的主要作用是利用 ROM BIOS 中断读取机器系统数据，并将这些数据保存到 0x90000 开始的位置（覆盖掉了 bootsect 程序所在的地方），所取得的参数和保留的内存位置见表 3－1 所示。这些参数将被内核中相关程序使用，例如字符设备驱动程序集中的 ttyio.c 程序等。

表 3－1 setup 程序读取并保留的参数

内存地址	长度(字节)	名称	描述
0x90000	2	光标位置	列号（0x00-最左端），行号（0x00-最顶端）
0x90002	2	扩展内存数	系统从 1MB 开始的扩展内存数值（KB）。
0x90004	2	显示页面	当前显示页面
0x90006	1	显示模式	
0x90007	1	字符列数	
0x90008	2	??	
0x9000A	1	显示内存	显示内存(0x00-64k,0x01-128k,0x02-192k,0x03=256k)
0x9000B	1	显示状态	0x00-彩色,I/O=0x3dX；0x11-单色,I/O=0x3bX
0x9000C	2	特性参数	显示卡特性参数
...			
0x90080	16	硬盘参数表	第 1 个硬盘的参数表
0x90090	16	硬盘参数表	第 2 个硬盘的参数表（如果没有，则清零）
0x901FC	2	根设备号	根文件系统所在的设备号（bootsec.s 中设置）

然后 setup 程序将 system 模块从 0x10000-0x8ffff（当时认为内核系统模块 system 的长度不会超过此值：512KB）整块向下移动到内存绝对地址 0x00000 处。接下来加载中断描述符表寄存器(idtr)和全局描述符表寄存器(gdtr)，开启 A20 地址线，重新设置两个中断控制芯片 8259A，将硬件中断号重新设置为 0x20 - 0x2f。最后设置 CPU 的控制寄存器 CR0（也称机器状态字），从而进入 32 位保护模式运行，并跳转到位于 system 模块最前面部分的 head.s 程序继续运行。

为了能让 head.s 在 32 位保护模式下运行，在本程序中临时设置了中断描述符表（IDT）和全局描述

符表（GDT），并在 GDT 中设置了当前内核代码段的描述符和数据段的描述符。下面在 head.s 程序中会根据内核的需要重新设置这些描述符表。

下面首先简单介绍一下段描述符的格式、描述符表的结构和段选择符（有些书中称之位选择子）的格式。Linux 内核代码中用到的代码段、数据段描述符的格式见图 3-2 所示。其中各字段的含义见下面说明。

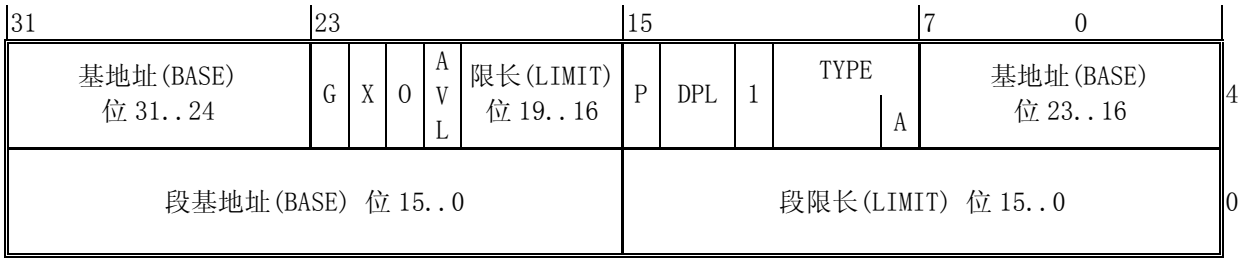

图 3-2 程序代码段和数据段的描述符格式

- 基地址（BASE）：定义段在 4GB 线性空间中的位置。处理器会将基地址的三个部分组合成一个 32 位的值。
- 段限长（LIMIT）：定义了段的最大长度。处理器将组合段限长的两个部分形成一个 20 位的值。处理器会依据颗粒度（Granularity）位字段的值来解释段限长域的实际含义：
  - 当以 1 字节为单元时，则定义了最高可为 1MB 字节的长度；
  - 当以 4KB 字节为单元时，则定义了最高可为 4GB 字节的长度。在加载时限长值将左移 12 位。
- 颗粒度（Granularity）：指定了限长字段值代表的单元含义。当为 0 时，限长单元值为 1 字节；当该位为 1 时，限长的单元值为 4KB 字节。
- 类型（TYPE）：4 比特（位 11-位 8），用于区分各种不同类型的描述符。对于代码段选择符，其最高比特位为 1。对于数据段选择符，其最高比特位是 0。
- 描述符特权级（Descriptor Privilege Level – DPL）：用于保护机制。共有 4 级：0–3。0 级是最高特权级，3 级是最低特权级。
- 段存在位（Segment-Present bit – P）：如果该位为零，则该描述符无效，不能用于地址变换过程。当指向该描述符的选择符被加载到段寄存器中时，处理器就会发出一个异常信号。
- 访问位（Accessed bit – A）：当处理器访问过该段时就会设置该比特位。

段描述符是存放在描述符表中的。描述符表其实就是内存中描述符项的一个阵列。描述符表有两类：全局描述符表（Global descriptor table – GDT）和局部描述符表（Local descriptor table – LDT）。处理器是通过使用 GDTR 和 LDTR 寄存器来定位 GDT 表和当前的 LDT 表。这两个寄存器以线性地址的方式保存了描述符表的基地址和表的长度。指令 lgdt 和 sgdt 用于访问 GDTR 寄存器；指令 lldt 和 sldt 用于访问 LDTR 寄存器。lgdt 使用内存中一个 6 字节操作数来加载 GDTR 寄存器。头两个字节代表描述符表的长度，后 4 个字节是描述符表的基地址。然而请注意，访问 LDTR 寄存器的指令 lldt 所使用的操作数却是一个 2 字节的操作数，表示全局描述符表 GDT 中一个描述符项的选择符。该选择符所对应的 GDT 表中的描述符项应该对应一个局部描述符表。

这里在对选择符进行一些说明。逻辑地址的选择符部分用于指定一描述符，它是通过指定一描述符表并且索引其中的一个描述符项完成的。图 3-3 示出了选择符的格式。各字段的含义说明如下。

图 3-3 段选择符格式

- 索引值(Index)：用于选择指定描述符表中 8192 个描述符中的一个。处理器将该索引值乘上 8(描述符的字节长度)，并加上描述符表的基地址即可访问表中指定的段描述符。
- 表指示器(Table Indicator - TI)：指定选择符所引用的描述符表。值为 0 表示指定 GDT 表，值为 1 表示指定当前的 LDT 表。
- 请求者的特权级(Requestor's Privalege Level - RPL)：用于保护机制。

由于 GDT 表的第一项(索引值为 0)没有被使用，因此一个具有索引值 0 和表指示器值也为 0 的选择符（也即指向 GDT 的第一项的选择符）可以用作为一个空(null)选择符。当一个段寄存器（不能是 CS 或 SS）加载了一个空选择符时，处理器并不会产生一个异常。但是若使用这个段寄存器访问内存时就会产生一个异常。对于初始化还未使用的段寄存器以陷入意外的引用来说，这个特性是很有用的。

现在，我们根据 CPU 在实模式和保护模式下寻址方式的不同，用比较的方法来简单说明 32 位保护模式运行机制的主要特点，以便能顺利地理解本节的程序。在后续章节中将逐步对其进行详细说明。

在实模式下，寻址一个内存地址主要是使用段和偏移值，段值被存放在段寄存器中（例如 ds），并且段的最大长度被固定为 64KB。段内偏移地址存放在任意一个可用于寻址的寄存器中（例如 si）。因此，根据段寄存器和偏移寄存器中的值，就可以算出实际指向的内存地址，见图 3-4 (a)所示。

而在保护模式运行方式下，段寄存器中存放的不再是寻址段的基地址，而是一个段描述符表中某项的索引值。索引值指定的段描述符项中含有需要寻址的内存段的基地址、段的最大长度值和段的访问级别等信息。寻址的内存位置是由该段描述符项中指定的段基地址值和偏移值组合而成，段的最大长度也由描述符指定。可见，和实模式下的寻址相比，段寄存器值换成了段描述符索引，但偏移值还是原实模式下的概念。这样，在保护模式下寻址一个内存地址就需要比实模式下多一道手续，也即需要使用段描述符表。这是由于在保护模式下访问一个内存段需要的信息比较多，一个 16 位的段寄存器放不下这么多内容。示意图见图 3-4 (b)所示。

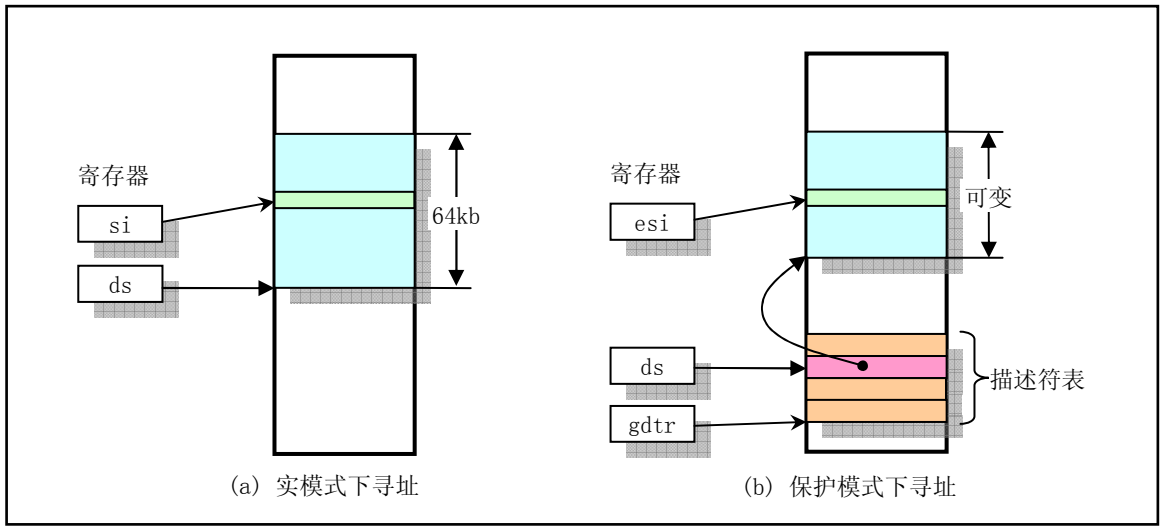

图 3-4 实模式与保护模式下寻址方式的比较

因此，在进入保护模式之前，必须首先设置好将要用到的段描述符表，例如全局描述符表 GDT。然后使用指令 lgdt 把描述符表的基地址告知 CPU（GDT 表的基地址存入 gdtr 寄存器）。再将机器状态字的保护模式标志置位即可进入 32 位保护运行模式。

3.4.2 代码注释

程序 3-2 linux/boot/setup.s

```
  1 !
  2 !       setup.s         (C) 1991 Linus Torvalds
  3 !
  4 ! setup.s is responsible for getting the system data from the BIOS,
  5 ! and putting them into the appropriate places in system memory.
  6 ! both setup.s and system has been loaded by the bootblock.
  7 !
  8 ! This code asks the bios for memory/disk/other parameters, and
  9 ! puts them in a "safe" place: 0x90000-0x901FF, ie where the
 10 ! boot-block used to be. It is then up to the protected mode
 11 ! system to read them from there before the area is overwritten
 12 ! for buffer-blocks.
    !
    ! setup.s 负责从 BIOS 中获取系统数据，并将这些数据放到系统内存的适当地方。
    ! 此时 setup.s 和 system 已经由 bootsect 引导块加载到内存中。
    !
    ! 这段代码询问 bios 有关内存/磁盘/其他参数，并将这些参数放到一个
    ! “安全的”地方：0x90000-0x901FF，也即原来 bootsect 代码块曾经在
    ! 的地方，然后在被缓冲块覆盖掉之前由保护模式的 system 读取。
 13 !
 14
 15 ! NOTE! These had better be the same as in bootsect.s!
    ! 以下这些参数最好和 bootsect.s 中的相同!
 16
 17 INITSEG  = 0x9000       ! we move boot here - out of the way  ! 原来 bootsect 所处的段。
 18 SYSSEG   = 0x1000       ! system loaded at 0x10000 (65536).   ! system 在 0x10000(64KB)处。
 19 SETUPSEG = 0x9020       ! this is the current segment         ! 本程序所在的段地址。
 20
 21 .globl begtext, begdata, begbss, endtext, enddata, endbss
 22 .text
 23 begtext:
 24 .data
 25 begdata:
 26 .bss
 27 begbss:
 28 .text
 29
 30 entry start
 31 start:
 32
 33 ! ok, the read went well so we get current cursor position and save it for
 34 ! posterity.
    ! ok，整个读磁盘过程都正常，现在将光标位置保存以备今后使用。
 35
 36         mov     ax,#INITSEG     ! this is done in bootsect already, but...
                                    ! 将 ds 置成#INITSEG(0x9000)。这已经在 bootsect 程序中
                                    ! 设置过，但是现在是 setup 程序，Linus 觉得需要再重新
                                    ! 设置一下。
 37         mov     ds,ax
```

```
38          mov     ah,#0x03        ! read cursor pos
                                    ! BIOS 中断 0x10 的读光标功能号 ah = 0x03
                                    ! 输入：bh = 页号
                                    ! 返回：ch = 扫描开始线，cl = 扫描结束线，
                                    ! dh = 行号(0x00 是顶端)，dl = 列号(0x00 是左边)。
39          xor     bh,bh
40          int     0x10            ! save it in known place, con_init fetches
41          mov     [0],dx          ! it from 0x90000.
                                    ! 上两句是说将光标位置信息存放在 0x90000 处，控制台
                                    ! 初始化时会来取。
42
43 ! Get memory size (extended mem, kB)  ! 下面 3 句取扩展内存的大小值（KB）。
                                    ! 是调用中断 0x15，功能号 ah = 0x88
                                    ! 返回：ax = 从 0x100000（1M）处开始的扩展内存大小(KB)。
                                    ! 若出错则 CF 置位，ax = 出错码。
44
45          mov     ah,#0x88
46          int     0x15
47          mov     [2],ax          ! 将扩展内存数值存在 0x90002 处（1 个字）。
48
49 ! Get video-card data:   ! 下面这段用于取显示卡当前显示模式。
                           ! 调用 BIOS 中断 0x10，功能号 ah = 0x0f
                           ! 返回：ah = 字符列数，al = 显示模式，bh = 当前显示页。
                           ! 0x90004(1 字)存放当前页，0x90006 显示模式，0x90007 字符列数。
50
51          mov     ah,#0x0f
52          int     0x10
53          mov     [4],bx          ! bh = display page
54          mov     [6],ax          ! al = video mode, ah = window width
55
56 ! check for EGA/VGA and some config parameters  ! 检查显示方式（EGA/VGA）并取参数。
                           ! 调用 BIOS 中断 0x10，附加功能选择 -取方式信息
                           ! 功能号：ah = 0x12，bl = 0x10
                           ! 返回：bh = 显示状态
                           !       (0x00 - 彩色模式，I/O 端口=0x3dX)
                           !       (0x01 - 单色模式，I/O 端口=0x3bX)
                           ! bl = 安装的显示内存
                           ! (0x00 - 64k, 0x01 - 128k, 0x02 - 192k, 0x03 = 256k)
                           ! cx = 显示卡特性参数(参见程序后的说明)。
57
58          mov     ah,#0x12
59          mov     bl,#0x10
60          int     0x10
61          mov     [8],ax    ! 0x90008 = ??
62          mov     [10],bx   ! 0x9000A = 安装的显示内存，0x9000B = 显示状态(彩色/单色)
63          mov     [12],cx   ! 0x9000C = 显示卡特性参数。
64
65 ! Get hd0 data     ! 取第一个硬盘的信息（复制硬盘参数表）。
                     ! 第 1 个硬盘参数表的首地址竟然是中断向量 0x41 的向量值！而第 2 个硬盘
                     ! 参数表紧接第 1 个表的后面，中断向量 0x46 的向量值也指向这第 2 个硬盘
                     ! 的参数表首址。表的长度是 16 个字节(0x10)。
                     ! 下面两段程序分别复制 BIOS 有关两个硬盘的参数表，0x90080 处存放第 1 个
                     ! 硬盘的表，0x90090 处存放第 2 个硬盘的表。
```

```
66
67          mov     ax,#0x0000
68          mov     ds,ax
69          lds     si,[4*0x41]  ! 取中断向量 0x41 的值，也即 hd0 参数表的地址➔ds:si
70          mov     ax,#INITSEG
71          mov     es,ax
72          mov     di,#0x0080   ! 传输的目的地址: 0x9000:0x0080 ➔ es:di
73          mov     cx,#0x10     ! 共传输 0x10 字节。
74          rep
75          movsb
76
77  ! Get hd1 data
78
79          mov     ax,#0x0000
80          mov     ds,ax
81          lds     si,[4*0x46]  ! 取中断向量 0x46 的值，也即 hd1 参数表的地址➔ds:si
82          mov     ax,#INITSEG
83          mov     es,ax
84          mov     di,#0x0090   ! 传输的目的地址: 0x9000:0x0090 ➔ es:di
85          mov     cx,#0x10
86          rep
87          movsb
88
89  ! Check that there IS a hd1 :-)  ! 检查系统是否存在第 2 个硬盘，如果不存在则第 2 个表清零。
    ! 利用 BIOS 中断调用 0x13 的取盘类型功能。
    ! 功能号 ah = 0x15;
    ! 输入：dl = 驱动器号（0x8X 是硬盘：0x80 指第 1 个硬盘，0x81 第 2 个硬盘）
    ! 输出：ah = 类型码；00 --没有这个盘，CF 置位； 01 --是软驱，没有 change-line 支持；
    !       02 --是软驱(或其他可移动设备)，有 change-line 支持； 03 --是硬盘。
90
91          mov     ax,#0x01500
92          mov     dl,#0x81
93          int     0x13
94          jc      no_disk1
95          cmp     ah,#3            ! 是硬盘吗？(类型 = 3 ？)。
96          je      is_disk1
97  no_disk1:
98          mov     ax,#INITSEG      ! 第 2 个硬盘不存在，则对第 2 个硬盘表清零。
99          mov     es,ax
100         mov     di,#0x0090
101         mov     cx,#0x10
102         mov     ax,#0x00
103         rep
104         stosb
105 is_disk1:
106
107 ! now we want to move to protected mode ...   ! 现在我们要进入保护模式中了...
108
109         cli                     ! no interrupts allowed !  ! 此时不允许中断。
110
111 ! first we move the system to it's rightful place
    ! 首先我们将 system 模块移到正确的位置。
    ! bootsect 引导程序是将 system 模块读入到从 0x10000（64KB）开始的位置。由于当时假设
```

```
    ! system 模块最大长度不会超过 0x80000（512KB），也即其末端不会超过内存地址 0x90000，
    ! 所以 bootsect 会将自己移动到 0x90000 开始的地方，并把 setup 加载到它的后面。
    ! 下面这段程序的用途是再把整个 system 模块移动到 0x00000 位置，即把从 0x10000 到 0x8ffff
    ! 的内存数据块(512KB)，整块地向内存低端移动了 0x10000（64KB）的位置。
112
113         mov     ax,#0x0000
114         cld                     ! 'direction'=0, movs moves forward
115 do_move:
116         mov     es,ax           ! destination segment ! es:di➔目的地址(初始为 0x0000:0x0)
117         add     ax,#0x1000
118         cmp     ax,#0x9000      ! 已经把从 0x8000 段开始的 64KB 代码移动完?
119         jz      end_move
120         mov     ds,ax           ! source segment  ! ds:si➔源地址(初始为 0x1000:0x0)
121         sub     di,di
122         sub     si,si
123         mov     cx,#0x8000      ! 移动 0x8000 字（64KB 字节）。
124         rep
125         movsw
126         jmp     do_move
127
128 ! then we load the segment descriptors
    ! 此后，我们加载段描述符。
    ! 从这里开始会遇到 32 位保护模式的操作，因此需要 Intel 32 位保护模式编程方面的知识了，
    ! 有关这方面的信息请查阅列表后的简单介绍或附录中的详细说明。这里仅作概要说明。
    ! 在进入保护模式中运行之前，我们需要首先设置好需要使用的段描述符表。这里需要设置全局
    ! 描述符表和中断描述符表。
    !
    ! lidt 指令用于加载中断描述符表(idt)寄存器，它的操作数是 6 个字节，0-1 字节是描述符表的
    ! 长度值(字节)；2-5 字节是描述符表的 32 位线性基地址（首地址），其形式参见下面
    ! 219-220 行和 223-224 行的说明。中断描述符表中的每一个表项（8 字节）指出发生中断时
    ! 需要调用的代码的信息，与中断向量有些相似，但要包含更多的信息。
    !
    ! lgdt 指令用于加载全局描述符表(gdt)寄存器，其操作数格式与 lidt 指令的相同。全局描述符
    ! 表中的每个描述符项(8 字节)描述了保护模式下数据和代码段（块）的信息。其中包括段的
    ! 最大长度限制(16 位)、段的线性基址（32 位）、段的特权级、段是否在内存、读写许可以及
    ! 其他一些保护模式运行的标志。参见后面 205-216 行。
    !
129
130 end_move:
131         mov     ax,#SETUPSEG    ! right, forgot this at first. didn't work :-)
132         mov     ds,ax           ! ds 指向本程序(setup)段。
133         lidt    idt_48          ! load idt with 0,0
                                    ! 加载中断描述符表(idt)寄存器，idt_48 是 6 字节操作数的位置
                                    ! (见 218 行)。前 2 字节表示 idt 表的限长，后 4 字节表示 idt 表
                                    ! 所处的基地址。
134         lgdt    gdt_48          ! load gdt with whatever appropriate
                                    ! 加载全局描述符表(gdt)寄存器，gdt_48 是 6 字节操作数的位置
                                    ! (见 222 行)。
135
136 ! that was painless, now we enable A20
    ! 以上的操作很简单，现在我们开启 A20 地址线。参见程序列表后有关 A20 信号线的说明。
    ! 关于所涉及到的一些端口和命令，可参考 kernel/chr_drv/keyboard.S 程序后对键盘接口的说明。
137
```

```
138         call    empty_8042              ! 等待输入缓冲器空。
                                            ! 只有当输入缓冲器为空时才可以对其进行写命令。
139         mov     al,#0xD1                ! command write ! 0xD1 命令码-表示要写数据到
140         out     #0x64,al                ! 8042 的 P2 端口。P2 端口的位 1 用于 A20 线的选通。
                                            ! 数据要写到 0x60 口。
141         call    empty_8042              ! 等待输入缓冲器空，看命令是否被接受。
142         mov     al,#0xDF                ! A20 on  ! 选通 A20 地址线的参数。
143         out     #0x60,al
144         call    empty_8042              ! 输入缓冲器为空，则表示 A20 线已经选通。
145
146 ! well, that went ok, I hope. Now we have to reprogram the interrupts :-(
147 ! we put them right after the intel-reserved hardware interrupts, at
148 ! int 0x20-0x2F. There they won't mess up anything. Sadly IBM really
149 ! messed this up with the original PC, and they haven't been able to
150 ! rectify it afterwards. Thus the bios puts interrupts at 0x08-0x0f,
151 ! which is used for the internal hardware interrupts as well. We just
152 ! have to reprogram the 8259's, and it isn't fun.
    !! 希望以上一切正常。现在我们必须重新对中断进行编程☹
    !! 我们将它们放在正好处于 Intel 保留的硬件中断后面，在 int 0x20-0x2F。
    !! 在那里它们不会引起冲突。不幸的是 IBM 在原 PC 机中搞糟了，以后也没有纠正过来。
    !! PC 机的 BIOS 将中断放在了 0x08-0x0f，这些中断也被用于内部硬件中断。
    !! 所以我们就必须重新对 8259 中断控制器进行编程，这一点都没意思。
153
154         mov     al,#0x11                ! initialization sequence
                                            ! 0x11 表示初始化命令开始，是 ICW1 命令字，表示边
                                            ! 沿触发、多片 8259 级连、最后要发送 ICW4 命令字。
155         out     #0x20,al                ! send it to 8259A-1  ! 发送到 8259A 主芯片。
    ! 下面定义的两个字是直接使用机器码表示的两条相对跳转指令，起延时作用。
    ! 0xeb 是直接近跳转指令的操作码，带 1 个字节的相对位移值。因此跳转范围是-127 到 127。CPU 通过
    ! 把这个相对位移值加到 EIP 寄存器中就形成一个新的有效地址。此时 EIP 指向下一条被执行的指令。
    ! 执行时所花费的 CPU 时钟周期数是 7 至 10 个。0x00eb 表示跳转值是 0 的一条指令，因此还是直接
    ! 执行下一条指令。这两条指令共可提供 14-20 个 CPU 时钟周期的延迟时间。在 as86 中没有表示相应
    ! 指令的助记符，因此 Linus 在 setup.s 等一些汇编程序中就直接使用机器码来表示这种指令。另外，
    ! 每个空操作指令 NOP 的时钟周期数是 3 个，因此若要达到相同的延迟效果就需要 6 至 7 个 NOP 指令。
156         .word   0x00eb,0x00eb           ! jmp $+2, jmp $+2     ! '$'表示当前指令的地址，
157         out     #0xA0,al                ! and to 8259A-2       ! 再发送到 8259A 从芯片。
158         .word   0x00eb,0x00eb
159         mov     al,#0x20                ! start of hardware int's (0x20)
160         out     #0x21,al                ! 送主芯片 ICW2 命令字，起始中断号，要送奇地址。
161         .word   0x00eb,0x00eb
162         mov     al,#0x28                ! start of hardware int's 2 (0x28)
163         out     #0xA1,al                ! 送从芯片 ICW2 命令字，从芯片的起始中断号。
164         .word   0x00eb,0x00eb
165         mov     al,#0x04                ! 8259-1 is master
166         out     #0x21,al                ! 送主芯片 ICW3 命令字，主芯片的 IR2 连从芯片 INT。
167         .word   0x00eb,0x00eb           ! 参见代码列表后的说明。
168         mov     al,#0x02                ! 8259-2 is slave
169         out     #0xA1,al                ! 送从芯片 ICW3 命令字，表示从芯片的 INT 连到主芯
                                            ! 片的 IR2 引脚上。
170         .word   0x00eb,0x00eb
171         mov     al,#0x01                ! 8086 mode for both
172         out     #0x21,al                ! 送主芯片 ICW4 命令字。8086 模式；普通 EOI 方式，
                                            ! 需发送指令来复位。初始化结束，芯片就绪。
```

```
173         .word   0x00eb,0x00eb
174         out     #0xA1,al                ! 送从芯片 ICW4 命令字，内容同上。
175         .word   0x00eb,0x00eb
176         mov     al,#0xFF                ! mask off all interrupts for now
177         out     #0x21,al                ! 屏蔽主芯片所有中断请求。
178         .word   0x00eb,0x00eb
179         out     #0xA1,al                ! 屏蔽从芯片所有中断请求。
180
181 ! well, that certainly wasn't fun :-(. Hopefully it works, and we don't
182 ! need no steenking BIOS anyway (except for the initial loading :-).
183 ! The BIOS-routine wants lots of unnecessary data, and it's less
184 ! "interesting" anyway. This is how REAL programmers do it.
185 !
186 ! Well, now's the time to actually move into protected mode. To make
187 ! things as simple as possible, we do no register set-up or anything,
188 ! we let the gnu-compiled 32-bit programs do that. We just jump to
189 ! absolute address 0x00000, in 32-bit protected mode.
    !! 哼，上面这段当然没劲☹，但希望这样能工作，而且我们也不再需要乏味的 BIOS 了（除了
    !! 初始的加载☺）。BIOS 子程序要求很多不必要的数据，而且它一点都没趣。那是“真正”的
    !! 程序员所做的事。
190
    ! 这里设置进入 32 位保护模式运行。首先加载机器状态字(lmsw-Load Machine Status Word)，也称
    ! 控制寄存器 CR0，其比特位 0 置 1 将导致 CPU 工作在保护模式。
191         mov     ax,#0x0001      ! protected mode (PE) bit ! 保护模式比特位(PE)。
192         lmsw    ax              ! This is it! ! 就这样加载机器状态字!
193         jmpi    0,8             ! jmp offset 0 of segment 8 (cs) ! 跳转至 cs 段 8，偏移 0 处。
    ! 我们已经将 system 模块移动到 0x00000 开始的地方，所以这里的偏移地址是 0。这里的段
    ! 值的 8 已经是保护模式下的段选择符了，用于选择描述符表和描述符表项以及所要求的特权级。
    ! 段选择符长度为 16 位（2 字节）；位 0-1 表示请求的特权级 0-3，linux 操作系统只
    ! 用到两级：0 级（系统级）和 3 级（用户级）；位 2 用于选择全局描述符表(0)还是局部描
    ! 述符表(1)；位 3-15 是描述符表项的索引，指出选择第几项描述符。所以段选择符
    ! 8(0b0000,0000,0000,1000)表示请求特权级 0、使用全局描述符表中的第 1 项，该项指出
    ! 代码的基地址是 0（参见 209 行），因此这里的跳转指令就会去执行 system 中的代码。
194
195 ! This routine checks that the keyboard command queue is empty
196 ! No timeout is used - if this hangs there is something wrong with
197 ! the machine, and we probably couldn't proceed anyway.
    ! 下面这个子程序检查键盘命令队列是否为空。这里不使用超时方法 - 如果这里死机，
    ! 则说明 PC 机有问题，我们就没有办法再处理下去了。
    ! 只有当输入缓冲器为空时（状态寄存器位 2 = 0）才可以对其进行写命令。
198 empty_8042:
199         .word   0x00eb,0x00eb   ! 这是两个跳转指令的机器码(跳转到下一句)，相当于延时空操作。
200         in      al,#0x64        ! 8042 status port  ! 读 AT 键盘控制器状态寄存器。
201         test    al,#2           ! is input buffer full?  ! 测试位 2，输入缓冲器满？
202         jnz     empty_8042      ! yes - loop
203         ret
204
205 gdt:    ! 全局描述符表开始处。描述符表由多个 8 字节长的描述符项组成。
            ! 这里给出了 3 个描述符项。第 1 项无用（206 行），但须存在。第 2 项是系统代码段
            ! 描述符（208-211 行），第 3 项是系统数据段描述符(213-216 行)。每个描述符的具体
            ! 含义参见列表后说明。
206         .word   0,0,0,0         ! dummy    ! 第 1 个描述符，不用。
207   ! 这里在 gdt 表中的偏移量为 0x08，当加载代码段寄存器(段选择符)时，使用的是这个偏移值。
```

```
208         .word   0x07FF          ! 8Mb - limit=2047 (2048*4096=8Mb)
209         .word   0x0000          ! base address=0
210         .word   0x9A00          ! code read/exec
211         .word   0x00C0          ! granularity=4096, 386
212   ! 这里在 gdt 表中的偏移量是 0x10，当加载数据段寄存器(如 ds 等)时，使用的是这个偏移值。
213         .word   0x07FF          ! 8Mb - limit=2047 (2048*4096=8Mb)
214         .word   0x0000          ! base address=0
215         .word   0x9200          ! data read/write
216         .word   0x00C0          ! granularity=4096, 386
217
218 idt_48:
219         .word   0               ! idt limit=0
220         .word   0,0             ! idt base=0L
221
222 gdt_48:
223         .word   0x800           ! gdt limit=2048, 256 GDT entries
                                    ! 全局表长度为 2KB 字节，因为每 8 字节组成一个段描述符项
                                    ! 所以表中共可有 256 项。
224         .word   512+gdt,0x9     ! gdt base = 0X9xxxx
                                    ! 4 个字节构成的内存线性地址：0x0009<<16 + 0x0200+gdt
                                    ! 也即 0x90200 + gdt(即在本程序段中的偏移地址，205 行)。
225
226 .text
227 endtext:
228 .data
229 enddata:
230 .bss
231 endbss:
```

3.4.3 其他信息

为了获取机器的基本参数，这段程序多次调用了 BIOS 中的中断，并开始涉及一些对硬件端口的操作。下面简要地描述程序中使用到的 BIOS 中断调用，并对 A20 地址线问题的缘原由进行解释，最后提及关于 Intel 32 位保护模式运行的问题。

3.4.3.1 当前内存映像

在 setup.s 程序执行结束后，系统模块 system 被移动到物理地址 0x0000 开始处，而从位置 0x90000 开始处则存放了内核将会使用的一些系统基本参数，示意图如图 3-5 所示。

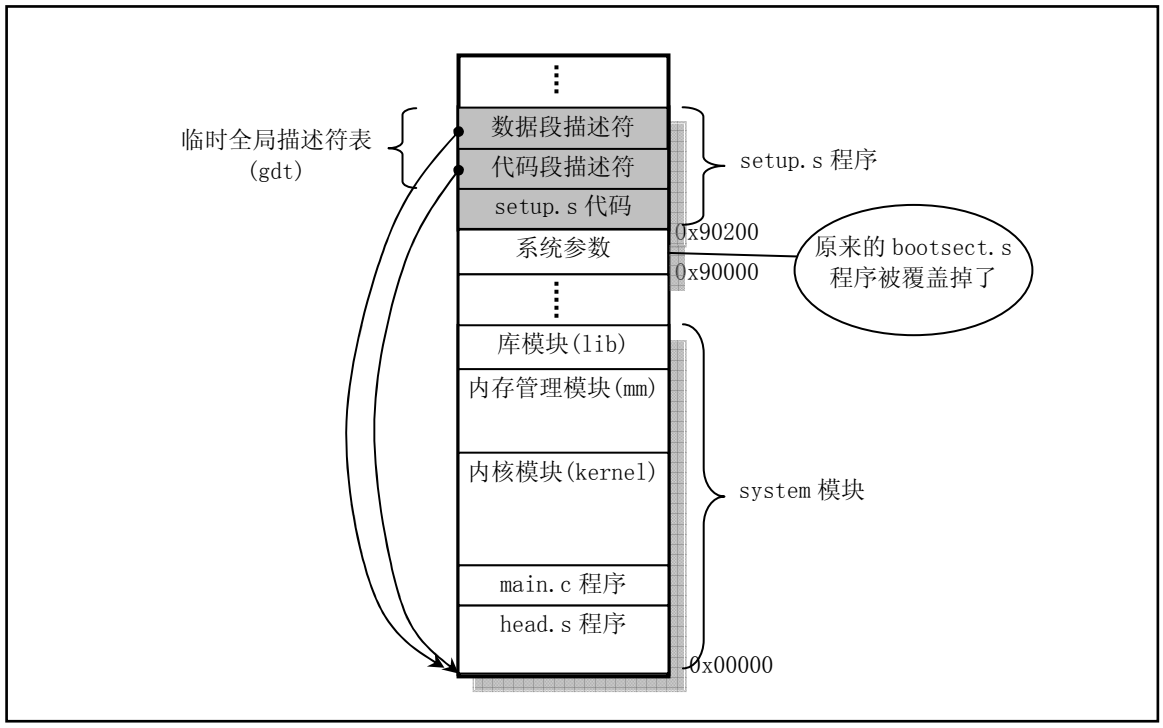

图 3-5 setup.s 程序结束后内存中程序示意图

此时临时全局表中有三个描述符，第一个是 NULL 不使用，另外两个分别是代码段描述符和数据段描述符。它们都指向系统模块的起始处，也即物理地址 0x0000 处。这样当 setup.s 中执行最后一条指令 'jmp 0,8 '（第 193 行）时，就会跳到 head.s 程序开始处继续执行下去。这条指令中的'8'是段选择符，用来指定所需使用的描述符项，此处是指 gdt 中的代码段描述符。'0'是描述符项指定的代码段中的偏移值。

3.4.3.2 BIOS 视频中断 0x10

这里说明上面程序中用到的 ROM BIOS 中视频中断调用的几个子功能。

A. 获取显示卡信息（其他辅助功能选择）：

表 3－2 获取显示卡信息（功能号： ah = 0x12，bh = 0x10）

输入/返回信息	寄存器	内容说明
输入信息	ah	功能号=0x12，获取显示卡信息
	bh	子功能号=0x10。
返回信息	bh	视频状态： 0x00 – 彩色模式（此时视频硬件 I/O 端口基地址为 0x3DX）； 0x01 – 单色模式（此时视频硬件 I/O 端口基地址为 0x3BX）； 注：其中端口地址中的 X 值可为 0 – f。
	bl	已安装的显示内存大小： 00 = 64K, 01 = 128K, 02 = 192K, 03 = 256K
	ch	特性连接器比特位信息： 比特位 说明 0 特性线 1，状态 2； 1 特性线 0，状态 2； 2 特性线 1，状态 1；

		3　　特性线 0，状态 1； 4-7　　未使用(为 0)
	cl	视频开关设置信息： 比特位 说明 0　　开关 1 关闭； 1　　开关 2 关闭； 2　　开关 3 关闭； 3　　开关 4 关闭； 4-7　　未使用。 原始 EGA/VGA 开关设置值: 0x00　　MDA/HGC； 0x01-0x03　　MDA/HGC； 0x04　　CGA 40x25； 0x05　　CGA 80x25； 0x06　　EGA+ 40x25； 0x07-0x09　　EGA+ 80x25； 0x0A　　EGA+ 80x25 单色； 0x0B　　EGA+ 80x25 单色。

3.4.3.3 硬盘基本参数表（“INT 0x41”）

中断向量表中，int 0x41 的中断向量位置（4 * 0x41 =0x0000:0x0104）存放的并不是中断程序的地址，而是第一个硬盘的基本参数表。对于 100%兼容的 BIOS 来说，这里存放着硬盘参数表阵列的首地址 F000h:E401h。第二个硬盘的基本参数表入口地址存于 int 0x46 中断向量位置处。

表 3－3 硬盘基本参数信息表

位移	大小	英文名称	说明
0x00	字	cyl	柱面数
0x02	字节	head	磁头数
0x03	字		开始减小写电流的柱面(仅 PC XT 使用，其他为 0)
0x05	字	wpcom	开始写前预补偿柱面号（乘 4）
0x07	字节		最大 ECC 猝发长度（仅 XT 使用，其他为 0）
0x08	字节	ctl	控制字节（驱动器步进选择） 位 0　　未用 位 1　　保留(0) (关闭 IRQ) 位 2　　允许复位 位 3　　若磁头数大于 8 则置 1 位 4　　未用(0) 位 5　　若在柱面数+1 处有生产商的坏区图，则置 1 位 6　　禁止 ECC 重试 位 7　　禁止访问重试。
0x09	字节		标准超时值（仅 XT 使用，其他为 0）
0x0A	字节		格式化超时值（仅 XT 使用，其他为 0）
0x0B	字节		检测驱动器超时值（仅 XT 使用，其他为 0）

0x0C	字	lzone	磁头着陆(停止)柱面号
0x0E	字节	sect	每磁道扇区数
0x0F	字节		保留。

3.4.3.4 A20 地址线问题

1981 年 8 月，IBM 公司最初推出的个人计算机 IBM PC 使用的 CPU 是 Intel 8088。在该微机中地址线只有 20 根(A0 – A19)。在当时内存 RAM 只有几百 KB 或不到 1MB 时，20 根地址线已足够用来寻址这些内存。其所能寻址的最高地址是 0xffff:0xffff，也即 0x10ffef。对于超出 0x100000(1MB)的寻址地址将默认地环绕到 0x0ffef。当 IBM 公司于 1985 年引入 AT 机时，使用的是 Intel 80286 CPU，具有 24 根地址线，最高可寻址 16MB，并且有一个与 8088 完全兼容的实模式运行方式。然而，在寻址值超过 1MB 时它却不能象 8088 那样实现地址寻址的环绕。但是当时已经有一些程序是利用这种地址环绕机制进行工作的。为了实现完全的兼容性，IBM 公司发明了使用一个开关来开启或禁止 0x100000 地址比特位。由于在当时的 8042 键盘控制器上恰好有空闲的端口引脚（输出端口 P2，引脚 P21），于是便使用了该引脚来作为与门控制这个地址比特位。该信号即被称为 A20。如果它为零，则比特 20 及以上地址都被清除。从而实现了兼容性。

由于在机器启动时，默认条件下，A20 地址线是禁止的，所以操作系统必须使用适当的方法来开启它。但是由于各种兼容机所使用的芯片集不同，要做到这一点却是非常的麻烦。因此通常要在几种控制方法中选择。

对 A20 信号线进行控制的常用方法是通过设置键盘控制器的端口值。这里的 setup.s 程序（138-144 行）即使用了这种典型的控制方式。对于其他一些兼容微机还可以使用其他方式来做到对 A20 线的控制。

有些操作系统将 A20 的开启和禁止作为实模式与保护运行模式之间进行转换的标准过程中的一部分。由于键盘的控制器速度很慢，因此就不能使用键盘控制器对 A20 线来进行操作。为此引进了一个 A20 快速门选项(Fast Gate A20)，它使用 I/O 端口 0x92 来处理 A20 信号线，避免了使用慢速的键盘控制器操作方式。对于不含键盘控制器的系统就只能使用 0x92 端口来控制，但是该端口也有可能被其他兼容微机上的设备（如显示芯片）所使用，从而造成系统错误的操作。

还有一种方式是通过读 0xee 端口来开启 A20 信号线，写该端口则会禁止 A20 信号线。

3.4.3.5 8259 中断控制器芯片

8259A 是一种可编程的中断控制芯片，每片可以管理 8 个中断源。通过多片的级联方式，能构成最多管理 64 个中断向量的系统。在 PC/AT 系列兼容机中，使用了两片 8259A 芯片，共可管理 15 级中断向量。其级连示意图见图 3-6 所示。其中从芯片的 INT 引脚连接到主芯片的 IR2 引脚上。主 8259A 芯片的端口基地址是 0x20，从芯片是 0xA0。

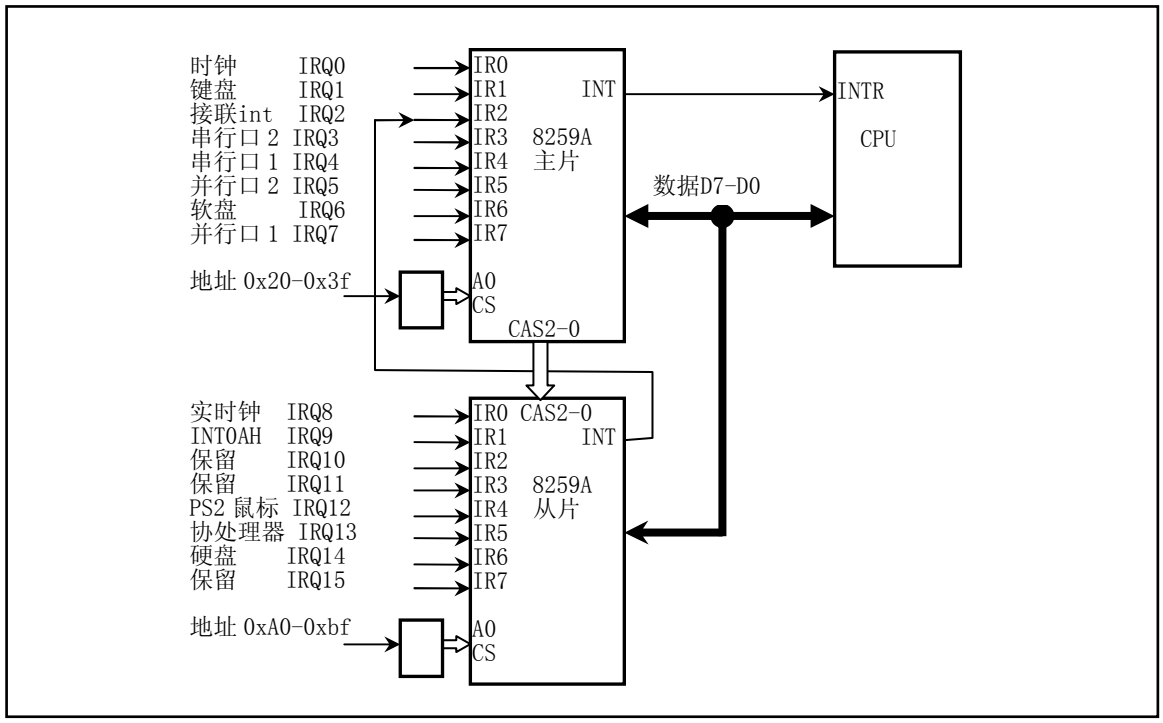

图 3-6 PC/AT 微机级连式 8259 控制系统

在总线控制器的控制下，芯片可以处于编程状态和操作状态。编程状态是 CPU 使用 IN 或 OUT 指令对 8259A 芯片进行初始化编程的状态。一旦完成了初始化编程，芯片即进入操作状态，此时芯片即可随时响应外部设备提出的中断请求（IRQ0 – IRQ15）。通过中断判优选择，芯片将选中当前最高优先级的中断请求作为中断服务对象，并通过 CPU 引脚 INT 通知 CPU 外中断请求的到来，CPU 响应后，芯片从数据总线 D7-D0 将编程设定的当前服务对象的中断号送出，CPU 由此获取对应的中断向量值，并执行中断服务程序。

在 Linux 内核中，这些硬件中断信号对应的中断号是从 int 32（0x20）开始的（int 0 - int 31 被用于 CPU 的陷阱中断），也即中断号范围是 int32 -- int 47。

3.4.3.6 Intel CPU 32 位保护运行模式

Intel CPU 一般可以在两种模式下运行，即实地址模式和保护模式。早期的 Intel CPU（8088/8086）只能工作在实模式下，某一时刻只能运行单个任务。对于 Intel 80386 以上的芯片则还可以运行在 32 位保护模式下。在保护模式下运行可以支持多任务；支持 4G 的物理内存；支持虚拟内存；支持内存的页式管理和段式管理；支持特权级。

虽然对保护模式下的运行机制是理解 Linux 内核的重要基础，但由于篇幅所限，对其工作原理的简单介绍可以参考书后的附录。但仍然建议初学者能够对书后列出的相关书籍，作一番仔细研究。为了真正理解 setup.s 程序和下面 head.s 程序的作用，起码要先明白段选择符、段描述符和 80x86 的页表寻址机制。

3.4.3.7 内存管理寄存器

Intel 80386 CPU 有 4 个寄存器用来定位控制分段内存管理的数据结构：

GDTR （Global Descriptor Table Register）全局描述符表寄存器；

LDTR （Local Descriptor Table Register）局部描述符表寄存器；

这两个寄存器用于指向段描述符表 GDT 和 LDT，对这两个表的详细说明请参见附录。

IDTR （Interrupt Descriptor Table Register）中断描述符表寄存器；

这个寄存器指向中断处理向量（句柄）表（IDT）的入口点。所有中断处理过程的入口地址信息均

存放在该表中的描述符表项中。

TR （Task Register）任务寄存器；

该寄存器指向处理器定义当前任务（进程）所需的信息，也即任务数据结构 task{}。

3.4.3.8 控制寄存器

Intel 80386 的控制寄存器共有 4 个，分别命名为 CR0、CR1、CR2、CR3。这些寄存器仅能够由系统程序通过 MOV 指令访问。见图 3-7 所示。

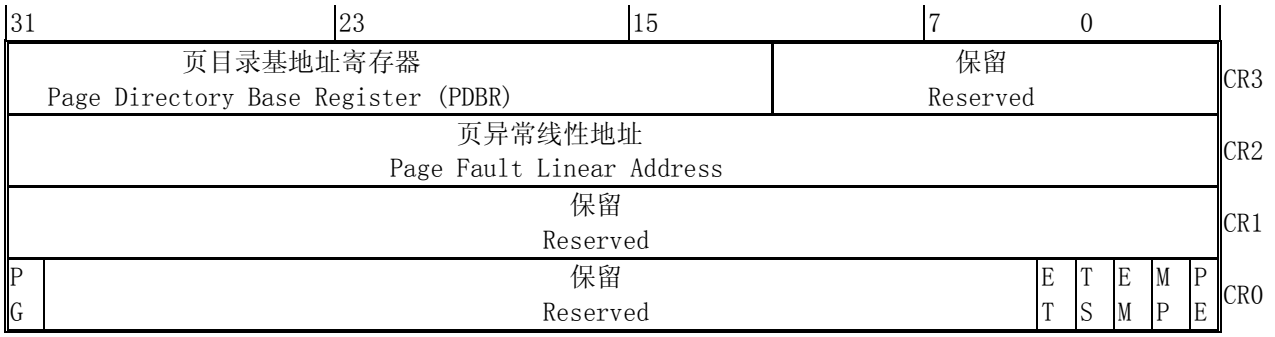

图 3-7 控制寄存器结构

控制寄存器 CR0 含有系统整体的控制标志，它控制或指示出整个系统的运行状态或条件。其中：

- PE – 保护模式开启位（Protection Enable，比特位 0）。如果设置了该比特位，就会使处理器开始在保护模式下运行。
- MP – 协处理器存在标志（Math Present，比特位 1）。用于控制 WAIT 指令的功能，以配合协处理的运行。
- EM – 仿真控制（Emulation，比特位 2）。指示是否需要仿真协处理器的功能。
- TS – 任务切换（Task Switch，比特位 3）。每当任务切换时处理器就会设置该比特位，并且在解释协处理器指令之前测试该位。
- ET – 扩展类型（Extention Type，比特位 4）。该位指出了系统中所含有的协处理器类型（是 80287 还是 80387）。
- PG – 分页操作（Paging，比特位 31）。该位指示出是否使用页表将线性地址变换成物理地址。参见第 10 章对分页内存管理的描述。

CR2 用于 PG 置位时处理页异常操作。CPU 会将引起错误的线性地址保存在该寄存器中。

CR3 同样也是在 PG 标志置位时起作用。该寄存器为 CPU 指定当前运行的任务所使用的页表目录。

3.5 head.s 程序

3.5.1 功能描述

head.s 程序在被编译后，会被连接成 system 模块的最前面开始部分，这也就是为什么称其为头部(head)程序的原因。从这里开始，内核完全都是在保护模式下运行了。heads.s 汇编程序与前面的语法格式不同，它采用的是 AT&T 的汇编语言格式，并且需要使用 GNU 的 gas 和 gld[5]进行编译连接。因此请注意代码中赋值的方向是从左到右。

5 在当前的 Linux 操作系统中，gas 和 gld 已经分别更名为 as 和 ld。

这段程序实际上处于内存绝对地址 0 处开始的地方。这个程序的功能比较单一。首先是加载各个数据段寄存器，重新设置中断描述符表 idt，共 256 项，并使各个表项均指向一个只报错误的哑中断程序。然后重新设置全局描述符表 gdt。接着使用物理地址 0 与 1MB 开始处的内容相比较的方法，检测 A20 地址线是否已真的开启（如果没有开启，则在访问高于 1MB 物理内存地址时 CPU 实际只会访问（IP MOD 1Mb）地址处的内容），如果检测下来发现没有开启，则进入死循环。然后程序测试 PC 机是否含有数学协处理器芯片（80287、80387 或其兼容芯片），并在控制寄存器 CR0 中设置相应的标志位。接着设置管理内存的分页处理机制，将页目录表放在绝对物理地址 0 开始处（也是本程序所处的物理内存位置，因此这段程序将被覆盖掉），紧随后面放置共可寻址 16MB 内存的 4 个页表，并分别设置它们的表项。最后利用返回指令将预先放置在堆栈中的/init/main.c 程序的入口地址弹出，去运行 main()程序。

3.5.2 代码注释

程序 3-3 linux/boot/head.s

```
1  /*
2   *  linux/boot/head.s
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   *  head.s contains the 32-bit startup code.
9   *
10  * NOTE!!! Startup happens at absolute address 0x00000000, which is also where
11  * the page directory will exist. The startup code will be overwritten by
12  * the page directory.
13  */
    /*
     *  head.s 含有 32 位启动代码。
     * 注意!!! 32 位启动代码是从绝对地址 0x00000000 开始的，这里也同样是页目录将存在的地方，
    * 因此这里的启动代码将被页目录覆盖掉。
    */
14 .text
15 .globl _idt,_gdt,_pg_dir,_tmp_floppy_area
16 _pg_dir:   # 页目录将会存放在这里。
17 startup_32:                # 18-22 行设置各个数据段寄存器。
18         movl $0x10,%eax    # 对于 GNU 汇编来说，每个直接操作数要以'$'开始，否则是表示地址。
                              # 每个寄存器名都要以'%'开头，eax 表示是 32 位的 ax 寄存器。

    # 再次注意!!! 这里已经处于 32 位运行模式，因此这里的$0x10 并不是把地址 0x10 装入各个
    # 段寄存器，它现在其实是全局段描述符表中的偏移值，或者更准确地说是一个描述符表项
    # 的选择符。有关选择符的说明请参见 setup.s 中 193 行下的说明。这里$0x10 的含义是请求
    # 特权级 0(位 0-1=0)、选择全局描述符表(位 2=0)、选择表中第 2 项(位 3-15=2)。它正好指
    # 向表中的数据段描述符项。（描述符的具体数值参见前面 setup.s 中 212，213 行）
    # 下面代码的含义是：置 ds,es,fs,gs 中的选择符为 setup.s 中构造的数据段（全局段描述符表
    # 的第 2 项）=0x10，并将堆栈放置在 stack_start 指向的 user_stack 数组区，然后使用本程序
    # 后面定义的新中断描述符表和全局段描述表。新全局段描述表中初始内容与 setup.s 中的基本
    # 一样，仅段限长从 8MB 修改成了 16MB。stack_start 定义在 kernel/sched.c，69 行。它是指向
    # user_stack 数组末端的一个长指针。
19         mov %ax,%ds
20         mov %ax,%es
```

```
21          mov %ax,%fs
22          mov %ax,%gs
23          lss _stack_start,%esp   # 表示_stack_start➔ss:esp，设置系统堆栈。
                                    # stack_start 定义在 kernel/sched.c，69 行。
24          call setup_idt          # 调用设置中断描述符表子程序。
25          call setup_gdt          # 调用设置全局描述符表子程序。
26          movl $0x10,%eax         # reload all the segment registers
27          mov %ax,%ds             # after changing gdt. CS was already
28          mov %ax,%es             # reloaded in 'setup_gdt'
29          mov %ax,%fs             # 因为修改了 gdt，所以需要重新装载所有的段寄存器。
30          mov %ax,%gs             # CS 代码段寄存器已经在 setup_gdt 中重新加载过了。
    # 由于段描述符中的段限长从 setup.s 程序的 8MB 改成了本程序设置的 16MB（见 setup.s 行 208-216
    # 和本程序后面的行 235-236），因此这里再次对所有段寄存器执行加载操作是必须的。
    # 另外，通过使用 bochs 跟踪观察，如果不对 CS 再次执行加载，那么在执行到行 26 时 CS 代码段不可见
    # 部分中的限长还是 8MB。这样看来应该重新加载 CS，但在实际机器上测试结果表明 CS 已经加载过了。
31          lss _stack_start,%esp
    # 32-36 行用于测试 A20 地址线是否已经开启。采用的方法是向内存地址 0x000000 处写入任意
    # 一个数值，然后看内存地址 0x100000(1M)处是否也是这个数值。如果一直相同的话，就一直
    # 比较下去，也即死循环、死机。表示地址 A20 线没有选通，结果内核就不能使用 1MB 以上内存。
32          xorl %eax,%eax
33  1:      incl %eax               # check that A20 really IS enabled
34          movl %eax,0x000000      # loop forever if it isn't
35          cmpl %eax,0x100000
36          je 1b                   # '1b'表示向后(backward)跳转到标号 1 去（33 行）。
                                    # 若是'5f'则表示向前(forward)跳转到标号 5 去。
37  /*
38   * NOTE! 486 should set bit 16, to check for write-protect in supervisor
39   * mode. Then it would be unnecessary with the "verify_area()"-calls.
40   * 486 users probably want to set the NE (#5) bit also, so as to use
41   * int 16 for math errors.
42   */
    /*
     * 注意! 在下面这段程序中，486 应该将位 16 置位，以检查在超级用户模式下的写保护,
     * 此后"verify_area()"调用中就不需要了。486 的用户通常也会想将 NE(#5)置位，以便
     * 对数学协处理器的出错使用 int 16。
     */
    # 下面这段程序（43-65）用于检查数学协处理器芯片是否存在。方法是修改控制寄存器 CR0，在
    # 假设存在协处理器的情况下执行一个协处理器指令，如果出错的话则说明协处理器芯片不存在，
    # 需要设置 CR0 中的协处理器仿真位 EM（位 2），并复位协处理器存在标志 MP（位 1）。
43          movl %cr0,%eax          # check math chip
44          andl $0x80000011,%eax   # Save PG,PE,ET
45  /* "orl $0x10020,%eax" here for 486 might be good */
46          orl $2,%eax             # set MP
47          movl %eax,%cr0
48          call check_x87
49          jmp after_page_tables   # 跳转到 135 行。
50
51  /*
52   * We depend on ET to be correct. This checks for 287/387.
53   */
    /*
     * 我们依赖于 ET 标志的正确性来检测 287/387 存在与否。
     */
```

```
54 check_x87:
55         fninit
56         fstsw %ax
57         cmpb $0,%al
58         je 1f                   /* no coprocessor: have to set bits */
59         movl %cr0,%eax           # 如果存在则向前跳转到标号 1 处，否则改写 cr0。
60         xorl $6,%eax            /* reset MP, set EM */
61         movl %eax,%cr0
62         ret
   # 下面是一汇编语言指示符。其含义是指存储边界对齐调整。"2"表示把随后的代码或数据的偏移位置
   # 调整到地址值最后 2 比特位为零的位置，即按 4 字节方式对齐内存地址。使用该指示符的目的是为
   # 了提高 32 位 CPU 访问内存中代码或数据的速度和效率。
63 .align 2    # 汇编语言指示符，
               #,
64 1:      .byte 0xDB,0xE4         /* fsetpm for 287, ignored by 387 */  # 287 协处理器码。
65         ret
66
67 /*
68  *  setup_idt
69  *
70  *  sets up a idt with 256 entries pointing to
71  *  ignore_int, interrupt gates. It then loads
72  *  idt. Everything that wants to install itself
73  *  in the idt-table may do so themselves. Interrupts
74  *  are enabled elsewhere, when we can be relatively
75  *  sure everything is ok. This routine will be over-
76  *  written by the page tables.
77  */
   /*
    * 下面这段是设置中断描述符表子程序 setup_idt
    *
    * 将中断描述符表 idt 设置成具有 256 个项，并都指向 ignore_int 中断门。然后加载中断
    * 描述符表寄存器(用 lidt 指令)。真正实用的中断门以后再安装。当我们在其他地方认为一切
    * 都正常时再开启中断。该子程序将会被页表覆盖掉。
    */
   # 中断描述符表中的项虽然也是 8 字节组成，但其格式与全局表中的不同，被称为门描述符
   # (Gate Descriptor)。它的 0-1,6-7 字节是偏移量，2-3 字节是选择符，4-5 字节是一些标志。
78 setup_idt:
79         lea ignore_int,%edx      # 将 ignore_int 的有效地址（偏移值）值➔edx 寄存器
80         movl $0x00080000,%eax    # 将选择符 0x0008 置入 eax 的高 16 位中。
81         movw %dx,%ax            /* selector = 0x0008 = cs */
                                    # 偏移值的低 16 位置入 eax 的低 16 位中。此时 eax 含有
                                    #门描述符低 4 字节的值。
82         movw $0x8E00,%dx        /* interrupt gate - dpl=0, present */
83                                  # 此时 edx 含有门描述符高 4 字节的值。
84         lea _idt,%edi            # _idt 是中断描述符表的地址。
85         mov $256,%ecx
86 rp_sidt:
87         movl %eax,(%edi)         # 将哑中断门描述符存入表中。
88         movl %edx,4(%edi)
89         addl $8,%edi             # edi 指向表中下一项。
90         dec %ecx
91         jne rp_sidt
```

```
 92         lidt idt_descr           # 加载中断描述符表寄存器值。
 93         ret
 94
 95 /*
 96  *  setup_gdt
 97  *
 98  *  This routines sets up a new gdt and loads it.
 99  *  Only two entries are currently built, the same
100  *  ones that were built in init.s. The routine
101  *  is VERY complicated at two whole lines, so this
102  *  rather long comment is certainly needed :-).
103  *  This routine will beoverwritten by the page tables.
104  */
    /*
     * 设置全局描述符表项 setup_gdt
     * 这个子程序设置一个新的全局描述符表 gdt，并加载。此时仅创建了两个表项，与前
     * 面的一样。该子程序只有两行，“非常的”复杂，所以当然需要这么长的注释了☺。
     * 该子程序将被页表覆盖掉。
     */
105 setup_gdt:
106         lgdt gdt_descr       # 加载全局描述符表寄存器(内容已设置好，见 234-238 行)。
107         ret
108
109 /*
110  * I put the kernel page tables right after the page directory,
111  * using 4 of them to span 16 Mb of physical memory. People with
112  * more than 16MB will have to expand this.
113  */
    /* Linus 将内核的内存页表直接放在页目录之后，使用了 4 个表来寻址 16 MB 的物理内存。
     * 如果你有多于 16 Mb 的内存，就需要在这里进行扩充修改。
     */
     # 每个页表长为 4 Kb 字节（1 页内存页面），而每个页表项需要 4 个字节，因此一个页表共可以存放
     # 1024 个表项。如果一个页表项寻址 4 KB 的地址空间，则一个页表就可以寻址 4 MB 的物理内存。
     # 页表项的格式为：项的前 0-11 位存放一些标志，例如是否在内存中(P 位 0)、读写许可(R/W 位 1)、
     # 普通用户还是超级用户使用(U/S 位 2)、是否修改过(是否脏了)(D 位 6)等；表项的位 12-31 是
     # 页框地址，用于指出一页内存的物理起始地址。
114 .org 0x1000       # 从偏移 0x1000 处开始是第 1 个页表（偏移 0 开始处将存放页表目录）。
115 pg0:
116
117 .org 0x2000
118 pg1:
119
120 .org 0x3000
121 pg2:
122
123 .org 0x4000
124 pg3:
125
126 .org 0x5000         # 定义下面的内存数据块从偏移 0x5000 处开始。
127 /*
128  * tmp_floppy_area is used by the floppy-driver when DMA cannot
129  * reach to a buffer-block. It needs to be aligned, so that it isn't
130  * on a 64kB border.
```

```
131  */
     /* 当 DMA（直接存储器访问）不能访问缓冲块时，下面的 tmp_floppy_area 内存块
      * 就可供软盘驱动程序使用。其地址需要对齐调整，这样就不会跨越 64KB 边界。
      */
132  _tmp_floppy_area:
133          .fill 1024,1,0          # 共保留 1024 项，每项 1 字节，填充数值 0。
134
     # 下面这几个入栈操作(pushl)用于为调用/init/main.c 程序和返回作准备。
     # 前面 3 个入栈 0 值应该分别是 envp、argv 指针和 argc 值，但 main()没有用到。
     # 139 行的入栈操作是模拟调用 main.c 程序时首先将返回地址入栈的操作，所以如果
     # main.c 程序真的退出时，就会返回到这里的标号 L6 处继续执行下去，也即死循环。
     # 140 行将 main.c 的地址压入堆栈，这样，在设置分页处理（setup_paging）结束后
     # 执行'ret'返回指令时就会将 main.c 程序的地址弹出堆栈，并去执行 main.c 程序去了。
135  after_page_tables:
136          pushl $0                # These are the parameters to main :-)
137          pushl $0                # 这些是调用 main 程序的参数（指 init/main.c）。
138          pushl $0                # 其中的'$'符号表示这是一个立即操作数。
139          pushl $L6               # return address for main, if it decides to.
140          pushl $_main            # '_main'是编译程序对 main 的内部表示方法。
141          jmp setup_paging        # 跳转至第 198 行。
142  L6:
143          jmp L6                  # main should never return here, but
144                                  # just in case, we know what happens.
145
146  /* This is the default interrupt "handler" :-) */
     /* 下面是默认的中断“向量句柄”☺ */
147  int_msg:
148          .asciz "Unknown interrupt\n\r"      # 定义字符串“未知中断(回车换行)”。
149  .align 2                    # 按 4 字节方式对齐内存地址。
150  ignore_int:
151          pushl %eax
152          pushl %ecx
153          pushl %edx
154          push %ds            # 这里请注意！！ds,es,fs,gs 等虽然是 16 位的寄存器，但入栈后
                                 # 仍然会以 32 位的形式入栈，也即需要占用 4 个字节的堆栈空间。
155          push %es
156          push %fs
157          movl $0x10,%eax     # 置段选择符（使 ds,es,fs 指向 gdt 表中的数据段）。
158          mov %ax,%ds
159          mov %ax,%es
160          mov %ax,%fs
161          pushl $int_msg      # 把调用 printk 函数的参数指针（地址）入栈。
162          call _printk        # 该函数在/kernel/printk.c 中。
                                 # '_printk'是 printk 编译后模块中的内部表示法。
163          popl %eax
164          pop %fs
165          pop %es
166          pop %ds
167          popl %edx
168          popl %ecx
169          popl %eax
170          iret            # 中断返回（把中断调用时压入栈的 CPU 标志寄存器（32 位）值也弹出）。
171
```

```
172
173 /*
174  * Setup_paging
175  *
176  * This routine sets up paging by setting the page bit
177  * in cr0. The page tables are set up, identity-mapping
178  * the first 16MB. The pager assumes that no illegal
179  * addresses are produced (ie >4Mb on a 4Mb machine).
180  *
181  * NOTE! Although all physical memory should be identity
182  * mapped by this routine, only the kernel page functions
183  * use the >1Mb addresses directly. All "normal" functions
184  * use just the lower 1Mb, or the local data space, which
185  * will be mapped to some other place - mm keeps track of
186  * that.
187  *
188  * For those with more memory than 16 Mb - tough luck. I've
189  * not got it, why should you :-) The source is here. Change
190  * it. (Seriously - it shouldn't be too difficult. Mostly
191  * change some constants etc. I left it at 16Mb, as my machine
192  * even cannot be extended past that (ok, but it was cheap :-)
193  * I've tried to show which constants to change by having
194  * some kind of marker at them (search for "16Mb"), but I
195  * won't guarantee that's all :-( )
196  */
    /*
     * 这个子程序通过设置控制寄存器 cr0 的标志（PG 位 31）来启动对内存的分页处理功能，
     * 并设置各个页表项的内容，以恒等映射前 16 MB 的物理内存。分页器假定不会产生非法的
     * 地址映射（也即在只有 4Mb 的机器上设置出大于 4Mb 的内存地址）。
     * 注意！尽管所有的物理地址都应该由这个子程序进行恒等映射，但只有内核页面管理函数能
     * 直接使用>1Mb 的地址。所有“一般”函数仅使用低于 1Mb 的地址空间，或者是使用局部数据
     * 空间，地址空间将被映射到其他一些地方去 -- mm(内存管理程序)会管理这些事的。
     * 对于那些有多于 16Mb 内存的家伙 - 真是太幸运了，我还没有，为什么你会有☺。代码就在
     * 这里，对它进行修改吧。（实际上，这并不太困难的。通常只需修改一些常数等。我把它设置
     * 为 16Mb，因为我的机器再怎么扩充甚至不能超过这个界限（当然，我的机器是很便宜的☺）。
     * 我已经通过设置某类标志来给出需要改动的地方（搜索“16Mb”），但我不能保证作这些
     * 改动就行了☹）。
     */
    # 在内存物理地址 0x0 处开始存放 1 页页目录表和 4 页页表。页目录表是系统所有进程公用的，而
    # 这里的 4 页页表则是属于内核专用。对于新的进程，系统会在主内存区为其申请页面存放页表。
    # 1 页内存长度是 4096 字节。
197 .align 2        # 按 4 字节方式对齐内存地址边界。
198 setup_paging:   # 首先对 5 页内存（1 页目录 + 4 页页表）清零
199         movl $1024*5,%ecx               /* 5 pages - pg_dir+4 page tables */
200         xorl %eax,%eax
201         xorl %edi,%edi                  /* pg_dir is at 0x000 */
                                             # 页目录从 0x000 地址开始。
202         cld;rep;stosl
    # 下面 4 句设置页目录表中的项，因为我们（内核）共有 4 个页表所以只需设置 4 项。
    # 页目录项的结构与页表中项的结构一样，4 个字节为 1 项。参见上面 113 行下的说明。
    # "$pg0+7"表示：0x00001007，是页目录表中的第 1 项。
    # 则第 1 个页表所在的地址 = 0x00001007 & 0xfffff000 = 0x1000;
    # 第 1 个页表的属性标志 = 0x00001007 & 0x00000fff = 0x07，表示该页存在、用户可读写。
```

```
203         movl $pg0+7,_pg_dir             /* set present bit/user r/w */
204         movl $pg1+7,_pg_dir+4           /*  --------- " " --------- */
205         movl $pg2+7,_pg_dir+8           /*  --------- " " --------- */
206         movl $pg3+7,_pg_dir+12          /*  --------- " " --------- */
    # 下面 6 行填写 4 个页表中所有项的内容，共有：4(页表)*1024(项/页表)=4096 项(0 - 0xfff)，
    # 也即能映射物理内存 4096*4Kb = 16Mb。
    # 每项的内容是：当前项所映射的物理内存地址 + 该页的标志（这里均为 7）。
    # 使用的方法是从最后一个页表的最后一项开始按倒退顺序填写。一个页表的最后一项在页表中的
    # 位置是 1023*4 = 4092。因此最后一页的最后一项的位置就是$pg3+4092。
207         movl $pg3+4092,%edi              # edi➔最后一页的最后一项。
208         movl $0xfff007,%eax             /*  16Mb - 4096 + 7 (r/w user,p) */
                                             # 最后 1 项对应物理内存页面的地址是 0xfff000，
                                             # 加上属性标志 7，即为 0xfff007.
209         std                              # 方向位置位，edi 值递减(4 字节)。
210 1:      stosl                           /* fill pages backwards - more efficient :-) */
211         subl $0x1000,%eax                # 每填写好一项，物理地址值减 0x1000。
212         jge 1b                           # 如果小于 0 则说明全添写好了。
    # 设置页目录基址寄存器 cr3 的值，指向页目录表。
213         xorl %eax,%eax                  /* pg_dir is at 0x0000 */   # 页目录表在 0x0000 处。
214         movl %eax,%cr3                  /* cr3 - page directory start */
    # 设置启动使用分页处理（cr0 的 PG 标志，位 31）
215         movl %cr0,%eax
216         orl $0x80000000,%eax             # 添上 PG 标志。
217         movl %eax,%cr0                  /* set paging (PG) bit */
218         ret                             /* this also flushes prefetch-queue */
    # 在改变分页处理标志后要求使用转移指令刷新预取指令队列，这里用的是返回指令 ret。
    # 该返回指令的另一个作用是将堆栈中的 main 程序的地址弹出，并开始运行/init/main.c 程序。
    # 本程序到此真正结束了。
219
220 .align 2                               # 按 4 字节方式对齐内存地址边界。
221 .word 0
222 idt_descr:                             #下面两行是 lidt 指令的 6 字节操作数：长度，基址。
223         .word 256*8-1                   # idt contains 256 entries
224         .long _idt
225 .align 2
226 .word 0
227 gdt_descr:                             # 下面两行是 lgdt 指令的 6 字节操作数：长度，基址。
228         .word 256*8-1                   # so does gdt (not that that's any        # not → note.
229         .long _gdt                      # magic number, but it works for me :^)
230
231         .align 3                        # 按 8 字节方式对齐内存地址边界。
232 _idt:   .fill 256,8,0                   # idt is uninitialized   # 256 项，每项 8 字节，填 0。
233
    # 全局表。前 4 项分别是空项（不用）、代码段描述符、数据段描述符、系统段描述符，其中
    # 系统段描述符 linux 没有派用处。后面还预留了 252 项的空间，用于放置所创建任务的
    # 局部描述符(LDT)和对应的任务状态段 TSS 的描述符。
    # (0-nul, 1-cs, 2-ds, 3-sys, 4-TSS0, 5-LDT0, 6-TSS1, 7-LDT1, 8-TSS2 etc...)
234 _gdt:   .quad 0x0000000000000000        /* NULL descriptor */
235         .quad 0x00c09a0000000fff        /* 16Mb */       # 0x08，内核代码段最大长度 16MB。
236         .quad 0x00c0920000000fff        /* 16Mb */       # 0x10，内核数据段最大长度 16MB。
237         .quad 0x0000000000000000        /* TEMPORARY - don't use */
238         .fill 252,8,0                   /* space for LDT's and TSS's etc */
```

3.5.3 其他信息

3.5.3.1 程序执行结束后的内存映像

head.s 程序执行结束后，已经正式完成了内存页目录和页表的设置，并重新设置了内核实际使用的中断描述符表 idt 和全局描述符表 gdt。另外还为软盘驱动程序开辟了 1KB 字节的缓冲区。此时 system 模块在内存中的详细映像见图 3-8 所示。

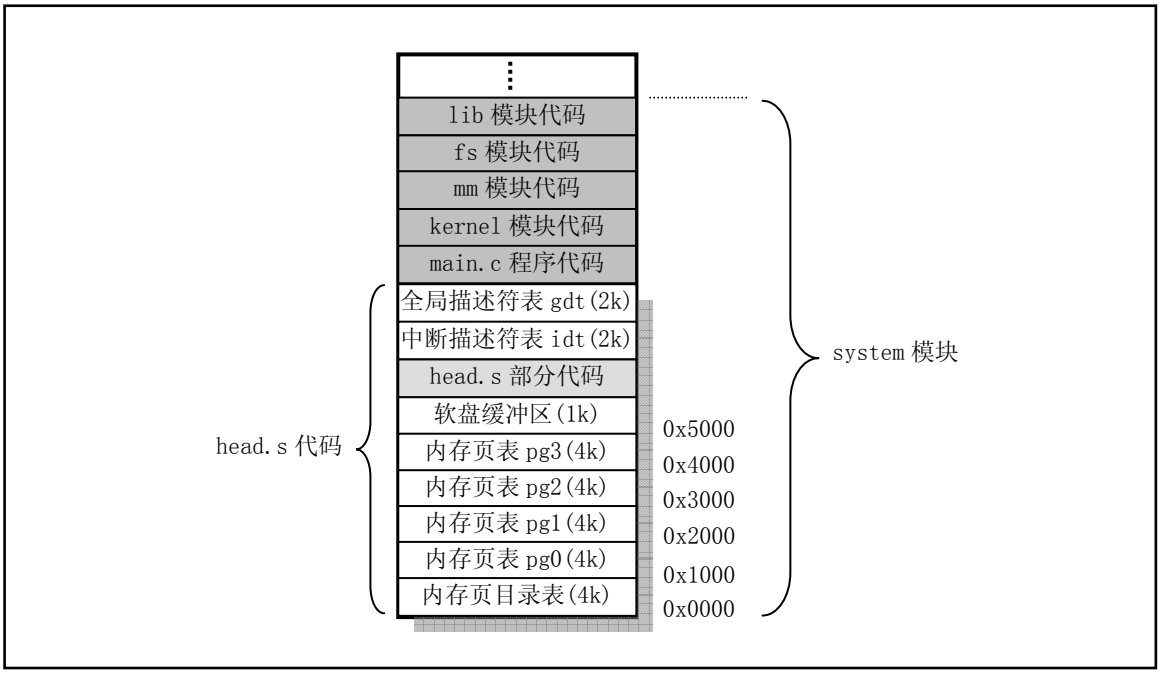

图 3-8 system 模块在内存中的映像示意图

3.5.3.2 Intel 32 位保护运行机制

理解这段程序的关键是真正了解 Intel 386 32 位保护模式的运行机制，也是继续阅读以下其余程序所必需的。为了与 8086 CPU 兼容，80x86 的保护模式被处理的较为复杂。当 CPU 运行在保护模式下时，它就将实模式下的段地址当作保护模式下段描述符的指针使用，此时段寄存器中存放的是一个描述符在描述符表中的偏移地址值。而当前描述符表的基地址则保存在描述符表寄存器中，如全局描述符表寄存器 gdtr、中断门描述符表寄存器 idtr，加载这些表寄存器须使用专用指令 lgdt 或 lidt。

CPU 在实模式运行方式时，段寄存器用来放置一个内存段地址（例如 0x9000），而此时在该段内可以寻址 64KB 的内存。但当进入保护模式运行方式时，此时段寄存器中放置的并不是内存中的某个地址值，而是指定描述符表中某个描述符项相对于该描述符表基址的一个偏移量。在这个 8 字节的描述符中含有该段线性地址的‘段’基址和段的长度，以及其他一些描述该段特征的比特位。因此此时所寻址的内存位置是这个段基址加上当前执行代码指针 eip 的值。当然，此时所寻址的实际物理内存地址，还需要经过内存页面处理管理机制进行变换后才能得到。简而言之，32 位保护模式下的内存寻址需要拐个弯，经过描述符表中的描述符和内存页管理来确定。

针对不同的使用方面，描述符表分为三种：全局描述符表（GDT）、中断描述符表（IDT）和局部描述符表（LDT）。当 CPU 运行在保护模式下，某一时刻 GDT 和 IDT 分别只能有一个，分别由寄存器 GDTR 和 IDTR 指定它们的表基址。局部表可以有 0-8191 个，其基址由当前 LDTR 寄存器的内容指定，是使用 GDT 中某个描述符来加载的，也即 LDT 也是由 GDT 中的描述符来指定。但是在某一时刻同样也只有其中的一个被认为是活动的。一般对于每个任务（进程）使用一个 LDT。在运行时，程序可以使用 GDT 中的描述符以及当前任务的 LDT 中的描述符。

中断描述符表 IDT 的结构与 GDT 类似，在 Linux 内核中它正好位于 GDT 表的后面。共含有 256 项 8 字节的描述符。但每个描述符项的格式与 GDT 的不同，其中存放着相应中断过程的偏移值（0-1，6-7 字节）、所处段的选择符值（2-3 字节）和一些标志（4-5 字节）。

图 3-9 是 Linux 内核中所使用的描述符表在内存中的示意图。图中，每个任务在 GDT 中占有两个描述符项。GDT 表中的 LDT0 描述符项是第一个任务（进程）的局部描述符表的描述符，TSS0 是第一个任务的任务状态段（TSS）的描述符。每个 LDT 中含有三个描述符，其中第一个不用，第二个是任务代码段的描述符，第三个是任务数据段和堆栈段的描述符。当 DS 段寄存器中是第一个任务的数据段选择符时，DS:ESI 即指向该任务数据段中的某个数据。

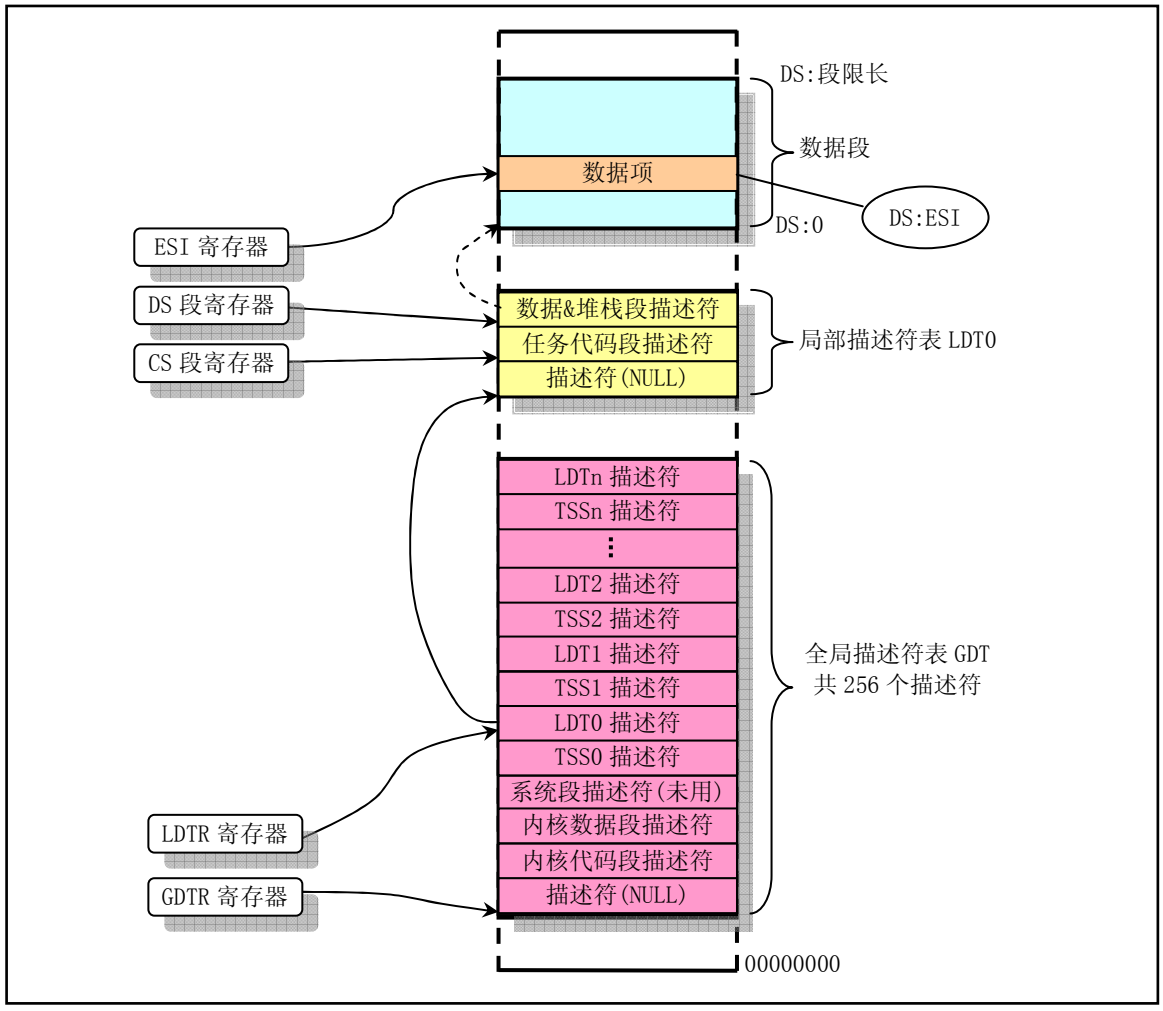

图 3-9 Linux 内核使用描述符表的示意图。

3.6 本章小结

引导加载程序 bootsect.s 将 setup.s 代码和 system 模块加载到内存中，并且分别把自己和 setup.s 代码移动到物理内存 0x90000 和 0x90200 处后，就把执行权交给了 setup 程序。其中 system 模块的首部包含有 head.s 代码。

setup 程序的主要作用是利用 ROM BIOS 的中断程序获取机器的一些基本参数，并保存在 0x90000 开始的内存块中，供后面程序使用。同时把 system 模块往下移动到物理地址 0x00000 开始处，这样，system 中的 head.s 代码就处在 0x00000 开始处了。然后加载描述符表基地址到描述符表寄存器中，为进行 32 位保护模式下的运行作好准备。接下来对中断控制硬件进行重新设置，最后通过设置机器控制寄存器 CR0

并跳转到 system 模块的 head.s 代码开始处，使 CPU 进入 32 位保护模式下运行。

Head.s 代码的主要作用是初步初始化中断描述符表中的 256 项门描述符，检查 A20 地址线是否已经打开，测试系统是否含有数学协处理器。然后初始化内存页目录表，为内存的分页管理作好准备工作。最后跳转到 system 模块中的初始化程序 init/main.c 中继续执行。

下一章的主要内容就是详细描述 init/main.c 程序的功能和作用。

第4章 初始化程序(init)

4.1 概述

在内核源代码的 init/目录中只有一个 main.c 文件。系统在执行完 boot/目录中的 head.s 程序后就会将执行权交给 main.c。该程序虽然不长，但却包括了内核初始化的所有工作。因此在阅读该程序的代码时需要参照很多其他程序中的初始化部分。如果能完全理解这里调用的所有程序，那么看完这章内容后你应该对 Linux 内核有了大致的了解。

从这一章开始，我们将接触大量的 C 程序代码，因此读者最好具有一定的 C 语言知识。最好的一本参考书还是 Brian W. Kernighan 和 Dennis M. Ritchie 编著的《C 程序设计语言》，对该书第五章关于指针和数组的理解，可以说是弄懂 C 语言的关键。

在注释 C 语言程序时，为了与程序中原有的注释相区别，我们使用'//'作为注释语句的开始。有关原有注释的翻译则采用与其一样的注释标志。对于程序中包含的头文件（*.h），仅作概要含义的解释，具体详细注释内容将在注释相应头文件的章节中给出。

4.2 main.c 程序

4.2.1 功能描述

main.c 程序首先利用前面 setup.s 程序取得的系统参数设置系统的根文件设备号以及一些内存全局变量。这些内存变量指明了主内存的开始地址、系统所拥有的内存容量和作为高速缓冲区内存的末端地址。如果还定义了虚拟盘（RAMDISK），则主内存将适当减少。整个内存的映像示意图见图 4-1 所示。

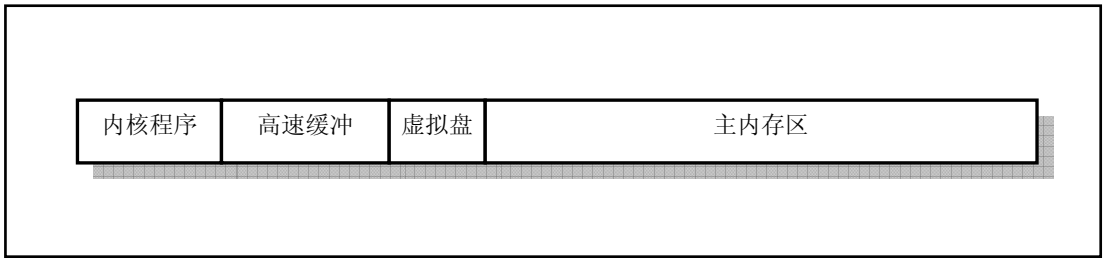

图 4-1 系统中内存功能划分示意图。

图中，高速缓冲部分还要扣除被显存和 ROM BIOS 占用的部分。高速缓冲区是用于磁盘等块设备临时存放数据的地方，以 1K（1024）字节为一个数据块单位。主内存区域的内存是由内存管理模块 mm 通过分页机制进行管理分配，以 4K 字节为一个内存页单位。内核程序可以自由访问高速缓冲中的数据，但需要通过 mm 才能使用分配到的内存页面。

然后，内核进行所有方面的硬件初始化工作。包括陷阱门、块设备、字符设备和 tty，包括人工设置

第一个任务（task 0）。待所有初始化工作完成后就设置中断允许标志以开启中断，main()也切换到了任务 0 中运行。在阅读这些初始化子程序时，最好是跟着被调用的程序深入进去看，如果实在看不下去了，就暂时先放一放，继续看下一个初始化调用。在有些理解之后再继续研究没有看完的地方。

在整个内核完成初始化后，内核将执行权切换到了用户模式（任务 0），也即 CPU 从 0 特权级切换到了第 3 特权级。此时 main.c 的主程序就工作在任务 0 中。然后系统第一次调用进程创建函数 fork()，创建出一个用于运行 init()的子进程。系统整个初始化过程见图 4-2 所示。

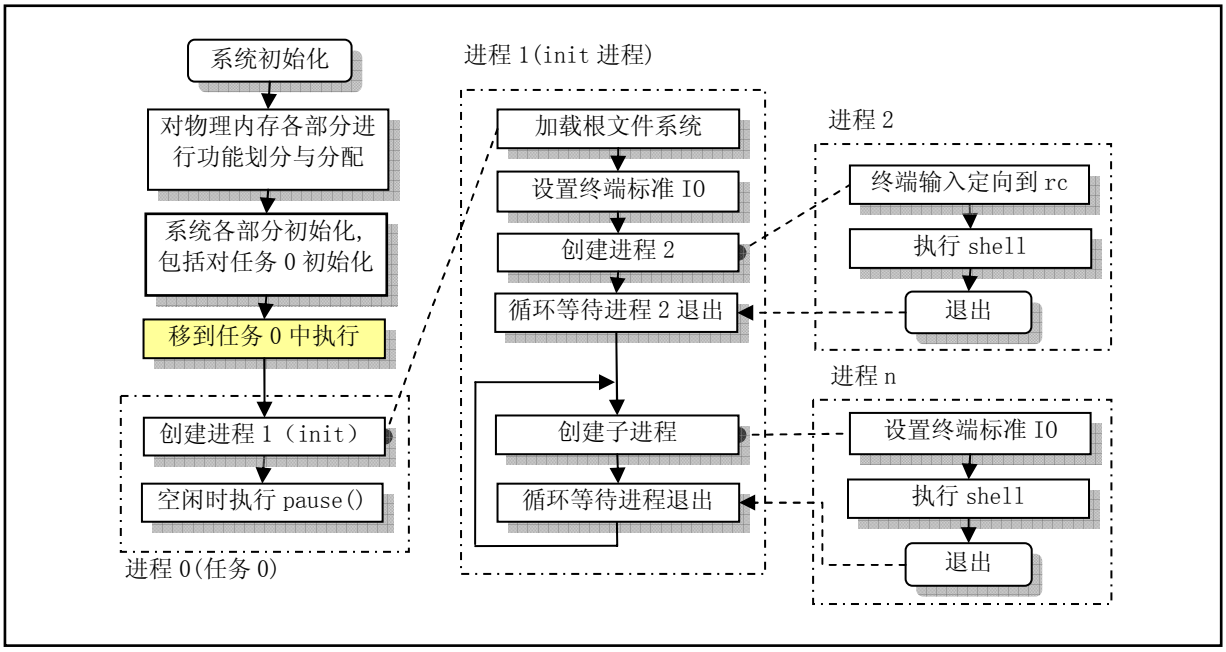

图 4-2 内核初始化程序流程示意图

该程序首先确定如何分配使用系统物理内存，然后调用内核各部分的初始化函数分别对内存管理、中断处理、块设备和字符设备、进程管理以及硬盘和软盘硬件进行初始化处理。在完成了这些操作之后，系统各部分已经处于可运行状态。此后程序把自己“手工”移动到任务 0（进程 0）中运行，并使用 fork()调用首次创建出进程 1（init 进程）。在 init 进程中程序将继续进行应用环境的初始化并执行 shell 登录程序。而原进程 0 则会在系统空闲时被调度执行，因此通常进程 0 也被称为 idle 进程。此时任务 0 仅执行 pause()系统调用，并又会调用调度函数。

在 init 进程中，如果终端环境建立成功，则会再生成一个子进程（进程 2），用于运行 shell 程序/bin/sh。若该子进程退出，则父进程进入一个死循环内，继续生成子进程，并在此子进程中再次执行 shell 程序/bin/sh，而父进程则继续等待。进程 2 与自己退出时随后创建的进程有些不同。进程 2 的终端输入被定向从/etc/rc 文件输入数据，因此当在进程 2 中执行 shell 时就会读入 rc 文件中的命令，执行一些预先设置的默认开机操作命令，例如执行一些后台程序，显示开机信息等。而在进程 2 退出后创建的进程中，标准输入被直接定向到终端 IO 上，因此在这些随后被创建的进程中不再执行系统开机初始化配置文件 rc 中的命令。rc 文件的作用与 DOS 系统根目录上的 AUTOEXEC.BAT 文件类似。

由于创建新进程的过程是通过完全复制父进程代码段和数据段的方式实现的，因此在首次使用 fork()创建新进程 init 时，为了确保新进程用户态堆栈没有进程 0 的多余信息，要求进程 0 在创建首个新进程之前不要使用用户态堆栈，也即要求任务 0 不要调用函数。因此在 main.c 主程序移动到任务 0 执行后，任务 0 中的代码 fork()不能以函数形式进行调用。程序中实现的方法是采用 gcc 函数内嵌的形式来执行这个系统调用。参见下面程序第 23 行。

> 通过声明一个内嵌（inline）函数，可以让 gcc 把函数的代码集成到调用它的代码中。这会提高代码执行的速度，因为省去了函数调用的开销。另外，如果任何一个实际参数是一个常量，那么在编译时这些已知值就可能使得无需把内嵌函数的所有代码都包括进来而让代码也得到简化。

另外，在创建新进程 init 的过程中，系统对其进行了一些特殊处理。在为新进程 init 复制父进程（进程 0）的页目录和页表项时并没有为它们处于内核区的代码和数据执行写时复制（Copy on Wirte）操作[6]，进程 0 和进程 init 实际上同时使用着内核代码区内（小于 1MB 的物理内存）相同的代码和数据物理内存页面，只是执行的代码不在一处，因此实际上它们也同时使用着相同的堆栈区。为了不出现冲突问题，就必须要求任务 0 在整个执行过程中禁止使用到堆栈区域，而让进程 init 能单独使用堆栈。因此 pause()也必须采用内嵌函数形式来实现。

当系统中一个进程（例如 init 进程的子进程，进程 2）执行过 execve()调用后，进程 2 的代码和数据区会位于系统的主内存区中，因此系统可以利用写时复制技术来处理其他新进程的创建和执行。

对于 Linux 来说，所有任务都是在用户模式下运行的，包括很多系统应用程序，如 shell 程序、网络子系统程序等。内核源代码 lib/目录下的库文件就是专门为这里新创建的进程提供支持函数的。

4.2.2 代码注释

程序 4-1 linux/init/main.c

```
 1 /*
 2  *  linux/init/main.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #define __LIBRARY__   // 定义该变量是为了包括定义在 unistd.h 中的内嵌汇编代码等信息。
 8 #include <unistd.h>   // *.h 头文件所在的默认目录是 include/，则在代码中就不用明确指明位置。
                         // 如果不是 UNIX 的标准头文件，则需要指明所在的目录，并用双引号括住。
                         // 标准符号常数与类型文件。定义了各种符号常数和类型，并声明了各种函数。
                         // 如果定义了__LIBRARY__，则还含系统调用号和内嵌汇编代码 syscall0()等。
 9 #include <time.h>     // 时间类型头文件。其中最主要定义了 tm 结构和一些有关时间的函数原形。
10
11 /*
12  * we need this inline - forking from kernel space will result
13  * in NO COPY ON WRITE (!!!), until an execve is executed. This
14  * is no problem, but for the stack. This is handled by not letting
15  * main() use the stack at all after fork(). Thus, no function
16  * calls - which means inline code for fork too, as otherwise we
17  * would use the stack upon exit from 'fork()'.
18  *
19  * Actually only pause and fork are needed inline, so that there
20  * won't be any messing with the stack from main(), but we define
21  * some others too.
22  */
    /*
     * 我们需要下面这些内嵌语句 - 从内核空间创建进程将导致没有写时复制(COPY ON WRITE)!!!
     * 直到执行一个 execve 调用。这对堆栈可能带来问题。处理方法是在 fork()调用后不让 main()使用
```

[6] 关于写时复制（Copy on Write）技术的说明请参见第 10 章内存管理，10.2 节。

```
 * 任何堆栈。因此就不能有函数调用 - 这意味着 fork 也要使用内嵌的代码，否则我们在从 fork()退出
 * 时就要使用堆栈了。
 * 实际上只有 pause 和 fork 需要使用内嵌方式，以保证从 main()中不会弄乱堆栈，但是我们同时还
 * 定义了其他一些函数。
 */
// 本程序会在移动到用户模式（切换到任务 0）后才执行 fork()，因此避免了在内核空间写时复制问题。
// 在执行了 moveto_user_mode()之后，本程序就以任务 0 的身份在运行了。而任务 0 是所有将创建的子
// 进程的父进程。当创建第一个子进程时，任务 0 的堆栈也会被复制。因此希望在 main.c 运行在任务 0
// 的环境下时不要有对堆栈的任何操作，以免弄乱堆栈，从而也不会弄乱所有子进程的堆栈。
23 static inline _syscall0(int,fork)
// 这是 unistd.h 中的内嵌宏代码。以嵌入汇编的形式调用 Linux 的系统调用中断 0x80。该中断是所有
// 系统调用的入口。该条语句实际上是 int fork()创建进程系统调用。
// syscall0 名称中最后的 0 表示无参数，1 表示 1 个参数。参见 include/unistd.h，133 行。
24 static inline _syscall0(int,pause)           // int pause()系统调用：暂停进程的执行，直到
                                               // 收到一个信号。
25 static inline _syscall1(int,setup,void *,BIOS)  // int setup(void * BIOS)系统调用，仅用于
                                                   // linux 初始化（仅在这个程序中被调用）。
26 static inline _syscall0(int,sync)               // int sync()系统调用：更新文件系统。
27
28 #include <linux/tty.h>     // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
29 #include <linux/sched.h>   // 调度程序头文件，定义了任务结构 task_struct、第 1 个初始任务
                              // 的数据。还有一些以宏的形式定义的有关描述符参数设置和获取的
                              // 嵌入式汇编函数程序。
30 #include <linux/head.h>    // head 头文件，定义了段描述符的简单结构，和几个选择符常量。
31 #include <asm/system.h>    // 系统头文件。以宏的形式定义了许多有关设置或修改
                              // 描述符/中断门等的嵌入式汇编子程序。
32 #include <asm/io.h>        // io 头文件。以宏的嵌入汇编程序形式定义对 io 端口操作的函数。
33
34 #include <stddef.h>        // 标准定义头文件。定义了 NULL, offsetof(TYPE, MEMBER)。
35 #include <stdarg.h>        // 标准参数头文件。以宏的形式定义变量参数列表。主要说明了-个
                              // 类型(va_list)和三个宏(va_start, va_arg 和 va_end)，vsprintf、
                              // vprintf、vfprintf。
36 #include <unistd.h>
37 #include <fcntl.h>         // 文件控制头文件。用于文件及其描述符的操作控制常数符号的定义。
38 #include <sys/types.h>     // 类型头文件。定义了基本的系统数据类型。
39
40 #include <linux/fs.h>      // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
41
42 static char printbuf[1024];       // 静态字符串数组，用作内核显示信息的缓存。
43
44 extern int vsprintf();            // 送格式化输出到一字符串中（在 kernel/vsprintf.c，92 行）。
45 extern void init(void);           // 函数原形，初始化（在 168 行）。
46 extern void blk_dev_init(void);   // 块设备初始化子程序（kernel/blk_drv/ll_rw_blk.c,157 行）
47 extern void chr_dev_init(void);   // 字符设备初始化（kernel/chr_drv/tty_io.c，347 行）
48 extern void hd_init(void);        // 硬盘初始化程序（kernel/blk_drv/hd.c，343 行）
49 extern void floppy_init(void);    // 软驱初始化程序（kernel/blk_drv/floppy.c，457 行）
50 extern void mem_init(long start, long end);      // 内存管理初始化（mm/memory.c，399 行）
51 extern long rd_init(long mem_start, int length); // 虚拟盘初始化(blk_drv/ramdisk.c,52)
52 extern long kernel_mktime(struct tm * tm);       // 计算系统开机启动时间（秒）。
53 extern long startup_time;                        // 内核启动时间（开机时间）（秒）。
54
55 /*
56  * This is set up by the setup-routine at boot-time
```

```
57  */
    /*
     * 以下这些数据是由 setup.s 程序在引导时间设置的（参见第 3 章中表 3-1）。
     */
58  #define EXT_MEM_K (*(unsigned short *)0x90002)      // 1MB 以后的扩展内存大小（KB）。
59  #define DRIVE_INFO (*(struct drive_info *)0x90080)  // 硬盘参数表基址。
60  #define ORIG_ROOT_DEV (*(unsigned short *)0x901FC)  // 根文件系统所在设备号。
61
62  /*
63   * Yeah, yeah, it's ugly, but I cannot find how to do this correctly
64   * and this seems to work. I anybody has more info on the real-time
65   * clock I'd be interested. Most of this was trial and error, and some
66   * bios-listing reading. Urghh.
67   */
    /*
     * 是啊，是啊，下面这段程序很差劲，但我不知道如何正确地实现，而且好象它还能运行。如果有
     * 关于实时时钟更多的资料，那我很感兴趣。这些都是试探出来的，另外还看了一些 bios 程序，呵！
     */
68
69  #define CMOS_READ(addr) ({ \          // 这段宏读取 CMOS 实时时钟信息。
70  outb_p(0x80|addr,0x70); \             // 0x70 是写端口号，0x80|addr 是要读取的 CMOS 内存地址。
71  inb_p(0x71); \                        // 0x71 是读端口号。
72  })
73
    // 定义宏。将 BCD 码转换成二进制数值。
74  #define BCD_TO_BIN(val) ((val)=((val)&15) + ((val)>>4)*10)
75
    // 该子程序取 CMOS 时钟，并设置开机时间→startup_time(秒)。参见后面 CMOS 内存列表。
76  static void time_init(void)
77  {
78          struct tm time;               // 时间结构 tm 定义在 include/time.h 中。
79
    // CMOS 的访问速度很慢。为了减小时间误差，在读取了下面循环中所有数值后，若此时 CMOS 中秒值
    // 发生了变化，那么就重新读取所有值。这样内核就能把与 CMOS 的时间误差控制在 1 秒之内。
80          do {
81                  time.tm_sec = CMOS_READ(0);       // 当前时间秒值（均是 BCD 码值）。
82                  time.tm_min = CMOS_READ(2);       // 当前分钟值。
83                  time.tm_hour = CMOS_READ(4);      // 当前小时值。
84                  time.tm_mday = CMOS_READ(7);      // 一月中的当天日期。
85                  time.tm_mon = CMOS_READ(8);       // 当前月份（1—12）。
86                  time.tm_year = CMOS_READ(9);      // 当前年份。
87          } while (time.tm_sec != CMOS_READ(0));
88          BCD_TO_BIN(time.tm_sec);                  // 转换成二进制数值。
89          BCD_TO_BIN(time.tm_min);
90          BCD_TO_BIN(time.tm_hour);
91          BCD_TO_BIN(time.tm_mday);
92          BCD_TO_BIN(time.tm_mon);
93          BCD_TO_BIN(time.tm_year);
94          time.tm_mon--;                            // tm_mon 中月份范围是 0—11。
    // 调用 kernel/mktime.c 中函数，计算从 1970 年 1 月 1 日 0 时起到开机当日经过的秒数，作为开机
    // 时间。
95          startup_time = kernel_mktime(&time);
96  }
```

```
 97
 98 static long memory_end = 0;                    // 机器具有的物理内存容量（字节数）。
 99 static long buffer_memory_end = 0;             // 高速缓冲区末端地址。
100 static long main_memory_start = 0;             // 主内存（将用于分页）开始的位置。
101
102 struct drive_info { char dummy[32]; } drive_info; // 用于存放硬盘参数表信息。
103
104 void main(void)         /* This really IS void, no error here. */
105 {                       /* The startup routine assumes (well, ...) this */
                            /* 这里确实是 void，并没错。在 startup 程序(head.s)中就是这样假设的*/
                            // 参见 head.s 程序第 136 行开始的几行代码。
106 /*
107  * Interrupts are still disabled. Do necessary setups, then
108  * enable them
109  */
    /*
     * 此时中断仍被禁止着，做完必要的设置后就将其开启。
     */
     // 下面这段代码用于保存：
     // 根设备号 ➔ROOT_DEV;  高速缓存末端地址➔buffer_memory_end;
     // 机器内存数➔memory_end; 主内存开始地址 ➔main_memory_start;
110         ROOT_DEV = ORIG_ROOT_DEV;               // ROOT_DEV 定义在 fs/super.c,29 行。
111         drive_info = DRIVE_INFO;                // 复制 0x90080 处的硬盘参数表。
112         memory_end = (1<<20) + (EXT_MEM_K<<10); // 内存大小=1Mb 字节+扩展内存(k)*1024 字节。
113         memory_end &= 0xfffff000;               // 忽略不到 4Kb（1 页）的内存数。
114         if (memory_end > 16*1024*1024)          // 如果内存超过 16Mb，则按 16Mb 计。
115                 memory_end = 16*1024*1024;
116         if (memory_end > 12*1024*1024)          // 如果内存>12Mb，则设置缓冲区末端=4Mb
117                 buffer_memory_end = 4*1024*1024;
118         else if (memory_end > 6*1024*1024)      // 否则如果内存>6Mb，则设置缓冲区末端=2Mb
119                 buffer_memory_end = 2*1024*1024;
120         else
121                 buffer_memory_end = 1*1024*1024;// 否则则设置缓冲区末端=1Mb
122         main_memory_start = buffer_memory_end;  // 主内存起始位置=缓冲区末端;
    // 如果定义了内存虚拟盘，则初始化虚拟盘。此时主内存将减少。参见 kernel/blk_drv/ramdisk.c。
123 #ifdef RAMDISK
124         main_memory_start += rd_init(main_memory_start, RAMDISK*1024);
125 #endif
    // 以下是内核进行所有方面的初始化工作。阅读时最好跟着调用的程序深入进去看，若实在看
    // 不下去了，就先放一放，继续看下一个初始化调用 -- 这是经验之谈☺。
126         mem_init(main_memory_start,memory_end);  // 主内存区初始化。（mm/memory.c，399）
127         trap_init();            // 陷阱门（硬件中断向量）初始化。（kernel/traps.c，181）
128         blk_dev_init();         // 块设备初始化。     （kernel/blk_drv/ll_rw_blk.c，157）
129         chr_dev_init();         // 字符设备初始化。   （kernel/chr_drv/tty_io.c，347）
130         tty_init();             // tty 初始化。       （kernel/chr_drv/tty_io.c，105）
131         time_init();            // 设置开机启动时间➔startup_time（见 76 行）。
132         sched_init();           // 调度程序初始化(加载了任务 0 的 tr,ldtr)(kernel/sched.c,385)
133         buffer_init(buffer_memory_end); // 缓冲管理初始化，建内存链表等。（fs/buffer.c，348）
134         hd_init();              // 硬盘初始化。       （kernel/blk_drv/hd.c，343）
135         floppy_init();          // 软驱初始化。       （kernel/blk_drv/floppy.c，457）
136         sti();                  // 所有初始化工作都做完了，开启中断。
    // 下面过程通过在堆栈中设置的参数，利用中断返回指令启动任务 0 执行。
137         move_to_user_mode();  // 移到用户模式下执行。（include/asm/system.h，第 1 行）
```

```
138         if (!fork()) {          /* we count on this going ok */
139                 init();         // 在新建的子进程（任务 1）中执行。
140         }
    // 下面代码开始以任务 0 的身份运行。
141 /*
142  *  NOTE!!  For any other task 'pause()' would mean we have to get a
143  * signal to awaken, but task0 is the sole exception (see 'schedule()')
144  * as task 0 gets activated at every idle moment (when no other tasks
145  * can run). For task0 'pause()' just means we go check if some other
146  * task can run, and if not we return here.
147  */
    /* 注意!! 对于任何其他的任务，'pause()'将意味着我们必须等待收到一个信号才会返
    * 回就绪运行态，但任务 0（task0）是唯一的例外情况（参见'schedule()'），因为任务 0 在
    * 任何空闲时间里都会被激活（当没有其他任务在运行时），因此对于任务 0'pause()'仅意味着
    * 我们返回来查看是否有其他任务可以运行，如果没有的话我们就回到这里，一直循环执行'pause()'。
    */
    // pause()系统调用（kernel/sched.c,144）会把任务 0 转换成可中断等待状态，再执行调度函数。
    // 但是调度函数只要发现系统中没有其他任务可以运行时就会切换到任务 0，而不依赖于任务 0 的
    // 状态。
148         for(;;) pause();
149 }
150
    // 下面函数产生格式化信息并输出到标准输出设备 stdout(1)，这里是指屏幕上显示。参数'*fmt'
    // 指定输出将采用的格式，参见标准 C 语言书籍。该子程序正好是 vsprintf 如何使用的一个例子。
    // 该程序使用 vsprintf()将格式化的字符串放入 printbuf 缓冲区，然后用 write()将缓冲区的内容
    // 输出到标准设备（1--stdout）。vsprintf()函数的实现见 kernel/vsprintf.c。
151 static int printf(const char *fmt, ...)
152 {
153         va_list args;
154         int i;
155
156         va_start(args, fmt);
157         write(1,printbuf,i=vsprintf(printbuf, fmt, args));
158         va_end(args);
159         return i;
160 }
161
162 static char * argv_rc[] = { "/bin/sh", NULL };     // 调用执行程序时参数的字符串数组。
163 static char * envp_rc[] = { "HOME=/", NULL };      // 调用执行程序时的环境字符串数组。
164
165 static char * argv[] = { "-/bin/sh",NULL };        // 同上。
166 static char * envp[] = { "HOME=/usr/root", NULL };
    // 上面 165 行中 argv[0]中的字符“-”是传递给 shell 程序 sh 的一个标志。通过识别该标志，sh
    // 程序会作为登录 shell 执行。其执行过程与在 shell 提示符下执行 sh 不太一样。
167
    // 在 main()中已经进行了系统初始化，包括内存管理、各种硬件设备和驱动程序。init()函数运行在
    // 任务 0 第 1 次创建的子进程（任务 1）中。它首先对第一个将要执行的程序（shell）的环境进行
    // 初始化，然后加载该程序并执行之。
168 void init(void)
169 {
170         int pid,i;
171
    // 这是一个系统调用。用于读取硬盘参数包括分区表信息并加载虚拟盘（若存在的话）和安装根文件
```

```
    // 系统设备。该函数是用 25 行上的宏定义的，对应函数是 sys_setup()，在 kernel/blk_drv/hd.c,71
行。
172         setup((void *) &drive_info);
    // 下面以读写访问方式打开设备“/dev/tty0”，它对应终端控制台。
    // 由于这是第一次打开文件操作，因此产生的文件句柄号（文件描述符）肯定是 0。该句柄是 UNIX 类
    // 操作系统默认的控制台标准输入句柄 stdin。这里把它以读和写的方式打开是为了复制产生标准
    // 输出（写）句柄 stdout 和标准出错输出句柄 stderr。
173         (void) open("/dev/tty0",O_RDWR,0);
174         (void) dup(0);                  // 复制句柄，产生句柄 1 号--stdout 标准输出设备。
175         (void) dup(0);                  // 复制句柄，产生句柄 2 号--stderr 标准出错输出设备。
    // 下面打印缓冲区块数和总字节数，每块 1024 字节，以及主内存区空闲内存字节数。
176         printf("%d buffers = %d bytes buffer space\n\r",NR_BUFFERS,
177                 NR_BUFFERS*BLOCK_SIZE);
178         printf("Free mem: %d bytes\n\r",memory_end-main_memory_start);
    // 下面 fork()用于创建一个子进程(任务 2)。对于被创建的子进程，fork()将返回 0 值，对于原进程
    // (父进程)则返回子进程的进程号 pid。所以 180-184 句是子进程执行的内容。该子进程关闭了句柄
    // 0(stdin)、以只读方式打开/etc/rc 文件，并使用 execve()函数将进程自身替换成/bin/sh 程序
    // (即 shell 程序)，然后执行/bin/sh 程序。所带参数和环境变量分别由 argv_rc 和 envp_rc 数组
    // 给出。关于 execve()请参见 fs/exec.c 程序，182 行。
    // 函数_exit()退出时的出错码 1 - 操作未许可；2 -- 文件或目录不存在。
179         if (!(pid=fork())) {
180                 close(0);
181                 if (open("/etc/rc",O_RDONLY,0))
182                         _exit(1);               // 如果打开文件失败，则退出(lib/_exit.c,10)。
183                 execve("/bin/sh",argv_rc,envp_rc);      // 替换成/bin/sh 程序并执行。
184                 _exit(2);                               // 若 execve()执行失败则退出。
185         }
    // 下面还是父进程(1)执行的语句。wait()等待子进程停止或终止，返回值应是子进程的进程号(pid)。
    // 这三句的作用是父进程等待子进程的结束。&i 是存放返回状态信息的位置。如果 wait()返回值不
    // 等于子进程号，则继续等待。
186         if (pid>0)
187                 while (pid != wait(&i))
188                         /* nothing */;    /* 空循环 */
    // 如果执行到这里，说明刚创建的子进程的执行已停止或终止了。下面循环中首先再创建一个子进程，
    // 如果出错，则显示“初始化程序创建子进程失败”信息并继续执行。对于所创建的子进程将关闭所
    // 有以前还遗留的句柄(stdin, stdout, stderr)，新创建一个会话并设置进程组号，然后重新打开
    // /dev/tty0 作为 stdin，并复制成 stdout 和 stderr。再次执行系统解释程序/bin/sh。但这次执行所
    // 选用的参数和环境数组另选了一套（见上面 165-167 行）。然后父进程再次运行 wait()等待。如果
    // 子进程又停止了执行，则在标准输出上显示出错信息“子进程 pid 停止了运行，返回码是 i”，然后
    // 继续重试下去…，形成“大”死循环。
189         while (1) {
190                 if ((pid=fork())<0) {
191                         printf("Fork failed in init\r\n");
192                         continue;
193                 }
194                 if (!pid) {                             // 新的子进程。
195                         close(0);close(1);close(2);
196                         setsid();                       // 创建一新的会话期，见后面说明。
197                         (void) open("/dev/tty0",O_RDWR,0);
198                         (void) dup(0);
199                         (void) dup(0);
200                         _exit(execve("/bin/sh",argv,envp));
201                 }
```

```
202                 while (1)
203                         if (pid == wait(&i))
204                                 break;
205                 printf("\n\rchild %d died with code %04x\n\r",pid,i);
206                 sync();                                         // 同步操作，刷新缓冲区。
207         }
208         _exit(0);       /* NOTE! _exit, not exit() */    /* 注意！是_exit()，不是 exit() */
    // _exit()和 exit()都用于正常终止一个函数。但_exit()直接是一个 sys_exit 系统调用，而 exit()则
    // 通常是普通函数库中的一个函数。它会先执行一些清除操作，例如调用执行各终止处理程序、关闭所
    // 有标准 IO 等，然后调用 sys_exit。
209 }
210
```

4.2.3 其他信息

4.2.3.1 CMOS 信息

PC 机的 CMOS（complementary metal oxide semiconductor，互补金属氧化物半导体）内存实际上是由电池供电的 64 或 128 字节 RAM 内存块，是系统时钟芯片的一部分。有些机器还有更大的内存容量。

该 64 字节的 CMOS 原先在 IBM PC-XT 机器上用于保存时钟和日期信息，存放的格式是 BCD 码。由于这些信息仅用去 14 字节，剩余的字节就用来存放一些系统配置数据了。

CMOS 的地址空间是在基本地址空间之外的。因此其中不包括可执行的代码。它需要使用在端口 70h,71h 使用 IN 和 OUT 指令来访问。为了读取指定偏移位置的字节，首先需要使用 OUT 向端口 70h 发送指定字节的偏移值，然后使用 IN 指令从 71h 端口读取指定的字节信息。

这段程序中（行 70）把欲读取的字节地址与 80h 进行或操作是没有必要的。因为那时的 CMOS 内存容量还没有超过 128 字节，因此与 80h 进行或操作是没有任何作用的。之所以会有这样的操作是因为当时 Linus 手头缺乏有关 CMOS 方面的资料，CMOS 中时钟和日期的偏移地址都是他逐步实验出来的，也许在他实验中将偏移地址与 80h 进行或操作（并且还修改了其他地方）后正好取得了所有正确的结果，因此他的代码中也就有了这步不必要的操作。不过从 1.0 版本之后，该操作就被去除了(可参见 1.0 版内核程序 drivers/block/hd.c 第 42 行起的代码)。表 4–1 是 CMOS 内存信息的一张简表。

表 4－1 CMOS 64 字节信息简表

地址偏移值	内容说明	地址偏移值	内容说明
0x00	当前秒值 (实时钟)	0x11	保留
0x01	报警秒值	0x12	硬盘驱动器类型
0x02	当前分钟 (实时钟)	0x13	保留
0x03	报警分钟值	0x14	设备字节
0x04	当前小时值 (实时钟)	0x15	基本内存 (低字节)
0x05	报警小时值	0x16	基本内存 (高字节)
0x06	一周中的当前天 (实时钟)	0x17	扩展内存 (低字节)
0x07	一月中的当日日期 (实时钟)	0x18	扩展内存 (高字节)
0x08	当前月份 (实时钟)	0x19-0x2d	保留
0x09	当前年份 (实时钟)	0x2e	校验和 (低字节)
0x0a	RTC 状态寄存器 A	0x2f	校验和 (高字节)
0x0b	RTC 状态寄存器 B	0x30	1Mb 以上的扩展内存 (低字节)
0x0c	RTC 状态寄存器 C	0x31	1Mb 以上的扩展内存 (高字节)
0x0d	RTC 状态寄存器 D	0x32	当前所处世纪值

0x0e	POST 诊断状态字节	0x33	信息标志
0x0f	停机状态字节	0x34-0x3f	保留
0x10	磁盘驱动器类型		

4.2.3.2 调用 fork()创建新进程

fork 是一个系统调用函数。该系统调用复制当前进程，并在进程表中创建一个与原进程(被称为父进程）几乎完全一样的新表项，并执行同样的代码，但该新进程（这里被称为子进程）拥有自己的数据空间和环境参数。

在父进程中，调用 fork()返回的是子进程的进程标识号 PID，而在子进程中 fork()返回的将是 0 值，这样，虽然此时还是在同样一程序中执行，但已开始叉开，各自执行自己的那段代码。如果 fork()调用失败，则会返回小于 0 的值。如示意图 4-3 所示。

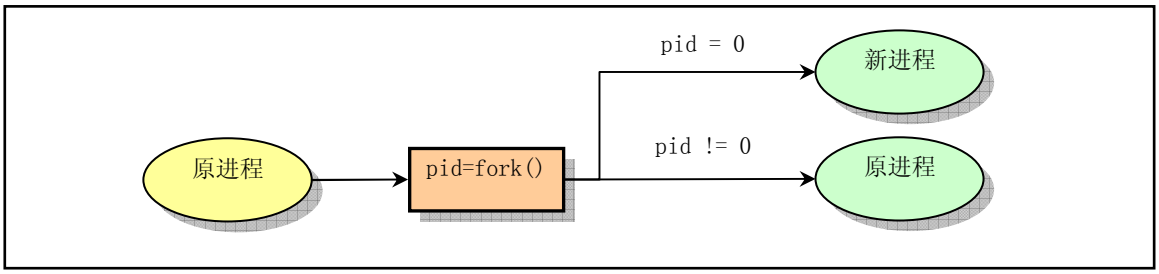

图 4-3 调用 fork()创建新进程

init 程序即是用 fork()调用的返回值来区分和执行不同的代码段的。上面代码中第 179 和 194 行是子进程的判断并开始子进程代码块的执行（利用 execve()系统调用执行其他程序，这里执行的是 sh），第 186 和 202 行是父进程执行的代码块。

4.2.3.3 关于会话期(session)的概念

在第 2 章我们说过，程序是一个可执行的文件，而进程（process）是一个执行中的程序实例。在内核中，每个进程都使用一个不同的大于零的正整数来标识，称为进程标识号 pid(Porcess ID)。而一个进程可以通过 fork()调用创建一个或多个子进程，这些进程就可以构成一个进程组。例如，对于下面在 shell 命令行上键入的一个管道命令，

```
[plinux root]# cat main.c | grep for | more
```

其中的每个命令：cat、grep 和 more 就都属于一个进程组。

进程组是一个或多个进程的集合。与进程类似，每个进程组都有一个唯一的进程组标识号 gid（Group ID）。进程组 gid 也是一个正整数。每一个进程组有一个称为组长的进程，组长进程就是其进程号 pid 等于进程组 gid 的进程。一个进程可以通过调用 setpgid()来参加一个现有的进程组或者创建一个新的进程组。进程组的概念有很多用途，但其中最常见的是我们在终端上向前台执行程序发出终止信号（通常是按 Ctrl-C 组合键），同时终止整个进程组中的所有进程。例如，如果我们向上述管道命令发出终止信号，则三个命令将同时终止执行。

而会话期（Session，或称为会话）则是一个或多个进程组的集合。通常情况下，用户登录后所执行的所有程序都属于一个会话期，而其登录 shell 则是会话期首进程（Session leader）。当我们退出登录（logout）时，所有属于我们这个会话期的进程都将被终止。这也是会话期概念的主要用途之一。setsid()函数就是用于建立一个新的会话期。通常该函数由环境初始化程序进行调用，见下节说明。进程、进程组和会话期之间的关系见图 4-4 所示。

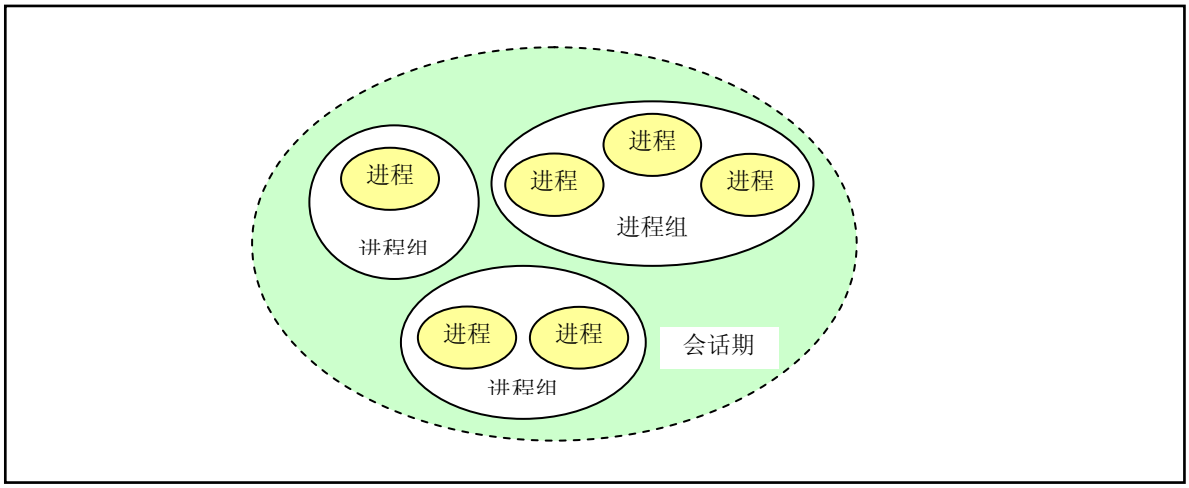

图 4-4 进程、进程组和会话期之间的关系

4.3 环境初始化工作

在内核系统初始化完毕之后，系统还需要根据具体配置执行进一步的环境初始化工作，才能真正具备一个常用系统所具备的一些工作环境。在前面的第 183 行和 200 行上，init()函数直接开始执行了命令解释程序（shell 程序）/bin/sh，而在实际可用的系统中却并非如此。为了能具有登录系统的处理和多人同时使用系统的能力，通常的系统是在这里或类似地方，执行系统环境初始化程序 init.c，而此程序会根据系统/etc/目录中配置文件的设置信息，对系统中支持的每个终端设备创建子进程，并在子进程中运行终端初始化设置程序 agetty（统称 getty 程序），getty 程序则会在终端上显示用户登录提示信息“login:”。当用户键入了用户名后，getty 替换去执行 login 程序。login 程序在验证了用户输入口令的正确性以后，最终调用 shell 程序，并进入 shell 交互工作界面。它们之间的执行关系见图 4-5 所示。

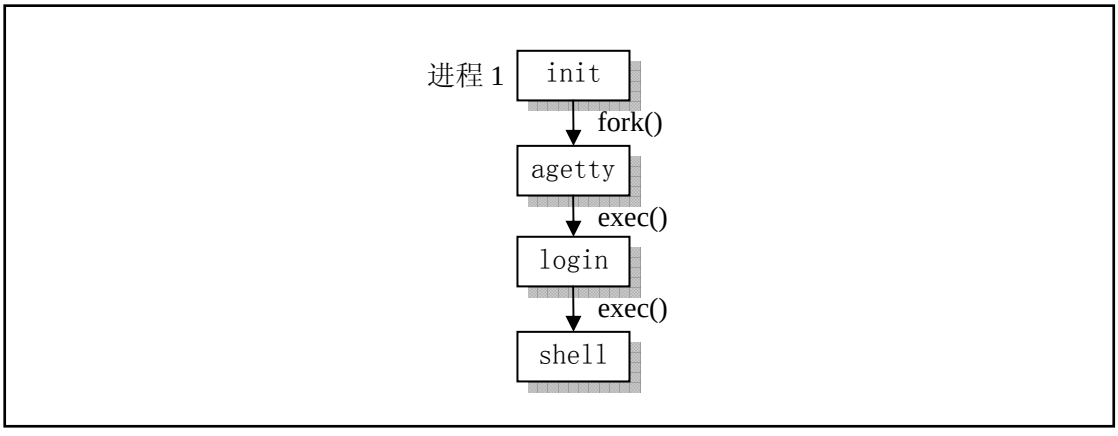

图 4-5 有关环境初始化的程序

虽然这几个程序（init, getty, login, shell）并不属于内核范畴，但对这几个程序的作用有一些基本了解会促进对内核为什么提供那么多功能的理解。

init 进程的主要任务是根据/etc/rc 文件中设置的信息，执行其中设置的命令，然后根据/etc/inittab 文件中的信息，为每一个允许登录的终端设备使用 fork()创建一个子进程，并在每个新创建的子进程中运

行 agetty[7]（getty）程序。而 init 进程则调用 wait()，进入等待子进程结束状态。每当它的一个子进程结束退出，它就会根据 wait()返回的 pid 号知道是哪个对应终端的子进程结束了，因此就会为相应终端设备再创建一个新的子进程，并在该子进程中重新执行 agetty 程序。这样，每个被允许的终端设备都始终有一个对应的进程为其等待处理。

在正常操作下，init 确定 agetty 正在工作着以允许用户登录，并且收取孤立进程。孤立进程是指那些其父辈进程已结束的进程；在 Linux 中所有的进程必须属于单棵进程树，所以孤立进程必须被收取。当系统关闭时，init 负责杀死所有其他的进程，卸载所有的文件系统以及停止处理器的工作，以及任何它被配置成要做的工作。

getty 程序的主要任务是设置终端类型、属性、速度和线路规程。它打开并初始化一个 tty 端口，显示提示信息，并等待用户键入用户名。该程序只能由超级用户执行。通常，若/etc/issue 文本文件存在，则 getty 会首先显示其中的文本信息，然后显示登录提示信息（例如：plinux login: ），读取用户键入的登录名，并执行 login 程序。

login 程序则主要用于要求登录用户输入密码。根据用户输入的用户名，它从口令文件 passwd 中取得对应用户的登录项，然后调用 getpass()以显示”password:”提示信息，读取用户键入的密码，然后使用加密算法对键入的密码进行加密处理，并与口令文件中该用户项中 pw_passwd 字段作比较。如果用户几次键入的密码均无效，则 login 程序会以出错码 1 退出执行，表示此次登录过程失败。此时父进程（进程 init）的 wait()会返回该退出进程的 pid，因此会根据记录下来的信息再次创建一个子进程，并在该子进程中针对该终端设备再次执行 agetty 程序，重复上述过程。

如果用户键入的密码正确，则 login 就会把当前工作目录（Current Work Directory）修改成口令文件中指定的该用户的起始工作目录。并把对该终端设备的访问权限修改成用户读/写和组写，设置进程的组 ID。然后利用所得到的信息初始化环境变量信息，例如起始目录（HOME=）、使用的 shell 程序（SHELL=）、用户名（USER=和 LOGNAME=）和系统执行程序的默认路径序列（PATH=）。接着显示/etc/motd 文件（message-of-the-day）中的文本信息，并检查并显示该用户是否有邮件的信息。最后 login 程序改变成登录用户的用户 ID 并执行口令文件中该用户项中指定的 shell 程序，如 bash 或 csh 等。

如果口令文件/etc/passwd 中该用户项中没有指定使用哪个 shell 程序，系统则会使用默认的/bin/sh 程序。如果口令文件中也没有为该用户指定用户起始目录的话，系统就会使用默认的根目录/。有关 login 程序的一些执行选项和特殊访问限制的说明，请参见 Linux 系统中的在线手册页（man 8 login）。

shell 程序是一个复杂的命令行解释程序，是当用户登录系统进行交互操作时执行的程序。它是用户与计算机进行交互操作的地方。它获取用户输入的信息，然后执行命令。用户可以在终端上向 shell 直接进行交互输入，也可以使用 shell 脚本文件向 shell 解释程序输入。

在登录过程中 login 开始执行 shell 时，所带参数 argv[0]的第一个字符是’-’，表示该 shell 是作为一个登录 shell 被执行。此时该 shell 程序会根据该字符，执行某些与登录过程相应的操作。登录 shell 会首先从/etc/profile 文件以及.profile 文件（若存在的话）读取命令并执行。如果在进入 shell 时设置了 ENV 环境变量，或者在登录 shell 的.profile 文件中设置了该变量，则 shell 下一步会从该变量命名的文件中读去命令并执行。因此用户应该把每次登录时都要执行的命令放在.profile 文件中，而把每次运行 shell 都要执行的命令放在 ENV 变量指定的文件中。设置 ENV 环境变量的方法是把下列语句放在你起始目录的.profile 文件中。

4.4 本章小结

对于 0.11 版内核，通过上面代码分析可知，只要根文件系统是一个 MINIX 文件系统，并且其中只要包含文件/etc/rc、/bin/sh、/dev/* 以及一些目录/etc/、/dev/、/bin/、/home/、/home/root/ 就可以构成一

[7] agetty - alternative Linux getty。

个最简单的根文件系统，让 Linux 运行起来。

从这里开始，对于后续章节的阅读，可以将 main.c 程序作为一条主线进行，并不需要按章节顺序阅读。若读者对内存分页管理机制不了解，则建议首先阅读第 10 章内存管理的内容。

为了能比较顺利地理解以下各章内容，作者强力希望读者此时能再次复习 32 位保护模式运行的机制，详细阅读一下附录中所提供的有关内容，或者参考 Intel 80x86 的有关书籍，把保护模式下的运行机制彻底弄清楚，然后再继续阅读。

如果您按章节顺序顺利地阅读到这里，那么您对 Linux 系统内核的初始化过程应该已经有了大致的了解。但您可能还会提出这样的问题：“在生成了一系列进程之后，系统是如何分时运行这些进程或者说如何调度这些进程运行的呢？也即‘轮子’是怎样转起来的呢？”。答案并不复杂：内核是通过执行 sched.c 程序中的调度函数 schedule()和 system_call.s 中的定时时钟中断过程_timer_interrupt 来操作的。内核设定每 10 毫秒发出一次时钟中断，并在该中断过程中，通过调用 do_timer()函数检查所有进程的当前执行情况来确定进程的下一步状态。

对于进程在执行过程中由于想用的资源暂时缺乏而临时需要等待一会时，它就会在系统调用中通过 sleep_on()类函数间接地调用 schedule()函数，将 CPU 的使用权自愿地移交给别的进程使用。至于系统接下来会运行哪个进程，则完全由 schedule()根据所有进程的当前状态和优先权决定。对于一直在可运行状态的进程，当时钟中断过程判断出它运行的时间片已被用完时，就会在 do_timer()中执行进程切换操作，该进程的 CPU 使用权就会被不情愿地剥夺，让给别的进程使用。

调度函数 schedule()和时钟中断过程即是下一章中的主题之一。

第5章 内核代码(kernel)

5.1 概述

linux/kernel/目录下共包括 10 个 C 语言文件和 2 个汇编语言文件以及一个 kernel 下编译文件的管理配置文件 Makefile。见列表 5-1 所示。对其中三个子目录中代码的注释将在后续章节中进行。本章主要对这 13 个代码文件进行注释。首先我们对所有程序的基本功能进行概括性的总体介绍，以便一开始就对这 12 个文件所实现的功能和它们之间的相互调用关系有个大致的了解，然后逐一对代码进行详细注释。

列表 5-1 linux/kernel/目录

	文件名	大小	最后修改时间(GMT)	说明
	blk_drv/		1991-12-08 14:09:29	
	chr_drv/		1991-12-08 18:36:09	
	math/		1991-12-08 14:09:58	
	Makefile	3309 bytes	1991-12-02 03:21:37	m
	asm.s	2335 bytes	1991-11-18 00:30:28	m
	exit.c	4175 bytes	1991-12-07 15:47:55	m
	fork.c	3693 bytes	1991-11-25 15:11:09	m
	mktime.c	1461 bytes	1991-10-02 14:16:29	m
	panic.c	448 bytes	1991-10-17 14:22:02	m
	printk.c	734 bytes	1991-10-02 14:16:29	m
	sched.c	8242 bytes	1991-12-04 19:55:28	m
	signal.c	2651 bytes	1991-12-07 15:47:55	m
	sys.c	3706 bytes	1991-11-25 19:31:13	m
	system_call.s	5265 bytes	1991-12-04 13:56:34	m
	traps.c	4951 bytes	1991-10-30 20:20:40	m
	vsprintf.c	4800 bytes	1991-10-02 14:16:29	m

5.2 总体功能描述

该目录下的代码文件从功能上可以分为三类，一类是硬件（异常）中断处理程序文件，一类是系统调用服务处理程序文件，另一类是进程调度等通用功能文件，参见图 5-1 图 2-17。我们现在根据这个分类方式，从实现的功能上进行更详细的说明。

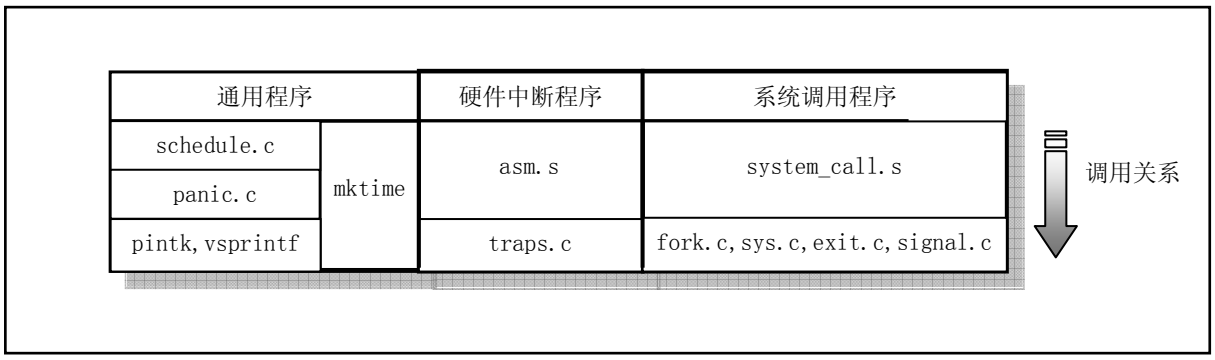

图 5-1 内核目录中各文件中函数的调用层次关系

5.2.1 中断处理程序

主要包括两个代码文件：asm.s 和 traps.c 文件。asm.s 用于实现大部分硬件异常所引起的中断的汇编语言处理过程。而 traps.c 程序则实现了 asm.s 的中断处理过程中调用的 c 函数。另外几个硬件中断处理程序在文件 system_call.s 和 mm/page.s 中实现。有关 PC 机中 8259A 可编程中断控制芯片的连接及其功能请参见图 2-5。

在用户程序（进程）将控制权交给中断处理程序之前，CPU 会首先将至少 12 字节的信息压入中断处理程序的堆栈中。这种情况与一个长调用（段间子程序调用）比较相像。CPU 会将代码段选择符和返回地址的偏移值压入堆栈。另一个与段间调用比较相象的地方是 80386 将信息压入到了目的代码的堆栈上，而不是被中断代码的堆栈。因此当发生中断时，使用的是目的代码的内核态堆栈。另外，CPU 还总是将标志寄存器 EFLAGS 的内容压入堆栈。如果优先级别发生了变化，例如从用户级改变到内核系统级，CPU 还会将原代码的堆栈段值和堆栈指针压入中断程序的堆栈中。对于具有优先级改变时堆栈的内容示意图见图 5-2 所示。

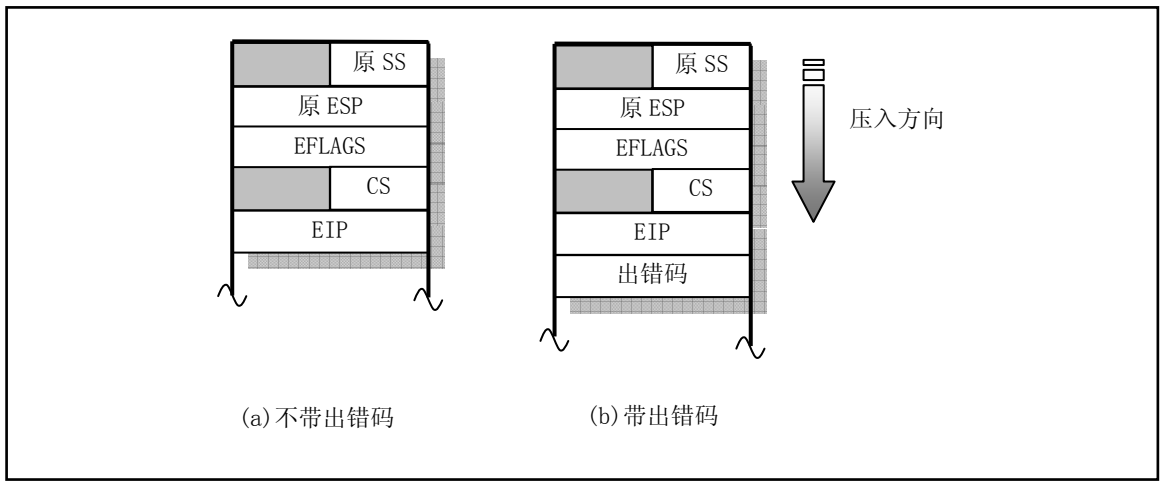

图 5-2 发生中断时堆栈中的内容

asm.s 代码文件主要涉及对 Intel 保留中断 int0--int16 的处理，其余保留的中断 int17-int31 由 Intel 公司留作今后扩充使用。对应于中断控制器芯片各 IRQ 发出的 int32-int47 的 16 个处理程序将分别在各种硬件（如时钟、键盘、软盘、数学协处理器、硬盘等）初始化程序中处理。Linux 系统调用中断 int128(0x80)的处理则将在 kernel/system_call.s 中给出。各个中断的具体定义见代码注释后其他信息一节中的说明。

由于有些异常引起中断时，CPU 内部会产生一个出错代码压入堆栈（异常中断 int 8 和 int10 - int 14），

见图 5-2 (b)所示，而其他的中断却并不带有这个出错代码（例如被零除出错和边界检查出错等），因此，asm.s 程序中将所有中断的处理根据是否携带出错代码而分别进行处理。但处理流程还是一样的。

对一个硬件异常所引起的中断的处理过程见图 5-3 所示。

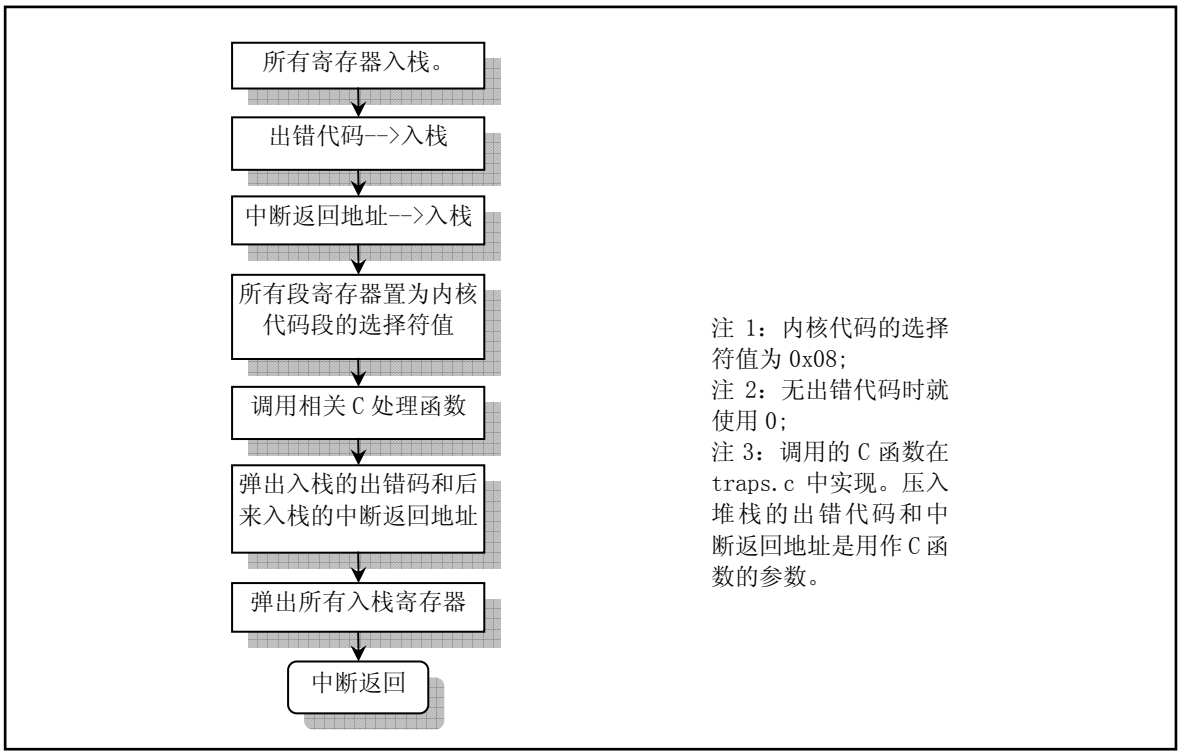

图 5-3 硬件异常（故障、陷阱）所引起的中断处理流程

5.2.2 系统调用处理相关程序

Linux 中应用程序调用内核的功能是通过中断调用 int 0x80 进行的，寄存器 eax 中放调用号，如果需要带参数，则 ebx、ecx 和 edx 用于存放调用参数。因此该中断调用被称为系统调用。实现系统调用的相关文件包括 system_call.s、fork.c、signal.c、sys.c 和 exit.c 文件。

system_call.s 程序的作用类似于硬件中断处理中的 asm.s 程序的作用，另外还对时钟中断和硬盘、软盘中断进行处理。而 fork.c 和 signal.c 中的一个函数则类似于 traps.c 程序的作用，为系统中断调用提供 C 处理函数。fork.c 程序提供两个 C 处理函数：find_empty_process()和 copy_process()。signal.c 程序还提供一个处理有关进程信号的函数 do_signal()，在系统调用中断处理过程中被调用。另外还包括 4 个系统调用 sys_xxx()函数。

sys.c 和 exit.c 程序实现了其他一些 sys_xxx()系统调用函数。这些 sys_xxx()函数都是相应系统调用所需调用的处理函数，有些是使用汇编语言实现的，如 sys_execve()；而另外一些则用 C 语言实现（例如 signal.c 中的 4 个系统调用函数）。

我们可以根据这些函数的简单命名规则这样来理解：通常以'do_'开头的中断处理过程中调用的 C 函数，要么是系统调用处理过程中通用的函数，要么是某个系统调用专用的；而以'sys_'开头的系统调用函数则是指定的系统调用的专用处理函数。例如，do_signal()函数基本上是所有系统调用都要执行的函数，而 sys_pause()、sys_execve()则是某个系统调用专用的 C 处理函数。

5.2.3 其他通用类程序

这些程序包括 schedule.c、mktime.c、panic.c、printk.c 和 vsprintf.c。

schedule.c 程序包括内核调用最频繁的 schedule()、sleep_on()和 wakeup()函数，是内核的核心调度程序，用于对进程的执行进行切换或改变进程的执行状态。另外还包括有关系统时钟中断和软盘驱动器定时的函数。mktime.c 程序中仅包含一个内核使用的时间函数 mktime()，仅在 init/main.c 中被调用一次。panic.c 中包含一个 panic()函数，用于在内核运行出现错误时显示出错信息并停机。printk.c 和 vsprintf.c 是内核显示信息的支持程序，实现了内核专用显示函数 printk()和字符串格式化输出函数 vsprintf()。

5.3 Makefile 文件

5.3.1 功能简介

编译 linux/kernel/下程序的 make 配置文件，不包括三个子目录。该文件的组成格式与第 2 章中列出的 Makefile 的基本相同，在阅读时可以参考程序 2-1 中的有关注释。

5.3.2 文件注释

程序 5-1 linux/kernel/Makefile

```
#
# Makefile for the FREAX-kernel.
#
# Note! Dependencies are done automagically by 'make dep', which also
# removes any old dependencies. DON'T put your own dependencies here
# unless it's something special (ie not a .c file).
#
# FREAX 内核的 Makefile 文件。
#
# 注意！依赖关系是由'make dep'自动进行的，它也会自动去除原来的依赖信息。不要把你自己的
# 依赖关系信息放在这里，除非是特别文件的（也即不是一个.c 文件的信息）。
# (Linux 最初的名字叫 FREAX，后来被 ftp.funet.fi 的管理员改成 Linux 这个名字)

AR      =gar    # GNU 的二进制文件处理程序，用于创建、修改以及从归档文件中抽取文件。
AS      =gas    # GNU 的汇编程序。
LD      =gld    # GNU 的连接程序。
LDFLAGS =-s -x  # 连接程序所有的参数，-s 输出文件中省略所有符号信息。-x 删除所有局部符号。
CC      =gcc    # GNU C 语言编译器。
CFLAGS  =-Wall -O -fstrength-reduce -fomit-frame-pointer -fcombine-regs \
        -finline-functions -mstring-insns -nostdinc -I../include
# C 编译程序选项。-Wall 显示所有的警告信息；-O 优化选项，优化代码长度和执行时间；
# -fstrength-reduce 优化循环执行代码，排除重复变量；-fomit-frame-pointer 省略保存不必要
# 的框架指针；-fcombine-regs 合并寄存器，减少寄存器类的使用；-finline-functions 将所有简
# 单短小的函数代码嵌入调用程序中；-mstring-insns Linus 自己填加的优化选项，以后不再使用；
# -nostdinc -I../include 不使用默认路径中的包含文件，而使用这里指定目录中的(../include)。
CPP     =gcc -E -nostdinc -I../include
# C 前处理选项。-E 只运行 C 前处理，对所有指定的 C 程序进行预处理并将处理结果输出到标准输
# 出设备或指定的输出文件中；-nostdinc -I../include 同前。

# 下面的规则指示 make 利用下面的命令将所有的.c 文件编译生成.s 汇编程序。该规则的命令
# 指使 gcc 采用 CFLAGS 所指定的选项对 C 代码编译后不进行汇编就停止（-S），从而产生与
# 输入的各个 C 文件对应的汇编代码文件。默认情况下所产生的汇编程序文件名是原 C 文件名
# 去掉.c 而加上.s 后缀。-o 表示其后是输出文件的名称。其中$*.s（或$@）是自动目标变量，
```

```
    # $<代表第一个先决条件，这里即是符合条件*.c 的文件。
18  .c.s:
19          $(CC) $(CFLAGS) \
20          -S -o $*.s $<
    # 下面规则表示将所有.s 汇编程序文件编译成.o 目标文件。22 行是实现该操作的具体命令。
21  .s.o:
22          $(AS) -c -o $*.o $<
23  .c.o:                       # 类似上面，*.c 文件-→*.o 目标文件。不进行连接。
24          $(CC) $(CFLAGS) \
25          -c -o $*.o $<
26
27  OBJS  = sched.o system_call.o traps.o asm.o fork.o \    # 定义目标文件变量 OBJS。
28          panic.o printk.o vsprintf.o sys.o exit.o \
29          signal.o mktime.o
30
31  kernel.o: $(OBJS)           # 在有了先决条件 OBJS 后使用下面的命令连接成目标 kernel.o
32          $(LD) -r -o kernel.o $(OBJS)
33          sync
34
    # 下面的规则用于清理工作。当执行'make clean'时，就会执行 36--40 行上的命令，去除所有编译
    # 连接生成的文件。'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
35  clean:
36          rm -f core *.o *.a tmp_make keyboard.s
37          for i in *.c;do rm -f `basename $$i .c`.s;done
38          (cd chr_drv; make clean)    # 进入 chr_drv/目录；执行该目录 Makefile 中的 clean 规则。
39          (cd blk_drv; make clean)
40          (cd math; make clean)
41
    # 下面的目标或规则用于检查各文件之间的依赖关系。方法如下：
    # 使用字符串编辑程序 sed 对 Makefile 文件（这里即是自己）进行处理，输出为删除 Makefile
    # 文件中'### Dependencies'行后面的所有行（下面从 51 开始的行），并生成 tmp_make
    # 临时文件（43 行的作用）。然后对 kernel/目录下的每一个 C 文件执行 gcc 预处理操作.
    # -M 标志告诉预处理程序输出描述每个目标文件相关性的规则，并且这些规则符合 make 语法。
    # 对于每一个源文件，预处理程序输出一个 make 规则，其结果形式是相应源程序文件的目标
    # 文件名加上其依赖关系--该源文件中包含的所有头文件列表。把预处理结果都添加到临时
    # 文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。
42  dep:
43          sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
44          (for i in *.c;do echo -n `echo $$i | sed 's,\.c,\.s,'`" "; \
45                  $(CPP) -M $$i;done) >> tmp_make
46          cp tmp_make Makefile
47          (cd chr_drv; make dep)     # 对 chr_drv/目录下的 Makefile 文件也作同样的处理。
48          (cd blk_drv; make dep)
49
50  ### Dependencies:
51  exit.s exit.o : exit.c ../include/errno.h ../include/signal.h \
52    ../include/sys/types.h ../include/sys/wait.h ../include/linux/sched.h \
53    ../include/linux/head.h ../include/linux/fs.h ../include/linux/mm.h \
54    ../include/linux/kernel.h ../include/linux/tty.h ../include/termios.h \
55    ../include/asm/segment.h
56  fork.s fork.o : fork.c ../include/errno.h ../include/linux/sched.h \
57    ../include/linux/head.h ../include/linux/fs.h ../include/sys/types.h \
58    ../include/linux/mm.h ../include/signal.h ../include/linux/kernel.h \
```

```
59   ../include/asm/segment.h ../include/asm/system.h
60 mktime.s mktime.o : mktime.c ../include/time.h
61 panic.s panic.o : panic.c ../include/linux/kernel.h ../include/linux/sched.h \
62   ../include/linux/head.h ../include/linux/fs.h ../include/sys/types.h \
63   ../include/linux/mm.h ../include/signal.h
64 printk.s printk.o : printk.c ../include/stdarg.h ../include/stddef.h \
65   ../include/linux/kernel.h
66 sched.s sched.o : sched.c ../include/linux/sched.h ../include/linux/head.h \
67   ../include/linux/fs.h ../include/sys/types.h ../include/linux/mm.h \
68   ../include/signal.h ../include/linux/kernel.h ../include/linux/sys.h \
69   ../include/linux/fdreg.h ../include/asm/system.h ../include/asm/io.h \
70   ../include/asm/segment.h
71 signal.s signal.o : signal.c ../include/linux/sched.h ../include/linux/head.h \
72   ../include/linux/fs.h ../include/sys/types.h ../include/linux/mm.h \
73   ../include/signal.h ../include/linux/kernel.h ../include/asm/segment.h
74 sys.s sys.o : sys.c ../include/errno.h ../include/linux/sched.h \
75   ../include/linux/head.h ../include/linux/fs.h ../include/sys/types.h \
76   ../include/linux/mm.h ../include/signal.h ../include/linux/tty.h \
77   ../include/termios.h ../include/linux/kernel.h ../include/asm/segment.h \
78   ../include/sys/times.h ../include/sys/utsname.h
79 traps.s traps.o : traps.c ../include/string.h ../include/linux/head.h \
80   ../include/linux/sched.h ../include/linux/fs.h ../include/sys/types.h \
81   ../include/linux/mm.h ../include/signal.h ../include/linux/kernel.h \
82   ../include/asm/system.h ../include/asm/segment.h ../include/asm/io.h
83 vsprintf.s vsprintf.o : vsprintf.c ../include/stdarg.h ../include/string.h
```

5.4 asm.s 程序

5.4.1 功能描述

asm.s 汇编程序中包括大部分 CPU 探测到的异常故障处理的底层代码，也包括数学协处理器（FPU）的异常处理。该程序与 kernel/traps.c 程序有着密切的关系。该程序的主要处理方式是在中断处理程序中调用相应的 C 函数程序，显示出错位置和出错号，然后退出中断。

在阅读这段代码时参照图 5-4 中堆栈变化示意图将是很有帮助的，图中每个行代表 4 个字节。在开始执行程序之前，堆栈指针 esp 指在中断返回地址一栏(图中 esp0 处)。当把将要调用的 C 函数 do_divide_error()或其他 C 函数地址入栈后，指针位置是 esp1 处,此时通过交换指令，该函数的地址被放入 eax 寄存器中，而原来 eax 的值被保存到堆栈上。在把一些寄存器入栈后，堆栈指针位置在 esp2 处。当正式调用 do_divide_error()之前，程序将开始执行时的 esp0 堆栈指针值压入堆栈，放到了 esp3 处，并在中断返回弹出入栈的寄存器之前指针通过加上 8 又回到 esp2 处。

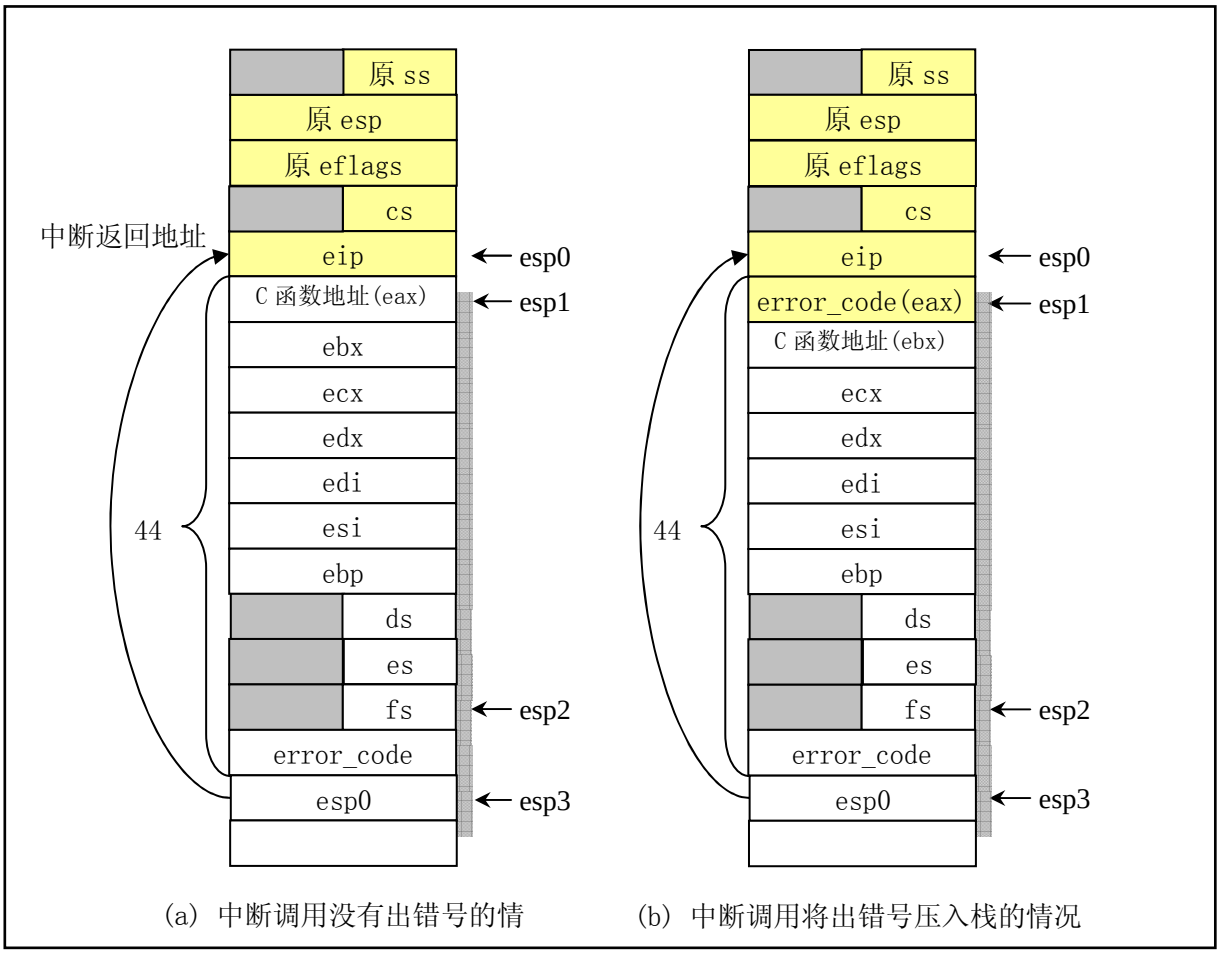

图 5-4 出错处理堆栈变化示意图

正式调用 do_divide_error()之前把出错代码以及 esp0 入栈的原因是为了把出错代码和 esp0 作为调用 C 函数 do_divide_error()的参数。在 traps.c 中，该函数的原形为：

void do_divide_error(long esp, long error_code)。

因此在这个 C 函数中就可以打印出出错的位置和错误号。程序中其余异常出错的处理过程与这里描述的过程基本类似。

5.4.2 代码注释

程序 5-2 linux/kernel/asm.s

```
 1 /*
 2  *  linux/kernel/asm.s
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * asm.s contains the low-level code for most hardware faults.
 9  * page_exception is handled by the mm, so that isn't here. This
10  * file also handles (hopefully) fpu-exceptions due to TS-bit, as
```

```
11  * the fpu must be properly saved/resored. This hasn't been tested.
12  */
    /*
     * asm.s 程序中包括大部分的硬件故障（或出错）处理的底层次代码。页异常是由内存管理程序
     * mm 处理的，所以不在这里。此程序还处理（希望是这样）由于 TS-位而造成的 fpu 异常，
     * 因为 fpu 必须正确地进行保存/恢复处理，这些还没有测试过。
     */
13
     # 本代码文件主要涉及对 Intel 保留中断 int0--int16 的处理（int17-int31 留作今后使用）。
     # 以下是一些全局函数名的声明，其原形在 traps.c 中说明。
14  .globl _divide_error,_debug,_nmi,_int3,_overflow,_bounds,_invalid_op
15  .globl _double_fault,_coprocessor_segment_overrun
16  .globl _invalid_TSS,_segment_not_present,_stack_segment
17  .globl _general_protection,_coprocessor_error,_irq13,_reserved
18
    # 下面这段程序处理无出错号的情况。参见图 5-4(a)。
    # int0 -- 处理被零除出错的情况。
    # 标号'_do_divide_error'实际上是 C 语言函数 do_divide_error()编译后所生成模块中对应的名称。
    # 'do_divide_error'在 traps.c 中实现（第 97 行开始）。
19  _divide_error:
20          pushl $_do_divide_error # 首先把将要调用的函数地址入栈。
21  no_error_code:                  # 这里是无出错号处理的入口处，见下面第 55 行等。
22          xchgl %eax,(%esp)       # _do_divide_error 的地址 ➔ eax，eax 被交换入栈。
23          pushl %ebx
24          pushl %ecx
25          pushl %edx
26          pushl %edi
27          pushl %esi
28          pushl %ebp
29          push %ds                # ！！16 位的段寄存器入栈后也要占用 4 个字节。
30          push %es
31          push %fs
32          pushl $0                # "error code"   # 将出错码入栈。
33          lea 44(%esp),%edx       # 取原调用返回地址处堆栈指针位置，并压入堆栈。
34          pushl %edx
35          movl $0x10,%edx         # 内核数据段选择符。
36          mov %dx,%ds
37          mov %dx,%es
38          mov %dx,%fs             # 下行上的'*'号表示是绝对调用操作数，与程序指针 PC 无关。
39          call *%eax              # 调用 C 函数 do_divide_error()。
40          addl $8,%esp            # 让堆栈指针重新指向寄存器 fs 入栈处。
41          pop %fs
42          pop %es
43          pop %ds
44          popl %ebp
45          popl %esi
46          popl %edi
47          popl %edx
48          popl %ecx
49          popl %ebx
50          popl %eax               # 弹出原来 eax 中的内容。
51          iret
52
```

```
   # int1 -- debug 调试中断入口点。处理过程同上。
   # 当 eflags 中 TF 标志置位时而引发的中断。
53 _debug:
54         pushl $_do_int3         # _do_debug C 函数指针入栈。以下同。
55         jmp no_error_code
56
   # int2 -- 非屏蔽中断调用入口点。
57 _nmi:
58         pushl $_do_nmi
59         jmp no_error_code
60
   # int3 -- 断点指令引起中断的入口点。处理同_debug。
   # 由 int 3 指令引发的中断，通常该指令由调式器插入被调式的代码中。
61 _int3:
62         pushl $_do_int3
63         jmp no_error_code
64
   # int4 -- 溢出出错处理中断入口点。
   # 当 eflags 中 OF 标志置位而引发的中断。
65 _overflow:
66         pushl $_do_overflow
67         jmp no_error_code
68
   # int5 -- 边界检查出错中断入口点。
   # 当操作数在有效范围以外时引发的中断。
69 _bounds:
70         pushl $_do_bounds
71         jmp no_error_code
72
   # int6 -- 无效操作指令出错中断入口点。
   # CPU 执行机构检测到一个无效的操作码而引起的中断。
73 _invalid_op:
74         pushl $_do_invalid_op
75         jmp no_error_code
76
   # int9 -- 协处理器段超出出错中断入口点。
77 _coprocessor_segment_overrun:
78         pushl $_do_coprocessor_segment_overrun
79         jmp no_error_code
80
   # int15 - 其他 Intel 保留中断的入口点。
81 _reserved:
82         pushl $_do_reserved
83         jmp no_error_code
84
   # int45 -- (= 0x20 + 13) 数学协处理器（Coprocessor）发出的中断。这是 Linux 设置的硬件中断。
   # 当协处理器执行完一个操作时就会发出 IRQ13 中断信号，以通知 CPU 操作完成。
85 _irq13:
86         pushl %eax
87         xorb %al,%al            # 80387 在执行计算时，CPU 会等待其操作完成。
88         outb %al,$0xF0          # 通过写 0xF0 端口，本中断将消除 CPU 的 BUSY 延续信号，并重新
                                   # 激活 80387 的处理器扩展请求引脚 PEREQ。该操作主要是为了确保
                                   # 在继续执行 80387 的任何指令之前，CPU 响应本中断。
```

```
89          movb $0x20,%al
90          outb %al,$0x20          # 向 8259 主中断控制芯片发送 EOI（中断结束）信号。
91          jmp 1f                  # 这两个跳转指令起延时作用。
92  1:      jmp 1f
93  1:      outb %al,$0xA0          # 再向 8259 从中断控制芯片发送 EOI（中断结束）信号。
94          popl %eax
95          jmp _coprocessor_error  # coprocessor_error 原在本程序中，现已放到 system_call.s 中。
96
    # 以下中断在调用时 CPU 会在中断返回地址之后将出错号压入堆栈，因此返回时也需要将出错号弹出。
    # int8 -- 双出错故障。（下面这段代码的含义参见图 5.3(b)）。
    # 通常当 CPU 在调用前一个异常的处理程序而又检测到一个新的异常时，这两个异常会被串行地进行
    # 处理，但也会碰到很少的情况，CPU 不能进行这样的串行处理操作，此时就会引发该中断。
97  _double_fault:
98          pushl $_do_double_fault         # C 函数地址入栈。
99  error_code:
100         xchgl %eax,4(%esp)              # error code <-> %eax，eax 原来的值被保存在堆栈上。
101         xchgl %ebx,(%esp)               # &function <-> %ebx，ebx 原来的值被保存在堆栈上。
102         pushl %ecx
103         pushl %edx
104         pushl %edi
105         pushl %esi
106         pushl %ebp
107         push %ds
108         push %es
109         push %fs
110         pushl %eax                      # error code    # 出错号入栈。
111         lea 44(%esp),%eax               # offset        # 程序返回地址处堆栈指针位置值入栈。
112         pushl %eax
113         movl $0x10,%eax                 # 置内核数据段选择符。
114         mov %ax,%ds
115         mov %ax,%es
116         mov %ax,%fs
117         call *%ebx                      # 调用相应的 C 函数，其参数已入栈。
118         addl $8,%esp                    # 堆栈指针重新指向栈中放置 fs 内容的位置。
119         pop %fs
120         pop %es
121         pop %ds
122         popl %ebp
123         popl %esi
124         popl %edi
125         popl %edx
126         popl %ecx
127         popl %ebx
128         popl %eax
129         iret
130
    # int10 -- 无效的任务状态段(TSS)。
    # CPU 企图切换到一个进程，而该进程的 TSS 无效。
131 _invalid_TSS:
132         pushl $_do_invalid_TSS
133         jmp error_code
134
    # int11 -- 段不存在。
```

```
    # 被引用的段不在内存中。
135 _segment_not_present:
136         pushl $_do_segment_not_present
137         jmp error_code
138
    # int12 -- 堆栈段错误。
    # 指令操作试图超出堆栈段范围，或者堆栈段不在内存中。
139 _stack_segment:
140         pushl $_do_stack_segment
141         jmp error_code
142
    # int13 -- 一般保护性出错。
143 _general_protection:
144         pushl $_do_general_protection
145         jmp error_code
146
    # int7 -- 设备不存在(_device_not_available)在(kernel/system_call.s,148)
    # int14 -- 页错误(_page_fault)在(mm/page.s,14)
    # int16 -- 协处理器错误(_coprocessor_error)在(kernel/system_call.s,131)
    # 时钟中断 int 0x20 (_timer_interrupt)在(kernel/system_call.s,176)
    # 系统调用 int 0x80 (_system_call)在 (kernel/system_call.s,80)
```

5.4.3 其他信息

5.4.3.1 Intel 保留中断向量的定义

这里给出了 Intel 保留中断向量具体含义的说明，见表 5–1 所示。

表 5－1 Intel 保留的中断号含义

中断号	名称	类型	信号	说明
0	Devide error	故障	SIGFPE	当进行除以零的操作时产生。
1	Debug	陷阱 故障	SIGTRAP	当进行程序单步跟踪调试时，设置了标志寄存器 eflags 的 T 标志时产生这个中断。
2	nmi	硬件		由不可屏蔽中断 NMI 产生。
3	Breakpoint	陷阱	SIGTRAP	由断点指令 int3 产生，与 debug 处理相同。
4	Overflow	陷阱	SIGSEGV	eflags 的溢出标志 OF 引起。
5	Bounds check	故障	SIGSEGV	寻址到有效地址以外时引起。
6	Invalid Opcode	故障	SIGILL	CPU 执行时发现一个无效的指令操作码。
7	Device not available	故障	SIGSEGV	设备不存在，指协处理器。在两种情况下会产生该中断：(a)CPU 遇到一个转意指令并且 EM 置位时。在这种情况下处理程序应该模拟导致异常的指令。 (b)MP 和 TS 都在置位状态时，CPU 遇到 WAIT 或一个转意指令。在这种情况下，处理程序在必要时应该更新协处理器的状态。
8	Double fault	异常中止	SIGSEGV	双故障出错。
9	Coprocessor segment overrun	异常中止	SIGFPE	协处理器段超出。
10	Invalid TSS	故障	SIGSEGV	CPU 切换时发觉 TSS 无效。
11	Segment not present	故障	SIGBUS	描述符所指的段不存在。

12	Stack segment	故障	SIGBUS	堆栈段不存在或寻址越出堆栈段。
13	General protection	故障	SIGSEGV	没有符合 80386 保护机制（特权级）的操作引起。
14	Page fault	故障	SIGSEGV	页不在内存。
15	Reserved			
16	Coprocessor error	故障	SIGFPE	协处理器发出的发出的出错信号引起。

5.5 traps.c 程序

5.5.1 功能描述

traps.c 程序主要包括一些在处理异常故障（硬件中断）底层代码 asm.s 文件中调用的相应 C 函数。用于显示出错位置和出错号等调试信息。其中的 die()通用函数用于在中断处理中显示详细的出错信息，而代码最后的初始化函数 trap_init()是在前面 init/main.c 中被调用，用于初始化硬件异常处理中断向量(陷阱门)，并设置允许中断请求信号的到来。在阅读本程序时需要参考 asm.s 程序。

5.5.2 代码注释

程序 5-3 linux/kernel/traps.c

```
 1 /*
 2  *  linux/kernel/traps.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * 'Traps.c' handles hardware traps and faults after we have saved some
 9  * state in 'asm.s'. Currently mostly a debugging-aid, will be extended
10  * to mainly kill the offending process (probably by giving it a signal,
11  * but possibly by killing it outright if necessary).
12  */
   /*
    * 在程序 asm.s 中保存了一些状态后，本程序用来处理硬件陷阱和故障。目前主要用于调试目的，
    * 以后将扩展用来杀死遭损坏的进程（主要是通过发送一个信号，但如果必要也会直接杀死）。
    */
13 #include <string.h>        // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
14
15 #include <linux/head.h>    // head 头文件，定义了段描述符的简单结构，和几个选择符常量。
16 #include <linux/sched.h>   // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                              // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
17 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
18 #include <asm/system.h>    // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
19 #include <asm/segment.h>   // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
20 #include <asm/io.h>        // 输入/输出头文件。定义硬件端口输入/输出宏汇编语句。
21
   // 以下语句定义了三个嵌入式汇编宏语句函数。有关嵌入式汇编的基本语法见列表后或参见附录。
   // 用圆括号括住的组合语句（花括号中的语句）可以作为表达式使用，其中最后的__res 是其输出值。
   // 取段 seg 中地址 addr 处的一个字节。
```

```
   // 参数：seg - 段选择符；addr - 段内指定地址。
   // 输出：%0 - eax (__res)；输入：%1 - eax (seg)；%2 - 内存地址 (*(addr))。
22 #define get_seg_byte(seg,addr) ({ \
23 register char __res; \
24 __asm__("push %%fs;mov %%ax,%%fs;movb %%fs:%2,%%al;pop %%fs" \
25         :"=a" (__res):"" (seg),"m" (*(addr))); \
26 __res;})
27
   // 取段 seg 中地址 addr 处的一个长字（4 字节）。
   // 参数：seg - 段选择符；addr - 段内指定地址。
   // 输出：%0 - eax (__res)；输入：%1 - eax (seg)；%2 - 内存地址 (*(addr))。
28 #define get_seg_long(seg,addr) ({ \
29 register unsigned long __res; \
30 __asm__("push %%fs;mov %%ax,%%fs;movl %%fs:%2,%%eax;pop %%fs" \
31         :"=a" (__res):"" (seg),"m" (*(addr))); \
32 __res;})
33
   // 取 fs 段寄存器的值（选择符）。
   // 输出：%0 - eax (__res)。
34 #define _fs() ({ \
35 register unsigned short __res; \
36 __asm__("mov %%fs,%%ax":"=a" (__res):); \
37 __res;})
38
   // 以下定义了一些函数原型。
39 int do_exit(long code);                     // 程序退出处理。(kernel/exit.c,102)
40
41 void page_exception(void);                  // 页异常。实际是 page_fault (mm/page.s,14)
42
   // 以下定义了一些中断处理程序原型，用于在函数 trap_init()中设置相应中断门描述符。
   // 这些函数的代码在（kernel/asm.s 或 system_call.s）中。
43 void divide_error(void);                    // int0 (kernel/asm.s,19)。
44 void debug(void);                           // int1 (kernel/asm.s,53)。
45 void nmi(void);                             // int2 (kernel/asm.s,57)。
46 void int3(void);                            // int3 (kernel/asm.s,61)。
47 void overflow(void);                        // int4 (kernel/asm.s,65)。
48 void bounds(void);                          // int5 (kernel/asm.s,69)。
49 void invalid_op(void);                      // int6 (kernel/asm.s,73)。
50 void device_not_available(void);            // int7 (kernel/system_call.s,148)。
51 void double_fault(void);                    // int8 (kernel/asm.s,97)。
52 void coprocessor_segment_overrun(void);     // int9 (kernel/asm.s,77)。
53 void invalid_TSS(void);                     // int10 (kernel/asm.s,131)。
54 void segment_not_present(void);             // int11 (kernel/asm.s,135)。
55 void stack_segment(void);                   // int12 (kernel/asm.s,139)。
56 void general_protection(void);              // int13 (kernel/asm.s,143)。
57 void page_fault(void);                      // int14 (mm/page.s,14)。
58 void coprocessor_error(void);               // int16 (kernel/system_call.s,131)。
59 void reserved(void);                        // int15 (kernel/asm.s,81)。
60 void parallel_interrupt(void);              // int39 (kernel/system_call.s,280)。
61 void irq13(void);                           // int45 协处理器中断处理(kernel/asm.s,85)。
62
   // 该子程序用来打印出错中断的名称、出错号、调用程序的 EIP、EFLAGS、ESP、fs 段寄存器值、
   // 段的基址、段的长度、进程号 pid、任务号、10 字节指令码。如果堆栈在用户数据段，则还
```

```
    // 打印 16 字节的堆栈内容。
 63 static void die(char * str,long esp_ptr,long nr)
 64 {
 65         long * esp = (long *) esp_ptr;
 66         int i;
 67
 68         printk("%s: %04x\n\r",str,nr&0xffff);
 69         printk("EIP:\t%04x:%p\nEFLAGS:\t%p\nESP:\t%04x:%p\n",
 70                 esp[1],esp[0],esp[2],esp[4],esp[3]);
 71         printk("fs: %04x\n",_fs());
 72         printk("base: %p, limit: %p\n",get_base(current->ldt[1]),get_limit(0x17));
 73         if (esp[4] == 0x17) {
 74                 printk("Stack: ");
 75                 for (i=0;i<4;i++)
 76                         printk("%p ",get_seg_long(0x17,i+(long *)esp[3]));
 77                 printk("\n");
 78         }
 79         str(i);                 // 取当前运行任务的任务号（include/linux/sched.h,159）。
 80         printk("Pid: %d, process nr: %d\n\r",current->pid,0xffff & i);
 81         for(i=0;i<10;i++)
 82                 printk("%02x ",0xff & get_seg_byte(esp[1],(i+(char *)esp[0])));
 83         printk("\n\r");
 84         do_exit(11);            /* play segment exception */
 85 }
 86
    // 以下这些以 do_开头的函数是对应名称中断处理程序调用的 C 函数。
 87 void do_double_fault(long esp, long error_code)
 88 {
 89         die("double fault",esp,error_code);
 90 }
 91
 92 void do_general_protection(long esp, long error_code)
 93 {
 94         die("general protection",esp,error_code);
 95 }
 96
 97 void do_divide_error(long esp, long error_code)
 98 {
 99         die("divide error",esp,error_code);
100 }
101
102 void do_int3(long * esp, long error_code,
103                 long fs,long es,long ds,
104                 long ebp,long esi,long edi,
105                 long edx,long ecx,long ebx,long eax)
106 {
107         int tr;
108
109         __asm__("str %%ax":"=a" (tr):"" (0));                   // 取任务寄存器值➔tr。
110         printk("eax\t\tebx\t\tecx\t\tedx\n\r%8x\t%8x\t%8x\t%8x\n\r",
111                 eax,ebx,ecx,edx);
112         printk("esi\t\tedi\t\tebp\t\tesp\n\r%8x\t%8x\t%8x\t%8x\n\r",
113                 esi,edi,ebp,(long) esp);
```

```
114         printk("\n\rds\tes\tfs\ttr\n\r%4x\t%4x\t%4x\t%4x\n\r",
115                 ds,es,fs,tr);
116         printk("EIP: %8x   CS: %4x  EFLAGS: %8x\n\r",esp[0],esp[1],esp[2]);
117 }
118
119 void do_nmi(long esp, long error_code)
120 {
121         die("nmi",esp,error_code);
122 }
123
124 void do_debug(long esp, long error_code)
125 {
126         die("debug",esp,error_code);
127 }
128
129 void do_overflow(long esp, long error_code)
130 {
131         die("overflow",esp,error_code);
132 }
133
134 void do_bounds(long esp, long error_code)
135 {
136         die("bounds",esp,error_code);
137 }
138
139 void do_invalid_op(long esp, long error_code)
140 {
141         die("invalid operand",esp,error_code);
142 }
143
144 void do_device_not_available(long esp, long error_code)
145 {
146         die("device not available",esp,error_code);
147 }
148
149 void do_coprocessor_segment_overrun(long esp, long error_code)
150 {
151         die("coprocessor segment overrun",esp,error_code);
152 }
153
154 void do_invalid_TSS(long esp,long error_code)
155 {
156         die("invalid TSS",esp,error_code);
157 }
158
159 void do_segment_not_present(long esp,long error_code)
160 {
161         die("segment not present",esp,error_code);
162 }
163
164 void do_stack_segment(long esp,long error_code)
165 {
166         die("stack segment",esp,error_code);
```

```
167 }
168
169 void do_coprocessor_error(long esp, long error_code)
170 {
171         if (last_task_used_math != current)
172                 return;
173         die("coprocessor error",esp,error_code);
174 }
175
176 void do_reserved(long esp, long error_code)
177 {
178         die("reserved (15,17-47) error",esp,error_code);
179 }
180
    // 下面是异常（陷阱）中断程序初始化子程序。设置它们的中断调用门（中断向量）。
    // set_trap_gate()与 set_system_gate()的都使用了中断描述符表 IDT 中的陷阱门（Trap Gate），
    // 它们之间的主要区别在于前者设置的特权级为 0，后者是 3。因此断点陷阱中断 int3、溢出中断
    // overflow 和边界出错中断 bounds 可以由任何程序产生。
    // 这两个函数均是嵌入式汇编宏程序(include/asm/system.h,第 36 行、39 行)。
181 void trap_init(void)
182 {
183         int i;
184
185         set_trap_gate(0,&divide_error);  // 设置除操作出错的中断向量值。以下雷同。
186         set_trap_gate(1,&debug);
187         set_trap_gate(2,&nmi);
188         set_system_gate(3,&int3);       /* int3-5 can be called from all */
189         set_system_gate(4,&overflow);    /* int3-5 可以被所有程序执行 */
190         set_system_gate(5,&bounds);
191         set_trap_gate(6,&invalid_op);
192         set_trap_gate(7,&device_not_available);
193         set_trap_gate(8,&double_fault);
194         set_trap_gate(9,&coprocessor_segment_overrun);
195         set_trap_gate(10,&invalid_TSS);
196         set_trap_gate(11,&segment_not_present);
197         set_trap_gate(12,&stack_segment);
198         set_trap_gate(13,&general_protection);
199         set_trap_gate(14,&page_fault);
200         set_trap_gate(15,&reserved);
201         set_trap_gate(16,&coprocessor_error);
    // 下面将 int17-48 的陷阱门先均设置为 reserved，以后每个硬件初始化时会重新设置自己的陷阱门。
202         for (i=17;i<48;i++)
203                 set_trap_gate(i,&reserved);
204         set_trap_gate(45,&irq13);              // 设置协处理器的陷阱门。
205         outb_p(inb_p(0x21)&0xfb,0x21);         // 允许主 8259A 芯片的 IRQ2 中断请求。
206         outb(inb_p(0xA1)&0xdf,0xA1);           // 允许从 8259A 芯片的 IRQ13 中断请求。
207         set_trap_gate(39,&parallel_interrupt);  // 设置并行口的陷阱门。
208 }
209
```

5.5.3 其他信息

5.5.3.1 嵌入式汇编的基本格式

本节是第一次在内核源程序中接触到 C 语言中的嵌入式汇编代码。由于我们在通常的 C 语言程序编制过程中一般是不会使用嵌入式汇编代码的，因此这里有必要对其基本格式和使用方法进行简单描述，详细说明可参见 GNU gcc 手册中第 4 章的内容（Extensions to the C Language Family），或见参考文献（Using Inline Assembly with gcc）。

具有输入和输出参数的嵌入汇编语句的基本格式为：

```
asm("汇编语句"
    : 输出寄存器
    : 输入寄存器
    : 会被修改的寄存器);
```

其中，“汇编语句”是你写汇编指令的地方；“输出寄存器”表示当这段嵌入汇编执行完之后，哪些寄存器用于存放输出数据。此地，这些寄存器会分别对应一 C 语言表达式或一个内存地址；“输入寄存器”表示在开始执行汇编代码时，这里指定的一些寄存器中应存放的输入值，它们也分别对应着一 C 变量或常数值。“会被修改的寄存器”表示你已对其中列出的寄存器中的值进行了改动，gcc 编译器不能再依赖于它原先对这些寄存器加载的值，如果必要的话，gcc 需要重新加载这些寄存器。

下面我们用例子来说明嵌入汇编语句的使用方法。这里列出了前面代码中第 22 行开始的一段代码作为例子来详细解说。为了能看得更清楚一些，我们对这段代码进行了重新排列和编号。

```
01  #define get_seg_byte(seg,addr) \
02  ({ \
03  register char __res; \
04  __asm__("push %%fs;    \
05              mov %%ax,%%fs;    \
06              movb %%fs:%2,%%al;    \
07              pop %%fs"    \
08              :"=a" (__res)    \
09              :"" (seg),"m" (*(addr))); \
10  __res;})
```

这段 10 行代码定义了一个嵌入汇编语言宏函数。通常使用汇编语句最方便的方式是把它们放在一个宏内。用圆括号括住的组合语句（花括号中的语句）可以作为表达式使用，其中最后一行上的变量__res（第 10 行）是该表达式的输出值。

因为是宏语句，需要在一行上定义，因此这里使用反斜杠'\'将这些语句连成一行。这条宏定义将被替换到宏名称在程序中被引用的地方。第 1 行定义了宏的名称，也即是宏函数名称 get_seg_byte(seg,addr)。第 3 行定义了一个寄存器变量__res。第 4 行上的__asm__表示嵌入汇编语句的开始。从第 4 行到第 7 行的 4 条语句是 AT&T 格式的汇编语句。

第 8 行即是输出寄存器，这句的含义是在这段代码运行结束后将 eax 所代表的寄存器的值放入__res 变量中，作为本函数的输出值，"=a"中的"a"称为加载代码，"="表示这是输出寄存器。第 9 行表示在这段

代码开始运行时将 seg 放到 eax 寄存器中，""表示使用与上面同个位置的输出相同的寄存器。而(*(addr))表示一个内存偏移地址值。为了在上面汇编语句中使用该地址值，嵌入汇编程序规定把输出和输入寄存器统一按顺序编号，顺序是从输出寄存器序列从左到右从上到下以"%0"开始，分别记为%0、%1、…%9。因此，输出寄存器的编号是%0（这里只有一个输出寄存器），输入寄存器前一部分("" (seg))的编号是%1，而后部分的编号是%2。上面第 6 行上的%2 即代表(*(addr))这个内存偏移量。

现在我们来研究 4—7 行上的代码的作用。第一句将 fs 段寄存器的内容入栈；第二句将 eax 中的段值赋给 fs 段寄存器；第三句是把 fs:(*(addr))所指定的字节放入 al 寄存器中。当执行完汇编语句后，输出寄存器 eax 的值将被放入__res，作为该宏函数（块结构表达式）的返回值。很简单，不是吗？

通过上面分析，我们知道，宏名称中的 seg 代表一指定的内存段值，而 addr 表示一内存偏移地址量。到现在为止，我们应该很清楚这段程序的功能了吧！该宏函数的功能是从指定段和偏移值的内存地址处取一个字节。

在看下一个例子。

```
01  asm("cld\n\t"
02      "rep\n\t"
03      "stol"
04      : /* 没有输出寄存器 */
05      : "c"(count-1), "a"(fill_value), "D"(dest)
06      : "%ecx", "%edi");
```

1-3 行这三句是通常的汇编语句，用以清方向位，重复保存值。第 4 行说明这段嵌入汇编程序没有用到输出寄存器。第 5 行的含义是：将 count-1 的值加载到 ecx 寄存器中（加载代码是"c"），fill_value 加载到 eax 中，dest 放到 edi 中。为什么要让 gcc 编译程序去做这样的寄存器值的加载，而不让我们自己做呢？因为 gcc 在它进行寄存器分配时可以进行某些优化工作。例如 fill_value 值可能已经在 eax 中。如果是在一个循环语句中的话，gcc 就可能在整个循环操作中保留 eax，这样就可以在每次循环中少用一个 movl 语句。

最后一行的作用是告诉 gcc 这些寄存器中的值已经改变了。很古怪吧？不过在 gcc 知道你拿这些寄存器做些什么后，这确实能够对 gcc 的优化操作有所帮助。表 5–2 中是一些你可能会用到的寄存器加载代码及其具体的含义。

表 5－2 常用寄存器加载代码说明

代码	说明	代码	说明
a	使用寄存器 eax	m	使用内存地址
b	使用寄存器 ebx	o	使用内存地址并可以加偏移值
c	使用寄存器 ecx	I	使用常数 0-31
d	使用寄存器 edx	J	使用常数 0-63
S	使用 esi	K	使用常数 0-255
D	使用 edi	L	使用常数 0-65535
q	使用动态分配字节可寻址寄存器（eax、ebx、ecx 或 edx）	M	使用常数 0-3
r	使用任意动态分配的寄存器	N	使用 1 字节常数（0-255）
g	使用通用有效的地址即可（eax、ebx、ecx、edx 或内存变量）	O	使用常数 0-31

A	使用 eax 与 edx 联合(64 位)		

下面的例子不是让你自己指定哪个变量使用哪个寄存器，而是让 gcc 为你选择。

```
01  asm("leal (%1, %1, 4), %0"
02      : "=r"(y)
03      : "0"(x));
```

第一句汇编语句”leal (r1, r2,4), r3”语句表示 r1+r2*4 ➔ r3。这个例子可以非常快地将 x 乘 5。 其中"%0","%1"是指 gcc 自动分配的寄存器。这里"%1"代表输入值 x 要放入的寄存器，"%0"表示输出值寄存器。输出寄存器代码前一定要加等于号。如果输入寄存器的代码是 0 或为空时，则说明使用与相应输出一样的寄存器。所以，如果 gcc 将 r 指定为 eax 的话，那么上面汇编语句的含义即为：

"leal (eax,eax,4), eax"

注意：在执行代码时，如果不希望汇编语句被 gcc 优化而挪动地方，就需要在 asm 符号后面添加 volatile 关键词：

asm volatile (……);

或者更详细的说明为：

__asm__ __volatile__ (……);

下面在具一个较长的例子，如果能看得懂，那就说明嵌入汇编代码对你来说基本没问题了。这段代码是从 include/string.h 文件中摘取的，是 strncmp()字符串比较函数的一种实现。需要注意的是，其中每行中的"\n\t"是用于 gcc 预处理程序输出列表好看而设置的，含义与 C 语言中相同。

```
//// 字符串 1 与字符串 2 的前 count 个字符进行比较。
// 参数：cs - 字符串 1，ct - 字符串 2，count - 比较的字符数。
// %0 - eax(__res)返回值，%1 - edi(cs)串 1 指针，%2 - esi(ct)串 2 指针，%3 - ecx(count)。
// 返回：如果串 1 > 串 2，则返回 1；串 1 = 串 2，则返回 0；串 1 < 串 2，则返回-1。
extern inline int strncmp(const char * cs,const char * ct,int count)
{
register int __res ;                    // __res 是寄存器变量。
__asm__("cld\n"                         // 清方向位。
        "1:\tdecl %3\n\t"               // count--。
        "js 2f\n\t"                     // 如果 count<0，则向前跳转到标号 2。
        "lodsb\n\t"                     // 取串 2 的字符 ds:[esi]➔al，并且 esi++。
        "scasb\n\t"                     // 比较 al 与串 1 的字符 es:[edi]，并且 edi++。
        "jne 3f\n\t"                    // 如果不相等，则向前跳转到标号 3。
        "testb %%al,%%al\n\t"           // 该字符是 NULL 字符吗？
        "jne 1b\n"                      // 不是，则向后跳转到标号 1，继续比较。
        "2:\txorl %%eax,%%eax\n\t"      // 是 NULL 字符，则 eax 清零（返回值）。
        "jmp 4f\n"                      // 向前跳转到标号 4，结束。
        "3:\tmovl $1,%%eax\n\t"         // eax 中置 1。
        "jl 4f\n\t"                     // 如果前面比较中串 2 字符<串 2 字符，则返回 1，结束。
        "negl %%eax\n"                  // 否则 eax = -eax，返回负值，结束。
        "4:"
        :"=a" (__res):"D" (cs),"S" (ct),"c" (count):"si","di","cx");
return __res;                           // 返回比较结果。
```

```
}
```

5.6 system_call.s 程序

5.6.1 功能描述

在 Linux 0.11 中，用户使用中断调用 int 0x80 和放在寄存器 eax 中的功能号来使用内核提供的各种功能，这些操作系统提供的功能被称之为系统调用功能。通常用户并不是直接使用系统调用中断，而是通过函数库（例如 libc）中提供的接口函数来调用的。例如创建进程的系统调用 fork 可直接使用函数 fork()即可。函数库 libc 中的 fork()函数会实现对中断 int 0x80 的调用过程并把调用结果返回给用户程序。

对于所有系统调用的实现函数，内核把它们按照系统调用功能号顺序排列成一张函数指针（地址）表（在 include/linux/sys.h 文件中）。然后在中断 int 0x80 的处理过程中根据用户提供的功能号调用对应系统调用函数进行处理。

本程序主要实现系统调用(system_call)中断 int 0x80 的入口处理过程以及信号检测处理（从代码第 80 行开始），同时给出了两个系统功能的底层接口，分别是 sys_execve 和 sys_fork。还列出了处理过程类似的协处理器出错(int 16)、设备不存在(int7)、时钟中断(int32)、硬盘中断(int46)、软盘中断(int38)的中断处理程序。

对于软中断(system_call、coprocessor_error、device_not_available)，其处理过程基本上是首先为调用相应 C 函数处理程序作准备，将一些参数压入堆栈。系统调用最多可以带 3 个参数，分别通过寄存器 ebx、ecx 和 edx 传入。然后调用 C 函数进行相应功能的处理，处理返回后再去检测当前任务的信号位图，对值最小的一个信号进行处理并复位信号位图中的该信号。系统调用的 C 语言处理函数分布在整个 linux 内核代码中，由 include/linux/sys.h 头文件中的系统函数指针数组表来匹配。

对于硬件中断请求信号 IRQ 发来的中断，其处理过程首先是向中断控制芯片 8259A 发送结束硬件中断控制字指令 EOI，然后调用相应的 C 函数处理程序。对于时钟中断也要对当前任务的信号位图进行检测处理。

对于系统调用(int 0x80)的中断处理过程，可以把它看作是一个“接口”程序。实际每个系统调用功能的处理基本上都是通过调用相应的 C 函数进行的。即所谓的“Bottom half”函数。

这个程序在刚进入时会首先检查 eax 中的功能号是否有效（在给定的范围内），然后保存会用到的寄存器。Linux 内核默认地把 ds,es 用于内核数据段，而 fs 用于用户数据段。接着通过一个地址跳转表（sys_call_table）调用相应系统调用的 C 函数。在 C 函数返回后，程序就把返回值压入堆栈保存起来。

接下来，该程序查看执行本次调用进程的状态。如果由于上面 C 函数的操作或其他情况而使进程的状态从执行态变成了其他状态，或者由于时间片已经用完（counter==0），则调用进程调度函数 schedule()（jmp _schedule）。由于在执行"jmp _schedule"之前已经把返回地址 ret_from_sys_call 入栈，因此在执行完 schedule()后最终会返回到 ret_from_sys_call 处继续执行。

从 ret_from_sys_call 标号处开始的代码执行一些系统调用的后处理工作。主要判断当前进程是否是初始进程 0，如果是就直接退出此次系统调用，中断返回。否则再根据代码段描述符和所使用的堆栈来判断本次统调用的进程是否是一个普通进程，若不是则说明是内核进程（例如初始进程 1）或其他。则也立刻弹出堆栈内容退出系统调用中断。末端的一块代码用来处理调用系统调用进程的信号。若进程结构的信号位图表明该进程有接收到信号，则调用信号处理函数 do_signal()。

最后，该程序恢复保存的寄存器内容，退出此次中断处理过程并返回调用程序。若有信号时则程序

会首先“返回”到相应信号处理函数中去执行，然后返回调用 system_call 的程序。

系统调用处理过程的整个流程见图 5-5 所示。

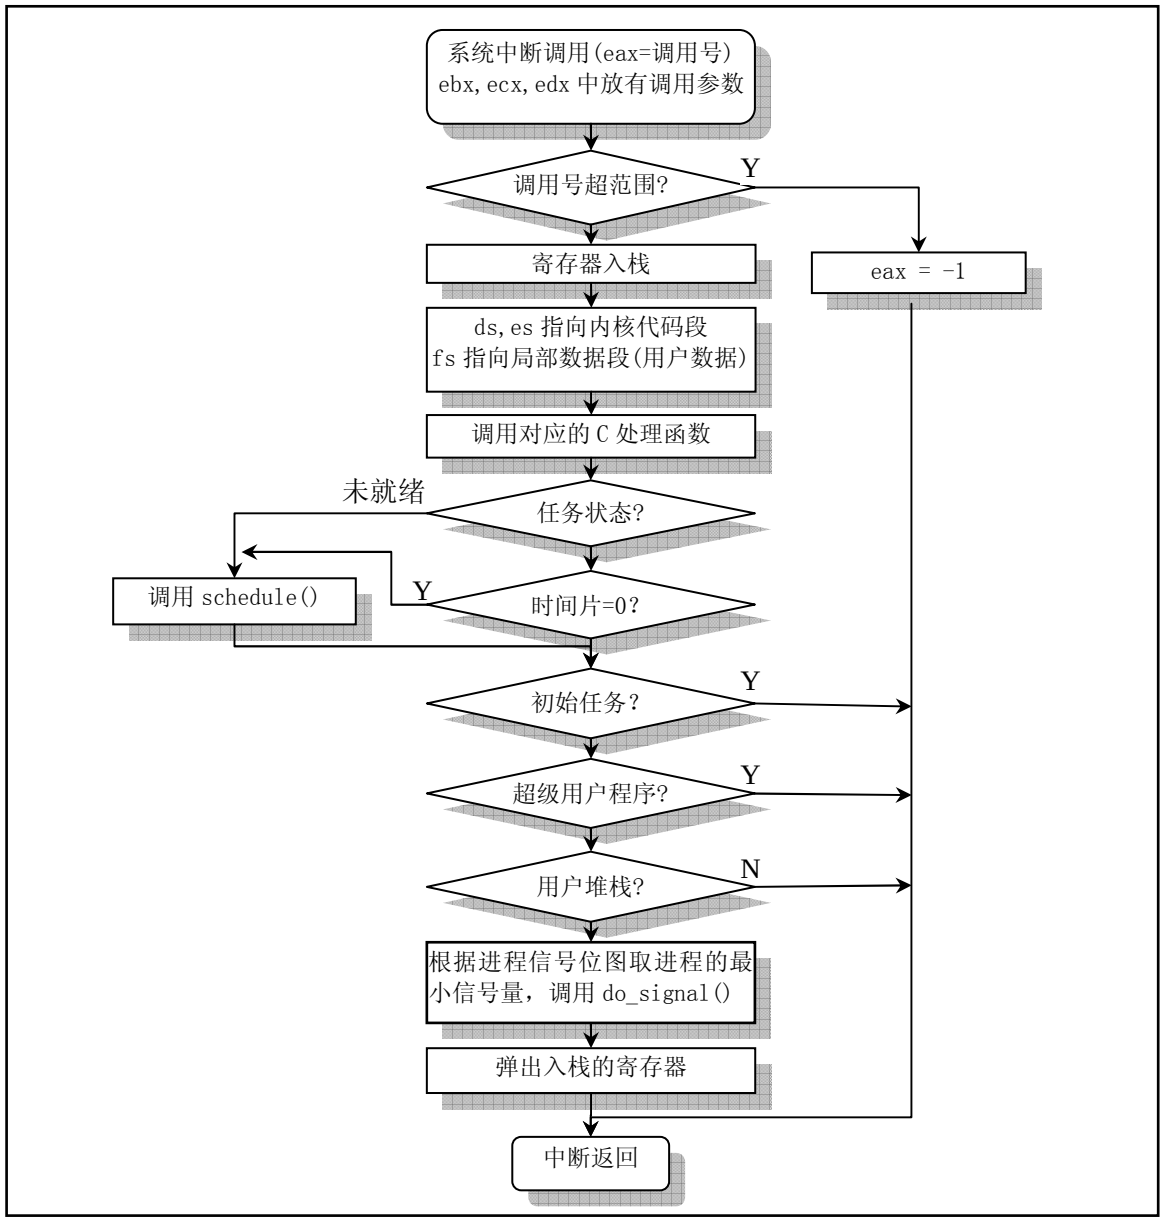

图 5-5 系统中断调用处理流程

5.6.2 代码注释

程序 5-4 linux/kernel/system_call.s

```
1 /*
2  *  linux/kernel/system_call.s
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
7 /*
8  *  system_call.s  contains the system-call low-level handling routines.
```

```
 9  * This also contains the timer-interrupt handler, as some of the code is
10  * the same. The hd- and flopppy-interrupts are also here.
11  *
12  * NOTE: This code handles signal-recognition, which happens every time
13  * after a timer-interrupt and after each system call. Ordinary interrupts
14  * don't handle signal-recognition, as that would clutter them up totally
15  * unnecessarily.
16  *
17  * Stack layout in 'ret_from_system_call':
18  *
19  *       0(%esp) - %eax
20  *       4(%esp) - %ebx
21  *       8(%esp) - %ecx
22  *       C(%esp) - %edx
23  *      10(%esp) - %fs
24  *      14(%esp) - %es
25  *      18(%esp) - %ds
26  *      1C(%esp) - %eip
27  *      20(%esp) - %cs
28  *      24(%esp) - %eflags
29  *      28(%esp) - %oldesp
30  *      2C(%esp) - %oldss
31  */
    /*
     * system_call.s 文件包含系统调用(system-call)底层处理子程序。由于有些代码比较类似，所以
     * 同时也包括时钟中断处理(timer-interrupt)句柄。硬盘和软盘的中断处理程序也在这里。
     *
     * 注意：这段代码处理信号(signal)识别，在每次时钟中断和系统调用之后都会进行识别。一般
     * 中断信号并不处理信号识别，因为会给系统造成混乱。
     *
     * 从系统调用返回（'ret_from_system_call'）时堆栈的内容见上面 19-30 行。
     */
32
33  SIG_CHLD        = 17          # 定义 SIG_CHLD 信号（子进程停止或结束）。
34
35  EAX             = 0x00        # 堆栈中各个寄存器的偏移位置。
36  EBX             = 0x04
37  ECX             = 0x08
38  EDX             = 0x0C
39  FS              = 0x10
40  ES              = 0x14
41  DS              = 0x18
42  EIP             = 0x1C
43  CS              = 0x20
44  EFLAGS          = 0x24
45  OLDESP          = 0x28        # 当有特权级变化时。
46  OLDSS           = 0x2C
47
    # 以下这些是任务结构(task_struct)中变量的偏移值，参见 include/linux/sched.h，77 行开始。
48  state   = 0             # these are offsets into the task-struct.  # 进程状态码
49  counter = 4             # 任务运行时间计数(递减)（滴答数），运行时间片。
50  priority = 8            # 运行优先数。任务开始运行时 counter=priority，越大则运行时间越长。
51  signal  = 12            # 是信号位图，每个比特位代表一种信号，信号值=位偏移值+1。
```

```
52 sigaction = 16          # MUST be 16 (=len of sigaction) // sigaction 结构长度必须是 16 字节。
                           # 信号执行属性结构数组的偏移值，对应信号将要执行的操作和标志信息。
53 blocked = (33*16)       # 受阻塞信号位图的偏移量。
54
   # 以下定义在 sigaction 结构中的偏移量，参见 include/signal.h，第 48 行开始。
55 # offsets within sigaction
56 sa_handler = 0                    # 信号处理过程的句柄（描述符）。
57 sa_mask = 4                       # 信号量屏蔽码
58 sa_flags = 8                      # 信号集。
59 sa_restorer = 12                  # 恢复函数指针，参见 kernel/signal.c。
60
61 nr_system_calls = 72              # Linux 0.11 版内核中的系统调用总数。
62
63 /*
64  * Ok, I get parallel printer interrupts while using the floppy for some
65  * strange reason. Urgel. Now I just ignore them.
66  */
   /*
    * 好了，在使用软驱时我收到了并行打印机中断，很奇怪。呵，现在不管它。
    */
    # 定义入口点。
67 .globl _system_call,_sys_fork,_timer_interrupt,_sys_execve
68 .globl _hd_interrupt,_floppy_interrupt,_parallel_interrupt
69 .globl _device_not_available, _coprocessor_error
70
   # 错误的系统调用号。
71 .align 2                          # 内存 4 字节对齐。
72 bad_sys_call:
73         movl $-1,%eax             # eax 中置-1，退出中断。
74         iret
   # 重新执行调度程序入口。调度程序 schedule 在(kernel/sched.c,104)。
75 .align 2
76 reschedule:
77         pushl $ret_from_sys_call  # 将 ret_from_sys_call 的地址入栈（101 行）。
78         jmp _schedule
   #### int 0x80 --linux 系统调用入口点(调用中断 int 0x80，eax 中是调用号)。
79 .align 2
80 _system_call:
81         cmpl $nr_system_calls-1,%eax   # 调用号如果超出范围的话就在 eax 中置-1 并退出。
82         ja bad_sys_call
83         push %ds                # 保存原段寄存器值。
84         push %es
85         push %fs
   # 一个系统调用最多可以带有 3 个参数，也可以不带参数。下面入栈的 ebx、ecx 和 edx 中放着系统
   # 调用相应 C 语言函数（见第 94 行）的调用参数。这几个寄存器入栈的顺序是由 GNU GCC 规定的，
   # ebx 中可存放第 1 个参数，ecx 中存放第 2 个参数，edx 中存放第 3 个参数。
   # 系统调用语句可参见头文件 include/unistd.h 中第 133 到 183 行的系统调用宏。
86         pushl %edx
87         pushl %ecx              # push %ebx,%ecx,%edx as parameters
88         pushl %ebx              # to the system call
89         movl $0x10,%edx         # set up ds,es to kernel space
90         mov %dx,%ds             # ds,es 指向内核数据段(全局描述符表中数据段描述符)。
91         mov %dx,%es
```

```
    # fs 指向局部数据段(局部描述符表中数据段描述符)，即指向执行本次系统调用的用户程序的数据段。
    # 注意，在 Linux 0.11 中内核给任务分配的代码和数据内存段是重叠的，它们的段基址和段限长相同。
    # 参见 fork.c 程序中 copy_mem()函数。
 92         movl $0x17,%edx             # fs points to local data space
 93         mov %dx,%fs
    # 下面这句操作数的含义是：调用地址 = _sys_call_table + %eax * 4。参见程序后的说明。
    # 对应的 C 程序中的 sys_call_table 在 include/linux/sys.h 中，其中定义了一个包括 72 个
    # 系统调用 C 处理函数的地址数组表。
 94         call _sys_call_table(,%eax,4)
 95         pushl %eax                  # 把系统调用返回值入栈。
 96         movl _current,%eax          # 取当前任务（进程）数据结构地址➔eax。
    # 下面 97-100 行查看当前任务的运行状态。如果不在就绪状态(state 不等于 0)就去执行调度程序。
    # 如果该任务在就绪状态，但其时间片已用完（counter=0），则也去执行调度程序。
 97         cmpl $0,state(%eax)         # state
 98         jne reschedule
 99         cmpl $0,counter(%eax)       # counter
100         je reschedule
    # 以下这段代码执行从系统调用 C 函数返回后，对信号量进行识别处理。
101 ret_from_sys_call:
    # 首先判别当前任务是否是初始任务 task0，如果是则不必对其进行信号量方面的处理，直接返回。
    # 103 行上的_task 对应 C 程序中的 task[]数组，直接引用 task 相当于引用 task[0]。
102         movl _current,%eax          # task[0] cannot have signals
103         cmpl _task,%eax
104         je 3f                       # 向前(forward)跳转到标号 3。
    # 通过对原调用程序代码选择符的检查来判断调用程序是否是内核任务（例如任务 1）。如果是则直接
    # 退出中断。否则对于普通进程则需进行信号量的处理。这里比较选择符是否为普通用户代码段的选择
    # 符 0x000f (RPL=3，局部表，第 1 个段(代码段))，如果不是则跳转退出中断程序。
105         cmpw $0x0f,CS(%esp)         # was old code segment supervisor ?
106         jne 3f
    # 如果原堆栈段选择符不为 0x17（即原堆栈不在用户段中），也说明本次系统调用的调用者不是用户
    # 任务，则也退出。
107         cmpw $0x17,OLDSS(%esp)      # was stack segment = 0x17 ?
108         jne 3f
    # 下面这段代码（109-120）的用途是首先取当前任务结构中的信号位图(32 位，每位代表 1 种信号)，
    # 然后用任务结构中的信号阻塞（屏蔽）码，阻塞不允许的信号位，取得数值最小的信号值，再把
    # 原信号位图中该信号对应的位复位（置 0），最后将该信号值作为参数之一调用 do_signal()。
    # do_signal()在（kernel/signal.c,82）中，其参数包括 13 个入栈的信息。
109         movl signal(%eax),%ebx      # 取信号位图➔ebx，每 1 位代表 1 种信号，共 32 个信号。
110         movl blocked(%eax),%ecx     # 取阻塞（屏蔽）信号位图➔ecx。
111         notl %ecx                   # 每位取反。
112         andl %ebx,%ecx              # 获得许可的信号位图。
113         bsfl %ecx,%ecx              # 从低位（位 0）开始扫描位图，看是否有 1 的位，
                                        # 若有，则 ecx 保留该位的偏移值（即第几位 0-31）。
114         je 3f                       # 如果没有信号则向前跳转退出。
115         btrl %ecx,%ebx              # 复位该信号（ebx 含有原 signal 位图）。
116         movl %ebx,signal(%eax)      # 重新保存 signal 位图信息➔current->signal。
117         incl %ecx                   # 将信号调整为从 1 开始的数(1-32)。
118         pushl %ecx                  # 信号值入栈作为调用 do_signal 的参数之一。
119         call _do_signal             # 调用 C 函数信号处理程序(kernel/signal.c,82)
120         popl %eax                   # 弹出信号值。
121 3:     popl %eax
122         popl %ebx
123         popl %ecx
```

```
124         popl %edx
125         pop %fs
126         pop %es
127         pop %ds
128         iret
129
    #### int16 -- 下面这段代码处理协处理器发出的出错信号。跳转执行 C 函数 math_error()
    # (kernel/math/math_emulate.c,82)，返回后将跳转到 ret_from_sys_call 处继续执行。
130 .align 2
131 _coprocessor_error:
132         push %ds
133         push %es
134         push %fs
135         pushl %edx
136         pushl %ecx
137         pushl %ebx
138         pushl %eax
139         movl $0x10,%eax             # ds,es 置为指向内核数据段。
140         mov %ax,%ds
141         mov %ax,%es
142         movl $0x17,%eax             # fs 置为指向局部数据段（出错程序的数据段）。
143         mov %ax,%fs
144         pushl $ret_from_sys_call    # 把下面调用返回的地址入栈。
145         jmp _math_error             # 执行 C 函数 math_error()(kernel/math/math_emulate.c,37)
146
    #### int7 -- 设备不存在或协处理器不存在(Coprocessor not available)。
    # 如果控制寄存器 CR0 的 EM 标志置位，则当 CPU 执行一个 ESC 转义指令时就会引发该中断，这样就
    # 可以有机会让这个中断处理程序模拟 ESC 转义指令（169 行）。
    # CR0 的 TS 标志是在 CPU 执行任务转换时设置的。TS 可以用来确定什么时候协处理器中的内容（上下文）
    # 与 CPU 正在执行的任务不匹配了。当 CPU 在运行一个转义指令时发现 TS 置位了，就会引发该中断。
    # 此时就应该恢复新任务的协处理器执行状态（165 行）。参见(kernel/sched.c,77)中的说明。
    # 该中断最后将转移到标号 ret_from_sys_call 处执行下去（检测并处理信号）。
147 .align 2
148 _device_not_available:
149         push %ds
150         push %es
151         push %fs
152         pushl %edx
153         pushl %ecx
154         pushl %ebx
155         pushl %eax
156         movl $0x10,%eax             # ds,es 置为指向内核数据段。
157         mov %ax,%ds
158         mov %ax,%es
159         movl $0x17,%eax             # fs 置为指向局部数据段（出错程序的数据段）。
160         mov %ax,%fs
161         pushl $ret_from_sys_call    # 把下面跳转或调用的返回地址入栈。
162         clts                        # clear TS so that we can use math
163         movl %cr0,%eax
164         testl $0x4,%eax             # EM (math emulation bit)
                                        # 如果不是 EM 引起的中断，则恢复新任务协处理器状态，
165         je _math_state_restore      # 执行 C 函数 math_state_restore()(kernel/sched.c,77)。
166         pushl %ebp
```

```
167         pushl %esi
168         pushl %edi
169         call _math_emulate      # 调用 C 函数 math_emulate(kernel/math/math_emulate.c,18)。
170         popl %edi
171         popl %esi
172         popl %ebp
173         ret                     # 这里的 ret 将跳转到 ret_from_sys_call(101 行)。
174
    #### int32 -- (int 0x20) 时钟中断处理程序。中断频率被设置为 100Hz(include/linux/sched.h,5),
    # 定时芯片 8253/8254 是在(kernel/sched.c,406)处初始化的。因此这里 jiffies 每 10 毫秒加 1。
    # 这段代码将 jiffies 增 1，发送结束中断指令给 8259 控制器，然后用当前特权级作为参数调用
    # C 函数 do_timer(long CPL)。当调用返回时转去检测并处理信号。
175 .align 2
176 _timer_interrupt:
177         push %ds                # save ds,es and put kernel data space
178         push %es                # into them. %fs is used by _system_call
179         push %fs
180         pushl %edx              # we save %eax,%ecx,%edx as gcc doesn't
181         pushl %ecx              # save those across function calls. %ebx
182         pushl %ebx              # is saved as we use that in ret_sys_call
183         pushl %eax
184         movl $0x10,%eax         # ds,es 置为指向内核数据段。
185         mov %ax,%ds
186         mov %ax,%es
187         movl $0x17,%eax         # fs 置为指向局部数据段（出错程序的数据段）。
188         mov %ax,%fs
189         incl _jiffies
    # 由于初始化中断控制芯片时没有采用自动 EOI，所以这里需要发指令结束该硬件中断。
190         movb $0x20,%al          # EOI to interrupt controller #1
191         outb %al,$0x20          # 操作命令字 OCW2 送 0x20 端口。
    # 下面 3 句从选择符中取出发生中断时代码的当前特权级别(0 或 3)并压入堆栈，作为 do_timer 的参数。
192         movl CS(%esp),%eax
193         andl $3,%eax            # %eax is CPL (0 or 3, 0=supervisor)
194         pushl %eax
    # do_timer(cpl)执行任务切换、计时等工作，在 kernel/sched.c,305 行实现。
195         call _do_timer          # 'do_timer(long CPL)' does everything from
196         addl $4,%esp            # task switching to accounting ...
197         jmp ret_from_sys_call
198
    #### 这是 sys_execve()系统调用。取中断调用程序的代码指针作为参数调用 C 函数 do_execve()。
    # do_execve()在(fs/exec.c,182)。
199 .align 2
200 _sys_execve:
201         lea EIP(%esp),%eax
202         pushl %eax
203         call _do_execve
204         addl $4,%esp            # 丢弃调用时压入栈的 EIP 值。
205         ret
206
    #### sys_fork()调用，用于创建子进程，是 system_call 功能 2。原形在 include/linux/sys.h 中。
    # 首先调用 C 函数 find_empty_process()，取得一个进程号 pid。若返回负数则说明目前任务数组
    # 已满。然后调用 copy_process()复制进程。
207 .align 2
```

```
208 _sys_fork:
209         call _find_empty_process    # 调用 find_empty_process()(kernel/fork.c,135)。
210         testl %eax,%eax
211         js 1f
212         push %gs
213         pushl %esi
214         pushl %edi
215         pushl %ebp
216         pushl %eax
217         call _copy_process          # 调用 C 函数 copy_process()(kernel/fork.c,68)。
218         addl $20,%esp               # 丢弃这里所有压栈内容。
219 1:      ret
220
    #### int 46 -- (int 0x2E) 硬盘中断处理程序，响应硬件中断请求 IRQ14。
    # 当请求的硬盘操作完成或出错就会发出此中断信号。(参见 kernel/blk_drv/hd.c)。
    # 首先向 8259A 中断控制从芯片发送结束硬件中断指令(EOI)，然后取变量 do_hd 中的函数指针放入 edx
    # 寄存器中，并置 do_hd 为 NULL，接着判断 edx 函数指针是否为空。如果为空，则给 edx 赋值指向
    # unexpected_hd_interrupt()，用于显示出错信息。随后向 8259A 主芯片送 EOI 指令，并调用 edx 中
    # 指针指向的函数: read_intr()、write_intr()或 unexpected_hd_interrupt()。
221 _hd_interrupt:
222         pushl %eax
223         pushl %ecx
224         pushl %edx
225         push %ds
226         push %es
227         push %fs
228         movl $0x10,%eax             # ds,es 置为内核数据段。
229         mov %ax,%ds
230         mov %ax,%es
231         movl $0x17,%eax             # fs 置为调用程序的局部数据段。
232         mov %ax,%fs
    # 由于初始化中断控制芯片时没有采用自动 EOI，所以这里需要发指令结束该硬件中断。
233         movb $0x20,%al
234         outb %al,$0xA0              # EOI to interrupt controller #1    # 送从 8259A。
235         jmp 1f                      # give port chance to breathe
236 1:      jmp 1f                      # 延时作用。
237 1:      xorl %edx,%edx
238         xchgl _do_hd,%edx           # do_hd 定义为一个函数指针，将被赋值 read_intr()或
                                        # write_intr()函数地址。(kernel/blk_drv/hd.c)
                                        # 放到 edx 寄存器后就将 do_hd 指针变量置为 NULL。
239         testl %edx,%edx             # 测试函数指针是否为 Null。
240         jne 1f                      # 若空，则使指针指向 C 函数 unexpected_hd_interrupt()。
241         movl $_unexpected_hd_interrupt,%edx    # (kernel/blk_drv/hdc,237)。
242 1:      outb %al,$0x20              # 送主 8259A 中断控制器 EOI 指令（结束硬件中断）。
243         call *%edx                  # "interesting" way of handling intr.
244         pop %fs                     # 上句调用 do_hd 指向的 C 函数。
245         pop %es
246         pop %ds
247         popl %edx
248         popl %ecx
249         popl %eax
250         iret
251
```

```
    #### int38 -- (int 0x26) 软盘驱动器中断处理程序，响应硬件中断请求 IRQ6。
    # 其处理过程与上面对硬盘的处理基本一样。(kernel/blk_drv/floppy.c)。
    # 首先向 8259A 中断控制器主芯片发送 EOI 指令，然后取变量 do_floppy 中的函数指针放入 eax
    # 寄存器中，并置 do_floppy 为 NULL，接着判断 eax 函数指针是否为空。如为空，则给 eax 赋值指向
    # unexpected_floppy_interrupt ()，用于显示出错信息。随后调用 eax 指向的函数: rw_interrupt,
    # seek_interrupt,recal_interrupt,reset_interrupt 或 unexpected_floppy_interrupt。
252 _floppy_interrupt:
253         pushl %eax
254         pushl %ecx
255         pushl %edx
256         push %ds
257         push %es
258         push %fs
259         movl $0x10,%eax             # ds,es 置为内核数据段。
260         mov %ax,%ds
261         mov %ax,%es
262         movl $0x17,%eax             # fs 置为调用程序的局部数据段。
263         mov %ax,%fs
264         movb $0x20,%al              # 送主 8259A 中断控制器 EOI 指令（结束硬件中断）。
265         outb %al,$0x20              # EOI to interrupt controller #1
266         xorl %eax,%eax
267         xchgl _do_floppy,%eax       # do_floppy 为一函数指针，将被赋值实际处理 C 函数程序，
                                        # 放到 eax 寄存器后就将 do_floppy 指针变量置空。
268         testl %eax,%eax             # 测试函数指针是否=NULL?
269         jne 1f                    # 若空，则使指针指向 C 函数 unexpected_floppy_interrupt()。
270         movl $_unexpected_floppy_interrupt,%eax
271 1:      call *%eax                  # "interesting" way of handling intr.
272         pop %fs                     # 上句调用 do_floppy 指向的函数。
273         pop %es
274         pop %ds
275         popl %edx
276         popl %ecx
277         popl %eax
278         iret
279
    #### int 39 -- (int 0x27) 并行口中断处理程序，对应硬件中断请求信号 IRQ7。
    # 本版本内核还未实现。这里只是发送 EOI 指令。
280 _parallel_interrupt:
281         pushl %eax
282         movb $0x20,%al
283         outb %al,$0x20
284         popl %eax
285         iret
```

5.6.3 其他信息

5.6.3.1 GNU 汇编语言的 32 位寻址方式

GNU 汇编语言采用的是 AT&T 的汇编语言语法。32 位寻址的正规格式为：

AT&T: immed32(basepointer, indexpointer, indexscale)

Intel: [basepointer + indexpointer*indexscal + immed32]

该格式寻址位置的计算方式为：immed32 + basepointer + indexpointer * indexscale

在应用时，并不需要写出所有这些字段，但 immed32 和 basepointer 之中必须有一个存在。以下是一些例子。

o 对一个指定的 C 语言变量寻址：

AT&T: _booga Intel: [_booga]

注意：变量前的下划线是从汇编程序中得到静态（全局）C 变量(booga)的方法。

o 对寄存器内容指向的位置寻址：

AT&T: (%eax) Intel: [eax]

o 通过寄存器中的内容作为基址寻址一个变量：

AT&T: _variable(%eax) Intel: [eax + _variable]

o 在一个整数数组中寻址一个值（比例值为 4）：

AT&T: _array(,%eax,4) Intel: [eax*4 + _array]

o 使用直接数寻址偏移量：

对于 C 语言：*(p+1) 其中 p 是字符的指针 char *

AT&T: 则 AT&T 格式：1(%eax) 其中 eax 中是 p 的值。 Intel: [eax+1]

o 在一个 8 字节为一个记录的数组中寻址指定的字符。其中 eax 中是指定的记录号，ebx 中是指定字符在记录中的偏移址：

AT&T: _array(%ebx,%eax,8) Intel: [ebx + eax*8 + _array]

5.6.3.2 增加系统调用功能

如果想为 Linux 0.11 增加新的系统调用功能，那么需要做以下一些事情。

首先在相关程序中编制出新系统调用的处理函数，例如名称为 sys_sethostname()的函数。该函数用于修改系统的计算机名称。通常这个处理函数可以放置在 kernel/sys.c 程序中。另外，由于使用了 thisname 结构，因此还需要把 sys_uname()中的 thisname 结构（218-220 行）移动到该函数外部。

```
#define MAXHOSTNAMELEN 8
int sys_sethostname(char *name, int len)
{
        int     i;

        if (!suser())
                return -EPERM;
        if (len > MAXHOSTNAMELEN)
                return -EINVAL;
        for (i=0; i < len; i++) {
                if ((thisname.nodename[i] = get_fs_byte(name+i)) == 0)
                        break;
        }
        if (thisname.nodename[i]) {
                thisname.nodename[i>MAXHOSTNAMELEN ? MAXHOSTNAMELEN : i] = 0;
        }
        return 0;
}
```

然后在 include/unistd.h 文件中增加新系统调用功能号和原型定义。例如可以在第 131 行后面加入功能号，在 251 行后面添加原型定义：

```
// 新系统调用功能号。
#define __NR_sethostname    72
// 新系统调用函数原型。
int sethostname(char *name, int len);
```

接着在 include/linux/sys.h 文件中加入外部函数声明并在函数指针表 sys_call_table 末端插入新系统调用处理函数的名称，见如下所示。注意，一定要严格按照功能号顺序排列函数名。

```
extern int sys_sethostname();
// 函数指针数组表。
fn_ptr sys_call_table[] = { sys_setup, sys_exit,sys_fork, sys_read,
 ...,
sys_setreuid, sys_setregid, sys_sethostname };
```

然后修改 system_call.s 程序第 61 行，将内核系统调用总数 nr_system_calls 增 1。此时可以重新编译内核。最后参照 lib/目录下库函数的实现方法在 libc 库中增加新的系统调用库函数 sethostname()。

```
#define __LIBRARY__
#include <unistd.h>

_syscall2(int, sethostname, char *, name, int, len);
```

5.7 mktime.c 程序

5.7.1 功能描述

该该程序只有一个函数 mktime()，仅供内核使用。计算从 1970 年 1 月 1 日 0 时起到开机当日经过的秒数，作为开机时间。

5.7.2 代码注释

程序 5-5 linux/kernel/mktime.c 程序

```
 1 /*
 2  *  linux/kernel/mktime.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <time.h>            // 时间头文件，定义了标准时间数据结构 tm 和一些处理时间函数原型。
 8
 9 /*
10  * This isn't the library routine, it is only used in the kernel.
11  * as such, we don't care about years<1970 etc, but assume everything
12  * is ok. Similarly, TZ etc is happily ignored. We just do everything
```

```
13  * as easily as possible. Let's find something public for the library
14  * routines (although I think minix times is public).
15  */
16 /*
17  * PS. I hate whoever though up the year 1970 - couldn't they have gotten
18  * a leap-year instead? I also hate Gregorius, pope or no. I'm grumpy.
19  */
    /*
     * 这不是库函数，它仅供内核使用。因此我们不关心小于 1970 年的年份等，但假定一切均很正常。
     * 同样，时间区域 TZ 问题也先忽略。我们只是尽可能简单地处理问题。最好能找到一些公开的库函数
     * （尽管我认为 minix 的时间函数是公开的）。
     * 另外，我恨那个设置 1970 年开始的人 - 难道他们就不能选择从一个闰年开始？我恨格里高利历、
     * 罗马教皇、主教，我什么都不在乎。我是个脾气暴躁的人。
     */
20 #define MINUTE 60                    // 1 分钟的秒数。
21 #define HOUR (60*MINUTE)             // 1 小时的秒数。
22 #define DAY (24*HOUR)                // 1 天的秒数。
23 #define YEAR (365*DAY)               // 1 年的秒数。
24
25 /* interestingly, we assume leap-years */
   /* 有趣的是我们考虑进了闰年 */
   // 下面以年为界限，定义了每个月开始时的秒数时间。
26 static int month[12] = {
27         0,
28         DAY*(31),
29         DAY*(31+29),
30         DAY*(31+29+31),
31         DAY*(31+29+31+30),
32         DAY*(31+29+31+30+31),
33         DAY*(31+29+31+30+31+30),
34         DAY*(31+29+31+30+31+30+31),
35         DAY*(31+29+31+30+31+30+31+31),
36         DAY*(31+29+31+30+31+30+31+31+30),
37         DAY*(31+29+31+30+31+30+31+31+30+31),
38         DAY*(31+29+31+30+31+30+31+31+30+31+30)
39 };
40
   // 该函数计算从 1970 年 1 月 1 日 0 时起到开机当日经过的秒数，作为开机时间。
   // 参数 tm 中各字段已经在 init/main.c 中被赋值，信息取自 CMOS。
41 long kernel_mktime(struct tm * tm)
42 {
43         long res;
44         int year;
45
46         year = tm->tm_year - 70;             // 从 70 年到现在经过的年数(2 位表示方式)，
                                                // 因此会有 2000 年问题。
47 /* magic offsets (y+1) needed to get leapyears right.*/
   /* 为了获得正确的闰年数，这里需要这样一个魔幻值(y+1) */
48         res = YEAR*year + DAY*((year+1)/4); // 这些年经过的秒数时间 + 每个闰年时多 1 天
49         res += month[tm->tm_mon];            // 的秒数时间，再加上当年到当月时的秒数。
50 /* and (y+2) here. If it wasn't a leap-year, we have to adjust */
   /* 以及(y+2)。如果(y+2)不是闰年，那么我们就必须进行调整(减去一天的秒数时间)。*/
51         if (tm->tm_mon>1 && ((year+2)%4))
```

```
52                  res -= DAY;
53          res += DAY*(tm->tm_mday-1);          // 再加上本月过去的天数的秒数时间。
54          res += HOUR*tm->tm_hour;             // 再加上当天过去的小时数的秒数时间。
55          res += MINUTE*tm->tm_min;            // 再加上 1 小时内过去的分钟数的秒数时间。
56          res += tm->tm_sec;                   // 再加上 1 分钟内已过的秒数。
57          return res;                          // 即等于从 1970 年以来经过的秒数时间。
58  }
59
```

5.7.3 其他信息

5.7.3.1 闰年时间的计算方法

闰年的基本计算方法是：

如果 y 能被 4 除尽且不能被 100 除尽，或者能被 400 除尽，则 y 是闰年。

5.8 sched.c 程序

5.8.1 功能描述

sched.c 是内核中有关任务调度管理的程序，其中包括有关调度的基本函数(sleep_on()、wakeup()、schedule()等)以及一些简单的系统调用函数（比如 getpid()）。系统时钟中断处理过程中调用的定时函数 do_timer()也被放置在本程序中。另外，为了便于软盘驱动器定时处理的编程，Linus 也将有关软盘定时操作的几个函数放到了这里。

这几个基本函数的代码虽然不长，但有些抽象，比较难以理解。好在市面上有许多教科书对此解释得都很清楚，因此可以参考其他书籍对这些函数的讨论。这些也就是教科书上重点讲述的对象，否则理论书籍也就没有什么好讲的了☺。这里仅对调度函数 schedule()作一些详细说明。

schedule()函数首先对所有任务（进程）进行检测，唤醒任何一个已经得到信号的任务。具体方法是针对任务数组中的每个任务，检查其报警定时值 alarm。如果任务的 alarm 时间已经过期(alarm<jiffies), 则在它的信号位图中设置 SIGALRM 信号，然后清 alarm 值。jiffies 是系统从开机开始算起的滴答数（10ms/滴答）。在 sched.h 中定义。如果进程的信号位图中除去被阻塞的信号外还有其他信号，并且任务处于可中断睡眠状态（TASK_INTERRUPTIBLE），则置任务为就绪状态（TASK_RUNNING）。

随后是调度函数的核心处理部分。这部分代码根据进程的时间片和优先权调度机制，来选择随后要执行的任务。它首先循环检查任务数组中的所有任务，根据每个就绪态任务剩余执行时间的值 counter，选取该值最大的一个任务，并利用 switch_to()函数切换到该任务。若所有就绪态任务的该值都等于零，表示此刻所有任务的时间片都已经运行完，于是就根据任务的优先权值 priority，重置每个任务的运行时间片值 counter，再重新执行循环检查所有任务的执行时间片值。

另两个值得一提的函数是自动进入睡眠函数 sleep_on()和唤醒函数 wake_up()，这两个函数虽然很短，却要比 schedule()函数难理解。这里用图示的方法加以解释。简单地说，sleep_on()函数的主要功能是当一个进程（或任务）所请求的资源正忙或不在内存中时暂时切换出去，放在等待队列中等待一段时间。当切换回来后再继续运行。放入等待队列的方式是利用了函数中的 tmp 指针作为各个正在等待任务的联系。

函数中共牵涉到对三个任务指针操作：*p、tmp 和 current，*p 是等待队列头指针，如文件系统内存 i 节点的 i_wait 指针、内存缓冲操作中的 buffer_wait 指针等；tmp 是临时指针；current 是当前任务指针。对于这些指针在内存中的变化情况我们可以用图 5-6 的示意图说明。图中的长条表示内存字节序列。

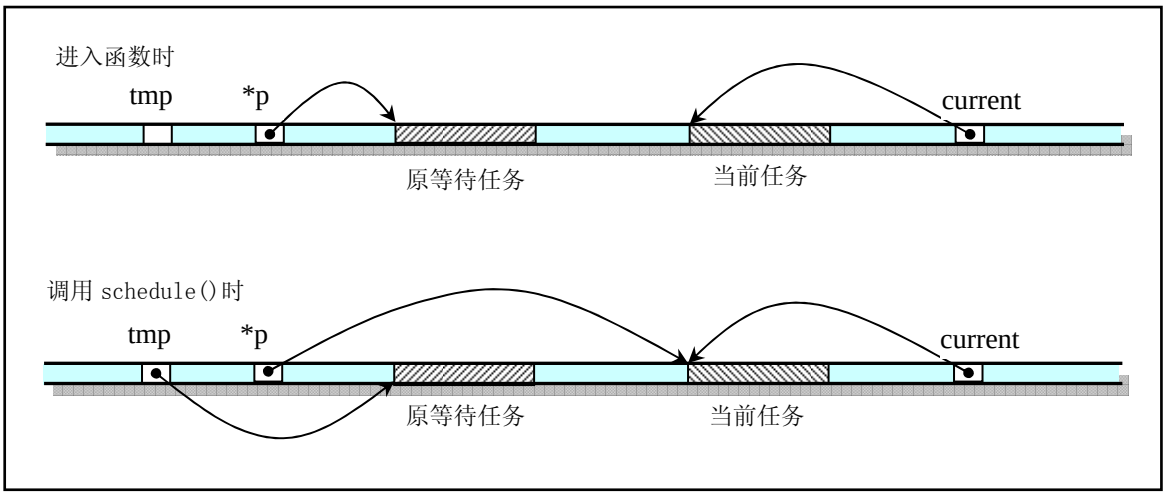

图 5-6 sleep_on()函数中指针变化示意图。

当刚进入该函数时，队列头指针*p 指向已经在等待队列中等待的任务结构（进程描述符）。当然，在系统刚开始执行时，等待队列上无等待任务。因此上图中原等待任务在刚开始时是不存在的，此时*p 指向 NULL。通过指针操作，在调用调度程序之前，队列头指针指向了当前任务结构，而函数中的临时指针 tmp 指向了原等待任务。从而通过该临时指针的作用，在几个进程为等待同一资源而多次调用该函数时，程序就隐式地构筑出一个等待队列。从图 5-7 中我们可以更容易地理解 sleep_on()函数的等待队列形成过程。图中示出了当向队列头部插入第三个任务时的情况。

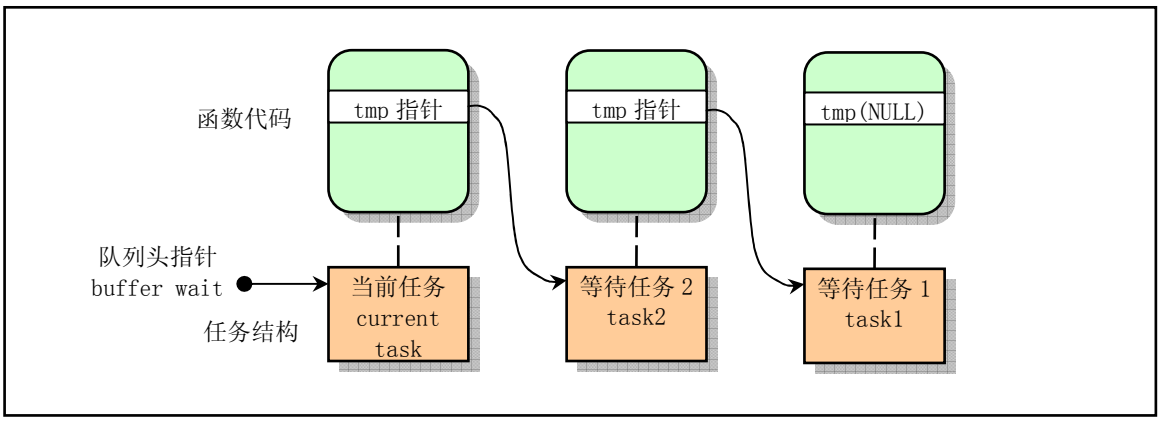

图 5-7 sleep_on()函数的隐式任务等待队列。

在插入等待队列后，sleep_on()函数就会调用 schedule()函数去执行别的进程。当进程被唤醒而重新执行时就会执行后续的语句，把比它早进入等待队列的一个进程唤醒。

唤醒操作函数 wake_up()把正在等待可用资源的指定任务置为就绪状态。该函数是一个通用唤醒函数。在有些情况下，例如读取磁盘上的数据块，由于等待队列中的任何一个任务都可能被先唤醒，因此还需要把被唤醒任务结构的指针置空。这样，在其后进入睡眠的进程被唤醒而又重新执行 sleep_on()时，就无需唤醒该进程了。

还有一个函数 interruptible_sleep_on()，它的结构与 sleep_on()的基本类似，只是在进行调度之前是把当前任务置成了可中断等待状态，并在本任务被唤醒后还需要判断队列上是否有后来的等待任务，若有，则调度它们先运行。在内核 0.12 开始，这两个函数被合二为一，仅用任务的状态作为参数来区分这两种情况。

在阅读本文件的代码时，最好同时参考包含文件 include/kernel/sched.h 文件中的注释，以便更清晰

地了解内核的调度机理。

5.8.2 代码注释

程序 5-6 linux/kernel/sched.c

```
 1 /*
 2  *  linux/kernel/sched.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * 'sched.c' is the main kernel file.  It contains scheduling primitives
 9  * (sleep_on, wakeup, schedule etc) as well as a number of simple system
10  * call functions (type getpid(), which just extracts a field from
11  * current-task
12  */
   /*
    * 'sched.c'是主要的内核文件。其中包括有关调度的基本函数(sleep_on、wakeup、schedule 等)以及
    * 一些简单的系统调用函数（比如 getpid()，仅从当前任务中获取一个字段）。
    */
13 #include <linux/sched.h>  // 调度程序头文件。定义了任务结构 task_struct、第 1 个初始任务
                             // 的数据。还有一些以宏的形式定义的有关描述符参数设置和获取的
                             // 嵌入式汇编函数程序。
14 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
15 #include <linux/sys.h>    // 系统调用头文件。含有 72 个系统调用 C 函数处理程序,以'sys_'开头。
16 #include <linux/fdreg.h>  // 软驱头文件。含有软盘控制器参数的一些定义。
17 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
18 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
19 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
20
21 #include <signal.h>       // 信号头文件。定义信号符号常量，sigaction 结构，操作函数原型。
22
   // 取信号 nr 在信号位图中对应位的二进制数值。信号编号 1-32。比如信号 5 的位图数值 = 1<<(5-1)
   // = 16 = 00010000b。
23 #define _S(nr) (1<<((nr)-1))
   // 除了 SIGKILL 和 SIGSTOP 信号以外其他都是可阻塞的(…10111111111011111111b)。
24 #define _BLOCKABLE (~(_S(SIGKILL) | _S(SIGSTOP)))
25
   // 显示任务号 nr 的进程号、进程状态和内核堆栈空闲字节数（大约）。
26 void show_task(int nr,struct task_struct * p)
27 {
28         int i,j = 4096-sizeof(struct task_struct);
29
30         printk("%d: pid=%d, state=%d, ",nr,p->pid,p->state);
31         i=0;
32         while (i<j && !((char *)(p+1))[i])  // 检测指定任务数据结构以后等于 0 的字节数。
33                 i++;
34         printk("%d (of %d) chars free in kernel stack\n\r",i,j);
35 }
36
   // 显示所有任务的任务号、进程号、进程状态和内核堆栈空闲字节数（大约）。
```

```
37 void show_stat(void)
38 {
39         int i;
40
   // NR_TASKS 是系统能容纳的最大进程(任务)数量(64 个)，定义在 include/kernel/sched.h 第 4 行。
41         for (i=0;i<NR_TASKS;i++)
42                 if (task[i])
43                         show_task(i,task[i]);
44 }
45
   // PC 机 8253 定时芯片的输入时钟频率约为 1.193180MHz。Linux 内核希望定时器发出中断的频率是
   // 100Hz，也即每 10ms 发出一次时钟中断。因此这里的 LATCH 是设置 8253 芯片的初值，参见 407 行。
46 #define LATCH (1193180/HZ)
47
48 extern void mem_use(void);          // [??]没有任何地方定义和引用该函数。
49
50 extern int timer_interrupt(void);  // 时钟中断处理程序(kernel/system_call.s,176)。
51 extern int system_call(void);      // 系统调用中断处理程序(kernel/system_call.s,80)。
52
   // 每个任务（进程）在内核态运行时都有自己的内核态堆栈。这里定义了任务的内核态堆栈结构。
53 union task_union {                 // 定义任务联合（任务结构成员和 stack 字符数组成员）。
54         struct task_struct task;    // 因为一个任务的数据结构与其内核态堆栈放在同一内存页
55         char stack[PAGE_SIZE];      // 中，所以从堆栈段寄存器 ss 可以获得其数据段选择符。
56 };
57
58 static union task_union init_task = {INIT_TASK,};  // 定义初始任务的数据(sched.h 中)。
59
   // 从开机开始算起的滴答数时间值（10ms/滴答）。定义在 include/linux/sched.h 第 139 行。
   // 前面的限定符 volatile，英文解释是易变、不稳定的意思。这里是要求 gcc 不要对该变量进行优化
   // 处理，也不要挪动位置，因为也许别的程序会来修改它的值。
60 long volatile jiffies=0;
61 long startup_time=0;                              // 开机时间。从 1970:0:0:0 开始计时的秒数。
62 struct task_struct *current = &(init_task.task); // 当前任务指针（初始化为初始任务）。
63 struct task_struct *last_task_used_math = NULL;  // 使用过协处理器任务的指针。
64
65 struct task_struct * task[NR_TASKS] = {&(init_task.task), };  // 定义任务指针数组。
66
   // 定义用户堆栈，4K。在内核初始化操作完成以后将被用作任务 0 的用户态堆栈。
67 long user_stack [ PAGE_SIZE>>2 ] ;
68
   // 该结构用于设置堆栈 ss:esp（数据段选择符，指针），见 head.s，第 23 行。指针指在最后一项。
69 struct {
70         long * a;
71         short b;
72         } stack_start = { & user_stack [PAGE_SIZE>>2] , 0x10 };
73 /*
74  *  'math_state_restore()' saves the current math information in the
75  * old math state array, and gets the new ones from the current task
76  */
   /*
    * 将当前协处理器内容保存到老协处理器状态数组中，并将当前任务的协处理器
    * 内容加载进协处理器。
    */
```

```
    // 当任务被调度交换过以后，该函数用以保存原任务的协处理器状态（上下文）并恢复新调度进来的
    // 当前任务的协处理器执行状态。
 77 void math_state_restore()
 78 {
 79         if (last_task_used_math == current) // 如果任务没变则返回(上一个任务就是当前任务)。
 80                 return;                     // 这里所指的"上一个任务"是刚被交换出去的任务。
 81         __asm__("fwait");                   // 在发送协处理器命令之前要先发 WAIT 指令。
 82         if (last_task_used_math) {          // 如果上个任务使用了协处理器，则保存其状态。
 83                 __asm__("fnsave %0"::"m" (last_task_used_math->tss.i387));
 84         }
 85         last_task_used_math=current;        // 现在，last_task_used_math 指向当前任务，
                                                // 以备当前任务被交换出去时使用。
 86         if (current->used_math) {           // 如果当前任务用过协处理器，则恢复其状态。
 87                 __asm__("frstor %0"::"m" (current->tss.i387));
 88         } else {                            // 否则的话说明是第一次使用，
 89                 __asm__("fninit"::);        // 于是就向协处理器发初始化命令，
 90                 current->used_math=1;       // 并设置使用了协处理器标志。
 91         }
 92 }
 93
 94 /*
 95  *  'schedule()' is the scheduler function. This is GOOD CODE! There
 96  * probably won't be any reason to change this, as it should work well
 97  * in all circumstances (ie gives IO-bound processes good response etc).
 98  * The one thing you might take a look at is the signal-handler code here.
 99  *
100  *   NOTE!!  Task 0 is the 'idle' task, which gets called when no other
101  * tasks can run. It can not be killed, and it cannot sleep. The 'state'
102  * information in task[0] is never used.
103  */
    /*
     * 'schedule()'是调度函数。这是个很好的代码！没有任何理由对它进行修改，因为它可以在所有的
     * 环境下工作（比如能够对 IO-边界处理很好的响应等）。只有一件事值得留意，那就是这里的信号
     * 处理代码。
     *   注意！！任务 0 是个闲置('idle')任务，只有当没有其他任务可以运行时才调用它。它不能被杀
     * 死，也不能睡眠。任务 0 中的状态信息'state'是从来不用的。
     */
104 void schedule(void)
105 {
106         int i,next,c;
107         struct task_struct ** p;            // 任务结构指针的指针。
108
109 /* check alarm, wake up any interruptible tasks that have got a signal */
    /* 检测 alarm（进程的报警定时值），唤醒任何已得到信号的可中断任务 */
110
    // 从任务数组中最后一个任务开始检测 alarm。
111         for(p = &LAST_TASK ; p > &FIRST_TASK ; --p)
112                 if (*p) {
    // 如果设置过任务的定时值 alarm，并且已经过期(alarm<jiffies),则在信号位图中置 SIGALRM 信号，
    // 即向任务发送 SIGALARM 信号。然后清 alarm。该信号的默认操作是终止进程。
    // jiffies 是系统从开机开始算起的滴答数（10ms/滴答）。定义在 sched.h 第 139 行。
113                         if ((*p)->alarm && (*p)->alarm < jiffies) {
114                                 (*p)->signal |= (1<<(SIGALRM-1));
```

```
115                                     (*p)->alarm = 0;
116                             }
    // 如果信号位图中除被阻塞的信号外还有其他信号，并且任务处于可中断状态，则置任务为就绪状态。
    // 其中'~(_BLOCKABLE & (*p)->blocked)'用于忽略被阻塞的信号，但 SIGKILL 和 SIGSTOP 不能被阻塞。
117                         if (((*p)->signal & ~(_BLOCKABLE & (*p)->blocked)) &&
118                         (*p)->state==TASK_INTERRUPTIBLE)
119                                 (*p)->state=TASK_RUNNING;       //置为就绪（可执行）状态。
120                 }
121
122 /* this is the scheduler proper: */
    /* 这里是调度程序的主要部分 */
123
124         while (1) {
125                 c = -1;
126                 next = 0;
127                 i = NR_TASKS;
128                 p = &task[NR_TASKS];
    // 这段代码也是从任务数组的最后一个任务开始循环处理，并跳过不含任务的数组槽。比较每个就绪
    // 状态任务的 counter（任务运行时间的递减滴答计数）值，哪一个值大，运行时间还不长，next 就
    // 指向哪个的任务号。
129                 while (--i) {
130                         if (!*--p)
131                                 continue;
132                         if ((*p)->state == TASK_RUNNING && (*p)->counter > c)
133                                 c = (*p)->counter, next = i;
134                 }
    // 如果比较得出有 counter 值不等于 0 的结果，则退出 124 行开始的循环，执行任务切换（141 行）。
135                 if (c) break;
    // 否则就根据每个任务的优先权值，更新每一个任务的 counter 值，然后回到 125 行重新比较。
    // counter 值的计算方式为 counter = counter /2 + priority。这里计算过程不考虑进程的状态。
136                 for(p = &LAST_TASK ; p > &FIRST_TASK ; --p)
137                         if (*p)
138                                 (*p)->counter = ((*p)->counter >> 1) +
139                                                 (*p)->priority;
140         }
    // 切换到任务号为 next 的任务运行。在 126 行 next 被初始化为 0。因此若系统中没有任何其他任务
    // 可运行时，则 next 始终为 0。因此调度函数会在系统空闲时去执行任务 0。此时任务 0 仅执行
    // pause()系统调用，并又会调用本函数。
141         switch_to(next);            // 切换到任务号为 next 的任务，并运行之。
142 }
143
    //// pause()系统调用。转换当前任务的状态为可中断的等待状态，并重新调度。
    // 该系统调用将导致进程进入睡眠状态，直到收到一个信号。该信号用于终止进程或者使进程调用
    // 一个信号捕获函数。只有当捕获了一个信号，并且信号捕获处理函数返回，pause()才会返回。
    // 此时 pause()返回值应该是-1，并且 errno 被置为 EINTR。这里还没有完全实现（直到 0.95 版）。
144 int sys_pause(void)
145 {
146         current->state = TASK_INTERRUPTIBLE;
147         schedule();
148         return 0;
149 }
150
    // 把当前任务置为不可中断的等待状态，并让睡眠队列头的指针指向当前任务。
```

```
    // 只有明确地唤醒时才会返回。该函数提供了进程与中断处理程序之间的同步机制。
    // 函数参数*p 是放置等待任务的队列头指针。
151 void sleep_on(struct task_struct **p)
152 {
153         struct task_struct *tmp;
154
    // 若指针无效，则退出。（指针所指的对象可以是 NULL，但指针本身不会为 0）。
155         if (!p)
156                 return;
    // 如果当前任务是任务 0，则死机(impossible!)。
157         if (current == &(init_task.task))
158                 panic("task[0] trying to sleep");
    // 让 tmp 指向已经在等待队列上的任务(如果有的话)，例如 inode->i_wait。并且将睡眠队列头的
    // 等待指针指向当前任务。
159         tmp = *p;
160         *p = current;
    // 将当前任务置为不可中断的等待状态，并执行重新调度。
161         current->state = TASK_UNINTERRUPTIBLE;
162         schedule();
    // 只有当这个等待任务被唤醒时，调度程序才又返回到这里，则表示进程已被明确地唤醒。
    // 既然大家都在等待同样的资源，那么在资源可用时，就有必要唤醒所有等待该资源的进程。该函数
    // 嵌套调用，也会嵌套唤醒所有等待该资源的进程。
163         if (tmp)                // 若在其前还存在等待的任务，则也将其置为就绪状态（唤醒）。
164                 tmp->state=0;
165 }
166
    // 将当前任务置为可中断的等待状态，并放入*p 指定的等待队列中。
167 void interruptible_sleep_on(struct task_struct **p)
168 {
169         struct task_struct *tmp;
170
171         if (!p)
172                 return;
173         if (current == &(init_task.task))
174                 panic("task[0] trying to sleep");
175         tmp=*p;
176         *p=current;
177 repeat: current->state = TASK_INTERRUPTIBLE;
178         schedule();
    // 如果等待队列中还有等待任务，并且队列头指针所指向的任务不是当前任务时，则将该等待任务置为
    // 可运行的就绪状态，并重新执行调度程序。当指针*p 所指向的不是当前任务时，表示在当前任务被放
    // 入队列后，又有新的任务被插入等待队列中，因此，就应该同时也将所有其他的等待任务置为可运行
    // 状态。
179         if (*p && *p != current) {
180                 (**p).state=0;
181                 goto repeat;
182         }
    // 下面一句代码有误，应该是*p = tmp，让队列头指针指向其余等待任务，否则在当前任务之前插入
    // 等待队列的任务均被抹掉了。当然，同时也需删除 192 行上的语句。
183         *p=NULL;
184         if (tmp)
185                 tmp->state=0;
186 }
```

```
187
    // 唤醒指定任务*p。
188 void wake_up(struct task_struct **p)
189 {
190         if (p && *p) {
191                 (**p).state=0;    // 置为就绪（可运行）状态。
192                 *p=NULL;
193         }
194 }
195
196 /*
197  * OK, here are some floppy things that shouldn't be in the kernel
198  * proper. They are here because the floppy needs a timer, and this
199  * was the easiest way of doing it.
200  */
    /*
     * 好了，从这里开始是一些有关软盘的子程序，本不应该放在内核的主要部分中的。将它们放在这里
     * 是因为软驱需要定时处理，而放在这里是最方便的。
     */
    // 这里用于软驱定时处理的代码是 201 - 262 行。在阅读这段代码之前请先看一下块设备一章中有关
    // 软盘驱动程序（floppy.c）后面的说明。或者到阅读软盘块设备驱动程序时在来看这段代码。
    // 其中时间单位：1 个滴答 = 1/100 秒。
    // 下面数组存放等待软驱马达启动到正常转速的进程指针。数组索引 0-3 分别对应软驱 A-D。
201 static struct task_struct * wait_motor[4] = {NULL,NULL,NULL,NULL};
    // 下面数组分别存放各软驱马达启动所需要的滴答数。程序中默认启动时间为 50 个滴答（0.5 秒）。
202 static int  mon_timer[4]={0,0,0,0};
    // 下面数组分别存放各软驱在马达停转之前需维持的时间。程序中设定为 10000 个滴答（100 秒）。
203 static int moff_timer[4]={0,0,0,0};
    // 对应软驱控制器中当前数字输出寄存器。该寄存器每位的定义如下：
    // 位 7-4：分别控制驱动器 D-A 马达的启动。1 - 启动；0 - 关闭。
    // 位 3  ：1 - 允许 DMA 和中断请求；0 - 禁止 DMA 和中断请求。
    // 位 2  ：1 - 启动软盘控制器；0 - 复位软盘控制器。
    // 位 1-0：00 - 11，用于选择控制的软驱 A-D。
204 unsigned char current_DOR = 0x0C;          // 这里设置初值为：允许 DMA 和中断请求、启动 FDC。
205
    // 指定软驱启动到正常运转状态所需等待时间。
    // nr -- 软驱号(0-3)，返回值为滴答数。
206 int ticks_to_floppy_on(unsigned int nr)
207 {
208         extern unsigned char selected;    // 选中软驱标志(kernel/blk_drv/floppy.c,122)。
209         unsigned char mask = 0x10 << nr;  // 所选软驱对应数字输出寄存器中启动马达比特位。
210                                           // mask 高 4 位是各软驱启动马达标志。
211         if (nr>3)
212                 panic("floppy_on: nr>3"); // 系统最多有 4 个软驱。
    // 首先预先设置好指定软驱 nr 停转之前需要经过的时间（100 秒）。然后取当前 DOR 寄存器值到
    // 临时变量 mask 中，并把指定软驱的马达启动标志置位。
213         moff_timer[nr]=10000;             /* 100 s = very big :-) */  // 停转维持时间。
214         cli();                            /* use floppy_off to turn it off */
215         mask |= current_DOR;
    // 如果当前没有选择软驱，则首先复位其他软驱的选择位，然后置指定软驱选择位。
216         if (!selected) {
217                 mask &= 0xFC;
218                 mask |= nr;
```

```
219         }
    // 如果数字输出寄存器的当前值与要求的值不同，则向 FDC 数字输出端口输出新值(mask)，并且如果
    // 要求启动的马达还没有启动，则置相应软驱的马达启动定时器值(HZ/2 = 0.5 秒或 50 个滴答)。若
    // 已经启动，则再设置启动定时为 2 个滴答，能满足下面 do_floppy_timer()中先递减后判断的要求。
    // 执行本次定时代码的要求即可。此后更新当前数字输出寄存器变量 current_DOR。
220         if (mask != current_DOR) {
221                 outb(mask,FD_DOR);
222                 if ((mask ^ current_DOR) & 0xf0)
223                         mon_timer[nr] = HZ/2;
224                 else if (mon_timer[nr] < 2)
225                         mon_timer[nr] = 2;
226                 current_DOR = mask;
227         }
228         sti();
229         return mon_timer[nr];           // 最后返回启动马达所需的时间值。
230 }
231
    // 等待指定软驱马达启动所需的一段时间，然后返回。
    // 设置指定软驱的马达启动到正常转速所需的延时，然后睡眠等待。在定时中断过程中会一直递减
    // 判断这里设定的延时值。当延时到期，就会唤醒这里的等待进程。
232 void floppy_on(unsigned int nr)
233 {
234         cli();  // 关中断。
235         while (ticks_to_floppy_on(nr))    // 如果马达启动定时还没到，就一直把当前进程置
236                 sleep_on(nr+wait_motor);  // 为不可中断睡眠状态并放入等待马达运行的队列中。
237         sti();  // 开中断。
238 }
239
    // 置关闭相应软驱马达停转定时器（3 秒）。
    // 若不使用该函数明确关闭指定的软驱马达，则在马达开启 100 秒之后也会被关闭。
240 void floppy_off(unsigned int nr)
241 {
242         moff_timer[nr]=3*HZ;
243 }
244
    // 软盘定时处理子程序。更新马达启动定时值和马达关闭停转计时值。该子程序会在时钟定时中断
    // 过程中被调用，因此系统每经过一个滴答(10ms)就会被调用一次，随时更新马达开启或停转定时
    // 器的值。如果某一个马达停转定时到，则将数字输出寄存器马达启动位复位。
245 void do_floppy_timer(void)
246 {
247         int i;
248         unsigned char mask = 0x10;
249
250         for (i=0 ; i<4 ; i++,mask <<= 1) {
251                 if (!(mask & current_DOR))              // 如果不是 DOR 指定的马达则跳过。
252                         continue;
253                 if (mon_timer[i]) {
254                         if (!--mon_timer[i])
255                                 wake_up(i+wait_motor); // 如果马达启动定时到则唤醒进程。
256                 } else if (!moff_timer[i]) {            // 如果马达停转定时到则
257                         current_DOR &= ~mask;           // 复位相应马达启动位，并
258                         outb(current_DOR,FD_DOR);       // 更新数字输出寄存器。
259                 } else
```

```
260                         moff_timer[i]--;                // 马达停转计时递减。
261         }
262 }
263
264 #define TIME_REQUESTS 64            // 最多可有 64 个定时器链表。
265
    // 定时器链表结构和定时器数组。
266 static struct timer_list {
267         long jiffies;               // 定时滴答数。
268         void (*fn)();               // 定时处理程序。
269         struct timer_list * next;   // 下一个定时器。
270 } timer_list[TIME_REQUESTS], * next_timer = NULL;
271
    // 添加定时器。输入参数为指定的定时值(滴答数)和相应的处理程序指针。
    // 软盘驱动程序（floppy.c）利用该函数执行启动或关闭马达的延时操作。
    // jiffies - 以 10 毫秒计的滴答数；*fn()- 定时时间到时执行的函数。
272 void add_timer(long jiffies, void (*fn)(void))
273 {
274         struct timer_list * p;
275
    // 如果定时处理程序指针为空，则退出。
276         if (!fn)
277                 return;
278         cli();
    // 如果定时值<=0，则立刻调用其处理程序。并且该定时器不加入链表中。
279         if (jiffies <= 0)
280                 (fn)();
281         else {
    // 从定时器数组中，找一个空闲项。
282                 for (p = timer_list ; p < timer_list + TIME_REQUESTS ; p++)
283                         if (!p->fn)
284                                 break;
    // 如果已经用完了定时器数组，则系统崩溃☺。
285                 if (p >= timer_list + TIME_REQUESTS)
286                         panic("No more time requests free");
    // 向定时器数据结构填入相应信息。并链入链表头
287                 p->fn = fn;
288                 p->jiffies = jiffies;
289                 p->next = next_timer;
290                 next_timer = p;
    // 链表项按定时值从小到大排序。在排序时减去排在前面需要的滴答数，这样在处理定时器时只要
    // 查看链表头的第一项的定时是否到期即可。[[?? 这段程序好象没有考虑周全。如果新插入的定时
    // 器值小于原来头一个定时器值时，也应该将其后面的定时值减去新的第 1 个的定时值。]]
291                 while (p->next && p->next->jiffies < p->jiffies) {
292                         p->jiffies -= p->next->jiffies;
293                         fn = p->fn;
294                         p->fn = p->next->fn;
295                         p->next->fn = fn;
296                         jiffies = p->jiffies;
297                         p->jiffies = p->next->jiffies;
298                         p->next->jiffies = jiffies;
299                         p = p->next;
300                 }
```

```
301         }
302         sti();
303 }
304
    //// 时钟中断 C 函数处理程序，在 kernel/system_call.s 中的_timer_interrupt（176 行）被调用。
    // 参数 cpl 是当前特权级 0 或 3，是时钟中断发生时正被执行的代码选择符中的特权级。cpl=0 时表
    // 示中断发生时正在执行内核代码；cpl=3 时表示中断发生时正在执行用户代码。
    // 对于一个进程由于执行时间片用完时，则进行任务切换。并执行一个计时更新工作。
305 void do_timer(long cpl)
306 {
307         extern int beepcount;  // 扬声器发声时间滴答数(kernel/chr_drv/console.c,697)
308         extern void sysbeepstop(void);  // 关闭扬声器(kernel/chr_drv/console.c,691)
309
    // 如果发声计数次数到，则关闭发声。(向 0x61 口发送命令，复位位 0 和 1。位 0 控制 8253
    // 计数器 2 的工作，位 1 控制扬声器)。
310         if (beepcount)
311                 if (!--beepcount)
312                         sysbeepstop();
313
    // 如果当前特权级(cpl)为 0（最高，表示是内核程序在工作），则将内核程序运行时间 stime 递增；
    // [ Linus 把内核程序统称为超级用户(supervisor)的程序，见 system_call.s,193 行上的英文注释]
    // 如果 cpl > 0，则表示是一般用户程序在工作，增加 utime。
314         if (cpl)
315                 current->utime++;
316         else
317                 current->stime++;
318
    // 如果有定时器存在，则将链表第 1 个定时器的值减 1。如果已等于 0，则调用相应的处理程序，
    // 并将该处理程序指针置为空。然后去掉该项定时器。
319         if (next_timer) {                       // next_timer 是定时器链表的头指针(见 270 行)。
320                 next_timer->jiffies--;
321                 while (next_timer && next_timer->jiffies <= 0) {
322                         void (*fn)(void);   // 这里插入了一个函数指针定义！！！☹
323
324                         fn = next_timer->fn;
325                         next_timer->fn = NULL;
326                         next_timer = next_timer->next;
327                         (fn)();                 // 调用处理函数。
328                 }
329         }
    // 如果当前软盘控制器 FDC 的数字输出寄存器中马达启动位有置位的，则执行软盘定时程序(245 行)。
330         if (current_DOR & 0xf0)
331                 do_floppy_timer();
332         if ((--current->counter)>0) return;  // 如果进程运行时间还没完，则退出。
333         current->counter=0;
334         if (!cpl) return;                       // 对于内核态程序，不依赖 counter 值进行调度。
335         schedule();
336 }
337
    // 系统调用功能 - 设置报警定时时间值(秒)。
    // 如果参数 seconds>0，则设置该新的定时值并返回原定时值。否则返回 0。
338 int sys_alarm(long seconds)
339 {
```

```
340         int old = current->alarm;
341
342         if (old)
343                 old = (old - jiffies) / HZ;
344         current->alarm = (seconds>0)?(jiffies+HZ*seconds):0;
345         return (old);
346 }
347
    // 取当前进程号 pid。
348 int sys_getpid(void)
349 {
350         return current->pid;
351 }
352
    // 取父进程号 ppid。
353 int sys_getppid(void)
354 {
355         return current->father;
356 }
357
    // 取用户号 uid。
358 int sys_getuid(void)
359 {
360         return current->uid;
361 }
362
    // 取 euid。
363 int sys_geteuid(void)
364 {
365         return current->euid;
366 }
367
    // 取组号 gid。
368 int sys_getgid(void)
369 {
370         return current->gid;
371 }
372
    // 取 egid。
373 int sys_getegid(void)
374 {
375         return current->egid;
376 }
377
    // 系统调用功能 -- 降低对 CPU 的使用优先权（有人会用吗？☺）。
    // 应该限制 increment 为大于 0 的值，否则可使优先权增大！！
378 int sys_nice(long increment)
379 {
380         if (current->priority-increment>0)
381                 current->priority -= increment;
382         return 0;
383 }
384
```

```
    // 调度程序的初始化子程序。
385 void sched_init(void)
386 {
387         int i;
388         struct desc_struct * p;  // 描述符表结构指针。
389
390         if (sizeof(struct sigaction) != 16)         // sigaction 是存放有关信号状态的结构。
391                 panic("Struct sigaction MUST be 16 bytes");
    // 在全局描述符表中设置初始任务（任务 0）的任务状态段描述符和局部数据表描述符。
    // FIRST_TSS_ENTRY 和 FIRST_LDT_ENTRY 的值分别是 4 和 5，定义在 include/linux/sched.h 中；
    // gdt 是一个描述符表数组（include/linux/head.h），实际上对应程序 head.s 中第 234 行上的
    // 全局描述符表基址（_gdt）。因此 gdt+FIRST_TSS_ENTRY 即为 gdt[FIRST_TSS_ENTRY]（gdt[4]），
    // 也即 gdt 数组第 4 项的地址。参见 include/asm/system.h,第 65 行开始。
392         set_tss_desc(gdt+FIRST_TSS_ENTRY,&(init_task.task.tss));
393         set_ldt_desc(gdt+FIRST_LDT_ENTRY,&(init_task.task.ldt));
    // 清任务数组和描述符表项（注意 i=1 开始，所以初始任务的描述符还在）。
394         p = gdt+2+FIRST_TSS_ENTRY;
395         for(i=1;i<NR_TASKS;i++) {
396                 task[i] = NULL;
397                 p->a=p->b=0;
398                 p++;
399                 p->a=p->b=0;
400                 p++;
401         }
402 /* Clear NT, so that we won't have troubles with that later on */
    /* 清除标志寄存器中的位 NT，这样以后就不会有麻烦 */
    // NT 标志用于控制程序的递归调用(Nested Task)。当 NT 置位时，那么当前中断任务执行
    // iret 指令时就会引起任务切换。NT 指出 TSS 中的 back_link 字段是否有效。
403         __asm__("pushfl ; andl $0xffffbfff,(%esp) ; popfl");  // 复位 NT 标志。
    // 将任务 0 的 TSS 加载到任务寄存器 tr。将局部描述符表加载到局部描述符表寄存器。
    // 注意！！是将 GDT 中相应 LDT 描述符的选择符加载到 ldtr。只明确加载这一次，以后新任务
    // LDT 的加载，是 CPU 根据 TSS 中的 LDT 项自动加载。
404         ltr(0);
405         lldt(0);
    // 下面代码用于初始化 8253 定时器。通道 0，选择工作方式 3，二进制计数方式。通道 0 的输出引脚
    // 接在中断控制主芯片的 IRQ0 上，它每 10 毫秒发出一个 IRQ0 请求。LATCH 是初始定时计数值。
406         outb_p(0x36,0x43);              /* binary, mode 3, LSB/MSB, ch 0 */
407         outb_p(LATCH & 0xff , 0x40);    /* LSB */   // 定时值低字节。
408         outb(LATCH >> 8 , 0x40);        /* MSB */   // 定时值高字节。
    // 设置时钟中断处理程序句柄（设置时钟中断门）。
409         set_intr_gate(0x20,&timer_interrupt);
    // 修改中断控制器屏蔽码，允许时钟中断。
410         outb(inb_p(0x21)&~0x01,0x21);
    // 设置系统调用中断门。
411         set_system_gate(0x80,&system_call);
    // 这两个设置中断描述符表 IDT 中描述符的宏在文件 include/asm/system.h 中第 33 行、39 行处。
    // 两者的区别请参见 system.h 文件开始处的说明。
412 }
413
```

5.8.3 其他信息

5.8.3.1 软盘驱动器控制器

有关对软盘控制器进行编程的详细说明请参见第 6 章程序 floppy.c 后面的解说，这里仅对其作一简单介绍。在对软盘控制器进行编程时需要访问 4 个端口。这些端口分别对应控制器上一个或多个寄存器。对于 1.2M 的软盘控制器有以下一些端口。

表 5 - 3 软盘控制器端口

I/O 端口	读写性	寄存器名称
0x3f2	只写	数字输出寄存器(数字控制寄存器)
0x3f4	只读	FDC 主状态寄存器
0x3f5	读/写	FDC 数据寄存器
0x3f7	只读	数字输入寄存器
0x3f7	只写	磁盘控制寄存器(传输率控制)

数字输出端口（数字控制端口）是一个 8 位寄存器，它控制驱动器马达开启、驱动器选择、启动/复位 FDC 以及允许/禁止 DMA 及中断请求。

FDC 的主状态寄存器也是一个 8 位寄存器，用于反映软盘控制器 FDC 和软盘驱动器 FDD 的基本状态。通常，在 CPU 向 FDC 发送命令之前或从 FDC 获取操作结果之前，都要读取主状态寄存器的状态位，以判别当前 FDC 数据寄存器是否就绪，以及确定数据传送的方向。

FDC 的数据端口对应多个寄存器（只写型命令寄存器和参数寄存器、只读型结果寄存器），但任一时刻只能有一个寄存器出现在数据端口 0x3f5。在访问只写型寄存器时，主状态控制的 DIO 方向位必须为 0（CPU → FDC），访问只读型寄存器时则反之。在读取结果时只有在 FDC 不忙之后才算读完结果，通常结果数据最多有 7 个字节。

软盘控制器共可以接受 15 条命令。每个命令均经历三个阶段：命令阶段、执行阶段和结果阶段。

命令阶段是 CPU 向 FDC 发送命令字节和参数字节。每条命令的第一个字节总是命令字节（命令码）。其后跟着 0--8 字节的参数。

执行阶段是 FDC 执行命令规定的操作。在执行阶段 CPU 是不加干预的，一般是通过 FDC 发出中断请求获知命令执行的结束。如果 CPU 发出的 FDC 命令是传送数据，则 FDC 可以以中断方式或 DMA 方式进行。中断方式每次传送 1 字节。DMA 方式是在 DMA 控制器管理下，FDC 与内存进行数据的传输直至全部数据传送完。此时 DMA 控制器会将传输字节计数终止信号通知 FDC，最后由 FDC 发出中断请求信号告知 CPU 执行阶段结束。

结果阶段是由 CPU 读取 FDC 数据寄存器返回值，从而获得 FDC 命令执行的结果。返回结果数据的长度为 0--7 字节。对于没有返回结果数据的命令，则应向 FDC 发送检测中断状态命令获得操作的状态。

5.9 signal.c 程序

5.9.1 功能描述

signal.c 程序涉及内核中所有有关信号处理的函数。在 UNIX 系统中，信号是一种“软件中断”处理机制。有许多较为复杂的程序会使用到信号。信号机制提供了一种处理异步事件的方法。例如，用户在终端键盘上键入 ctrl-C 组合键来终止一个程序的执行。该操作就会产生一个 SIGINT（SIGnal INTerrupt）信号，并被发送到当前前台执行的进程中；当进程设置的一个报警时钟到期时，系统就会向进程发送一

个 SIGALRM 信号；当发生硬件异常时，系统也会向正在执行的进程发送相应的信号。另外，一个进程也可以向另一个进程发送信号。例如使用 kill()函数向同组的子进程发送终止执行信号。

信号处理机制在很早的 UNIX 系统中就已经有了，但那些早期 UNIX 内核中信号处理的方法并不是那么可靠。信号可能会被丢失，而且在处理紧要区域代码时进程有时很难关闭一个指定的信号，后来 POSIX 提供了一种可靠处理信号的方法。为了保持兼容性，本程序中还是提供了两种处理信号的方法。

在内核代码中通常使用一个无符号长整数（32 位）中的比特位来表示各种不同信号。因此最多可表示 32 个不同的信号。在本版 Linux 内核中，定义了 22 种不同的信号。其中 20 种信号是 POSIX.1 标准中规定的所有信号，另外 2 种是 Linux 的专用信号：SIGUNUSED（未定义）和 SIGSTKFLT（堆栈错），前者可表示系统目前还不支持的所有其他信号种类。这 22 种信号的具体名称和定义可参考程序后的信号列表，也可参阅 include/signal.h 头文件。

对于进程来说，当收到一个信号时，可以由三种不同的处理或操作方式。

1. 忽略该信号。大多数信号都可以被进程忽略。但有两个信号忽略不掉：SIGKILL 和 SIGSTOP。不能被忽略掉的原因是能为超级用户提供一个确定的方法来终止或停止指定的任何进程。另外，若忽略掉某些硬件异常而产生的信号（例如被 0 除），则进程的行为或状态就可能变得不可知了。
2. 捕获该信号。为了进行该操作，我们必须首先告诉内核在指定的信号发生时调用我们自定义的信号处理函数。在该处理函数中，我们可以做任何操作，当然也可以什么不做，起到忽略该信号的同样作用。自定义信号处理函数来捕获信号的一个例子是：如果我们在程序执行过程中创建了一些临时文件，那么我们就可以定义一个函数来捕获 SIGTERM（终止执行）信号，并在该函数中做一些清理临时文件的工作。SIGTERM 信号是 kill 命令发送的默认信号。
3. 执行默认操作。内核为每种信号都提供一种默认操作。通常这些默认操作就是终止进程的执行。参见程序后信号列表中的说明。

本程序给出了设置和获取进程信号阻塞码（屏蔽码）系统调用函数 sys_ssetmask()和 sys_sgetmask()、信号处理系统调用 sys_signal()（即传统信号处理函数 signal()）、修改进程在收到特定信号时所采取的行动的系统调用 sys_sigaction()(既可靠信号处理函数 sigaction())以及在系统调用中断处理程序中处理信号的函数 do_signal()。有关信号操作的发送信号函数 send_sig()和通知父进程函数 tell_father()则被包含在另一个程序（exit.c）中。程序中的名称前缀 sig 均是信号 signal 的简称。

signal()和 sigaction()的功能比较类似，都是更改信号原处理句柄（handler ,或称为处理程序）。但 signal()就是内核操作上述传统信号处理的方式，在某些特殊时刻可能会造成信号丢失。

在 include/signal.h 头文件第 55 行上，signal()函数原型声明如下：

```
void (*signal(int signr, void (*handler)(int)))(int);
```

这个 signal()函数有两个参数。一个指定需要捕获的信号 signr；另外一个是新的信号处理函数指针（新的信号处理句柄）void (*handler)(int)。新的信号处理句柄是一个无返回值且具有一个整型参数的函数指针，该整型参数用于当指定信号发生时内核将其传递给处理句柄。

signal()函数会给信号值是 signr 的信号安装一个新的信号处理函数句柄 handler，该信号句柄可以是用户指定的一个信号处理函数，也可以是内核提供的特定的函数指针 SIG_IGN 或 SIG_DFL。

当指定的信号到来时，如果相关的信号处理句柄被设置成 SIG_IGN，那么该信号就会被忽略掉。如果信号句柄是 SIG_DFL，那么就会执行该信号的默认操作。否则，如果信号句柄被设置成用户的一个信号处理函数，那么内核首先会把该信号句柄被复位成其默认句柄，或者会执行与实现相关的信号阻塞操作，然后会调用执行指定的信号处理函数。

signal()函数会返回原信号处理句柄，这个返回的句柄也是一个无返回值且具有一个整型参数的函数指针。并且在新句柄被调用执行过一次后，信号处理句柄又会被恢复成默认处理句柄值 SIG_DFL。

在 include/signal.h 文件中（第 45 行起），默认句柄 SIG_DFL 和忽略处理句柄 SIG_IGN 的定义是：

```
#define SIG_DFL      ((void (*)(int))0)
#define SIG_IGN      ((void (*)(int))1)
```

都分别表示无返回值的函数指针，与 signal()函数中第二个参数的要求相同。指针值分别是 0 和 1。这两个指针值逻辑上讲是实际程序中不可能出现的函数地址值。因此在 signal()函数中就可以根据这两个特殊的指针值来判断是否使用默认信号处理句柄或忽略对信号的处理（当然 SIGKILL 和 SIGSTOP 是不能被忽略的）。参见下面程序列表中第 94—98 行的处理过程。

当一个程序被执行时，系统会设置其处理所有信号的方式为 SIG_DFL 或 SIG_IGN。另外，当程序 fork()一个子进程时，子进程会继承父进程的信号处理方式（信号屏蔽码）。因此父进程对信号的设置和处理方式在子进程中同样有效。

为了能连续地捕获一个指定的信号，signal()函数的通常使用方式例子如下。

```
void sig_handler(int signr)          // 信号句柄。
{
    signal(SIGINT, sig_handler);     // 为处理下一次信号发生而重新设置自己的处理句柄。
    ...
}

main ()
{
    signal(SIGINT, sig_handler);     // 主程序中设置自己的信号处理句柄。
    ...
}
```

signal()函数不可靠的原因在于当信号已经发生而进入自己设置的信号处理函数中，但在重新再一次设置自己的处理句柄之前，在这段时间内有可能又有一个信号发生。但是此时系统已经把处理句柄设置成默认值。因此就有可能造成信号丢失。

sigaction()函数采用了 sigaction 数据结构来保存指定信号的信息，它是一种可靠的内核处理信号的机制，它可以让我们方便地查看或修改指定信号的处理句柄。该函数是 signal()函数的一个超集。该函数在 include/signal.h 头文件（第 66 行）中的声明为：

```
int sigaction(int sig, struct sigaction *act, struct sigaction *oldact);
```

其中参数 sig 是我们需要查看或修改其信号处理句柄的信号，后两个参数是 sigaction 结构的指针。当参数 act 指针不是 NULL 时，就可以根据 act 结构中的信息修改指定信号的行为。当 oldact 不为空时，内核就会在该结构中返回信号原来的设置信息。sigaction 结构见如下所示：

```
48 struct sigaction {
49         void (*sa_handler)(int);          // 信号处理句柄。
50         sigset_t sa_mask;                 // 信号的屏蔽码，可以阻塞指定的信号集。
51         int sa_flags;                     // 信号选项标志。
52         void (*sa_restorer)(void);        // 信号恢复函数指针（系统内部使用）。
53 };
```

当修改一个信号的处理方法时，如果处理句柄 sa_handler 不是默认处理句柄 SIG_DFL 或忽略处理句

柄 SIG_IGN，那么在 sa_handler 处理句柄可被调用前，sa_mask 字段就指定了需要加入到进程信号屏蔽位图中的一个信号集。如果信号处理句柄返回，系统就会恢复进程原来的信号屏蔽位图。这样在一个信号句柄被调用时，我们就可以阻塞指定的一些信号。当信号句柄被调用时，新的信号屏蔽位图会自动地把当前发送的信号包括进去，阻塞该信号的继续发送。从而在我们处理一指定信号期间能确保阻塞同一个信号而不让其丢失，直到此次处理完毕。另外，在一个信号被阻塞期间而又多次发生时通常只保存其一个样例，也即在阻塞解除时对于阻塞的多个同一信号只会再调用一次信号处理句柄。在我们修改了一个信号的处理句柄之后，除非再次更改，否则就一直使用该处理句柄。这与传统的 signal()函数不一样。signal()函数会在一处理句柄结束后将其恢复成信号的默认处理句柄。

sigaction 结构中的 sa_flags 用于指定其他一些处理信号的选项，这些选项的定义请参见 include/signal.h 文件中（第 36-39 行）的说明。

sigaction 结构中的最后一个字段和 sys_signal()函数的参数 restorer 是一函数指针。它在编译连接程序时由 Libc 函数库提供，用于在信号处理程序结束后清理用户态堆栈，并恢复系统调用存放在 eax 中的返回值，见下面详细说明。

do_signal()函数是内核系统调用(int 0x80)中断处理程序中对信号的预处理程序。在进程每次调用系统调用时，若进程已收到信号，则该函数就会把信号的处理句柄（即对应的信号处理函数）插入到用户程序堆栈中。这样，在当前系统调用结束返回后就会立刻执行信号句柄程序，然后再继续执行用户的程序，见图 5-8 所示。

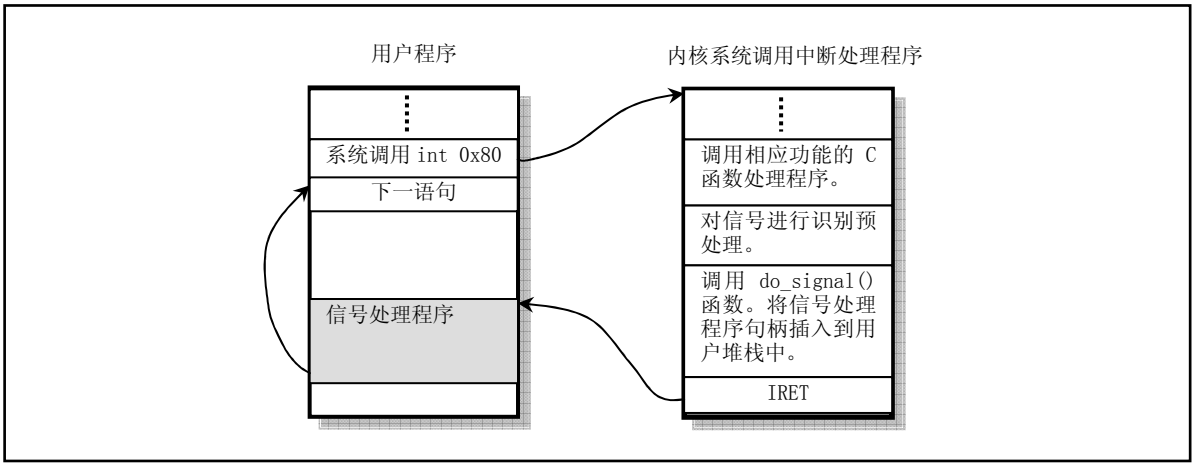

图 5-8 信号处理程序的调用方式。

在把信号处理程序的参数插入到用户堆栈中之前，do_signal()函数首先会把用户程序堆栈指针向下扩展 longs 个长字(参见下面程序中 106 行)，然后将相关的参数添入其中，参见图 5-9 所示。由于 do_signal()函数从 104 行开始的代码比较难以理解，下面我们将对其进行详细描述。

在用户程序调用系统调用刚进入内核时，该进程的内核态堆栈上会由 CPU 自动压入如图 5-9 中所示的内容，也即：用户程序的 SS 和 ESP 以及用户程序中下一条指令的执行点位置 CS 和 EIP。在处理完此次指定的系统调用功能并准备调用 do_signal()时（也即 system_call.s 程序 118 行之后），内核态堆栈中的内容见图 5-10 中左边所示。因此 do_signal()的参数即是这些在内核态堆栈上的内容。

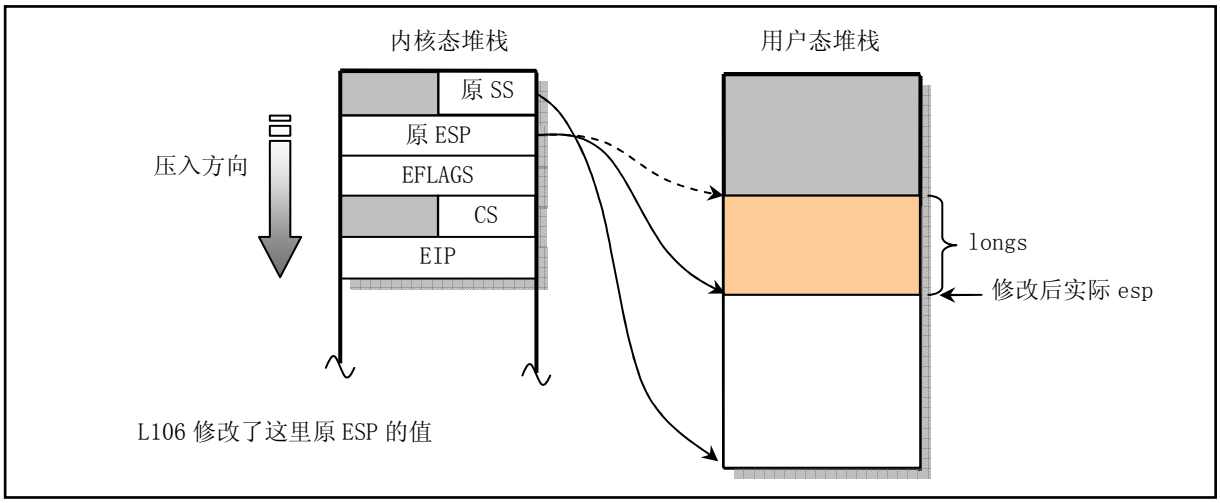

图 5-9 do_signal()函数对用户堆栈的修改

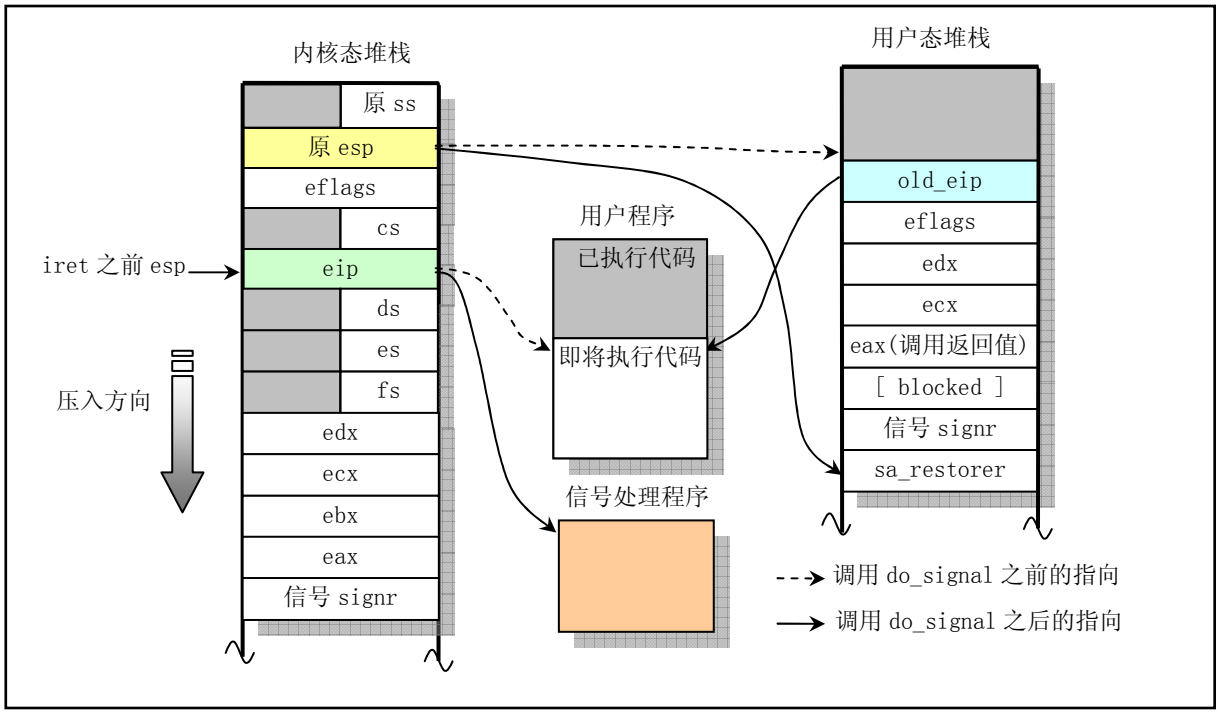

图 5-10 do_signal()函数修改用户态堆栈的具体过程

在 do_signal()处理完两个默认信号句柄（SIG_IGN 和 SIG_DFL）之后，若用户自定义了信号处理程序（信号句柄 sa_handler），则从 104 行起 do_signal()开始准备把用户自定义的句柄插入用户态堆栈中。它首先把内核态堆栈中原用户程序的返回执行点指针 eip 保存为 old_eip，然后将该 eip 替换成指向自定义句柄 sa_handler，也即让图中内核态堆栈中的 eip 指向 sa_handler。接下来通过把内核态中保存的“原 esp”减去 longs 值，把用户态堆栈向下扩展了 7 或 8 个长字空间。最后把内核堆栈上的一些寄存器内容复制到了这个空间中，见图中右边所示。

总共往用户态堆栈上放置了 7 到 8 个值，我们现在来说明这些值的含义以及放置这些值的原因。

old_eip 即是原用户程序的返回地址，它是在内核堆栈上 eip 被替换成信号句柄地址之前保留下来的。eflags、edx 和 ecx 是原用户程序在调用系统调用之前的值，基本上也是调用系统调用的参数，在系统调用返回后仍然需要恢复这些用户程序的寄存器值。eax 中保存有系统调用的返回值。如果所处理的信号还允许收到本身，则堆栈上还存放有该进程的阻塞码 blocked。下一个是信号 signr 值。

最后一个是信号活动恢复函数的指针 sa_restorer。这个恢复函数不是由用户设定的，因为在用户定义 signal()函数时只提供了一个信号值 signr 和一个信号处理句柄 handler。

下面是为 SIGINT 信号设置自定义信号处理句柄的一个简单例子，默认情况下，按下 Ctrl-C 组合键会产生 SIGINT 信号。

```
#include <signal.h>
#include <stdio.h>
#include <unistd.h>

void handler(int sig)                          // 信号处理句柄。
{
    printf("The signal is %d\n", sig);
    (void) signal(SIGINT, SIG_DFL);            // 恢复 SIGINT 信号的默认处理句柄。（实际上内核会
}                                              // 自动恢复默认值，但对于其他系统未必如此）

int main()
{
    (void) signal(SIGINT, handler);            // 设置 SIGINT 的用户自定义信号处理句柄。
    while (1) {
        printf("Signal test.\n");
        sleep(1);                              // 等待 1 秒钟。
    }
}
```

其中，信号处理函数 handler()会在信号 SIGINT 出现时被调用执行。该函数首先输出一条信息，然后会把 SIGINT 信号的处理过程设置成默认信号处理句柄。因此在第二次按下 Ctrl-C 组合键时，SIG_DFL 会让该程序结束运行。

那么 sa_restorer 这个函数是从哪里来的呢？其实它是由函数库提供的。在 Libc 函数库中有它的函数，定义如下：

```
.globl ____sig_restore
.globl ____masksig_restore
# 若没有 blocked 则使用这个 restorer 函数
____sig_restore:
    addl $4,%esp            # 丢弃信号值 signr
    popl %eax               # 恢复系统调用返回值。
    popl %ecx               # 恢复原用户程序寄存器值。
    popl %edx
    popfl                   # 恢复用户程序时的标志寄存器。
    ret
# 若有 blocked 则使用下面这个 restorer 函数，blocked 供 ssetmask 使用。
____masksig_restore:
    addl $4,%esp            # 丢弃信号值 signr
    call ____ssetmask       # 设置信号屏蔽码 old blocking
    addl $4,%esp            # 丢弃 blocked 值。
    popl %eax
    popl %ecx
    popl %edx
    popfl
    ret
```

该函数的主要作用是为了在信号处理程序结束后，恢复用户程序执行系统调用后的返回值和一些寄存器内容，并清除作为信号处理程序参数的信号值 signr。在编译连接用户自定义的信号处理函数时，编译程序会把这个函数插入到用户程序中。由该函数负责清理在信号处理程序执行完后恢复用户程序的寄存器值和系统调用返回值，就好象没有运行过信号处理程序，而是直接从系统调用中返回的。

最后说明一下执行的流程。在 do_signel()执行完后，system_call.s 将会把进程内核态堆栈上 eip 以下的所有值弹出堆栈。在执行了 iret 指令之后，CPU 将把内核态堆栈上的 cs:eip、eflags 以及 ss:esp 弹出，恢复到用户态去执行程序。由于 eip 已经被替换为指向信号句柄，因此，此刻即会立即执行用户自定义的信号处理程序。在该信号处理程序执行完后，通过 ret 指令，CPU 会把控制权移交给 sa_restorer 所指向的恢复程序去执行。而 sa_restorer 程序会做一些用户态堆栈的清理工作，也即会跳过堆栈上的信号值 signr，并把系统调用后的返回值 eax 和寄存器 ecx、edx 以及标志寄存器 eflags。完全恢复了系统调用后各寄存器和 CPU 的状态。最后通过 sa_restorer 的 ret 指令弹出原用户程序的 eip（也即堆栈上的 old_eip），返回去执行用户程序。

5.9.2 代码注释

程序 5-7 linux/kernel/signal.c

```
1  /*
2   *  linux/kernel/signal.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
8  #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
9  #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
10
11 #include <signal.h>       // 信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
12
13 volatile void do_exit(int error_code);  // 前面的限定符 volatile 要求编译器不要对其进行优化。
14
   // 获取当前任务信号屏蔽位图（屏蔽码）。
15 int sys_sgetmask()
16 {
17         return current->blocked;
18 }
19
   // 设置新的信号屏蔽位图。SIGKILL 不能被屏蔽。返回值是原信号屏蔽位图。
20 int sys_ssetmask(int newmask)
21 {
22         int old=current->blocked;
23
24         current->blocked = newmask & ~(1<<(SIGKILL-1));
25         return old;
26 }
27
   // 复制 sigaction 数据到 fs 数据段 to 处。即从内核空间复制到用户（任务）的数据段中。
28 static inline void save_old(char * from,char * to)
29 {
30         int i;
```

```
31
32          verify_area(to, sizeof(struct sigaction));  // 验证 to 处的内存是否足够。
33          for (i=0 ; i< sizeof(struct sigaction) ; i++) {
34                  put_fs_byte(*from,to);              // 复制到 fs 段。一般是用户数据段。
35                  from++;                         // put_fs_byte()在 include/asm/segment.h 中。
36                  to++;
37          }
38  }
39
    // 把 sigaction 数据从 fs 数据段 from 位置复制到 to 处。即从用户数据空间复制到内核数据段中。
40  static inline void get_new(char * from,char * to)
41  {
42          int i;
43
44          for (i=0 ; i< sizeof(struct sigaction) ; i++)
45                  *(to++) = get_fs_byte(from++);
46  }
47
    // signal()系统调用。类似于 sigaction()。为指定的信号安装新的信号句柄(信号处理程序)。
    // 信号句柄可以是用户指定的函数，也可以是 SIG_DFL（默认句柄）或 SIG_IGN（忽略）。
    // 参数 signum --指定的信号；handler -- 指定的句柄；restorer -恢复函数指针，该函数由 Libc
    // 库提供。用于在信号处理程序结束后恢复系统调用返回时几个寄存器的原有值以及系统调用的返回
    // 值，就好象系统调用没有执行过信号处理程序而直接返回到用户程序一样。
    // 函数返回原信号句柄。
48  int sys_signal(int signum, long handler, long restorer)
49  {
50          struct sigaction tmp;
51
52          if (signum<1 || signum>32 || signum==SIGKILL) // 信号值要在（1-32）范围内，
53                  return -1;                          // 并且不得是 SIGKILL。
54          tmp.sa_handler = (void (*)(int)) handler;     // 指定的信号处理句柄。
55          tmp.sa_mask = 0;                              // 执行时的信号屏蔽码。
56          tmp.sa_flags = SA_ONESHOT | SA_NOMASK;        // 该句柄只使用 1 次后就恢复到默认值，
                                                          // 并允许信号在自己的处理句柄中收到。
57          tmp.sa_restorer = (void (*)(void)) restorer;  // 保存恢复处理函数指针。
58          handler = (long) current->sigaction[signum-1].sa_handler;
59          current->sigaction[signum-1] = tmp;
60          return handler;
61  }
62
    // sigaction()系统调用。改变进程在收到一个信号时的操作。signum 是除了 SIGKILL 以外的任何
    // 信号。[如果新操作(action)不为空]则新操作被安装。如果 oldaction 指针不为空，则原操作
    // 被保留到 oldaction。成功则返回 0，否则为-1。
63  int sys_sigaction(int signum, const struct sigaction * action,
64          struct sigaction * oldaction)
65  {
66          struct sigaction tmp;
67
    // 信号值要在（1-32）范围内，并且信号 SIGKILL 的处理句柄不能被改变。
68          if (signum<1 || signum>32 || signum==SIGKILL)
69                  return -1;
    // 在信号的 sigaction 结构中设置新的操作（动作）。
70          tmp = current->sigaction[signum-1];
```

```
71          get_new((char *) action,
72                  (char *) (signum-1+current->sigaction));
    // 如果 oldaction 指针不为空的话，则将原操作指针保存到 oldaction 所指的位置。
73          if (oldaction)
74                  save_old((char *) &tmp,(char *) oldaction);
    // 如果允许信号在自己的信号句柄中收到，则令屏蔽码为 0，否则设置屏蔽本信号。
75          if (current->sigaction[signum-1].sa_flags & SA_NOMASK)
76                  current->sigaction[signum-1].sa_mask = 0;
77          else
78                  current->sigaction[signum-1].sa_mask |= (1<<(signum-1));
79          return 0;
80  }
81
    // 系统调用的中断处理程序中真正的信号处理程序（在 kernel/system_call.s,119 行）。
    // 该段代码的主要作用是将信号的处理句柄插入到用户程序堆栈中，并在本系统调用结束
    // 返回后立刻执行信号句柄程序，然后继续执行用户的程序。
82  void do_signal(long signr,long eax, long ebx, long ecx, long edx,
83          long fs, long es, long ds,
84          long eip, long cs, long eflags,
85          unsigned long * esp, long ss)
86  {
87          unsigned long sa_handler;
88          long old_eip=eip;
89          struct sigaction * sa = current->sigaction + signr - 1; //current->sigaction[signu-1]。
90          int longs;
91          unsigned long * tmp_esp;
92
93          sa_handler = (unsigned long) sa->sa_handler;
    // 如果信号句柄为 SIG_IGN(忽略)则不对信号进行处理而直接返回；如果句柄为 SIG_DFL(默认处理)，
    // 则如果信号是 SIGCHLD 也直接返回，否则终止进程的执行。
    // 句柄 SIG_IGN 被定义为 1，SIG_DFL 被定义为 0。参见 include/signal.h, 第 45、46 行。
94          if (sa_handler==1)
95                  return;
96          if (!sa_handler) {
97                  if (signr==SIGCHLD)
98                          return;
99                  else
100                         do_exit(1<<(signr-1)); // 为什么以信号位图为参数？不为什么!? ☺
                                                   // 这里应该是 do_exit(1<<(signr))。
101         }
    // 如果该信号句柄只需使用一次，则将该句柄置空(该信号句柄已经保存在 sa_handler 指针中)。
102         if (sa->sa_flags & SA_ONESHOT)
103                 sa->sa_handler = NULL;
    // 下面这段代码将信号处理句柄插入到用户堆栈中，同时也将 sa_restorer,signr,进程屏蔽码(如果
    // SA_NOMASK 没置位),eax,ecx,edx 作为参数以及原调用系统调用的程序返回指针及标志寄存器值
    // 压入堆栈。因此在本次系统调用中断(0x80)返回用户程序时会首先执行用户的信号句柄程序，然后
    // 再继续执行用户程序。

    // 将内核态堆栈上用户调用系统调用的代码指针 eip 指向该信号处理句柄。
104         *(&eip) = sa_handler;
    // 如果允许信号自己的处理句柄收到信号自己，则也需要将进程的阻塞码压入堆栈。
    // 注意，这里 longs 的结果应该选择(7*4):(8*4)，因为堆栈是以 4 字节为单位操作的。
105         longs = (sa->sa_flags & SA_NOMASK)?7:8;
```

```
    // 将原调用程序的用户堆栈指针向下扩展 7（或 8）个长字（用来存放调用信号句柄的参数等），
    // 并检查内存使用情况（例如如果内存超界则分配新页等）。
106         *(&esp) -= longs;
107         verify_area(esp,longs*4);
    // 在用户堆栈中从下到上存放 sa_restorer, 信号 signr, 屏蔽码 blocked(如果 SA_NOMASK 置位),
    // eax, ecx, edx, eflags 和用户程序原代码指针。
108         tmp_esp=esp;
109         put_fs_long((long) sa->sa_restorer,tmp_esp++);
110         put_fs_long(signr,tmp_esp++);
111         if (!(sa->sa_flags & SA_NOMASK))
112                 put_fs_long(current->blocked,tmp_esp++);
113         put_fs_long(eax,tmp_esp++);
114         put_fs_long(ecx,tmp_esp++);
115         put_fs_long(edx,tmp_esp++);
116         put_fs_long(eflags,tmp_esp++);
117         put_fs_long(old_eip,tmp_esp++);
118         current->blocked |= sa->sa_mask;  // 进程阻塞码(屏蔽码)添上 sa_mask 中的码位。
119 }
120
```

5.9.3 其他信息

5.9.3.1 进程信号说明

进程中的信号是用于进程之间通信的一种简单消息，通常是下表中的一个标号数值，并且不携带任何其他的信息。例如当一个子进程终止或结束时，就会产生一个标号为 17 的 SIGCHILD 信号发送给父进程，以通知父进程有关子进程的当前状态。

关于一个进程如何处理收到的信号，一般有两种做法：一是程序的进程不去处理，此时该信号会由系统相应的默认信号处理程序进行处理；第二种做法是进程使用自己的信号处理程序来处理信号。Linux 0.11 内核所支持的信号见表 5–4 所示。

表 5 - 4 进程信号

标号	名称	说明	默认操作
1	SIGHUP	(Hangup) 当你不再有控制终端时内核会产生该信号，或者当你关闭 Xterm 或断开 modem。由于后台程序没有控制的终端，因而它们常用 SIGHUP 来发出需要重新读取其配置文件的信号。	(Abort) 挂断控制终端或进程。
2	SIGINT	(Interrupt) 来自键盘的中断。通常终端驱动程序会将其与^C 绑定。	(Abort) 终止程序。
3	SIGQUIT	(Quit) 来自键盘的退出中断。通常终端驱动程序会将其与^\绑定。	(Dump) 程序被终止并产生 dump core 文件。
4	SIGILL	(Illegal Instruction) 程序出错或者执行了一条非法操作指令。	(Dump) 程序被终止并产生 dump core 文件。
5	SIGTRAP	(Breakpoint/Trace Trap) 调试用，跟踪断点。	
6	SIGABRT	(Abort) 放弃执行，异常结束。	(Dump) 程序被终止并产生 dump core 文件。
6	SIGIOT	(IO Trap) 同 SIGABRT	(Dump) 程序被终止并产生 dump core 文件。
7	SIGUNUSED	(Unused) 没有使用。	
8	SIGFPE	(Floating Point Exception) 浮点异常。	(Dump) 程序被终止并

			产生 dump core 文件。
9	SIGKILL	(Kill) 程序被终止。该信号不能被捕获或者被忽略。想立刻终止一个进程，就发送信号 9。注意程序将没有任何机会做清理工作。	(Abort) 程序被终止。
10	SIGUSR1	(User defined Signal 1) 用户定义的信号。	(Abort) 进程被终止。
11	SIGSEGV	(Segmentation Violation) 当程序引用无效的内存时会产生此信号。比如：寻址没有映射的内存；寻址未许可的内存。	(Dump) 程序被终止并产生 dump core 文件。
12	SIGUSR2	(User defined Signal 2) 保留给用户程序用于 IPC 或其他目的。	(Abort) 进程被终止。
13	SIGPIPE	(Pipe) 当程序向一个套接字或管道写时由于没有读者而产生该信号。	(Abort) 进程被终止。
14	SIGALRM	(Alarm) 该信号会在用户调用 alarm 系统调用所设置的延迟时间到后产生。该信号常用于判别系统调用超时。	(Abort) 进程被终止。
15	SIGTERM	(Terminate) 用于和善地要求一个程序终止。它是 kill 的默认信号。与 SIGKILL 不同，该信号能被捕获，这样就能在退出运行前做清理工作。	(Abort) 进程被终止。
16	SIGSTKFLT	(Stack fault on coprocessor) 协处理器堆栈错误。	(Abort) 进程被终止。
17	SIGCHLD	(Child) 子进程发出。子进程已停止或终止。可改变其含义挪作它用。	(Ignore) 子进程停止或结束。
18	SIGCONT	(Continue) 该信号致使被 SIGSTOP 停止的进程恢复运行。可以被捕获。	(Continue) 恢复进程的执行。
19	SIGSTOP	(Stop) 停止进程的运行。该信号不可被捕获或忽略。	(Stop) 停止进程运行。
20	SIGTSTP	(Terminal Stop) 向终端发送停止键序列。该信号可以被捕获或忽略。	(Stop) 停止进程运行。
21	SIGTTIN	(TTY Input on Background) 后台进程试图从一个不再被控制的终端上读取数据，此时该进程将被停止，直到收到 SIGCONT 信号。该信号可以被捕获或忽略。	(Stop) 停止进程运行。
22	SIGTTOU	(TTY Output on Background) 后台进程试图向一个不再被控制的终端上输出数据，此时该进程将被停止，直到收到 SIGCONT 信号。该信号可被捕获或忽略。	(Stop) 停止进程运行。

5.10 exit.c 程序

5.10.1 功能描述

该程序主要描述了进程（任务）终止和退出的有关处理事宜。主要包含进程释放、会话（进程组）终止和程序退出处理函数以及杀死进程、终止进程、挂起进程等系统调用函数。还包括进程信号发送函数 send_sig()和通知父进程子进程终止的函数 tell_father()。

释放进程的函数 release()主要根据指定的任务数据结构（任务描述符）指针，在任务数组中删除指定的进程指针、释放相关内存页，并立刻让内核重新调度任务的运行。

进程组终止函数 kill_session()通过向会话号与当前进程相同的进程发送挂断进程的信号。

系统调用 sys_kill()用于向进程发送任何指定的信号。根据参数 pid（进程标识号）不同的数值，该系统调用会向不同的进程或进程组发送信号。程序注释中已经列出了各种不同情况的处理方式。

程序退出处理函数 do_exit()是在 exit 系统调用的中断处理程序中被调用。它首先会释放当前进程的

代码段和数据段所占的内存页面。如果当前进程有子进程，就将子进程的 father 置为 1，即把子进程的父进程改为进程 1（init 进程)。如果该子进程已经处于僵死状态，则向进程 1 发送子进程终止信号 SIGCHLD。接着关闭当前进程打开的所有文件、释放使用的终端设备、协处理器设备，若当前进程是进程组的领头进程，则还需要终止所有相关进程。随后把当前进程置为僵死状态，设置退出码，并向其父进程发送子进程终止信号 SIGCHLD。最后让内核重新调度任务的运行。

系统调用 waitpid()用于挂起当前进程，直到 pid 指定的子进程退出（终止）或者收到要求终止该进程的信号，或者是需要调用一个信号句柄（信号处理程序)。如果 pid 所指的子进程早已退出（已成所谓的僵死进程)，则本调用将立刻返回。子进程使用的所有资源将释放。该函数的具体操作也要根据其参数进行不同的处理。详见代码中的相关注释。

5.10.2 代码注释

程序 5-8 linux/kernel/exit.c

```
 1 /*
 2  *  linux/kernel/exit.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)
 8 #include <signal.h>       // 信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
 9 #include <sys/wait.h>     // 等待调用头文件。定义系统调用 wait()和 waitpid()及相关常数符号。
10
11 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
12 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
13 #include <linux/tty.h>    // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
14 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
15
16 int sys_pause(void);      // 把进程置为睡眠状态的系统调用。（kernel/sched.c，144 行）
17 int sys_close(int fd);    // 关闭指定文件的系统调用。（fs/open.c，192 行）
18
   //// 释放指定进程占用的任务槽及其任务数据结构所占用的内存。
   // 参数 p 是任务数据结构的指针。该函数在后面的 sys_kill()和 sys_waitpid()中被调用。
   // 扫描任务指针数组表 task[]以寻找指定的任务。如果找到，则首先清空该任务槽，然后释放
   // 该任务数据结构所占用的内存页面，最后执行调度函数并在返回时立即退出。如果在任务数组
   // 表中没有找到指定任务对应的项，则内核 panic☺。
19 void release(struct task_struct * p)
20 {
21         int i;
22
23         if (!p)                 // 如果进程数据结构指针是 NULL，则什么也不做，退出。
24                 return;
25         for (i=1 ; i<NR_TASKS ; i++)        // 扫描任务数组，寻找指定任务。
26                 if (task[i]==p) {
27                         task[i]=NULL;       // 置空该任务项并释放相关内存页。
28                         free_page((long)p);
29                         schedule();         // 重新调度（似乎没有必要）。
30                         return;
31                 }
```

```
32          panic("trying to release non-existent task");  // 指定任务若不存在则死机。
33  }
34
    //// 向指定任务 p 发送信号 sig，权限为 priv。
    // 参数：sig  -- 信号值；
    //       p    -- 指定任务的指针；
    //       priv -- 强制发送信号的标志。即不需要考虑进程用户属性或级别而能发送信号的权利。
    // 该函数首先判断参数的正确性，然后判断条件是否满足。如果满足就向指定进程发送信号 sig
    // 并退出，否则返回未许可错误号。
35  static inline int send_sig(long sig,struct task_struct * p,int priv)
36  {
    // 若信号不正确或任务指针为空则出错退出。
37          if (!p || sig<1 || sig>32)
38                  return -EINVAL;
    // 如果强制发送标志置位，或者当前进程的有效用户标识符(euid)就是指定进程的 euid（也即是自己），
    // 或者当前进程是超级用户，则向进程 p 发送信号 sig，即在进程 p 位图中添加该信号，否则出错退出。
    // 其中 suser()定义为(current->euid==0)，用于判断是否是超级用户。
39          if (priv || (current->euid==p->euid) || suser())
40                  p->signal |= (1<<(sig-1));
41          else
42                  return -EPERM;
43          return 0;
44  }
45
    //// 终止会话(session)。
    // 进程会话的概念请参见第 4 章中有关进程组和会话的说明。
46  static void kill_session(void)
47  {
48          struct task_struct **p = NR_TASKS + task;       // 指针*p 首先指向任务数组最末端。
49
    // 扫描任务指针数组，对于所有的任务（除任务 0 以外），如果其会话号 session 等于当前进程的
    // 会话号就向它发送挂断进程信号 SIGHUP。
50          while (--p > &FIRST_TASK) {
51                  if (*p && (*p)->session == current->session)
52                          (*p)->signal |= 1<<(SIGHUP-1); // 发送挂断进程信号。
53          }
54  }
55
56  /*
57   * XXX need to check permissions needed to send signals to process
58   * groups, etc. etc.  kill() permissions semantics are tricky!
59   */
    /*
     * 为了向进程组等发送信号，XXX 需要检查许可。kill()的许可机制非常巧妙！
     * /
    //// 系统调用 kill()可用于向任何进程或进程组发送任何信号，而并非只是杀死进程☺。
    // 参数 pid 是进程号；sig 是需要发送的信号。
    // 如果 pid 值>0，则信号被发送给进程号是 pid 的进程。
    // 如果 pid=0，那么信号就会被发送给当前进程的进程组中的所有进程。
    // 如果 pid=-1，则信号 sig 就会发送给除第一个进程（初始进程 init）外的所有进程。
    // 如果 pid < -1，则信号 sig 将发送给进程组-pid 的所有进程。
    // 如果信号 sig 为 0，则不发送信号，但仍会进行错误检查。如果成功则返回 0。
    // 该函数扫描任务数组表，并根据 pid 的值对满足条件的进程发送指定的信号 sig。若 pid 等于 0，
```

```
    // 表明当前进程是进程组组长，因此需要向所有组内的进程强制发送信号 sig。
 60 int sys_kill(int pid,int sig)
 61 {
 62         struct task_struct **p = NR_TASKS + task;
 63         int err, retval = 0;
 64
 65         if (!pid) while (--p > &FIRST_TASK) {
 66                 if (*p && (*p)->pgrp == current->pid)
 67                         if (err=send_sig(sig,*p,1))       // 强制发送信号。
 68                                 retval = err;
 69         } else if (pid>0) while (--p > &FIRST_TASK) {
 70                 if (*p && (*p)->pid == pid)
 71                         if (err=send_sig(sig,*p,0))
 72                                 retval = err;
 73         } else if (pid == -1) while (--p > &FIRST_TASK)
 74                 if (err = send_sig(sig,*p,0))
 75                         retval = err;
 76         else while (--p > &FIRST_TASK)
 77                 if (*p && (*p)->pgrp == -pid)
 78                         if (err = send_sig(sig,*p,0))
 79                                 retval = err;
 80         return retval;
 81 }
 82
    //// 通知父进程 -- 向进程 pid 发送信号 SIGCHLD：默认情况下子进程将停止或终止。
    // 如果没有找到父进程，则自己释放。但根据 POSIX.1 要求，若父进程已先行终止，则子进程应该
    // 被初始进程 1 收容。
 83 static void tell_father(int pid)
 84 {
 85         int i;
 86
 87         if (pid)
    // 扫描进程数组表寻找指定进程 pid，并向其发送子进程将停止或终止信号 SIGCHLD。
 88                 for (i=0;i<NR_TASKS;i++) {
 89                         if (!task[i])
 90                                 continue;
 91                         if (task[i]->pid != pid)
 92                                 continue;
 93                         task[i]->signal |= (1<<(SIGCHLD-1));
 94                         return;
 95                 }
 96 /* if we don't find any fathers, we just release ourselves */
 97 /* This is not really OK. Must change it to make father 1 */
    /* 如果没有找到父进程，则进程就自己释放。这样做并不好，必须改成由进程 1 充当其父进程。*/
 98         printk("BAD BAD - no father found\n\r");
 99         release(current);                    // 如果没有找到父进程，则自己释放。
100 }
101
    //// 程序退出处理函数。在下面 137 行处的系统调用 sys_exit()中被调用。
    // 参数 code 是错误码。
102 int do_exit(long code)
103 {
104         int i;
```

```
105
    // 释放当前进程代码段和数据段所占的内存页（free_page_tables()在 mm/memory.c,105 行）。
106         free_page_tables(get_base(current->ldt[1]),get_limit(0x0f));
107         free_page_tables(get_base(current->ldt[2]),get_limit(0x17));
    // 如果当前进程有子进程，就将子进程的 father 置为 1(其父进程改为进程 1，即 init 进程)。
    // 如果该子进程已经处于僵死(ZOMBIE)状态，则向进程 1 发送子进程终止信号 SIGCHLD。
108         for (i=0 ; i<NR_TASKS ; i++)
109                 if (task[i] && task[i]->father == current->pid) {
110                         task[i]->father = 1;
111                         if (task[i]->state == TASK_ZOMBIE)
112             /* assumption task[1] is always init */  /* 这里假设 task[1]肯定是进程 init */
113                                 (void) send_sig(SIGCHLD, task[1], 1);
114                 }
    // 关闭当前进程打开着的所有文件。
115         for (i=0 ; i<NR_OPEN ; i++)
116                 if (current->filp[i])
117                         sys_close(i);
    // 对当前进程的工作目录 pwd、根目录 root 以及程序的 i 节点进行同步操作，并分别置空（释放）。
118         iput(current->pwd);
119         current->pwd=NULL;
120         iput(current->root);
121         current->root=NULL;
122         iput(current->executable);
123         current->executable=NULL;
    // 如果当前进程是会话头领(leader)进程并且其有控制终端，则释放该终端。
124         if (current->leader && current->tty >= 0)
125                 tty_table[current->tty].pgrp = 0;
    // 如果当前进程上次使用过协处理器，则将 last_task_used_math 置空。
126         if (last_task_used_math == current)
127                 last_task_used_math = NULL;
    // 如果当前进程是 leader 进程，则终止该会话的所有相关进程。
128         if (current->leader)
129                 kill_session();
    // 把当前进程置为僵死状态，表明当前进程已经释放了资源。并保存将由父进程读取的退出码。
130         current->state = TASK_ZOMBIE;
131         current->exit_code = code;
    // 通知父进程，也即向父进程发送信号 SIGCHLD -- 子进程将停止或终止。
132         tell_father(current->father);
133         schedule();         // 重新调度进程运行，以让父进程处理僵死进程其他的善后事宜。
134         return (-1);    /* just to suppress warnings */
135 }
136
    //// 系统调用 exit()。终止进程。
137 int sys_exit(int error_code)
138 {
139         return do_exit((error_code&0xff)<<8);
140 }
141
    //// 系统调用 waitpid()。挂起当前进程，直到 pid 指定的子进程退出（终止）或者收到要求终止
    // 该进程的信号，或者是需要调用一个信号句柄（信号处理程序）。如果 pid 所指的子进程早已
    // 退出（已成所谓的僵死进程），则本调用将立刻返回。子进程使用的所有资源将释放。
    // 如果 pid > 0, 表示等待进程号等于 pid 的子进程。
    // 如果 pid = 0, 表示等待进程组号等于当前进程组号的任何子进程。
```

```
    // 如果 pid < -1, 表示等待进程组号等于 pid 绝对值的任何子进程。
    // [ 如果 pid = -1, 表示等待任何子进程。]
    // 若 options = WUNTRACED, 表示如果子进程是停止的, 也马上返回（无须跟踪）。
    // 若 options = WNOHANG, 表示如果没有子进程退出或终止就马上返回。
    // 如果返回状态指针 stat_addr 不为空, 则就将状态信息保存到那里。
142 int sys_waitpid(pid_t pid,unsigned long * stat_addr, int options)
143 {
144         int flag, code;
145         struct task_struct ** p;
146
147         verify_area(stat_addr,4);
148 repeat:
149         flag=0;
    // 从任务数组末端开始扫描所有任务, 跳过空项、本进程项以及非当前进程的子进程项。
150         for(p = &LAST_TASK ; p > &FIRST_TASK ; --p) {
151                 if (!*p || *p == current)               // 跳过空项和本进程项。
152                         continue;
153                 if ((*p)->father != current->pid)       // 如果不是当前进程的子进程则跳过。
154                         continue;
    // 此时扫描选择到的进程 p 肯定是当前进程的子进程。
    // 如果等待的子进程号 pid>0, 但与被扫描子进程 p 的 pid 不相等, 说明它是当前进程另外的子进程,
    // 于是跳过该进程, 接着扫描下一个进程。
155                 if (pid>0) {
156                         if ((*p)->pid != pid)
157                                 continue;
    // 否则, 如果指定等待进程的 pid=0, 表示正在等待进程组号等于当前进程组号的任何子进程。如果
    // 此时被扫描进程 p 的进程组号与当前进程的组号不等, 则跳过。
158                 } else if (!pid) {
159                         if ((*p)->pgrp != current->pgrp)
160                                 continue;
    // 否则, 如果指定的 pid<-1, 表示正在等待进程组号等于 pid 绝对值的任何子进程。如果此时被扫描
    // 进程 p 的组号与 pid 的绝对值不等, 则跳过。
161                 } else if (pid != -1) {
162                         if ((*p)->pgrp != -pid)
163                                 continue;
164                 }
    // 如果前 3 个对 pid 的判断都不符合, 则表示当前进程正在等待其任何子进程, 也即 pid=-1 的情况。
    // 此时所选择到的进程 p 正是所等待的子进程。接下来根据这个子进程 p 所处的状态来处理。
165                 switch ((*p)->state) {
    // 子进程 p 处于停止状态时, 如果此时 WUNTRACED 标志没有置位, 表示程序无须立刻返回, 于是继续
    // 扫描处理其他进程。如果 WUNTRACED 置位, 则把状态信息 0x7f 放入*stat_addr, 并立刻返回子进程
    // 号 pid。这里 0x7f 表示的返回状态使 WIFSTOPPED()宏为真。参见 include/sys/wait.h, 14 行。
166                         case TASK_STOPPED:
167                                 if (!(options & WUNTRACED))
168                                         continue;
169                                 put_fs_long(0x7f,stat_addr);
170                                 return (*p)->pid;
    // 如果子进程 p 处于僵死状态,则首先把它在用户态和内核态运行的时间分别累计到当前进程(父进程)
    // 中, 然后取出子进程的 pid 和退出码, 并释放该子进程。最后返回子进程的退出码和 pid。
171                         case TASK_ZOMBIE:
172                                 current->cutime += (*p)->utime;
173                                 current->cstime += (*p)->stime;
174                                 flag = (*p)->pid;               // 临时保存子进程 pid。
```

```
175                                 code = (*p)->exit_code;         // 取子进程的退出码。
176                                 release(*p);                    // 释放该子进程。
177                                 put_fs_long(code,stat_addr);    // 置状态信息为退出码值。
178                                 return flag;                    // 退出，返回子进程的 pid.
    // 如果这个子进程 p 的状态既不是停止也不是僵死，那么就置 flag=1。表示找到过一个符合要求的
    // 子进程，但是它处于运行态或睡眠态。
179                         default:
180                                 flag=1;
181                                 continue;
182                 }
183         }
    // 在上面对任务数组扫描结束后，如果 flag 被置位，说明有符合等待要求的子进程并没有处于退出
    // 或僵死状态。如果此时已设置 WNOHANG 选项（表示若没有子进程处于退出或终止态就立刻返回），
    // 就立刻返回 0，退出。否则把当前进程置为可中断等待状态并重新执行调度。
184         if (flag) {
185                 if (options & WNOHANG)              // 若 options = WNOHANG，则立刻返回。
186                         return 0;
187                 current->state=TASK_INTERRUPTIBLE; // 置当前进程为可中断等待状态。
188                 schedule();                         // 重新调度。
    // 当又开始执行本进程时，如果本进程没有收到除 SIGCHLD 以外的信号，则还是重复处理。否则，
    // 返回出错码并退出。
189                 if (!(current->signal &= ~(1<<(SIGCHLD-1))))
190                         goto repeat;
191                 else
192                         return -EINTR;              // 退出，返回出错码。
193         }
    // 若没有找到符合要求的子进程，则返回出错码。
194         return -ECHILD;
195 }
196
```

5.11 fork.c 程序

5.11.1 功能描述

fork()系统调用用于创建子进程。Linux 中所有进程都是进程 0（任务 0）的子进程。该程序是 sys_fork()（在 kernel/system_call.s 中从 208 行开始）系统调用的辅助处理函数集，给出了 sys_fork()系统调用中使用的两个 C 语言函数：find_empty_process()和 copy_process()。还包括进程内存区域验证与内存分配函数 verify_area()和 copy_mem()。

copy_process()用于创建并复制进程的代码段和数据段以及环境。在进程复制过程中，工作主要牵涉到进程数据结构中信息的设置。系统首先为新建进程在主内存区中申请一页内存来存放其任务数据结构信息，并复制当前进程任务数据结构中的所有内容作为新进程任务数据结构的模板。

随后对已复制的任务数据结构内容进行修改。把当前进程设置为新进程的父进程，清除信号位图并复位新进程各统计值。接着根据当前进程环境设置新进程任务状态段（TSS）中各寄存器的值。由于创建进程时新进程返回值应为 0，所以需要设置 tss.eax = 0。新建进程内核态堆栈指针 tss.esp0 被设置成新进程任务数据结构所在内存页面的顶端，而堆栈段 tss.ss0 被设置成内核数据段选择符。tss.ldt 被设置为局部表描述符在 GDT 中的索引值。如果当前进程使用了协处理器，则还需要把协处理器的完整状态保

存到新进程的 tss.i387 结构中。

此后系统设置新任务代码段和数据段的基址和段限长，并复制当前进程内存分页管理的页目录项和页表项。如果父进程中有文件是打开的，则子进程中相应的文件也是打开着的，因此需要将对应文件的打开次数增 1。接着在 GDT 中设置新任务的 TSS 和 LDT 描述符项，其中基地址信息指向新进程任务结构中的 tss 和 ldt。最后再将新任务设置成可运行状态，并向当前进程返回新进程号。

图 5-11 是内存验证函数 verify_area()中验证内存的起始位置和范围的调整示意图。因为内存写验证函数 write_verify()需要以内存页面为单位（4096 字节）进行操作，因此在调用 write_verify()之前，需要把验证的起始位置调整为页面起始位置，同时对验证范围作相应调整。

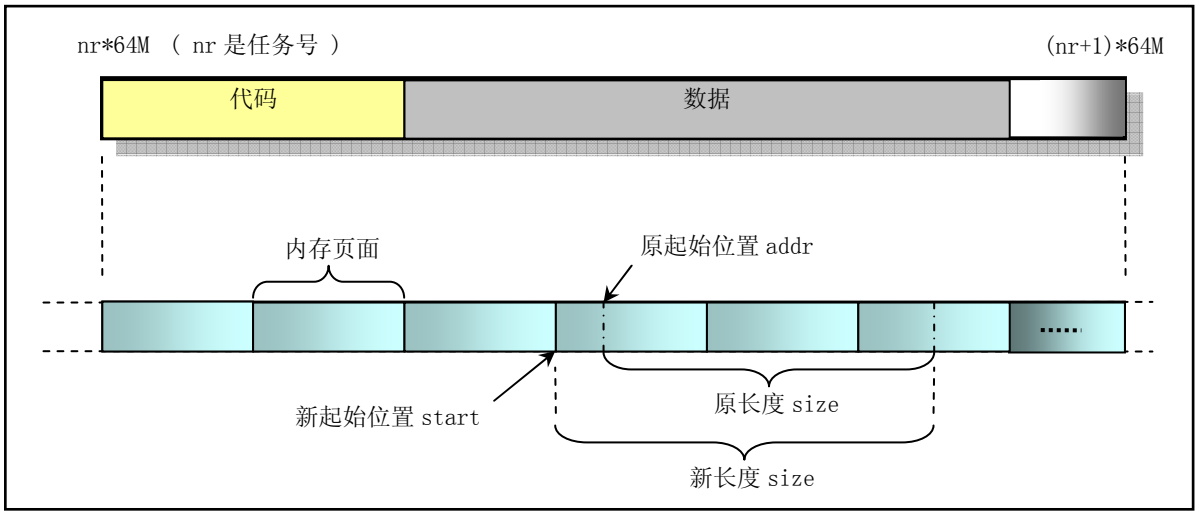

图 5-11 内存验证范围和起始位置的调整

上面根据 fork.c 程序中各函数的功能描述了 fork()的作用。这里我们从总体上再对其稍加说明。总的来说 fork()首先会为新进程申请一页内存页用来复制父进程的任务数据结构（PCB）信息，然后会为新进程修改复制的任务数据结构的某些字段值，包括利用系统调用中断发生时逐步压入堆栈的寄存器信息（即 copy_process()的参数）重新设置任务结构中的 TSS 结构的各字段值，让新进程的状态保持父进程即将进入中断过程前的状态。然后为新进程确定在线性地址空间中的起始位置（nr * 64MB）。对于 CPU 的分段机制，Linux 0.11 的代码段和数据段在线性地址空间中的位置和长度完全相同。接着系统会为新进程复制父进程的页目录项和页表项。对于 Linux 0.11 内核来说，所有程序共用一个位于物理内存开始位置处的页目录表，而新进程的页表则需另行申请一页内存来存放。

在 fork()的执行过程中，内核并不会立刻为新进程分配代码和数据内存页。新进程将与父进程共同使用父进程已有的代码和数据内存页面。只有当以后执行过程中如果其中有一个进程以写方式访问内存时被访问的内存页面才会在写操作前被复制到新申请的内存页面中。

5.11.2 代码注释

程序 5-9 linux/kernel/fork.c

```
1 /*
2  *  linux/kernel/fork.c
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
```

```
 7 /*
 8  *  'fork.c' contains the help-routines for the 'fork' system call
 9  * (see also system_call.s), and some misc functions ('verify_area').
10  * Fork is rather simple, once you get the hang of it, but the memory
11  * management can be a bitch. See 'mm/mm.c': 'copy_page_tables()'
12  */
    /*
     * 'fork.c'中含有系统调用'fork'的辅助子程序（参见 system_call.s），以及一些其他函数
     * ('verify_area')。一旦你了解了 fork，就会发现它是非常简单的，但内存管理却有些难度。
     * 参见'mm/mm.c'中的'copy_page_tables()'。
     */
13 #include <errno.h>          // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
14
15 #include <linux/sched.h>   // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                              // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
16 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
17 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
18 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
19
20 extern void write_verify(unsigned long address);     // mm/memory.c L261.
21
22 long last_pid=0;          // 最新进程号，其值由 get_empty_process()生成。
23
    //// 进程空间区域写前验证函数。
    // 对当前进程地址从 addr 到 addr + size 这一段空间以页为单位执行写操作前的检测操作。
    // 由于检测判断是以页面为单位进行操作，因此程序首先需要找出 addr 所在页面开始地址 start，
    // 然后 start 加上进程数据段基址，使这个 start 变换成 CPU 4G 线性空间中的地址。最后循环
    // 调用 write_verify()对指定大小的内存空间进行写前验证。若页面是只读的，则执行共享检验
    // 和复制页面操作（写时复制）。
24 void verify_area(void * addr,int size)
25 {
26         unsigned long start;
27
28         start = (unsigned long) addr;
    // 将起始地址 start 调整为其所在页的左边界开始位置，同时相应地调整验证区域大小。
    // 下句中的 start & 0xfff 用来获得指定起始位置 addr（也即 start）在所在页面中的偏移值，
    // 原验证范围 size 加上这个偏移值即扩展成以 addr 所在页面起始位置开始的范围值。因此在 30 行
    // 上也需要把验证开始位置 start 调整成页面边界值。参见前面的图“内存验证范围的调整”。
29         size += start & 0xfff;
30         start &= 0xfffff000;
    // 下面把 start 加上进程数据段在线性地址空间中的起始基址，变成系统整个线性空间中的地址位置。
    // 对于 0.11 内核，其数据段和代码段在线性地址空间中的基址和限长均相同。
31         start += get_base(current->ldt[2]);
32         while (size>0) {
33                 size -= 4096;
    // 写页面验证。若页面不可写，则复制页面。（mm/memory.c，261 行）
34                 write_verify(start);
35                 start += 4096;
36         }
37 }
38
    // 设置新任务的代码和数据段基址、限长并复制页表。
    // nr 为新任务号；p 是新任务数据结构的指针。
```

```
39 int copy_mem(int nr,struct task_struct * p)
40 {
41         unsigned long old_data_base,new_data_base,data_limit;
42         unsigned long old_code_base,new_code_base,code_limit;
43
   // 取当前进程局部描述符表中描述符项的段限长（字节数）。
44         code_limit=get_limit(0x0f);             // 取局部描述符表中代码段描述符项中段限长。
45         data_limit=get_limit(0x17);             // 取局部描述符表中数据段描述符项中段限长。
   // 取当前进程代码段和数据段在线性地址空间中的基地址。
46         old_code_base = get_base(current->ldt[1]);  // 取原代码段基址。
47         old_data_base = get_base(current->ldt[2]);  // 取原数据段基址。
48         if (old_data_base != old_code_base)     // 0.11 版不支持代码和数据段分立的情况。
49                 panic("We don't support separate I&D");
50         if (data_limit < code_limit)            // 如果数据段长度 < 代码段长度也不对。
51                 panic("Bad data_limit");
   // 创建中新进程在线性地址空间中的基地址等于 64MB * 其任务号。
52         new_data_base = new_code_base = nr * 0x4000000; // 新基址=任务号*64Mb(任务大小)。
53         p->start_code = new_code_base;
   // 设置新进程局部描述符表中段描述符中的基地址。
54         set_base(p->ldt[1],new_code_base);      // 设置代码段描述符中基址域。
55         set_base(p->ldt[2],new_data_base);      // 设置数据段描述符中基址域。
   // 设置新进程的页目录表项和页表项。即把新进程的线性地址内存页对应到实际物理地址内存页面上。
   // 由于 Linux 采用了写时复制（Copy on Write）技术，因此这里仅为新进程设置了自己的页目录表项
   // 和页表项，而没有实际为新进程分配物理内存页面。此时新进程与其父进程共享所有物理页面。
56         if (copy_page_tables(old_data_base,new_data_base,data_limit)) {
57                 free_page_tables(new_data_base,data_limit);  // 若出错则释放申请的页表项。
58                 return -ENOMEM;
59         }
60         return 0;
61 }
62
63 /*
64  *  Ok, this is the main fork-routine. It copies the system process
65  * information (task[nr]) and sets up the necessary registers. It
66  * also copies the data segment in it's entirety.
67  */
   /*
    * OK，下面是主要的 fork 子程序。它复制系统进程信息(task[n])并且设置必要的寄存器。
    * 它还整个地复制数据段。
    */
   // 复制进程。
   // 该函数的参数是进入系统调用中断处理过程（system_call.s）开始，直到调用本系统调用处理
   // 过程（system_call.s 第 208 行）和调用本函数时（system_call.s 第 217 行）逐步压入堆栈的
   // 各寄存器的值。这些在 system_call.s 程序中逐步压入堆栈的值（参数）包括:
   // ① CPU 执行中断指令压入的用户堆栈地址 ss 和 esp、标志寄存器 eflags 和返回地址 cs 和 eip;
   // ② 第 83--88 行在刚进入 system_call 时压入堆栈的段寄存器 ds、es、fs 和 edx、ecx、edx;
   // ③ 第 94 行调用 sys_call_table 中相应函数指针时压入堆栈的返回地址（用参数 none 表示）;
   // ④ 第 212--216 行在调用 copy_process()之前压入堆栈的 gs、esi、edi、ebp 和 eax（nr）的值。
   // 其中参数 nr 是调用 find_empty_process()分配的任务数组项号。
68 int copy_process(int nr,long ebp,long edi,long esi,long gs,long none,
69                 long ebx,long ecx,long edx,
70                 long fs,long es,long ds,
71                 long eip,long cs,long eflags,long esp,long ss)
```

```
72 {
73         struct task_struct *p;
74         int i;
75         struct file *f;
76
77         p = (struct task_struct *) get_free_page();    // 为新任务数据结构分配内存。
78         if (!p)                         // 如果内存分配出错，则返回出错码并退出。
79                 return -EAGAIN;
80         task[nr] = p;                   // 将新任务结构指针放入任务数组中。
                                           // 其中 nr 为任务号，由前面 find_empty_process()返回。
81         *p = *current;  /* NOTE! this doesn't copy the supervisor stack */
                           /* 注意！这样做不会复制超级用户的堆栈 */（只复制当前进程内容）。
82         p->state = TASK_UNINTERRUPTIBLE; // 将新进程的状态先置为不可中断等待状态。
83         p->pid = last_pid;              // 新进程号。由前面调用 find_empty_process()得到。
84         p->father = current->pid;       // 设置父进程号。
85         p->counter = p->priority;
86         p->signal = 0;                  // 信号位图置 0。
87         p->alarm = 0;                   // 报警定时值（滴答数）。
88         p->leader = 0;                  /* process leadership doesn't inherit */
                                           /* 进程的领导权是不能继承的 */
89         p->utime = p->stime = 0;        // 初始化用户态时间和核心态时间。
90         p->cutime = p->cstime = 0;      // 初始化子进程用户态和核心态时间。
91         p->start_time = jiffies;        // 当前滴答数时间。
   // 以下设置任务状态段 TSS 所需的数据（参见列表后说明）。
92         p->tss.back_link = 0;
   // 由于系统给任务结构 p 分配了 1 页新内存，所以此时 esp0 正好指向该页顶端。ss0:esp0 用于作为
   // 程序在内核态执行时的堆栈。
93         p->tss.esp0 = PAGE_SIZE + (long) p;  // 内核态堆栈指针。
94         p->tss.ss0 = 0x10;              // 堆栈段选择符（与内核数据段相同）。
95         p->tss.eip = eip;               // 指令代码指针。
96         p->tss.eflags = eflags;         // 标志寄存器。
97         p->tss.eax = 0;                 // 这是当 fork()返回时，新进程会返回 0 的原因所在。
98         p->tss.ecx = ecx;
99         p->tss.edx = edx;
100        p->tss.ebx = ebx;
101        p->tss.esp = esp;               // 新进程完全复制了父进程的堆栈内容。因此要求 task0
102        p->tss.ebp = ebp;               // 的堆栈比较“干净”。
103        p->tss.esi = esi;
104        p->tss.edi = edi;
105        p->tss.es = es & 0xffff;        // 段寄存器仅 16 位有效。
106        p->tss.cs = cs & 0xffff;
107        p->tss.ss = ss & 0xffff;
108        p->tss.ds = ds & 0xffff;
109        p->tss.fs = fs & 0xffff;
110        p->tss.gs = gs & 0xffff;
111        p->tss.ldt = _LDT(nr);  // 设置新任务局部表描述符的选择符（LDT 描述符在 GDT 中）。
112        p->tss.trace_bitmap = 0x80000000;  （高 16 位有效）。
   // 如果当前任务使用了协处理器，就保存其上下文。汇编指令 clts 用于清除控制寄存器 CR0 中的任务
   // 已交换（TS）标志。每当发生任务切换，CPU 都会设置该标志。该标志用于管理数学协处理器：如果
   // 该标志置位，那么每个 ESC 指令都会被捕获（异常 7）。如果协处理器存在标志 MP 也同时置位的话，
   // 那么 WAIT 指令也会捕获。因此，如果任务切换发生在一个 ESC 指令开始执行之后，则协处理器中的
   // 内容就可能需要在执行新的 ESC 指令之前保存起来。捕获处理句柄会保存协处理器的内容并复位 TS
   // 标志。指令 fnsave 用于把协处理器的所有状态保存到目的操作数指定的内存区域中（tss.i387）。
```

```
113         if (last_task_used_math == current)
114                 __asm__("clts ; fnsave %0"::"m" (p->tss.i387));
    // 设置新任务代码段和数据段描述符中的基址和限长，并复制页表。如果出错（返回值不是 0），则
    // 复位任务数组中相应项并释放为该新任务分配的内存页。
115         if (copy_mem(nr,p)) {           // 返回不为 0 表示出错。
116                 task[nr] = NULL;
117                 free_page((long) p);
118                 return -EAGAIN;
119         }
    // 如果父进程中有文件是打开的，则将对应文件的打开次数增 1。
120         for (i=0; i<NR_OPEN;i++)
121                 if (f=p->filp[i])
122                         f->f_count++;
    // 将当前进程（父进程）的 pwd, root 和 executable 引用次数均增 1。
123         if (current->pwd)
124                 current->pwd->i_count++;
125         if (current->root)
126                 current->root->i_count++;
127         if (current->executable)
128                 current->executable->i_count++;
    // 在 GDT 中设置新任务的 TSS 段和 LDT 段描述符项。这两个段的限长均被设置成 104 字节。
    // 参见 include/asm/system.h，52-66 行。另外在任务切换时，任务寄存器 tr 由 CPU 自动加载。
129         set_tss_desc(gdt+(nr<<1)+FIRST_TSS_ENTRY,&(p->tss));
130         set_ldt_desc(gdt+(nr<<1)+FIRST_LDT_ENTRY,&(p->ldt));
131         p->state = TASK_RUNNING;        /* do this last, just in case */
                                            /* 最后再将新任务设置成可运行状态，以防万一 */
132         return last_pid;                // 返回新进程号（与任务号是不同的）。
133 }
134
    // 为新进程取得不重复的进程号 last_pid，并返回在任务数组中的任务号(数组 index)。
135 int find_empty_process(void)
136 {
137         int i;
138
139         repeat:
    // 如果 last_pid 增 1 后超出其正数表示范围，则重新从 1 开始使用 pid 号。
140                 if ((++last_pid)<0) last_pid=1;
    // 在任务数组中搜索刚设置的 pid 号是否已经被任何任务使用。如果是则重新获得一个 pid 号。
141                 for(i=0 ; i<NR_TASKS ; i++)
142                         if (task[i] && task[i]->pid == last_pid) goto repeat;
    // 在任务数组中为新任务寻找一个空闲项，并返回项号。last_pid 是一个全局变量，不用返回。
143         for(i=1 ; i<NR_TASKS ; i++)     // 任务 0 排除在外。
144                 if (!task[i])
145                         return i;
    // 如果任务数组中 64 个项已经被全部占用，则返回出处码。
146         return -EAGAIN;
147 }
148
```

5.11.3 其他信息

5.11.3.1 任务状态段（TSS）信息

下面图 5-12 是任务状态段 TSS（Task State Segment）的内容。对它的说明请参见附录。

31 23	15 7 0	
I/O 映射图基地址(MAP BASE)	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	64
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	局部描述符表(LDT)的选择符	60
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	GS	5C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	FS	58
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	DS	54
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	SS	50
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	CS	4C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	ES	48
EDI		44
ESI		40
EBP		3C
ESP		38
EBX		34
EDX		30
ECX		2C
EAX		28
EFLAGS		24
指令指针(EIP)		20
页目录基地址寄存器 CR3（PDBR）		1C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	SS2	18
ESP2		14
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	SS1	10
ESP1		0C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	SS0	08
ESP0		04
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	前一执行任务 TSS 的描述符	00

图 5-12 **任务状态段** TSS **中的信息**。

CPU 管理任务需要的所有信息被存储于一个特殊类型的段中，任务状态段(task state segment - TSS)。图中显示出执行 80386 任务的 TSS 格式。

TSS 中的字段可以分为两类：

1. CPU 在进行任务切换时更新的动态信息集。这些字段有：
   - o 通用寄存器（EAX，ECX，EDX，EBX，ESP，EBP，ESI，EDI）；
   - o 段寄存器（ES, CS, SS, DS, FS, GS）；
   - o 标志寄存器（EFLAGS）；
   - o 指令指针（EIP）；

   前一个执行任务的 TSS 的选择符（仅当返回时才更新）。

2. CPU 读取但不会更改的静态信息集。这些字段有：

- o 任务的 LDT 的选择符；
- o 含有任务页目录基地址的寄存器（PDBR）；
- o 特权级 0-2 的堆栈指针；
- o 当任务进行切换时导致 CPU 产生一个调试(debug)异常的 T-比特位（调试跟踪位）；
- o I/O 比特位图基地址（其长度上限就是 TSS 的长度上限，在 TSS 描述符中说明）。

任务状态段可以存放在线形空间的任何地方。与其他各类段相似，任务状态段也是由描述符来定义的。当前正在执行任务的 TSS 是由任务寄存器（TR）来指示的。指令 LTR 和 STR 用来修改和读取任务寄存器中的选择符（任务寄存器的可见部分）。

I/O 比特位图中的每 1 比特对应 1 个 I/O 端口。比如端口 41 的比特位就是 I/O 位图基地址+5，位偏移 1 处。在保护模式中，当遇到 1 个 I/O 指令时(IN, INS, OUT, OUTS)，CPU 首先就会检查当前特权级是否小于标志寄存器的 IOPL，如果这个条件满足，就执行该 I/O 操作。如果不满足，那么 CPU 就会检查 TSS 中的 I/O 比特位图。如果相应比特位是置位的，就会产生一般保护性异常，否则就会执行该 I/O 操作。

如果 I/O 位图基址被设置成大于或等于 TSS 段限长，则表示该 TSS 段没有 I/O 许可位图，那么对于所有当前特权层 CPL>IOPL 的 I/O 指令均会导致发生异常保护。在默认情况下，Linux 0.11 内核中把 I/O 位图基址设置成了 0x8000，显然大于 TSS 段限长 104 字节，因此 Linux 0.11 内核中没有 I/O 许可位图。

在 Linux 0.11 中，图中 SS0:ESP0 用于存放任务在内核态运行时的堆栈指针。SS1:ESP1 和 SS2:ESP2 分别对应运行于特权级 1 和 2 时使用的堆栈指针，这两个特权级在 Linux 中没有使用。而任务工作于用户态时堆栈指针则保存在 SS:ESP 寄存器中。由上所述可知，每当任务进入内核态执行时，其内核态堆栈指针初始位置不变，均为任务数据结构所在页面的顶端位置处。

5.12 sys.c 程序

5.12.1 功能描述

sys.c 程序含有很多系统调用功能的实现函数。其中，函数若仅有返回值-ENOSYS，则表示本版 Linux 内核还没有实现该功能，可以参考目前的代码来了解它们的实现方法。所有系统调用功能说明请参见头文件 include/linux/sys.h。

该程序中含有很多有关进程 ID（pid）、进程组 ID（pgrp 或 pgid）、用户 ID（uid）、用户组 ID（gid）、实际用户 ID（ruid）、有效用户 ID（euid）以及会话 ID（session）等的操作函数。下面首先对这些 ID 作一简要说明。

一个用户有用户 ID（uid）和用户组 ID（gid）。这两个 ID 是 passwd 文件中对该用户设置的 ID，通常被称为实际用户 ID（ruid）和实际组 ID（rgid）。而在每个文件的 i 节点信息中都保存着宿主的用户 ID 和组 ID，它们指明了文件拥有者和所属用户组。主要用于访问或执行文件时的权限判别操作。另外，在一个进程的任务数据结构中，为了实现不同功能而保存了 3 种用户 ID 和组 ID。见表 5–5 所示。

表 5－5 与进程相关的用户 ID 和组 ID

类别	用户 ID	组 ID
进程的	uid - 用户 ID。指明拥有该进程的用户。	gid - 组 ID。指明拥有该进程的用户组。
有效的	euid - 有效用户 ID。指明访问文件的权限。	egid - 有效组 ID。指明访问文件的权限。
保存的	suid - 保存的用户 ID。当执行文件的设置用户	sgid - 保存的组 ID。当执行文件的设置组 ID 标志

	ID 标志（set-user-ID）置位时，suid 中保存着执行文件的 uid。否则 suid 等于进程的 euid。	（set-group-ID）置位时，sgid 中保存着执行文件的 gid。否则 sgid 等于进程的 egid。

进程的 uid 和 gid 分别就是进程拥有者的用户 ID 和组 ID，也即进程的实际用户 ID（ruid）和实际组 ID（rgid）。超级用户可以使用函数 set_uid()和 set_gid()对它们进行修改。有效用户 ID 和有效组 ID 用于进程访问文件时的许可权判断。

保存的用户 ID（suid）和保存的组 ID（sgid）用于进程访问设置了 set-user-ID 或 set-group-ID 标志的文件。当执行一个程序时，进程的 euid 通常就是实际用户 ID，egid 通常就是实际组 ID。因此进程只能访问进程的有效用户、有效用户组规定的文件或其他允许访问的文件。但是如果一个文件的 set-user-ID 标志置位时，那么进程的有效用户 ID 就会被设置成该文件宿主的用户 ID，因此进程就可以访问设置了这种标志的受限文件，同时该文件宿主的用户 ID 被保存在 suid 中。同理，文件的 set-group-ID 标志也有类似的作用并作相同的处理。

例如，如果一个程序的宿主是超级用户，但该程序设置了 set-user-ID 标志，那么当该程序被一个进程运行时，则该进程的有效用户 ID（euid）就会被设置成超级用户的 ID（0）。于是这个进程就拥有了超级用户的权限。一个实际例子就是 Linux 系统的 passwd 命令。该命令是一个设置了 set-user-Id 的程序，因此允许用户修改自己的口令。因为该程序需要把用户的新口令写入/etc/passwd 文件中，而该文件只有超级用户才有写权限，因此 passwd 程序就需要使用 set-user-ID 标志。

另外，进程也有标识自己属性的进程 ID（pid）、所属进程组的进程组 ID（pgrp 或 pgid）和所属会话的会话 ID（session）。这 3 个 ID 用于表明进程与进程之间的关系，与用户 ID 和组 ID 无关。

5.12.2 代码注释

程序 5-10 linux/kernel/sys.c 程序

```
 1 /*
 2  *  linux/kernel/sys.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
 8
 9 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
10 #include <linux/tty.h>    // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
13 #include <sys/times.h>    // 定义了进程中运行时间的结构 tms 以及 times()函数原型。
14 #include <sys/utsname.h>  // 系统名称结构头文件。
15
   // 返回日期和时间。以下返回值是-ENOSYS 的系统调用函数均表示在本版本内核中还未实现。
16 int sys_ftime()
17 {
18         return -ENOSYS;
19 }
20
   //
21 int sys_break()
22 {
23         return -ENOSYS;
```

```
24 }
25
   // 用于当前进程对子进程进行调试(debugging)。
26 int sys_ptrace()
27 {
28         return -ENOSYS;
29 }
30
   // 改变并打印终端行设置。
31 int sys_stty()
32 {
33         return -ENOSYS;
34 }
35
   // 取终端行设置信息。
36 int sys_gtty()
37 {
38         return -ENOSYS;
39 }
40
   // 修改文件名。
41 int sys_rename()
42 {
43         return -ENOSYS;
44 }
45
   //
46 int sys_prof()
47 {
48         return -ENOSYS;
49 }
50
   // 设置当前任务的实际以及/或者有效组 ID（gid）。如果任务没有超级用户特权，
   // 那么只能互换其实际组 ID 和有效组 ID。如果任务具有超级用户特权，就能任意设置有效的和实际
   // 的组 ID。保留的 gid（saved gid）被设置成与有效 gid 同值。
51 int sys_setregid(int rgid, int egid)
52 {
53         if (rgid>0) {
54                 if ((current->gid == rgid) ||
55                     suser())
56                         current->gid = rgid;
57                 else
58                         return(-EPERM);
59         }
60         if (egid>0) {
61                 if ((current->gid == egid) ||
62                     (current->egid == egid) ||
63                     (current->sgid == egid) ||
64                     suser())
65                         current->egid = egid;
66                 else
67                         return(-EPERM);
68         }
```

```
69          return 0;
70  }
71
    // 设置进程组号(gid)。如果任务没有超级用户特权，它可以使用 setgid()将其有效 gid
    //  (effective gid) 设置为成其保留 gid(saved gid)或其实际 gid(real gid)。如果任务有
    // 超级用户特权，则实际 gid、有效 gid 和保留 gid 都被设置成参数指定的 gid。
72  int sys_setgid(int gid)
73  {
74          return(sys_setregid(gid, gid));
75  }
76
    // 打开或关闭进程计帐功能。
77  int sys_acct()
78  {
79          return -ENOSYS;
80  }
81
    // 映射任意物理内存到进程的虚拟地址空间。
82  int sys_phys()
83  {
84          return -ENOSYS;
85  }
86
87  int sys_lock()
88  {
89          return -ENOSYS;
90  }
91
92  int sys_mpx()
93  {
94          return -ENOSYS;
95  }
96
97  int sys_ulimit()
98  {
99          return -ENOSYS;
100 }
101
    // 返回从 1970 年 1 月 1 日 00:00:00 GMT 开始计时的时间值（秒）。如果 tloc 不为 null，则时间值
    // 也存储在那里。
102 int sys_time(long * tloc)
103 {
104         int i;
105
106         i = CURRENT_TIME;
107         if (tloc) {
108                 verify_area(tloc,4);    // 验证内存容量是否够（这里是 4 字节）。
109                 put_fs_long(i,(unsigned long *)tloc);   // 也放入用户数据段 tloc 处。
110         }
111         return i;
112 }
113
114 /*
```

```
115  * Unprivileged users may change the real user id to the effective uid
116  * or vice versa.
117  */
     /*
      * 无特权的用户可以见实际用户标识符(real uid)改成有效用户标识符(effective uid)，反之也然。
      */
     // 设置任务的实际以及/或者有效用户 ID（uid）。如果任务没有超级用户特权，那么只能互换其
     // 实际用户 ID 和有效用户 ID。如果任务具有超级用户特权，就能任意设置有效的和实际的用户 ID。
     // 保留的 uid（saved uid）被设置成与有效 uid 同值。
118  int sys_setreuid(int ruid, int euid)
119  {
120          int old_ruid = current->uid;
121
122          if (ruid>0) {
123                  if ((current->euid==ruid) ||
124                      (old_ruid == ruid) ||
125                      suser())
126                          current->uid = ruid;
127                  else
128                          return(-EPERM);
129          }
130          if (euid>0) {
131                  if ((old_ruid == euid) ||
132                      (current->euid == euid) ||
133                      suser())
134                          current->euid = euid;
135                  else {
136                          current->uid = old_ruid;
137                          return(-EPERM);
138                  }
139          }
140          return 0;
141  }
142
     // 设置任务用户号(uid)。如果任务没有超级用户特权，它可以使用 setuid()将其有效 uid
     //  （effective uid）设置成其保留 uid(saved uid)或其实际 uid(real uid)。如果任务有
     // 超级用户特权，则实际 uid、有效 uid 和保留 uid 都被设置成参数指定的 uid。
143  int sys_setuid(int uid)
144  {
145          return(sys_setreuid(uid, uid));
146  }
147
     // 设置系统时间和日期。参数 tptr 是从 1970 年 1 月 1 日 00:00:00 GMT 开始计时的时间值（秒）。
     // 调用进程必须具有超级用户权限。
148  int sys_stime(long * tptr)
149  {
150          if (!suser())                   // 如果不是超级用户则出错返回（许可）。
151                  return -EPERM;
152          startup_time = get_fs_long((unsigned long *)tptr) - jiffies/HZ;
153          return 0;
154  }
155
     // 获取当前任务时间。tms 结构中包括用户时间、系统时间、子进程用户时间、子进程系统时间。
```

```
156 int sys_times(struct tms * tbuf)
157 {
158         if (tbuf) {
159                 verify_area(tbuf,sizeof *tbuf);
160                 put_fs_long(current->utime,(unsigned long *)&tbuf->tms_utime);
161                 put_fs_long(current->stime,(unsigned long *)&tbuf->tms_stime);
162                 put_fs_long(current->cutime,(unsigned long *)&tbuf->tms_cutime);
163                 put_fs_long(current->cstime,(unsigned long *)&tbuf->tms_cstime);
164         }
165         return jiffies;
166 }
167
    // 当参数 end_data_seg 数值合理，并且系统确实有足够的内存，而且进程没有超越其最大数据段大小
    // 时，该函数设置数据段末尾为 end_data_seg 指定的值。该值必须大于代码结尾并且要小于堆栈
    // 结尾 16KB。返回值是数据段的新结尾值（如果返回值与要求值不同，则表明有错发生）。
    // 该函数并不被用户直接调用，而由 libc 库函数进行包装，并且返回值也不一样。
168 int sys_brk(unsigned long end_data_seg)
169 {
    //如果参数>代码结尾，并且小于堆栈-16KB，则设置新数据段结尾值。
170         if (end_data_seg >= current->end_code &&
171             end_data_seg < current->start_stack - 16384)
172                 current->brk = end_data_seg;
173         return current->brk;                        // 返回进程当前的数据段结尾值。
174 }
175
176 /*
177  * This needs some heave checking ...
178  * I just haven't get the stomach for it. I also don't fully
179  * understand sessions/pgrp etc. Let somebody who does explain it.
180  */
    /*
     * 下面代码需要某些严格的检查…
     * 我只是没有胃口来做这些。我也不完全明白 sessions/pgrp 等。还是让了解它们的人来做吧。
     */
    // 设置进程的进程组 ID 为 pgid。
    // 如果参数 pid=0，则使用当前进程号。如果 pgid 为 0，则使用参数 pid 指定的进程的组 ID 作为
    // pgid。如果该函数用于将进程从一个进程组移到另一个进程组，则这两个进程组必须属于同一个
    // 会话(session)。在这种情况下，参数 pgid 指定了要加入的现有进程组 ID，此时该组的会话 ID
    // 必须与将要加入进程的相同(193 行)。
181 int sys_setpgid(int pid, int pgid)
182 {
183         int i;
184
185         if (!pid)                           // 如果参数 pid=0，则使用当前进程号。
186                 pid = current->pid;
187         if (!pgid)                          // 如果 pgid 为 0，则使用当前进程 pid 作为 pgid。
188                 pgid = current->pid;        // [??这里与 POSIX 的描述有出入]
189         for (i=0 ; i<NR_TASKS ; i++)        // 扫描任务数组，查找指定进程号的任务。
190                 if (task[i] && task[i]->pid==pid) {
191                         if (task[i]->leader)        // 如果该任务已经是首领，则出错返回。
192                                 return -EPERM;
193                         if (task[i]->session != current->session) // 如果该任务的会话 ID
194                                 return -EPERM;      // 与当前进程的不同，则出错返回。
```

```
195                         task[i]->pgrp = pgid;       // 设置该任务的 pgrp。
196                         return 0;
197                 }
198         return -ESRCH;
199 }
200
    // 返回当前进程的组号。与 getpgid(0)等同。
201 int sys_getpgrp(void)
202 {
203         return current->pgrp;
204 }
205
    // 创建一个会话(session)（即设置其 leader=1），并且设置其会话号=其组号=其进程号。
    // setsid -- SET Session ID。
206 int sys_setsid(void)
207 {
208         if (current->leader && !suser())    // 如果当前进程已是会话首领并且不是超级用户
209                 return -EPERM;              // 则出错返回。
210         current->leader = 1;                // 设置当前进程为新会话首领。
211         current->session = current->pgrp = current->pid; // 设置本进程 session = pid。
212         current->tty = -1;                  // 表示当前进程没有控制终端。
213         return current->pgrp;               // 返回会话 ID。
214 }
215
    // 获取系统信息。其中 utsname 结构包含 5 个字段，分别是：本版本操作系统的名称、网络节点名称、
    // 当前发行级别、版本级别和硬件类型名称。
216 int sys_uname(struct utsname * name)
217 {
218         static struct utsname thisname = {  // 这里给出了结构中的信息，这种编码肯定会改变。
219                 "linux .0","nodename","release ","version ","machine "
220         };
221         int i;
222
223         if (!name) return -ERROR;           // 如果存放信息的缓冲区指针为空则出错返回。
224         verify_area(name,sizeof *name);     // 验证缓冲区大小是否超限（超出已分配的内存等）。
225         for(i=0;i<sizeof *name;i++)         // 将 utsname 中的信息逐字节复制到用户缓冲区中。
226                 put_fs_byte(((char *) &thisname)[i],i+(char *) name);
227         return 0;
228 }
229
    // 设置当前进程创建文件属性屏蔽码为 mask & 0777。并返回原屏蔽码。
230 int sys_umask(int mask)
231 {
232         int old = current->umask;
233
234         current->umask = mask & 0777;
235         return (old);
236 }
237
```

5.13 vsprintf.c 程序

5.13.1 功能描述

该程序主要包括 vsprintf()函数，用于对参数产生格式化的输出。由于该函数是 C 函数库中的标准函数，基本没有涉及内核工作原理方面的内容，因此可以跳过。直接阅读代码后对该函数的使用说明。vsprintf()函数的使用方法请参照 C 库函数手册。

5.13.2 代码注释

程序 5-11 linux/kernel/vsprintf.c

```
1  /*
2   *  linux/kernel/vsprintf.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /* vsprintf.c -- Lars Wirzenius & Linus Torvalds. */
8  /*
9   * Wirzenius wrote this portably, Torvalds fucked it up :-)
10  */
    // Lars Wirzenius 是 Linus 的好友，在 Helsinki 大学时曾同处一间办公室。在 1991 年夏季开发 Linux
    // 时，Linus 当时对 C 语言还不是很熟悉，还不会使用可变参数列表函数功能。因此 Lars Wirzenius
    // 就为他编写了这段用于内核显示信息的代码。他后来(1998 年)承认在这段代码中有一个 bug，直到
    // 1994 年才有人发现，并予以纠正。这个 bug 是在使用*作为输出域宽度时，忘记递增指针跳过这个星
    // 号了。在本代码中这个 bug 还仍然存在（130 行）。 他的个人主页是 http://liw.iki.fi/liw/
11
12 #include <stdarg.h>        // 标准参数头文件。以宏的形式定义变量参数列表。主要说明了-个
                              // 类型(va_list)和三个宏(va_start, va_arg 和 va_end)，用于
                              // vsprintf、vprintf、vfprintf 函数。
13 #include <string.h>        // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
14
15 /* we use this so that we can do without the ctype library */
   /* 我们使用下面的定义，这样我们就可以不使用 ctype 库了 */
16 #define is_digit(c)     ((c) >= '0' && (c) <= '9')   // 判断字符是否数字字符。
17
   // 该函数将字符数字串转换成整数。输入是数字串指针的指针，返回是结果数值。另外指针将前移。
18 static int skip_atoi(const char **s)
19 {
20         int i=0;
21
22         while (is_digit(**s))
23                 i = i*10 + *((*s)++) - '0';
24         return i;
25 }
26
   // 这里定义转换类型的各种符号常数。
27 #define ZEROPAD 1               /* pad with zero */         /* 填充零 */
28 #define SIGN    2               /* unsigned/signed long */  /* 无符号/符号长整数 */
29 #define PLUS    4               /* show plus */             /* 显示加 */
30 #define SPACE   8               /* space if plus */         /* 如是加，则置空格 */
```

```
31 #define LEFT    16              /* left justified */      /* 左调整 */
32 #define SPECIAL 32              /* 0x */                  /* 0x */
33 #define SMALL   64              /* use 'abcdef' instead of 'ABCDEF' */ /* 使用小写字母 */
34
   // 除操作。输入：n 为被除数，base 为除数；结果：n 为商，函数返回值为余数。
   // 参见 4.5.3 节有关嵌入汇编的信息。
35 #define do_div(n,base) ({ \
36 int __res; \
37 __asm__("divl %4":"=a" (n),"=d" (__res):"" (n),"1" (0),"r" (base)); \
38 __res; })
39
   // 将整数转换为指定进制的字符串。
   // 输入：num-整数；base-进制；size-字符串长度；precision-数字长度(精度)；type-类型选项。
   // 输出：str 字符串指针。
40 static char * number(char * str, int num, int base, int size, int precision
41         ,int type)
42 {
43         char c,sign,tmp[36];
44         const char *digits="0123456789ABCDEFGHIJKLMNOPQRSTUVWXYZ";
45         int i;
46
   // 如果类型 type 指出用小写字母，则定义小写字母集。
   // 如果类型指出要左调整（靠左边界），则屏蔽类型中的填零标志。
   // 如果进制基数小于 2 或大于 36，则退出处理，也即本程序只能处理基数在 2-32 之间的数。
47         if (type&SMALL) digits="0123456789abcdefghijklmnopqrstuvwxyz";
48         if (type&LEFT) type &= ~ZEROPAD;
49         if (base<2 || base>36)
50                 return 0;
   // 如果类型指出要填零，则置字符变量 c='0'（也即''），否则 c 等于空格字符。
   // 如果类型指出是带符号数并且数值 num 小于 0，则置符号变量 sign=负号，并使 num 取绝对值。
   // 否则如果类型指出是加号，则置 sign=加号，否则若类型带空格标志则 sign=空格，否则置 0。
51         c = (type & ZEROPAD) ? '0' : ' ';
52         if (type&SIGN && num<0) {
53                 sign='-';
54                 num = -num;
55         } else
56                 sign=(type&PLUS) ? '+' : ((type&SPACE) ? ' ' : 0);
   // 若带符号，则宽度值减 1。若类型指出是特殊转换，则对于十六进制宽度再减少 2 位(用于 0x)，
   // 对于八进制宽度减 1（用于八进制转换结果前放一个零）。
57         if (sign) size--;
58         if (type&SPECIAL)
59                 if (base==16) size -= 2;
60                 else if (base==8) size--;
   // 如果数值 num 为 0，则临时字符串='0'；否则根据给定的基数将数值 num 转换成字符形式。
61         i=0;
62         if (num==0)
63                 tmp[i++]='0';
64         else while (num!=0)
65                 tmp[i++]=digits[do_div(num,base)];
   // 若数值字符个数大于精度值，则精度值扩展为数字个数值。
   // 宽度值 size 减去用于存放数值字符的个数。
66         if (i>precision) precision=i;
67         size -= precision;
```

```
    // 从这里真正开始形成所需要的转换结果，并暂时放在字符串 str 中。
    // 若类型中没有填零(ZEROPAD)和左靠齐（左调整）标志，则在 str 中首先
    // 填放剩余宽度值指出的空格数。若需带符号位，则存入符号。
 68         if (!(type&(ZEROPAD+LEFT)))
 69                 while(size-->0)
 70                         *str++ = ' ';
 71         if (sign)
 72                 *str++ = sign;
    // 若类型指出是特殊转换，则对于八进制转换结果头一位放置一个'0'；而对于十六进制则存放'0x'。
 73         if (type&SPECIAL)
 74                 if (base==8)
 75                         *str++ = '';
 76                 else if (base==16) {
 77                         *str++ = '';
 78                         *str++ = digits[33];   // 'X'或'x'
 79                 }
    // 若类型中没有左调整（左靠齐）标志，则在剩余宽度中存放 c 字符（'0'或空格），见 51 行。
 80         if (!(type&LEFT))
 81                 while(size-->0)
 82                         *str++ = c;
    // 此时 i 存有数值 num 的数字个数。若数字个数小于精度值，则 str 中放入（精度值-i）个'0'。
 83         while(i<precision--)
 84                 *str++ = '';
    // 将转数值换好的数字字符填入 str 中。共 i 个。
 85         while(i-->0)
 86                 *str++ = tmp[i];
    // 若宽度值仍大于零，则表示类型标志中有左靠齐标志。则在剩余宽度中放入空格。
 87         while(size-->0)
 88                 *str++ = ' ';
 89         return str;    // 返回转换好的字符串。
 90 }
 91
    // 下面函数是送格式化输出到字符串中。
    // 为了能在内核中使用格式化的输出，Linus 在内核实现了该 C 标准函数。
    // 其中参数 fmt 是格式字符串；args 是个数变化的值；buf 是输出字符串缓冲区。
    // 请参见本代码列表后的有关格式转换字符的介绍。
 92 int vsprintf(char *buf, const char *fmt, va_list args)
 93 {
 94         int len;
 95         int i;
 96         char * str;             // 用于存放转换过程中的字符串。
 97         char *s;
 98         int *ip;
 99
100         int flags;              /* flags to number() */
101                                 /* number()函数使用的标志 */
102         int field_width;        /* width of output field */
                                    /* 输出字段宽度*/
103         int precision;          /* min. # of digits for integers; max
104                                    number of chars for from string */
                                    /* min. 整数数字个数；max. 字符串中字符个数 */
105         int qualifier;          /* 'h', 'l', or 'L' for integer fields */
```

```
106                                 /* 'h', 'l',或'L'用于整数字段 */
    // 首先将字符指针指向 buf，然后扫描格式字符串，对各个格式转换指示进行相应的处理。
107         for (str=buf ; *fmt ; ++fmt) {
    // 格式转换指示字符串均以'%'开始，这里从 fmt 格式字符串中扫描'%'，寻找格式转换字符串的开始。
    // 不是格式指示的一般字符均被依次存入 str。
108                 if (*fmt != '%') {
109                         *str++ = *fmt;
110                         continue;
111                 }
112
    // 下面取得格式指示字符串中的标志域，并将标志常量放入 flags 变量中。
113                 /* process flags */
114                 flags = 0;
115                 repeat:
116                         ++fmt;          /* this also skips first '%' */
117                         switch (*fmt) {
118                                 case '-': flags |= LEFT; goto repeat;    // 左靠齐调整。
119                                 case '+': flags |= PLUS; goto repeat;    // 放加号。
120                                 case ' ': flags |= SPACE; goto repeat;   // 放空格。
121                                 case '#': flags |= SPECIAL; goto repeat; // 是特殊转换。
122                                 case '0': flags |= ZEROPAD; goto repeat;  // 要填零(即'0')。
123                                 }
124
    // 取当前参数字段宽度域值，放入 field_width 变量中。如果宽度域中是数值则直接取其为宽度值。
    // 如果宽度域中是字符'*'，表示下一个参数指定宽度。因此调用 va_arg 取宽度值。若此时宽度值
    // 小于 0，则该负数表示其带有标志域'-'标志（左靠齐），因此还需在标志变量中添入该标志，并
    // 将字段宽度值取为其绝对值。
125                 /* get field width */
126                 field_width = -1;
127                 if (is_digit(*fmt))
128                         field_width = skip_atoi(&fmt);
129                 else if (*fmt == '*') {
130                         /* it's the next argument */     // 这里有个 bug，应插入++fmt;
131                         field_width = va_arg(args, int);
132                         if (field_width < 0) {
133                                 field_width = -field_width;
134                                 flags |= LEFT;
135                         }
136                 }
137
    // 下面这段代码，取格式转换串的精度域，并放入 precision 变量中。精度域开始的标志是'.'。
    // 其处理过程与上面宽度域的类似。如果精度域中是数值则直接取其为精度值。如果精度域中是
    // 字符'*'，表示下一个参数指定精度。因此调用 va_arg 取精度值。若此时宽度值小于 0，则将
    // 字段精度值取为 0。
138                 /* get the precision */
139                 precision = -1;
140                 if (*fmt == '.') {
141                         ++fmt;
142                         if (is_digit(*fmt))
143                                 precision = skip_atoi(&fmt);
144                         else if (*fmt == '*') {
145                                 /* it's the next argument */  // 同上这里也应插入++fmt;
146                                 precision = va_arg(args, int);
```

```
147                     }
148                     if (precision < 0)
149                             precision = 0;
150             }
151
    // 下面这段代码分析长度修饰符，并将其存入 qualifer 变量。（h,l,L 的含义参见列表后的说明）。
152             /* get the conversion qualifier */
153             qualifier = -1;
154             if (*fmt == 'h' || *fmt == 'l' || *fmt == 'L') {
155                     qualifier = *fmt;
156                     ++fmt;
157             }
158
    // 下面分析转换指示符。
159             switch (*fmt) {
    // 如果转换指示符是'c'，则表示对应参数应是字符。此时如果标志域表明不是左靠齐，则该字段前面
    // 放入'宽度域值-1'个空格字符，然后再放入参数字符。如果宽度域还大于 0，则表示为左靠齐，则在
    // 参数字符后面添加'宽度值-1'个空格字符。
160             case 'c':
161                     if (!(flags & LEFT))
162                             while (--field_width > 0)
163                                     *str++ = ' ';
164                     *str++ = (unsigned char) va_arg(args, int);
165                     while (--field_width > 0)
166                             *str++ = ' ';
167                     break;
168
    // 如果转换指示符是's'，则表示对应参数是字符串。首先取参数字符串的长度，若其超过了精度域值，
    // 则扩展精度域=字符串长度。此时如果标志域表明不是左靠齐，则该字段前放入'宽度值-字符串长度'
    // 个空格字符。然后再放入参数字符串。如果宽度域还大于 0，则表示为左靠齐，则在参数字符串后面
    // 添加'宽度值-字符串长度'个空格字符。
169             case 's':
170                     s = va_arg(args, char *);
171                     len = strlen(s);
172                     if (precision < 0)
173                             precision = len;
174                     else if (len > precision)
175                             len = precision;
176
177                     if (!(flags & LEFT))
178                             while (len < field_width--)
179                                     *str++ = ' ';
180                     for (i = 0; i < len; ++i)
181                             *str++ = *s++;
182                     while (len < field_width--)
183                             *str++ = ' ';
184                     break;
185
    // 如果格式转换符是'o'，表示需将对应的参数转换成八进制数的字符串。调用 number()函数处理。
186             case 'o':
187                     str = number(str, va_arg(args, unsigned long), 8,
188                             field_width, precision, flags);
189                     break;
```

```
190
    // 如果格式转换符是'p'，表示对应参数是一个指针类型。此时若该参数没有设置宽度域，则默认宽度
    // 为 8，并且需要添零。然后调用 number()函数进行处理。
191                 case 'p':
192                         if (field_width == -1) {
193                                 field_width = 8;
194                                 flags |= ZEROPAD;
195                         }
196                         str = number(str,
197                                 (unsigned long) va_arg(args, void *), 16,
198                                 field_width, precision, flags);
199                         break;
200
    // 若格式转换指示是'x'或'X'，则表示对应参数需要打印成十六进制数输出。'x'表示用小写字母表示。
201                 case 'x':
202                         flags |= SMALL;
203                 case 'X':
204                         str = number(str, va_arg(args, unsigned long), 16,
205                                 field_width, precision, flags);
206                         break;
207
    // 如果格式转换字符是'd','i'或'u'，则表示对应参数是整数，'d','i'代表符号整数，因此需要加上
    // 带符号标志。'u'代表无符号整数。
208                 case 'd':
209                 case 'i':
210                         flags |= SIGN;
211                 case 'u':
212                         str = number(str, va_arg(args, unsigned long), 10,
213                                 field_width, precision, flags);
214                         break;
215
    // 若格式转换指示符是'n'，则表示要把到目前为止转换输出字符数保存到对应参数指针指定的位置中。
    // 首先利用 va_arg()取得该参数指针，然后将已经转换好的字符数存入该指针所指的位置。
216                 case 'n':
217                         ip = va_arg(args, int *);
218                         *ip = (str - buf);
219                         break;
220
    // 若格式转换符不是'%'，则表示格式字符串有错，直接将一个'%'写入输出串中。
    // 如果格式转换符的位置处还有字符，则也直接将该字符写入输出串中，并返回到 107 行继续处理
    // 格式字符串。否则表示已经处理到格式字符串的结尾处，则退出循环。
221                 default:
222                         if (*fmt != '%')
223                                 *str++ = '%';
224                         if (*fmt)
225                                 *str++ = *fmt;
226                         else
227                                 --fmt;
228                         break;
229                 }
230         }
231         *str = '\0';            // 最后在转换好的字符串结尾处添上 null。
232         return str-buf;         // 返回转换好的字符串长度值。
```

```
233 }
234
```

5.13.3 其他信息

5.13.3.1 vsprintf()的格式字符串

int vsprintf(char *buf, const char *fmt, va_list args)

vsprintf()函数是 printf()系列函数之一。这些函数都产生格式化的输出：接受确定输出格式的格式字符串 fmt，用格式字符串对个数变化的参数进行格式化，产生格式化的输出。

printf 直接把输出送到标准输出句柄 stdout。cprintf 把输出送到控制台。fprintf 把输出送到文件句柄。printf 前带'v'字符的(例如 vfprintf)表示参数是从 va_arg 数组的 va_list args 中接受。printf 前面带's'字符则表示把输出送到以 null 结尾的字符串 buf 中（此时用户应确保 buf 有足够的空间存放字符串）。下面详细说明格式字符串的使用方法。

1. 格式字符串

printf 系列函数中的格式字符串用于控制函数转换方式、格式化和输出其参数。对于每个格式，必须有对应的参数，参数过多将被忽略。格式字符串中含有两类成份，一种是将被直接复制到输出中的简单字符；另一种是用于对对应参数进行格式化的转换指示字符串。

2. 格式指示字符串

格式指示串的形式如下：

%[flags][width][.prec][|h|l|L][type]

每一个转换指示串均需要以百分号(%)开始。其中

[flags]	是可选择的标志字符序列；
[width]	是可选择的的宽度指示符；
[.prec]	是可选择的精度(precision)指示符；
[h|l|L]	是可选择的输入长度修饰符；
[type]	是转换类型字符(或称为转换指示符)。

flags 控制输出对齐方式、数值符号、小数点、尾零、二进制、八进制或十六进制等，参见上面列表 27-33 行的注释。标志字符及其含义如下：

表示需要将相应参数转换为“特殊形式”。对于八进制(o)，则转换后的字符串的首位必须是一个零。对于十六进制(x 或 X)，则转换后的字符串需以'0x'或'0X'开头。对于 e,E,f,F,g 以及 G，则即使没有小数位，转换结果也将总是有一个小数点。对于 g 或 G，后拖的零也不会删除。

0 转换结果应该是附零的。对于 d,i,o,u,x,X,e,E,f,g 和 G，转换结果的左边将用零填空而不是用空格。如果同时出现 0 和-标志，则 0 标志将被忽略。对于数值转换，如果给出了精度域，0 标志也被忽略。

- 转换后的结果在相应字段边界内将作左调整（靠左）。(默认是作右调整--靠右)。n 转换例外，转换结果将在右面填空格。

' ' 表示带符号转换产生的一个正数结果前应该留一个空格。

+ 表示在一个符号转换结果之前总需要放置一个符号（+或-）。对于默认情况，只有负数使用负号。

width 指定了输出字符串宽度，即指定了字段的最小宽度值。如果被转换的结果要比指定的宽度小，则在其左边（或者右边，如果给出了左调整标志）需要填充空格或零（由 flags 标志确定）的个数等。除了使用数值来指定宽度域以外，也可以使用'*'来指出字段的宽度由下一个整型参数给出。当转换值宽度大于 width 指定的宽度时，在任何情况下小宽度值都不会截断结果。字段宽度会扩充以包含完整结果。

precision 是说明输出数字起码的个数。对于 d,I,o,u,x 和 X 转换，精度值指出了起码出现数字的个数。对于 e,E,f 和 F，该值指出在小数点之后出现的数字的个数。对于 g 或 G，指出最大有效数字个数。对于 s 或 S 转换，精度值说明输出字符串的最大字符数。

长度修饰指示符说明了整型数转换后的输出类型形式。下面叙述中‘整型数转换’代表 d,i,o,u,x 或 X 转换。

hh　　说明后面的整型数转换对应于一个带符号字符或无符号字符参数。

h　　说明后面的整型数转换对应于一个带符号整数或无符号短整数参数。

l　　说明后面的整型数转换对应于一个长整数或无符号长整数参数。

ll　　说明后面的整型数转换对应于一个长长整数或无符号长长整数参数。

L　　说明 e,E,f,F,g 或 G 转换结果对应于一个长双精度参数。

type 是说明接受的输入参数类型和输出的格式。各个转换指示符的含义如下：

d,I　　整数型参数将被转换为带符号整数。如果有精度(precision)的话，则给出了需要输出的最少数字个数。如果被转换的值数字个数较少，就会在其左边添零。默认的精度值是 1。

o,u,x,X　会将无符号的整数转换为无符号八进制(o)、无符号十进制(u)或者是无符号十六进制(x 或 X)表示方式输出。x 表示要使用小写字母（abcdef）来表示十六进制数，X 表示用大写字母（ABCDEF）表示十六进制数。如果存在精度域的话，说明需要输出的最少数字个数。如果被转换的值数字个数较少，就会在其左边添零。默认的精度值是 1。

e,E　　这两个转换字符用于经四舍五入将参数转换成[-]d.ddde±dd 的形式。小数点之后的数字个数等于精度。如果没有精度域，就取默认值 6。如果精度是 0，则没有小数出现。E 表示用大写字母 E 来表示指数。指数部分总是用 2 位数字表示。如果数值为 0，那么指数就是 00。

f,F　　这两个转换字符用于经四舍五入将参数转换成[-]ddd.ddd 的形式。小数点之后的数字个数等于精度。如果没有精度域，就取默认值 6。如果精度是 0，则没有小数出现。如果有小数点，那么后面起码会有 1 位数字。

g,G　　这两个转换字符将参数转换为 f 或 e 的格式（如果是 G，则是 F 或 E 格式）。精度值指定了整数的个数。如果没有精度域，则其默认值为 6。如果精度为 0，则作为 1 来对待。如果转换时指数小于 -4 或大于等于精度，则采用 e 格式。小数部分后拖的零将被删除。仅当起码有一位小数时才会出现小数点。

c　　参数将被转换成无符号字符并输出转换结果。

s　　要求输入为指向字符串的指针，并且该字符串要以 null 结尾。如果有精度域，则只输出精度所要求的字符个数，并且字符串无须以 null 结尾。

p　　以指针形式输出十六进制数。

n　　用于把到目前为止转换输出的字符个数保存到由对应输入指针指定的位置中。不对参数进行转换。

%　　输出一个百分号%，不进行转换。也即此时整个转换指示为%%。

5.13.4 与当前版本的区别

由于该文件也属于库函数，所以从 1.2 版内核开始就直接使用库中的函数了。也即删除了该文件。

5.14 printk.c 程序

5.14.1 功能描述

printk()是内核中使用的打印（显示）函数，功能与 C 标准函数库中的 print()相同。重新编写这么一个函数的原因是在内核中不能使用专用于用户模式的 fs 段寄存器，需要首先保存它。printk()函数首先使用 svprintf()对参数进行格式化处理，然后在保存了 fs 段寄存器的情况下调用 tty_write()进行信息的打印显示。

5.14.2 代码注释

程序 5-12 linux/kernel/printk.c

```
 1 /*
 2  *  linux/kernel/printk.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * When in kernel-mode, we cannot use printf, as fs is liable to
 9  * point to 'interesting' things. Make a printf with fs-saving, and
10  * all is well.
11  */
   /*
    * 当处于内核模式时，我们不能使用 printf，因为寄存器 fs 指向其他不感兴趣的地方。
    * 自己编制一个 printf 并在使用前保存 fs，一切就解决了。
    */
12 #include <stdarg.h>       // 标准参数头文件。以宏的形式定义变量参数列表。主要说明了-个
                             // 类型(va_list)和三个宏(va_start, va_arg 和 va_end)，用于
                             // vsprintf、vprintf、vfprintf 函数。
13 #include <stddef.h>       // 标准定义头文件。定义了 NULL, offsetof(TYPE, MEMBER)。
14
15 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
16
17 static char buf[1024];
18
   // 下面该函数 vsprintf()在 linux/kernel/vsprintf.c 中 92 行开始。
19 extern int vsprintf(char * buf, const char * fmt, va_list args);
20
   // 内核使用的显示函数。
21 int printk(const char *fmt, ...)
22 {
23         va_list args;                   // va_list 实际上是一个字符指针类型。
24         int i;
25
26         va_start(args, fmt);            // 参数处理开始函数。在（include/stdarg.h,13）
27         i=vsprintf(buf,fmt,args);       // 使用格式串 fmt 将参数列表 args 输出到 buf 中。
                                           // 返回值 i 等于输出字符串的长度。
28         va_end(args);                   // 参数处理结束函数。
29         __asm__("push %%fs\n\t"         // 保存 fs。
30                 "push %%ds\n\t"
```

```
31                  "pop %%fs\n\t"          // 令 fs = ds。
32                  "pushl %0\n\t"          // 将字符串长度压入堆栈(这三个入栈是调用参数)。
33                  "pushl $_buf\n\t"       // 将 buf 的地址压入堆栈。
34                  "pushl $0\n\t"          // 将数值 0 压入堆栈。是通道号 channel。
35                  "call _tty_write\n\t"   // 调用 tty_write 函数。(kernel/chr_drv/tty_io.c,290)。
36                  "addl $8,%%esp\n\t"     // 跳过（丢弃）两个入栈参数(buf,channel)。
37                  "popl %0\n\t"           // 弹出字符串长度值，作为返回值。
38                  "pop %%fs"              // 恢复原 fs 寄存器。
39                  ::"r" (i):"ax","cx","dx");  // 通知编译器，寄存器 ax,cx,dx 值可能已经改变。
40          return i;                       // 返回字符串长度。
41  }
42
```

5.15 panic.c 程序

5.15.1 功能描述

panic()函数用于显示内核错误信息并使系统进入死循环。在内核程序很多地方，若内核代码在执行过程中出现严重错误时就会调用该函数。在很多情况下调用 panic()函数是一种简明的处理方法。这种做法很好地遵循了 UNIX“尽量简明”的原则。

panic 是“惊慌，恐慌”的意思。在 Douglas Adams 的小说《Hitch hikers Guide to the Galaxy》(《银河徒步旅行者指南》)中，书中最有名的一句话就是“Don't Panic!”。该系列小说是 linux 骇客最常阅读的一类书籍。

5.15.2 代码注释

程序 5-13 linux/kernel/panic.c

```
1  /*
2   *  linux/kernel/panic.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   * This function is used through-out the kernel (includeinh mm and fs)
9   * to indicate a major problem.
10  */
    /*
     * 该函数在整个内核中使用（包括在 头文件*.h, 内存管理程序 mm 和文件系统 fs 中），
     * 用以指出主要的出错问题。
     */
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
13
14 void sys_sync(void);    /* it's really int */ /* 实际上是整型 int (fs/buffer.c,44) */
15
   // 该函数用来显示内核中出现的重大错误信息，并运行文件系统同步函数，然后进入死循环 -- 死机。
   // 如果当前进程是任务 0 的话，还说明是交换任务出错，并且还没有运行文件系统同步函数。
16 volatile void panic(const char * s)
```

```
17 {
18         printk("Kernel panic: %s\n\r",s);
19         if (current == task[0])
20                 printk("In swapper task - not syncing\n\r");
21         else
22                 sys_sync();
23         for(;;);
24 }
25
```

5.16 本章小结

linux/kernel 目录下的 12 个代码文件给出了内核中最为重要的一些机制的实现，主要包括系统调用、进程调度、进程复制以及进程的终止处理四部分。

第6章 块设备驱动程序(block driver)

6.1 概述

操作系统的主要功能之一就是与周边的输入输出设备进行通信，采用统一的接口来控制这些外围设备。操作系统的所有设备可以粗略地分成两种类型：块设备（block device）和字符型设备(character device)。块设备是一种可以以固定大小的数据块为单位进行寻址和访问的设备，例如硬盘设备和软盘设备。字符设备是一种以字符流作为操作对象的设备，不能进行寻址操作。例如打印机设备、网络接口设备和终端设备。为了便于管理和访问，操作系统将这些设备统一地以设备号进行分类。在 Linux 0.11 内核中设备被分成 7 类，即共有 7 个设备号（0 到 6）。每个类型中的设备可再根据子（从、次）设备号来加以进一步区别。表 6–1 中列出了各个设备号的设备类型和相关的设备。从表中可以看出某些设备（内存设备）既可以作为块设备也可以作为字符设备进行访问。本章主要讨论和描述块设备驱动程序的实现原理和方法，关于字符设备的讨论放在下一章中进行。

表 6－1 Linux 0.11 内核中的主设备号

主设备号	类型	说明
0	无	无。
1	块/字符	ram,内存设备（虚拟盘等）。
2	块	fd,软驱设备。
3	块	hd,硬盘设备。
4	字符	ttyx 设备（虚拟或串行终端）。
5	字符	tty 设备。
6	字符	lp 打印机设备。

Linux 0.11 内核主要支持硬盘、软盘和内存虚拟盘三种块设备。由于块设备主要与文件系统和高速缓冲有关，因此在继续阅读本章内容之前最好能够先快速浏览一下文件系统一章的内容。本章所涉及的源代码文件见列表 6-1 所示。

列表 6-1 linux/kernel/blk_drv 目录

	文件名	大小	最后修改时间(GMT)	说明
	Makefile	1951 bytes	1991-12-05 19:59:42	make 配置文件
	blk.h	3464 bytes	1991-12-05 19:58:01	块设备专用头文件
	floppy.c	11429 bytes	1991-12-07 00:00:38	软盘驱动程序
	hd.c	7807 bytes	1991-12-05 19:58:17	硬盘驱动程序
	ll_rw_blk.c	3539 bytes	1991-12-04 13:41:42	块设备接口程序
	ramdisk.c	2740 bytes	1991-12-06 03:08:06	虚拟盘驱动程序

本章程序代码的功能可分为两类，一类是对应各块设备的驱动程序，这类程序有:

1. 硬盘驱动程序 hd.c；
2. 软盘驱动程序 floppy.c；
3. 内存虚拟盘驱动程序 ramdisk.c；

另一类只有一个程序，是内核中其他程序访问块设备的接口程序 ll_rw_blk.c。块设备专用头文件 blk.h 为这三种块设备与 ll_rw_blk.c 程序交互提供了一个统一的设置方式和相同的设备请求开始程序。

6.2 总体功能

对硬盘和软盘块设备上数据的读写操作是通过中断处理程序进行的。内核每次读写的数据量以一个逻辑块（1024 字节）为单位，而块设备控制器则是以扇区（512 字节）为单位。在处理过程中，使用了读写请求项等待队列来顺序缓冲一次读写多个逻辑块的操作。

当程序需要读取硬盘上的一个逻辑块时，就会向缓冲区管理程序提出申请，而程序的进程则进入睡眠等待状态。缓冲区管理程序首先在缓冲区中寻找以前是否已经读取过这块数据。如果缓冲区中已经有了，就直接将对应的缓冲区块头指针返回给程序并唤醒该程序进程。若缓冲区中还不存在所要求的数据块，则缓冲管理程序就会调用本章中的低级块读写函数 ll_rw_block()，向相应的块设备驱动程序发出一个读数据块的操作请求。该函数会为此创建一个请求结构项，并插入请求队列中。为了提供读写磁盘的效率，减小磁头移动的距离，在插入请求项时使用了电梯移动算法。

此时，若对应块设备的请求项队列为空，则表明此刻该块设备不忙。于是内核就会立刻向该块设备的控制器发出读数据命令。当块设备的控制器将数据读入到指定的缓冲块中后，就会发出中断请求信号，并调用相应的读命令后处理函数，处理继续读扇区操作或者结束本次请求项的过程。例如对相应块设备进行关闭操作和设置该缓冲块数据已经更新标志，最后唤醒等待该块数据的进程。

6.2.1 块设备请求项和请求队列

根据上面描述，我们知道低级读写函数 ll_rw_block()是通过请求项来与各种块设备建立联系并发出读写请求。对于各种块设备，内核使用了一张块设备表 blk_dev[]来进行管理。每种块设备都在块设备表中占有一项。块设备表中每个块设备项的结构为（摘自后面 blk.h）：

```
struct blk_dev_struct {
        void (*request_fn)(void);               // 请求项操作的函数指针。
        struct request * current_request;       // 当前请求项指针。
};
extern struct blk_dev_struct blk_dev[NR_BLK_DEV]; // 块设备表（数组）（NR_BLK_DEV = 7）。
```

其中，第一个字段是一个函数指针，用于操作相应块设备的请求项。例如，对于硬盘驱动程序，它是 do_hd_request()，而对于软盘设备，它就是 do_floppy_request()。第二个字段是当前请求项结构指针，用于指明本块设备目前正在处理的请求项，初始化时都被置成 NULL。

块设备表将在内核初始化时，在 init/main.c 程序调用各设备的初始化函数时被设置。为了便于扩展，Linus 把块设备表建成了一个以主设备号为索引的数组。在 Linux 0.11 中，主设备号有 7 种，见表 6–2 所示。其中，主设备号 1、2 和 3 分别对应块设备：虚拟盘、软盘和硬盘。在块设备数组中其他各项都被默认地置成 NULL。

表 6－2 内核中的主设备号与相关操作函数

主设备号	类型	说明	请求项操作函数

0	无	无。	NULL
1	块/字符	ram,内存设备（虚拟盘等）。	do_rd_request()
2	块	fd,软驱设备。	do_fd_request()
3	块	hd,硬盘设备。	do_hd_request()
4	字符	ttyx 设备（虚拟或串行终端等）。	NULL
5	字符	tty 设备。	NULL
6	字符	lp 打印机设备。	NULL

当内核发出一个块设备读写或其他操作请求时，ll_rw_block()函数即会根据其参数中指明的操作命令和数据缓冲块头中的设备号，利用对应的请求项操作函数 do_XX_request()建立一个块设备请求项，并利用电梯算法插入到请求项队列中。请求项队列由请求项数组中的项构成，共有 32 项，每个请求项的数据结构如下所示：

```
struct request {
        int dev;                        // 使用的设备号（若为-1，表示该项空闲）。
        int cmd;                        // 命令(READ 或 WRITE)。
        int errors;                     // 操作时产生的错误次数。
        unsigned long sector;           // 起始扇区。(1 块=2 扇区)
        unsigned long nr_sectors;       // 读/写扇区数。
        char * buffer;                  // 数据缓冲区。
        struct task_struct * waiting;   // 任务等待操作执行完成的地方。
        struct buffer_head * bh;        // 缓冲区头指针(include/linux/fs.h,68)。
        struct request * next;          // 指向下一请求项。
};
extern struct request request[NR_REQUEST];     // 请求队列数组（NR_REQUEST = 32）。
```

每个块设备的当前请求指针与请求项数组中该设备的请求项链表共同构成了该设备的请求队列。项与项之间利用字段 next 指针形成链表。因此块设备项和相关的请求队列形成如下所示结构。请求项采用数组加链表结构的主要原因是为了满足两个目的：一是利用请求项的数组结构在搜索空闲请求块时可以进行循环操作，因此程序可以编制得很简洁；二是为满足电梯算法插入请求项操作，因此也需要采用链表结构。图 6-1 中示出了硬盘设备当前具有 4 个请求项，软盘设备具有 1 个请求项，而虚拟盘设备目前暂时没有读写请求项。

对于一个当前空闲的块设备，当 ll_rw_block()函数为其建立第一个请求项时，会让该设备的当前请求项指针 current_request 直接指向刚建立的请求项，并且立刻调用对应设备的请求项操作函数开始执行块设备读写操作。当一个块设备已经有几个请求项组成的链表存在，ll_rw_block()就会利用电梯算法，根据磁头移动距离最小原则，把新建的请求项插入到链表适当的位置处。

另外，为满足读操作的优先权，在为建立新的请求项而搜索请求项数组时，把建立写操作时的空闲项搜索范围限制在整个请求项数组的前 2/3 范围内，而剩下的 1/3 请求项专门给读操作建立请求项使用。

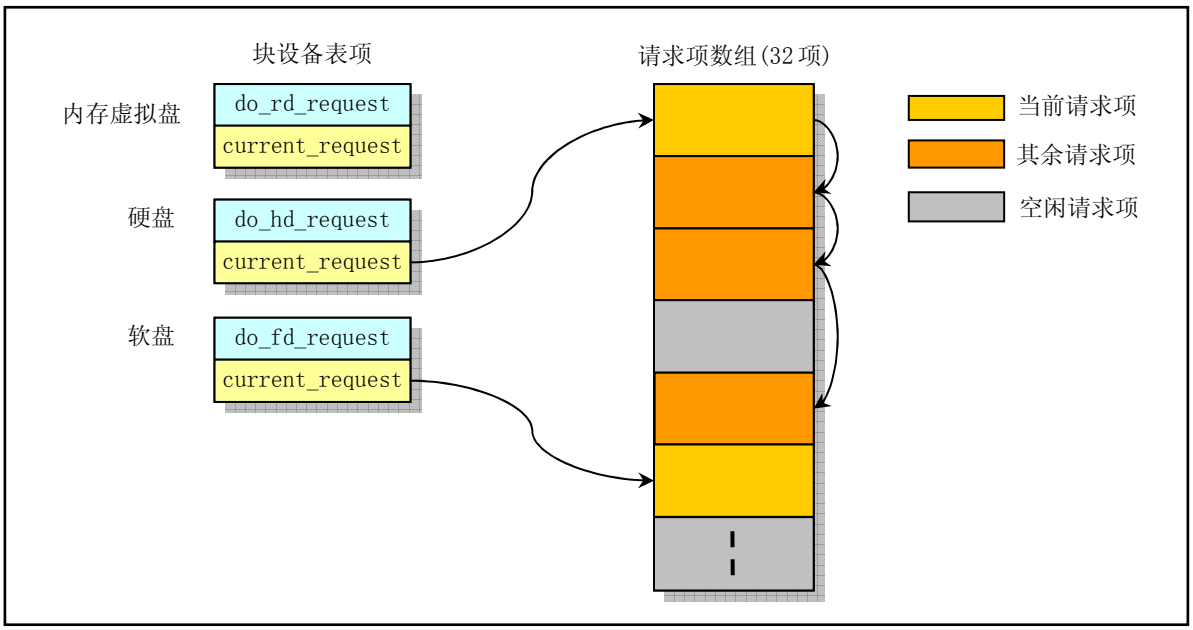

图 6-1 设备表项与请求项

6.2.2 块设备操作方式

在系统（内核）与硬盘进行 IO 操作时，需要考虑三个对象之间的交互作用。它们是系统、控制器和驱动器（例如硬盘或软盘驱动器），见图 6-2 所示。系统可以直接向控制器发送命令或等待控制器发出中断请求；控制器在接收到命令后就会控制驱动器的操作，读/写数据或者进行其他操作。因此我们可以把这里控制器发出的中断信号看作是这三者之间的同步操作信号，所经历的操作步骤为：

首先系统指明控制器在执行命令结束而引发的中断过程中应该调用的 C 函数，然后向块设备控制器发送读、写、复位或其他操作命令；

当控制器完成了指定的命令，会发出中断请求信号，引发系统执行块设备的中断处理过程，并在其中调用指定的 C 函数对读/写或其他命令进行命令结束后的处理工作。

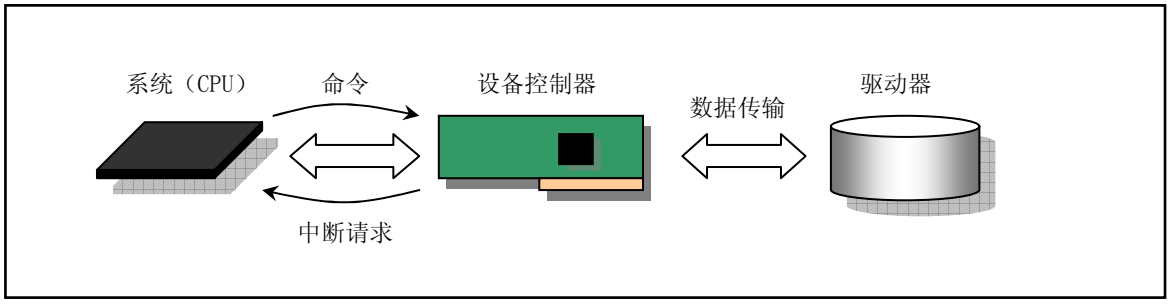

图 6-2 系统、块设备控制器和驱动器

对于写盘操作，系统需要在发出了写命令后（使用 hd_out()）等待控制器给予允许向控制器写数据的响应，也即需要查询等待控制器状态寄存器的数据请求服务标志 DRQ 置位。一旦 DRQ 置位，系统就可以向控制器缓冲区发送一个扇区的数据，同样也使用 hd_out()函数。

当控制器把数据全部写入驱动器（后发生错误）以后，还会产生中断请求信号，从而在中断处理过程中执行前面预设置的 C 函数（write_intr()）。这个函数会查询是否还有数据要写。如果有，系统就再把一个扇区的数据传到控制器缓冲区中，然后再次等待控制器把数据写入驱动器后引发的中断，一直这样

重复执行。如果此时所有数据都已经写入驱动器，则该 C 函数就执行本次写盘结束后的处理工作：唤醒等待该请求项有关数据的相关进程、唤醒等待请求项的进程、释放当前请求项并从链表中删除该请求项以及释放锁定的相关缓冲区。最后再调用请求项操作函数去执行下一个读/写盘请求项（若还有的话）。

对于读盘操作，系统在向控制器发送出包括需要读的扇区开始位置、扇区数量等信息的命令后，就等待控制器产生中断信号。当控制器按照读命令的要求，把指定的一扇区数据从驱动器传到了自己的缓冲区之后就会发出中断请求。从而会执行到前面为读盘操作预设置的 C 函数（read_intr()）。该函数首先把控制器缓冲区中一个扇区的数据放到系统的缓冲区中，调整系统缓冲区中当前写入位置，然后递减需读的扇区数量。若还有数据要读（递减结果值不为 0），则继续等待控制器发出下一个中断信号。若此时所有要求的扇区都已经读到系统缓冲区中，就执行与上面写盘操作一样的结束处理工作。

对于虚拟盘设备，由于它的读写操作不牵涉到与外部设备之间的同步操作，因此没有上述的中断处理过程。当前请求项对虚拟设备的读写操作完全在 do_rd_request()中实现。

6.3 Makefile 文件

6.3.1 功能描述

该 makefile 文件用于管理对本目录下所有程序的编译。

6.3.2 代码注释

程序 6-1 linux/kernel/blk_drv/Makefile

```
 1 #
 2 # Makefile for the FREAX-kernel block device drivers.
 3 #
 4 # Note! Dependencies are done automagically by 'make dep', which also
 5 # removes any old dependencies. DON'T put your own dependencies here
 6 # unless it's something special (ie not a .c file).
 7 #
   # FREAX 内核块设备驱动程序的 Makefile 文件
   # 注意！依赖关系是由'make dep'自动进行的，它也会自动去除原来的依赖信息。不要把你自己的
   # 依赖关系信息放在这里，除非是特别文件的（也即不是一个.c 文件的信息）。
   # (Linux 最初的名字叫 FREAX，后来被 ftp.funet.fi 的管理员改成 Linux 这个名字)。
 8
 9 AR      =gar    # GNU 的二进制文件处理程序，用于创建、修改以及从归档文件中抽取文件。
10 AS      =gas    # GNU 的汇编程序。
11 LD      =gld    # GNU 的连接程序。
12 LDFLAGS =-s -x  # 连接程序所有的参数，-s 输出文件中省略所有符号信息。-x 删除所有局部符号。
13 CC      =gcc    # GNU C 语言编译器。
   # 下一行是 C 编译程序选项。-Wall 显示所有的警告信息；-O 优化选项，优化代码长度和执行时间；
   # -fstrength-reduce 优化循环执行代码，排除重复变量；-fomit-frame-pointer 省略保存不必要
   # 的框架指针；-fcombine-regs 合并寄存器，减少寄存器类的使用；-finline-functions 将所有简
   # 单短小的函数代码嵌入调用程序中；-mstring-insns Linus 自己填加的优化选项，以后不再使用；
   # -nostdinc -I../include 不使用默认路径中的包含文件，而使用指定目录中的(../../include)。
14 CFLAGS  =-Wall -O -fstrength-reduce -fomit-frame-pointer -fcombine-regs \
15         -finline-functions -mstring-insns -nostdinc -I../../include
   # C 前处理选项。-E 只运行 C 前处理，对所有指定的 C 程序进行预处理并将处理结果输出到标准输
   # 出设备或指定的输出文件中；-nostdinc -I../../include 同前。
```

```
16 CPP     =gcc -E -nostdinc -I../../include
17
   # 下面的规则指示 make 利用下面的命令将所有的.c 文件编译生成.s 汇编程序。该规则的命令
   # 指使 gcc 采用 CFLAGS 所指定的选项对 C 代码编译后不进行汇编就停止（-S），从而产生与
   # 输入的各个 C 文件对应的汇编代码文件。默认情况下所产生的汇编程序文件名是原 C 文件名
   # 去掉.c 而加上.s 后缀。-o 表示其后是输出文件的名称。其中$*.s（或$@）是自动目标变量，
   # $<代表第一个先决条件，这里即是符合条件*.c 的文件。
18 .c.s:
19         $(CC) $(CFLAGS) \
20         -S -o $*.s $<
  # 下面规则表示将所有.s 汇编程序文件编译成.o 目标文件。22 行是实现该操作的具体命令。
21 .s.o:
22         $(AS) -c -o $*.o $<
23 .c.o:                     # 类似上面，*.c 文件-→*.o 目标文件。不进行连接。
24         $(CC) $(CFLAGS) \
25         -c -o $*.o $<
26
27 OBJS  = ll_rw_blk.o floppy.o hd.o ramdisk.o        # 定义目标文件变量 OBJS。
28
   # 在有了先决条件 OBJS 后使用下面的命令连接成目标 blk_drv.a 库文件。
29 blk_drv.a: $(OBJS)
30         $(AR) rcs blk_drv.a $(OBJS)
31         sync
32
   # 下面的规则用于清理工作。当执行'make clean'时，就会执行 34--35 行上的命令，去除所有编译
   # 连接生成的文件。'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
33 clean:
34         rm -f core *.o *.a tmp_make
35         for i in *.c;do rm -f `basename $$i .c`.s;done
36
   # 下面得目标或规则用于检查各文件之间的依赖关系。方法如下：
   # 使用字符串编辑程序 sed 对 Makefile 文件（即是本文件）进行处理，输出为删除 Makefile
   # 文件中'### Dependencies'行后面的所有行（下面从 44 开始的行），并生成 tmp_make
   # 临时文件（38 行的作用）。然后对 kernel/blk_drv/目录下的每个 C 文件执行 gcc 预处理操作.
   # -M 标志告诉预处理程序输出描述每个目标文件相关性的规则，并且这些规则符合 make 语法。
   # 对于每一个源文件，预处理程序输出一个 make 规则，其结果形式是相应源程序文件的目标
   # 文件名加上其依赖关系--该源文件中包含的所有头文件列表。把预处理结果都添加到临时
   # 文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。
37 dep:
38         sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
39         (for i in *.c;do echo -n `echo $$i | sed 's,\.c,\.s,'`" "; \
40                 $(CPP) -M $$i;done) >> tmp_make
41         cp tmp_make Makefile
42
43 ### Dependencies:
44 floppy.s floppy.o : floppy.c ../../include/linux/sched.h ../../include/linux/head.h \
45   ../../include/linux/fs.h ../../include/sys/types.h ../../include/linux/mm.h \
46   ../../include/signal.h ../../include/linux/kernel.h \
47   ../../include/linux/fdreg.h ../../include/asm/system.h \
48   ../../include/asm/io.h ../../include/asm/segment.h blk.h
49 hd.s hd.o : hd.c ../../include/linux/config.h ../../include/linux/sched.h \
50   ../../include/linux/head.h ../../include/linux/fs.h \
51   ../../include/sys/types.h ../../include/linux/mm.h ../../include/signal.h \
```

```
52   ../../include/linux/kernel.h ../../include/linux/hdreg.h \
53   ../../include/asm/system.h ../../include/asm/io.h \
54   ../../include/asm/segment.h blk.h
55 ll_rw_blk.s ll_rw_blk.o : ll_rw_blk.c ../../include/errno.h ../../include/linux/sched.h \
56   ../../include/linux/head.h ../../include/linux/fs.h \
57   ../../include/sys/types.h ../../include/linux/mm.h ../../include/signal.h \
58   ../../include/linux/kernel.h ../../include/asm/system.h blk.h
```

6.4 blk.h 文件

6.4.1 功能描述

这是有关硬盘块设备参数的头文件，因为只用于块设备，所以与块设备代码放在同一个地方。其中主要定义了请求等待队列中项的数据结构 request，用宏语句定义了电梯搜索算法，并对内核目前支持的虚拟盘，硬盘和软盘三种块设备，根据它们各自的主设备号分别对应了常数值。

关于该文件中定义的"extern inline"函数的具体含义，GNU CC 使用手册中的说明如下[8]：

> 如果在函数定义中同时指定了 inline 和 extern 关键字，则该函数定义仅作为嵌入（内联）使用。并且在任何情况下该函数自身都不会被编译，即使明确地指明其地址也没用。这样的地址只能成为一个外部引用，就好象你仅声明了该函数，而没有定义该函数。
>
> inline 与 extern 组合所产生的作用几乎与一个宏（macro）相同。使用这种组合的方法是将一个函数定义和这些关键字放在一个头文件中，并且把该函数定义的另一个拷贝（去除 inline 和 extern）放在一个库文件中。头文件中的函数定义将导致大多数函数调用成为嵌入形式。如果还有其他地方使用该函数，那么它们将引用到库文件中单独的拷贝。

6.4.2 代码注释

程序 6-2 linux/kernel/blk_drv/blk.h

```
1 #ifndef _BLK_H
2 #define _BLK_H
3
4 #define NR_BLK_DEV      7       // 块设备的数量。
5 /*
6  * NR_REQUEST is the number of entries in the request-queue.
7  * NOTE that writes may use only the low 2/3 of these: reads
8  * take precedence.
9  *
10 * 32 seems to be a reasonable number: enough to get some benefit
11 * from the elevator-mechanism, but not so much as to lock a lot of
12 * buffers when they are in the queue. 64 seems to be too many (easily
13 * long pauses in reading when heavy writing/syncing is going on)
14 */
  /*
   * 下面定义的 NR_REQUEST 是请求队列中所包含的项数。
```

[8] GNU CC 手册“An Inline Function is As Fast As a Macro”。

```
 * 注意，读操作仅使用这些项低端的 2/3；读操作优先处理。
 *
 * 32 项好象是一个合理的数字：已经足够从电梯算法中获得好处，
 * 但当缓冲区在队列中而锁住时又不显得是很大的数。64 就看上
 * 去太大了（当大量的写/同步操作运行时很容易引起长时间的暂停）。
 */
15 #define NR_REQUEST      32
16
17 /*
18  * Ok, this is an expanded form so that we can use the same
19  * request for paging requests when that is implemented. In
20  * paging, 'bh' is NULL, and 'waiting' is used to wait for
21  * read/write completion.
22  */
/*
 * OK，下面是 request 结构的一个扩展形式，因而当实现以后，我们就可以在分页请求中
 * 使用同样的 request 结构。在分页处理中，'bh'是 NULL，而'waiting'则用于等待读/写的完成。
 */
// 下面是请求队列中项的结构。其中如果 dev=-1，则表示该项没有被使用。
23 struct request {
24         int dev;                /* -1 if no request */      // 使用的设备号。
25         int cmd;                /* READ or WRITE */         // 命令(READ 或 WRITE)。
26         int errors;                                 //操作时产生的错误次数。
27         unsigned long sector;                       // 起始扇区。(1 块=2 扇区)
28         unsigned long nr_sectors;                   // 读/写扇区数。
29         char * buffer;                              // 数据缓冲区。
30         struct task_struct * waiting;               // 任务等待操作执行完成的地方。
31         struct buffer_head * bh;                    // 缓冲区头指针(include/linux/fs.h,68)。
32         struct request * next;                      // 指向下一请求项。
33 };
34
35 /*
36  * This is used in the elevator algorithm: Note that
37  * reads always go before writes. This is natural: reads
38  * are much more time-critical than writes.
39  */
/*
 * 下面的定义用于电梯算法：注意读操作总是在写操作之前进行。
 * 这是很自然的：读操作对时间的要求要比写操作严格得多。
 */
40 #define IN_ORDER(s1,s2) \
41 ((s1)->cmd<(s2)->cmd || (s1)->cmd==(s2)->cmd && \
42 ((s1)->dev < (s2)->dev || ((s1)->dev == (s2)->dev && \
43 (s1)->sector < (s2)->sector)))
44
// 块设备结构。
45 struct blk_dev_struct {
46         void (*request_fn)(void);           // 请求操作的函数指针。
47         struct request * current_request;   // 请求信息结构。
48 };
49
50 extern struct blk_dev_struct blk_dev[NR_BLK_DEV]; // 块设备表（数组），每种块设备占用一项。
51 extern struct request request[NR_REQUEST];        // 请求队列数组。
```

```
52 extern struct task_struct * wait_for_request;      // 等待空闲请求的任务结构队列头指针。
53
   // 在块设备驱动程序（如 hd.c）要包含此头文件时，必须先定义驱动程序对应设备的主设备号。这样
   // 下面 61 行—87 行就能为包含本文件的驱动程序给出正确的宏定义。
54 #ifdef MAJOR_NR              // 主设备号。
55
56 /*
57  * Add entries as needed. Currently the only block devices
58  * supported are hard-disks and floppies.
59  */
   /*
    * 需要时加入条目。目前块设备仅支持硬盘和软盘（还有虚拟盘）。
    */
60
61 #if (MAJOR_NR == 1)  // RAM 盘的主设备号是 1。根据这里的定义可以推理内存块主设备号也为 1。
62 /* ram disk */       /* RAM 盘（内存虚拟盘）*/
63 #define DEVICE_NAME "ramdisk"              // 设备名称 ramdisk。
64 #define DEVICE_REQUEST do_rd_request       // 设备请求函数 do_rd_request()。
65 #define DEVICE_NR(device) ((device) & 7)   // 设备号(0--7)。
66 #define DEVICE_ON(device)                  // 开启设备。虚拟盘无须开启和关闭。
67 #define DEVICE_OFF(device)                 // 关闭设备。
68
69 #elif (MAJOR_NR == 2)     // 软驱的主设备号是 2。
70 /* floppy */
71 #define DEVICE_NAME "floppy"               // 设备名称 floppy。
72 #define DEVICE_INTR do_floppy              // 设备中断处理程序 do_floppy()。
73 #define DEVICE_REQUEST do_fd_request       // 设备请求函数 do_fd_request()。
74 #define DEVICE_NR(device) ((device) & 3)   // 设备号（0--3）。
75 #define DEVICE_ON(device) floppy_on(DEVICE_NR(device))    // 开启设备函数 floppyon()。
76 #define DEVICE_OFF(device) floppy_off(DEVICE_NR(device)) // 关闭设备函数 floppyoff()。
77
78 #elif (MAJOR_NR == 3)     // 硬盘主设备号是 3。
79 /* harddisk */
80 #define DEVICE_NAME "harddisk"             // 硬盘名称 harddisk。
81 #define DEVICE_INTR do_hd                  // 设备中断处理程序 do_hd()。
82 #define DEVICE_REQUEST do_hd_request       // 设备请求函数 do_hd_request()。
83 #define DEVICE_NR(device) (MINOR(device)/5) // 设备号（0--1）。每个硬盘可以有 4 个分区。
84 #define DEVICE_ON(device)                  // 硬盘一直在工作，无须开启和关闭。
85 #define DEVICE_OFF(device)
86
87 #elif
88 /* unknown blk device */  /* 未知块设备 */
89 #error "unknown blk device"
90
91 #endif
92
93 #define CURRENT (blk_dev[MAJOR_NR].current_request) // CURRENT 是指定主设备号的当前请求结构。
94 #define CURRENT_DEV DEVICE_NR(CURRENT->dev)         // CURRENT_DEV 是 CURRENT 的设备号。
95
   // 下面声明两个宏定义为函数指针。
96 #ifdef DEVICE_INTR
97 void (*DEVICE_INTR)(void) = NULL;
98 #endif
```

```
 99 static void (DEVICE_REQUEST)(void);
100
    // 释放锁定的缓冲区（块）。
101 extern inline void unlock_buffer(struct buffer_head * bh)
102 {
103         if (!bh->b_lock)                // 如果指定的缓冲区 bh 并没有被上锁，则显示警告信息。
104                 printk(DEVICE_NAME ": free buffer being unlocked\n");
105         bh->b_lock=0;                   // 否则将该缓冲区解锁。
106         wake_up(&bh->b_wait);           // 唤醒等待该缓冲区的进程。
107 }
108
    // 结束请求处理。
    // 首先关闭指定块设备，然后检查此次读写缓冲区是否有效。如果有效则根据参数值设置缓冲区数据
    // 更新标志，并解锁该缓冲区。如果更新标志参数值是 0，表示此次请求项的操作已失败，因此显示
    // 相关块设备 IO 错误信息。最后，唤醒等待该请求项的进程以及等待空闲请求项出现的进程，释放
    // 并从请求链表中删除本请求项。
109 extern inline void end_request(int uptodate)
110 {
111         DEVICE_OFF(CURRENT->dev);                   // 关闭设备。
112         if (CURRENT->bh) {                          // CURRENT 为指定主设备号的当前请求结构。
113                 CURRENT->bh->b_uptodate = uptodate;// 置更新标志。
114                 unlock_buffer(CURRENT->bh);         // 解锁缓冲区。
115         }
116         if (!uptodate) {                            // 如果更新标志为 0 则显示设备错误信息。
117                 printk(DEVICE_NAME " I/O error\n\r");
118                 printk("dev %04x, block %d\n\r",CURRENT->dev,
119                         CURRENT->bh->b_blocknr);
120         }
121         wake_up(&CURRENT->waiting);                 // 唤醒等待该请求项的进程。
122         wake_up(&wait_for_request);                 // 唤醒等待请求的进程。
123         CURRENT->dev = -1;                          // 释放该请求项。
124         CURRENT = CURRENT->next;                    // 从请求链表中删除该请求项，并且
125 }                                                   // 当前请求项指针指向下一个请求项。
126
    // 定义初始化请求宏。
127 #define INIT_REQUEST \
128 repeat: \
129         if (!CURRENT) \                         // 如果当前请求结构指针为 null 则返回。
130                 return; \                       // 表示本设备目前已无需要处理的请求项。
131         if (MAJOR(CURRENT->dev) != MAJOR_NR) \  // 如果当前设备的主设备号不对则死机。
132                 panic(DEVICE_NAME ": request list destroyed"); \
133         if (CURRENT->bh) { \
134                 if (!CURRENT->bh->b_lock) \     // 如果在进行请求操作时缓冲区没锁定则死机。
135                         panic(DEVICE_NAME ": block not locked"); \
136         }
137
138 #endif
139
140 #endif
141
```

6.5 hd.c 程序

6.5.1 功能描述

hd.c 程序是硬盘控制器驱动程序，提供对硬盘控制器块设备的读写驱动和硬盘初始化处理。程序中所有函数按照功能不同可分为 5 类：

- 初始化硬盘和设置硬盘所用数据结构信息的函数，如 sys_setup()和 hd_init()；
- 向硬盘控制器发送命令的函数 hd_out()；
- 处理硬盘当前请求项的函数 do_hd_request()；
- 硬盘中断处理过程中调用的 C 函数，如 read_intr()、write_intr()、bad_rw_intr()和 recal_intr()。do_hd_request()函数也将在 read_intr()和 write_intr()中被调用；
- 硬盘控制器操作辅助函数，如 controler_ready()、drive_busy()、win_result()、hd_out()和 reset_controler()等。

sys_setup()函数利用 boot/setup.s 程序提供的信息对系统中所含硬盘驱动器的参数进行了设置。然后读取硬盘分区表，并尝试把启动引导盘上的虚拟盘根文件系统映像文件复制到内存虚拟盘中，若成功则加载虚拟盘中的根文件系统，否则就继续执行普通根文件系统加载操作。

hd_init()函数用于在内核初始化时设置硬盘控制器中断描述符，并复位硬盘控制器中断屏蔽码，以允许硬盘控制器发送中断请求信号。

hd_out()是硬盘控制器操作命令发送函数。该函数带有一个中断过程中调用的 C 函数指针参数，在向控制器发送命令之前，它首先使用这个参数预置好中断过程中会调用的函数指针（do_hd），然后它按照规定的方式依次向硬盘控制器 0x1f0 至 0x1f7 发送命令参数块。除控制器诊断（WIN_DIAGNOSE）和建立驱动器参数（WIN_SPECIFY）两个命令以外，硬盘控制器在接收到任何其他命令并执行了命令以后，都会向 CPU 发出中断请求信号，从而引发系统去执行硬盘中断处理过程（在 system_call.s，221 行）。

do_hd_request()是硬盘请求项的操作函数。其操作流程如下：

- 首先判断当前请求项是否存在，若当前请求项指针为空，则说明目前硬盘块设备已经没有待处理的请求项，因此立刻退出程序。这是在宏 INIT_REQUEST 中执行的语句。否则就继续处理当前请求项。
- 对当前请求项中指明的设备号和请求的盘起始扇区号的合理性进行验证；
- 根据当前请求项提供的信息计算请求数据的磁盘磁道号、磁头号和柱面号；
- 如果复位标志（reset）已被设置，则也设置硬盘重新校正标志（recalibrate），并对硬盘执行复位操作，向控制器重新发送“建立驱动器参数”命令（WIN_SPECIFY）。该命令不会引发硬盘中断；
- 如果重新校正标志被置位的话，就向控制器发送硬盘重新校正命令（WIN_RESTORE），并在发送之前预先设置好该命令引发的中断中需要执行的 C 函数（recal_intr()），并退出。recal_intr()函数的主要作用是：当控制器执行该命令结束并引发中断时，能重新（继续）执行本函数。
- 如果当前请求项指定是写操作，则首先设置硬盘控制器调用的 C 函数为 write_intr()，向控制器发送写操作的命令参数块，并循环查询控制器的状态寄存器，以判断请求服务标志（DRQ）是否置位。若该标志置位，则表示控制器已“同意”接收数据，于是接着就把请求项所指缓冲区中的数据写入控制器的数据缓冲区中。若循环查询超时后该标志仍然没有置位，则说明此次操作失败。于是调用 bad_rw_intr()函数，根据处理当前请求项发生的出错次数来确定是放弃继续当前请求项还是需要设置复位标志，以继续重新处理当前请求项。
- 如果当前请求项是读操作，则设置硬盘控制器调用的 C 函数为 read_intr()，并向控制器发送读盘操作命令。

write_intr()是在当前请求项是写操作时被设置成中断过程调用的 C 函数。控制器完成写盘命令后会

立刻向 CPU 发送中断请求信号，于是在控制器写操作完成后就会立刻调用该函数。

该函数首先调用 win_result()函数，读取控制器的状态寄存器，以判断是否有错误发生。若在写盘操作时发生了错误，则调用 bad_rw_intr()，根据处理当前请求项发生的出错次数来确定是放弃继续当前请求项还是需要设置复位标志，以继续重新处理当前请求项。若没有发生错误，则根据当前请求项中指明的需写扇区总数，判断是否已经把此请求项要求的所有数据写盘了。若还有数据需要写盘，则再把一个扇区的数据复制到控制器缓冲区中。若数据已经全部写盘，则处理当前请求项的结束事宜：唤醒等待本请求项完成的进程、唤醒等待空闲请求项的进程（若有的话）、设置当前请求项所指缓冲区数据已更新标志、释放当前请求项（从块设备链表中删除该项）。最后继续调用 do_hd_request()函数，以继续处理硬盘设备的其他请求项。

read_intr()则是在当前请求项是读操作时被设置成中断过程中调用的 C 函数。控制器在把指定的扇区数据从硬盘驱动器读入自己的缓冲区后，就会立刻发送中断请求信号。而该函数的主要作用就是把控制器中的数据复制到当前请求项指定的缓冲区中。

与 write_intr()开始的处理方式相同，该函数首先也调用 win_result()函数，读取控制器的状态寄存器，以判断是否有错误发生。若在读盘时发生了错误，则执行与 write_intr()同样的处理过程。若没有发生任何错误，则从控制器缓冲区把一个扇区的数据复制到请求项指定的缓冲区中。然后根据当前请求项中指明的欲读扇区总数，判断是否已经读取了所有的数据。若还有数据要读，则退出，以等待下一个中断的到来。若数据已经全部获得，则处理当前请求项的结束事宜：唤醒等待当前请求项完成的进程、唤醒等待空闲请求项的进程（若有的话）、设置当前请求项所指缓冲区数据已更新标志、释放当前请求项（从块设备链表中删除该项）。最后继续调用 do_hd_request()函数，以继续处理硬盘设备的其他请求项。

为了能更清晰的看清楚硬盘读写操作的处理过程，我们可以把这些函数、中断处理过程以及硬盘控制器三者之间的执行时序关系用图 6-3 表示出来。

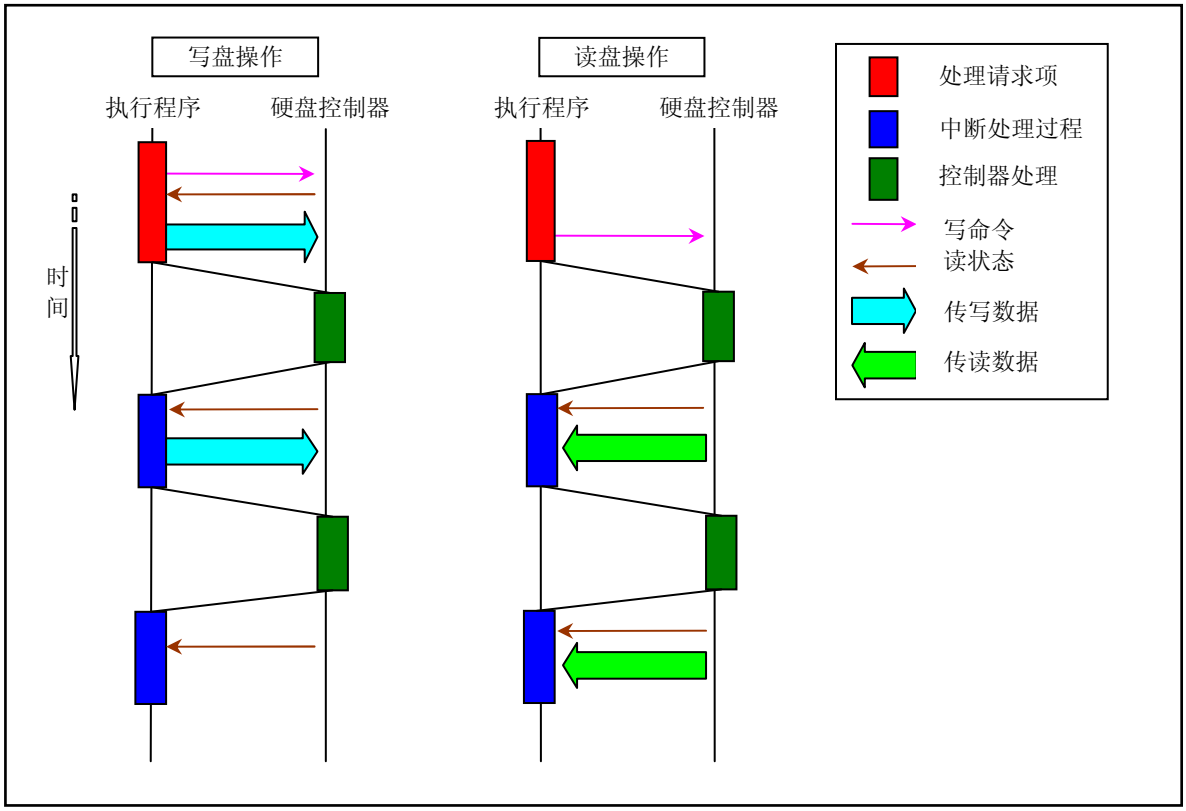

图 6-3 读/写硬盘数据的时序关系

由以上分析可以看出，本程序中最重要的 4 个函数是 hd_out()、do_hd_request()、read_intr()和 write_intr()。理解了这 4 个函数的作用也就理解了硬盘驱动程序的操作过程☺。

6.5.2 代码注释

程序 6-3 linux/kernel/blk_drv/hd.c

```
1  /*
2   *  linux/kernel/hd.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   * This is the low-level hd interrupt support. It traverses the
9   * request-list, using interrupts to jump between functions. As
10  * all the functions are called within interrupts, we may not
11  * sleep. Special care is recommended.
12  *
13  *  modified by Drew Eckhardt to check nr of hd's from the CMOS.
14  */
    /*
     * 本程序是底层硬盘中断辅助程序。主要用于扫描请求列表，使用中断在函数之间跳转。
     * 由于所有的函数都是在中断里调用的，所以这些函数不可以睡眠。请特别注意。
     * 由 Drew Eckhardt 修改，利用 CMOS 信息检测硬盘数。
     */
15
16 #include <linux/config.h> // 内核配置头文件。定义键盘语言和硬盘类型（HD_TYPE）可选项。
17 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
18 #include <linux/fs.h>     // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
19 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
20 #include <linux/hdreg.h>  // 硬盘参数头文件。定义访问硬盘寄存器端口，状态码，分区表等信息。
21 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
22 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
23 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
24
   // 必须在 blk.h 文件之前定义下面的主设备号常数，因为 blk.h 文件中要用到该常数。
25 #define MAJOR_NR 3        // 硬盘主设备号是 3。
26 #include "blk.h"          // 块设备头文件。定义请求数据结构、块设备数据结构和宏函数等信息。
27
28 #define CMOS_READ(addr) ({ \  // 读 CMOS 参数宏函数。
29 outb_p(0x80|addr,0x70); \
30 inb_p(0x71); \
31 })
32
33 /* Max read/write errors/sector */
34 #define MAX_ERRORS      7     // 读/写一个扇区时允许的最多出错次数。
35 #define MAX_HD          2     // 系统支持的最多硬盘数。
36
37 static void recal_intr(void); // 硬盘中断程序在复位操作时会调用的重新校正函数(287 行)。
38
39 static int recalibrate = 1;   // 重新校正标志。将磁头移动到 0 柱面。
40 static int reset = 1;         // 复位标志。当发生读写错误时会设置该标志，以复位硬盘和控制器。
```

```
41
42 /*
43  * This struct defines the HD's and their types.
44  */
   /* 下面结构定义了硬盘参数及类型 */
   // 各字段分别是磁头数、每磁道扇区数、柱面数、写前预补偿柱面号、磁头着陆区柱面号、控制字节。
   // 它们的含义请参见程序列表后的说明。
45 struct hd_i_struct {
46         int head,sect,cyl,wpcom,lzone,ctl;
47         };

   // 如果已经在 include/linux/config.h 头文件中定义了 HD_TYPE，就取其中定义好的参数作为
   // hd_info[]的数据。否则，先默认都设为 0 值，在 setup()函数中会进行设置。
48 #ifdef HD_TYPE
49 struct hd_i_struct hd_info[] = { HD_TYPE };
50 #define NR_HD ((sizeof (hd_info))/(sizeof (struct hd_i_struct)))          // 计算硬盘个数。
51 #else
52 struct hd_i_struct hd_info[] = { {0,0,0,0,0,0},{0,0,0,0,0,0} };
53 static int NR_HD = 0;
54 #endif
55
   // 定义硬盘分区结构。给出每个分区的物理起始扇区号、分区扇区总数。
   // 其中 5 的倍数处的项（例如 hd[0]和 hd[5]等）代表整个硬盘中的参数。
56 static struct hd_struct {
57         long start_sect;
58         long nr_sects;
59 } hd[5*MAX_HD]={{0,0},};
60
   // 读端口 port，共读 nr 字，保存在 buf 中。
61 #define port_read(port,buf,nr) \
62 __asm__("cld;rep;insw"::"d" (port),"D" (buf),"c" (nr):"cx","di")
63
   // 写端口 port，共写 nr 字，从 buf 中取数据。
64 #define port_write(port,buf,nr) \
65 __asm__("cld;rep;outsw"::"d" (port),"S" (buf),"c" (nr):"cx","si")
66
67 extern void hd_interrupt(void);          // 硬盘中断过程（system_call.s，221 行）。
68 extern void rd_load(void);               // 虚拟盘创建加载函数（ramdisk.c，71 行）。
69
70 /* This may be used only once, enforced by 'static int callable' */
   /* 下面该函数只在初始化时被调用一次。用静态变量 callable 作为可调用标志。*/
   // 该函数的参数由初始化程序 init/main.c 的 init 子程序设置为指向 0x90080 处，此处存放着 setup.s
   // 程序从 BIOS 取得的 2 个硬盘的基本参数表(32 字节)。硬盘参数表信息参见下面列表后的说明。
   // 本函数主要功能是读取 CMOS 和硬盘参数表信息，用于设置硬盘分区结构 hd，并加载 RAM 虚拟盘和
   // 根文件系统。
71 int sys_setup(void * BIOS)
72 {
73         static int callable = 1;
74         int i,drive;
75         unsigned char cmos_disks;
76         struct partition *p;
77         struct buffer_head * bh;
78
```

```
    // 初始化时 callable=1，当运行该函数时将其设置为 0，使本函数只能执行一次。
 79         if (!callable)
 80                 return -1;
 81         callable = 0;
    // 如果没有在 config.h 中定义硬盘参数，就从 0x90080 处读入。
 82 #ifndef HD_TYPE
 83         for (drive=0 ; drive<2 ; drive++) {
 84                 hd_info[drive].cyl = *(unsigned short *) BIOS;        // 柱面数。
 85                 hd_info[drive].head = *(unsigned char *) (2+BIOS);    // 磁头数。
 86                 hd_info[drive].wpcom = *(unsigned short *) (5+BIOS);  // 写前预补偿柱面号。
 87                 hd_info[drive].ctl = *(unsigned char *) (8+BIOS);     // 控制字节。
 88                 hd_info[drive].lzone = *(unsigned short *) (12+BIOS); // 磁头着陆区柱面号。
 89                 hd_info[drive].sect = *(unsigned char *) (14+BIOS);   // 每磁道扇区数。
 90                 BIOS += 16;       // 每个硬盘的参数表长 16 字节，这里 BIOS 指向下一个表。
 91         }
    // setup.s 程序在取 BIOS 中的硬盘参数表信息时，如果只有 1 个硬盘，就会将对应第 2 个硬盘的
    // 16 字节全部清零。因此这里只要判断第 2 个硬盘柱面数是否为 0 就可以知道有没有第 2 个硬盘了。
 92         if (hd_info[1].cyl)
 93                 NR_HD=2;          // 硬盘数置为 2。
 94         else
 95                 NR_HD=1;
 96 #endif
    // 设置每个硬盘的起始扇区号和扇区总数。其中编号 i*5 含义参见本程序后的有关说明。
 97         for (i=0 ; i<NR_HD ; i++) {
 98                 hd[i*5].start_sect = 0;                          // 硬盘起始扇区号。
 99                 hd[i*5].nr_sects = hd_info[i].head*
100                                 hd_info[i].sect*hd_info[i].cyl;  // 硬盘总扇区数。
101         }
102
103         /*
104                 We querry CMOS about hard disks : it could be that
105                 we have a SCSI/ESDI/etc controller that is BIOS
106                 compatable with ST-506, and thus showing up in our
107                 BIOS table, but not register compatable, and therefore
108                 not present in CMOS.
109
110                 Furthurmore, we will assume that our ST-506 drives
111                 <if any> are the primary drives in the system, and
112                 the ones reflected as drive 1 or 2.
113
114                 The first drive is stored in the high nibble of CMOS
115                 byte 0x12, the second in the low nibble.  This will be
116                 either a 4 bit drive type or 0xf indicating use byte 0x19
117                 for an 8 bit type, drive 1, 0x1a for drive 2 in CMOS.
118
119                 Needless to say, a non-zero value means we have
120                 an AT controller hard disk for that drive.
121
122
123         */
    /*
     * 我们对 CMOS 有关硬盘的信息有些怀疑：可能会出现这样的情况，我们有一块 SCSI/ESDI/等的
     * 控制器，它是以 ST-506 方式与 BIOS 兼容的，因而会出现在我们的 BIOS 参数表中，但却又不
```

```
     * 是寄存器兼容的，因此这些参数在 CMOS 中又不存在。
     * 另外，我们假设 ST-506 驱动器（如果有的话）是系统中的基本驱动器，也即以驱动器 1 或 2
     * 出现的驱动器。
     * 第 1 个驱动器参数存放在 CMOS 字节 0x12 的高半字节中，第 2 个存放在低半字节中。该 4 位字节
     * 信息可以是驱动器类型，也可能仅是 0xf。0xf 表示使用 CMOS 中 0x19 字节作为驱动器 1 的 8 位
     * 类型字节，使用 CMOS 中 0x1A 字节作为驱动器 2 的类型字节。
     * 总之，一个非零值意味着我们有一个 AT 控制器硬盘兼容的驱动器。
     */
124
    // 这里根据上述原理来检测硬盘到底是否是 AT 控制器兼容的。有关 CMOS 信息请参见 4.2.3.1 节。
125         if ((cmos_disks = CMOS_READ(0x12)) & 0xf0)
126                 if (cmos_disks & 0x0f)
127                         NR_HD = 2;
128                 else
129                         NR_HD = 1;
130         else
131                 NR_HD = 0;
    // 若 NR_HD=0，则两个硬盘都不是 AT 控制器兼容的，硬盘数据结构清零。
    // 若 NR_HD=1，则将第 2 个硬盘的参数清零。
132         for (i = NR_HD ; i < 2 ; i++) {
133                 hd[i*5].start_sect = 0;
134                 hd[i*5].nr_sects = 0;
135         }
    // 读取每一个硬盘上第 1 块数据（第 1 个扇区有用），获取其中的分区表信息。
    // 首先利用函数 bread()读硬盘第 1 块数据(fs/buffer.c,267)，参数中的 0x300 是硬盘的主设备号
    // (参见列表后的说明)。然后根据硬盘头 1 个扇区位置 0x1fe 处的两个字节是否为'55AA'来判断
    // 该扇区中位于 0x1BE 开始的分区表是否有效。最后将分区表信息放入硬盘分区数据结构 hd 中。
136         for (drive=0 ; drive<NR_HD ; drive++) {
137                 if (!(bh = bread(0x300 + drive*5,0))) {  // 0x300, 0x305 逻辑设备号。
138                         printk("Unable to read partition table of drive %d\n\r",
139                                 drive);
140                         panic("");
141                 }
142                 if (bh->b_data[510] != 0x55 || (unsigned char)
143                     bh->b_data[511] != 0xAA) {      // 判断硬盘信息有效标志'55AA'。
144                         printk("Bad partition table on drive %d\n\r",drive);
145                         panic("");
146                 }
147                 p = 0x1BE + (void *)bh->b_data;     // 分区表位于硬盘第 1 扇区的 0x1BE 处。
148                 for (i=1;i<5;i++,p++) {
149                         hd[i+5*drive].start_sect = p->start_sect;
150                         hd[i+5*drive].nr_sects = p->nr_sects;
151                 }
152                 brelse(bh);      // 释放为存放硬盘块而申请的内存缓冲区页。
153         }
154         if (NR_HD)               // 如果有硬盘存在并且已读入分区表，则打印分区表正常信息。
155                 printk("Partition table%s ok.\n\r",(NR_HD>1)?"s":"");
156         rd_load();               // 加载（创建）RAMDISK(kernel/blk_drv/ramdisk.c,71)。
157         mount_root();            // 安装根文件系统(fs/super.c,242)。
158         return (0);
159 }
160
    //// 判断并循环等待驱动器就绪。
```

```
    // 读硬盘控制器状态寄存器端口 HD_STATUS(0x1f7)，并循环检测驱动器就绪比特位和控制器忙位。
    // 如果返回值为 0，则表示等待超时出错，否则 OK。
161 static int controller_ready(void)
162 {
163         int retries=10000;
164
165         while (--retries && (inb_p(HD_STATUS)&0xc0)!=0x40);
166         return (retries);       // 返回等待循环的次数。
167 }
168
    //// 检测硬盘执行命令后的状态。(win_表示温切斯特硬盘的缩写)
    // 读取状态寄存器中的命令执行结果状态。返回 0 表示正常，1 出错。如果执行命令错，
    // 则再读错误寄存器 HD_ERROR(0x1f1)。
169 static int win_result(void)
170 {
171         int i=inb_p(HD_STATUS);  // 取状态信息。
172
173         if ((i & (BUSY_STAT | READY_STAT | WRERR_STAT | SEEK_STAT | ERR_STAT))
174                 == (READY_STAT | SEEK_STAT))
175                 return(0); /* ok */
176         if (i&1) i=inb(HD_ERROR);   // 若 ERR_STAT 置位，则读取错误寄存器。
177         return (1);
178 }
179
    //// 向硬盘控制器发送命令块（参见列表后的说明）。
    // 调用参数：drive - 硬盘号(0-1);    nsect - 读写扇区数;
    //           sect  - 起始扇区;       head  - 磁头号;
    //           cyl   - 柱面号;         cmd   - 命令码（参见控制器命令列表，表 6.3）;
    //           *intr_addr() - 硬盘中断发生时处理程序中将调用的 C 处理函数。
180 static void hd_out(unsigned int drive,unsigned int nsect,unsigned int sect,
181                 unsigned int head,unsigned int cyl,unsigned int cmd,
182                 void (*intr_addr)(void))
183 {
184         register int port asm("dx");    // port 变量对应寄存器 dx。
185
186         if (drive>1 || head>15)         // 如果驱动器号(0,1)>1 或磁头号>15，则程序不支持。
187                 panic("Trying to write bad sector");
188         if (!controller_ready())        // 如果等待一段时间后仍未就绪则出错，死机。
189                 panic("HD controller not ready");
190         do_hd = intr_addr;              // do_hd 函数指针将在硬盘中断程序中被调用。
191         outb_p(hd_info[drive].ctl,HD_CMD);      // 向控制寄存器(0x3f6)输出控制字节。
192         port=HD_DATA;                           // 置 dx 为数据寄存器端口(0x1f0)。
193         outb_p(hd_info[drive].wpcom>>2,++port); // 参数：写预补偿柱面号(需除 4)。
194         outb_p(nsect,++port);                   // 参数：读/写扇区总数。
195         outb_p(sect,++port);                    // 参数：起始扇区。
196         outb_p(cyl,++port);                     // 参数：柱面号低 8 位。
197         outb_p(cyl>>8,++port);                  // 参数：柱面号高 8 位。
198         outb_p(0xA0|(drive<<4)|head,++port);    // 参数：驱动器号+磁头号。
199         outb(cmd,++port);                       // 命令：硬盘控制命令。
200 }
201
    //// 等待硬盘就绪。也即循环等待主状态控制器忙标志位复位。若仅有就绪或寻道结束标志
    // 置位，则成功，返回 0。若经过一段时间仍为忙，则返回 1。
```

```
202 static int drive_busy(void)
203 {
204         unsigned int i;
205
206         for (i = 0; i < 10000; i++)                 // 循环等待就绪标志位置位。
207                 if (READY_STAT == (inb_p(HD_STATUS) & (BUSY_STAT|READY_STAT)))
208                         break;
209         i = inb(HD_STATUS);                         // 再取主控制器状态字节。
210         i &= BUSY_STAT | READY_STAT | SEEK_STAT;    // 检测忙位、就绪位和寻道结束位。
211         if (i == READY_STAT | SEEK_STAT)            // 若仅有就绪或寻道结束标志，则返回 0。
212                 return(0);
213         printk("HD controller times out\n\r");      // 否则等待超时，显示信息。并返回 1。
214         return(1);
215 }
216
    //// 诊断复位（重新校正）硬盘控制器。
217 static void reset_controller(void)
218 {
219         int     i;
220
221         outb(4,HD_CMD);                             // 向控制寄存器端口发送控制字节(4-复位)。
222         for(i = 0; i < 100; i++) nop();             // 等待一段时间（循环空操作）。
223         outb(hd_info[0].ctl & 0x0f ,HD_CMD);        // 再发送正常的控制字节(不禁止重试、重读)。
224         if (drive_busy())                           // 若等待硬盘就绪超时，则显示出错信息。
225                 printk("HD-controller still busy\n\r");
226         if ((i = inb(HD_ERROR)) != 1)               // 取错误寄存器，若不等于 1（无错误）则出错。
227                 printk("HD-controller reset failed: %02x\n\r",i);
228 }
229
    //// 复位硬盘 nr。首先复位（重新校正）硬盘控制器。然后发送硬盘控制器命令“建立驱动器参数”，
    // 其中 recal_intr()是在硬盘中断处理程序中调用的重新校正处理函数。
230 static void reset_hd(int nr)
231 {
232         reset_controller();
233         hd_out(nr,hd_info[nr].sect,hd_info[nr].sect,hd_info[nr].head-1,
234                 hd_info[nr].cyl,WIN_SPECIFY,&recal_intr);
235 }
236
    //// 意外硬盘中断调用函数。
    // 发生意外硬盘中断时，硬盘中断处理程序中调用的默认 C 处理函数。在被调用函数指针为空时
    // 调用该函数。参见(kernel/system_call.s,241 行)。
237 void unexpected_hd_interrupt(void)
238 {
239         printk("Unexpected HD interrupt\n\r");
240 }
241
    //// 读写硬盘失败处理调用函数。
242 static void bad_rw_intr(void)
243 {
244         if (++CURRENT->errors >= MAX_ERRORS)    // 如果读扇区时的出错次数大于或等于 7 次时，
245                 end_request(0);                 // 则结束请求并唤醒等待该请求的进程，而且
                                                    // 对应缓冲区更新标志复位（没有更新）。
246         if (CURRENT->errors > MAX_ERRORS/2)     // 如果读一扇区时的出错次数已经大于 3 次，
```

```
247                 reset = 1;                      // 则要求执行复位硬盘控制器操作。
248 }
249
    //// 读操作中断调用函数。将在硬盘读命令结束时引发的中断过程中被调用。
    // 该函数首先判断此次读命令操作是否出错。若命令结束后控制器还处于忙状态，或者命令执行错误，
    // 则处理硬盘操作失败问题，接着请求硬盘作复位处理并执行其他请求项。
    // 如果读命令没有出错，则从数据寄存器端口把一个扇区的数据读到请求项的缓冲区中，并递减请求项
    // 所需读取的扇区数值。若递减后不等于 0，表示本项请求还有数据没取完，于是直接返回，等待硬盘
    // 在读出另一个扇区数据后的中断。否则表明本请求项所需的所有扇区都已读完，于是处理本次请求项
    // 结束事宜。最后再次调用 do_hd_request()，去处理其他硬盘请求项。
    // 注意：257 行语句中的 256 是指内存字，也即 512 字节。
250 static void read_intr(void)
251 {
252         if (win_result()) {                     // 若控制器忙、读写错或命令执行错，
253                 bad_rw_intr();                  // 则进行读写硬盘失败处理
254                 do_hd_request();                // 然后再次请求硬盘作相应(复位)处理。
255                 return;
256         }
257         port_read(HD_DATA,CURRENT->buffer,256); // 将数据从数据寄存器口读到请求结构缓冲区。
258         CURRENT->errors = 0;                    // 清出错次数。
259         CURRENT->buffer += 512;                 // 调整缓冲区指针，指向新的空区。
260         CURRENT->sector++;                      // 起始扇区号加 1，
261         if (--CURRENT->nr_sectors) {            // 如果所需读出的扇区数还没有读完，则
262                 do_hd = &read_intr;             // 再次置硬盘调用 C 函数指针为 read_intr()
263                 return;                         // 因为硬盘中断处理程序每次调用 do_hd 时
264         }                                       // 都会将该函数指针置空。参见 system_call.s
265         end_request(1);                 // 若全部扇区数据已经读完，则处理请求结束事宜，
266         do_hd_request();                // 执行其他硬盘请求操作。
267 }
268
    //// 写扇区中断调用函数。在硬盘中断处理程序中被调用。
    // 在写命令执行后，会产生硬盘中断信号，执行硬盘中断处理程序，此时在硬盘中断处理程序中调用的
    // C 函数指针 do_hd()已经指向 write_intr()，因此会在写操作完成（或出错）后，执行该函数。
269 static void write_intr(void)
270 {
271         if (win_result()) {             // 如果硬盘控制器返回错误信息，
272                 bad_rw_intr();          // 则首先进行硬盘读写失败处理，
273                 do_hd_request();        // 然后再次请求硬盘作相应(复位)处理，
274                 return;                 // 然后返回（也退出了此次硬盘中断）。
275         }
276         if (--CURRENT->nr_sectors) {    // 否则将欲写扇区数减 1，若还有扇区要写，则
277                 CURRENT->sector++;      // 当前请求起始扇区号+1，
278                 CURRENT->buffer += 512; // 调整请求缓冲区指针，
279                 do_hd = &write_intr;    // 置硬盘中断程序调用函数指针为 write_intr()，
280                 port_write(HD_DATA,CURRENT->buffer,256);  // 再向数据寄存器端口写 256 字。
281                 return;                 // 返回等待硬盘再次完成写操作后的中断处理。
282         }
283         end_request(1);                 // 若全部扇区数据已经写完，则处理请求结束事宜，
284         do_hd_request();                // 执行其他硬盘请求操作。
285 }
286
    //// 硬盘重新校正（复位）中断调用函数。在硬盘中断处理程序中被调用。
    // 如果硬盘控制器返回错误信息，则首先进行硬盘读写失败处理，然后请求硬盘作相应(复位)处理。
```

```
287 static void recal_intr(void)
288 {
289         if (win_result())
290                 bad_rw_intr();
291         do_hd_request();
292 }
293
    //// 执行硬盘读写请求操作。
    // 若请求项是块设备的第 1 个，则块设备当前请求项指针（参见 ll_rw_blk.c，28 行）会直接指向该
    // 请求项，并会立刻调用本函数执行读写操作。否则在一个读写操作完成而引发的硬盘中断过程中，
    // 若还有请求项需要处理，则也会在中断过程中调用本函数。参见 kernel/system_call.s，221 行。
294 void do_hd_request(void)
295 {
296         int i,r;
297         unsigned int block,dev;
298         unsigned int sec,head,cyl;
299         unsigned int nsect;
300
    // 检测请求项的合法性，若已没有请求项则退出(参见 blk.h,127)。
301         INIT_REQUEST;
    // 取设备号中的子设备号(见列表后对硬盘设备号的说明)。子设备号即是硬盘上的分区号。
302         dev = MINOR(CURRENT->dev);    // CURRENT 定义为 blk_dev[MAJOR_NR].current_request。
303         block = CURRENT->sector;      // 请求的起始扇区。
    // 如果子设备号不存在或者起始扇区大于该分区扇区数-2，则结束该请求，并跳转到标号 repeat 处
    // （定义在 INIT_REQUEST 开始处）。因为一次要求读写 2 个扇区（512*2 字节），所以请求的扇区号
    // 不能大于分区中最后倒数第二个扇区号。
304         if (dev >= 5*NR_HD || block+2 > hd[dev].nr_sects) {
305                 end_request(0);
306                 goto repeat;          // 该标号在 blk.h 最后面。
307         }
    // 通过加上本分区的起始扇区号，把将所需读写的块对应到整个硬盘的绝对扇区号上。
308         block += hd[dev].start_sect;
309         dev /= 5;                     // 此时 dev 代表硬盘号（是第 1 个硬盘(0)还是第 2 个(1)）。
    // 下面嵌入汇编代码用来从硬盘信息结构中根据起始扇区号和每磁道扇区数计算在磁道中的
    // 扇区号(sec)、所在柱面号(cyl)和磁头号(head)。
310         __asm__("divl %4":"=a" (block),"=d" (sec):"" (block),"1" (0),
311                 "r" (hd_info[dev].sect));
312         __asm__("divl %4":"=a" (cyl),"=d" (head):"" (block),"1" (0),
313                 "r" (hd_info[dev].head));
314         sec++;
315         nsect = CURRENT->nr_sectors;  // 欲读/写的扇区数。
    // 如果 reset 标志是置位的，则执行复位操作。复位硬盘和控制器，并置需要重新校正标志，返回。
316         if (reset) {
317                 reset = 0;
318                 recalibrate = 1;
319                 reset_hd(CURRENT_DEV);
320                 return;
321         }
    // 如果重新校正标志(recalibrate)置位，则首先复位该标志，然后向硬盘控制器发送重新校正命令。
    // 该命令会执行寻道操作，让处于任何地方的磁头移动到 0 柱面。
322         if (recalibrate) {
323                 recalibrate = 0;
324                 hd_out(dev,hd_info[CURRENT_DEV].sect,0,0,0,
```

```
325                         WIN_RESTORE,&recal_intr);
326                 return;
327         }
    // 如果当前请求是写扇区操作，则发送写命令，循环读取状态寄存器信息并判断请求服务标志
    // DRQ_STAT 是否置位。DRQ_STAT 是硬盘状态寄存器的请求服务位，表示驱动器已经准备好在主机和
    // 数据端口之间传输一个字或一个字节的数据。
328         if (CURRENT->cmd == WRITE) {
329                 hd_out(dev,nsect,sec,head,cyl,WIN_WRITE,&write_intr);
330                 for(i=0 ; i<3000 && !(r=inb_p(HD_STATUS)&DRQ_STAT) ; i++)
331                         /* nothing */ ;
    // 如果请求服务 DRQ 置位则退出循环。若等到循环结束也没有置位，则表示此次写硬盘操作失败，去
    // 处理下一个硬盘请求。否则向硬盘控制器数据寄存器端口 HD_DATA 写入 1 个扇区的数据。
332                 if (!r) {
333                         bad_rw_intr();
334                         goto repeat;            // 该标号在 blk.h 文件最后面，也即跳到 301 行。
335                 }
336                 port_write(HD_DATA,CURRENT->buffer,256);
    // 如果当前请求是读硬盘扇区，则向硬盘控制器发送读扇区命令。
337         } else if (CURRENT->cmd == READ) {
338                 hd_out(dev,nsect,sec,head,cyl,WIN_READ,&read_intr);
339         } else
340                 panic("unknown hd-command");
341 }
342
    // 硬盘系统初始化。
    // 中断描述符表 IDT 中的中断门描述符设置宏 set_intr_gate()在 include/asm/system.h 中实现。
343 void hd_init(void)
344 {
345         blk_dev[MAJOR_NR].request_fn = DEVICE_REQUEST;  // do_hd_request()。
346         set_intr_gate(0x2E,&hd_interrupt);  // 设置硬盘中断门向量 int 0x2E(46)。
                                                // hd_interrupt 在(kernel/system_call.s,221)。
347         outb_p(inb_p(0x21)&0xfb,0x21);      // 复位接联的主 8259A int2 的屏蔽位，允许从片
                                                // 发出中断请求信号。
348         outb(inb_p(0xA1)&0xbf,0xA1);        // 复位硬盘的中断请求屏蔽位（在从片上），允许
                                                // 硬盘控制器发送中断请求信号。
349 }
350
```

6.5.3 其他信息

6.5.3.1 AT 硬盘接口寄存器

AT 硬盘控制器的编程寄存器端口说明见表 6–3 所示。另外请参见 include/linux/hdreg.h 头文件。

表 6－3 AT 硬盘控制器寄存器端口及作用

端口	名称	读操作	写操作
0x1f0	HD_DATA	数据寄存器 -- 扇区数据（读、写、格式化）	
0x1f1	HD_ERROR	错误寄存器（错误状态）	写前预补偿寄存器
0x1f2	HD_NSECTOR	扇区数寄存器 -- 扇区数（读、写、检验、格式化）	
0x1f3	HD_SECTOR	扇区号寄存器 -- 起始扇区（读、写、检验）	
0x1f4	HD_LCYL	柱面号寄存器 -- 柱面号低字节（读、写、检验、格式化）	
0x1f5	HD_HCYL	柱面号寄存器 -- 柱面号高字节（读、写、检验、格式化）	

0x1f6	HD_CURRENT	驱动器/磁头寄存器 -- 驱动器号/磁头号（101dhhhh, d=驱动器号，h=磁头号）	
0x1f7	HD_STATUS	主状态寄存器 (HD_STATUS)	命令寄存器 (HD_COMMAND)
0x3f6	HD_CMD	---	硬盘控制寄存器 (HD_CMD)
0x3f7		数字输入寄存器（与 1.2M 软盘合用）	---

下面对各端口寄存器进行详细说明。

◆数据寄存器（HD_DATA，0x1f0）

这是一对 16 位高速 PIO 数据传输器，用于扇区读、写和磁道格式化操作。CPU 通过该数据寄存器向硬盘写入或从硬盘读出 1 个扇区的数据，也即要使用命令'rep outsw'或'rep insw'重复读/写 cx=256 字。

◆错误寄存器（读）/写前预补偿寄存器（写）（HD_ERROR，0x1f1）

在读时，该寄存器存放有 8 位的错误状态。但只有当主状态寄存器(HD_STATUS，0x1f7)的位 0=1 时该寄存器中的数据才有效。执行控制器诊断命令时的含义与其他命令时的不同。见表 6–4 所示。

表 6－4 硬盘控制器错误寄存器

值	诊断命令时	其他命令时
0x01	无错误	数据标志丢失
0x02	控制器出错	磁道 0 错
0x03	扇区缓冲区错	
0x04	ECC 部件错	命令放弃
0x05	控制处理器错	
0x10		ID 未找到
0x40		ECC 错误
0x80		坏扇区

在写操作时，该寄存器即作为写前预补偿寄存器。它记录写预补偿起始柱面号。对应于与硬盘基本参数表位移 0x05 处的一个字，需除 4 后输出。

◆扇区数寄存器（HD_NSECTOR，0x1f2）

该寄存器存放读、写、检验和格式化命令指定的扇区数。当用于多扇区操作时，每完成 1 扇区的操作该寄存器就自动减 1，直到为 0。若初值为 0，则表示传输最大扇区数 256。

◆扇区号寄存器（HD_SECTOR，0x1f3）

该寄存器存放读、写、检验操作命令指定的扇区号。在多扇区操作时，保存的是起始扇区号，而每完成 1 扇区的操作就自动增 1。

◆柱面号寄存器（HD_LCYL，HD_HCYL，0x1f4，0x1f5）

该两个柱面号寄存器分别存放有柱面号的低 8 位和高 2 位。

◆驱动器/磁头寄存器(HD_CURRENT，0x1f6)

该寄存器存放有读、写、检验、寻道和格式化命令指定的驱动器和磁头号。其位格式为 101dhhhh。其中 101 表示采用 ECC 校验码和每扇区为 512 字节；d 表示选择的驱动器（0 或 1）；hhhh 表示选择的磁头。见表 6–5 所示。

表 6－5 驱动器/磁头寄存器含义

位	名称		说明
0	HS0	磁头号位 0	磁头号最低位。
1	HS1	磁头号位 1	

2	HS2	磁头号位 2	
3	HS3	磁头号位 3	磁头号最高位。
4	DRV	驱动器	选择驱动器，0 - 选择驱动器 0； 1 - 选择驱动器 1。
5	Reserved	保留	总是 1。
6	Reserved	保留	总是 0。
7	Reserved	保留	总是 1。

◆主状态寄存器（读）/命令寄存器（写）（HD_STATUS/HD_COMMAND，0x1f7)

在读时，对应一个 8 位主状态寄存器。反映硬盘控制器在执行命令前后的操作状态。各位的含义见表 6–6 所示。

表 6－6 8 位主状态寄存器

位	名称	屏蔽码	说明
0	ERR_STAT	0x01	命令执行错误。当该位置位时说明前一个命令以出错结束。此时出错寄存器和状态寄存器中的比特位含有引起错误的一些信息。
1	INDEX_STAT	0x02	收到索引。当磁盘旋转遇到索引标志时会设置该位。
2	ECC_STAT	0x04	ECC 校验错。当遇到一个可恢复的数据错误而且已得到纠正，就会设置该位。这种情况不会中断一个多扇区读操作。
3	DRQ_STAT	0x08	数据请求服务。当该位被置位时，表示驱动器已经准备好在主机和数据端口之间传输一个字或一个字节的数据。
4	SEEK_STAT	0x10	驱动器寻道结束。当该位被置位时，表示寻道操作已经完成，磁头已经停在指定的磁道上。当发生错误时，该位并不会改变。只有主机读取了状态寄存器后，该位就会再次表示当前寻道的完成状态。
5	WRERR_STAT	0x20	驱动器故障（写出错）。当发生错误时，该位并不会改变。只有主机读取了状态寄存器后，该位就会再次表示当前写操作的出错状态。
6	READY_STAT	0x40	驱动器准备好（就绪）。表示驱动器已经准备好接收命令。当发生错误时，该位并不会改变。只有主机读取了状态寄存器后，该位就会再次表示当前驱动器就绪状态。在开机时，应该复位该比特位，直到驱动器速度达到正常并且能够接收命令。
7	BUSY_STAT	0x80	控制器忙碌。当驱动器正在操作由驱动器的控制器设置该位。此时主机不能发送命令块。而对任何命令寄存器的读操作将返回状态寄存器的值。在下列条件下该位会被置位： 在机器复位信号 RESET 变负或者设备控制寄存器的 SRST 被设置之后 400 纳秒以内。在机器复位之后要求该位置位状态不能超过 30 秒。 主机在向命令寄存器写重新校正、读、读缓冲、初始化驱动器参数以及执行诊断等命令的 400 纳秒以内。 在写操作、写缓冲或格式化磁道命令期间传输了 512 字节数据的 5 微秒之内。

当执行写操作时，该端口对应命令寄存器，接受 CPU 发出的硬盘控制命令，共有 8 种命令，见表 6–7 所示。其中最后一列用于说明相应命令结束后控制器所采取的动作（引发中断或者什么也不做）。

表 6－7 AT 硬盘控制器命令列表

命令名称	命令码字节	默认值	命令执行结束

		高 4 位	D3 D2 D1 D0		形式
WIN_RESTORE	驱动器重新校正(复位)	0x1	R R R R	0x10	中断
WIN_READ	读扇区	0x2	0 0 L T	0x20	中断
WIN_WRITE	写扇区	0x3	0 0 L T	0x30	中断
WIN_VERIFY	扇区检验	0x4	0 0 0 T	0x40	中断
WIN_FORMAT	格式化磁道	0x5	0 0 0 0	0x50	中断
WIN_INIT	控制器初始化	0x6	0 0 0 0	0x60	中断
WIN_SEEK	寻道	0x7	R R R R	0x70	中断
WIN_DIAGNOSE	控制器诊断	0x9	0 0 0 0	0x90	中断或空闲
WIN_SPECIFY	建立驱动器参数	0x9	0 0 0 1	0x91	中断

表中命令码字节的低 4 位是附加参数，其含义为：

R 是步进速率。R=0，则步进速率为 35us；R=1 为 0.5ms，以此量递增。程序中默认 R=0。

L 是数据模式。L=0 表示读/写扇区为 512 字节；L=1 表示读/写扇区为 512 加 4 字节的 ECC 码。程序中默认值是 L=0。

T 是重试模式。T=0 表示允许重试；T=1 则禁止重试。程序中取 T=0。

下面分别对这几个命令进行详细说明。

(1) 0x1X -- （WIN_RESTORE），驱动器重新校正（Recalibrate）命令

该命令把读/写磁头从磁盘上任何位置移动到 0 柱面。当接收到该命令时，驱动器会设置 BUSY_STAT 标志并且发出一个 0 柱面寻道指令。然后驱动器等待寻道操作结束，更新状态、复位 BUSY_STAT 标志并且产生一个中断。

(2) 0x20 -- （WIN_READ）可重试读扇区；0x21 -- 无重试读扇区。

读扇区命令可以从指定扇区开始读取 1 到 256 个扇区。若所指定的命令块（见表 6–9）中扇区计数为 0 的话，则表示读取 256 个扇区。当驱动器接受了该命令，将会设立 BUSY_STAT 标志并且开始执行该命令。对于单个扇区的读取操作，若磁头的磁道位置不对，则驱动器会隐含地执行一次寻道操作。一旦磁头在正确的磁道上，驱动器磁头就会定位到磁道地址场中相应的标志域（ID 域）上。

对于无重试读扇区命令，若两个索引脉冲发生之前不能正确读取无错的指定 ID 域，则驱动器就会在错误寄存器中给出 ID 没有找到的错误信息。对于可重试读扇区命令，驱动器则会在读 ID 域碰到问题时重试多次。重试的次数由驱动器厂商设定。

如果驱动器正确地读到了 ID 域，那么它就需要在指定的字节数中识别数据地址标志（Data Address Mark），否则就报告数据地址标志没有找到的错误。一旦磁头找到数据地址标志，驱动器就会把数据域中的数据读入扇区缓冲区中。如果发生错误，驱动器就会设置出错比特位、设置 DRQ_STAT 并且产生一个中断。不管是否发生错误，驱动器总是会在读扇区后设置 DRQ_STAT。在命令完成后，命令块寄存器中将含有最后一个所读扇区的柱面号、磁头号和扇区号。

对于多扇区读操作，每当驱动器准备好向主机发送一个扇区的数据时就会设置 DRQ_STAT、清 BUSY_STAT 标志并且产生一个中断。当扇区数据传输结束，驱动器就会复位 DRQ_STAT 和 BUSY_STAT 标志，但在最后一个扇区传输完成后会设置 BUSY_STAT 标志。在命令结束后命令块寄存器中将含有最后一个所读扇区的柱面号、磁头号和扇区号。

如果在多扇区读操作中发生了一个不可纠正的错误，读操作将在发生错误的扇区处终止。同样，此时命令块寄存器中将含有该出错扇区的柱面号、磁头号和扇区号。不管错误是否可以被纠正，驱动器都会把数据放入扇区缓冲区中。

(3) 0x30 -- （WIN_WRITE）可重试写扇区；0x31 -- 无重试写扇区。

写扇区命令可以从指定扇区开始写 1 到 256 个扇区。若所指定的命令块（见表 6–9）中扇区计数为 0 的话，则表示要写 256 个扇区。当驱动器接受了该命令，它将设置 DRQ_STAT 并等待扇区缓冲区被添满数据。在开始第一次向扇区缓冲区添入数据时不会产生中断，一旦数据填满驱动器就会复位 DRQ、设置 BUSY_STAT 标志并且开始执行命令。

对于写一个扇区数据的操作，驱动器会在收到命令时设置 DRQ_STAT 并且等待主机填满扇区缓冲区。一旦数据已被传输，驱动器就会设置 BUSY_STAT 并且复位 DRQ_STAT。与读扇区操作一样，若磁头的磁道位置不对，则驱动器会隐含地执行一次寻道操作。一旦磁头在正确的磁道上，驱动器磁头就会定位到磁道地址场中相应的标志域（ID 域）上。

如果 ID 域被正确地读出，则扇区缓冲区中的数据包括 ECC 字节就被写到磁盘上。当驱动器处理过扇区后就会清 BUSY_STAT 标志并且产生一个中断。此时主机就可以读取状态寄存器。在命令结束后，命令块寄存器中将含有最后一个所写扇区的柱面号、磁头号和扇区号。

在多扇区写操作期间，除了对第一个扇区的操作，当驱动器准备好从主机接收一个扇区的数据时就会设置 DRQ_STAT、清 BUSY_STAT 标志并且产生一个中断。一旦一个扇区传输完毕，驱动器就会复位 DRQ 并设置 BUSY 标志。当最后一个扇区被写到磁盘上后，驱动器就会清掉 BUSY_STAT 标志并产生一个中断（此时 DRQ_STAT 已经复位）。在写命令结束后，命令块寄存器中将含有最后一个所写扇区的柱面号、磁头号和扇区号。

如果在多扇区写操作中发生了一个错误，写操作将在发生错误的扇区处终止。同样，此时命令块寄存器中将含有该出错扇区的柱面号、磁头号和扇区号。

(4) 0x40 -- （WIN_VERIFY）可重试读扇区验证；0x41 -- 无重试读扇区验证。

该命令的执行过程与读扇区操作相同，但是本命令不会导致驱动器去设置 DRQ_STAT，并且不会向主机传输数据。当收到读验证命令时，驱动器就会设置 BUSY_STAT 标志。当指定的扇区被验证过后，驱动器就会复位 BUSY_STAT 标志并且产生一个中断。在命令结束后，命令块寄存器中将含有最后一个所验证扇区的柱面号、磁头号和扇区号。

如果在多扇区验证操作中发生了一个错误，验证操作将在发生错误的扇区处终止。同样，此时命令块寄存器中将含有该出错扇区的柱面号、磁头号和扇区号。

(5) 0x50 -- （WIN_FORMAT）格式化磁道命令。

扇区计数寄存器中指定了磁道地址。当驱动器接受该命令时，它会设置 DRQ_STAT 比特位，然后等待主机填满扇区缓冲区。当缓冲区满后，驱动器就会清 DRQ_STAT、设置 BUSY_STAT 标志并且开始命令的执行。

(6) 0x60 -- （WIN_INIT）控制器初始化。

(7) 0x7X -- （WIN_SEEK）寻道操作。

寻道操作命令将命令块寄存器中所选择的磁头移动到指定的磁道上。当主机发出一个寻道命令时，驱动器会设置 BUSY 标志并且产生一个中断。在寻道操作结束之前，驱动器在寻道操作完成之前不会设置 SEEK_STAT（DSC - 寻道完成）。在驱动器产生一个中断之前寻道操作可能还没有完成。如果在寻道操作进行当中主机又向驱动器发出了一个新命令，那么 BUSY_STAT 将依然处于置位状态，直到寻道结束。然后驱动器才开始执行新的命令。

(8) 0x90 -- （WIN_DIAGNOSE）驱动器诊断命令。

该命令执行驱动器内部实现的诊断测试过程。驱动器 0 会在收到该命令的 400ns 内设置 BUSY_STAT 比特位。

如果系统中含有第 2 个驱动器，即驱动器 1，那么两个驱动器都会执行诊断操作。驱动器 0 会等待驱动器 1 执行诊断操作 5 秒钟。如果驱动器 1 诊断操作失败，则驱动器 0 就会在自己的诊断状态中附加 0x80。如果主机在读取驱动器 0 的状态时检测到驱动器 1 的诊断操作失败，它就会设置驱动器/磁头寄存器(0x1f6)的驱动器选择比特位（位 4），然后读取驱动器 1 的状态。如果驱动器 1 通过诊断检测或者驱动器 1 不存在，则驱动器 0 就直接把自己的诊断状态加载到出错寄存器中。

如果驱动器 1 不存在，那么驱动器 0 仅报告自己的诊断结果，并且在复位 BUSY_STAT 比特位后产生一个中断。

(9) 0x91 -- （WIN_SPECIFY）建立驱动器参数命令。

该命令用于让主机设置多扇区操作时磁头交换和扇区计数循环值。在收到该命令时驱动器会设置 BUSY_STAT 比特位并产生一个中断。该命令仅使用两个寄存器的值。一个是扇区计数寄存器，用于指定扇区数；另一个是驱动器/磁头寄存器，用于指定磁头数-1，而驱动器选择比特位（位 4）则根据具体选择的驱动器来设置。

该命令不会验证所选择的扇区计数值和磁头数。如果这些值无效，驱动器不会报告错误。直到另一个命令使用这些值而导致无效一个访问错误。

◆硬盘控制寄存器（写）（HD_CMD，0x3f6）

该寄存器是只写的。用于存放硬盘控制字节并控制复位操作。其定义与硬盘基本参数表的位移 0x08 处的字节说明相同，见表 6–8 所示。

表 6－8 硬盘控制字节的含义

位移	大小	说明
0x08	字节	控制字节（驱动器步进选择） 位 0　未用 位 1　保留(0) (关闭 IRQ) 位 2　允许复位 位 3　若磁头数大于 8 则置 1 位 4　未用(0) 位 5　若在柱面数+1 处有生产商的坏区图，则置 1 位 6　禁止 ECC 重试 位 7　禁止访问重试。

6.5.3.2 AT 硬盘控制器编程

在对硬盘控制器进行操作控制时，需要同时发送参数和命令。其命令格式见表 6–9 所示。首先发送 6 字节的参数，最后发出 1 字节的命令码。不管什么命令均需要完整输出这 7 字节的命令块，依次写入端口 0x1f1 -- 0x1f7。一旦命令块寄存器加载，命令就开始执行。

表 6－9 命令格式

端口	说明
0x1f1	写预补偿起始柱面号
0x1f2	扇区数
0x1f3	起始扇区号
0x1f4	柱面号低字节
0x1f5	柱面号高字节
0x1f6	驱动器号/磁头号
0x1f7	命令码

首先 CPU 向控制寄存器端口(HD_CMD)0x3f6 输出控制字节，建立相应的硬盘控制方式。方式建立后即可按上面顺序发送参数和命令。步骤为：

1. 检测控制器空闲状态：CPU 通过读主状态寄存器，若位 7（BUSY_STAT）为 0，表示控制器空闲。若在规定时间内控制器一直处于忙状态，则判为超时出错。参见 hd.c 中第 161 行的

controller_ready()函数。

2. 检测驱动器是否就绪：CPU 判断主状态寄存器位 6（READY_STAT）是否为 1 来看驱动器是否就绪。为 1 则可输出参数和命令。参见 hd.c 中第 202 行的 drive_busy()函数。
3. 输出命令块：按顺序输出分别向对应端口输出参数和命令。参见 hd.c 中第 180 行开始的 hd_out()函数。
4. CPU 等待中断产生：命令执行后，由硬盘控制器产生中断请求信号（IRQ14 -- 对应中断 int46）或置控制器状态为空闲，表明操作结束或表示请求扇区传输（多扇区读/写）。程序 hd.c 中在中断处理过程中调用的函数参见代码 237--293 行。有 5 个函数分别对应 5 种情况。
5. 检测操作结果：CPU 再次读主状态寄存器，若位 0 等于 0 则表示命令执行成功，否则失败。若失败则可进一步查询错误寄存器(HD_ERROR)取错误码。参见 hd.c 中第 202 行的 win_result()函数。

6.5.3.3 硬盘基本参数表

中断向量表中，int 0x41 的中断向量位置（4 * 0x41 =0x0000:0x0104）存放的并不是中断程序的地址而是第一个硬盘的基本参数表，见表 6–10 所示。对于 100%兼容的 BIOS 来说，这里存放着硬盘参数表阵列的首地址 F000h:E401h。第二个硬盘的基本参数表入口地址存于 int 0x46 中断向量中。

表 6－10 硬盘基本参数信息表

位移	大小	说明
0x00	字	柱面数
0x02	字节	磁头数
0x03	字	开始减小写电流的柱面(仅 PC XT 使用，其他为 0)
0x05	字	开始写前预补偿柱面号（乘 4）
0x07	字节	最大 ECC 猝发长度（仅 XT 使用，其他为 0）
0x08	字节	控制字节（驱动器步进选择） 位 0　未用 位 1　保留(0) (关闭 IRQ) 位 2　允许复位 位 3　若磁头数大于 8 则置 1 位 4　未用(0) 位 5　若在柱面数+1 处有生产商的坏区图，则置 1 位 6　禁止 ECC 重试 位 7　禁止访问重试。
0x09	字节	标准超时值（仅 XT 使用，其他为 0）
0x0A	字节	格式化超时值（仅 XT 使用，其他为 0）
0x0B	字节	检测驱动器超时值（仅 XT 使用，其他为 0）
0x0C	字	磁头着陆(停止)柱面号
0x0E	字节	每磁道扇区数
0x0F	字节	保留。

6.5.3.4 硬盘设备号命名方式

硬盘的主设备号是 3。其他设备的主设备号分别为：

1-内存,2-磁盘,3-硬盘,4-ttyx,5-tty,6-并行口,7-非命名管道

由于 1 个硬盘中可以存在 1--4 个分区，因此硬盘还依据分区的不同用次设备号进行指定分区。因此

硬盘的逻辑设备号由以下方式构成：

设备号=主设备号*256 + 次设备号

也即 dev_no = (major<<8) + minor

两个硬盘的所有逻辑设备号见表 6–11 所示。

表 6－11 硬盘逻辑设备号

逻辑设备号	对应设备文件	说明
0x300	/dev/hd0	代表整个第 1 个硬盘
0x301	/dev/hd1	表示第 1 个硬盘的第 1 个分区
0x302	/dev/hd2	表示第 1 个硬盘的第 2 个分区
0x303	/dev/hd3	表示第 1 个硬盘的第 3 个分区
0x304	/dev/hd4	表示第 1 个硬盘的第 4 个分区
0x305	/dev/hd5	代表整个第 2 个硬盘
0x306	/dev/hd6	表示第 2 个硬盘的第 1 个分区
0x307	/dev/hd7	表示第 2 个硬盘的第 2 个分区
0x308	/dev/hd8	表示第 2 个硬盘的第 3 个分区
0x309	/dev/hd9	表示第 2 个硬盘的第 4 个分区

其中 0x300 和 0x305 并不与哪个分区对应，而是代表整个硬盘。

从 linux 内核 0.95 版后已经不使用这种烦琐的命名方式，而是使用与现在相同的命名方法了。

6.5.3.5 硬盘分区表

为了实现多个操作系统共享硬盘资源，硬盘可以在逻辑上分为 1--4 个分区。每个分区之间的扇区号是邻接的。分区表由 4 个表项组成，每个表项由 16 字节组成，对应一个分区的信息，存放有分区的大小和起止的柱面号、磁道号和扇区号，见表 6–12 所示。分区表存放在硬盘的 0 柱面 0 头第 1 个扇区的 0x1BE--0x1FD 处。

表 6－12 硬盘分区表结构

位置	名称	大小	说明
0x00	boot_ind	字节	引导标志。4 个分区中同时只能有一个分区是可引导的。 0x00-不从该分区引导操作系统；0x80-从该分区引导操作系统。
0x01	head	字节	分区起始磁头号。
0x02	sector	字节	分区起始扇区号(位 0-5)和起始柱面号高 2 位(位 6-7)。
0x03	cyl	字节	分区起始柱面号低 8 位。
0x04	sys_ind	字节	分区类型字节。0x0b-DOS; 0x80-Old Minix; 0x83-Linux …
0x05	end_head	字节	分区的结束磁头号。
0x06	end_sector	字节	结束扇区号(位 0-5)和结束柱面号高 2 位(位 6-7)。
0x07	end_cyl	字节	结束柱面号低 8 位。
0x08--0x0b	start_sect	长字	分区起始物理扇区号。
0x0c--0x0f	nr_sects	长字	分区占用的扇区数。

硬盘的第 1 个扇区称为主引导扇区（Master Boot Record --MBR），它除了多包含一个分区表以外，其他与软盘上第一个扇区（boot 扇区）的作用一样，只是它的代码会把自己从 0x7c00 下移到 0x6000 处，

腾出 0x7c00 处的空间，然后根据分区表中的信息，找出活动分区是哪一个，接着把活动分区的第 1 个扇区加载到 0x7c00 处去执行。一个分区从硬盘的哪个柱面、磁头和扇区开始，都记录在分区表中。因此从分区表中可以知道一个活动分区的第 1 个扇区（即该分区的引导扇区）在硬盘的什么地方。

6.6 ll_rw_blk.c 程序

6.6.1 功能描述

该程序主要用于执行低层块设备读/写操作，是本章所有块设备与系统其他部分的接口程序。其他程序通过调用该程序的低级块读写函数 ll_rw_block()来读写块设备中的数据。该函数的主要功能是为块设备创建块设备读写请求项，并插入到指定块设备请求队列中。实际的读写操作则是由设备的请求项处理函数 request_fn()完成。对于硬盘操作，该函数是 do_hd_request()；对于软盘操作，该函数是 do_fd_request()；对于虚拟盘则是 do_rd_request()。若 ll_rw_block()为一个块设备建立起一个请求项，并通过测试块设备的当前请求项指针为空而确定设备空闲时，就会设置该新建的请求项为当前请求项，并直接调用 request_fn()对该请求项进行操作。否则就会使用电梯算法将新建的请求项插入到该设备的请求项链表中等待处理。而当 request_fn()结束对一个请求项的处理，就会把该请求项从链表中删除。

由于 request_fn()在每个请求项处理结束时，都会通过中断回调 C 函数（主要是 read_intr()和 write_intr()）再次调用 request_fn()自身去处理链表中其余的请求项，因此，只要设备的请求项链表（或者称为队列）中有未处理的请求项存在，都会陆续地被处理，直到设备的请求项链表是空为止。当请求项链表空时，request_fn()将不再向驱动器控制器发送命令，而是立刻退出。因此，对 request_fn()函数的循环调用就此结束。参见图 6-4 所示。

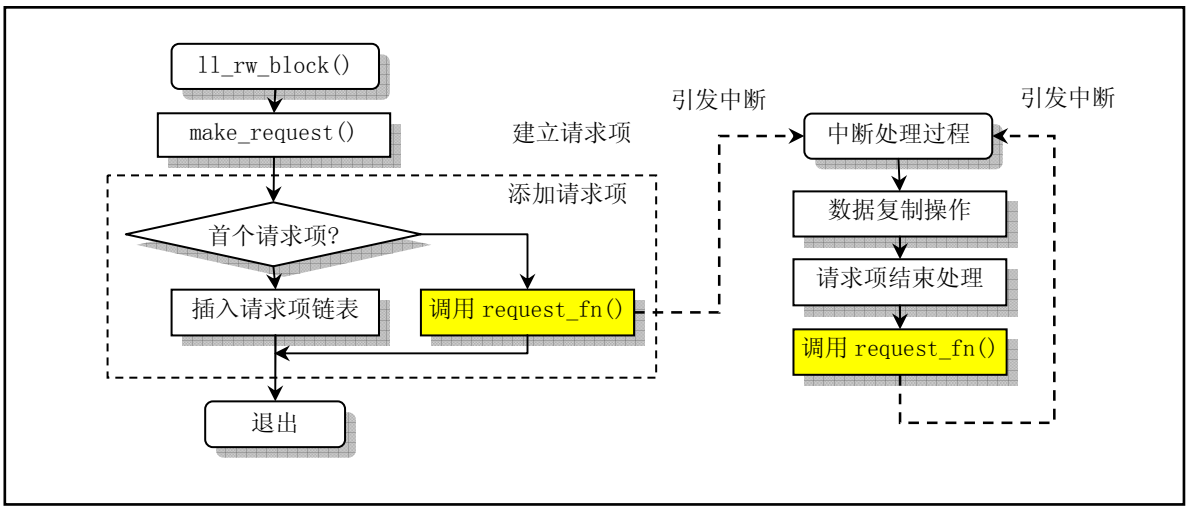

图 6-4 ll_rw_block 调用序列

对于虚拟盘设备，由于它的读写操作不牵涉到上述与外界硬件设备同步操作，因此没有上述的中断处理过程。当前请求项对虚拟设备的读写操作完全在 do_rd_request()中实现。

6.6.2 代码注释

程序 6-4 linux/kernel/blk_drv/ll_rw_blk.c

```
1 /*
```

```
 2  *  linux/kernel/blk_dev/ll_rw.c
 3  *
 4  * (C) 1991 Linus Torvalds
 5  */
 6
 7 /*
 8  * This handles all read/write requests to block devices
 9  */
   /*
    * 该程序处理块设备的所有读/写操作。
    */
10 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)
11 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
12 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
13 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
14
15 #include "blk.h"          // 块设备头文件。定义请求数据结构、块设备数据结构和宏函数等信息。
16
17 /*
18  * The request-struct contains all necessary data
19  * to load a nr of sectors into memory
20  */
   /*
    * 请求结构中含有加载 nr 扇区数据到内存中的所有必须的信息。
    */
21 struct request request[NR_REQUEST];
22
23 /*
24  * used to wait on when there are no free requests
25  */
   /* 是用于在请求数组没有空闲项时进程的临时等待处 */
26 struct task_struct * wait_for_request = NULL;
27
28 /* blk_dev_struct is:
29  *      do_request-address
30  *      next-request
31  */
   /* blk_dev_struct 块设备结构是：(kernel/blk_drv/blk.h,23)
    *      do_request-address    // 对应主设备号的请求处理程序指针。
    *      current-request       // 该设备的下一个请求。
    */
   // 该数组使用主设备号作为索引。实际内容将在各种块设备驱动程序初始化时填入。例如，硬盘
   // 驱动程序进行初始化时（hd.c，343 行），第一条语句即用于设置 blk_dev[3]的内容。
32 struct blk_dev_struct blk_dev[NR_BLK_DEV] = {
33         { NULL, NULL },          /* no_dev */    // 0 - 无设备。
34         { NULL, NULL },          /* dev mem */   // 1 - 内存。
35         { NULL, NULL },          /* dev fd */    // 2 - 软驱设备。
36         { NULL, NULL },          /* dev hd */    // 3 - 硬盘设备。
37         { NULL, NULL },          /* dev ttyx */  // 4 - ttyx 设备。
38         { NULL, NULL },          /* dev tty */   // 5 - tty 设备。
39         { NULL, NULL }           /* dev lp */    // 6 - lp 打印机设备。
40 };
```

```
41
   // 锁定指定的缓冲区 bh。如果指定的缓冲区已经被其他任务锁定，则使自己睡眠（不可中断地等待），
   // 直到被执行解锁缓冲区的任务明确地唤醒。
42 static inline void lock_buffer(struct buffer_head * bh)
43 {
44         cli();                          // 清中断许可。
45         while (bh->b_lock)              // 如果缓冲区已被锁定，则睡眠，直到缓冲区解锁。
46                 sleep_on(&bh->b_wait);
47         bh->b_lock=1;                   // 立刻锁定该缓冲区。
48         sti();                          // 开中断。
49 }
50
   // 释放（解锁）锁定的缓冲区。
51 static inline void unlock_buffer(struct buffer_head * bh)
52 {
53         if (!bh->b_lock)                // 如果该缓冲区并没有被锁定，则打印出错信息。
54                 printk("ll_rw_block.c: buffer not locked\n\r");
55         bh->b_lock = 0;                 // 清锁定标志。
56         wake_up(&bh->b_wait);           // 唤醒等待该缓冲区的任务。
57 }
58
59 /*
60  * add-request adds a request to the linked list.
61  * It disables interrupts so that it can muck with the
62  * request-lists in peace.
63  */
   /*
    * add-request()向链表中加入一项请求。它会关闭中断，
    * 这样就能安全地处理请求链表了 */
    */
   //// 向链表中加入请求项。参数 dev 指定块设备，req 是请求项结构信息指针。

64 static void add_request(struct blk_dev_struct * dev, struct request * req)
65 {
66         struct request * tmp;
67
68         req->next = NULL;
69         cli();                                  // 关中断。
70         if (req->bh)
71                 req->bh->b_dirt = 0;            // 清缓冲区“脏”标志。
   // 如果 dev 的当前请求(current_request)子段为空，则表示目前该设备没有请求项，本次是第 1 个
   // 请求项，因此可将块设备当前请求指针直接指向该请求项，并立刻执行相应设备的请求函数。
72         if (!(tmp = dev->current_request)) {
73                 dev->current_request = req;
74                 sti();                          // 开中断。
75                 (dev->request_fn)();            // 执行设备请求函数，对于硬盘是 do_hd_request()。
76                 return;
77         }
   // 如果目前该设备已经有请求项在等待，则首先利用电梯算法搜索最佳插入位置，然后将当前请求插入
   // 到请求链表中。电梯算法的作用是让磁盘磁头的移动距离最小，从而改善硬盘访问时间。
78         for ( ; tmp->next ; tmp=tmp->next)
79                 if ((IN_ORDER(tmp,req) ||
80                     !IN_ORDER(tmp,tmp->next)) &&
```

```
 81                     IN_ORDER(req,tmp->next))
 82                         break;
 83         req->next=tmp->next;
 84         tmp->next=req;
 85         sti();
 86 }
 87
    //// 创建请求项并插入请求队列。参数是：主设备号 major，命令 rw，存放数据的缓冲区头指针 bh。
 88 static void make_request(int major,int rw, struct buffer_head * bh)
 89 {
 90         struct request * req;
 91         int rw_ahead;
 92
 93 /* WRITEA/READA is special case - it is not really needed, so if the */
 94 /* buffer is locked, we just forget about it, else it's a normal read */
    /* WRITEA/READA 是一种特殊情况 - 它们并并非必要，所以如果缓冲区已经上锁，*/
    /* 我们就不管它而退出，否则的话就执行一般的读/写操作。 */
    // 这里'READ'和'WRITE'后面的'A'字符代表英文单词 Ahead，表示提前预读/写数据块的意思。
    // 对于命令是 READA/WRITEA 的情况，当指定的缓冲区正在使用，已被上锁时，就放弃预读/写请求。
    // 否则就作为普通的 READ/WRITE 命令进行操作。
 95         if (rw_ahead = (rw == READA || rw == WRITEA)) {
 96                 if (bh->b_lock)
 97                         return;
 98                 if (rw == READA)
 99                         rw = READ;
100                 else
101                         rw = WRITE;
102         }
    // 如果命令不是 READ 并且也不是 WRITE，则表示内核程序有错，显示出错信息并死机。
103         if (rw!=READ && rw!=WRITE)
104                 panic("Bad block dev command, must be R/W/RA/WA");
    // 锁定缓冲区，如果缓冲区已经上锁，则当前任务（进程）就会睡眠，直到被明确地唤醒。
105         lock_buffer(bh);
    // 如果命令是写并且缓冲区数据不脏（没有被修改过），或者命令是读并且缓冲区数据是更新过的，
    // 则不用添加这个请求。将缓冲区解锁并退出。
106         if ((rw == WRITE && !bh->b_dirt) || (rw == READ && bh->b_uptodate)) {
107                 unlock_buffer(bh);
108                 return;
109         }
110 repeat:
111 /* we don't allow the write-requests to fill up the queue completely:
112  * we want some room for reads: they take precedence. The last third
113  * of the requests are only for reads.
114  */
    /* 我们不能让队列中全都是写请求项：我们需要为读请求保留一些空间：读操作
     * 是优先的。请求队列的后三分之一空间是为读准备的。
     */
    // 请求项是从请求数组末尾开始搜索空项填入的。根据上述要求，对于读命令请求，可以直接
    // 从队列末尾开始操作，而写请求则只能从队列 2/3 处向队列头处搜索空项填入。
115         if (rw == READ)
116                 req = request+NR_REQUEST;          // 对于读请求，将队列指针指向队列尾部。
117         else
118                 req = request+((NR_REQUEST*2)/3); // 对于写请求，队列指针指向队列 2/3 处。
```

```
119 /* find an empty request */
    /* 搜索一个空请求项 */
    // 从后向前搜索，当请求结构 request 的 dev 字段值=-1 时，表示该项未被占用。
120         while (--req >= request)
121                 if (req->dev<0)
122                         break;
123 /* if none found, sleep on new requests: check for rw_ahead */
    /* 如果没有找到空闲项，则让该次新请求睡眠：需检查是否提前读/写 */
    // 如果没有一项是空闲的（此时 request 数组指针已经搜索越过头部），则查看此次请求是否是
    // 提前读/写（READA 或 WRITEA），如果是则放弃此次请求。否则让本次请求睡眠（等待请求队列
    // 腾出空项），过一会再来搜索请求队列。
124         if (req < request) {                    // 如果请求队列中没有空项，则
125                 if (rw_ahead) {                 // 如果是提前读/写请求，则解锁缓冲区，退出。
126                         unlock_buffer(bh);
127                         return;
128                 }
129                 sleep_on(&wait_for_request); // 否则让本次请求睡眠，过会再查看请求队列。
130                 goto repeat;
131         }
132 /* fill up the request-info, and add it to the queue */
    /* 向空闲请求项中填写请求信息，并将其加入队列中 */
    // 程序执行到这里表示已找到一个空闲请求项。请求结构参见（kernel/blk_drv/blk.h,23）。
133         req->dev = bh->b_dev;                   // 设备号。
134         req->cmd = rw;                          // 命令(READ/WRITE)。
135         req->errors=0;                          // 操作时产生的错误次数。
136         req->sector = bh->b_blocknr<<1;         // 起始扇区。块号转换成扇区号(1 块=2 扇区)。
137         req->nr_sectors = 2;                    // 读写扇区数。
138         req->buffer = bh->b_data;               // 数据缓冲区。
139         req->waiting = NULL;                    // 任务等待操作执行完成的地方。
140         req->bh = bh;                           // 缓冲块头指针。
141         req->next = NULL;                       // 指向下一请求项。
142         add_request(major+blk_dev,req);         // 将请求项加入队列中 (blk_dev[major],req)。
143 }
144
    //// 低层读写数据块函数，是块设备与系统其他部分的接口函数。
    // 该函数在 fs/buffer.c 中被调用。主要功能是创建块设备读写请求项并插入到指定块设备请求队列中。
    // 实际的读写操作则是由设备的 request_fn()函数完成。对于硬盘操作，该函数是 do_hd_request()；
    // 对于软盘操作，该函数是 do_fd_request()；对于虚拟盘则是 do_rd_request()。
    // 另外，需要读/写块设备的信息已保存在缓冲块头结构中，如设备号、块号。
    // 参数：rw - READ、READA、WRITE 或 WRITEA 命令；bh - 数据缓冲块头指针。
145 void ll_rw_block(int rw, struct buffer_head * bh)
146 {
147         unsigned int major;                     // 主设备号（对于硬盘是 3）。
148
    // 如果设备的主设备号不存在或者该设备的读写操作函数不存在，则显示出错信息，并返回。
149         if ((major=MAJOR(bh->b_dev)) >= NR_BLK_DEV ||
150         !(blk_dev[major].request_fn)) {
151                 printk("Trying to read nonexistent block-device\n\r");
152                 return;
153         }
154         make_request(major,rw,bh);              //  创建请求项并插入请求队列。
155 }
156
```

```
    //// 块设备初始化函数，由初始化程序 main.c 调用（init/main.c,128）。
    // 初始化请求数组，将所有请求项置为空闲项(dev = -1)。有 32 项(NR_REQUEST = 32)。
157 void blk_dev_init(void)
158 {
159         int i;
160
161         for (i=0 ; i<NR_REQUEST ; i++) {
162                 request[i].dev = -1;
163                 request[i].next = NULL;
164         }
165 }
166
```

6.7 ramdisk.c 程序

6.7.1 功能描述

本文件是内存虚拟盘（Ram Disk）驱动程序，由 Theodore Ts'o 编制。虚拟盘设备是一种利用物理内存来模拟实际磁盘存储数据的方式。其目的主要是为了提高对“磁盘”数据的读写操作速度。除了需要占用一些宝贵的内存资源外，其主要缺点是一旦系统崩溃或关闭，虚拟盘中的所有数据将全部消失。因此虚拟盘中通常存放一些系统命令等常用工具程序或临时数据，而非重要的输入文档。

当在 linux/Makefile 文件中定义了常量 RAMDISK，内核初始化程序就会在内存中划出一块该常量值指定大小的内存区域用于存放虚拟盘数据。虚拟盘在物理内存中所处的具体位置是在内核初始化阶段确定的（init/main.c，123 行），它位于内核高速缓冲区和主内存区之间。若运行的机器含有 16MB 的物理内存，那么虚拟盘区域会被设置在内存 4MB 开始处，虚拟盘容量即等于 RAMDISK 的值（KB）。若 RAMDISK=512，则此时内存情况见图 6-5 所示。

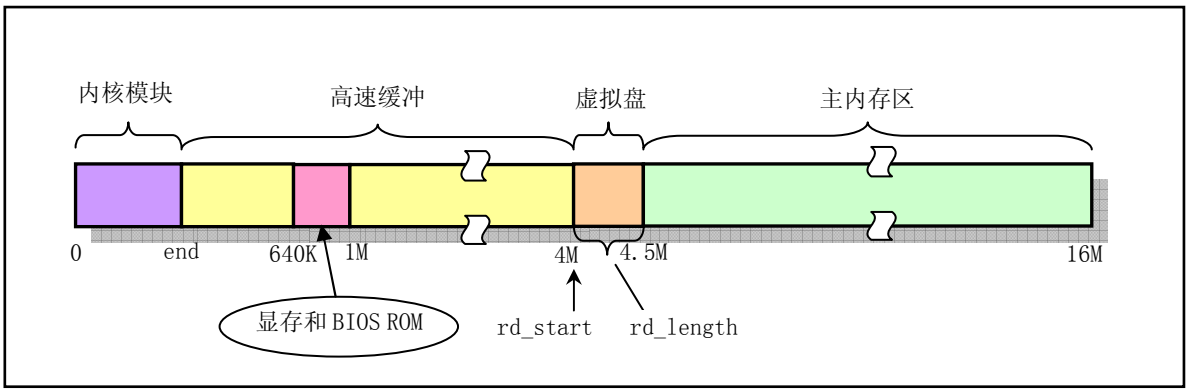

图 6-5 虚拟盘在 16MB 内存系统中所处的具体位置

对虚拟盘设备的读写访问操作原则上完全按照对普通磁盘的操作进行，也需要按照块设备的访问方式对其进行读写操作。由于在实现上不牵涉与外部控制器或设备进行同步操作，因此其实现方式比较简单。对于数据在系统与设备之间的“传送”只需执行内存数据块复制操作即可。

本程序包含 3 个函数。rd_init()会在系统初始化时被 init/main.c 程序调用，用于确定虚拟盘在物理内存中的具体位置和大小；do_rd_request()是虚拟盘设备的请求项操作函数，对当前请求项实现虚拟盘数据

的访问操作；rd_load()是虚拟盘根文件加载函数。在系统初始化阶段，该函数被用于尝试从启动引导盘上指定的磁盘块位置开始处把一个根文件系统加载到虚拟盘中。在函数中，这个起始磁盘块位置被定为256。当然你也可以根据自己的具体要求修改这个值，只要保证这个值所规定的磁盘容量能容纳内核映像文件即可。这样一个由内核引导映像文件（Bootimage）加上根文件系统映像文件（Rootiamge）组合而成的“二合一”磁盘，就可以象启动 DOS 系统盘那样来启动 Linux 系统。关于这种组合盘（集成盘）的制作方式可参见第 14 章中相关内容。

在进行正常的根文件系统加载之前，系统会首先执行 rd_load()函数，试图从磁盘的第 257 块中读取根文件系统超级块。若成功，就把该根文件映像文件读到内存虚拟盘中，并把根文件系统设备标志 ROOT_DEV 设置为虚拟盘设备（0x0101），否则退出 rd_load()，系统继续从别的设备上执行根文件加载操作。

6.7.2 代码注释

程序 6-5 linux/kernel/blk_drv/ramdisk.c

```
1  /*
2   *  linux/kernel/blk_drv/ramdisk.c
3   *
4   *  Written by Theodore Ts'o, 12/2/91
5   */
   /* 由 Theodore Ts'o 编制，12/2/91
    */
   // Theodore Ts'o (Ted Ts'o)是 Linux 社区中的著名人物。Linux 在世界范围内的流行也有他很大的
   // 功劳，早在 Linux 操作系统刚问世时，他就怀着极大的热情为 Linux 的发展提供了 maillist 服务，
   // 并在北美地区最早设立了 Linux 的 ftp 服务器站点（tsx-11.mit.edu），而且至今仍为广大 Linux
   // 用户提供服务。他对 Linux 作出的最大贡献之一是提出并实现了 ext2 文件系统。该文件系统已成为
   // linux 世界中事实上的文件系统标准。最近他又推出了 ext3 文件系统，大大提高了文件系统的稳定
   // 性和访问效率。作为对他的推崇，第 97 期（2002 年 5 月）的 LinuxJournal 期刊将他作为了封面人
   // 物，并对他进行了采访。目前，他为 IBM Linux 技术中心工作，并从事着有关 LSB (Linux Standard Base)
   // 等方面的工作。(他的主页：http://thunk.org/tytso/)
6
7  #include <string.h>        // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
8
9  #include <linux/config.h> // 内核配置头文件。定义键盘语言和硬盘类型（HD_TYPE）可选项。
10 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
11 #include <linux/fs.h>     // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
12 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
13 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
14 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
15 #include <asm/memory.h>   // 内存拷贝头文件。含有 memcpy()嵌入式汇编宏函数。
16
17 #define MAJOR_NR 1        // RAM 盘主设备号是 1。主设备号必须在 blk.h 之前被定义。
18 #include "blk.h"
19
20 char    *rd_start;        // 虚拟盘在内存中的起始位置。在 52 行初始化函数 rd_init()中
                             // 确定。参见(init/main.c,124)（缩写 rd_代表 ramdisk_）。
21 int     rd_length = 0;    // 虚拟盘所占内存大小（字节）。
22
   // 虚拟盘当前请求项操作函数。程序结构与 do_hd_request()类似(hd.c,294)。
   // 在低级块设备接口函数 ll_rw_block()建立了虚拟盘（rd）的请求项并添加到 rd 的链表中之后，
   // 就会调用该函数对 rd 当前请求项进行处理。该函数首先计算当前请求项中指定的起始扇区对应
```

```
    // 虚拟盘所处内存的起始位置 addr 和要求的扇区数对应的字节长度值 len，然后根据请求项中的
    // 命令进行操作。若是写命令 WRITE，就把请求项所指缓冲区中的数据直接复制到内存位置 addr
    // 处。若是读操作则反之。数据复制完成后即可直接调用 end_request()对本次请求项作结束处理。
    // 然后跳转到函数开始处再去处理下一个请求项。
23  void do_rd_request(void)
24  {
25          int     len;
26          char    *addr;
27
    // 检测请求项的合法性，若已没有请求项则退出(参见 blk.h,127)。
28          INIT_REQUEST;
    // 下面语句取得 ramdisk 的起始扇区对应的内存起始位置和内存长度。
    // 其中 sector << 9 表示 sector * 512，CURRENT 定义为(blk_dev[MAJOR_NR].current_request)。
29          addr = rd_start + (CURRENT->sector << 9);
30          len = CURRENT->nr_sectors << 9;
    // 如果子设备号不为 1 或者对应内存起始位置>虚拟盘末尾，则结束该请求，并跳转到 repeat 处。
    // 标号 repeat 定义在宏 INIT_REQUEST 内，位于宏的开始处，参见 blk.h，127 行。
31          if ((MINOR(CURRENT->dev) != 1) || (addr+len > rd_start+rd_length)) {
32                  end_request(0);
33                  goto repeat;
34          }
    // 如果是写命令(WRITE)，则将请求项中缓冲区的内容复制到 addr 处，长度为 len 字节。
35          if (CURRENT-> cmd == WRITE) {
36                  (void ) memcpy(addr,
37                                 CURRENT->buffer,
38                                 len);
    // 如果是读命令(READ)，则将 addr 开始的内容复制到请求项中缓冲区中，长度为 len 字节。
39          } else if (CURRENT->cmd == READ) {
40                  (void) memcpy(CURRENT->buffer,
41                                addr,
42                                len);
    // 否则显示命令不存在，死机。
43          } else
44                  panic("unknown ramdisk-command");
    // 请求项成功后处理，置更新标志。并继续处理本设备的下一请求项。
45          end_request(1);
46          goto repeat;
47  }
48
49  /*
50   * Returns amount of memory which needs to be reserved.
51   */
    /* 返回内存虚拟盘 ramdisk 所需的内存量 */
    // 虚拟盘初始化函数。确定虚拟盘在内存中的起始地址，长度。并对整个虚拟盘区清零。
52  long rd_init(long mem_start, int length)
53  {
54          int     i;
55          char    *cp;
56
57          blk_dev[MAJOR_NR].request_fn = DEVICE_REQUEST;  // do_rd_request()。
58          rd_start = (char *) mem_start;                  // 对于 16MB 系统，该值为 4MB。
59          rd_length = length;
60          cp = rd_start;
```

```
61          for (i=0; i < length; i++)
62                  *cp++ = '\0';
63          return(length);
64  }
65
66  /*
67   * If the root device is the ram disk, try to load it.
68   * In order to do this, the root device is originally set to the
69   * floppy, and we later change it to be ram disk.
70   */
    /*
     * 如果根文件系统设备(root device)是 ramdisk 的话，则尝试加载它。root device 原先是指向
     * 软盘的，我们将它改成指向 ramdisk。
     */
    //// 尝试把根文件系统加载到虚拟盘中。
    // 该函数将在内核设置函数 setup()（hd.c，156 行）中被调用。另外，1 磁盘块 = 1024 字节。
71  void rd_load(void)
72  {
73          struct buffer_head *bh;         // 高速缓冲块头指针。
74          struct super_block      s;      // 文件超级块结构。
75          int             block = 256;    /* Start at block 256 */
76          int             i = 1;      /* 表示根文件系统映像文件在 boot 盘第 256 磁盘块开始处*/
77          int             nblocks;
78          char            *cp;            /* Move pointer */
79
80          if (!rd_length)                 // 如果 ramdisk 的长度为零，则退出。
81                  return;
82          printk("Ram disk: %d bytes, starting at 0x%x\n", rd_length,
83                  (int) rd_start);        // 显示 ramdisk 的大小以及内存起始位置。
84          if (MAJOR(ROOT_DEV) != 2)       // 如果此时根文件设备不是软盘，则退出。
85                  return;
    // 读软盘块 256+1,256,256+2。breada()用于读取指定的数据块，并标出还需要读的块，然后返回
    // 含有数据块的缓冲区指针。如果返回 NULL，则表示数据块不可读(fs/buffer.c,322)。
    // 这里 block+1 是指磁盘上的超级块。
86          bh = breada(ROOT_DEV,block+1,block,block+2,-1);
87          if (!bh) {
88                  printk("Disk error while looking for ramdisk!\n");
89                  return;
90          }
    // 将 s 指向缓冲区中的磁盘超级块。(d_super_block 磁盘中超级块结构)。
91          *((struct d_super_block *) &s) = *((struct d_super_block *) bh->b_data);
92          brelse(bh);
93          if (s.s_magic != SUPER_MAGIC)   // 如果超级块中魔数不对，则说明不是 minix 文件系统。
94                  /* No ram disk image present, assume normal floppy boot */
                    /* 磁盘中没有 ramdisk 映像文件，退出去执行通常的软盘引导 */
95                  return;
    // 块数 = 逻辑块数(区段数) * 2^(每区段块数的次方)。
    // 如果数据块数大于内存中虚拟盘所能容纳的块数，则也不能加载，显示出错信息并返回。否则显示
    // 加载数据块信息。
96          nblocks = s.s_nzones << s.s_log_zone_size;
97          if (nblocks > (rd_length >> BLOCK_SIZE_BITS)) {
98                  printk("Ram disk image too big!  (%d blocks, %d avail)\n",
99                          nblocks, rd_length >> BLOCK_SIZE_BITS);
```

```
100                 return;
101         }
102         printk("Loading %d bytes into ram disk... 0000k",
103                 nblocks << BLOCK_SIZE_BITS);
    // cp 指向虚拟盘起始处，然后将磁盘上的根文件系统映像文件复制到虚拟盘上。
104         cp = rd_start;
105         while (nblocks) {
106                 if (nblocks > 2)    // 如果需读取的块数多于 3 快则采用超前预读方式读数据块。
107                         bh = breada(ROOT_DEV, block, block+1, block+2, -1);
108                 else                // 否则就单块读取。
109                         bh = bread(ROOT_DEV, block);
110                 if (!bh) {
111                         printk("I/O error on block %d, aborting load\n",
112                                 block);
113                         return;
114                 }
115                 (void) memcpy(cp, bh->b_data, BLOCK_SIZE); // 将缓冲区中的数据复制到 cp 处。
116                 brelse(bh);                                // 释放缓冲区。
117                 printk("\010\010\010\010\010%4dk",i);      // 打印加载块计数值。
118                 cp += BLOCK_SIZE;                          // 虚拟盘指针前移。
119                 block++;
120                 nblocks--;
121                 i++;
122         }
123         printk("\010\010\010\010\010done \n");
124         ROOT_DEV=0x0101;                           // 修改 ROOT_DEV 使其指向虚拟盘 ramdisk。
125 }
126
```

6.8 floppy.c 程序

6.8.1 功能描述

本程序是软盘控制器驱动程序。与其他块设备驱动程序一样，该程序也以请求项操作函数 do_fd_request()为主，执行对软盘上数据的读写操作。

考虑到软盘驱动器在不工作时马达通常不转，所以在实际能对驱动器中的软盘进行读写操作之前，我们需要等待马达启动并达到正常的运行速度。与计算机的运行速度相比，这段时间较长，通常需要 0.5 秒左右的时间。

另外，当对一个磁盘的读写操作完毕，我们也需要让驱动器停止转动，以减少对磁盘表面的摩擦。但我们也不能在对磁盘操作完后就立刻让它停止转动。因为，可能马上又需要对其进行读写操作。因此，在一个驱动器没有操作后还是需要让驱动器空转一段时间，以等待可能到来的读写操作，若驱动器在一个较长时间内都没有操作，则程序让它停止转动。这段维持旋转的时间可设定在大约 3 秒左右。

当一个磁盘的读写操作发生错误，或某些其他情况导致一个驱动器的马达没有被关闭。此时我们也需要让系统在一定时间之后自动将其关闭。Linus 在程序中把这个延时值设定在 100 秒。

由此可见，在对软盘驱动器进行操作时会用到很多延时（定时）操作。因此在该驱动程序中涉及较多的定时处理函数。还有几个与定时处理关系比较密切的函数被放在了 kernel/sched.c 中（行 201-262）。这是软盘驱动程序与硬盘驱动程序之间的最大区别，也是软盘驱动程序比硬盘驱动程序复杂的原因。

虽然本程序比较复杂，但对软盘读写操作的工作原理却与其他块设备是一样的。本程序也是使用请求项和请求项链表结构来处理所有对软盘的读写操作。因此请求项操作函数 do_fd_request()仍然是本程序中的重要函数之一。在阅读时应该以该函数为主线展开。另外，软盘控制器的使用比较复杂，其中涉及到很多控制器的执行状态和标志。因此在阅读时，还需要频繁地参考程序后的有关说明以及本程序的头文件 include/linux/fdreg.h。该文件定义了所有软盘控制器参数常量，并说明了这些常量的含义。

6.8.2 代码注释

程序 6-6 linux/kernel/blk_drv/floppy.c

```
1  /*
2   *  linux/kernel/floppy.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   * 02.12.91 - Changed to static variables to indicate need for reset
9   * and recalibrate. This makes some things easier (output_byte reset
10  * checking etc), and means less interrupt jumping in case of errors,
11  * so the code is hopefully easier to understand.
12  */
    /*
     * 02.12.91 - 修改成静态变量，以适应复位和重新校正操作。这使得某些事情
     * 做起来较为方便（output_byte 复位检查等），并且意味着在出错时中断跳转
     * 要少一些，所以也希望代码能更容易被理解。
     */
13
14 /*
15  * This file is certainly a mess. I've tried my best to get it working,
16  * but I don't like programming floppies, and I have only one anyway.
17  * Urgel. I should check for more errors, and do more graceful error
18  * recovery. Seems there are problems with several drives. I've tried to
19  * correct them. No promises.
20  */
    /*
     * 这个文件当然比较混乱。我已经尽我所能使其能够工作，但我不喜欢软驱编程，
     * 而且我也只有一个软驱。另外，我应该做更多的查错工作，以及改正更多的错误。
     * 对于某些软盘驱动器，本程序好象还存在一些问题。我已经尝试着进行纠正了，
     * 但不能保证问题已消失。
     */
21
22 /*
23  * As with hd.c, all routines within this file can (and will) be called
24  * by interrupts, so extreme caution is needed. A hardware interrupt
25  * handler may not sleep, or a kernel panic will happen. Thus I cannot
26  * call "floppy-on" directly, but have to set a special timer interrupt
27  * etc.
28  *
29  * Also, I'm not certain this works on more than 1 floppy. Bugs may
30  * abund.
31  */
    /*
```

```
 * 如同 hd.c 文件一样，该文件中的所有子程序都能够被中断调用，所以需要特别
 * 地小心。硬件中断处理程序是不能睡眠的，否则内核就会傻掉(死机)☺。因此不能
 * 直接调用"floppy-on"，而只能设置一个特殊的定时中断等。
 *
 * 另外，我不能保证该程序能在多于 1 个软驱的系统上工作，有可能存在错误。
 */
32
33 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
34 #include <linux/fs.h>     // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
35 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
36 #include <linux/fdreg.h>  // 软驱头文件。含有软盘控制器参数的一些定义。
37 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
38 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
39 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
40
41 #define MAJOR_NR 2        // 软驱的主设备号是 2。
42 #include "blk.h"          // 块设备头文件。定义请求数据结构、块设备数据结构和宏函数等信息。
43
44 static int recalibrate = 0;         // 标志：需要重新校正。
45 static int reset = 0;               // 标志：需要进行复位操作。
46 static int seek = 0;                // 标志：需要执行寻道。
47
   // 当前数字输出寄存器(Digital Output Register)，定义在 sched.c，204 行。
   // 该变量是软驱操作中的重要标志变量，请参见程序后对 DOR 寄存器的说明。
48 extern unsigned char current_DOR;
49
50 #define immoutb_p(val,port) \      // 字节直接输出（嵌入汇编语言宏）。
51 __asm__("outb %0,%1\n\tjmp 1f\n1:\tjmp 1f\n1:"::"a" ((char) (val)),"i" (port))
52
   // 这两个定义用于计算软驱的设备号。次设备号 = TYPE*4 + DRIVE。计算方法参见列表后。
53 #define TYPE(x) ((x)>>2)            // 软驱类型（2--1.2Mb，7--1.44Mb）。
54 #define DRIVE(x) ((x)&0x03)         // 软驱序号（0--3 对应 A--D）。
55 /*
56  * Note that MAX_ERRORS=8 doesn't imply that we retry every bad read
57  * max 8 times - some types of errors increase the errorcount by 2,
58  * so we might actually retry only 5-6 times before giving up.
59  */
   /*
    * 注意，下面定义 MAX_ERRORS=8 并不表示对每次读错误尝试最多 8 次 - 有些类型
    * 的错误将把出错计数值乘 2，所以我们实际上在放弃操作之前只需尝试 5-6 遍即可。
    */
60 #define MAX_ERRORS 8
61
62 /*
63  * globals used by 'result()'
64  */
   /* 下面是函数'result()'使用的全局变量 */
   // 这些状态字节中各比特位的含义请参见 include/linux/fdreg.h 头文件。
65 #define MAX_REPLIES 7                           // FDC 最多返回 7 字节的结果信息。
66 static unsigned char reply_buffer[MAX_REPLIES]; // 存放 FDC 返回的应答结果信息。
67 #define ST0 (reply_buffer[0])                   // 返回结果状态字节 0。
68 #define ST1 (reply_buffer[1])                   // 返回结果状态字节 1。
```

```
69 #define ST2 (reply_buffer[2])                    // 返回结果状态字节 2。
70 #define ST3 (reply_buffer[3])                    // 返回结果状态字节 3。
71
72 /*
73  * This struct defines the different floppy types. Unlike minix
74  * linux doesn't have a "search for right type"-type, as the code
75  * for that is convoluted and weird. I've got enough problems with
76  * this driver as it is.
77  *
78  * The 'stretch' tells if the tracks need to be boubled for some
79  * types (ie 360kB diskette in 1.2MB drive etc). Others should
80  * be self-explanatory.
81  */
   /*
    * 下面的软盘结构定义了不同的软盘类型。与 minix 不同的是，linux 没有
    * "搜索正确的类型"-类型，因为对其处理的代码令人费解且怪怪的。本程序
    * 已经让我遇到了许多的问题了。
    *
    * 对某些类型的软盘（例如在 1.2MB 驱动器中的 360kB 软盘等），'stretch'用于
    * 检测磁道是否需要特殊处理。其他参数应该是自明的。
    */
   // 软盘参数有：
   // size          大小(扇区数)；
   // sect          每磁道扇区数；
   // head          磁头数；
   // track         磁道数；
   // stretch       对磁道是否要特殊处理（标志）；
   // gap           扇区间隙长度(字节数)；
   // rate          数据传输速率；
   // spec1         参数（高 4 位步进速率，低四位磁头卸载时间）。
82 static struct floppy_struct {
83         unsigned int size, sect, head, track, stretch;
84         unsigned char gap,rate,spec1;
85 } floppy_type[] = {
86         {    0,  0,0,  0,0,0x00,0x00,0x00 },      /* no testing */
87         {  720,  9,2,40,0,0x2A,0x02,0xDF },      /* 360kB PC diskettes */
88         { 2400,15,2,80,0,0x1B,0x00,0xDF },       /* 1.2 MB AT-diskettes */
89         {  720,  9,2,40,1,0x2A,0x02,0xDF },      /* 360kB in 720kB drive */
90         { 1440,  9,2,80,0,0x2A,0x02,0xDF },      /* 3.5" 720kB diskette */
91         {  720,  9,2,40,1,0x23,0x01,0xDF },      /* 360kB in 1.2MB drive */
92         { 1440,  9,2,80,0,0x23,0x01,0xDF },      /* 720kB in 1.2MB drive */
93         { 2880,18,2,80,0,0x1B,0x00,0xCF },       /* 1.44MB diskette */
94 };
95 /*
96  * Rate is 0 for 500kb/s, 2 for 300kbps, 1 for 250kbps
97  * Spec1 is 0xSH, where S is stepping rate (F=1ms, E=2ms, D=3ms etc),
98  * H is head unload time (1=16ms, 2=32ms, etc)
99  *
100 * Spec2 is (HLD<<1 | ND), where HLD is head load time (1=2ms, 2=4 ms etc)
101 * and ND is set means no DMA. Hardcoded to 6 (HLD=6ms, use DMA).
102 */
   /*
    * 上面速率 rate：0 表示 500kb/s，1 表示 300kbps，2 表示 250kbps。
```

```
     * 参数 spec1 是 0xSH，其中 S 是步进速率（F-1 毫秒，E-2ms，D=3ms 等），
     * H 是磁头卸载时间（1=16ms，2=32ms 等）
     *
     * spec2 是（HLD<<1 | ND），其中 HLD 是磁头加载时间（1=2ms，2=4ms 等）
     * ND 置位表示不使用 DMA（No DMA），在程序中硬编码成 6（HLD=6ms，使用 DMA）。
     */
103
104 extern void floppy_interrupt(void);      // system_call.s 中软驱中断过程标号。
105 extern char tmp_floppy_area[1024];       // boot/head.s 132 行处定义的软盘缓冲区。
106
107 /*
108  * These are global variables, as that's the easiest way to give
109  * information to interrupts. They are the data used for the current
110  * request.
111  */
    /*
     * 下面是一些全局变量，因为这是将信息传给中断程序最简单的方式。它们是
     * 用于当前请求项的数据。
     */
112 static int cur_spec1 = -1;
113 static int cur_rate = -1;
114 static struct floppy_struct * floppy = floppy_type;
115 static unsigned char current_drive = 0;
116 static unsigned char sector = 0;
117 static unsigned char head = 0;
118 static unsigned char track = 0;
119 static unsigned char seek_track = 0;
120 static unsigned char current_track = 255;          // 当前磁头所在磁道号。
121 static unsigned char command = 0;
    // 软驱已选定标志。在处理一个软驱的请求项之前需要首先选定一个软驱。
122 unsigned char selected = 0;
123 struct task_struct * wait_on_floppy_select = NULL;
124
    //// 取消选定软驱。复位软驱已选定标志 selected。
    // 数字输出寄存器(DOR)的低 2 位用于指定选择的软驱（0-3 对应 A-D）。
125 void floppy_deselect(unsigned int nr)
126 {
127         if (nr != (current_DOR & 3))
128                 printk("floppy_deselect: drive not selected\n\r");
129         selected = 0;
130         wake_up(&wait_on_floppy_select);
131 }
132
133 /*
134  * floppy-change is never called from an interrupt, so we can relax a bit
135  * here, sleep etc. Note that floppy-on tries to set current_DOR to point
136  * to the desired drive, but it will probably not survive the sleep if
137  * several floppies are used at the same time: thus the loop.
138  */
    /*
     * floppy-change()不是从中断程序中调用的，所以这里我们可以轻松一下，睡眠等。
     * 注意 floppy-on()会尝试设置 current_DOR 指向所需的驱动器，但当同时使用几个
     * 软盘时不能睡眠：因此此时只能使用循环方式。
```

```
 */
//// 检测指定软驱中软盘更换情况。如果软盘更换了则返回 1，否则返回 0。
// 该函数由程序 fs/buffer.c 中的 check_disk_change()函数调用（第 119 行）。
int floppy_change(unsigned int nr)
{
repeat:
        floppy_on(nr);                  // 启动指定软驱 nr（kernel/sched.c,251）。
// 如果当前选择的软驱不是指定的软驱 nr，并且已经选定了其他软驱，则让当前任务进入可中断
// 等待状态。
        while ((current_DOR & 3) != nr && selected)
                interruptible_sleep_on(&wait_on_floppy_select);
// 如果当前没有选择其他软驱或者当前任务被唤醒时，当前软驱仍然不是指定的软驱 nr，则循环等待。
        if ((current_DOR & 3) != nr)
                goto repeat;
// 取数字输入寄存器值，如果最高位（位 7）置位，则表示软盘已更换，此时关闭马达并退出返回 1。
// 否则关闭马达退出返回 0。
        if (inb(FD_DIR) & 0x80) {
                floppy_off(nr);
                return 1;
        }
        floppy_off(nr);
        return 0;
}

//// 复制内存缓冲块，共 1024 字节。
#define copy_buffer(from,to) \
__asm__("cld ; rep ; movsl" \
        ::"c" (BLOCK_SIZE/4),"S" ((long)(from)),"D" ((long)(to)) \
        :"cx","di","si")

//// 设置（初始化）软盘 DMA 通道。
static void setup_DMA(void)
{
        long addr = (long) CURRENT->buffer;  // 当前请求项缓冲区所处内存中位置（地址）。

        cli();
// 如果缓冲区处于内存 1M 以上的地方，则将 DMA 缓冲区设在临时缓冲区域(tmp_floppy_area)处。
// 因为 8237A 芯片只能在 1M 地址范围内寻址。如果是写盘命令，则需要把数据复制到该临时区域。
        if (addr >= 0x100000) {
                addr = (long) tmp_floppy_area;
                if (command == FD_WRITE)
                        copy_buffer(CURRENT->buffer,tmp_floppy_area);
        }
/* mask DMA 2 */   /* 屏蔽 DMA 通道 2 */
// 单通道屏蔽寄存器端口为 0x10。位 0-1 指定 DMA 通道(0--3)，位 2：1 表示屏蔽，0 表示允许请求。
        immoutb_p(4|2,10);
/* output command byte. I don't know why, but everyone (minix, */
/* sanches & canton) output this twice, first to 12 then to 11 */
/* 输出命令字节。我是不知道为什么，但是每个人（minix，*/
/* sanches 和 canton）都输出两次，首先是 12 口，然后是 11 口 */
// 下面嵌入汇编代码向 DMA 控制器端口 12 和 11 写方式字（读盘 0x46，写盘 0x4A）。
        __asm__("outb %%al,$12\n\tjmp 1f\n1:\tjmp 1f\n1:\t"
        "outb %%al,$11\n\tjmp 1f\n1:\tjmp 1f\n1:"::
```

```
176         "a" ((char) ((command == FD_READ)?DMA_READ:DMA_WRITE));
177 /* 8 low bits of addr */   /* 地址低 0-7 位 */
    // 向 DMA 通道 2 写入基/当前地址寄存器（端口 4）。
178         immoutb_p(addr,4);
179         addr >>= 8;
180 /* bits 8-15 of addr */   /* 地址高 8-15 位 */
181         immoutb_p(addr,4);
182         addr >>= 8;
183 /* bits 16-19 of addr */   /* 地址 16-19 位 */
    // DMA 只可以在 1MB 内存空间内寻址，其高 16-19 位地址需放入页面寄存器(端口 0x81)。
184         immoutb_p(addr,0x81);
185 /* low 8 bits of count-1 (1024-1=0x3ff) */   /* 计数器低 8 位(1024-1 = 0x3ff) */
    // 向 DMA 通道 2 写入基/当前字节计数器值（端口 5）。
186         immoutb_p(0xff,5);
187 /* high 8 bits of count-1 */   /* 计数器高 8 位 */
    // 一次共传输 1024 字节（两个扇区）。
188         immoutb_p(3,5);
189 /* activate DMA 2 */   /* 开启 DMA 通道 2 的请求 */
    // 复位对 DMA 通道 2 的屏蔽，开放 DMA2 请求 DREQ 信号。
190         immoutb_p(0|2,10);
191         sti();
192 }
193
    //// 向软驱控制器输出一个字节（命令或参数）。
    // 在向控制器发送一个字节之前，控制器需要处于准备好状态，并且数据传输方向是 CPU→FDC，
    // 因此需要首先读取控制器状态信息。这里使用了循环查询方式，以作适当延时。
194 static void output_byte(char byte)
195 {
196         int counter;
197         unsigned char status;
198
199         if (reset)
200                 return;
    // 循环读取主状态控制器 FD_STATUS(0x3f4)的状态。如果状态是 STATUS_READY 并且 STATUS_DIR=0
    // (CPU→FDC)，则向数据端口输出指定字节。
201         for(counter = 0 ; counter < 10000 ; counter++) {
202                 status = inb_p(FD_STATUS) & (STATUS_READY | STATUS_DIR);
203                 if (status == STATUS_READY) {
204                         outb(byte,FD_DATA);
205                         return;
206                 }
207         }
    // 如果到循环 1 万次结束还不能发送，则置复位标志，并打印出错信息。
208         reset = 1;
209         printk("Unable to send byte to FDC\n\r");
210 }
211
    //// 读取 FDC 执行的结果信息。
    // 结果信息最多 7 个字节，存放在 reply_buffer[]中。返回读入的结果字节数，若返回值=-1
    // 表示出错。程序处理方式与上面函数类似。
212 static int result(void)
213 {
214         int i = 0, counter, status;
```

```
215
    // 若复位标志已置位，则立刻退出。
216         if (reset)
217                 return -1;
218         for (counter = 0 ; counter < 10000 ; counter++) {
219                 status = inb_p(FD_STATUS)&(STATUS_DIR|STATUS_READY|STATUS_BUSY);
    // 如果控制器状态是 READY，表示已经没有数据可取，返回已读取的字节数。
220                 if (status == STATUS_READY)
221                         return i;
    // 如果控制器状态是方向标志置位（CPU←FDC）、已准备好、忙，表示有数据可读取。于是把控制器
    // 中的结果数据读入到应答结果数组中。最多读取 MAX_REPLIES（7）个字节。
222                 if (status == (STATUS_DIR|STATUS_READY|STATUS_BUSY)) {
223                         if (i >= MAX_REPLIES)
224                                 break;
225                         reply_buffer[i++] = inb_p(FD_DATA);
226                 }
227         }
228         reset = 1;
229         printk("Getstatus times out\n\r");
230         return -1;
231 }
232
    //// 软盘操作出错中断调用函数。由软驱中断处理程序调用。
233 static void bad_flp_intr(void)
234 {
235         CURRENT->errors++;          // 当前请求项出错次数增 1。
    // 如果当前请求项出错次数大于最大允许出错次数，则取消选定当前软驱，并结束该请求项（缓冲
    // 区内容没有被更新）。
236         if (CURRENT->errors > MAX_ERRORS) {
237                 floppy_deselect(current_drive);
238                 end_request(0);
239         }
    // 如果当前请求项出错次数大于最大允许出错次数的一半，则置复位标志，需对软驱进行复位操作，
    // 然后再试。否则软驱需重新校正一下，再试。
240         if (CURRENT->errors > MAX_ERRORS/2)
241                 reset = 1;
242         else
243                 recalibrate = 1;
244 }
245
246 /*
247  * Ok, this interrupt is called after a DMA read/write has succeeded,
248  * so we check the results, and copy any buffers.
249  */
    /*
     * OK，下面的中断处理函数是在 DMA 读/写成功后调用的，这样我们就可以检查执行结果，
     * 并复制缓冲区中的数据。
     */
    //// 软盘读写操作中断调用函数。
    // 在软驱控制器操作结束后引发的中断处理过程中被调用（Bottom half）。
250 static void rw_interrupt(void)
251 {
    // 读取 FDC 执行的结果信息。如果返回结果字节数不等于 7，或者状态字节 0、1 或 2 中存在出错
```

```
    // 标志，那么，若是写保护就显示出错信息，释放当前驱动器，并结束当前请求项。否则就执行出错
    // 计数处理。然后继续执行软盘请求项操作。以下状态的含义参见 fdreg.h 文件。
    // ( 0xf8 = ST0_INTR | ST0_SE | ST0_ECE | ST0_NR )
    // ( 0xbf = ST1_EOC | ST1_CRC | ST1_OR | ST1_ND | ST1_WP | ST1_MAM，应该是 0xb7)
    // ( 0x73 = ST2_CM | ST2_CRC | ST2_WC | ST2_BC | ST2_MAM )
252         if (result() != 7 || (ST0 & 0xf8) || (ST1 & 0xbf) || (ST2 & 0x73)) {
253                 if (ST1 & 0x02) {           // 0x02 = ST1_WP - Write Protected。
254                         printk("Drive %d is write protected\n\r",current_drive);
255                         floppy_deselect(current_drive);
256                         end_request(0);
257                 } else
258                         bad_flp_intr();
259                 do_fd_request();
260                 return;
261         }
    // 如果当前请求项的缓冲区位于 1M 地址以上，则说明此次软盘读操作的内容还放在临时缓冲区内，
    // 需要复制到当前请求项的缓冲区中（因为 DMA 只能在 1M 地址范围寻址）。
262         if (command == FD_READ && (unsigned long)(CURRENT->buffer) >= 0x100000)
263                 copy_buffer(tmp_floppy_area,CURRENT->buffer);
    // 释放当前软驱（放弃不选定），执行当前请求项结束处理：唤醒等待该请求项的进行，唤醒等待空
    // 闲请求项的进程（若有的话），从软驱设备请求项链表中删除本请求项。再继续执行其他软盘请求
    // 项操作。
264         floppy_deselect(current_drive);
265         end_request(1);
266         do_fd_request();
267 }
268
    //// 设置 DMA 并输出软盘操作命令和参数（输出 1 字节命令+ 0~7 字节参数）。
269 inline void setup_rw_floppy(void)
270 {
271         setup_DMA();                    // 初始化软盘 DMA 通道。
272         do_floppy = rw_interrupt;       // 置软盘中断调用函数指针。
273         output_byte(command);           // 发送命令字节。
274         output_byte(head<<2 | current_drive);  // 参数（磁头号+驱动器号）。
275         output_byte(track);             // 参数（磁道号）。
276         output_byte(head);              // 参数（磁头号）。
277         output_byte(sector);            // 参数（起始扇区号）。
278         output_byte(2);                 /* sector size = 512 */   // 参数(字节数(N=2)512 字节)。
279         output_byte(floppy->sect);      // 参数（每磁道扇区数）。
280         output_byte(floppy->gap);       // 参数（扇区间隔长度）。
281         output_byte(0xFF);              /* sector size (0xff when n!=0 ?) */
                                            // 参数（当 N=0 时，扇区定义的字节长度），这里无用。
    // 若复位标志已置位，则继续执行下一软盘操作请求。
282         if (reset)
283                 do_fd_request();
284 }
285
286 /*
287  * This is the routine called after every seek (or recalibrate) interrupt
288  * from the floppy controller. Note that the "unexpected interrupt" routine
289  * also does a recalibrate, but doesn't come here.
290  */
    /*
```

```
 * 该子程序是在每次软盘控制器寻道（或重新校正）中断后被调用的。注意
 * "unexpected interrupt"(意外中断)子程序也会执行重新校正操作，但不在此地。
 */
//// 寻道处理结束后中断过程中调用的函数。
// 首先发送检测中断状态命令，获得状态信息 ST0 和磁头所在磁道信息。若出错则执行错误计数
// 检测处理或取消本次软盘操作请求项。否则根据状态信息设置当前磁道变量，然后调用函数
// setup_rw_floppy()设置 DMA 并输出软盘读写命令和参数。
291 static void seek_interrupt(void)
292 {
293 /* sense drive status */    /* 检测驱动器状态 */
// 发送检测中断状态命令，该命令不带参数。返回结果信息是两个字节：ST0 和磁头当前磁道号。
294         output_byte(FD_SENSEI);
// 读取 FDC 执行的结果信息。如果返回结果字节数不等于 2，或者 ST0 不为寻道结束，或者磁头所在
// 磁道(ST1)不等于设定磁道，则说明发生了错误，于是执行检测错误计数处理，然后继续执行软盘
// 请求项，并退出。
295         if (result() != 2 || (ST0 & 0xF8) != 0x20 || ST1 != seek_track) {
296                 bad_flp_intr();
297                 do_fd_request();
298                 return;
299         }
300         current_track = ST1;        // 设置当前磁道。
301         setup_rw_floppy();          // 设置 DMA 并输出软盘操作命令和参数。
302 }
303
304 /*
305  * This routine is called when everything should be correctly set up
306  * for the transfer (ie floppy motor is on and the correct floppy is
307  * selected).
308  */
/*
 * 该函数是在传输操作的所有信息都正确设置好后被调用的（也即软驱马达已开启
 * 并且已选择了正确的软盘（软驱）。
 */
//// 读写数据传输函数。

309 static void transfer(void)
310 {
// 首先看当前驱动器参数是否就是指定驱动器的参数，若不是就发送设置驱动器参数命令及相应
// 参数（参数 1：高 4 位步进速率，低四位磁头卸载时间；参数 2：磁头加载时间）。
311         if (cur_spec1 != floppy->spec1) {
312                 cur_spec1 = floppy->spec1;
313                 output_byte(FD_SPECIFY);        // 发送设置磁盘参数命令。
314                 output_byte(cur_spec1);         /* hut etc */   // 发送参数。
315                 output_byte(6);                 /* Head load time =6ms, DMA */
316         }
// 判断当前数据传输速率是否与指定驱动器的一致，若不是就发送指定软驱的速率值到数据传输
// 速率控制寄存器(FD_DCR)。
317         if (cur_rate != floppy->rate)
318                 outb_p(cur_rate = floppy->rate,FD_DCR);
// 若返回结果信息表明出错，则再调用软盘请求函数，并返回。
319         if (reset) {
320                 do_fd_request();
321                 return;
```

```
322         }
    // 若寻道标志为零（不需要寻道），则设置 DMA 并发送相应读写操作命令和参数，然后返回。
323         if (!seek) {
324                 setup_rw_floppy();
325                 return;
326         }
    // 否则执行寻道处理。置软盘中断处理调用函数为寻道中断函数。
327         do_floppy = seek_interrupt;
    // 如果起始磁道号不等于零则发送磁头寻道命令和参数
328         if (seek_track) {
329                 output_byte(FD_SEEK);     // 发送磁头寻道命令。
330                 output_byte(head<<2 | current_drive);  //发送参数：磁头号+当前软驱号。
331                 output_byte(seek_track);               // 发送参数：磁道号。
332         } else {
333                 output_byte(FD_RECALIBRATE);           // 发送重新校正命令（磁头归零）。
334                 output_byte(head<<2 | current_drive);  //发送参数：磁头号+当前软驱号。
335         }
    // 如果复位标志已置位，则继续执行软盘请求项。
336         if (reset)
337                 do_fd_request();
338 }
339
340 /*
341  * Special case - used after a unexpected interrupt (or reset)
342  */
    /*
     * 特殊情况 - 用于意外中断（或复位）处理后。
     */
    //// 软驱重新校正中断调用函数。
    // 首先发送检测中断状态命令（无参数），如果返回结果表明出错，则置复位标志，否则复位重新
    // 校正标志。然后再次执行软盘请求。
343 static void recal_interrupt(void)
344 {
345         output_byte(FD_SENSEI);                    // 发送检测中断状态命令。
346         if (result()!=2 || (ST0 & 0xE0) == 0x60) // 如果返回结果字节数不等于 2 或命令
347                 reset = 1;                         // 异常结束，则置复位标志。
348         else                                       // 否则复位重新校正标志。
349                 recalibrate = 0;
350         do_fd_request();                           // 执行软盘请求项。
351 }
352
    //// 意外软盘中断请求中断调用函数。
    // 首先发送检测中断状态命令（无参数），如果返回结果表明出错，则置复位标志，否则置重新
    // 校正标志。
353 void unexpected_floppy_interrupt(void)
354 {
355         output_byte(FD_SENSEI);                    // 发送检测中断状态命令。
356         if (result()!=2 || (ST0 & 0xE0) == 0x60) // 如果返回结果字节数不等于 2 或命令
357                 reset = 1;                         // 异常结束，则置复位标志。
358         else                                       // 否则置重新校正标志。
359                 recalibrate = 1;
360 }
361
```

```
    //// 软盘重新校正处理函数。
    // 向软盘控制器 FDC 发送重新校正命令和参数，并复位重新校正标志。
362 static void recalibrate_floppy(void)
363 {
364         recalibrate = 0;                    // 复位重新校正标志。
365         current_track = 0;                  // 当前磁道号归零。
366         do_floppy = recal_interrupt;        // 置软盘中断调用函数指针指向重新校正调用函数。
367         output_byte(FD_RECALIBRATE);        // 发送命令：重新校正。
368         output_byte(head<<2 | current_drive); // 发送参数：（磁头号加）当前驱动器号。
369         if (reset)                          // 如果出错(复位标志被置位)则继续执行软盘请求。
370                 do_fd_request();
371 }
372
    //// 软盘控制器 FDC 复位中断调用函数。在软盘中断处理程序中调用。
    // 首先发送检测中断状态命令（无参数），然后读出返回的结果字节。接着发送设定软驱参数命令
    // 和相关参数，最后再次调用执行软盘请求。
373 static void reset_interrupt(void)
374 {
375         output_byte(FD_SENSEI);                 // 发送检测中断状态命令。
376         (void) result();                        // 读取命令执行结果字节。
377         output_byte(FD_SPECIFY);                // 发送设定软驱参数命令。
378         output_byte(cur_spec1);         /* hut etc */ // 发送参数。
379         output_byte(6);                 /* Head load time =6ms, DMA */
380         do_fd_request();                        // 调用执行软盘请求。
381 }
382
383 /*
384  * reset is done by pulling bit 2 of DOR low for a while.
385  */
    /* FDC 复位是通过将数字输出寄存器(DOR)位 2 置 0 一会儿实现的 */
    //// 复位软盘控制器。
386 static void reset_floppy(void)
387 {
388         int i;
389
390         reset = 0;                              // 复位标志置 0。
391         cur_spec1 = -1;
392         cur_rate = -1;
393         recalibrate = 1;                        // 重新校正标志置位。
394         printk("Reset-floppy called\n\r");      // 显示执行软盘复位操作信息。
395         cli();                                  // 关中断。
396         do_floppy = reset_interrupt;            // 设置在软盘中断处理程序中调用的函数。
397         outb_p(current_DOR & ~0x04,FD_DOR);     // 对软盘控制器 FDC 执行复位操作。
398         for (i=0 ; i<100 ; i++)                 // 空操作，延迟。
399                 __asm__("nop");
400         outb(current_DOR,FD_DOR);               // 再启动软盘控制器。
401         sti();                                  // 开中断。
402 }
403
    //// 软驱启动定时中断调用函数。
    // 首先检查数字输出寄存器(DOR)，使其选择当前指定的驱动器。然后调用执行软盘读写传输
    // 函数 transfer()。
404 static void floppy_on_interrupt(void)
```

```
405 {
406 /* We cannot do a floppy-select, as that might sleep. We just force it */
    /* 我们不能任意设置选择的软驱，因为这样做可能会引起进程睡眠。我们只是迫使它自己选择 */
407         selected = 1;    // 置已选定当前驱动器标志。
    // 若当前驱动器号与数字输出寄存器 DOR 中的不同,则需要重新设置 DOR 为当前驱动器 current_drive。
    // 定时延迟 2 个滴答时间，然后调用软盘读写传输函数 transfer()。否则直接调用软盘读写传输函数。
408         if (current_drive != (current_DOR & 3)) {
409                 current_DOR &= 0xFC;
410                 current_DOR |= current_drive;
411                 outb(current_DOR,FD_DOR);              // 向数字输出寄存器输出当前 DOR。
412                 add_timer(2,&transfer);                // 添加定时器并执行传输函数。
413         } else
414                 transfer();                           // 执行软盘读写传输函数。
415 }
416
    //// 软盘读写请求项处理函数。
    //
417 void do_fd_request(void)
418 {
419         unsigned int block;
420
421         seek = 0;
    // 如果复位标志已置位，则执行软盘复位操作，并返回。
422         if (reset) {
423                 reset_floppy();
424                 return;
425         }
    // 如果重新校正标志已置位，则执行软盘重新校正操作，并返回。
426         if (recalibrate) {
427                 recalibrate_floppy();
428                 return;
429         }
    // 检测请求项的合法性，若已没有请求项则退出(参见 blk.h,127)。
430         INIT_REQUEST;
    // 将请求项结构中软盘设备号中的软盘类型(MINOR(CURRENT->dev)>>2)作为索引取得软盘参数块。
431         floppy = (MINOR(CURRENT->dev)>>2) + floppy_type;
    // 如果当前驱动器不是请求项中指定的驱动器，则置标志 seek，表示需要进行寻道操作。
    // 然后置请求项设备为当前驱动器。
432         if (current_drive != CURRENT_DEV)
433                 seek = 1;
434         current_drive = CURRENT_DEV;
    // 设置读写起始扇区。因为每次读写是以块为单位（1 块为 2 个扇区），所以起始扇区需要起码比
    // 磁盘总扇区数小 2 个扇区。否则结束该次软盘请求项，执行下一个请求项。
435         block = CURRENT->sector;          // 取当前软盘请求项中起始扇区号→block。
436         if (block+2 > floppy->size) {     // 如果 block+2 大于磁盘扇区总数，则
437                 end_request(0);           // 结束本次软盘请求项。
438                 goto repeat;
439         }
    // 求对应在磁道上的扇区号，磁头号，磁道号，搜寻磁道号（对于软驱读不同格式的盘）。
440         sector = block % floppy->sect;    // 起始扇区对每磁道扇区数取模，得磁道上扇区号。
441         block /= floppy->sect;            // 起始扇区对每磁道扇区数取整，得起始磁道数。
442         head = block % floppy->head;      // 起始磁道数对磁头数取模，得操作的磁头号。
443         track = block / floppy->head;     // 起始磁道数对磁头数取整，得操作的磁道号。
```

```
444         seek_track = track << floppy->stretch; // 相应于驱动器中盘类型进行调整，得寻道号。
    // 如果寻道号与当前磁头所在磁道不同，则置需要寻道标志 seek。
445         if (seek_track != current_track)
446                 seek = 1;
447         sector++;                       // 磁盘上实际扇区计数是从 1 算起。
448         if (CURRENT->cmd == READ)       // 如果请求项中是读操作，则置软盘读命令码。
449                 command = FD_READ;
450         else if (CURRENT->cmd == WRITE) // 如果请求项中是写操作，则置软盘写命令码。
451                 command = FD_WRITE;
452         else
453                 panic("do_fd_request: unknown command");
    // 向系统添加定时器。为了能对软驱进行读写操作，需要首先启动驱动器马达并达到正常运转速度。
    // 这需要一定的时间。因此这里利用 ticks_to_floppy_on()计算启动延时时间，设定一个定时器。
    // 当定时时间到时，就调用函数 floppy_on_interrupt()。
454         add_timer(ticks_to_floppy_on(current_drive),&floppy_on_interrupt);
455 }
456
    //// 软盘系统初始化。
    // 设置软盘块设备的请求处理函数(do_fd_request())，并设置软盘中断门(int 0x26，对应硬件
    // 中断请求信号 IRQ6），然后取消对该中断信号的屏蔽，允许软盘控制器 FDC 发送中断请求信号。
    // 中断描述符表 IDT 中陷阱门描述符设置宏 set_trap_gate()在 include/asm/system.h 中实现。
457 void floppy_init(void)
458 {
459         blk_dev[MAJOR_NR].request_fn = DEVICE_REQUEST;  // = do_fd_request()。
460         set_trap_gate(0x26,&floppy_interrupt);  //设置软盘中断门 int 0x26(38)。
461         outb(inb_p(0x21)&~0x40,0x21);           // 复位软盘的中断请求屏蔽位，允许
                                                    // 软盘控制器发送中断请求信号。
462 }
463
```

6.8.3 其他信息

6.8.3.1 软盘驱动器的设备号

在 Linux 中，软驱的主设备号是 2，次设备号 = TYPE*4 + DRIVE，其中 DRIVE 为 0-3，分别对应软驱 A、B、C 或 D；TYPE 是软驱的类型，2 表示 1.2M 软驱，7 表示 1.44M 软驱，也即 floppy.c 中 85 行定义的软盘类型（floppy_type[]）数组的索引值，见表 6–13 所示。

表 6－13 软盘驱动器类型

类型	说明
0	不用。
1	360KB PC 软驱。
2	1.2MB AT 软驱。
3	360kB 在 720kB 驱动器中使用。
4	3.5" 720kB 软盘。
5	360kB 在 1.2MB 驱动器中使用。
6	720kB 在 1.2MB 驱动器中使用。
7	1.44MB 软驱。

例如，因为 7*4 + 0 = 28，所以 /dev/PS0 (2,28)指的是 1.44M A 驱动器,其设备号是 0x021c。

同理 /dev/at0 (2,8)指的是 1.2M A 驱动器，其设备号是 0x0208。

6.8.3.2 软盘控制器

对软盘控制器（FDC）进行编程比较烦琐。在编程时需要访问 4 个端口，分别对应软盘控制器上一个或多个寄存器。对于 1.2M 的软盘控制器有表 6–14 中的一些端口。

表 6－14 软盘控制器端口

I/O 端口	读写性	寄存器名称
0x3f2	只写	数字输出寄存器（DOR）(数字控制寄存器)
0x3f4	只读	FDC 主状态寄存器(STATUS)
0x3f5	读/写	FDC 数据寄存器(DATA)
0x3f7	只读	数字输入寄存器（DIR）
	只写	磁盘控制寄存器(DCR)(传输率控制)

数字输出端口 DOR（数字控制端口）是一个 8 位寄存器，它控制驱动器马达开启、驱动器选择、启动/复位 FDC 以及允许/禁止 DMA 及中断请求。该寄存器各比特位的含义见表 6–15 所示。

表 6－15 数字输出寄存器定义

位	名称	说明
7	MOT_EN3	启动软驱 D 马达：1-启动；0-关闭。
6	MOT_EN2	启动软驱 C 马达：1-启动；0-关闭。
5	MOT_EN1	启动软驱 B 马达：1-启动；0-关闭。
4	MOT_EN0	启动软驱 A 马达：1-启动；0-关闭。
3	DMA_INT	允许 DMA 和中断请求；0-禁止 DMA 和中断请求。
2	RESET	允许软盘控制器 FDC 工作。0-复位 FDC。
1	DRV_SEL1	00-11 用于选择软盘驱动器 A-D。
0	DRV_SEL0	

FDC 的主状态寄存器也是一个 8 位寄存器，用于反映软盘控制器 FDC 和软盘驱动器 FDD 的基本状态。通常，在 CPU 向 FDC 发送命令之前或从 FDC 获取操作结果之前，都要读取主状态寄存器的状态位，以判别当前 FDC 数据寄存器是否就绪，以及确定数据传送的方向。见表 6–16 所示。

表 6－16 FDC 主状态控制器 MSR 定义

位	名称	说明
7	RQM	数据口就绪：控制器 FDC 数据寄存器已准备就绪。
6	DIO	传输方向：1- FDC→CPU；0- CPU→FDC
5	NDM	非 DMA 方式：1- 非 DMA 方式；0- DMA 方式
4	CB	控制器忙：FDC 正处于命令执行忙碌状态
3	DDB	软驱 D 忙
2	DCB	软驱 C 忙
1	DBB	软驱 B 忙
0	DAB	软驱 A 忙

FDC 的数据端口对应多个寄存器（只写型命令寄存器和参数寄存器、只读型结果寄存器），但任一时刻只能有一个寄存器出现在数据端口 0x3f5。在访问只写型寄存器时，主状态控制的 DIO 方向位必须为 0（CPU → FDC），访问只读型寄存器时则反之。在读取结果时只有在 FDC 不忙之后才算读完结果，通常结果数据最多有 7 个字节。

数据输入寄存器（DIR）只有位 7（D7）对软盘有效，用来表示盘片更换状态。其余七位用于硬盘控制器接口。

磁盘控制寄存器(DCR)用于选择盘片在不同类型驱动器上使用的数据传输率。仅使用低 2 位（D1D0），00 - 500kbps，01 - 300kbps，10 - 250kbps。

Linux 0.11 内核中，驱动程序与软驱中磁盘之间的数据传输是通过 DMA 控制器实现的。在进行读写操作之前，需要首先初始化 DMA 控制器，并对软驱控制器进行编程。对于 386 兼容 PC，软驱控制器使用硬件中断 IR6（对应中断描述符 0x26），并采用 DMA 控制器的通道 2。有关 DMA 控制处理的内容见后面小节。

6.8.3.3 软盘控制器命令

软盘控制器共可以接受 15 条命令。每个命令均经历三个阶段：命令阶段、执行阶段和结果阶段。

命令阶段是 CPU 向 FDC 发送命令字节和参数字节。每条命令的第一个字节总是命令字节（命令码）。其后跟着 0--8 字节的参数。

执行阶段是 FDC 执行命令规定的操作。在执行阶段 CPU 是不加干预的，一般是通过 FDC 发出中断请求获知命令执行的结束。如果 CPU 发出的 FDC 命令是传送数据，则 FDC 可以以中断方式或 DMA 方式进行。中断方式每次传送 1 字节。DMA 方式是在 DMA 控制器管理下，FDC 与内存进行数据的传输直至全部数据传送完。此时 DMA 控制器会将传输字节计数终止信号通知 FDC，最后由 FDC 发出中断请求信号告知 CPU 执行阶段结束。

结果阶段是由 CPU 读取 FDC 数据寄存器返回值，从而获得 FDC 命令执行的结果。返回结果数据的长度为 0--7 字节。对于没有返回结果数据的命令，则应向 FDC 发送检测中断状态命令获得操作的状态。

由于 Linux 0.11 的软盘驱动程序中只使用其中 6 条命令，因此这里仅对这些用到的命令进行描述。

1. 重新校正命令（FD_RECALIBRATE）

该命令用来让磁头退回到 0 磁道。通常用于在软盘操作出错时对磁头重新校正定位。其命令码是 0x07，参数是指定的驱动器号（0—3）。

该命令无结果阶段，程序需要通过执行“检测中断状态”来获取该命令的执行结果。见表 6–17 所示。

表 6－17 重新校正命令（FD_RECALIBRATE）

阶段	序	D7	D6	D5	D4	D3	D2	D1	D0	说明
命令	0	0	0	0	0	0	1	1	1	重新校正命令码：0x07
	1	0	0	0	0	0	0	US1	US2	驱动器号
执行										磁头移动到 0 磁道
结果		无。								需使用命令获取执行结果。

2. 磁头寻道命令（FD_SEEK）

该命令让选中驱动器的磁头移动到指定磁道上。第 1 个参数指定驱动器号和磁头号，位 0-1 是驱动器号，位 2 是磁头号，其他比特位无用。第 2 个参数指定磁道号。

该命令也无结果阶段，程序需要通过执行“检测中断状态”来获取该命令的执行结果。见表 6–18 所示。

表 6－18 磁头寻道命令（FD_SEEK）

阶段	序	D7	D6	D5	D4	D3	D2	D1	D0	说明
命令	0	0	0	0	0	1	1	1	1	磁头寻道命令码：0x0F
	1	0	0	0	0	0	HD	US1	US2	磁头号、驱动器号。
	2	C								磁道号。
执行										磁头移动到指定磁道上。
结果		无。								需使用命令获取执行结果。

3. 读扇区数据命令（FD_READ）

该命令用于从磁盘上读取指定位置开始的扇区，经 DMA 控制传输到系统内存中。每当一个扇区读完，参数 4（R）就自动加 1，以继续读取下一个扇区，直到 DMA 控制器把传输计数终止信号发送给软盘控制器。该命令通常是在磁头寻道命令执行后磁头已经位于指定磁道后开始。见表 6–19 所示。

返回结果中，磁道号 C 和扇区号 R 是当前磁头所处位置。因为在读完一个扇区后起始扇区号 R 自动增 1，因此结果中的 R 值是下一个未读扇区号。若正好读完一个磁道上最后一个扇区（即 EOT），则磁道号也会增 1，并且 R 值复位成 1。

表 6－19 读扇区数据命令（FD_READ）

阶段	序	D7	D6	D5	D4	D3	D2	D1	D0	说明
命令	0	MT	MF	SK	0	0	1	1	0	读命令码：0xE6（MT=MF=SK=1）
	1	0	0	0	0	0	0	US1	US2	驱动器号。
	2	C								磁道号
	3	H								磁头号
	4	R								起始扇区号
	5	N								扇区字节数
	6	EOT								磁道上最大扇区号
	7	GPL								扇区之间间隔长度（3）
	8	DTL								N=0 时，指定扇区字节数
执行										数据从磁盘传送到系统
结果	1	ST0								状态字节 0
	2	ST1								状态字节 1
	3	ST2								状态字节 2
	4	C								磁道号
	5	H								磁头号
	6	R								扇区号
	7	N								扇区字节数

其中 MT、MF 和 SK 的含义分别为：

MT 表示多磁道操作。MT=1 表示允许在同一磁道上两个磁头连续操作。

MF 表示记录方式。MF=1 表示选用 MFM 记录方式，否则是 FM 记录方式。

SK 表示是否跳过有删除标志的扇区。SK=1 表示跳过。

返回的个状态字节 ST0、ST1 和 ST2 的含义分别见表 6–20、表 6–21 和表 6–22 所示。

表 6－20 状态字节 0 （ST0）

位	名称	说明
7 6	ST0_INTR	中断原因。00 – 命令正常结束；01 – 命令异常结束； 10 – 命令无效；11 – 软盘驱动器状态改变。
5	ST0_SE	寻道操作或重新校正操作结束。（Seek End）
4	ST0_ECE	设备检查出错（零磁道校正出错）。（Equip. Check Error）
3	ST0_NR	软驱未就绪。（Not Ready）
2	ST0_HA	磁头地址。中断时磁头号。（Head Address）
1 0	ST0_DS	驱动器选择号（发生中断时驱动器号）。（Drive Select） 00 – 11 分别对应驱动器 0—3。

表 6－21 状态字节 1 （ST1）

位	名称	说明
7	ST1_EOC	访问超过磁道上最大扇区号 EOT。（End of Cylinder）
6		未使用（0）。
5	ST1_CRC	CRC 校验出错。
4	ST1_OR	数据传输超时，DMA 控制器故障。（Over Run）
3		未使用（0）。
2	ST1_ND	未找到指定的扇区。（No Data - unreadable）
1	ST1_WP	写保护。（Write Protect）
0	ST1_MAM	未找到扇区地址标志 ID AM。（Missing Address Mask）

表 6－22 状态字节 2 （ST2）

位	名称	说明
7		未使用（0）。
6	ST2_CM	SK=0 时，读数据遇到删除标志。（Control Mark = deleted）
5	ST2_CRC	扇区数据场 CRC 校验出错。
4	ST2_WC	扇区 ID 信息的磁道号 C 不符。（Wrong Cylinder）
3	ST2_SEH	检索（扫描）条件满足要求。（Scan Equal Hit）
2	ST2_SNS	检索条件不满足要求。（Scan Not Satisfied）
1	ST2_BC	扇区 ID 信息的磁道号 C=0xFF，磁道坏。（Bad Cylinder）
0	ST2_MAM	未找到扇区数据标志 DATA AM。（Missing Address Mask）

4. 写扇区数据命令（FD_WRITE）

该命令用于将内存中的数据写到磁盘上。在 DMA 传输方式下，软驱控制器把内存中的数据串行地写到磁盘指定扇区中。每写完一个扇区，起始扇区号自动增 1，并继续写下一个扇区，直到软驱控制器收到 DMA 控制器的计数终止信号。见表 6–23 所示，其中缩写名称的含义与读命令中的相同。

表 6－23 写扇区数据命令（FD_WRITE）

阶段	序	D7	D6	D5	D4	D3	D2	D1	D0	说明

命令	0	MT	MF	0	0	0	1	0	1	写数据命令码：0xC5（MT=MF=1）
	1	0	0	0	0	0	0	US1	US2	驱动器号。
	2	C								磁道号
	3	H								磁头号
	4	R								起始扇区号
	5	N								扇区字节数
	6	EOT								磁道上最大扇区号
	7	GPL								扇区之间间隔长度（3）
	8	DTL								N=0 时，指定扇区字节数
执行										数据从系统传送到磁盘
结果	1	ST0								状态字节 0
	2	ST1								状态字节 1
	3	ST2								状态字节 2
	4	C								磁道号
	5	H								磁头号
	6	R								扇区号
	7	N								扇区字节数

5. 检测中断状态命令（FD_SENSEI）

发送该命令后软驱控制器会立刻返回常规结果 1 和 2（即状态 ST0 和磁头所处磁道号 PCN）。它们是控制器执行上一条命令后的状态。通常在一个命令执行结束后会向 CPU 发出中断信号。对于读写扇区、读写磁道、读写删除标志、读标识场、格式化和扫描等命令以及非 DMA 传输方式下的命令引起的中断，可以直接根据主状态寄存器的标志知道中断原因。而对于驱动器就绪信号发生变化、寻道和重新校正（磁头回零道）而引起的中断，由于没有返回结果，就需要利用本命令来读取控制器执行命令后的状态信息。见表 6–24 所示。

表 6－24 检测中断状态命令（FD_SENSEI）

阶段	序	D7	D6	D5	D4	D3	D2	D1	D0	说明
命令	0	0	0	0	0	1	0	0	0	检测中断状态命令码：0x08
执行										
结果	1	ST0								状态字节 0
	2	C								磁头所在磁道号

6. 设定驱动器参数命令（FD_SPECIFY）

该命令用于设定软盘控制器内部的三个定时器初始值和选择传输方式，即把驱动器马达步进速率（STR）、磁头加载/卸载（HLT/HUT）时间和是否采用 DMA 方式来传输数据的信息送入软驱控制器。见表 6–25 所示。

表 6－25 设定驱动器参数命令（FD_SPECIFY）

阶段	序	D7	D6	D5	D4	D3	D2	D1	D0	说明
命令	0	0	0	0	0	0	0	1	1	设定参数命令码：0x03
	1	SRT（单位 2ms）				HUT（单位 32ms）				马达步进速率、磁头卸载时间
	2	HLT（单位 4ms）							ND	磁头加载时间、非 DMA 方式

执行			设置控制器，不发生中断
结果		无	无

6.8.3.4 软盘控制器编程方法

在 PC 机中，软盘控制器一般采用与 NEC PD765 或 Intel 8287A 兼容的芯片，例如 Intel 的 82078。由于软盘的驱动程序比较复杂，因此下面对这类芯片构成的软盘控制器的编程方法进行较为详细的介绍。

典型的磁盘操作不仅仅包括发送命令和等待控制器返回结果，的软盘驱动器的控制是一种低级操作，它需要程序在不同阶段对其执行状况进行干涉。

◆命令与结果阶段的交互

在上述磁盘操作命令或参数发送到软盘控制器之前，必须首先查询控制器的主状态寄存器（MSR），以获知驱动器的就绪状态和数据传输方向。软盘驱动程序中使用了一个 output_byte(byte)函数来专门实现该操作。该函数的等效框图见图 6-6 所示。

该函数一直循环到主状态寄存器的数据口就绪标志 RQM 为 1，并且方向标志 DIO 是 0（CPU→FDC），此时控制器就已准备好接受命令和参数字节。循环语句起超时计数功能，以应付控制器没有响应的情况。本驱动程序中把循环次数设置成了 10000 次。对这个循环次数的选择需要仔细，以避免程序作出不正确的超时判断。在 Linux 内核版本 0.1x 至 0.9x 中就经常会碰到需要调整这个循环次数的问题，因为当时人们所使用的 PC 机运行速度差别较大（16MHz -- 40MHz），因此循环所产生的实际延时也有很大的区别。这可以参见早期 Linux 的邮件列表中的许多文章。为了彻底解决这个问题，最好能使用系统硬件时钟来产生固定频率的延时值。

对于读取控制器的结果字节串的结果阶段，也需要采取与发送命令相同的操作方法，只是此时数据传输方向标志要求是置位状态（FDC→CPU）。本程序中对应的函数是 result()。该函数把读取的结果状态字节存放到了 reply_buffer[]字节数组中。

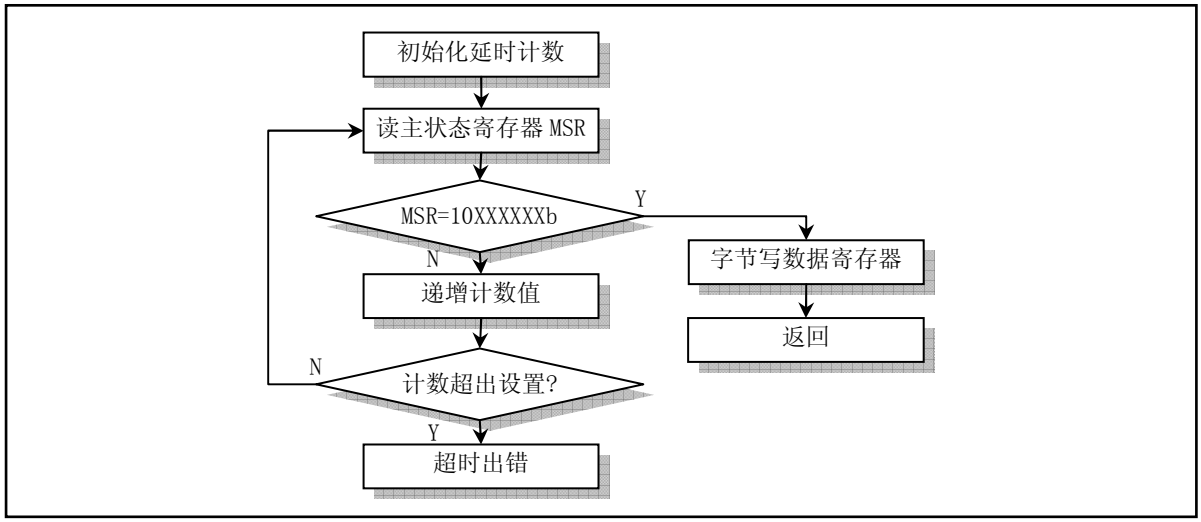

图 6-6 向软盘控制器发送命令或参数字节

◆软盘控制器初始化

对软盘控制器的初始化操作包括在控制器复位后对驱动器进行适当的参数配置。控制器复位操作是指对数字输出寄存器 DOR 的位 2（启动 FDC 标志）置 0 然后再置 1。在机器复位之后，“指定驱动器参数”命令 SPECIFY 所设置的值就不再有效，需要重新建立。在 floppy.c 程序中，复位操作在函数 reset_floppy()和中断处理 C 函数 reset_interrupt()中。前一个函数用于修改 DOR 寄存器的位 2，让控制器

复位，后一个函数用于在控制器复位后使用 SPECIFY 命令重新建立控制器中的驱动器参数。在数据传输准备阶段，若判断出与实际的磁盘规格不同，还在传输函数 transfer()开始处对其另行进行重新设置。

在控制器复位后，还应该向数字控制寄存器 DCR 发送指定的传输速率值，以重新初始化数据传输速率。如果机器执行了复位操作（例如热启动），则数据传输速率会变成默认值 250Kpbs。但通过数字输出寄存器 DOR 向控制器发出的复位操作并不会影响设置的数据传输速率。

◆驱动器重新校正和磁头寻道

驱动器重新校正（FD_RECALIBRATE）和磁头寻道(FD_SEEK)是两个磁头定位命令。重新校正命令让磁头移动到零磁道，而磁头寻道命令则让磁头移动到指定的磁道上。这两个磁头定位命令与典型的读/写命令不同，因为它们没有结果阶段。一旦发出这两个命令之一，控制器将立刻会在主状态寄存器（MSR）返回就绪状态，并以后台形式执行磁头定位操作。当定位操作完成后，控制器就会产生中断以请求服务。此时就应该发送一个“检测中断状态”命令，以结束中断和读取定位操作后的状态。由于驱动器和马达启动信号是直接由数字输出寄存器（DOR）控制的，因此，如果驱动器或马达还没有启动，那么写 DOR 的操作必须在发出定位命令之前进行。流程图见图 6-7 所示。

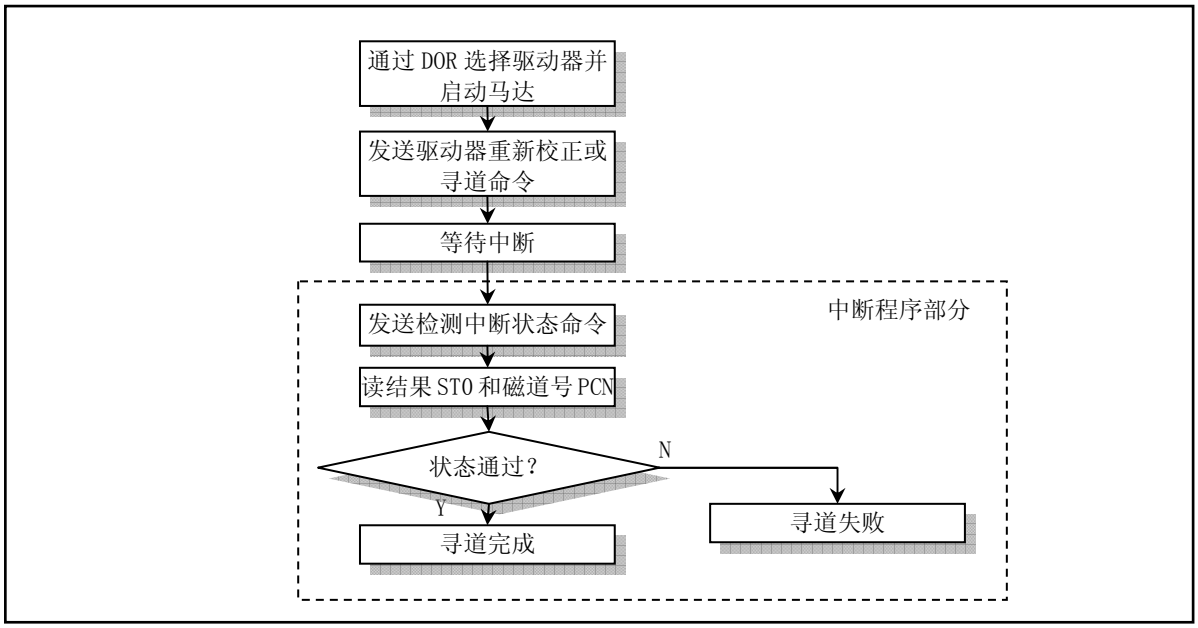

图 6-7 重新校正和寻道操作

◆数据读/写操作

数据读或写操作需要分几步来完成。首先驱动器马达需要开启，并把磁头定位到正确的磁道上，然后初始化 DMA 控制器，最后发送数据读或写命令。另外，还需要定出发生错误时的处理方案。典型的操作流程图见图 6-8 所示。

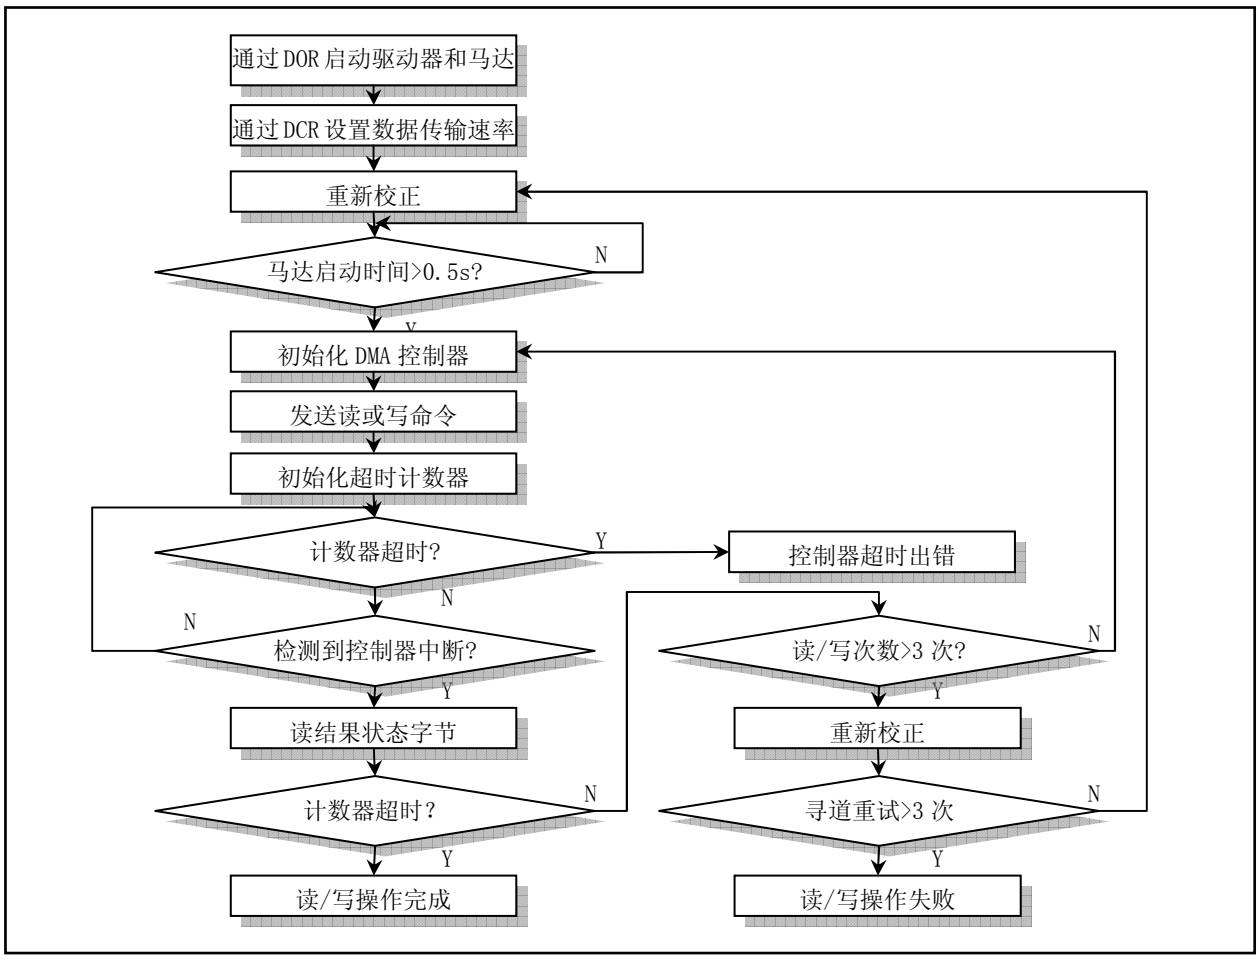

图 6-8 数据读/写操作流程图

在对磁盘进行数据传输之前，磁盘驱动器的马达必须首先达到正常的运转速度。对于大多数 3½英寸软驱来讲，这段启动时间大约需要 300ms，而 5¼英寸的软驱则需要大约 500ms。在 floppy.c 程序中将这个启动延迟时间设置成了 500ms。

在马达启动后，就需要使用数字控制寄存器 DCR 设置与当前磁盘介质匹配的数据传输率。

如果隐式寻道方式没有开启，接下来就需要发送寻道命令 FD_SEEK，把磁头定位到正确的磁道上。在寻道操作结束后，磁头还需要花费一段到位（加载）时间。对于大多数驱动器，这段延迟时间起码需要 15ms。当使用了隐式寻道方式，那么就可以使用“指定驱动器参数”命令指定的磁头加载时间（HLT）来确定最小磁头到位时间。例如在数据传输速率为 500Kbps 的情况下，若 HLT=8，则有效磁头到位时间是 16ms。当然，如果磁头已经在正确的磁道上到位了，也就无须确保这个到位时间了。

然后对 DMA 控制器进行初始化操作，读写命令也随即执行。通常，在数据传输完成后，DMA 控制器会发出终止计数（TC）信号，此时软盘控制器就会完成当前数据传输并发出中断请求信号，表明操作已到达结果阶段。如果在操作过程中出现错误或者最后一个扇区号等于磁道最后一个扇区（EOT），那么软盘控制器也会马上进入结果阶段。

根据上面流程图，如果在读取结果状态字节后发现错误，则会通过重新初始化 DMA 控制器，再尝试重新开始执行数据读或写操作命令。持续的错误通常表明寻道操作并没有让磁头到达指定的磁道，此时应该多次重复对磁头执行重新校准，并再次执行寻道操作。若此后还是出错，则最终控制器就会向驱动程序报告读写操作失败。

◆磁盘格式化操作

Linux 0.11 内核中虽然没有实现对软盘的格式化操作，但作为参考，这里还是对磁盘格式化操作进行简单说明。磁盘格式化操作过程包括把磁头定位到每个磁道上，并创建一个用于组成数据字段（场[9]）的固定格式字段。

在马达已启动并且设置了正确的数据传输率之后，磁头会返回零磁道。此时磁盘需要在 500ms 延迟时间内到达正常和稳定的运转速度。

在格式化操作期间磁盘上建立的标识字段（ID 字段）是在执行阶段由 DMA 控制器提供。DMA 控制器被初始化成为每个扇区标识场提供磁道（C）、磁头（H）、扇区号（R）和扇区字节数的值。例如，对于每个磁道具有 9 个扇区的磁盘，每个扇区大小是 2（512 字节），若是用磁头 1 格式化磁道 7，那么 DMA 控制器应该被编程为传输 36 个字节的数据（9 扇区 x 每扇区 4 个字节），数据字段应该是：7,1,1,2，7,1,2,2，7,1,3,2，...，7,1,9.2。因为在格式化命令执行期间，软盘控制器提供的数据会被直接作为标识字段记录在磁盘上，数据的内容可以是任意的。因此有些人就利用这个功能来防止保护磁盘复制。

在一个磁道上的每个磁头都已经执行了格式化操作以后，就需要执行寻道操作让磁头前移到下一磁道上，并重复执行格式化操作。因为“格式化磁道”命令不含有隐式的寻道操作，所以必须使用寻道命令 SEEK。同样，前面所讨论的磁头到位时间也需要在每次寻道后设置。

6.8.3.5 DMA 控制器编程

DMA（Direct Memory Access)是“直接存储器访问”的缩写。DMA 控制器的主要功能是通过让外部设备直接与内存传输数据来增强系统的性能。通常它由机器上的 Intel 8237 芯片或其兼容芯片实现。通过对 DMA 控制器进行编程，外设与内存之间的数据传输能在不受 CPU 控制的条件下进行。因此在数据传输期间，CPU 可以做其他事。DMA 控制器传输数据的工作过程如下：

1. 初始化 DMA 控制器。

   程序通过 DMA 控制器端口对其进行初始化操作。该操作包括：① 向 DMA 控制器发送控制命令；② 传输的内存起始地址；③ 数据长度。发送的命令指明传输使用的 DMA 通道、是内存传输到外设（写）还是外设数据传输到内存、是单字节传输还是批量（块）传输。对于 PC 机，软盘控制器被指定使用 DMA 通道 2。在 Linux 0.11 内核中，软盘驱动程序采用的是单字节传输模式。由于 Intel 8237 芯片只有 16 根地址引脚（其中 8 根与数据线合用），因此只能寻址 64KB 的内存空间。为了能让它访问 1MB 的地址空间，DMA 控制器采用了一个页面寄存器把 1MB 内存分成了 16 个页面来操作，见表 6–26 所示。因此传输的内存起始地址需要转换成所处的 DMA 页面值和页面中的偏移地址。每次传输的数据长度也不能超过 64KB。

表 6－26 DMA 页面对应的内存地址范围

DMA 页面	地址范围（64KB）
0x0	0x00000 - 0x0FFFF
0x1	0x10000 - 0x1FFFF
0x2	0x20000 - 0x2FFFF
0x3	0x20000 - 0x3FFFF
0x4	0x20000 - 0x4FFFF
0x5	0x20000 - 0x5FFFF
0x6	0x00000 - 0x6FFFF
0x7	0x00000 - 0x7FFFF
0x8	0x10000 - 0x8FFFF
0x9	0x20000 - 0x9FFFF

[9] 关于磁盘格式的说明资料，以前均把 filed 翻译成场。其实对于程序员来讲，翻译成字段或域或许更顺耳一些。☺

0xA	0x20000 - 0xAFFFF
0xB	0x20000 - 0xBFFFF
0xC	0x20000 - 0xCFFFF
0xD	0x00000 - 0xDFFFF
0xE	0x00000 - 0xEFFFF
0xF	0x10000 - 0xFFFFF

2. 数据传输

在初始化完成之后，对 DMA 控制器的屏蔽寄存器进行设置，开启 DMA 通道 2，从而 DMA 控制器开始进行数据的传输。

3. 传输结束

当所需传输的数据全部传输完成，DMA 控制器就会产生“操作完成”（EOP）信号发送到软盘控制器。此时软盘控制器即可执行结束操作：关闭驱动器马达并向 CPU 发送中断请求信号。

在 PC/AT 机中，DMA 控制器有 8 个独立的通道可使用，其中后 4 个通道是 16 位的。软盘控制器被指定使用 DMA 通道 2。在使用一个通道之前必须首先对其设置。这牵涉到对三个端口的操作，分别是：页面寄存器端口、（偏移）地址寄存器端口和数据计数寄存器端口。由于 DMA 寄存器是 8 位的，而地址和计数值是 16 位的，因此各自需要发送两次。首先发送低字节，然后发送高字节。每个通道对应的端口地址见表 6–27 所示。

表 6－27 DMA 各通道使用的页面、地址和计数寄存器端口

DMA 通道	页面寄存器	地址寄存器	计数寄存器
0	0x87	0x00	0x01
1	0x83	0x02	0x03
2	0x81	0x04	0x05
3	0x82	0x06	0x07
4	0x8F	0xC0	0xC2
5	0x8B	0xC4	0xC6
6	0x89	0xC8	0xCA
7	0x8A	0xCC	0xCE

对于通常的 DMA 应用，有 4 个常用寄存器用于控制 DMA 控制器的状态。它们是命令寄存器、请求寄存器、单屏蔽寄存器、方式寄存器和清除字节指针触发器。见表 6–28 所示。Linux 0.11 内核使用了表中带阴影的 3 个寄存器端口（0x0A, 0x0B, 0x0C）。

表 6－28 DMA 编程常用的 DMA 寄存器

名称	端口地址	
	（通道 0-3）	（通道 4-7）
命令寄存器	0x08	0xD0
请求寄存器	0x09	0xD2
单屏蔽寄存器	0x0A	0xD4
方式寄存器	0x0B	0xD6
清除先后触发器	0x0C	0xD8

命令寄存器用于规定 DMA 控制器芯片的操作要求，设定 DMA 控制器的总体状态。通常它在开机初始化之后就无须变动。在 Linux 0.11 内核中，软盘驱动程序就直接使用了开机后 ROM BIOS 的设置值。作为参考，这里列出命令寄存器各比特位的含义，见表 6–29 所示。（在读该端口时，所得内容是 DMA 控制器状态寄存器的信息）

表 6－29 DMA 命令寄存器格式

位	说明
7	DMA 响应外设信号 DACK：0-DACK 低电平有效；1-DACK 高电平有效。
6	外设请求 DMA 信号 DREQ：0-DREQ 低电平有效；1-DREQ 高电平有效。
5	写方式选择：0-选择迟后写；1-选择扩展写；X-若位 3=1。
4	DMA 通道优先方式：0-固定优先；1-轮转优先。
3	DMA 周期选择：0-普通定时周期（5）；1-压缩定时周期（3）；X-若位 0=1。
2	开启 DMA 控制器：0-允许控制器工作；1-禁止控制器工作。
1	通道 0 地址保持：0-禁止通道 0 地址保持；1-允许通道 0 地址保持；X-若位 0=0。
0	内存传输方式：0-禁止内存至内存传输方式；1-允许内存至内存传输方式。

请求寄存器用于记录外设对通道的请求服务信号 DREQ。每个通道对应一位。当 DREQ 有效时对应位置 1，当 DMA 控制器对其作出响应时会对该位置 0。如果不使用 DMA 的请求信号 DREQ 引脚，那么也可以通过编程直接设置相应通道的请求位来请求 DMA 控制器的服务。在 PC 机中，软盘控制器与 DMA 控制器的通道 2 有直接的请求信号 DREQ 连接，因此 Linux 内核中也无须对该寄存器进行操作。作为参考，这里还是列出请求通道服务的字节格式，见表 6–30 所示。

表 6－30 DMA 请求寄存器各比特位的含义

位	说明
7 -3	不用。
2	屏蔽标志。0 - 请求位置位；1 - 请求位复位（置 0）。
1 0	通道选择。00-11 分别选择通道 0-3。

单屏蔽寄存器的端口是 0x0A（对于 16 位通道则是 0xD4）。一个通道被屏蔽，是指使用该通道的外设发出的 DMA 请求信号 DREQ 得不到 DMA 控制器的响应，因此也就无法让 DMA 控制器操作该通道。该寄存器各比特位的含义见表 6–31 所示。

表 6－31 DMA 单屏蔽寄存器各比特位的含义

位	说明
7 -3	不用。
2	屏蔽标志。1 - 屏蔽选择的通道；0 - 开启选择的通道。
1 0	通道选择。00-11 分别选择通道 0-3。

方式寄存器用于指定某个 DMA 通道的操作方式。在 Linux 0.11 内核中，使用了其中读（0x46）和写（0x4A）两种方式。该寄存器各位的含义见表 6–32 所示。

表 6－32 DMA 方式寄存器各比特位的含义

位	说明
7	选择传输方式。
6	00-请求模式；01-单字节模式；10-块字节模式；11-接连模式。
5	地址增减方式。0-地址递减；1-地址递增。
4	自动预置（初始化）。0-自动预置；1-非自动预置。
3	传输类型。
2	00-DMA 校验；01-DMA 写传输；10-DMA 读传输。11-无效。
1	通道选择。00-11 分别选择通道 0-3。
0	

通道的地址和计数寄存器可以读写 16 位的数据。清除先后触发器端口 0x0C 就是用于在读/写 DMA 控制器中地址或计数信息之前把字节先后触发器初始化为默认状态。当字节触发器为 0 时，则访问低字节；当字节触发器为 1 时，则访问高字节。每访问一次，该触发器就变化一次。写 0x0C 端口就可以将触发器置成 0 状态。

在使用 DMA 控制器时，通常需要按照一定的步骤来进行，下面以软盘驱动程序使用 DMA 控制器的方式来加以说明：

1. 关中断，以排除任何干扰；
2. 修改屏蔽寄存器（端口 0x0A），以屏蔽需要使用的 DMA 通道。对于软盘驱动程序来说就是通道 2；
3. 向 0x0C 端口写操作，置字节先后触发器为默认状态；
4. 写方式寄存器（端口 0x0B），以设置指定通道的操作方式字。对于；
5. 写地址寄存器（端口 0x04），设置 DMA 使用的内存页面中的偏移地址。先写低字节，后写高字节；
6. 写页面寄存器（端口 0x81），设置 DMA 使用的内存页面；
7. 写计数寄存器（端口 0x05），设置 DMA 传输的字节数。应该是传输长度-1。同样需要针对高低字节分别写一次。本书中软盘驱动程序每次要求 DMA 控制器传输的长度是 1024 字节，因此写 DMA 控制器的长度值应该是 1023（即 0x3FF）；
8. 再次修改屏蔽寄存器（端口 0x0A），以开启 DMA 通道；
9. 最后，开启中断，以允许软盘控制器在传输结束后向系统发出中断请求。

第7章 字符设备驱动程序(char driver)

7.1 概述

在 linux 0.11 内核中，字符设备主要包括控制终端设备和串行终端设备。本章的代码就是用于对这些设备的输入输出进行操作。有关终端驱动程序的工作原理可参考 M.J.Bach 的《UNIX 操作系统设计》第 10 章第 3 节内容。

列表 7-1 linux/kernel/chr_drv 目录

	文件名	大小	最后修改时间(GMT)	说明
	Makefile	2443 bytes	1991-12-02 03:21:41	Make 配置文件
	console.c	14568 bytes	1991-11-23 18:41:21	终端处理程序
	keyboard.S	12780 bytes	1991-12-04 15:07:58	键盘中断处理程序
	rs_io.s	2718 bytes	1991-10-02 14:16:30	串行线路处理程序
	serial.c	1406 bytes	1991-11-17 21:49:05	串行终端处理程序
	tty_io.c	7634 bytes	1991-12-08 18:09:15	终端 IO 处理程序
	tty_ioctl.c	4979 bytes	1991-11-25 19:59:38	终端 IO 控制程序

7.2 总体功能描述

本章的程序可分成三块。一块是关于 RS-232 串行线路驱动程序，包括程序 rs_io.s 和 serial.c；另一块是涉及控制台驱动程序，这包括键盘中断驱动程序 keyboard.S 和控制台显示驱动程序 console.c；第三部分是终端驱动程序与上层接口部分，包括终端输入输出程序 tty_io.c 和终端控制程序 tty_ioctl.c。下面我们首先概述终端控制驱动程序实现的基本原理，然后再分这三部分分别说明它们的基本功能。

7.2.1 终端驱动程序基本原理

终端驱动程序用于控制终端设备，在终端设备和进程之间传输数据，并对所传输的数据进行一定的处理。用户在键盘上键入的原始数据（Raw data），在通过终端程序处理后，被传送给一个接收进程；而进程向终端发送的数据，在终端程序处理后，被显示在终端屏幕上或者通过串行线路被发送到远程终端。根据终端程序对待输入或输出数据的方式，可以把终端工作模式分成两种。一种是规范模式（canonical），此时经过终端程序的数据将被进行变换处理，然后再送出。例如把 TAB 字符扩展为 8 个空格字符，用键入的删除字符（backspace）控制删除前面键入的字符等。使用的处理函数一般称为行规则(line discipline)模块。另一种是非规范模式或称原始(raw)模式。在这种模式下，行规则程序仅在终端与进程之间传送数据，而不对数据进行规范模式的变换处理。

在终端驱动程序中，根据它们与设备的关系，以及在执行流程中的位置，可以分为字符设备的直接驱动程序和与上层直接联系的接口程序。我们可以用图 7-1 示意图来表示这种控制关系。

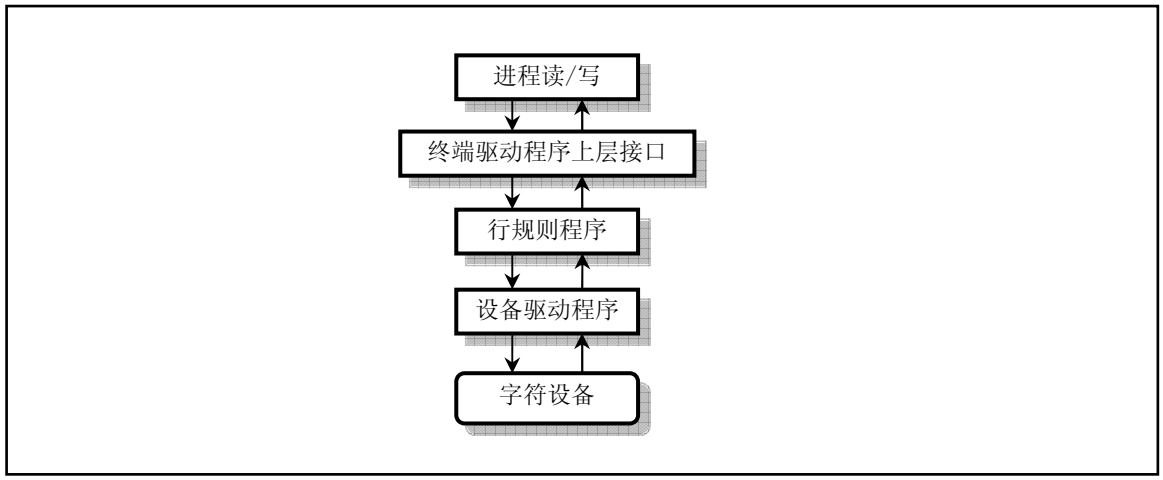

图 7-1 终端驱动程序控制流程

7.2.2 终端基本数据结构

每个终端设备都对应有一个 tty_struct 数据结构，主要用来保存终端设备当前参数设置、所属的前台进程组 ID 和字符 IO 缓冲队列等信息。该结构定义在 include/linux/tty.h 文件中，其结构如下所示：

```
struct tty_struct {
        struct termios termios;                 // 终端 io 属性和控制字符数据结构。
        int pgrp;                               // 所属进程组。
        int stopped;                            // 停止标志。
        void (*write)(struct tty_struct * tty); // tty 写函数指针。
        struct tty_queue read_q;                // tty 读队列。
        struct tty_queue write_q;               // tty 写队列。
        struct tty_queue secondary;             // tty 辅助队列(存放规范模式字符序列)，
};                                              // 可称为规范(熟)模式队列。
extern struct tty_struct tty_table[];           // tty 结构数组。
```

Linux 内核使用了数组 tty_table[]来保存系统中每个终端设备的信息。每个数组项是一个数据结构 tty_struct，对应系统中一个终端设备。Linux 0.11 内核共支持三个终端设备。一个是控制台设备，另外两个是使用系统上两个串行端口的串行终端设备。

termios 结构用于存放对应终端设备的 io 属性。有关该结构的详细描述见下面说明。pgrp 是进程组标识，它指明一个会话中处于前台的进程组，即当前拥有该终端设备的进程组。pgrp 主要用于进程的作业控制操作。stopped 是一个标志，表示对应终端设备是否已经停止使用。函数指针*write()是该终端设备的输出处理函数，对于控制台终端，它负责驱动显示硬件，在屏幕上显示字符等信息。对于通过系统串行端口连接的串行终端，它负责把输出字符发送到串行端口。

终端所处理的数据被保存在 3 个 tty_queue 结构的字符缓冲队列中（或称为字符表），见下面所示：

```
struct tty_queue {
        unsigned long data;                     // 等待队列缓冲区中当前数据统计值。
                                                // 对于串口终端，则存放串口端口地址。
        unsigned long head;                     // 缓冲区中数据头指针。
        unsigned long tail;                     // 缓冲区中数据尾指针。
        struct task_struct * proc_list;         // 等待本缓冲队列的进程列表。
```

```
        char buf[1024];                         // 队列的缓冲区。
};
```

每个字符缓冲队列的长度是 1K 字节。其中读缓冲队列 read_q 用于临时存放从键盘或串行终端输入的原始（raw）字符序列；写缓冲队列 write_q 用于存放写到控制台显示屏或串行终端去的数据；根据 ICANON 标志，辅助队列 secondary 用于存放从 read_q 中取出的经过行规则程序处理（过滤）过的数据，或称为熟(cooked)模式数据。这是在行规则程序把原始数据中的特殊字符如删除（backspace）字符变换后的规范输入数据，以字符行为单位供应用程序读取使用。上层终端读函数 tty_read()即用于读取 secondary 队列中的字符。

在读入用户键入的数据时，中断处理汇编程序只负责把原始字符数据放入输入缓冲队列中，而由中断处理过程中调用的 C 函数（copy_to_cooked()）来处理字符的变换工作。例如当进程向一个终端写数据时，终端驱动程序就会调用行规则函数 copy_to_cooked()，把用户缓冲区中的所有数据数据到写缓冲队列中，并将数据发送到终端上显示。在终端上按下一个键时，所引发的键盘中断处理过程会把按键扫描码对应的字符放入读队列 read_q 中，并调用规范模式处理程序把 read_q 中的字符经过处理再放入辅助队列 secondary 中。与此同时，如果终端设备设置了回显标志（L_ECHO），则也把该字符放入写队列 write_q 中，并调用终端写函数把该字符显示在屏幕上。通常除了象键入密码或其他特殊要求以外，回显标志都是置位的。我们可以通过修改终端的 termios 结构中的信息来改变这些标志值。

在上述 tty_struct 结构中还包括一个 termios 结构，该结构定义在 include/termios.h 头文件中，其字段内容如下所示：

```
struct termios {
        unsigned long c_iflag;          /* input mode flags */      // 输入模式标志。
        unsigned long c_oflag;          /* output mode flags */     // 输出模式标志。
        unsigned long c_cflag;          /* control mode flags */    // 控制模式标志。
        unsigned long c_lflag;          /* local mode flags */      // 本地模式标志。
        unsigned char c_line;           /* line discipline */       // 线路规程（速率）。
        unsigned char c_cc[NCCS];       /* control characters */    // 控制字符数组。
};
```

其中，c_iflag 是输入模式标志集。Linux 0.11 内核实现了 POSIX.1 定义的所有 11 个输入标志，参见 termios.h 头文件中的说明。终端设备驱动程序用这些标志来控制如何对终端输入的字符进行变换（过滤）处理。例如是否需要把输入的的换行符（NL）转换成回车符（CR）、是否需要把输入的大写字符转换成小写字符（因为以前有些终端设备只能输入大写字符）等。在 Linux 0.11 内核中，相关的处理函数是 tty_io.c 文件中的 copy_to_cooked()。

c_oflag 是输出模式标志集。终端设备驱动程序使用这些标志控制如何把字符输出到终端上。c_cflag 是控制模式标志集。主要用于定义串行终端传输特性，包括波特率、字符比特位数以及停止位数等。c_lflag 是本地模式标志集。主要用于控制驱动程序与用户的交互。例如是否需要回显（Echo）字符、是否需要把搽除字符直接显示在屏幕上、是否需要让终端上键入的控制字符产生信号。这些操作也同样在 copy_to_cooked()函数中实现。

上述 4 种标志集的类型都是 unsigned long，每个比特位可表示一种标志，因此每个标志集最多可有 32 个输入标志。所有这些标志及其含义可参见 termios.h 头文件。

c_cc[]数组包含了所有可以修改的特殊字符。例如你可以通过修改其中的中断字符（^C）由其他按键产生。其中 NCCS 是数组的长度值。

因此，利用系统调用 ioctl 或使用相关函数(tcsetattr())，我们可以通过修改 termios 结构中的信息来改变终端的设置参数。行规则函数即是根据这些设置参数进行操作。例如，控制终端是否要对键入的字符

进行回显、设置串行终端传输的波特率、清空读缓冲队列和写缓冲队列。

当用户修改终端参数，将规范模式标志复位，则就会把终端设置为工作在原始模式，此时行规则程序会把用户键入的数据原封不动地传送给用户，而回车符也被当作普通字符处理。因此，在用户使用系统调用 read 时，就应该作出某种决策方案以判断系统调用 read 什么时候算完成并返回。这将由终端 termios 结构中的 VTIME 和 VMIN 控制字符决定。这两个是读操作的超时定时值。VMIN 表示为了满足读操作，需要读取的最少字符数；VTIME 则是一个读操作等待定时值。

我们可以使用命令 stty 来查看当前终端设备 termios 结构中标志的设置情况。在 Linux 0.1x 系统命令行提示符下键入 stty 命令会显示以下信息：

```
[/root]# stty
---------Characters----------
INTR:   '^C'  QUIT:   '^\'  ERASE:  '^H'  KILL:   '^U'  EOF:    '^D'
TIME:    0    MIN:     1    SWTC:   '^@'  START:  '^Q'  STOP:   '^S'
SUSP:   '^Z'  EOL:    '^@'  EOL2:   '^@'  LNEXT:  '^V'
DISCARD:  '^O'  REPRINT:  '^R'  RWERASE:  '^W'
----------Control Flags---------
-CSTOPB  CREAD -PARENB -PARODD  HUPCL -CLOCAL -CRTSCTS
Baud rate: 9600 Bits: CS8
----------Input Flags----------
-IGNBRK -BRKINT -IGNPAR -PARMRK -INPCK -ISTRIP  -INLCR -IGNCR
 ICRNL  -IUCLC   IXON   -IXANY   IXOFF -IMAXBEL
---------Output Flags---------
 OPOST -OLCUC  ONLCR -OCRNL -ONOCR -ONLRET -OFILL -OFDEL
Delay modes: CR0 NL0 TAB0 BS0 FF0 VT0
-----------Local Flags---------
 ISIG  ICANON -XCASE  ECHO -ECHOE -ECHOK -ECHONL -NOFLSH
-TOSTOP  ECHOCTL  ECHOPRT  ECHOKE -FLUSHO -PENDIN -IEXTEN
rows 0 cols 0
```

其中带有减号标志表示没有设置。另外对于现在的 Linux 系统，需要键入’stty -a’才能显示所有这些信息，并且显示格式有所区别。

终端程序所使用的上述主要数据结构和它们之间的关系可见图 7-2 所示。

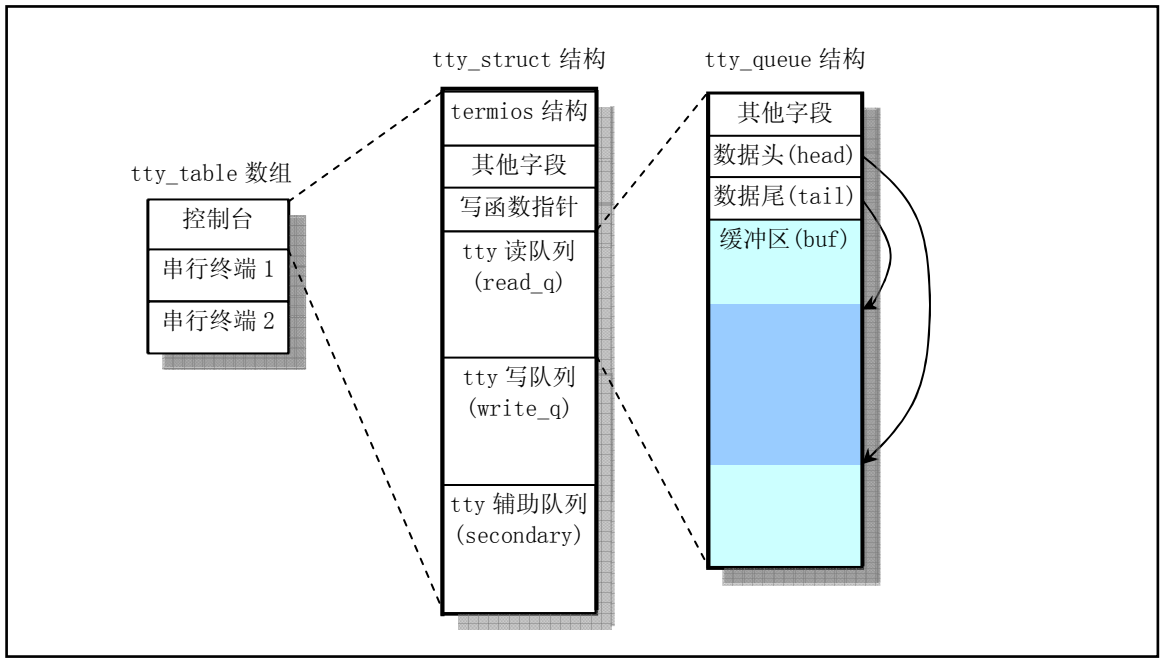

图 7-2 终端程序的数据结构

7.2.3 规范模式和非规范模式

7.2.3.1 规范模式

当 c_lflag 中的 ICANON 标志置位时，则按照规范模式对终端输入数据进行处理。此时输入字符被装配成行，进程以字符行的形式读取。当一行字符输入后，终端驱动程序会立刻返回。行的定界符有 NL、EOL、EOL2 和 EOF。其中除最后一个 EOF（文件结束）将被处理程序删除外，其余四个字符将被作为一行的最后一个字符返回给调用程序。

在规范模式下，终端输入的以下字符将被处理：ERASE、KILL、EOF、EOL、REPRINT、WERASE 和 EOL2。

ERASE 是搽除字符（Backspace）。在规范模式下，当 copy_to_cooked()函数遇该输入字符时会删除缓冲队列中最后输入的一个字符。若队列中最后一个字符是上一行的字符（例如是 NL），则不作任何处理。此后该字符被忽略，不放到缓冲队列中。

KILL 是删行字符。它删除队列中最后一行字符。此后该字符被忽略掉。

EOF 是文件结束符。在 copy_to_cooked()函数中该字符以及行结束字符 EOL 和 EOL2 都将被当作回车符来处理。在读操作函数中遇到该字符将立即返回。EOF 字符不会放入队列中而是被忽略掉。

REPRINT 和 WERASE 是扩展规范模式下识别的字符。REPRINT 会让所有未读的输入被输出。而 WERASE 用于搽除单词（跳过空白字符）。在 Linux 0.11 中，程序忽略了对这两个字符的识别和处理。

7.2.3.2 非规范模式

如果 ICANON 处于复位状态，则终端程序工作在非规范模式下。此时终端程序不对上述字符进行处理，而是将它们当作普通字符处理。输入数据也没有行的概念。终端程序何时返回读进程是由 MIN 和 TIME 的值确定。这两个变量是 c_cc[]数组中的变量。通过修改它们即可改变在非规范模式下进程读字符的处理方式。

MIN 指明读操作最少需要读取的字符数；TIME 指定等待读取字符的超时值（计量单位是 1/10 秒）。根据它们的值可分四种情况来说明。

1. MIN>0，TIME>0

此时 TIME 是一个字符间隔超时定时值，在接收到第一个字符后才起作用。在超时之前，若先

接收到了 MIN 个字符，则读操作立刻返回。若在收到 MIN 个字符之前超时了，则读操作返回已经接收到的字符数。此时起码能返回一个字符。因此在接收到一个字符之前若 secondary 空，则读进程将被阻塞（睡眠）。

2. MIN>0，TIME=0

   此时只有在收到 MIN 个字符时读操作才返回。否则就无限期等待（阻塞）。

3. MIN=0，TIME>0

   此时 TIME 是一个读操作超时定时值。当收到一个字符或者已超时，则读操作就立刻返回。如果是超时返回，则读操作返回 0 个字符。

4. MIN=0，TIME=0

   在这种设置下，如果队列中有数据可以读取，则读操作读取需要的字符数。否则立刻返回 0 个字符数。

在以上四中情况中，MIN 仅表明最少读到的字符数。如果进程要求读取比 MIN 要多的字符，那么只要队列中有就可能满足进程的当前需求。有关对终端设备的读操作处理，请参见程序 tty_io.c 中的 tty_read()函数。

7.2.4 控制台驱动程序

在 Linux 0.11 内核中，终端控制台驱动程序涉及 keyboard.S 和 console.c 程序。keyboard.S 用于处理用户键入的字符，把它们放入读缓冲队列 read_q 中，并调用 copy_to_cooked()函数读取 read_q 中的字符，经转换后放入辅助缓冲队列 secondary。console.c 程序实现控制台终端的输出处理。

例如，当用户在键盘上键入了一个字符时，会引起键盘中断响应（中断请求信号 IRQ1,对应中断号 INT 33），此时键盘中断处理程序就会从键盘控制器读入对应的键盘扫描码，然后根据使用的键盘扫描码映射表译成相应字符，放入 tty 读队列 read_q 中。然后调用中断处理程序的 C 函数 do_tty_interrupt()，它又直接调用行规则函数 copy_to_cooked()对该字符进行过滤处理，并放入 tty 辅助队列 secondary 中，同时把该字符放入 tty 写队列 write_q 中，并调用写控制台函数 con_write()。此时如果该终端的回显（echo）属性是设置的，则该字符会显示到屏幕上。do_tty_interrupt()和 copy_to_cooked()函数在 tty_io.c 中实现。整个操作过程见图 7-3 所示。

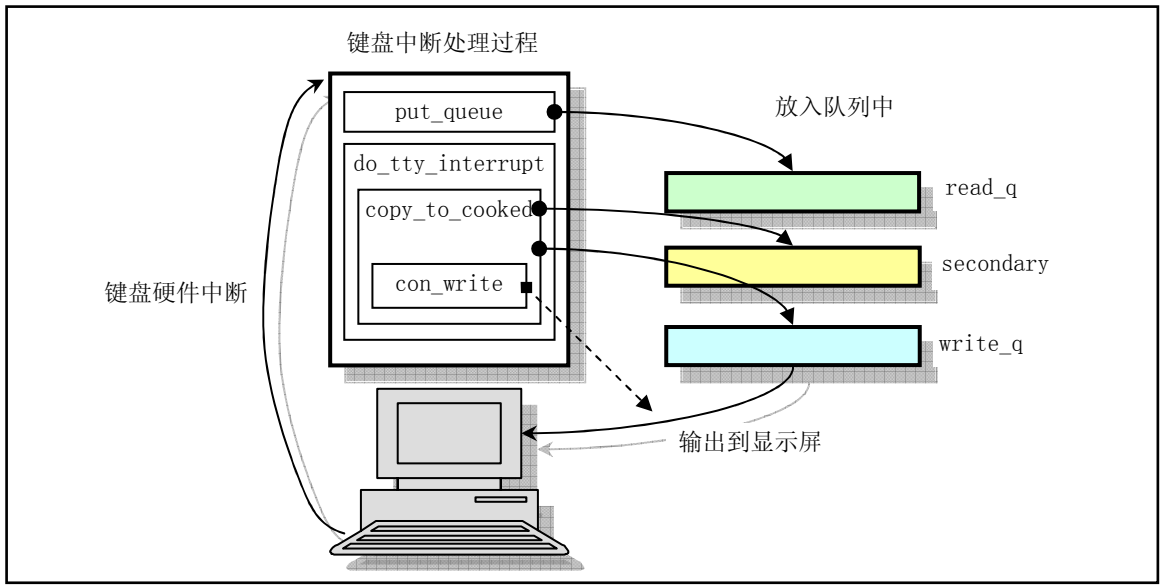

图 7-3 控制台键盘中断处理过程

对于进程执行 tty 写操作，终端驱动程序是一个字符一个字符进行处理的。在写缓冲队列 write_q 没有满时，就从用户缓冲区取一个字符，经过处理放入 write_q 中。当把用户数据全部放入 write_q 队列或者此时 write_q 已满，就调用终端结构 tty_struct 中指定的写函数，把 write_q 缓冲队列中的数据输出到控制台。对于控制台终端，其写函数是 con_write()，在 console.c 程序中实现。

有关控制台终端操作的驱动程序，主要涉及两个程序。一个是键盘中断处理程序 keyboard.S，主要用于把用户键入的字符并放入 read_q 缓冲队列中；另一个是屏幕显示处理程序 console.c，用于从 write_q 队列中取出字符并显示在屏幕上。所有这三个字符缓冲队列与上述函数或文件的关系都可以用图 7-4 清晰地表示出来。

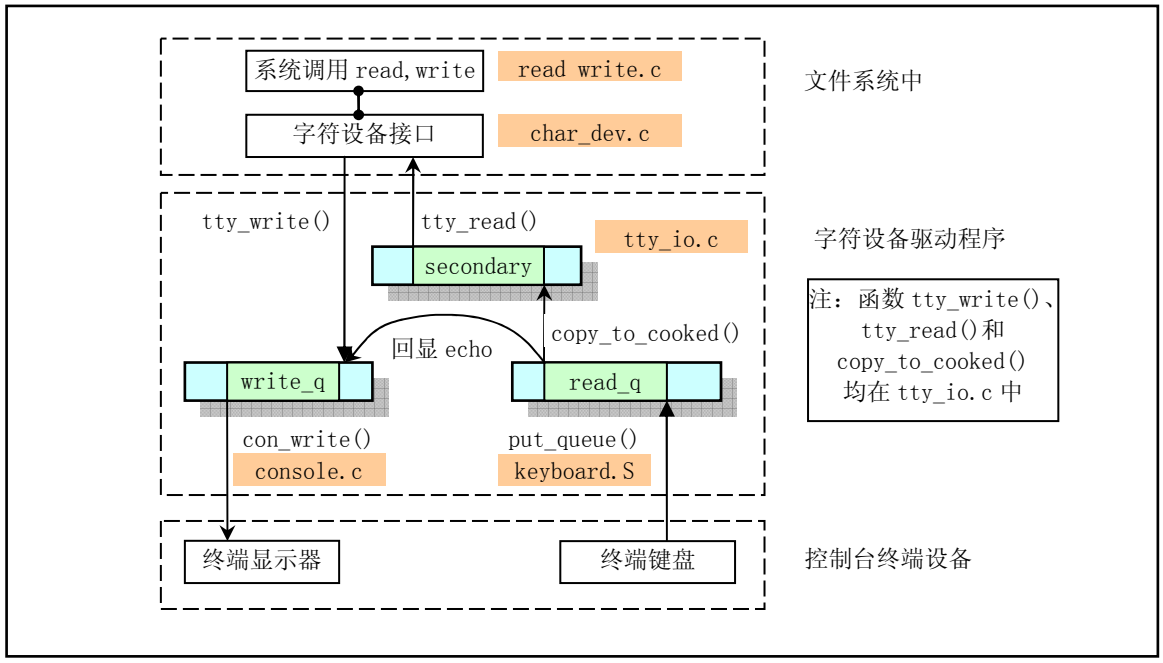

图 7-4 控制台终端字符缓冲队列以及函数和程序之间的关系

7.2.5 串行终端驱动程序

处理串行终端操作的程序有 serial.c 和 rs_io.s。serial.c 程序负责对串行端口进行初始化操作。另外，通过取消对发送保持寄存器空中断允许的屏蔽来开启串行中断发送字符操作。rs_io.s 程序是串行中断处理过程。主要根据引发中断的 4 种原因分别进行处理。

引起系统发生串行中断的情况有：a. 由于 modem 状态发生了变化；b. 由于线路状态发生了变化；c. 由于接收到字符；d. 由于在中断允许标志寄存器中设置了发送保持寄存器中断允许标志，需要发送字符。对引起中断的前两种情况的处理过程是通过读取对应状态寄存器值，从而使其复位。对于由于接收到字符的情况，程序首先把该字符放入读缓冲队列 read_q 中，然后调用 copy_to_cooked()函数转换成以字符行为单位的规范模式字符放入辅助队列 secondary 中。对于需要发送字符的情况，则程序首先从写缓冲队列 write_q 尾指针处中取出一个字符发送出去，再判断写缓冲队列是否已空，若还有字符则循环执行发送操作。

对于通过系统串行端口接入的终端，除了需要与控制台类似的处理外，还需要进行串行通信的输入/输出处理操作。数据的读入是由串行中断处理程序放入读队列 read_q 中，随后执行与控制台终端一样的操作。

例如，对于一个接在串行端口 1 上的终端，键入的字符将首先通过串行线路传送到主机，引起主机串行口 1 中断请求。此时串行口中断处理程序就会将字符放入串行终端 1 的 tty 读队列 read_q 中，然后

调用中断处理程序的 C 函数 do_tty_interrupt()，它又直接调用行规则函数 copy_to_cooked()对该字符进行过滤处理，并放入 tty 辅助队列 secondary 中，同时把该字符放入 tty 写队列 write_q 中，并调用写串行终端 1 的函数 rs_write()。该函数又会把字符回送给串行终端，此时如果该终端的回显（echo）属性是设置的，则该字符会显示在串行终端的屏幕上。

当进程需要写数据到一个串行终端上时，操作过程与写终端类似，只是此时终端的 tty_struct 数据结构中的写函数是串行终端写函数 rs_write()。该函数取消对发送保持寄存器空允许中断的屏蔽，从而在发送保持寄存器为空时就会引起串行中断发生。而该串行中断过程则根据此次引起中断的原因，从 write_q 写缓冲队列中取出一个字符并放入发送保持寄存器中进行字符发送操作。该操作过程也是一次中断发送一个字符，到最后 write_q 为空时就会再次屏蔽发送保持寄存器空允许中断位，从而禁止此类中断发生。

串行终端的写函数 rs_write()在 serial.c 程序中实现。串行中断程序在 rs_io.s 中实现。串行终端三个字符缓冲队列与函数、程序的关系参见图 7-5 所示。

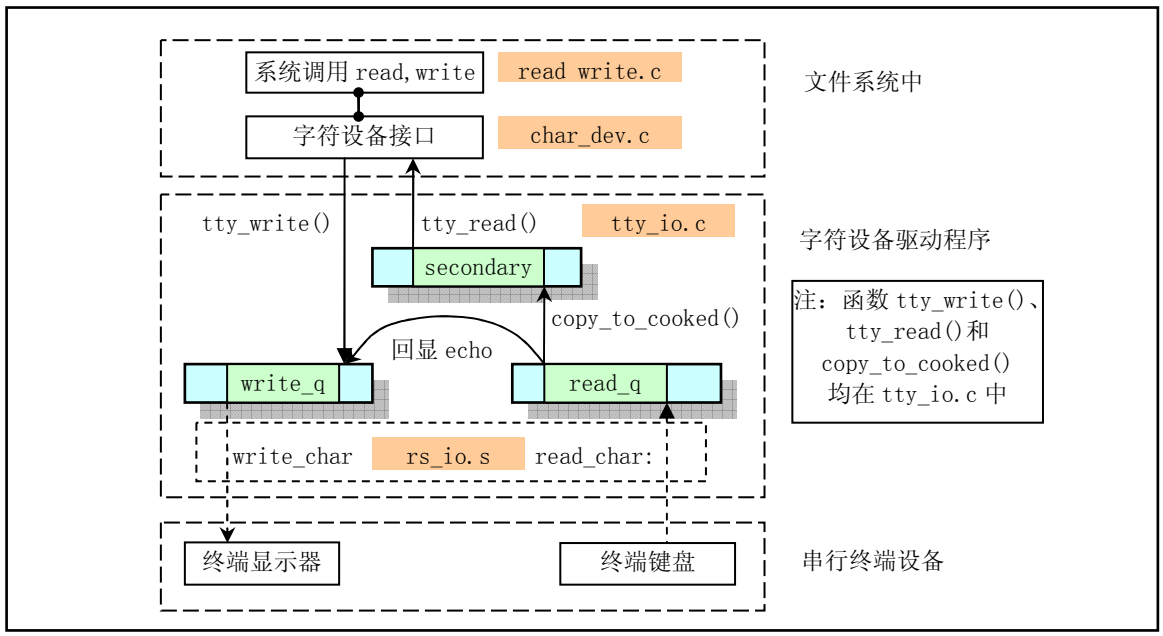

图 7-5 串行终端设备字符缓冲队列与函数之间的关系

由上图可见，串行终端与控制台处理过程之间的主要区别是串行终端利用程序 rs_io.s 取代了控制台操作显示器和键盘的程序 console.c 和 keyboard.S，其余部分的处理过程完全一样。

7.2.6 终端驱动程序接口

通常，用户是通过文件系统与设备打交道的，每个设备都有一个文件名称，相应地也在文件系统中占用一个索引节点（i 节点），但该 i 节点中的文件类型是设备类型，以便与其他正规文件相区别。用户就可以直接使用文件系统调用来访问设备。终端驱动程序也同样为此目的向文件系统提供了调用接口函数。终端驱动程序与系统其他程序的接口是使用 tty_io.c 文件中的通用函数实现的。其中实现了读终端函数 tty_read()和写终端函数 tty_write()，以及输入行规则函数 copy_to_cooked()。另外，在 tty_ioctl.c 程序中，实现了修改终端参数的输入输出控制函数（或系统调用）tty_ioctl()。终端的设置参数是放在终端数据结构中的 termios 结构中，其中的参数比较多，也比较复杂，请参考 include/termios.h 文件中的说明。

对于不同终端设备，可以有不同的行规则程序与之匹配。但在 Linux 0.11 中仅有一个行规则函数，因此 termios 结构中的行规则字段'c_line'不起作用，都被设置为 0。

7.3 Makefile 文件

7.3.1 功能描述

字符设备驱动程序的编译管理程序。由 Make 工具软件使用。

7.3.2 代码注释

程序 7-1 linux/kernel/chr_drv/Makefile

```
 1 #
 2 # Makefile for the FREAX-kernel character device drivers.
 3 #
 4 # Note! Dependencies are done automagically by 'make dep', which also
 5 # removes any old dependencies. DON'T put your own dependencies here
 6 # unless it's something special (ie not a .c file).
 7 #
   # FREAX(Linux)内核字符设备驱动程序的 Makefile 文件。
   # 注意！依赖关系是由'make dep'自动进行的，它也会自动去除原来的依赖信息。不要把你自己的
   # 依赖关系信息放在这里，除非是特别文件的（也即不是一个.c 文件的信息）。
 8
 9 AR      =gar    # GNU 的二进制文件处理程序，用于创建、修改以及从归档文件中抽取文件。
10 AS      =gas    # GNU 的汇编程序。
11 LD      =gld    # GNU 的连接程序。
12 LDFLAGS =-s -x  # 连接程序所有的参数，-s 输出文件中省略所有符号信息。-x 删除所有局部符号。
13 CC      =gcc    # GNU C 语言编译器。
   # 下一行是 C 编译程序选项。-Wall 显示所有的警告信息；-O 优化选项，优化代码长度和执行时间；
   # -fstrength-reduce 优化循环执行代码，排除重复变量；-fomit-frame-pointer 省略保存不必要
   # 的框架指针；-fcombine-regs 合并寄存器，减少寄存器类的使用；-finline-functions 将所有简
   # 单短小的函数代码嵌入调用程序中；-mstring-insns Linus 自己填加的优化选项，以后不再使用；
   # -nostdinc -I../include 不使用默认路径中的包含文件，而使用指定目录中的(../../include)。
14 CFLAGS  =-Wall -O -fstrength-reduce -fomit-frame-pointer -fcombine-regs \
15         -finline-functions -mstring-insns -nostdinc -I../../include
   # C 前处理选项。-E 只运行 C 前处理，对所有指定的 C 程序进行预处理并将处理结果输出到标准输
   # 出设备或指定的输出文件中；-nostdinc -I../../include 同前。
16 CPP     =gcc -E -nostdinc -I../../include
17
   # 下面的规则指示 make 利用下面的命令将所有的.c 文件编译生成.s 汇编程序。该规则的命令
   # 指使 gcc 采用 CFLAGS 所指定的选项对 C 代码编译后不进行汇编就停止（-S），从而产生与
   # 输入的各个 C 文件对应的汇编代码文件。默认情况下所产生的汇编程序文件名是原 C 文件名
   # 去掉.c 而加上.s 后缀。-o 表示其后是输出文件的名称。其中$*.s（或$@）是自动目标变量，
   # $<代表第一个先决条件，这里即是符合条件*.c 的文件。
18 .c.s:
19         $(CC) $(CFLAGS) \
20         -S -o $*.s $<
  # 下面规则表示将所有.s 汇编程序文件编译成.o 目标文件。22 行是实现该操作的具体命令。
21 .s.o:
22         $(AS) -c -o $*.o $<
23 .c.o:                      # 类似上面，*.c 文件-→*.o 目标文件。不进行连接。
24         $(CC) $(CFLAGS) \
25         -c -o $*.o $<
26
```

```
27 OBJS  = tty_io.o console.o keyboard.o serial.o rs_io.o \    # 定义目标文件变量 OBJS。
28         tty_ioctl.o
29
30 chr_drv.a: $(OBJS)          # 在有了先决条件 OBJS 后使用下面的命令连接成目标 chr_drv.a 库文件。
31         $(AR) rcs chr_drv.a $(OBJS)
32         sync
33
   # 对 kerboard.S 汇编程序进行预处理。-traditional 选项用来对程序作修改使其支持传统的 C 编译器。
   # 处理后的程序改名为 kernboard.s。
34 keyboard.s: keyboard.S ../../include/linux/config.h
35         $(CPP) -traditional keyboard.S -o keyboard.s
36
    # 下面的规则用于清理工作。当执行'make clean'时，就会执行下面的命令，去除所有编译
    # 连接生成的文件。'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
37 clean:
38         rm -f core *.o *.a tmp_make keyboard.s
39         for i in *.c;do rm -f `basename $$i .c`.s;done
40
    # 下面得目标或规则用于检查各文件之间的依赖关系。方法如下：
    # 使用字符串编辑程序 sed 对 Makefile 文件（即是本文件）进行处理，输出为删除 Makefile
    # 文件中'### Dependencies'行后面的所有行（下面从 48 开始的行），并生成 tmp_make
    # 临时文件（44 行的作用）。然后对 kernel/chr_drv/目录下的每个 C 文件执行 gcc 预处理操作.
    # -M 标志告诉预处理程序输出描述每个目标文件相关性的规则，并且这些规则符合 make 语法。
    # 对于每一个源文件，预处理程序输出一个 make 规则，其结果形式是相应源程序文件的目标
    # 文件名加上其依赖关系--该源文件中包含的所有头文件列表。把预处理结果都添加到临时
    # 文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。
41 dep:
42         sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
43         (for i in *.c;do echo -n `echo $$i | sed 's,\.c,\.s,'`" "; \
44                 $(CPP) -M $$i;done) >> tmp_make
45         cp tmp_make Makefile
46
47 ### Dependencies:
48 console.s console.o : console.c ../../include/linux/sched.h \
49   ../../include/linux/head.h ../../include/linux/fs.h \
50   ../../include/sys/types.h ../../include/linux/mm.h ../../include/signal.h \
51   ../../include/linux/tty.h ../../include/termios.h ../../include/asm/io.h \
52   ../../include/asm/system.h
53 serial.s serial.o : serial.c ../../include/linux/tty.h ../../include/termios.h \
54   ../../include/linux/sched.h ../../include/linux/head.h \
55   ../../include/linux/fs.h ../../include/sys/types.h ../../include/linux/mm.h \
56   ../../include/signal.h ../../include/asm/system.h ../../include/asm/io.h
57 tty_io.s tty_io.o : tty_io.c ../../include/ctype.h ../../include/errno.h \
58   ../../include/signal.h ../../include/sys/types.h \
59   ../../include/linux/sched.h ../../include/linux/head.h \
60   ../../include/linux/fs.h ../../include/linux/mm.h ../../include/linux/tty.h \
61   ../../include/termios.h ../../include/asm/segment.h \
62   ../../include/asm/system.h
63 tty_ioctl.s tty_ioctl.o : tty_ioctl.c ../../include/errno.h ../../include/termios.h \
64   ../../include/linux/sched.h ../../include/linux/head.h \
65   ../../include/linux/fs.h ../../include/sys/types.h ../../include/linux/mm.h \
66   ../../include/signal.h ../../include/linux/kernel.h \
67   ../../include/linux/tty.h ../../include/asm/io.h \
```

```
68   ../../include/asm/segment.h ../../include/asm/system.h
```

7.4 keyboard.s 程序

7.4.1 功能描述

该键盘驱动汇编程序主要包括键盘中断处理程序。在英文惯用法中，make 表示键被按下；break 表示键被松开(放开)。

该程序首先根据键盘特殊键（例如 Alt、Shift、Ctrl、Caps 键）的状态设置程序后面要用到的状态标志变量 mode 的值，然后根据引起键盘中断的按键扫描码，调用已经编排成跳转表的相应扫描码处理子程序，把扫描码对应的字符放入读字符队列(read_q)中。接下来调用 C 处理函数 do_tty_interrupt()(tty_io.c，342 行)，该函数仅包含一个对行规程函数 copy_to_cooked()的调用。这个行规程函数的主要作用就是把 read_q 读缓冲队列中的字符经过适当处理放入规范模式队列（辅助队列 secondary）中，并且在处理过程中，若相应终端设备设置了回显标志，还会把字符放入写队列（write_q）中，从而在终端屏幕上会显示出刚键入的字符。

对于 AT 键盘的扫描码，当键按下时，则对应键的扫描码被送出，但当键松开时，将会发送两个字节，第一个是 0xf0，第 2 个还是按下时的扫描码。为了向下的兼容性，设计人员将 AT 键盘发出的扫描码转换成了老式 PC/XT 标准键盘的扫描码。因此这里仅对 PC/XT 的扫描码进行处理即可。有关键盘扫描码的说明，请参见程序列表后的描述。

7.4.2 代码注释

程序 7-2 linux/kernel/chr_drv/keyboard.S

```
1  /*
2   *  linux/kernel/keyboard.S
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   *      Thanks to Alfred Leung for US keyboard patches
9   *              Wolfgang Thiel for German keyboard patches
10  *              Marc Corsini for the French keyboard
11  */
    /*
     * 感谢 Alfred Leung 添加了 US 键盘补丁程序；
     *     Wolfgang Thiel 添加了德语键盘补丁程序；
     *     Marc Corsini 添加了法文键盘补丁程序。
     */
12
13 #include <linux/config.h> // 内核配置头文件。定义键盘语言和硬盘类型（HD_TYPE）可选项。
14
15 .text
16 .globl _keyboard_interrupt
17
18 /*
```

```
19  * these are for the keyboard read functions
20  */
    /*
     * 以下这些是用于键盘读操作。
     */
    // size 是键盘缓冲区的长度（字节数）。
21  size    = 1024          /* must be a power of two ! And MUST be the same
22                             as in tty_io.c !!!! */
                            /* 数值必须是 2 的次方! 并且与 tty_io.c 中的值匹配!!!! */
    // 以下这些是缓冲队列结构中的偏移量 */
23  head = 4                // 缓冲区中头指针字段偏移。
24  tail = 8                // 缓冲区中尾指针字段偏移。
25  proc_list = 12          // 等待该缓冲队列的进程字段偏移。
26  buf = 16                // 缓冲区字段偏移。
27
    // mode 是键盘特殊键的按下状态标志。
    // 表示大小写转换键(caps)、交换键(alt)、控制键(ctrl)和换档键(shift)的状态。
    // 位 7 caps 键按下；
    // 位 6 caps 键的状态(应该与 leds 中的对应标志位一样)；
    // 位 5 右 alt 键按下；
    // 位 4 左 alt 键按下；
    // 位 3 右 ctrl 键按下；
    // 位 2 左 ctrl 键按下；
    // 位 1 右 shift 键按下；
    // 位 0 左 shift 键按下。
28  mode:   .byte 0         /* caps, alt, ctrl and shift mode */
    // 数字锁定键(num-lock)、大小写转换键(caps-lock)和滚动锁定键(scroll-lock)的 LED 发光管状态。
    // 位 7-3 全 0 不用；
    // 位 2 caps-lock；
    // 位 1 num-lock(初始置 1，也即设置数字锁定键(num-lock)发光管为亮)；
    // 位 0 scroll-lock。
29  leds:   .byte 2         /* num-lock, caps, scroll-lock mode (nom-lock on) */
    // 当扫描码是 0xe0 或 0xe1 时，置该标志。表示其后还跟随着 1 个或 2 个字符扫描码，参见列表后说明。
    // 位 1 =1 收到 0xe1 标志；
    // 位 0 =1 收到 0xe0 标志。
30  e0:     .byte 0
31
32  /*
33   *  con_int is the real interrupt routine that reads the
34   *  keyboard scan-code and converts it into the appropriate
35   *  ascii character(s).
36   */
    /*
     * con_int 是实际的中断处理子程序，用于读键盘扫描码并将其转换
     * 成相应的 ascii 字符。
     */
    //// 键盘中断处理程序入口点。
37  _keyboard_interrupt:
38          pushl %eax
39          pushl %ebx
40          pushl %ecx
41          pushl %edx
42          push %ds
```

```
43          push %es
44          movl $0x10,%eax          // 将 ds、es 段寄存器置为内核数据段。
45          mov %ax,%ds
46          mov %ax,%es
47          xorl %al,%al             /* %eax is scan code */  /* eax 中是扫描码 */
48          inb $0x60,%al            // 读取扫描码➔al。
49          cmpb $0xe0,%al           // 该扫描码是 0xe0 吗？如果是则跳转到设置 e0 标志代码处。
50          je set_e0
51          cmpb $0xe1,%al           // 扫描码是 0xe1 吗？如果是则跳转到设置 e1 标志代码处。
52          je set_e1
53          call key_table(,%eax,4) // 调用键处理程序 ker_table + eax * 4（参见下面 502 行）。
54          movb $0,e0               // 复位 e0 标志。
    // 下面这段代码(55-65 行)是针对使用 8255A 的 PC 标准键盘电路进行硬件复位处理。端口 0x61 是
    // 8255A 输出口 B 的地址，该输出端口的第 7 位(PB7)用于禁止和允许对键盘数据的处理。
    // 这段程序用于对收到的扫描码做出应答。方法是首先禁止键盘，然后立刻重新允许键盘工作。
55  e0_e1:  inb $0x61,%al            // 取 PPI 端口 B 状态，其位 7 用于允许/禁止(0/1)键盘。
56          jmp 1f                   // 延迟一会。
57  1:      jmp 1f
58  1:      orb $0x80,%al            // al 位 7 置位(禁止键盘工作)。
59          jmp 1f                   // 再延迟一会。
60  1:      jmp 1f
61  1:      outb %al,$0x61           // 使 PPI PB7 位置位。
62          jmp 1f                   // 延迟一会。
63  1:      jmp 1f
64  1:      andb $0x7F,%al           // al 位 7 复位。
65          outb %al,$0x61           // 使 PPI PB7 位复位（允许键盘工作）。
66          movb $0x20,%al           // 向 8259 中断芯片发送 EOI(中断结束)信号。
67          outb %al,$0x20
68          pushl $0                 // 控制台 tty 号=0，作为参数入栈。
69          call _do_tty_interrupt   // 将收到数据复制成规范模式数据并存放在规范字符缓冲队列中。
70          addl $4,%esp             // 丢弃入栈的参数，弹出保留的寄存器，并中断返回。
71          pop %es
72          pop %ds
73          popl %edx
74          popl %ecx
75          popl %ebx
76          popl %eax
77          iret
78  set_e0: movb $1,e0               // 收到扫描前导码 0xe0 时，设置 e0 标志（位 0）。
79          jmp e0_e1
80  set_e1: movb $2,e0               // 收到扫描前导码 0xe1 时，设置 e1 标志（位 1）。
81          jmp e0_e1
82
83  /*
84   * This routine fills the buffer with max 8 bytes, taken from
85   * %ebx:%eax. (%edx is high). The bytes are written in the
86   * order %al,%ah,%eal,%eah,%bl,%bh ... until %eax is zero.
87   */
    /*
     * 下面该子程序把 ebx:eax 中的最多 8 个字符添入缓冲队列中。(edx 是
     * 所写入字符的顺序是 al,ah,eal,eah,bl,bh...直到 eax 等于 0。
     */
88  put_queue:
```

```
89          pushl %ecx                  // 保存 ecx，edx 内容。
90          pushl %edx                  // 取控制台 tty 结构中读缓冲队列指针。
91          movl _table_list,%edx       # read-queue for console
92          movl head(%edx),%ecx        // 取缓冲队列中头指针➔ecx。
93 1:       movb %al,buf(%edx,%ecx)     // 将 al 中的字符放入缓冲队列头指针位置处。
94          incl %ecx                   // 头指针前移 1 字节。
95          andl $size-1,%ecx           // 以缓冲区大小调整头指针(若超出则返回缓冲区开始)。
96          cmpl tail(%edx),%ecx        # buffer full - discard everything
                                        // 头指针==尾指针吗(缓冲队列满)?
97          je 3f                       // 如果已满，则后面未放入的字符全抛弃。
98          shrdl $8,%ebx,%eax          // 将 ebx 中 8 位比特位右移 8 位到 eax 中，但 ebx 不变。
99          je 2f                       // 还有字符吗？若没有(等于 0)则跳转。
100         shrl $8,%ebx                // 将 ebx 中比特位右移 8 位，并跳转到标号 1 继续操作。
101         jmp 1b
102 2:      movl %ecx,head(%edx)        // 若已将所有字符都放入了队列，则保存头指针。
103         movl proc_list(%edx),%ecx   // 该队列的等待进程指针？
104         testl %ecx,%ecx             // 检测任务结构指针是否空(有等待该队列的进程吗？)。
105         je 3f                       // 无，则跳转；
106         movl $0,(%ecx)              // 有，则置该进程为可运行就绪状态(唤醒该进程)。
107 3:      popl %edx                   // 弹出保留的寄存器并返回。
108         popl %ecx
109         ret
110
    // 下面这段代码根据 ctrl 或 alt 的扫描码，分别设置模式标志中相应位。如果该扫描码之前收到过
    // 0xe0 扫描码(e0 标志置位)，则说明按下的是键盘右边的 ctrl 或 alt 键，则对应设置 ctrl 或 alt
    // 在模式标志 mode 中的比特位。
111 ctrl:   movb $0x04,%al              // 0x4 是模式标志 mode 中左 ctrl 键对应的比特位(位 2)。
112         jmp 1f
113 alt:    movb $0x10,%al              // 0x10 是模式标志 mode 中左 alt 键对应的比特位(位 4)。
114 1:      cmpb $0,e0                  // e0 标志置位了吗(按下的是右边的 ctrl 或 alt 键吗)?
115         je 2f                       // 不是则转。
116         addb %al,%al                // 是，则改成置相应右键的标志位(位 3 或位 5)。
117 2:      orb %al,mode                // 设置模式标志 mode 中对应的比特位。
118         ret
    // 这段代码处理 ctrl 或 alt 键松开的扫描码，对应复位模式标志 mode 中的比特位。在处理时要根据
    // e0 标志是否置位来判断是否是键盘右边的 ctrl 或 alt 键。
119 unctrl: movb $0x04,%al             // 模式标志 mode 中左 ctrl 键对应的比特位(位 2)。
120         jmp 1f
121 unalt:  movb $0x10,%al             // 0x10 是模式标志 mode 中左 alt 键对应的比特位(位 4)。
122 1:      cmpb $0,e0                  // e0 标志置位了吗(释放的是右边的 ctrl 或 alt 键吗)?
123         je 2f                       // 不是，则转。
124         addb %al,%al                // 是，则该成复位相应右键的标志位(位 3 或位 5)。
125 2:      notb %al                    // 复位模式标志 mode 中对应的比特位。
126         andb %al,mode
127         ret
128
129 lshift:
130         orb $0x01,mode              // 是左 shift 键按下，设置 mode 中对应的标志位(位 0)。
131         ret
132 unlshift:
133         andb $0xfe,mode             // 是左 shift 键松开，复位 mode 中对应的标志位(位 0)。
134         ret
135 rshift:
```

```
136         orb $0x02,mode                  // 是右 shift 键按下，设置 mode 中对应的标志位(位 1)。
137         ret
138 unrshift:
139         andb $0xfd,mode                 // 是右 shift 键松开，复位 mode 中对应的标志位(位 1)。
140         ret
141
142 caps:   testb $0x80,mode                // 测试模式标志 mode 中位 7 是否已经置位(按下状态)。
143         jne 1f                          // 如果已处于按下状态，则返回(ret)。
144         xorb $4,leds                    // 翻转 leds 标志中 caps-lock 比特位(位 2)。
145         xorb $0x40,mode                 // 翻转 mode 标志中 caps 键按下的比特位(位 6)。
146         orb $0x80,mode                  // 设置 mode 标志中 caps 键已按下标志位(位 7)。
    // 这段代码根据 leds 标志，开启或关闭 LED 指示器。
147 set_leds:
148         call kb_wait                    // 等待键盘控制器输入缓冲空。
149         movb $0xed,%al          /* set leds command */  /* 设置 LED 的命令 */
150         outb %al,$0x60                  // 发送键盘命令 0xed 到 0x60 端口。
151         call kb_wait                    // 等待键盘控制器输入缓冲空。
152         movb leds,%al                   // 取 leds 标志，作为参数。
153         outb %al,$0x60                  // 发送该参数。
154         ret
155 uncaps: andb $0x7f,mode                 // caps 键松开，则复位模式标志 mode 中的对应位(位 7)。
156         ret
157 scroll:
158         xorb $1,leds                    // scroll 键按下，则翻转 leds 标志中的对应位(位 0)。
159         jmp set_leds                    // 根据 leds 标志重新开启或关闭 LED 指示器。
160 num:    xorb $2,leds                    // num 键按下，则翻转 leds 标志中的对应位(位 1)。
161         jmp set_leds                    // 根据 leds 标志重新开启或关闭 LED 指示器。
162
163 /*
164  *  curosr-key/numeric keypad cursor keys are handled here.
165  *  checking for numeric keypad etc.
166  */
    /*
     * 这里处理方向键/数字小键盘方向键，检测数字小键盘等。
     */
167 cursor:
168         subb $0x47,%al          // 扫描码是小数字键盘上的键(其扫描码>=0x47)发出的？
169         jb 1f                   // 如果小于则不处理，返回。
170         cmpb $12,%al            // 如果扫描码 > 0x53(0x53 - 0x47= 12)，则
171         ja 1f                   // 扫描码值超过 83(0x53)，不处理，返回。
172         jne cur2                /* check for ctrl-alt-del */ /* 检查是否 ctrl-alt-del */
                                    // 如果等于 12，则说明 del 键已被按下，则继续判断 ctrl
                                    // 和 alt 是否也同时按下。
173         testb $0x0c,mode        // 有 ctrl 键按下吗？
174         je cur2                 // 无，则跳转。
175         testb $0x30,mode        // 有 alt 键按下吗？
176         jne reboot              // 有，则跳转到重启动处理。
177 cur2:   cmpb $0x01,e0           /* e0 forces cursor movement */ /* e0 置位表示光标移动 */
                                    // e0 标志置位了吗？
178         je cur                  // 置位了，则跳转光标移动处理处 cur。
179         testb $0x02,leds        /* not num-lock forces cursor */ /* num-lock 键则不许 */
                                    // 测试 leds 中标志 num-lock 键标志是否置位。
180         je cur                  // 如果没有置位(num 的 LED 不亮)，则也进行光标移动处理。
```

```
181         testb $0x03,mode        /* shift forces cursor */ /* shift 键也使光标移动 */
                                    // 测试模式标志 mode 中 shift 按下标志。
182         jne cur                 // 如果有 shift 键按下，则也进行光标移动处理。
183         xorl %ebx,%ebx          // 否则查询扫数字表(199 行)，取对应键的数字 ASCII 码。
184         movb num_table(%eax),%al    // 以 eax 作为索引值，取对应数字字符➔al。
185         jmp put_queue           // 将该字符放入缓冲队列中。由于要放入队列的字符数<=4，因此
186 1:      ret                     // 在执行 put_queue 之前需把 ebx 清零，参见 87 行上的注释。
187
    // 这段代码处理光标的移动。
188 cur:    movb cur_table(%eax),%al  // 取光标字符表中相应键的代表字符➔al。
189         cmpb $'9,%al              // 若该字符<='9'，说明是上一页、下一页、插入或删除键，
190         ja ok_cur                 // 则功能字符序列中要添入字符'~'。
191         movb $'~,%ah
192 ok_cur: shll $16,%eax             // 将 ax 中内容移到 eax 高字中。
193         movw $0x5b1b,%ax          // 在 ax 中放入'esc ['字符，与 eax 高字中字符组成移动序列。
194         xorl %ebx,%ebx            // 由于放入队列字符数<=4，因此需要把 ebx 清零。
195         jmp put_queue             // 将该字符放入缓冲队列中。
196
197 #if defined(KBD_FR)
198 num_table:
199         .ascii "789 456 1230."    // 数字小键盘上键对应的数字 ASCII 码表。
200 #else
201 num_table:
202         .ascii "789 456 1230,"
203 #endif
204 cur_table:
205         .ascii "HA5 DGC YB623"    // 数字小键盘上方向键或插入删除键对应的移动表示字符表。
206
207 /*
208  * this routine handles function keys
209  */
    // 下面子程序处理功能键。
210 func:
211         pushl %eax
212         pushl %ecx
213         pushl %edx
214         call _show_stat         // 调用显示各任务状态函数(kernl/sched.c, 37)。
215         popl %edx
216         popl %ecx
217         popl %eax
218         subb $0x3B,%al          // 功能键'F1'的扫描码是 0x3B，因此此时 al 中是功能键索引号。
219         jb end_func             // 如果扫描码小于 0x3b，则不处理，返回。
220         cmpb $9,%al             // 功能键是 F1-F10?
221         jbe ok_func             // 是，则跳转。
222         subb $18,%al            // 是功能键 F11，F12 吗?
223         cmpb $10,%al            // 是功能键 F11?
224         jb end_func             // 不是，则不处理，返回。
225         cmpb $11,%al            // 是功能键 F12?
226         ja end_func             // 不是，则不处理，返回。
227 ok_func:
228         cmpl $4,%ecx            /* check that there is enough room */ /*检查空间*/ [??ecx]
229         jl end_func             // 需要放入 4 个字符序列，如果放不下，则返回。
230         movl func_table(,%eax,4),%eax  // 取功能键对应字符序列。
```

```
231         xorl %ebx,%ebx          // 由于放入队列字符数<=4，因此执行 put_queue 之前需把 ebx 清零。
232         jmp put_queue           // 放入缓冲队列中。
233 end_func:
234         ret
235
236 /*
237  * function keys send F1:'esc [ [ A' F2:'esc [ [ B' etc.
238  */
    /*
     * 功能键发送的扫描码，F1 键为：'esc [ [ A'， F2 键为：'esc [ [ B'等。
     */
239 func_table:
240         .long 0x415b5b1b,0x425b5b1b,0x435b5b1b,0x445b5b1b
241         .long 0x455b5b1b,0x465b5b1b,0x475b5b1b,0x485b5b1b
242         .long 0x495b5b1b,0x4a5b5b1b,0x4b5b5b1b,0x4c5b5b1b
243
    // 扫描码-ASCII 字符映射表。
    // 根据在 config.h 中定义的键盘类型(FINNISH，US，GERMEN，FRANCH)，将相应键的扫描码映射
    // 到 ASCII 字符。
244 #if     defined(KBD_FINNISH)
    // 以下是芬兰语键盘的扫描码映射表。
245 key_map:
246         .byte 0,27              // 扫描码 0x00,0x01 对应的 ASCII 码；
247         .ascii "1234567890+'"   // 扫描码 0x02,...0x0c,0x0d 对应的 ASCII 码，以下类似。
248         .byte 127,9
249         .ascii "qwertyuiop}"
250         .byte 0,13,0
251         .ascii "asdfghjkl|{"
252         .byte 0,0
253         .ascii "'zxcvbnm,.-"
254         .byte 0,'*,0,32         /* 36-39 */   /* 扫描码 0x36-0x39 对应的 ASCII 码 */
255         .fill 16,1,0            /* 3A-49 */   /* 扫描码 0x3A-0x49 对应的 ASCII 码 */
256         .byte '-,0,0,0,'+       /* 4A-4E */   /* 扫描码 0x4A-0x4E 对应的 ASCII 码 */
257         .byte 0,0,0,0,0,0,0     /* 4F-55 */   /* 扫描码 0x4F-0x55 对应的 ASCII 码 */
258         .byte '<
259         .fill 10,1,0
260
    // shift 键同时按下时的映射表。
261 shift_map:
262         .byte 0,27
263         .ascii "!\"#$%&/()=?`"
264         .byte 127,9
265         .ascii "QWERTYUIOP]^"
266         .byte 13,0
267         .ascii "ASDFGHJKL\\["
268         .byte 0,0
269         .ascii "*ZXCVBNM;:_"
270         .byte 0,'*,0,32         /* 36-39 */
271         .fill 16,1,0            /* 3A-49 */
272         .byte '-,0,0,0,'+       /* 4A-4E */
273         .byte 0,0,0,0,0,0,0     /* 4F-55 */
274         .byte '>
275         .fill 10,1,0
```

```
276
    // alt 键同时按下时的映射表。
277 alt_map:
278         .byte 0,0
279         .ascii "\0@\0$\0\0{[]}\\\0"
280         .byte 0,0
281         .byte 0,0,0,0,0,0,0,0,0,0,0
282         .byte '~,13,0
283         .byte 0,0,0,0,0,0,0,0,0,0,0
284         .byte 0,0
285         .byte 0,0,0,0,0,0,0,0,0,0,0
286         .byte 0,0,0,0           /* 36-39 */
287         .fill 16,1,0            /* 3A-49 */
288         .byte 0,0,0,0,0         /* 4A-4E */
289         .byte 0,0,0,0,0,0,0     /* 4F-55 */
290         .byte '|
291         .fill 10,1,0
292
293 #elif defined(KBD_US)
294
    // 以下是美式键盘的扫描码映射表。
295 key_map:
296         .byte 0,27
297         .ascii "1234567890-="
298         .byte 127,9
299         .ascii "qwertyuiop[]"
300         .byte 13,0
301         .ascii "asdfghjkl;'"
302         .byte '`,0
303         .ascii "\\zxcvbnm,./"
304         .byte 0,'*,0,32         /* 36-39 */
305         .fill 16,1,0            /* 3A-49 */
306         .byte '-,0,0,0,'+       /* 4A-4E */
307         .byte 0,0,0,0,0,0,0     /* 4F-55 */
308         .byte '<
309         .fill 10,1,0
310
311
312 shift_map:
313         .byte 0,27
314         .ascii "!@#$%^&*()_+"
315         .byte 127,9
316         .ascii "QWERTYUIOP{}"
317         .byte 13,0
318         .ascii "ASDFGHJKL:\""
319         .byte '~,0
320         .ascii "|ZXCVBNM<>?"
321         .byte 0,'*,0,32         /* 36-39 */
322         .fill 16,1,0            /* 3A-49 */
323         .byte '-,0,0,0,'+       /* 4A-4E */
324         .byte 0,0,0,0,0,0,0     /* 4F-55 */
325         .byte '>
326         .fill 10,1,0
```

```
327
328 alt_map:
329         .byte 0,0
330         .ascii "\0@\0$\0\0{[]}\\\0"
331         .byte 0,0
332         .byte 0,0,0,0,0,0,0,0,0,0
333         .byte '~,13,0
334         .byte 0,0,0,0,0,0,0,0,0,0
335         .byte 0,0
336         .byte 0,0,0,0,0,0,0,0,0,0
337         .byte 0,0,0,0           /* 36-39 */
338         .fill 16,1,0            /* 3A-49 */
339         .byte 0,0,0,0,0         /* 4A-4E */
340         .byte 0,0,0,0,0,0,0     /* 4F-55 */
341         .byte '|
342         .fill 10,1,0
343
344 #elif defined(KBD_GR)
345
    // 以下是德语键盘的扫描码映射表。
346 key_map:
347         .byte 0,27
348         .ascii "1234567890\\'"
349         .byte 127,9
350         .ascii "qwertzuiop@+"
351         .byte 13,0
352         .ascii "asdfghjkl[]^"
353         .byte 0,'#
354         .ascii "yxcvbnm,.-"
355         .byte 0,'*,0,32         /* 36-39 */
356         .fill 16,1,0            /* 3A-49 */
357         .byte '-,0,0,0,'+       /* 4A-4E */
358         .byte 0,0,0,0,0,0,0     /* 4F-55 */
359         .byte '<
360         .fill 10,1,0
361
362
363 shift_map:
364         .byte 0,27
365         .ascii "!\"#$%&/()=?`"
366         .byte 127,9
367         .ascii "QWERTZUIOP\\*"
368         .byte 13,0
369         .ascii "ASDFGHJKL{}~"
370         .byte 0,''
371         .ascii "YXCVBNM;:_"
372         .byte 0,'*,0,32         /* 36-39 */
373         .fill 16,1,0            /* 3A-49 */
374         .byte '-,0,0,0,'+       /* 4A-4E */
375         .byte 0,0,0,0,0,0,0     /* 4F-55 */
376         .byte '>
377         .fill 10,1,0
378
```

```
379 alt_map:
380         .byte 0,0
381         .ascii "\0@\0$\0\0{[]}\\\0"
382         .byte 0,0
383         .byte '@,0,0,0,0,0,0,0,0,0,0
384         .byte '~,13,0
385         .byte 0,0,0,0,0,0,0,0,0,0,0
386         .byte 0,0
387         .byte 0,0,0,0,0,0,0,0,0,0,0
388         .byte 0,0,0,0           /* 36-39 */
389         .fill 16,1,0            /* 3A-49 */
390         .byte 0,0,0,0,0         /* 4A-4E */
391         .byte 0,0,0,0,0,0,0     /* 4F-55 */
392         .byte '|
393         .fill 10,1,0
394
395
396 #elif defined(KBD_FR)
397
    // 以下是法语键盘的扫描码映射表。
398 key_map:
399         .byte 0,27
400         .ascii "&{\"'(-}_/@)="
401         .byte 127,9
402         .ascii "azertyuiop^$"
403         .byte 13,0
404         .ascii "qsdfghjklm|"
405         .byte '`,0,42           /* coin sup gauche, don't know, [*|mu] */
406         .ascii "wxcvbn,;:!"
407         .byte 0,'*,0,32         /* 36-39 */
408         .fill 16,1,0            /* 3A-49 */
409         .byte '-,0,0,0,'+       /* 4A-4E */
410         .byte 0,0,0,0,0,0,0     /* 4F-55 */
411         .byte '<
412         .fill 10,1,0
413
414 shift_map:
415         .byte 0,27
416         .ascii "1234567890]+"
417         .byte 127,9
418         .ascii "AZERTYUIOP<>"
419         .byte 13,0
420         .ascii "QSDFGHJKLM%"
421         .byte '~,0,'#
422         .ascii "WXCVBN?./\\"
423         .byte 0,'*,0,32         /* 36-39 */
424         .fill 16,1,0            /* 3A-49 */
425         .byte '-,0,0,0,'+       /* 4A-4E */
426         .byte 0,0,0,0,0,0,0     /* 4F-55 */
427         .byte '>
428         .fill 10,1,0
429
430 alt_map:
```

```
431         .byte 0,0
432         .ascii "\0~#{[|`\\^@]}"
433         .byte 0,0
434         .byte '@,0,0,0,0,0,0,0,0,0,0
435         .byte '~,13,0
436         .byte 0,0,0,0,0,0,0,0,0,0,0
437         .byte 0,0
438         .byte 0,0,0,0,0,0,0,0,0,0,0
439         .byte 0,0,0,0           /* 36-39 */
440         .fill 16,1,0            /* 3A-49 */
441         .byte 0,0,0,0,0         /* 4A-4E */
442         .byte 0,0,0,0,0,0,0     /* 4F-55 */
443         .byte '|
444         .fill 10,1,0
445
446 #else
447 #error "KBD-type not defined"
448 #endif
449 /*
450  * do_self handles "normal" keys, ie keys that don't change meaning
451  * and which have just one character returns.
452  */
    /*
     * do_self 用于处理“普通”键，也即含义没有变化并且只有一个字符返回的键。
     */
453 do_self:
    // 454-460 行用于根据模式标志 mode 选择 alt_map、shift_map 或 key_map 映射表之一。
454         lea alt_map,%ebx                // alt 键同时按下时的映射表基址 alt_map➔ebx。
455         testb $0x20,mode                /* alt-gr */  /* 右 alt 键同时按下了？ */
456         jne 1f                          // 是，则向前跳转到标号 1 处。
457         lea shift_map,%ebx              // shift 键同时按下时的映射表基址 shift_map➔ebx。
458         testb $0x03,mode                // 有 shift 键同时按下了吗？
459         jne 1f                          // 有，则向前跳转到标号 1 处。
460         lea key_map,%ebx                // 否则使用普通映射表 key_map。
    // 取映射表中对应扫描码的 ASCII 字符，若没有对应字符，则返回(转 none)。
461 1:      movb (%ebx,%eax),%al            // 将扫描码作为索引值，取对应的 ASCII 码➔al。
462         orb %al,%al                     // 检测看是否有对应的 ASCII 码。
463         je none                         // 若没有(对应的 ASCII 码=0)，则返回。
    // 若 ctrl 键已按下或 caps 键锁定，并且字符在'a'-'}'(0x61-0x7D)范围内，则将其转成大写字符
    // (0x41-0x5D)。
464         testb $0x4c,mode                /* ctrl or caps */ /* 控制键已按下或 caps 亮？ */
465         je 2f                           // 没有，则向前跳转标号 2 处。
466         cmpb $'a,%al                    // 将 al 中的字符与'a'比较。
467         jb 2f                           // 若 al 值<'a'，则转标号 2 处。
468         cmpb $'},%al                    // 将 al 中的字符与'}'比较。
469         ja 2f                           // 若 al 值>'}'，则转标号 2 处。
470         subb $32,%al                    // 将 al 转换为大写字符(减 0x20)。
    // 若 ctrl 键已按下，并且字符在'`'--'_'(0x40-0x5F)之间(是大写字符)，则将其转换为控制字符
    // (0x00-0x1F)。
471 2:      testb $0x0c,mode                /* ctrl */  /* ctrl 键同时按下了吗？ */
472         je 3f                           // 若没有则转标号 3。
473         cmpb $64,%al                    // 将 al 与'@'(64)字符比较(即判断字符所属范围)。
474         jb 3f                           // 若值<'@'，则转标号 3。
```

```
475         cmpb $64+32,%al                 // 将 al 与'``'(96)字符比较(即判断字符所属范围)。
476         jae 3f                          // 若值>='``'，则转标号 3。
477         subb $64,%al                    // 否则 al 值减 0x40，
                                            // 即将字符转换为 0x00-0x1f 之间的控制字符。
    // 若左 alt 键同时按下，则将字符的位 7 置位。
478 3:      testb $0x10,mode                /* left alt */  /* 左 alt 键同时按下？ */
479         je 4f                           // 没有，则转标号 4。
480         orb $0x80,%al                   // 字符的位 7 置位。
    // 将 al 中的字符放入读缓冲队列中。
481 4:      andl $0xff,%eax                 // 清 eax 的高字和 ah。
482         xorl %ebx,%ebx                  // 由于放入队列字符数<=4，因此需把 ebx 清零。
483         call put_queue                  // 将字符放入缓冲队列中。
484 none:   ret
485
486 /*
487  * minus has a routine of it's own, as a 'E0h' before
488  * the scan code for minus means that the numeric keypad
489  * slash was pushed.
490  */
    /*
     * 减号有它自己的处理子程序，因为在减号扫描码之前的 0xe0
     * 意味着按下了数字小键盘上的斜杠键。
     */
491 minus:  cmpb $1,e0                      // e0 标志置位了吗？
492         jne do_self                     // 没有，则调用 do_self 对减号符进行普通处理。
493         movl $'/,%eax                   // 否则用'/'替换减号'-'➔al。
494         xorl %ebx,%ebx                  // 由于放入队列字符数<=4，因此需把 ebx 清零。
495         jmp put_queue                   // 并将字符放入缓冲队列中。
496
497 /*
498  * This table decides which routine to call when a scan-code has been
499  * gotten. Most routines just call do_self, or none, depending if
500  * they are make or break.
501  */
    /* 下面是一张子程序地址跳转表。当取得扫描码后就根据此表调用相应的扫描码处理子程序。
     * 大多数调用的子程序是 do_self，或者是 none，这起决于是按键(make)还是释放键(break)。
     */
502 key_table:
503         .long none,do_self,do_self,do_self      /* 00-03 s0 esc 1 2 */
504         .long do_self,do_self,do_self,do_self   /* 04-07 3 4 5 6 */
505         .long do_self,do_self,do_self,do_self   /* 08-0B 7 8 9 0 */
506         .long do_self,do_self,do_self,do_self   /* 0C-0F + ' bs tab */
507         .long do_self,do_self,do_self,do_self   /* 10-13 q w e r */
508         .long do_self,do_self,do_self,do_self   /* 14-17 t y u i */
509         .long do_self,do_self,do_self,do_self   /* 18-1B o p } ^ */
510         .long do_self,ctrl,do_self,do_self      /* 1C-1F enter ctrl a s */
511         .long do_self,do_self,do_self,do_self   /* 20-23 d f g h */
512         .long do_self,do_self,do_self,do_self   /* 24-27 j k l | */
513         .long do_self,do_self,lshift,do_self    /* 28-2B { para lshift , */
514         .long do_self,do_self,do_self,do_self   /* 2C-2F z x c v */
515         .long do_self,do_self,do_self,do_self   /* 30-33 b n m , */
516         .long do_self,minus,rshift,do_self      /* 34-37 . - rshift * */
517         .long alt,do_self,caps,func             /* 38-3B alt sp caps f1 */
```

```
518         .long func,func,func,func                   /* 3C-3F f2 f3 f4 f5 */
519         .long func,func,func,func                   /* 40-43 f6 f7 f8 f9 */
520         .long func,num,scroll,cursor                /* 44-47 f10 num scr home */
521         .long cursor,cursor,do_self,cursor          /* 48-4B up pgup - left */
522         .long cursor,cursor,do_self,cursor          /* 4C-4F n5 right + end */
523         .long cursor,cursor,cursor,cursor           /* 50-53 dn pgdn ins del */
524         .long none,none,do_self,func                /* 54-57 sysreq ? < f11 */
525         .long func,none,none,none                   /* 58-5B f12 ? ? ? */
526         .long none,none,none,none                   /* 5C-5F ? ? ? ? */
527         .long none,none,none,none                   /* 60-63 ? ? ? ? */
528         .long none,none,none,none                   /* 64-67 ? ? ? ? */
529         .long none,none,none,none                   /* 68-6B ? ? ? ? */
530         .long none,none,none,none                   /* 6C-6F ? ? ? ? */
531         .long none,none,none,none                   /* 70-73 ? ? ? ? */
532         .long none,none,none,none                   /* 74-77 ? ? ? ? */
533         .long none,none,none,none                   /* 78-7B ? ? ? ? */
534         .long none,none,none,none                   /* 7C-7F ? ? ? ? */
535         .long none,none,none,none                   /* 80-83 ? br br br */
536         .long none,none,none,none                   /* 84-87 br br br br */
537         .long none,none,none,none                   /* 88-8B br br br br */
538         .long none,none,none,none                   /* 8C-8F br br br br */
539         .long none,none,none,none                   /* 90-93 br br br br */
540         .long none,none,none,none                   /* 94-97 br br br br */
541         .long none,none,none,none                   /* 98-9B br br br br */
542         .long none,unctrl,none,none                 /* 9C-9F br unctrl br br */
543         .long none,none,none,none                   /* A0-A3 br br br br */
544         .long none,none,none,none                   /* A4-A7 br br br br */
545         .long none,none,unlshift,none               /* A8-AB br br unlshift br */
546         .long none,none,none,none                   /* AC-AF br br br br */
547         .long none,none,none,none                   /* B0-B3 br br br br */
548         .long none,none,unrshift,none               /* B4-B7 br br unrshift br */
549         .long unalt,none,uncaps,none                /* B8-BB unalt br uncaps br */
550         .long none,none,none,none                   /* BC-BF br br br br */
551         .long none,none,none,none                   /* C0-C3 br br br br */
552         .long none,none,none,none                   /* C4-C7 br br br br */
553         .long none,none,none,none                   /* C8-CB br br br br */
554         .long none,none,none,none                   /* CC-CF br br br br */
555         .long none,none,none,none                   /* D0-D3 br br br br */
556         .long none,none,none,none                   /* D4-D7 br br br br */
557         .long none,none,none,none                   /* D8-DB br ? ? ? */
558         .long none,none,none,none                   /* DC-DF ? ? ? ? */
559         .long none,none,none,none                   /* E0-E3 e0 e1 ? ? */
560         .long none,none,none,none                   /* E4-E7 ? ? ? ? */
561         .long none,none,none,none                   /* E8-EB ? ? ? ? */
562         .long none,none,none,none                   /* EC-EF ? ? ? ? */
563         .long none,none,none,none                   /* F0-F3 ? ? ? ? */
564         .long none,none,none,none                   /* F4-F7 ? ? ? ? */
565         .long none,none,none,none                   /* F8-FB ? ? ? ? */
566         .long none,none,none,none                   /* FC-FF ? ? ? ? */
567
568 /*
569  * kb_wait waits for the keyboard controller buffer to empty.
570  * there is no timeout - if the buffer doesn't empty, we hang.
```

```
571  */
     /*
      * 子程序 kb_wait 用于等待键盘控制器缓冲空。不存在超时处理 - 如果
      * 缓冲永远不空的话，程序就会永远等待(死掉)。
      */
572 kb_wait:
573         pushl %eax
574 1:      inb $0x64,%al               // 读键盘控制器状态。
575         testb $0x02,%al             // 测试输入缓冲器是否为空(等于 0)。
576         jne 1b                      // 若不空，则跳转循环等待。
577         popl %eax
578         ret
579 /*
580  * This routine reboots the machine by asking the keyboard
581  * controller to pulse the reset-line low.
582  */
    /*
     * 该子程序通过设置键盘控制器，向复位线输出负脉冲，使系统复位重启(reboot)。
     */
583 reboot:
584         call kb_wait                // 首先等待键盘控制器输入缓冲器空。
    // 下一句是往物理内存地址 0x472 处写值 0x1234。该位置是启动模式（reboot_mode）标志字。
    // 在启动过程中 ROM BIOS 会读取该启动模式标志值并根据其值来指导下一步的执行。如果该值
    // 是 0x1234，则 BIOS 就会跳过内存检测过程而执行热启动（Warm-boot）过程。如果若该值为 0，
    // 则执行冷启动（Cold-boot）过程。
585         movw $0x1234,0x472          /* don't do memory check */ /* 不进行内存检测 */
586         movb $0xfc,%al              /* pulse reset and A20 low */
587         outb %al,$0x64              // 向系统复位和 A20 线输出负脉冲。
588 die:    jmp die                     // 死机。
```

7.4.3 其他信息

7.4.3.1 AT 键盘接口编程

主机系统板上所采用的键盘控制器是 intel 8042 芯片或其兼容芯片，其逻辑示意图，见图 7-6 所示。其中输出端口 P2 分别用于其他目的。位 0(P20 引脚)用于实现 CPU 的复位操作，位 1（P21 引脚）用于控制 A20 信号线的开启与否。当该输出端口位 0 为 1 时就开启（选通）了 A20 信号线，为 0 则禁止 A20 信号线。参见引导启动程序一章中对 A20 信号线的详细说明。

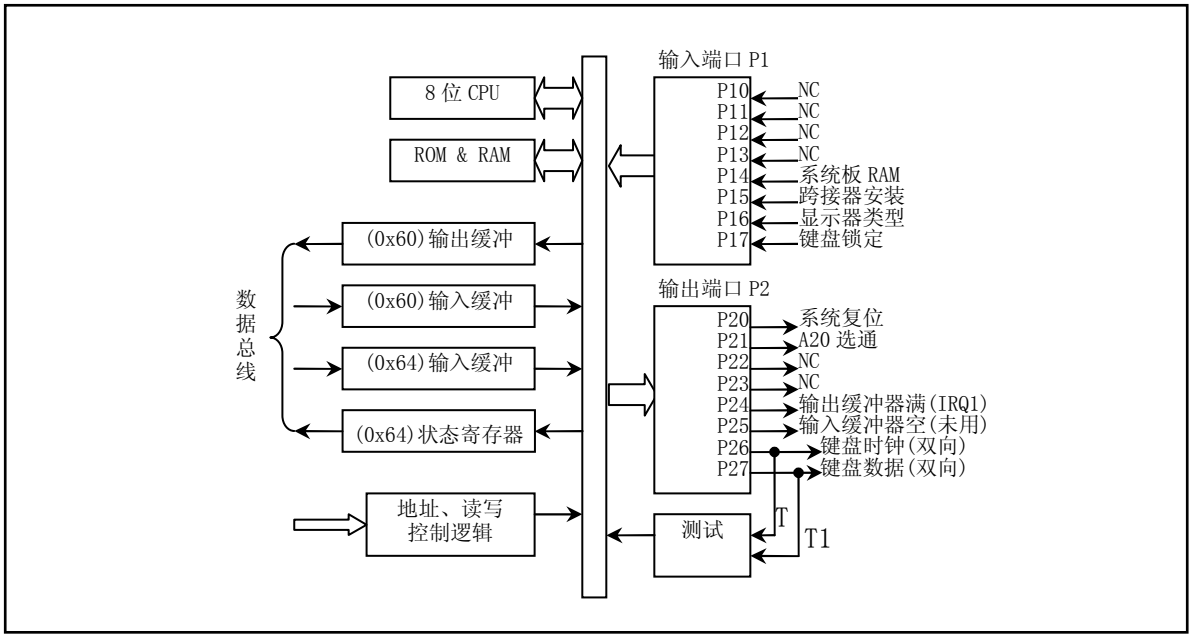

图 7-6 键盘控制器 804X 逻辑示意图

分配给键盘控制器的 IO 端口范围是 0x60-0x6f，但实际上 IBM CP/AT 使用的只有 0x60 和 0x64 两个口地址(0x61、0x62 和 0x63 用于与 XT 兼容目的)见表 7–1 所示，加上对端口的读和写操作含义不同，因此主要可有 4 种不同操作。对键盘控制器进行编程，将涉及芯片中的状态寄存器、输入缓冲器和输出缓冲器。

表 7－1 键盘控制器 804X 端口

端口	读/写	名称	用途
0x60	读	数据端口或输出缓冲器	是一个 8 位只读寄存器。当键盘控制器收到来自键盘的扫描码或命令响应时，一方面置状态寄存器位 0 = 1，另一方面产生中断 IRQ1。通常应该仅在状态端口位 0 = 1 时才读。
0x60	写	输入缓冲器	用于向键盘发送命令与/或随后的参数，或向键盘控制器写参数。键盘命令共有 10 多条，见表格后说明。通常都应该仅在状态端口位 1=0 时才写。
0x61	读/写		该端口 0x61 是 8255A 输出口 B 的地址，是针对使用/兼容 8255A 的 PC 标准键盘电路进行硬件复位处理。该端口用于对收到的扫描码做出应答。方法是首先禁止键盘，然后立刻重新允许键盘。所操作的数据为： 位 7=1 禁止键盘；=0 允许键盘； 位 6=0 迫使键盘时钟为低位，因此键盘不能发送任何数据。 位 5-0 这些位与键盘无关，是用于可编程并行接口(PPI)。
0x64	读	状态寄存器	是一个 8 位只读寄存器，其位字段含义分别为： 位 7=1 来自键盘传输数据奇偶校验错； 位 6=1 接收超时(键盘传送未产生 IRQ1)； 位 5=1 发送超时(键盘无响应)； 位 4=1 键盘接口被键盘锁禁止；[??是=0 时] 位 3=1 写入输入缓冲器中的数据是命令(通过端口 0x64)； =0 写入输入缓冲器中的数据是参数(通过端口 0x60)； 位 2 系统标志状态：0 = 上电启动或复位；1 = 自检通过；

			位 1=1 输入缓冲器满(0x60/64 口有给 8042 的数据)； 位 0=1 输出缓冲器满(数据端口 0x60 有给系统的数据)。
0x64	写	输入缓冲器	向键盘控制器写命令。可带一参数，参数从端口 0x60 写入。键盘控制器命令有 12 条，见表格后说明。

7.4.3.2 键盘命令

系统在向端口 0x60 写入 1 字节，便是发送键盘命令。键盘在接收到命令后 20ms 内应予以响应，即回送一个命令响应。有的命令后还需要跟一参数（也写到该端口）。命令列表见表 7–2 所示。注意，如果没有另外指明，所有命令均被回送一个 0xfa 响应码(ACK)。

表 7－2 键盘命令一览表

命令码	参数	功能
0xed	有	设置/复位模式指示器。置 1 开启，0 关闭。参数字节： 位 7-3 保留全为 0； 位 2 = caps-lock 键； 位 1 = num-lock 键； 位 0 = scroll-lock 键。
0xee	无	诊断回应。键盘应回送 0xee。
0xef		保留不用。
0xf0	有	读取/设置扫描码集。参数字节等于： 0x00 - 选择当前扫描码集； 0x01 - 选择扫描码集 1(用于 PCs，PS/2 30 等)； 0x02 - 选择扫描码集 2(用于 AT，PS/2，是缺省值)； 0x03 - 选择扫描码集 3。
0xf1		保留不用。
0xf2	无	读取键盘标识号(读取 2 个字节)。AT 键盘返回响应码 0xfa。
0xf3	有	设置扫描码连续发送时的速率和延迟时间。参数字节的含义为： 位 7 保留为 0； 位 6-5 延时值：令 C=位 6-5，则有公式：延时值=(1+C)*250ms； 位 4-0 扫描码连续发送的速率；令 B=位 4-3；A=位 2-0，则有公式： 速率=1/((8+A)*2^B*0.00417)。 参数缺省值为 0x2c。
0xf4	无	开启键盘。
0xf5	无	禁止键盘。
0xf6	无	设置键盘默认参数。
0xf7-0xfd		保留不用。
0xfe	无	重发扫描码。当系统检测到键盘传输数据有错，则发此命令。
0xff	无	执行键盘上电复位操作，称之为基本保证测试(BAT)。操作过程为： 1. 键盘收到该命令后立刻响应发送 0xfa； 2. 键盘控制器使键盘时钟和数据线置为高电平； 3. 键盘开始执行 BAT 操作； 4. 若正常完成，则键盘发送 0xaa；否则发送 0xfd 并停止扫描。

7.4.3.3 键盘控制器命令

系统向输入缓冲(端口 0x64)写入 1 字节，即发送一键盘控制器命令。可带一参数。参数是通过写 0x60 端口发送的。见表 7–3 所示。

表 7－3 键盘控制器命令一览表

命令	参数	功能
0x20	无	读给键盘控制器的最后一个命令字节，放在端口 0x60 供系统读取。
0x21-0x3f	无	读取由命令低 5 比特位指定的控制器内部 RAM 中的命令。
0x60-0x7f	有	写键盘控制器命令字节。参数字节：（默认值为 0x5d） 位 7 保留为 0； 位 6 IBM PC 兼容模式(奇偶检验，转换为系统扫描码，单字节 PC 断开码)； 位 5 PC 模式（对扫描码不进行奇偶校验；不转换成系统扫描码）； 位 4 禁止键盘工作（使键盘时钟为低电平）； 位 3 禁止超越(override)，对键盘锁定转换不起作用； 位 2 系统标志；1 表示控制器工作正确； 位 1 保留为 0； 位 0 允许输出寄存器满中断。
0xaa	无	初始化键盘控制器自测试。成功返回 0x55；失败返回 0xfc。
0xab	无	初始化键盘接口测试。返回字节： 0x00 无错； 0x01 键盘时钟线为低(始终为低，低粘连)； 0x02 键盘时钟线为高； 0x03 键盘数据线为低； 0x04 键盘数据线为高；
0xac	无	诊断转储。804x 的 16 字节 RAM、输出口、输入口状态依次输出给系统。
0xad	无	禁止键盘工作（设置命令字节位 4=1）。
0xae	无	允许键盘工作（复位命令字节位 4=0）。
0xc0	无	读 804x 的输入端口 P1，并放在 0x60 供读取；
0xd0	无	读 804x 的输出端口 P2，并放在 0x60 供读取；
0xd1	有	写 804x 的输出端口 P2，原 IBM PC 使用输出端口的位 2 控制 A20 门。注意，位 0(系统复位)应该总是置位的。
0xe0	无	读测试端 T0 和 T1 的输入送输出缓冲器供系统读取。 位 1 键盘数据；位 0 键盘时钟。
0xed	有	控制 LED 的状态。置 1 开启，0 关闭。参数字节： 位 7-3 保留全为 0； 位 2 = caps-lock 键； 位 1 = num-lock 键； 位 0 = scroll-lock 键。
0xf0-0xff	无	送脉冲到输出端口。该命令序列控制输出端口 P20-23 线，参见键盘控制器逻辑示意图。欲让哪一位输出负脉冲(6 微秒)，即置该位为 0。也即该命令的低 4 位分别控制负脉冲的输出。例如，若要复位系统，则需发出命令 0xfe(P20 低)即可。

7.4.3.4 键盘扫描码

PC 机采用的均是非编码键盘。键盘上每个键都有一个位置编号，是从左到右从上到下。并且 PC XT

机与 AT 机键盘的位置码差别很大。键盘内的微处理机向系统发送的是键对应的扫描码。当键按下时，键盘输出的扫描码称为接通(make)扫描码，而该键松开时发送的则称为断开(break)扫描码。XT 键盘各键的扫描码见表 7–4 所示。

键盘上的每个键都有一个包含在字节低 7 位（位 6-0）中相应的扫描码。在高位（位 7）表示是按键还是松开按键。位 7=0 表示刚将键按下的扫描码，位 7=1 表示键松开的扫描码。例如，如果某人刚把 ESC 键按下，则传输给系统的扫描码将是 1（1 是 ESC 键的扫描码），当该键释放时将产生 1+0x80=129 扫描码。

对于 PC、PC/XT 的标准 83 键键盘，接通扫描码与键号（键的位置码）是一样的。并用 1 字节表示。例如“A”键，键位置号是 30，接通码是扫描码是 0x1e。而其断开码是是接通扫描码加上 0x80，即 0x9e。对于 AT 机使用的 84/101/102 扩展键盘，则与 PC/XT 标准键盘区别较大。

对于某些“扩展”的键，则情况有些不同。当一个扩展键被按下时，将产生一个中断并且键盘端口将输出一个“扩展的”的扫描码前缀 0xe0，而在下一个“中断”中将给出。比如，对于 PC/XT 标准键盘，左边的控制键 ctrl 的扫描码是 29，而右边的“扩展的”控制键 ctrl 则具有一个扩展的扫描码 29。这个规则同样适合于 alt、箭头键。

另外，还有两个键的处理非常特殊，PrtScn 键和 Pause/Break 键。按下 PrtScn 键将会向键盘中断程序发送*2*个扩展字符，42(0x2a)和 55(0x37)，所以实际的字节序列将是 0xe0，0x2a，0xe0，0x37。但在键重复产生时将只发送扩展码 0x37。当键松开时，又重新发送两个扩展的加上 0x80 的码（0xe0，0xaa，0xe0，0xb7）。当 prtscn 键按下时，如果 shift 或 ctrl 键也按下了，则仅发送 0xe0，0x37，并且在松开时仅发送 0xe0，0xb7)。

对于 Pause/Break 键。如果你在按下该键的同时也按下了控制键，则将行如扩展键 70，而在其他情况下它将发送字符序列 0xe1，0x1d，0x45，0xe1，0x9d，0xc5。将键按下并不会产生重复的扫描码，而松开键也并不会产生任何扫描码。

因此，可以这样来看待和处理：扫描码 0xe0 意味着还有一个字符跟随其后，而扫描码 0xe1 则表示后面跟随着 2 个字符。

对于 AT 键盘的扫描码，与 PC/XT 的略有不同。当键按下时，则对应键的扫描码被送出，但当键松开时，将会发送两个字节，第一个是 0xf0，第 2 个还是相同的键扫描码。现在键盘设计者使用 8049 作为 AT 键盘的输入处理器，为了向下的兼容性将 AT 键盘发出的扫描码转换成了老式 PC/XT 标准键盘的扫描码。

AT 键盘有三种独立的扫描码集：一种是我们上面说明的(83 键映射，而增加的键有多余的 0xe0 码)，一种几乎是顺序的，还有一种却只有 1 个字节！最后一种所带来的问题是只有左 shift，caps，左 ctrl 和左 alt 键的松开码被发送。键盘的默认扫描码集是扫描码集 2，可以利用命令更改。

对于扫描码集 1 和 2，有特殊码 0xe0 和 0xe1。它们用于具有相同功能的键。比如：左控制键 ctrl 位置是 0x1d(对于 PC/XT)，则右边的控制键就是 0xe0，0x1d。这是为了与 PC/XT 程序兼容。请注意唯一使用 0xe1 的时候是当它表示临时控制键时，对此情况同时也有一个 0xe0 的版本。

表 7－4 XT 键盘扫描码表

F1	F2	`	1	2	3	4	5	6	7	8	9	0	-	=	\	BS	ESC	NUML	SCRL	SYSR
3B	3C	29	02	03	04	05	06	07	08	09	0A	0B	0C	0D	2B	0E	01	45	46	**
F3	F4	TAB	Q	W	E	R	T	Y	U	I	O	P	[	]			Home	↑	PgUp	PrtSc
3D	3E	0F	10	11	12	13	14	15	16	17	18	19	1A	1B			47	48	49	37
F5	F6	CNTL	A	S	D	F	G	H	J	K	L	;	’	ENTER			←	5	→	-
3F	40	1D	1E	1F	20	21	22	23	24	25	26	27	28	1C			4B	4C	4D	4A
F7	F8	LSHFT	Z	X	C	V	B	N	M	,	.	/	RSHFT				End	↓	PgDn	+
41	42	2A	2C	2D	2E	2F	30	31	32	33	34	35	36				4F	50	51	4E
F9	F0	ALT	Space											CAPLOCK			Ins		Del	
3F	40	1D	39											3A			52		53	

7.5 console.c 程序

7.5.1 功能描述

本文件是内核中最长的程序之一，但功能比较单一。其中的所有子程序都是为了实现终端屏幕写函数 con_write()以及进行终端初始化操作。

函数 con_write()会从终端 tty_struct 结构的写缓冲队列 write_q 中取出字符或字符序列，然后根据字符的性质（是普通字符还是转义字符序列），把字符显示在终端屏幕上或进行一些光标移动、字符檫除等屏幕控制操作。

终端屏幕初始化函数 con_init()会根据系统初始化时获得的系统信息，设置有关屏幕的一些基本参数值，用于 con_write()函数的操作。

有关终端设备字符缓冲队列的说明可参见 include/linux/tty.h 头文件。其中给出了字符缓冲队列的数据结构 tty_queue、终端的数据结构 tty_struct 和一些控制字符的值。另外还有一些对缓冲队列进行操作的宏定义。缓冲队列及其操作示意图请参见图 7-9 所示。

7.5.2 代码注释

程序 7-3 linux/kernel/chr_drv/console.c

```
1  /*
2   *  linux/kernel/console.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   *      console.c
9   *
10  * This module implements the console io functions
11  *      'void con_init(void)'
12  *      'void con_write(struct tty_queue * queue)'
13  * Hopefully this will be a rather complete VT102 implementation.
14  *
15  * Beeping thanks to John T Kohl.
16  */
    /*
     * 该模块实现控制台输入输出功能
     *      'void con_init(void)'
     *      'void con_write(struct tty_queue * queue)'
     * 希望这是一个非常完整的 VT102 实现。
     *
     * 感谢 John T Kohl 实现了蜂鸣指示。
     */
17
18 /*
19  *  NOTE!!! We sometimes disable and enable interrupts for a short while
20  * (to put a word in video IO), but this will work even for keyboard
```

```
21  * interrupts. We know interrupts aren't enabled when getting a keyboard
22  * interrupt, as we use trap-gates. Hopefully all is well.
23  */
    /*
     * 注意!!! 我们有时短暂地禁止和允许中断(在将一个字(word)放到视频 IO)，但即使
     * 对于键盘中断这也是可以工作的。因为我们使用陷阱门，所以我们知道在获得一个
     * 键盘中断时中断是不允许的。希望一切均正常。
     */
24
25 /*
26  * Code to check for different video-cards mostly by Galen Hunt,
27  * <g-hunt@ee.utah.edu>
28  */
    /*
     * 检测不同显示卡的代码大多数是 Galen Hunt 编写的，
     * <g-hunt@ee.utah.edu>
     */
29
30 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
31 #include <linux/tty.h>    // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
32 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
33 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
34
35 /*
36  * These are set up by the setup-routine at boot-time:
37  */
    /*
     * 这些是设置子程序 setup 在引导启动系统时设置的参数：
     */
38
    // 参见对 boot/setup.s 的注释，和 setup 程序读取并保留的参数表。
39 #define ORIG_X                  (*(unsigned char *)0x90000)     // 光标列号。
40 #define ORIG_Y                  (*(unsigned char *)0x90001)     // 光标行号。
41 #define ORIG_VIDEO_PAGE         (*(unsigned short *)0x90004)    // 显示页面。
42 #define ORIG_VIDEO_MODE         ((*(unsigned short *)0x90006) & 0xff)  // 显示模式。
43 #define ORIG_VIDEO_COLS         (((*(unsigned short *)0x90006) & 0xff00) >> 8) // 字符列数。
44 #define ORIG_VIDEO_LINES        (25)                            // 显示行数。
45 #define ORIG_VIDEO_EGA_AX       (*(unsigned short *)0x90008)    // [??]
46 #define ORIG_VIDEO_EGA_BX       (*(unsigned short *)0x9000a)    // 显示内存大小和色彩模式。
47 #define ORIG_VIDEO_EGA_CX       (*(unsigned short *)0x9000c)    // 显示卡特性参数。
48
    // 定义显示器单色/彩色显示模式类型符号常数。
49 #define VIDEO_TYPE_MDA          0x10    /* Monochrome Text Display    */ /* 单色文本   */
50 #define VIDEO_TYPE_CGA          0x11    /* CGA Display                */ /* CGA 显示器  */
51 #define VIDEO_TYPE_EGAM         0x20    /* EGA/VGA in Monochrome Mode */ /* EGA/VGA 单色*/
52 #define VIDEO_TYPE_EGAC         0x21    /* EGA/VGA in Color Mode      */ /* EGA/VGA 彩色*/
53
54 #define NPAR 16
55
56 extern void keyboard_interrupt(void);          // 键盘中断处理程序(keyboard.S)。
57
58 static unsigned char    video_type;             /* Type of display being used   */
```

```
                                                    /* 使用的显示类型 */
59 static unsigned long    video_num_columns;        /* Number of text columns     */
                                                    /* 屏幕文本列数 */
60 static unsigned long    video_size_row;           /* Bytes per row              */
                                                    /* 每行使用的字节数 */
61 static unsigned long    video_num_lines;          /* Number of test lines       */
                                                    /* 屏幕文本行数 */
62 static unsigned char    video_page;               /* Initial video page         */
                                                    /* 初始显示页面 */
63 static unsigned long    video_mem_start;          /* Start of video RAM         */
                                                    /* 显示内存起始地址 */
64 static unsigned long    video_mem_end;            /* End of video RAM (sort of) */
                                                    /* 显示内存结束(末端)地址 */
65 static unsigned short   video_port_reg;          /* Video register select port */
                                                    /* 显示控制索引寄存器端口 */
66 static unsigned short   video_port_val;          /* Video register value port  */
                                                    /* 显示控制数据寄存器端口 */
67 static unsigned short   video_erase_char;        /* Char+Attrib to erase with  */
                                                    /* 擦除字符属性与字符(0x0720) */
68
   // 以下这些变量用于屏幕卷屏操作。
69 static unsigned long    origin;          /* Used for EGA/VGA fast scroll */ // scr_start。
                                            /* 用于 EGA/VGA 快速滚屏 */ // 滚屏起始内存地址。
70 static unsigned long    scr_end;         /* Used for EGA/VGA fast scroll */
                                            /* 用于 EGA/VGA 快速滚屏 */ // 滚屏末端内存地址。
71 static unsigned long    pos;             // 当前光标对应的显示内存位置。
72 static unsigned long    x,y;             // 当前光标位置。
73 static unsigned long    top,bottom;      // 滚动时顶行行号；底行行号。
   // state 用于标明处理 ESC 转义序列时的当前步骤。npar,par[]用于存放 ESC 序列的中间处理参数。
74 static unsigned long    state=0;         // ANSI 转义字符序列处理状态。
75 static unsigned long    npar,par[NPAR]; // ANSI 转义字符序列参数个数和参数数组。
76 static unsigned long    ques=0;
77 static unsigned char    attr=0x07;       // 字符属性(黑底白字)。
78
79 static void sysbeep(void);               // 系统蜂鸣函数。
80
81 /*
82  * this is what the terminal answers to a ESC-Z or csi0c
83  * query (= vt100 response).
84  */
   /*
    * 下面是终端回应 ESC-Z 或 csi0c 请求的应答(=vt100 响应)。
    */
   // csi - 控制序列引导码(Control Sequence Introducer)。
85 #define RESPONSE "\033[?1;2c"
86
87 /* NOTE! gotoxy thinks x==video_num_columns is ok */
   /* 注意! gotoxy 函数认为 x==video_num_columns，这是正确的 */
   //// 跟踪光标当前位置。
   // 参数：new_x - 光标所在列号；new_y - 光标所在行号。
   // 更新当前光标位置变量 x,y，并修正 pos 指向光标在显示内存中的对应位置。
88 static inline void gotoxy(unsigned int new_x,unsigned int new_y)
89 {
```

```
    // 如果输入的光标行号超出显示器列数，或者光标行号超出显示的最大行数，则退出。
 90         if (new_x > video_num_columns || new_y >= video_num_lines)
 91                 return;
    // 更新当前光标变量；更新光标位置对应的在显示内存中位置变量 pos。
 92         x=new_x;
 93         y=new_y;
 94         pos=origin + y*video_size_row + (x<<1);
 95 }
 96
    //// 设置滚屏起始显示内存地址。
 97 static inline void set_origin(void)
 98 {
 99         cli();
    // 首先选择显示控制数据寄存器 r12，然后写入卷屏起始地址高字节。向右移动 9 位，表示向右移动
    // 8 位，再除以 2(2 字节代表屏幕上 1 字符)。是相对于默认显示内存操作的。
100         outb_p(12, video_port_reg);
101         outb_p(0xff&((origin-video_mem_start)>>9), video_port_val);
    // 再选择显示控制数据寄存器 r13，然后写入卷屏起始地址底字节。向右移动 1 位表示除以 2。
102         outb_p(13, video_port_reg);
103         outb_p(0xff&((origin-video_mem_start)>>1), video_port_val);
104         sti();
105 }
106
    //// 向上卷动一行（屏幕窗口向下移动）。
    // 将屏幕窗口向下移动一行。参见程序列表后说明。
107 static void scrup(void)
108 {
    // 如果显示类型是 EGA，则执行以下操作。
109         if (video_type == VIDEO_TYPE_EGAC || video_type == VIDEO_TYPE_EGAM)
110         {
    // 如果移动起始行 top=0，移动最底行 bottom=video_num_lines=25，则表示整屏窗口向下移动。
111                 if (!top && bottom == video_num_lines) {
    // 调整屏幕显示对应内存的起始位置指针 origin 为向下移一行屏幕字符对应的内存位置，同时也调整
    // 当前光标对应的内存位置以及屏幕末行末端字符指针 scr_end 的位置。
112                         origin += video_size_row;
113                         pos += video_size_row;
114                         scr_end += video_size_row;
    // 如果屏幕末端最后一个显示字符所对应的显示内存指针 scr_end 超出了实际显示内存的末端，则将
    // 屏幕内容内存数据移动到显示内存的起始位置 video_mem_start 处，并在出现的新行上填入空格字符。
115                         if (scr_end > video_mem_end) {
    // %0 - eax(擦除字符+属性)；%1 - ecx((显示器字符行数-1)所对应的字符数/2，是以长字移动)；
    // %2 - edi(显示内存起始位置 video_mem_start)；%3 - esi(屏幕内容对应的内存起始位置 origin)。
    // 移动方向：[edi]➔[esi]，移动 ecx 个长字。
116                                 __asm__("cld\n\t"               // 清方向位。
117                                         "rep\n\t"               // 重复操作，将当前屏幕内存数据
118                                         "movsl\n\t"             // 移动到显示内存起始处。
119                                         "movl _video_num_columns,%1\n\t" // ecx=1 行字符数。
120                                         "rep\n\t"               // 在新行上填入空格字符。
121                                         "stosw"
122                                         ::"a" (video_erase_char),
123                                         "c" ((video_num_lines-1)*video_num_columns>>1),
124                                         "D" (video_mem_start),
125                                         "S" (origin)
```

```
126                                         :"cx","di","si");
    // 根据屏幕内存数据移动后的情况，重新调整当前屏幕对应内存的起始指针、光标位置指针和屏幕末端
    // 对应内存指针 scr_end。
127                                 scr_end -= origin-video_mem_start;
128                                 pos -= origin-video_mem_start;
129                                 origin = video_mem_start;
130                         } else {
    // 如果调整后的屏幕末端对应的内存指针 scr_end 没有超出显示内存的末端 video_mem_end，则只需在
    // 新行上填入擦除字符(空格字符)。
    // %0 - eax(擦除字符+属性)；%1 - ecx(显示器字符行数)；%2 - edi(屏幕对应内存最后一行开始处)；
131                                 __asm__("cld\n\t"       // 清方向位。
132                                         "rep\n\t"       // 重复操作，在新出现行上
133                                         "stosw"         // 填入擦除字符(空格字符)。
134                                         ::"a" (video_erase_char),
135                                         "c" (video_num_columns),
136                                         "D" (scr_end-video_size_row)
137                                         :"cx","di");
138                         }
    // 向显示控制器中写入新的屏幕内容对应的内存起始位置值。
139                         set_origin();
    // 否则表示不是整屏移动。也即表示从指定行 top 开始的所有行向上移动 1 行(删除 1 行)。此时直接
    // 将屏幕从指定行 top 到屏幕末端所有行对应的显示内存数据向上移动 1 行，并在新出现的行上填入擦
    // 除字符。
    // %0-eax(擦除字符+属性)；%1-ecx(top 行下 1 行开始到屏幕末行的行数所对应的内存长字数)；
    // %2-edi(top 行所处的内存位置)；%3-esi(top+1 行所处的内存位置)。
140                 } else {
141                         __asm__("cld\n\t"               // 清方向位。
142                                 "rep\n\t"               // 循环操作，将 top+1 到 bottom 行
143                                 "movsl\n\t"             // 所对应的内存块移到 top 行开始处。
144                                 "movl _video_num_columns,%%ecx\n\t" // ecx = 1 行字符数。
145                                 "rep\n\t"               // 在新行上填入擦除字符。
146                                 "stosw"
147                                 ::"a" (video_erase_char),
148                                 "c" ((bottom-top-1)*video_num_columns>>1),
149                                 "D" (origin+video_size_row*top),
150                                 "S" (origin+video_size_row*(top+1))
151                                 :"cx","di","si");
152                 }
153         }
    // 如果显示类型不是 EGA(是 MDA)，则执行下面移动操作。因为 MDA 显示控制卡会自动调整超出显示范
    // 围的情况，也即会自动翻卷指针，所以这里不对屏幕内容对应内存超出显示内存的情况单独处理。处
    // 理方法与 EGA 非整屏移动情况完全一样。
154         else            /* Not EGA/VGA */
155         {
156                 __asm__("cld\n\t"
157                         "rep\n\t"
158                         "movsl\n\t"
159                         "movl _video_num_columns,%%ecx\n\t"
160                         "rep\n\t"
161                         "stosw"
162                         ::"a" (video_erase_char),
163                         "c" ((bottom-top-1)*video_num_columns>>1),
164                         "D" (origin+video_size_row*top),
```

```
165                         "S" (origin+video_size_row*(top+1))
166                         :"cx","di","si");
167         }
168 }
169
    //// 向下卷动一行（屏幕窗口向上移动）。
    // 将屏幕窗口向上移动一行，屏幕显示的内容向下移动 1 行，在被移动开始行的上方出现一新行。参见
    // 程序列表后说明。处理方法与 scrup()相似，只是为了在移动显示内存数据时不出现数据覆盖错误情
    // 况，复制是以反方向进行的，也即从屏幕倒数第 2 行的最后一个字符开始复制
170 static void scrdown(void)
171 {
    // 如果显示类型是 EGA，则执行下列操作。
    // [??好象 if 和 else 的操作完全一样啊!为什么还要分别处理呢？难道与任务切换有关？]
172         if (video_type == VIDEO_TYPE_EGAC || video_type == VIDEO_TYPE_EGAM)
173         {
    // %0-eax(擦除字符+属性)；%1-ecx(top 行开始到屏幕末行-1 行的行数所对应的内存长字数)；
    // %2-edi(屏幕右下角最后一个长字位置)；%3-esi(屏幕倒数第 2 行最后一个长字位置)。
    // 移动方向：[esi]➔[edi]，移动 ecx 个长字。
174                 __asm__("std\n\t"               // 置方向位。
175                         "rep\n\t"               // 重复操作，向下移动从 top 行到 bottom-1 行
176                         "movsl\n\t"             // 对应的内存数据。
177                         "addl $2,%%edi\n\t"     /* %edi has been decremented by 4 */
                                                    /* %edi 已经减 4，因为也是方向填擦除字符 */
178                         "movl _video_num_columns,%%ecx\n\t" // 置 ecx=1 行字符数。
179                         "rep\n\t"               // 将擦除字符填入上方新行中。
180                         "stosw"
181                         ::"a" (video_erase_char),
182                         "c" ((bottom-top-1)*video_num_columns>>1),
183                         "D" (origin+video_size_row*bottom-4),
184                         "S" (origin+video_size_row*(bottom-1)-4)
185                         :"ax","cx","di","si");
186         }
    // 如果不是 EGA 显示类型，则执行以下操作（目前与上面完全一样）。
187         else            /* Not EGA/VGA */
188         {
189                 __asm__("std\n\t"
190                         "rep\n\t"
191                         "movsl\n\t"
192                         "addl $2,%%edi\n\t"     /* %edi has been decremented by 4 */
193                         "movl _video_num_columns,%%ecx\n\t"
194                         "rep\n\t"
195                         "stosw"
196                         ::"a" (video_erase_char),
197                         "c" ((bottom-top-1)*video_num_columns>>1),
198                         "D" (origin+video_size_row*bottom-4),
199                         "S" (origin+video_size_row*(bottom-1)-4)
200                         :"ax","cx","di","si");
201         }
202 }
203
    //// 光标位置下移一行(lf - line feed 换行)。
204 static void lf(void)
205 {
```

```
    // 如果光标没有处在倒数第 2 行之后，则直接修改光标当前行变量 y++，并调整光标对应显示内存位置
    // pos(加上屏幕一行字符所对应的内存长度)。
206         if (y+1<bottom) {
207                 y++;
208                 pos += video_size_row;
209                 return;
210         }
    // 否则需要将屏幕内容上移一行。
211         scrup();
212 }
213
    //// 光标上移一行(ri - reverse line feed 反向换行)。
214 static void ri(void)
215 {
    // 如果光标不在第 1 行上，则直接修改光标当前行标量 y--，并调整光标对应显示内存位置 pos，减去
    // 屏幕上一行字符所对应的内存长度字节数。
216         if (y>top) {
217                 y--;
218                 pos -= video_size_row;
219                 return;
220         }
    // 否则需要将屏幕内容下移一行。
221         scrdown();
222 }
223
    // 光标回到第 1 列(0 列)左端(cr - carriage return 回车)。
224 static void cr(void)
225 {
    // 光标所在的列号*2 即 0 列到光标所在列对应的内存字节长度。
226         pos -= x<<1;
227         x=0;
228 }
229
    // 擦除光标前一字符(用空格替代)(del - delete 删除)。
230 static void del(void)
231 {
    // 如果光标没有处在 0 列，则将光标对应内存位置指针 pos 后退 2 字节(对应屏幕上一个字符)，然后
    // 将当前光标变量列值减 1，并将光标所在位置字符擦除。
232         if (x) {
233                 pos -= 2;
234                 x--;
235                 *(unsigned short *)pos = video_erase_char;
236         }
237 }
238
    //// 删除屏幕上与光标位置相关的部分，以屏幕为单位。csi - 控制序列引导码(Control Sequence
    // Introducer)。
    // ANSI 转义序列：'ESC [sJ'(s = 0 删除光标到屏幕底端；1 删除屏幕开始到光标处；2 整屏删除)。
    // 参数：par - 对应上面 s。
239 static void csi_J(int par)
240 {
241         long count __asm__("cx");       // 设为寄存器变量。
242         long start __asm__("di");
```

```
243
    // 首先根据三种情况分别设置需要删除的字符数和删除开始的显示内存位置。
244         switch (par) {
245                 case 0: /* erase from cursor to end of display */ /* 擦除光标到屏幕底端 */
246                         count = (scr_end-pos)>>1;
247                         start = pos;
248                         break;
249                 case 1: /* erase from start to cursor */ /* 删除从屏幕开始到光标处的字符 */
250                         count = (pos-origin)>>1;
251                         start = origin;
252                         break;
253                 case 2: /* erase whole display */  /* 删除整个屏幕上的字符 */
254                         count = video_num_columns * video_num_lines;
255                         start = origin;
256                         break;
257                 default:
258                         return;
259         }
    // 然后使用擦除字符填写删除字符的地方。
    // %0 - ecx(要删除的字符数 count)；%1 - edi(删除操作开始地址)；%2 - eax（填入的擦除字符）。
260         __asm__("cld\n\t"
261                 "rep\n\t"
262                 "stosw\n\t"
263                 ::"c" (count),
264                 "D" (start),"a" (video_erase_char)
265                 :"cx","di");
266 }
267
    //// 删除行内与光标位置相关的部分，以一行为单位。
    // ANSI 转义字符序列：'ESC [sK'(s = 0 删除到行尾；1 从开始删除；2 整行都删除)。
268 static void csi_K(int par)
269 {
270         long count __asm__("cx");          // 设置寄存器变量。
271         long start __asm__("di");
272
    // 首先根据三种情况分别设置需要删除的字符数和删除开始的显示内存位置。
273         switch (par) {
274                 case 0: /* erase from cursor to end of line */ /* 删除光标到行尾字符 */
275                         if (x>=video_num_columns)
276                                 return;
277                         count = video_num_columns-x;
278                         start = pos;
279                         break;
280                 case 1: /* erase from start of line to cursor */ /* 删除从行开始到光标处 */
281                         start = pos - (x<<1);
282                         count = (x<video_num_columns)?x:video_num_columns;
283                         break;
284                 case 2: /* erase whole line */ /* 将整行字符全删除 */
285                         start = pos - (x<<1);
286                         count = video_num_columns;
287                         break;
288                 default:
289                         return;
```

```
290         }
    // 然后使用擦除字符填写删除字符的地方。
    // %0 - ecx(要删除的字符数 count)；%1 - edi(删除操作开始地址)；%2 - eax（填入的擦除字符）。
291         __asm__("cld\n\t"
292                 "rep\n\t"
293                 "stosw\n\t"
294                 ::"c" (count),
295                 "D" (start),"a" (video_erase_char)
296                 :"cx","di");
297 }
298
    //// 允许翻译(重显)（允许重新设置字符显示方式，比如加粗、加下划线、闪烁、反显等）。
    // ANSI 转义字符序列：'ESC [nm'。n = 0 正常显示；1 加粗；4 加下划线；7 反显；27 正常显示。
299 void csi_m(void)
300 {
301         int i;
302
303         for (i=0;i<=npar;i++)
304                 switch (par[i]) {
305                         case 0:attr=0x07;break;
306                         case 1:attr=0x0f;break;
307                         case 4:attr=0x0f;break;
308                         case 7:attr=0x70;break;
309                         case 27:attr=0x07;break;
310                 }
311 }
312
    //// 根据设置显示光标。
    // 根据显示内存光标对应位置 pos，设置显示控制器光标的显示位置。
313 static inline void set_cursor(void)
314 {
315         cli();
    // 首先使用索引寄存器端口选择显示控制数据寄存器 r14(光标当前显示位置高字节)，然后写入光标
    // 当前位置高字节(向右移动 9 位表示高字节移到低字节再除以 2)。是相对于默认显示内存操作的。
316         outb_p(14, video_port_reg);
317         outb_p(0xff&((pos-video_mem_start)>>9), video_port_val);
    // 再使用索引寄存器选择 r15，并将光标当前位置低字节写入其中。
318         outb_p(15, video_port_reg);
319         outb_p(0xff&((pos-video_mem_start)>>1), video_port_val);
320         sti();
321 }
322
    //// 发送对终端 VT100 的响应序列。
    // 将响应序列放入读缓冲队列中。
323 static void respond(struct tty_struct * tty)
324 {
325         char * p = RESPONSE;
326
327         cli();                  // 关中断。
328         while (*p) {            // 将字符序列放入写队列。
329                 PUTCH(*p,tty->read_q);
330                 p++;
331         }
```

```
332         sti();                  // 开中断。
333         copy_to_cooked(tty);    // 转换成规范模式(放入辅助队列中)。
334 }
335
    //// 在光标处插入一空格字符。
336 static void insert_char(void)
337 {
338         int i=x;
339         unsigned short tmp, old = video_erase_char;
340         unsigned short * p = (unsigned short *) pos;
341
    // 光标开始的所有字符右移一格，并将擦除字符插入在光标所在处。
    // 若一行上都有字符的话，则行最后一个字符将不会更动◎?
342         while (i++<video_num_columns) {
343                 tmp=*p;
344                 *p=old;
345                 old=tmp;
346                 p++;
347         }
348 }
349
    //// 在光标处插入一行（则光标将处在新的空行上）。
    // 将屏幕从光标所在行到屏幕底向下卷动一行。
350 static void insert_line(void)
351 {
352         int oldtop,oldbottom;
353
354         oldtop=top;                     // 保存原 top，bottom 值。
355         oldbottom=bottom;
356         top=y;                          // 设置屏幕卷动开始行。
357         bottom = video_num_lines;       // 设置屏幕卷动最后行。
358         scrdown();                      // 从光标开始处，屏幕内容向下滚动一行。
359         top=oldtop;                     // 恢复原 top，bottom 值。
360         bottom=oldbottom;
361 }
362
    //// 删除光标处的一个字符。
363 static void delete_char(void)
364 {
365         int i;
366         unsigned short * p = (unsigned short *) pos;
367
    // 如果光标超出屏幕最右列，则返回。
368         if (x>=video_num_columns)
369                 return;
    // 从光标右一个字符开始到行末所有字符左移一格。
370         i = x;
371         while (++i < video_num_columns) {
372                 *p = *(p+1);
373                 p++;
374         }
    // 最后一个字符处填入擦除字符(空格字符)。
375         *p = video_erase_char;
```

```
376 }
377
    //// 删除光标所在行。
    // 从光标所在行开始屏幕内容上卷一行。
378 static void delete_line(void)
379 {
380         int oldtop,oldbottom;
381
382         oldtop=top;                     // 保存原 top，bottom 值。
383         oldbottom=bottom;
384         top=y;                          // 设置屏幕卷动开始行。
385         bottom = video_num_lines;       // 设置屏幕卷动最后行。
386         scrup();                        // 从光标开始处，屏幕内容向上滚动一行。
387         top=oldtop;                     // 恢复原 top，bottom 值。
388         bottom=oldbottom;
389 }
390
    //// 在光标处插入 nr 个字符。
    // ANSI 转义字符序列：'ESC [n@ '。
    // 参数 nr = 上面 n。
391 static void csi_at(unsigned int nr)
392 {
    // 如果插入的字符数大于一行字符数，则截为一行字符数；若插入字符数 nr 为 0，则插入 1 个字符。
393         if (nr > video_num_columns)
394                 nr = video_num_columns;
395         else if (!nr)
396                 nr = 1;
    // 循环插入指定的字符数。
397         while (nr--)
398                 insert_char();
399 }
400
    //// 在光标位置处插入 nr 行。
    // ANSI 转义字符序列'ESC [nL'。
401 static void csi_L(unsigned int nr)
402 {
    // 如果插入的行数大于屏幕最多行数，则截为屏幕显示行数；若插入行数 nr 为 0，则插入 1 行。
403         if (nr > video_num_lines)
404                 nr = video_num_lines;
405         else if (!nr)
406                 nr = 1;
    // 循环插入指定行数 nr。
407         while (nr--)
408                 insert_line();
409 }
410
    //// 删除光标处的 nr 个字符。
    // ANSI 转义序列：'ESC [nP'。
411 static void csi_P(unsigned int nr)
412 {
    // 如果删除的字符数大于一行字符数，则截为一行字符数；若删除字符数 nr 为 0，则删除 1 个字符。
413         if (nr > video_num_columns)
414                 nr = video_num_columns;
```

```
415         else if (!nr)
416                 nr = 1;
    // 循环删除指定字符数 nr。
417         while (nr--)
418                 delete_char();
419 }
420
    //// 删除光标处的 nr 行。
    // ANSI 转义序列：'ESC [nM'。
421 static void csi_M(unsigned int nr)
422 {
    // 如果删除的行数大于屏幕最多行数，则截为屏幕显示行数；若删除的行数 nr 为 0，则删除 1 行。
423         if (nr > video_num_lines)
424                 nr = video_num_lines;
425         else if (!nr)
426                 nr=1;
    // 循环删除指定行数 nr。
427         while (nr--)
428                 delete_line();
429 }
430
431 static int saved_x=0;           // 保存的光标列号。
432 static int saved_y=0;           // 保存的光标行号。
433
    //// 保存当前光标位置。
434 static void save_cur(void)
435 {
436         saved_x=x;
437         saved_y=y;
438 }
439
    //// 恢复保存的光标位置。
440 static void restore_cur(void)
441 {
442         gotoxy(saved_x, saved_y);
443 }
444
    //// 控制台写函数。
    // 从终端对应的 tty 写缓冲队列中取字符，并显示在屏幕上。
445 void con_write(struct tty_struct * tty)
446 {
447         int nr;
448         char c;
449
    // 首先取得写缓冲队列中现有字符数 nr，然后针对每个字符进行处理。
450         nr = CHARS(tty->write_q);
451         while (nr--) {
    // 从写队列中取一字符 c，根据前面所处理字符的状态 state 分别处理。状态之间的转换关系为：
    // state = 0：初始状态；或者原是状态 4；或者原是状态 1，但字符不是'['；
    //         1：原是状态 0，并且字符是转义字符 ESC(0x1b = 033 = 27)；
    //         2：原是状态 1，并且字符是'['；
    //         3：原是状态 2；或者原是状态 3，并且字符是';'或数字。
    //         4：原是状态 3，并且字符不是';'或数字；
```

```
452                 GETCH(tty->write_q,c);
453                 switch(state) {
454                         case 0:
    // 如果字符不是控制字符(c>31)，并且也不是扩展字符(c<127)，则
455                                 if (c>31 && c<127) {
    // 若当前光标处在行末端或末端以外，则将光标移到下行头列。并调整光标位置对应的内存指针 pos。
456                                         if (x>=video_num_columns) {
457                                                 x -= video_num_columns;
458                                                 pos -= video_size_row;
459                                                 lf();
460                                         }
    // 将字符 c 写到显示内存中 pos 处，并将光标右移 1 列，同时也将 pos 对应地移动 2 个字节。
461                                         __asm__("movb _attr,%%ah\n\t"
462                                                 "movw %%ax,%1\n\t"
463                                                 ::"a" (c),"m" (*(short *)pos)
464                                                 :"ax");
465                                         pos += 2;
466                                         x++;
    // 如果字符 c 是转义字符 ESC，则转换状态 state 到 1。
467                                 } else if (c==27)
468                                         state=1;
    // 如果字符 c 是换行符(10)，或是垂直制表符 VT(11)，或者是换页符 FF(12)，则移动光标到下一行。
469                                 else if (c==10 || c==11 || c==12)
470                                         lf();
    // 如果字符 c 是回车符 CR(13)，则将光标移动到头列(0 列)。
471                                 else if (c==13)
472                                         cr();
    // 如果字符 c 是 DEL(127)，则将光标右边一字符擦除(用空格字符替代)，并将光标移到被擦除位置。
473                                 else if (c==ERASE_CHAR(tty))
474                                         del();
    // 如果字符 c 是 BS(backspace,8)，则将光标右移 1 格，并相应调整光标对应内存位置指针 pos。
475                                 else if (c==8) {
476                                         if (x) {
477                                                 x--;
478                                                 pos -= 2;
479                                         }
    // 如果字符 c 是水平制表符 TAB(9)，则将光标移到 8 的倍数列上。若此时光标列数超出屏幕最大列数，
    // 则将光标移到下一行上。
480                                 } else if (c==9) {
481                                         c=8-(x&7);
482                                         x += c;
483                                         pos += c<<1;
484                                         if (x>video_num_columns) {
485                                                 x -= video_num_columns;
486                                                 pos -= video_size_row;
487                                                 lf();
488                                         }
489                                         c=9;
    // 如果字符 c 是响铃符 BEL(7)，则调用蜂鸣函数，是扬声器发声。
490                                 } else if (c==7)
491                                         sysbeep();
492                                 break;
    // 如果原状态是 0，并且字符是转义字符 ESC(0x1b = 033 = 27)，则转到状态 1 处理。
```

```
493                         case 1:
494                                 state=0;
    // 如果字符 c 是'['，则将状态 state 转到 2。
495                                 if (c=='[')
496                                         state=2;
    // 如果字符 c 是'E'，则光标移到下一行开始处(0 列)。
497                                 else if (c=='E')
498                                         gotoxy(0,y+1);
    // 如果字符 c 是'M'，则光标上移一行。
499                                 else if (c=='M')
500                                         ri();
    // 如果字符 c 是'D'，则光标下移一行。
501                                 else if (c=='D')
502                                         lf();
    // 如果字符 c 是'Z'，则发送终端应答字符序列。
503                                 else if (c=='Z')
504                                         respond(tty);
    // 如果字符 c 是'7'，则保存当前光标位置。注意这里代码写错！应该是(c=='7')。
505                                 else if (x=='7')
506                                         save_cur();
    // 如果字符 c 是'8'，则恢复到原保存的光标位置。注意这里代码写错！应该是(c=='8')。
507                                 else if (x=='8')
508                                         restore_cur();
509                                 break;
    // 如果原状态是 1，并且上一字符是'['，则转到状态 2 来处理。
510                         case 2:
    // 首先对 ESC 转义字符序列参数使用的处理数组 par[]清零，索引变量 npar 指向首项，并且设置状态
    // 为 3。若此时字符不是'?'，则直接转到状态 3 去处理，否则去读一字符，再到状态 3 处理代码处。
511                                 for(npar=0;npar<NPAR;npar++)
512                                         par[npar]=0;
513                                 npar=0;
514                                 state=3;
515                                 if (ques=(c=='?'))
516                                         break;
    // 如果原来是状态 2；或者原来就是状态 3，但原字符是';'或数字，则在下面处理。
517                         case 3:
    // 如果字符 c 是分号';'，并且数组 par 未满，则索引值加 1。
518                                 if (c==';' && npar<NPAR-1) {
519                                         npar++;
520                                         break;
    // 如果字符 c 是数字字符'0'-'9'，则将该字符转换成数值并与 npar 所索引的项组成 10 进制数。
521                                 } else if (c>='' && c<='9') {
522                                         par[npar]=10*par[npar]+c-'';
523                                         break;
    // 否则转到状态 4。
524                                 } else state=4;
    // 如果原状态是状态 3，并且字符不是';'或数字，则转到状态 4 处理。首先复位状态 state=0。
525                         case 4:
526                                 state=0;
527                                 switch(c) {
    // 如果字符 c 是'G'或'`'，则 par[]中第一个参数代表列号。若列号不为零，则将光标右移一格。
528                                         case 'G': case '`':
529                                                 if (par[0]) par[0]--;
```

```
530                                             gotoxy(par[0],y);
531                                             break;
    // 如果字符 c 是'A'，则第一个参数代表光标上移的行数。若参数为 0 则上移一行。
532                                     case 'A':
533                                             if (!par[0]) par[0]++;
534                                             gotoxy(x,y-par[0]);
535                                             break;
    // 如果字符 c 是'B'或'e'，则第一个参数代表光标下移的行数。若参数为 0 则下移一行。
536                                     case 'B': case 'e':
537                                             if (!par[0]) par[0]++;
538                                             gotoxy(x,y+par[0]);
539                                             break;
    // 如果字符 c 是'C'或'a'，则第一个参数代表光标右移的格数。若参数为 0 则右移一格。
540                                     case 'C': case 'a':
541                                             if (!par[0]) par[0]++;
542                                             gotoxy(x+par[0],y);
543                                             break;
    // 如果字符 c 是'D'，则第一个参数代表光标左移的格数。若参数为 0 则左移一格。
544                                     case 'D':
545                                             if (!par[0]) par[0]++;
546                                             gotoxy(x-par[0],y);
547                                             break;
    // 如果字符 c 是'E'，则第一个参数代表光标向下移动的行数，并回到 0 列。若参数为 0 则下移一行。
548                                     case 'E':
549                                             if (!par[0]) par[0]++;
550                                             gotoxy(0,y+par[0]);
551                                             break;
    // 如果字符 c 是'F'，则第一个参数代表光标向上移动的行数，并回到 0 列。若参数为 0 则上移一行。
552                                     case 'F':
553                                             if (!par[0]) par[0]++;
554                                             gotoxy(0,y-par[0]);
555                                             break;
    // 如果字符 c 是'd'，则第一个参数代表光标所需在的行号(从 0 计数)。
556                                     case 'd':
557                                             if (par[0]) par[0]--;
558                                             gotoxy(x,par[0]);
559                                             break;
    // 如果字符 c 是'H'或'f'，则第一个参数代表光标移到的行号，第二个参数代表光标移到的列号。
560                                     case 'H': case 'f':
561                                             if (par[0]) par[0]--;
562                                             if (par[1]) par[1]--;
563                                             gotoxy(par[1],par[0]);
564                                             break;
    // 如果字符 c 是'J'，则第一个参数代表以光标所处位置清屏的方式：
    // ANSI 转义序列：'ESC [sJ'(s = 0 删除光标到屏幕底端；1 删除屏幕开始到光标处；2 整屏删除)。
565                                     case 'J':
566                                             csi_J(par[0]);
567                                             break;
    // 如果字符 c 是'K'，则第一个参数代表以光标所在位置对行中字符进行删除处理的方式。
    // ANSI 转义字符序列：'ESC [sK'(s = 0 删除到行尾；1 从开始删除；2 整行都删除)。
568                                     case 'K':
569                                             csi_K(par[0]);
570                                             break;
```

```
    // 如果字符 c 是'L'，表示在光标位置处插入 n 行(ANSI 转义字符序列'ESC [nL')。
571                                     case 'L':
572                                             csi_L(par[0]);
573                                             break;
    // 如果字符 c 是'M'，表示在光标位置处删除 n 行(ANSI 转义字符序列'ESC [nM')。
574                                     case 'M':
575                                             csi_M(par[0]);
576                                             break;
    // 如果字符 c 是'P'，表示在光标位置处删除 n 个字符(ANSI 转义字符序列'ESC [nP')。
577                                     case 'P':
578                                             csi_P(par[0]);
579                                             break;
    // 如果字符 c 是'@'，表示在光标位置处插入 n 个字符(ANSI 转义字符序列'ESC [n@')。
580                                     case '@':
581                                             csi_at(par[0]);
582                                             break;
    // 如果字符 c 是'm'，表示改变光标处字符的显示属性，比如加粗、加下划线、闪烁、反显等。
    // ANSI 转义字符序列：'ESC [nm'。n = 0 正常显示；1 加粗；4 加下划线；7 反显；27 正常显示。
583                                     case 'm':
584                                             csi_m();
585                                             break;
    // 如果字符 c 是'r'，则表示用两个参数设置滚屏的起始行号和终止行号。
586                                     case 'r':
587                                             if (par[0]) par[0]--;
588                                             if (!par[1]) par[1] = video_num_lines;
589                                             if (par[0] < par[1] &&
590                                                 par[1] <= video_num_lines) {
591                                                     top=par[0];
592                                                     bottom=par[1];
593                                             }
594                                             break;
    // 如果字符 c 是's'，则表示保存当前光标所在位置。
595                                     case 's':
596                                             save_cur();
597                                             break;
    // 如果字符 c 是'u'，则表示恢复光标到原保存的位置处。
598                                     case 'u':
599                                             restore_cur();
600                                             break;
601                                     }
602                             }
603                     }
    // 最后根据上面设置的光标位置，向显示控制器发送光标显示位置。
604                     set_cursor();
605 }
606
607 /*
608  *  void con_init(void);
609  *
610  * This routine initalizes console interrupts, and does nothing
611  * else. If you want the screen to clear, call tty_write with
612  * the appropriate escape-sequece.
613  *
```

```
614  * Reads the information preserved by setup.s to determine the current display
615  * type and sets everything accordingly.
616  */
     /*
      * void con_init(void);
      * 这个子程序初始化控制台中断，其他什么都不做。如果你想让屏幕干净的话，就使用
      * 适当的转义字符序列调用 tty_write()函数。
      *
      * 读取 setup.s 程序保存的信息，用以确定当前显示器类型，并且设置所有相关参数。
      */
617  void con_init(void)
618  {
619          register unsigned char a;
620          char *display_desc = "????";
621          char *display_ptr;
622
623          video_num_columns = ORIG_VIDEO_COLS;        // 显示器显示字符列数。
624          video_size_row = video_num_columns * 2;     // 每行需使用字节数。
625          video_num_lines = ORIG_VIDEO_LINES;         // 显示器显示字符行数。
626          video_page = ORIG_VIDEO_PAGE;               // 当前显示页面。
627          video_erase_char = 0x0720;                  // 擦除字符(0x20 显示字符， 0x07 是属性)。
628
     // 如果原始显示模式等于 7，则表示是单色显示器。
629          if (ORIG_VIDEO_MODE == 7)                   /* Is this a monochrome display? */
630          {
631                  video_mem_start = 0xb0000;          // 设置单显映像内存起始地址。
632                  video_port_reg = 0x3b4;             // 设置单显索引寄存器端口。
633                  video_port_val = 0x3b5;             // 设置单显数据寄存器端口。
     // 根据 BIOS 中断 int 0x10 功能 0x12 获得的显示模式信息，判断显示卡单色显示卡还是彩色显示卡。
     // 如果使用上述中断功能所得到的 BX 寄存器返回值不等于 0x10，则说明是 EGA 卡。因此初始
     // 显示类型为 EGA 单色；所使用映像内存末端地址为 0xb8000；并置显示器描述字符串为'EGAm'。
     // 在系统初始化期间显示器描述字符串将显示在屏幕的右上角。
634                  if ((ORIG_VIDEO_EGA_BX & 0xff) != 0x10)
635                  {
636                          video_type = VIDEO_TYPE_EGAM;  // 设置显示类型(EGA 单色)。
637                          video_mem_end = 0xb8000;       // 设置显示内存末端地址。
638                          display_desc = "EGAm";         // 设置显示描述字符串。
639                  }
     // 如果 BX 寄存器的值等于 0x10，则说明是单色显示卡 MDA。则设置相应参数。
640                  else
641                  {
642                          video_type = VIDEO_TYPE_MDA;   // 设置显示类型(MDA 单色)。
643                          video_mem_end    = 0xb2000;    // 设置显示内存末端地址。
644                          display_desc = "*MDA";         // 设置显示描述字符串。
645                  }
646          }
     // 如果显示模式不为 7，则为彩色模式。此时所用的显示内存起始地址为 0xb800；显示控制索引寄存
     // 器端口地址为 0x3d4；数据寄存器端口地址为 0x3d5。
647          else                                        /* If not, it is color. */
648          {
649                  video_mem_start = 0xb8000;          // 显示内存起始地址。
650                  video_port_reg  = 0x3d4;            // 设置彩色显示索引寄存器端口。
651                  video_port_val  = 0x3d5;            // 设置彩色显示数据寄存器端口。
```

```
    // 再判断显示卡类别。如果 BX 不等于 0x10，则说明是 EGA 显示卡。
652                 if ((ORIG_VIDEO_EGA_BX & 0xff) != 0x10)
653                 {
654                         video_type = VIDEO_TYPE_EGAC;   // 设置显示类型(EGA 彩色)。
655                         video_mem_end = 0xbc000;        // 设置显示内存末端地址。
656                         display_desc = "EGAc";          // 设置显示描述字符串。
657                 }
    // 如果 BX 寄存器的值等于 0x10，则说明是 CGA 显示卡。则设置相应参数。
658                 else
659                 {
660                         video_type = VIDEO_TYPE_CGA;    // 设置显示类型(CGA)。
661                         video_mem_end = 0xba000;        // 设置显示内存末端地址。
662                         display_desc = "*CGA";          // 设置显示描述字符串。
663                 }
664         }
665
666         /* Let the user known what kind of display driver we are using */
            /* 让用户知道我们正在使用哪一类显示驱动程序 */
667
    // 在屏幕的右上角显示显示描述字符串。采用的方法是直接将字符串写到显示内存的相应位置处。
    // 首先将显示指针 display_ptr 指到屏幕第一行右端差 4 个字符处(每个字符需 2 个字节，因此减 8)。
668         display_ptr = ((char *)video_mem_start) + video_size_row - 8;
    // 然后循环复制字符串中的字符，并且每复制一个字符都空开一个属性字节。
669         while (*display_desc)
670         {
671                 *display_ptr++ = *display_desc++;       // 复制字符。
672                 display_ptr++;                          // 空开属性字节位置。
673         }
674
675         /* Initialize the variables used for scrolling (mostly EGA/VGA) */
            /* 初始化用于滚屏的变量(主要用于 EGA/VGA) */
676
677         origin  = video_mem_start;                  // 滚屏起始显示内存地址。
678         scr_end = video_mem_start + video_num_lines * video_size_row;  // 滚屏结束内存地址。
679         top     = 0;                                // 最顶行号。
680         bottom  = video_num_lines;                  // 最底行号。
681
682         gotoxy(ORIG_X,ORIG_Y);                      // 初始化光标位置 x,y 和对应的内存位置 pos。
683         set_trap_gate(0x21,&keyboard_interrupt);    // 设置键盘中断陷阱门(system.h，36 行)。
684         outb_p(inb_p(0x21)&0xfd,0x21);              // 取消 8259A 中对键盘中断的屏蔽，允许 IRQ1。
685         a=inb_p(0x61);                              // 延迟读取键盘端口 0x61(8255A 端口 PB)。
686         outb_p(a|0x80,0x61);                        // 设置禁止键盘工作(位 7 置位)，
687         outb(a,0x61);                               // 再允许键盘工作，用以复位键盘操作。
688 }
689 /* from bsd-net-2: */
690
    //// 停止蜂鸣。
    // 复位 8255A PB 端口的位 1 和位 0。
691 void sysbeepstop(void)
692 {
693         /* disable counter 2 */ /* 禁止定时器 2 */
694         outb(inb_p(0x61)&0xFC, 0x61);
695 }
```

```
696
697 int beepcount = 0;
698
    // 开通蜂鸣。
    // 8255A 芯片 PB 端口的位 1 用作扬声器的开门信号；位 0 用作 8253 定时器 2 的门信号，该定时器的
    // 输出脉冲送往扬声器，作为扬声器发声的频率。因此要使扬声器蜂鸣，需要两步：首先开启 PB 端口
    // 位 1 和位 0（置位），然后设置定时器发送一定的定时频率即可。
699 static void sysbeep(void)
700 {
701         /* enable counter 2 */  /* 开启定时器 2 */
702         outb_p(inb_p(0x61)|3, 0x61);
703         /* set command for counter 2, 2 byte write */  /* 送设置定时器 2 命令 */
704         outb_p(0xB6, 0x43);
705         /* send 0x637 for 750 HZ */  /* 设置频率为 750HZ，因此送定时值 0x637 */
706         outb_p(0x37, 0x42);
707         outb(0x06, 0x42);
708         /* 1/8 second */  /* 蜂鸣时间为 1/8 秒 */
709         beepcount = HZ/8;
710 }
711
```

7.5.3 其他信息

7.5.3.1 显示控制卡编程

这里仅给出和说明兼容显示卡端口的说明。描述了 MDA、CGA、EGA 和 VGA 显示控制卡的通用编程端口，这些端口都是与 CGA 使用的 MC6845 芯片兼容，其名称和用途见表 7–5 所示。其中以 CGA/EGA/VGA 的端口(0x3d0-0x3df)为例进行说明，MDA 的端口是 0x3b0 - 0x3bf。

对显示控制卡进行编程的基本步骤是：首先写显示卡的索引寄存器，选择要进行设置的显示控制内部寄存器之一(r0-r17)，然后将参数写到其数据寄存器端口。也即显示卡的数据寄存器端口每次只能对显示卡中的一个内部寄存器进行操作。内部寄存器见表 7–6 所示。

表 7 - 5 CGA 端口寄存器名称及作用

端口	读/写	名称和用途
0x3d4	写	CRT(6845)索引寄存器。用于选择通过端口 0x3b5 访问的各个数据寄存器(r0-r17)。
0x3d5	写	CRT(6845)数据寄存器。其中数据寄存器 r12-r15 还可以读。 各个数据寄存器的功能说明见下表。
0x3d8	读/写	模式控制寄存器。 位 7-6 未用； 位 5=1 允许闪烁； 位 4=1 640*200 图形模式； 位 3=1 允许视频； 位 2=1 单色显示； 位 1=1 图形模式；=0 文本模式； 位 0=1 80*25 文本模式；=0 40*25 文本模式。
0x3d9	读/写	CGA 调色板寄存器。选择所采用的色彩。 位 7-6 未用；

		位 5=1 激活色彩集：青(cyan)、紫(magenta)、白(white)； =0 激活色彩集：红(red)、绿(green)、蓝(blue)； 位 4=1 增强显示图形、文本背景色彩； 位 3=1 增强显示 40*25 的边框、320*200 的背景、640*200 的前景颜色； 位 2=1 显示红色：40*25 的边框、320*200 的背景、640*200 的前景； 位 1=1 显示绿色：40*25 的边框、320*200 的背景、640*200 的前景； 位 0=1 显示蓝色：40*25 的边框、320*200 的背景、640*200 的前景；
0x3da	读	CGA 显示状态寄存器。 位 7-4 未用； 位 3=1 在垂直回扫阶段； 位 2=1 光笔开关关闭；=0 光笔开关接通； 位 1=1 光笔选通有效； 位 0=1 可以不干扰显示访问显示内存；=0 此时不要使用显示内存。
0x3db	写	清除光笔锁存（复位光笔寄存器）。
0x3dc	读/写	预设置光笔锁存（强制光笔选通有效）。

表 7－6 MC6845 内部数据寄存器及初始值

编号	名称	单位	读/写	40*25 模式	80*25 模式	图形模式
r0	水平字符总数	字符	写	0x38	0x71	0x38
r1	水平显示字符数	字符	写	0x28	0x50	0x28
r2	水平同步位置	字符	写	0x2d	0x5a	0x2d
r3	水平同步脉冲宽度	字符	写	0x0a	0x0a	0x0a
r4	垂直字符总数	字符行	写	0x1f	0x1f	0x7f
r5	垂直同步脉冲宽度	扫描行	写	0x06	0x06	0x06
r6	垂直显示字符数	字符行	写	0x19	0x19	0x64
r7	垂直同步位置	字符行	写	0x1c	0x1c	0x70
r8	隔行/逐行选择		写	0x02	0x02	0x02
r9	最大扫描行数	扫描行	写	0x07	0x07	0x01
r10	光标开始位置	扫描行	写	0x06	0x06	0x06
r11	光标结束位置	扫描行	写	0x07	0x07	0x07
r12	显示内存起始位置(高)		写	0x00	0x00	0x00
r13	显示内存末端位置(低)		写	0x00	0x00	0x00
r14	光标当前位置(高)		读/写	可变		
r15	光标当前位置(低)		读/写			
r16	光笔当前位置(高)		读	可变		
r17	光笔当前位置(低)		读			

7.5.3.2 滚屏操作原理

滚屏操作是指将指定开始行和结束行的一块文本内容向上移动(向上卷动 scroll up)或向下移动(向下卷动 scroll down)，如果将屏幕看作是显示内存上对应屏幕内容的一个窗口的话，那么将屏幕内容向上移即是将窗口沿显示内存向下移动；将屏幕内容向下移动即是将窗口向下移动。在程序中就是重新设置显示控制器中显示内存的起始位置 origin 以及调整程序中相应的变量。对于这两种操作各自都有两种情况。

对于向上卷动，当屏幕对应的显示内存窗口在向下移动后仍然在显示内存范围之内的情况，也即对应当前屏幕的内存块位置始终在显示内存起始位置(video_mem_start)和末端位置 video_mem_end 之间，那么只需要调整显示控制器中起始显示内存位置即可。但是当对应屏幕的内存块位置在向下移动时超出了实际显示内存的末端(video_mem_end)这种情况，就需要移动对应显示内存中的数据，以保证所有当前屏幕数据都落在显示内存范围内。在这第二中情况，程序中是将屏幕对应的内存数据移动到实际显示内存的开始位置处(video_mem_start)。

程序中实际的处理过程分三步进行。首先调整屏幕显示起始位置 origin；然后判断对应屏幕内存数据是否超出显示内存下界(video_mem_end)，如果超出就将屏幕对应的内存数据移动到实际显示内存的开始位置处(video_mem_start)；最后对移动后屏幕上出现的新行用空格字符填满。见图 7-7 所示。其中图(a)对应第一种简单情况，图(b)对应需要移动内存数据时的情况。

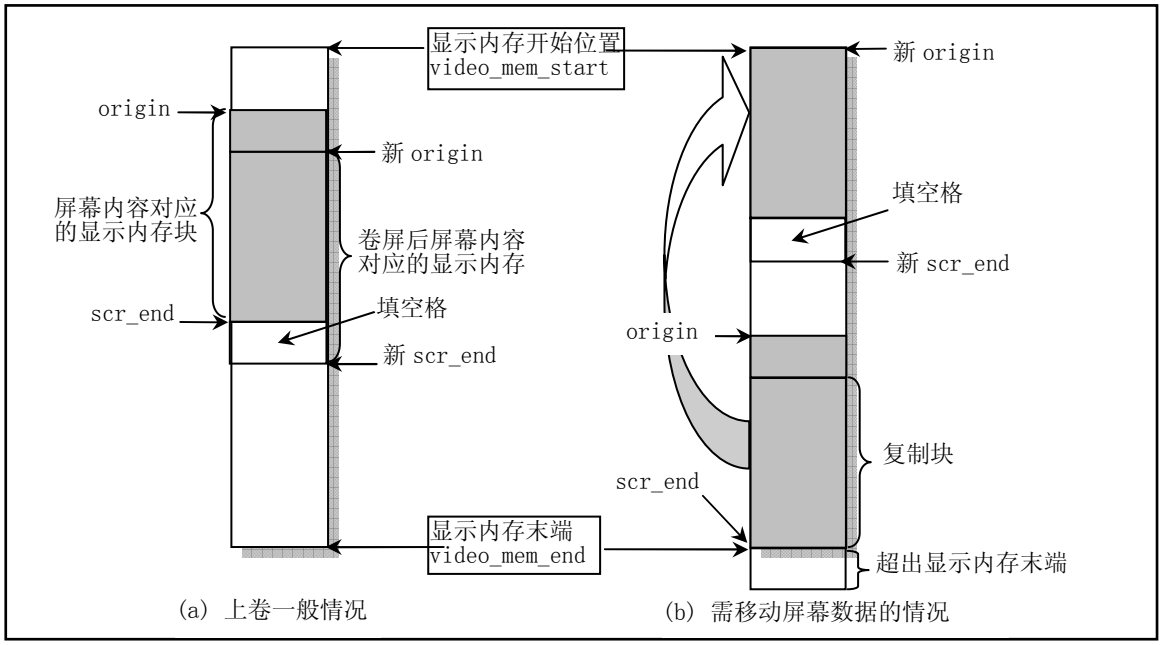

图 7-7 向上卷屏(scroll up)操作示意图

向下卷动屏幕的操作与向上卷屏相似，也会遇到这两种类似情况，只是由于屏幕窗口上移，因此会在屏幕上方出现一空行，并且在屏幕内容所对应的内存超出显示内存范围时需要将屏幕数据内存块往下移动到显示内存的末端位置。

7.5.3.3 ANSI 转义控制序列

终端通常有两部分功能，分别作为计算机信息的输入设备(键盘)和输出设置(显示器)。终端可有许多控制命令，使得终端执行一定的操作而不是仅仅在屏幕上显示一个字符。使用这种方式，计算机就可以命令终端执行移动光标、切换显示模式和响铃等操作。为了能理解程序的执行处理过程，下面对终端控制命令进行一些简单描述。首先说明控制字符和控制序列的含义。

控制字符是指 ASCII 码表开头的 32 个字符(0x00 - 0x1f 或 0-31)以及字符 DEL(0x7f 或 127)，参见附录中的 ASCII 码表。通常一个指定类型的终端都会采用其中的一个子集作为控制字符，而其他的控制字符将不起作用。例如，对于 VT100 终端所采用的控制字符见表 7–7 所示。

表 7－7 控制字符

控制字符	八进制	十六进制	采取的行动
NUL	000	0x00	在输入时忽略（不保存在输入缓冲中）。
ENQ	005	0x05	传送应答消息。
BEL	007	0x07	从键盘发声响。
BS	010	0x08	将光标移向左边一个字符位置处。若光标已经处在左边沿，则无动作。
HT	011	0x09	将光标移到下一个制表位。若右侧已经没有制表位，则移到右边缘处。
LF	012	0x0a	此代码导致一个回车或换行操作（见换行模式）。
VT	013	0x0b	作用如 LF。
FF	014	0x0c	作用如 LF。
CR	015	0x0d	将光标移到当前行的左边缘处。
SO	016	0x0e	使用由 SCS 控制序列设计的 G1 字符集。
SI	017	0x0f	选择 G0 字符集。由 ESC 序列选择。
XON	021	0x11	使终端重新进行传输。
XOFF	023	0x13	使中断除发送 XOFF 和 XON 以外，停止发送其他所有代码。
CAN	030	0x18	如果在控制序列期间发送，则序列不会执行而立刻终止。同时会显示出错字符。
SUB	032	0x1a	作用同 CAN。
ESC	033	0x1b	产生一个控制序列。
DEL	177	0x7f	在输入时忽略（不保存在输入缓冲中）。

控制序列已经由 ANSI(美国国家标准局 American National Standards Institute)制定为标准：X3.64-1977。控制序列是指由一些非控制字符构成的一个特殊字符序列，终端在收到这个序列时并不是将它们直接显示在屏幕上，而是采取一定的控制操作，比如，移动光标、删除字符、删除行、插入字符或插入行等操作。ANSI 控制序列由以下一些基本元素组成：

控制序列引入码(Control Sequence Introducer - CSI)：表示一个转移序列，提供辅助的控制并且本身是影响随后一系列连续字符含义解释的前缀。通常，一般 CSI 都使用 ESC [。

参数(Parameter)：零个或多个数字字符组成的一个数值。

数值参数(Numeric Parameter)：表示一个数的参数，使用 n 表示。

选择参数(Selective Parameter)：用于从一功能子集中选择一个子功能，一般用 s 表示。通常，具有多个选择参数的一个控制序列所产生的作用，如同分立的几个控制序列。例如：CSI sa;sb;sc F 的作用是与 CSI sa F CSI sb F CSI sc F 完全一样的。

参数字符串(Parameter String)：用分号';'隔开的参数字符串。

默认值(Default)：当没有明确指定一个值或者值是 0 的话，就会指定一个与功能相关的值。

最后字符(Final character)：用于结束一个转义或控制序列。

图 7-8 中是一个控制序列的例子：取消所有字符的属性，然后开启下划线和反显属性。ESC [0;4;7m

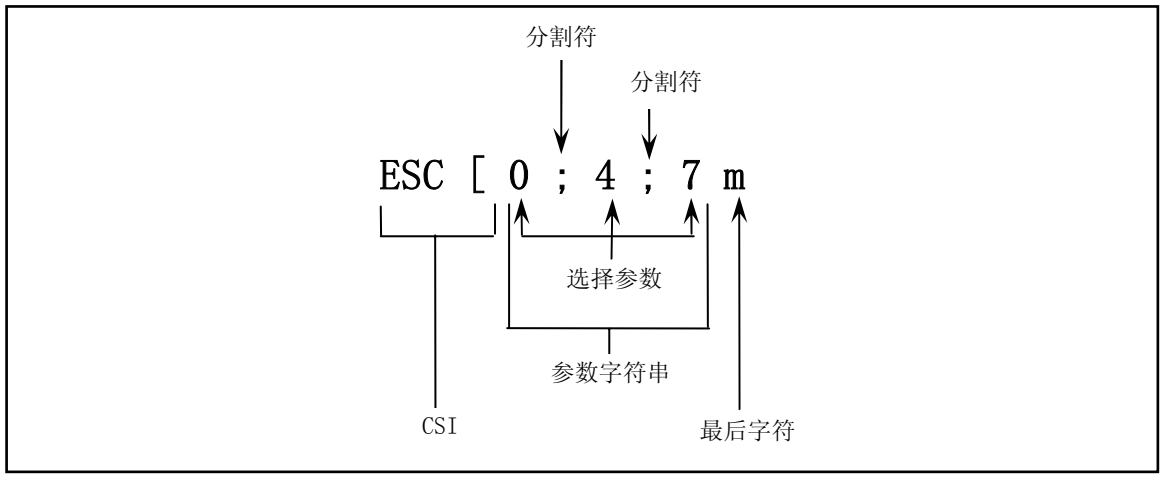

图 7-8 控制序列例子

表 7–8 是一些常用的控制序列列表。其中 E 表示 0x1b，如果 n 是 0 的话，则可以省略：E[0J == E[J

表 7－8 常用控制序列

转义序列	功能	转义序列	功能
E[nA	光标上移 n 行	E[nK	删除部分或整行：
E[nB	光标下移 n 行		n = 0 从光标处到行末端
E[nC	光标右移 n 个字符位置		n = 1 从行开始到光标处
E[nD	光标左移 n 个字符位置		n = 2 整行
E[n`	光标移动到字符 n 位置	E[nX	删除 n 个字符
E[na	光标右移 n 个字符位置	E[nS	向上卷屏 n 行（屏幕下移）
E[nd	光标移动到行 n 上	E[nT	向下卷屏 n 行（屏幕上移）
E[ne	光标下移 n 行	E[nm	设置字符显示属性：
E[nF	光标上移 n 行，停在行开始处		n = 0 普通属性（无属性）
E[nE	光标下移 n 行，停在行开始处		n = 1 粗（bold）
E[y;xH	光标移到 x,y 位置		n = 4 下划线（underscore）
E[H	光标移到屏幕左上角		n = 5 闪烁（blink）
E[y;xf	光标移到位置 x,y		n = 7 反显（reverse）
E[nZ	光标后移 n 制表位		n = 3X 设置前台显示色彩
E[nL	插入 n 条空白行		n = 4X 设置后台显示色彩
E[n@	插入 n 个空格字符		X = 0 黑 black X = 1 红 red
E[nM	删除 n 行		X = 2 绿 green X = 3 棕 brown
E[nP	删除 n 个字符		X = 4 蓝 blue X = 5 紫 magenta
E[nJ	檫除部分或全部显示字符：		X = 6 青 cyan X = 7 白 white
	n = 0 从光标处到屏幕底部；		使用分号可以同时设置多个属性，
	n = 1 从屏幕上端到光标处；		例如：E[0;1;33;40m
	n = 2 屏幕上所有字符。	E[s	保存光标位置
		E[u	恢复保存的光标位置

7.6 serial.c 程序

7.6.1 功能描述

本程序实现系统串行端口初始化，为使用串行终端设备作好准备工作。在 rs_init()初始化函数中，设置了默认的串行通信参数，并设置串行端口的中断陷阱门（中断向量）。rs_write()函数用于把串行终端设备写缓冲队列中的字符通过串行线路发送给远端的终端设备。

rs_write()将在文件系统中用于操作字符设备文件时被调用。当一个程序往串行设备/dev/tty64 文件执行写操作时，就会执行系统调用 sys_write()（在 fs/read_write.c 中），而这个系统调用在判别出所读文件是一个字符设备文件时，即会调用 rw_char()函数（在 fs/char_dev.c 中），该函数则会根据所读设备的子设备号等信息，由字符设备读写函数表（设备开关表）调用 rw_tty()，最终调用到这里的串行终端写操作函数 rs_write()。

rs_write()函数实际上只是开启串行发送保持寄存器已空中断标志，在 UART 将数据发送出去后允许发中断信号。具体发送操作是在 rs_io.s 程序中完成。

7.6.2 代码注释

程序 7-4 linux/kernel/chr_drv/serial.c

```
 1 /*
 2  *  linux/kernel/serial.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  *      serial.c
 9  *
10  * This module implements the rs232 io functions
11  *      void rs_write(struct tty_struct * queue);
12  *      void rs_init(void);
13  * and all interrupts pertaining to serial IO.
14  */
   /*
    *     serial.c
    * 该程序用于实现 rs232 的输入输出功能
    *     void rs_write(struct tty_struct *queue);
    *     void rs_init(void);
    * 以及与传输 IO 有关系的所有中断处理程序。
    */
15
16 #include <linux/tty.h>    // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
17 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
18 #include <asm/system.h>   // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
19 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
20
21 #define WAKEUP_CHARS (TTY_BUF_SIZE/4)  // 当写队列中含有 WAKEUP_CHARS 个字符时，就开始发送。
22
```

```
23 extern void rs1_interrupt(void);        // 串行口 1 的中断处理程序(rs_io.s, 34)。
24 extern void rs2_interrupt(void);        // 串行口 2 的中断处理程序(rs_io.s, 38)。
25
   //// 初始化串行端口
   // port: 串口 1 - 0x3F8，串口 2 - 0x2F8。
26 static void init(int port)
27 {
28         outb_p(0x80,port+3);     /* set DLAB of line control reg */
                                    /* 设置线路控制寄存器的 DLAB 位(位 7) */
29         outb_p(0x30,port);       /* LS of divisor (48 -> 2400 bps */
                                    /* 发送波特率因子低字节，0x30->2400bps */
30         outb_p(0x00,port+1);     /* MS of divisor */
                                    /* 发送波特率因子高字节，0x00 */
31         outb_p(0x03,port+3);     /* reset DLAB */
                                    /* 复位 DLAB 位，数据位为 8 位 */
32         outb_p(0x0b,port+4);     /* set DTR,RTS, OUT_2 */
                                    /* 设置 DTR，RTS，辅助用户输出 2 */
33         outb_p(0x0d,port+1);     /* enable all intrs but writes */
                                    /* 除了写(写保持空)以外，允许所有中断源中断 */
34         (void)inb(port);         /* read data port to reset things (?) */
                                    /* 读数据口，以进行复位操作(?) */
35 }
36
   //// 初始化串行中断程序和串行接口。
   // 中断描述符表 IDT 中的中断门描述符设置宏 set_intr_gate()在 include/asm/system.h 中实现。
37 void rs_init(void)
38 {
39         set_intr_gate(0x24,rs1_interrupt);   // 设置串行口 1 的中断门向量(硬件 IRQ4 信号)。
40         set_intr_gate(0x23,rs2_interrupt);   // 设置串行口 2 的中断门向量(硬件 IRQ3 信号)。
41         init(tty_table[1].read_q.data);      // 初始化串行口 1(.data 是端口号)。
42         init(tty_table[2].read_q.data);      // 初始化串行口 2。
43         outb(inb_p(0x21)&0xE7,0x21);         // 允许主 8259A 芯片的 IRQ3，IRQ4 中断信号请求。
44 }
45
46 /*
47  * This routine gets called when tty_write has put something into
48  * the write_queue. It must check wheter the queue is empty, and
49  * set the interrupt register accordingly
50  *
51  *      void _rs_write(struct tty_struct * tty);
52  */
   /*
    * 在 tty_write()已将数据放入输出(写)队列时会调用下面的子程序。必须首先
    * 检查写队列是否为空，并相应设置中断寄存器。
    */
   //// 串行数据发送输出。
   // 实际上只是开启串行发送保持寄存器已空中断标志，在 UART 将数据发送出去后允许发中断信号。
53 void rs_write(struct tty_struct * tty)
54 {
55         cli();                           // 关中断。
   // 如果写队列不空，则从 0x3f9(或 0x2f9) 首先读取中断允许寄存器内容，添上发送保持寄存器中断
   // 允许标志（位 1）后，再写回该寄存器。这样就会让串行设备由于要写（发送）字符而引发中断。
56         if (!EMPTY(tty->write_q))
```

```
57                  outb(inb_p(tty->write_q.data+1)|0x02,tty->write_q.data+1);
58          sti();                          // 开中断。
59 }
60
```

7.6.3 其他信息

7.6.3.1 异步串行通信芯片 UART

PC 微机的串行通信使用的异步串行通信芯片是 INS 8250 或 NS16450 兼容芯片，统称为 UART(通用异步接收发送器)。对 UART 的编程实际上是对其内部寄存器执行读写操作。因此可将 UART 看作是一组寄存器集合，包含发送、接收和控制三部分。UART 内部有 10 个寄存器，供 CPU 通过 IN/OUT 指令对其进行访问。这些寄存器的端口和用途见表 7–9 所示。其中端口 0x3f8-0x3fe 用于微机上 COM1 串行口，0x2f8-0x2fe 对应 COM2 端口。条件 DLAB(Divisor Latch Access Bit)是除数锁存访问位，是指线路控制寄存器的位 7。

表 7－9 UART 内部寄存器对应端口及用途

端口	读/写	条件	用途
0x3f8 (0x2f8)	写	DLAB=0	写发送保持寄存器。含有将发送的字符。
	读	DLAB=0	读接收缓存寄存器。含有收到的字符。
	读/写	DLAB=1	读/写波特率因子低字节（LSB）。
0x3f9 (0x2f9)	读/写	DLAB=1	读/写波特率因子高字节（MSB）。
	读/写	DLAB=0	读/写中断允许寄存器。 位 7-4 全 0 保留不用； 位 3=1 modem 状态中断允许； 位 2=1 接收器线路状态中断允许； 位 1=1 发送保持寄存器空中断允许； 位 0=1 已接收到数据中断允许。
0x3fa (0x2fa)	读		读中断标识寄存器。中断处理程序用以判断此次中断是 4 种中的那一种。 位 7-3 全 0（不用）； 位 2-1 确定中断的优先级； = 11 接收状态有错中断，优先级最高； = 10 已接收到数据中断，优先级第 2； = 01 发送保持寄存器空中断，优先级第 3； = 00 modem 状态改变中断，优先级第 4。 位 0=0 有待处理中断；=1 无中断。
0x3fb (0x2fb)	写		写线路控制寄存器。 位 7=1 除数锁存访问位(DLAB)。 0 接收器，发送保持或中断允许寄存器访问； 位 6=1 允许间断； 位 5=1 保持奇偶位； 位 4=1 偶校验；=0 奇校验； 位 3=1 允许奇偶校验；=0 无奇偶校验； 位 2=1 1 位停止位；=0 无停止位； 位 1-0 数据位长度：

			= 00　5 位数据位； = 01　6 位数据位； = 10　7 位数据位； = 11　8 位数据位。
0x3fc (0x2fc)	写		写 modem 控制寄存器。 位 7-5 全 0 保留； 位 4=1 芯片处于循环反馈诊断操作模式； 位 3=1 辅助用户指定输出 2，允许 INTRPT 到系统； 位 2=1 辅助用户指定输出 1，PC 机未用； 位 1=1 使请求发送 RTS 有效； 位 0=1 使数据终端就绪 DTR 有效。
0x3fd (0x2fd)	读		读线路状态寄存器。 位 7=0 保留； 位 6=1 发送移位寄存器为空； 位 5=1 发送保持寄存器为空，可以取字符发送； 位 4=1 接收到满足间断条件的位序列； 位 3=1 帧格式错误； 位 2=1 奇偶校验错误； 位 1=1 超越覆盖错误； 位 0=1 接收器数据准备好，系统可读取。
0x3fe (0x2fe)	读		读 modem 状态寄存器。δ 表示信号发生变化。 位 7=1 载波检测(CD)有效； 位 6=1 响铃指示(RI)有效； 位 5=1 数据设备就绪(DSR)有效； 位 4=1 清除发送（CTS）有效； 位 3=1 检测到 δ 载波； 位 2=1 检测到响铃信号边沿； 位 1=1 δ 数据设备就绪(DSR)； 位 0=1 δ 清除发送(CTS)。

7.7 rs_io.s 程序

7.7.1 功能描述

该汇编程序实现 rs232 串行通信中断处理过程。在进行字符的传输和存储过程中，该中断过程主要对终端的读、写缓冲队列进行操作。它把从串行线路上接收到的字符存入串行终端的读缓冲队列 read_q 中，或把写缓冲队列 write_q 中需要发送出去的字符通过串行线路发送给远端的串行终端设备。

引起系统发生串行中断的情况有 4 种：a. 由于 modem 状态发生了变化；b. 由于线路状态发生了变化；c. 由于接收到字符；d. 由于在中断允许标志寄存器中设置了发送保持寄存器中断允许标志，需要发送字符。对引起中断的前两种情况的处理过程是通过读取对应状态寄存器值，从而使其复位。对于由于接收到字符的情况，程序首先把该字符放入读缓冲队列 read_q 中，然后调用 copy_to_cooked()函数转换成以字符行为单位的规范模式字符放入辅助队列 secondary 中。对于需要发送字符的情况，则程序首先

从写缓冲队列 write_q 尾指针处中取出一个字符发送出去，再判断写缓冲队列是否已空，若还有字符则循环执行发送操作。

因此，在阅读本程序之前，最好先看一下 include/linux/tty.h 头文件。其中给出了字符缓冲队列的数据结构 tty_queue、终端的数据结构 tty_struct 和一些控制字符的值。另外还有一些对缓冲队列进行操作的宏定义。缓冲队列及其操作示意图请参见图 7-9 所示。

7.7.2 代码注释

程序 7-5 linux/kernel/chr_drv/rs_io.s

```
1  /*
2   *  linux/kernel/rs_io.s
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   *      rs_io.s
9   *
10  * This module implements the rs232 io interrupts.
11  */
    /*
     * 该程序模块实现 rs232 输入输出中断处理程序。
     */
12
13 .text
14 .globl _rs1_interrupt,_rs2_interrupt
15
    // size 是读写队列缓冲区的字节长度。
16 size    = 1024                          /* must be power of two !    必须是 2 的次方并且需
17                                            and must match the value  与 tty_io.c 中的值匹配!
18                                            in tty_io.c!!! */
19
20 /* these are the offsets into the read/write buffer structures */
   /* 以下这些是读写缓冲结构中的偏移量 */
   // 对应定义在 include/linux/tty.h 文件中 tty_queue 结构中各变量的偏移量。
21 rs_addr = 0             // 串行端口号字段偏移（端口号是 0x3f8 或 0x2f8）。
22 head = 4               // 缓冲区中头指针字段偏移。
23 tail = 8               // 缓冲区中尾指针字段偏移。
24 proc_list = 12         // 等待该缓冲的进程字段偏移。
25 buf = 16               // 缓冲区字段偏移。
26
27 startup = 256          /* chars left in write queue when we restart it */
                          /* 当写队列里还剩 256 个字符空间(WAKEUP_CHARS)时，我们就可以写 */
28
29 /*
30  * These are the actual interrupt routines. They look where
31  * the interrupt is coming from, and take appropriate action.
32  */
   /*
    * 这些是实际的中断程序。程序首先检查中断的来源，然后执行相应
    * 的处理。
```

```
 */
33 .align 2
   //// 串行端口 1 中断处理程序入口点。
34 _rs1_interrupt:
35         pushl $_table_list+8    // tty 表中对应串口 1 的读写缓冲指针的地址入栈(tty_io.c，99)。
36         jmp rs_int              // 字符缓冲队列结构格式请参见 include/linux/tty.h，第 16 行。
37 .align 2
   //// 串行端口 2 中断处理程序入口点。
38 _rs2_interrupt:
39         pushl $_table_list+16   // tty 表中对应串口 2 的读写缓冲队列指针的地址入栈。
40 rs_int:
41         pushl %edx
42         pushl %ecx
43         pushl %ebx
44         pushl %eax
45         push %es
46         push %ds                /* as this is an interrupt, we cannot */
47         pushl $0x10             /* know that bs is ok. Load it */
48         pop %ds                 /* 由于这是一个中断程序，我们不知道 ds 是否正确，*/
49         pushl $0x10             /* 所以加载它们(让 ds、es 指向内核数据段 */
50         pop %es
51         movl 24(%esp),%edx      // 将缓冲队列指针地址存入 edx 寄存器，
                                   // 也即上面 35 或 39 行上最先压入堆栈的地址。
52         movl (%edx),%edx        // 取读缓冲队列结构指针(地址)➔edx。
                                   // 对于串行终端，data 字段存放着串行端口地址（端口号）。
53         movl rs_addr(%edx),%edx // 取串口 1（或串口 2）的端口号➔edx。
54         addl $2,%edx            /* interrupt ident. reg */  /* edx 指向中断标识寄存器 */
55 rep_int:                        // 中断标识寄存器端口是 0x3fa（0x2fa），参见上节列表后信息。
56         xorl %eax,%eax          // eax 清零。
57         inb %dx,%al             // 取中断标识字节，用以判断中断来源(有 4 种中断情况)。
58         testb $1,%al            // 首先判断有无待处理的中断(位 0=1 无中断；=0 有中断)。
59         jne end                 // 若无待处理中断，则跳转至退出处理处 end。
60         cmpb $6,%al             /* this shouldn't happen, but ... */ /* 这不会发生，但是…*/
61         ja end                  // al 值>6? 是则跳转至 end（没有这种状态）。
62         movl 24(%esp),%ecx      // 再取缓冲队列指针地址➔ecx。
63         pushl %edx              // 将中断标识寄存器端口号 0x3fa(0x2fa)入栈。
64         subl $2,%edx            // 0x3f8(0x2f8)。
65         call jmp_table(,%eax,2) /* NOTE! not *4, bit0 is 0 already */ /* 不乘 4，位 0 已是 0*/
   // 上面语句是指，当有待处理中断时，al 中位 0=0，位 2-1 是中断类型，因此相当于已经将中断类型
   // 乘了 2，这里再乘 2，获得跳转表（第 79 行）对应各中断类型地址，并跳转到那里去作相应处理。
   // 中断来源有 4 种：modem 状态发生变化；要写（发送）字符；要读（接收）字符；线路状态发生变化。
   // 要发送字符中断是通过设置发送保持寄存器标志实现的。在 serial.c 程序中的 rs_write()函数中，
   // 当写缓冲队列中有数据时，就会修改中断允许寄存器内容，添加上发送保持寄存器中断允许标志，
   // 从而在系统需要发送字符时引起串行中断发生。
66         popl %edx               // 弹出中断标识寄存器端口号 0x3fa（或 0x2fa）。
67         jmp rep_int             // 跳转，继续判断有无待处理中断并继续处理。
68 end:    movb $0x20,%al          // 向中断控制器发送结束中断指令 EOI。
69         outb %al,$0x20          /* EOI */
70         pop %ds
71         pop %es
72         popl %eax
73         popl %ebx
74         popl %ecx
```

```
75          popl %edx
76          addl $4,%esp            # jump over _table_list entry # 丢弃缓冲队列指针地址。
77          iret
78
    // 各中断类型处理程序地址跳转表，共有 4 种中断来源：
    // modem 状态变化中断，写字符中断，读字符中断，线路状态有问题中断。
79  jmp_table:
80          .long modem_status,write_char,read_char,line_status
81
    // 由于 modem 状态发生变化而引发此次中断。通过读 modem 状态寄存器对其进行复位操作。
82  .align 2
83  modem_status:
84          addl $6,%edx            /* clear intr by reading modem status reg */
85          inb %dx,%al             /* 通过读 modem 状态寄存器进行复位(0x3fe) */
86          ret
87
    // 由于线路状态发生变化而引起这次串行中断。通过读线路状态寄存器对其进行复位操作。
88  .align 2
89  line_status:
90          addl $5,%edx            /* clear intr by reading line status reg. */
91          inb %dx,%al             /* 通过读线路状态寄存器进行复位(0x3fd) */
92          ret
93
    // 由于串行设备（芯片）接收到字符而引起这次中断。将接收到的字符放到读缓冲队列 read_q 头
    // 指针（head）处，并且让该指针前移一个字符位置。若 head 指针已经到达缓冲区末端，则让其
    // 折返到缓冲区开始处。最后调用 C 函数 do_tty_interrupt()（也即 copy_to_cooked()），把读
    // 入的字符经过一定处理放入规范模式缓冲队列（辅助缓冲队列 secondary）中。
94  .align 2
95  read_char:
96          inb %dx,%al             /* 读取字符➔al。
97          movl %ecx,%edx          /* 当前串口缓冲队列指针地址➔edx。
98          subl $_table_list,%edx  // 缓冲队列指针表首址 - 当前串口队列指针地址➔edx，
99          shrl $3,%edx            // 差值/8。对于串口 1 是 1，对于串口 2 是 2。
100         movl (%ecx),%ecx        # read-queue # 取读缓冲队列结构地址➔ecx。
101         movl head(%ecx),%ebx    // 取读队列中缓冲头指针➔ebx。
102         movb %al,buf(%ecx,%ebx) // 将字符放在缓冲区中头指针所指的位置。
103         incl %ebx               // 将头指针前移一字节。
104         andl $size-1,%ebx       // 用缓冲区大小对头指针进行模操作。指针不能超过缓冲区大小。
105         cmpl tail(%ecx),%ebx    // 缓冲区头指针与尾指针比较。
106         je 1f                   // 若相等，表示缓冲区满，跳转到标号 1 处。
107         movl %ebx,head(%ecx)    // 保存修改过的头指针。
108 1:      pushl %edx              // 将串口号压入堆栈(1- 串口 1，2 - 串口 2)，作为参数，
109         call _do_tty_interrupt  // 调用 tty 中断处理 C 函数（tty_io.c，242，145）。
110         addl $4,%esp            // 丢弃入栈参数，并返回。
111         ret
112
    // 由于设置了发送保持寄存器允许中断标志而引起此次中断。说明对应串行终端的写字符缓冲队列中
    // 有字符需要发送。于是计算出写队列中当前所含字符数，若字符数已小于 256 个则唤醒等待写操作
    // 进程。然后从写缓冲队列尾部取出一个字符发送，并调整和保存尾指针。如果写缓冲队列已空，则
    // 跳转到 write_buffer_empty 处处理写缓冲队列空的情况。
113 .align 2
114 write_char:
115         movl 4(%ecx),%ecx               # write-queue # 取写缓冲队列结构地址➔ecx。
```

```
116         movl head(%ecx),%ebx            // 取写队列头指针➔ebx。
117         subl tail(%ecx),%ebx            // 头指针 - 尾指针 = 队列中字符数。
118         andl $size-1,%ebx               # nr chars in queue  # 对指针取模运算。
119         je write_buffer_empty           // 如果头指针 = 尾指针，说明写队列无字符，跳转处理。
120         cmpl $startup,%ebx              // 队列中字符数超过 256 个?
121         ja 1f                           // 超过，则跳转处理。
122         movl proc_list(%ecx),%ebx       # wake up sleeping process # 唤醒等待的进程。
                                            // 取等待该队列的进程的指针，并判断是否为空。
123         testl %ebx,%ebx                 # is there any?  # 有等待的进程吗?
124         je 1f                           // 是空的，则向前跳转到标号 1 处。
125         movl $0,(%ebx)                  // 否则将进程置为可运行状态(唤醒进程)。。
126 1:      movl tail(%ecx),%ebx            // 取尾指针。
127         movb buf(%ecx,%ebx),%al         // 从缓冲中尾指针处取一字符➔al。
128         outb %al,%dx                    // 向端口 0x3f8(0x2f8)送出到保持寄存器中。
129         incl %ebx                       // 尾指针前移。
130         andl $size-1,%ebx               // 尾指针若到缓冲区末端，则折回。
131         movl %ebx,tail(%ecx)            // 保存已修改过的尾指针。
132         cmpl head(%ecx),%ebx            // 尾指针与头指针比较，
133         je write_buffer_empty           // 若相等，表示队列已空，则跳转。
134         ret
    // 处理写缓冲队列 write_q 已空的情况。若有等待写该串行终端的进程则唤醒之，然后屏蔽发送
    // 保持寄存器空中断，不让发送保持寄存器空时产生中断。
135 .align 2
136 write_buffer_empty:
137         movl proc_list(%ecx),%ebx       # wake up sleeping process # 唤醒等待的进程。
                                            // 取等待该队列的进程的指针，并判断是否为空。
138         testl %ebx,%ebx                 # is there any?  # 有等待的进程吗?
139         je 1f                           # 无，则向前跳转到标号 1 处。
140         movl $0,(%ebx)                  # 否则将进程置为可运行状态(唤醒进程)。
141 1:      incl %edx                       # 指向端口 0x3f9(0x2f9)。
142         inb %dx,%al                     # 读取中断允许寄存器。
143         jmp 1f                          # 稍作延迟。
144 1:      jmp 1f
145 1:      andb $0xd,%al                   /* disable transmit interrupt */
                                            /* 屏蔽发送保持寄存器空中断（位 1） */
146         outb %al,%dx                    // 写入 0x3f9(0x2f9)。
147         ret
```

7.8 tty_io.c 程序

7.8.1 功能描述

每个 tty 设备有 3 个缓冲队列，分别是读缓冲队列（read_q）、写缓冲队列（write_q）和辅助缓冲队列（secondary），定义在 tty_struct 结构中（include/linux/tty.h）。对于每个缓冲队列，读操作是从缓冲队列的左端取字符，并且把缓冲队列尾（tail）指针向右移动。而写操作则是往缓冲队列的右端添加字符，并且也把头(head)指针向右移动。这两个指针中，任何一个若移动到超出了缓冲队列的末端，则折回到左端重新开始。见图 7-9 所示。

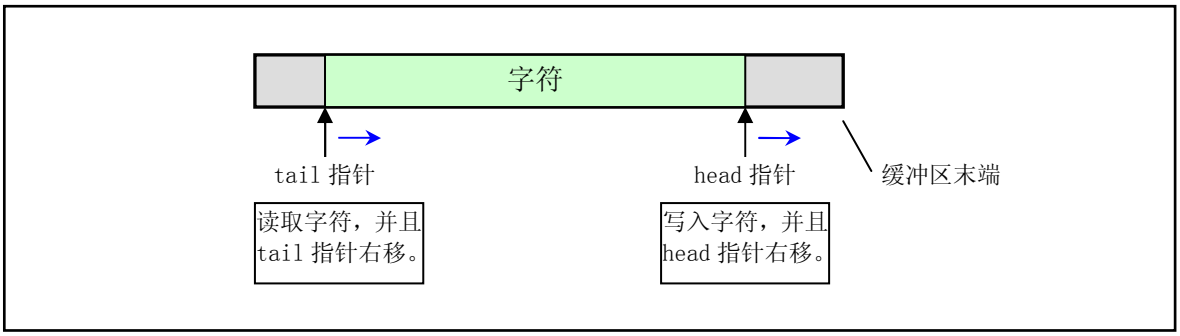

图 7-9 tty 字符缓冲队列的操作方式

本程序包括字符设备的上层接口函数。主要含有终端读/写函数 tty_read()和 tty_write()。读操作的行规则函数 copy_to_cooked()也在这里实现。

tty_read()和 tty_write()将在文件系统中用于操作字符设备文件时被调用。例如当一个程序读/dev/tty 文件时，就会执行系统调用 sys_read()（在 fs/read_write.c 中），而这个系统调用在判别出所读文件是一个字符设备文件时，即会调用 rw_char()函数（在 fs/char_dev.c 中），该函数则会根据所读设备的子设备号等信息，由字符设备读写函数表（设备开关表）调用 rw_tty()，最终调用到这里的终端读操作函数 tty_read()。

copy_to_cooked()函数由键盘中断过程调用（通过 do_tty_interrupt()），用于根据终端 termios 结构中设置的字符输入/输出标志（例如 INLCR、OUCLC）对 read_q 队列中的字符进行处理，把字符转换成以字符行为单位的规范模式字符序列，并保存在辅助字符缓冲队列（规范模式缓冲队列）（secondary）中，供上述 tty_read()读取。在转换处理期间，若终端的回显标志 L_ECHO 置位，则还会把字符放入写队列 write_q 中，并调用终端写函数把该字符显示在屏幕上。如果是串行终端，那么写函数将是 rs_write()（在 serial.c，53 行）。rs_write()会把串行终端写队列中的字符通过串行线路发送给串行终端，并显示在串行终端的屏幕上。copy_to_cooked()函数最后还将唤醒等待着辅助缓冲队列的进程。函数实现的步骤如下所示：

1. 如果读队列空或者辅助队列已经满，则跳转到最后一步（第 10 步），否则执行以下操作；
2. 从读队列 read_q 的尾指针处取一字符，并且尾指针前移一字符位置；
3. 若是回车（CR）或换行（NL）字符，则根据终端 termios 结构中输入标志（ICRNL、INLCR、INOCR）的状态，对该字符作相应转换。例如，如果读取的是一个回车字符并且 ICRNL 标志是置位的，则把它替换成换行字符；
4. 若大写转小写标志 IUCLC 是置位的，则把字符替换成对应的小写字符；
5. 若规范模式标志 ICANON 是置位的，则对该字符进行规范模式处理：
   a. 若是删行字符（^U），则删除 secondary 中的一行字符（队列头指针后退，直到遇到回车或换行或队列已空为止）；
   b. 若是檫除字符（^H），则删除 secondary 中头指针处的一个字符，头指针后退一个字符位置；
   c. 若是停止字符（^S），则设置终端的停止标志 stopped=1；
   d. 若是开始字符（^Q），则复位终端的停止标志。
6. 如果接收键盘信号标志 ISIG 是置位的，则为进程生成对应键入控制字符的信号；
7. 如果是行结束字符（例如 NL 或^D），则辅助队列 secondary 的行数统计值 data 增 1；
8. 如果本地回显标志是置位的，则把字符也放入写队列 write_q 中，并调用终端写函数在屏幕上显示该字符；
9. 把该字符放入辅助队列 secondary 中，返回上面第 1 步继续循环处理读队列中其他字符；
10. 最后唤醒睡眠在辅助队列上的进程。

在阅读下面程序时不免首先查看一下 include/linux/tty.h 头文件。在该头文件定义了 tty 字符缓冲队列

的数据结构以及一些宏操作定义。另外还定义了控制字符的 ASCII 码值。

7.8.2 代码注释

程序 7-6 linux/kernel/chr_drv/tty_io.c

```
 1 /*
 2  *  linux/kernel/tty_io.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * 'tty_io.c' gives an orthogonal feeling to tty's, be they consoles
 9  * or rs-channels.  It also implements echoing, cooked mode etc.
10  *
11  * Kill-line thanks to John T Kohl.
12  */
   /*
   * 'tty_io.c'给 tty 一种非相关的感觉，是控制台还是串行通道。该程序同样
   * 实现了回显、规范(熟)模式等。
   *
   * Kill-line，谢谢 John T Kahl。
   */
13 #include <ctype.h>          // 字符类型头文件。定义了一些有关字符类型判断和转换的宏。
14 #include <errno.h>          // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
15 #include <signal.h>         // 信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
16
   // 下面给出相应信号在信号位图中的对应比特位。
17 #define ALRMMASK (1<<(SIGALRM-1))      // 警告(alarm)信号屏蔽位。
18 #define KILLMASK (1<<(SIGKILL-1))      // 终止(kill)信号屏蔽位。
19 #define INTMASK (1<<(SIGINT-1))        // 键盘中断(int)信号屏蔽位。
20 #define QUITMASK (1<<(SIGQUIT-1))      // 键盘退出(quit)信号屏蔽位。
21 #define TSTPMASK (1<<(SIGTSTP-1))      // tty 发出的停止进程(tty stop)信号屏蔽位。
22
23 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
24 #include <linux/tty.h>    // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
25 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
26 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
27
28 #define _L_FLAG(tty,f)  ((tty)->termios.c_lflag & f)  // 取 termios 结构中的本地模式标志。
29 #define _I_FLAG(tty,f)  ((tty)->termios.c_iflag & f)  // 取 termios 结构中的输入模式标志。
30 #define _O_FLAG(tty,f)  ((tty)->termios.c_oflag & f)  // 取 termios 结构中的输出模式标志。
31
   // 取 termios 结构中本地模式标志集中的一个标志位。
32 #define L_CANON(tty)     _L_FLAG((tty),ICANON)     // 取本地模式标志集中规范（熟）模式标志位。
33 #define L_ISIG(tty)      _L_FLAG((tty),ISIG)       // 取信号标志位。
34 #define L_ECHO(tty)      _L_FLAG((tty),ECHO)       // 取回显字符标志位。
35 #define L_ECHOE(tty)     _L_FLAG((tty),ECHOE)      // 规范模式时，取回显擦出标志位。
36 #define L_ECHOK(tty)     _L_FLAG((tty),ECHOK)      // 规范模式时，取 KILL 擦除当前行标志位。
37 #define L_ECHOCTL(tty)   _L_FLAG((tty),ECHOCTL)    // 取回显控制字符标志位。
38 #define L_ECHOKE(tty)    _L_FLAG((tty),ECHOKE)     // 规范模式时，取 KILL 擦除行并回显标志位。
```

```
39
   // 取 termios 结构中输入模式标志中的一个标志位。
40 #define I_UCLC(tty)       _I_FLAG((tty),IUCLC)      // 取输入模式标志集中大写到小写转换标志位。
41 #define I_NLCR(tty)       _I_FLAG((tty),INLCR)      // 取换行符 NL 转回车符 CR 标志位。
42 #define I_CRNL(tty)       _I_FLAG((tty),ICRNL)      // 取回车符 CR 转换行符 NL 标志位。
43 #define I_NOCR(tty)       _I_FLAG((tty),IGNCR)      // 取忽略回车符 CR 标志位。
44
   // 取 termios 结构中输出模式标志中的一个标志位。
45 #define O_POST(tty)       _O_FLAG((tty),OPOST)      // 取输出模式标志集中执行输出处理标志。
46 #define O_NLCR(tty)       _O_FLAG((tty),ONLCR)      // 取换行符 NL 转回车换行符 CR-NL 标志。
47 #define O_CRNL(tty)       _O_FLAG((tty),OCRNL)      // 取回车符 CR 转换行符 NL 标志。
48 #define O_NLRET(tty)      _O_FLAG((tty),ONLRET)     // 取换行符 NL 执行回车功能的标志。
49 #define O_LCUC(tty)       _O_FLAG((tty),OLCUC)      // 取小写转大写字符标志。
50
   // tty 数据结构的 tty_table 数组。其中包含三个初始化项数据，分别对应控制台、串口终端 1 和
   // 串口终端 2 的初始化数据。
51 struct tty_struct tty_table[] = {
52         {
53                 {ICRNL,         /* change incoming CR to NL */   /* 将输入的 CR 转换为 NL */
54                 OPOST|ONLCR,    /* change outgoing NL to CRNL */ /* 将输出的 NL 转 CRNL */
55                 0,              // 控制模式标志初始化为 0。
56                 ISIG | ICANON | ECHO | ECHOCTL | ECHOKE,    // 本地模式标志。
57                 0,              /* console termio */         // 控制台 termio。
58                 INIT_C_CC},                                  // 控制字符数组。
59                 0,              /* initial pgrp */           // 所属初始进程组。
60                 0,              /* initial stopped */        // 初始停止标志。
61                 con_write,                                   // tty 写函数指针。
62                 {0,0,0,0,""},   /* console read-queue */     // tty 控制台读队列。
63                 {0,0,0,0,""},   /* console write-queue */    // tty 控制台写队列。
64                 {0,0,0,0,""}    /* console secondary queue */  // tty 控制台辅助(第二)队列。
65         },{
66                 {0, /* no translation */      // 输入模式标志。0，无须转换。
67                 0,  /* no translation */      // 输出模式标志。0，无须转换。
68                 B2400 | CS8,                  // 控制模式标志。波特率 2400bps，8 位数据位。
69                 0,                            // 本地模式标志 0。
70                 0,                            // 行规程 0。
71                 INIT_C_CC},                   // 控制字符数组。
72                 0,                            // 所属初始进程组。
73                 0,                            // 初始停止标志。
74                 rs_write,                     // 串口 1 tty 写函数指针。
75                 {0x3f8,0,0,0,""},             /* rs 1 */  // 串行终端 1 读缓冲队列。
76                 {0x3f8,0,0,0,""},             // 串行终端 1 写缓冲队列。
77                 {0,0,0,0,""}                  // 串行终端 1 辅助缓冲队列。
78         },{
79                 {0, /* no translation */      // 输入模式标志。0，无须转换。
80                 0,  /* no translation */      // 输出模式标志。0，无须转换。
81                 B2400 | CS8,                  // 控制模式标志。波特率 2400bps，8 位数据位。
82                 0,                            // 本地模式标志 0。
83                 0,                            // 行规程 0。
84                 INIT_C_CC},                   // 控制字符数组。
85                 0,                            // 所属初始进程组。
86                 0,                            // 初始停止标志。
87                 rs_write,                     // 串口 2 tty 写函数指针。
```

```
 88                 {0x2f8,0,0,0,""},                   /* rs 2 */  // 串行终端 2 读缓冲队列。
 89                 {0x2f8,0,0,0,""},                  // 串行终端 2 写缓冲队列。
 90                 {0,0,0,0,""}                       // 串行终端 2 辅助缓冲队列。
 91         }
 92 };
 93
 94 /*
 95  * these are the tables used by the machine code handlers.
 96  * you can implement pseudo-tty's or something by changing
 97  * them. Currently not done.
 98  */
    /*
     * 下面是汇编程序使用的缓冲队列地址表。通过修改你可以实现
     * 伪 tty 终端或其他终端类型。目前还没有这样做。
     */
    // tty 缓冲队列地址表。rs_io.s 汇编程序使用，用于取得读写缓冲队列地址。
 99 struct tty_queue * table_list[]={
100         &tty_table[0].read_q, &tty_table[0].write_q,   // 控制台终端读、写缓冲队列地址。
101         &tty_table[1].read_q, &tty_table[1].write_q,   // 串行口 1 终端读、写缓冲队列地址。
102         &tty_table[2].read_q, &tty_table[2].write_q    // 串行口 2 终端读、写缓冲队列地址。
103         };
104
    //// tty 终端初始化函数。
    // 初始化串口终端和控制台终端。
105 void tty_init(void)
106 {
107         rs_init();              // 初始化串行中断程序和串行接口 1 和 2。(serial.c, 37)
108         con_init();             // 初始化控制台终端。(console.c, 617)
109 }
110
    //// tty 键盘中断（^C）字符处理函数。
    // 向 tty 结构中指明的（前台）进程组中所有的进程发送指定的信号 mask，通常该信号是 SIGINT。
    // 参数：tty - 相应 tty 终端结构指针；mask - 信号屏蔽位。
111 void tty_intr(struct tty_struct * tty, int mask)
112 {
113         int i;
114
    // 如果 tty 所属进程组号小于等于 0，则退出。
    // 当 pgrp=0 时，表明进程是初始进程 init，它没有控制终端，因此不应该会发出中断字符。
115         if (tty->pgrp <= 0)
116                 return;
    // 扫描任务数组，向 tty 指明的进程组（前台进程组）中所有进程发送指定的信号。
117         for (i=0;i<NR_TASKS;i++)
    // 如果该项任务指针不为空，并且其组号等于 tty 组号，则设置（发送）该任务指定的信号 mask。
118                 if (task[i] && task[i]->pgrp==tty->pgrp)
119                         task[i]->signal |= mask;
120 }
121
    //// 如果队列缓冲区空则让进程进入可中断的睡眠状态。
    // 参数：queue - 指定队列的指针。
    // 进程在取队列缓冲区中字符时调用此函数。
122 static void sleep_if_empty(struct tty_queue * queue)
123 {
```

```
124         cli();                      // 关中断。
    // 若当前进程没有信号要处理并且指定的队列缓冲区空，则让进程进入可中断睡眠状态，并让
    // 队列的进程等待指针指向该进程。
125         while (!current->signal && EMPTY(*queue))
126                 interruptible_sleep_on(&queue->proc_list);
127         sti();                      // 开中断。
128 }
129
    //// 若队列缓冲区满则让进程进入可中断的睡眠状态。
    // 参数：queue - 指定队列的指针。
    // 进程在往队列缓冲区中写入时调用此函数。
130 static void sleep_if_full(struct tty_queue * queue)
131 {
    // 若队列缓冲区不满，则返回退出。
132         if (!FULL(*queue))
133                 return;
134         cli();                      // 关中断。
    // 如果进程没有信号需要处理并且队列缓冲区中空闲剩余区长度<128，则让进程进入可中断睡眠状态，
    // 并让该队列的进程等待指针指向该进程。
135         while (!current->signal && LEFT(*queue)<128)
136                 interruptible_sleep_on(&queue->proc_list);
137         sti();                      // 开中断。
138 }
139
    //// 等待按键。
    // 如果控制台的读队列缓冲区空则让进程进入可中断的睡眠状态。
140 void wait_for_keypress(void)
141 {
142         sleep_if_empty(&tty_table[0].secondary);
143 }
144
    //// 复制成规范模式字符序列。
    // 将指定 tty 终端队列缓冲区中的字符复制成规范(熟)模式字符并存放在辅助队列(规范模式队列)中。
    // 参数：tty - 指定终端的 tty 结构。
145 void copy_to_cooked(struct tty_struct * tty)
146 {
147         signed char c;
148
    // 如果 tty 的读队列缓冲区不空并且辅助队列缓冲区为空，则循环执行下列代码。
149         while (!EMPTY(tty->read_q) && !FULL(tty->secondary)) {
    // 从读队列尾处取一字符到 c，并前移尾指针。
150                 GETCH(tty->read_q,c);
    // 下面对输入字符，利用输入模式标志集进行处理。
    // 如果该字符是回车符 CR(13)，则：若回车转换行标志 CRNL 置位则将该字符转换为换行符 NL(10)；
    // 否则若忽略回车标志 NOCR 置位，则忽略该字符，继续处理其他字符。
151                 if (c==13)
152                         if (I_CRNL(tty))
153                                 c=10;
154                         else if (I_NOCR(tty))
155                                 continue;
156                         else ;
    // 如果该字符是换行符 NL(10)并且换行转回车标志 NLCR 置位，则将其转换为回车符 CR(13)。
157                 else if (c==10 && I_NLCR(tty))
```

```
158                         c=13;
    // 如果大写转小写标志 UCLC 置位，则将该字符转换为小写字符。
159                 if (I_UCLC(tty))
160                         c=tolower(c);
    // 如果本地模式标志集中规范（熟）模式标志 CANON 置位，则进行以下处理。
161                 if (L_CANON(tty)) {
    // 如果该字符是键盘终止控制字符 KILL(^U)，则进行删除输入行上所有字符的处理。
162                         if (c==KILL_CHAR(tty)) {
163                                 /* deal with killing the input line */ /* 删除输入行处理 */
    // 如果 tty 辅助队列不空，或者辅助队列中最后一个字符是换行 NL(10)，或者该字符是文件结束字符
    // (^D)，则循环执行下列代码。
164                                 while(!(EMPTY(tty->secondary) ||
165                                         (c=LAST(tty->secondary))==10 ||
166                                         c==EOF_CHAR(tty))) {
    // 如果本地回显标志 ECHO 置位，那么：若字符是控制字符(值<32)，则往 tty 的写队列中放入擦除
    // 字符 ERASE。再放入一个擦除字符 ERASE，并且调用该 tty 的写函数，该写函数就会把写队列中的
    // 字符输出到终端的屏幕上。另外，因为控制字符在放入写队列时是用两个字符表示的（例如^V），
    // 因此需要特别对控制字符多放入一个 ERASE。
167                                         if (L_ECHO(tty)) {
168                                                 if (c<32)
169                                                         PUTCH(127,tty->write_q);
170                                                 PUTCH(127,tty->write_q);
171                                                 tty->write(tty);
172                                         }
    // 将 tty 辅助队列头指针后退 1 字节。
173                                         DEC(tty->secondary.head);
174                                 }
175                                 continue;    // 继续读取并处理其他字符。
176                         }
    // 如果该字符是删除控制字符 ERASE(^H)，那么：
177                         if (c==ERASE_CHAR(tty)) {
    // 若 tty 的辅助队列为空，或者其最后一个字符是换行符 NL(10)，或者是文件结束符，则继续处理
    // 其他字符。
178                                 if (EMPTY(tty->secondary) ||
179                                    (c=LAST(tty->secondary))==10 ||
180                                    c==EOF_CHAR(tty))
181                                         continue;
    // 如果本地回显标志 ECHO 置位，那么：若字符是控制字符(值<32)，则往 tty 的写队列中放入擦除
    // 字符 ERASE。再放入一个擦除字符 ERASE，并且调用该 tty 的写函数。
182                                 if (L_ECHO(tty)) {
183                                         if (c<32)
184                                                 PUTCH(127,tty->write_q);
185                                         PUTCH(127,tty->write_q);
186                                         tty->write(tty);
187                                 }
    // 将 tty 辅助队列头指针后退 1 字节，继续处理其他字符。
188                                 DEC(tty->secondary.head);
189                                 continue;
190                         }
    //如果该字符是停止字符(^S)，则置 tty 停止标志，继续处理其他字符。
191                         if (c==STOP_CHAR(tty)) {
192                                 tty->stopped=1;
193                                 continue;
```

```
194                         }
    // 如果该字符是开始字符(^Q)，则复位 tty 停止标志，继续处理其他字符。
195                         if (c==START_CHAR(tty)) {
196                                 tty->stopped=0;
197                                 continue;
198                         }
199                 }
    // 若输入模式标志集中 ISIG 标志置位，表示终端键盘可以产生信号，则在收到 INTR、QUIT、SUSP
    // 或 DSUSP 字符时，需要为进程产生相应的信号。
200                 if (L_ISIG(tty)) {
    // 如果该字符是键盘中断符(^C)，则向当前进程发送键盘中断信号，并继续处理下一字符。
201                         if (c==INTR_CHAR(tty)) {
202                                 tty_intr(tty,INTMASK);
203                                 continue;
204                         }
    // 如果该字符是退出符(^\)，则向当前进程发送键盘退出信号，并继续处理下一字符。
205                         if (c==QUIT_CHAR(tty)) {
206                                 tty_intr(tty,QUITMASK);
207                                 continue;
208                         }
209                 }
    // 如果该字符是换行符 NL(10)，或者是文件结束符 EOF(4，^D)，表示一行字符已处理完，则把辅助
    // 缓冲队列中含有字符行数值增 1。在 tty_read()中若取走一行字符，就会将其值减 1，见 264 行。
210                 if (c==10 || c==EOF_CHAR(tty))
211                         tty->secondary.data++;
    // 如果本地模式标志集中回显标志 ECHO 置位，那么，如果字符是换行符 NL(10)，则将换行符 NL(10)
    // 和回车符 CR(13)放入 tty 写队列缓冲区中；如果字符是控制字符(字符值<32)并且回显控制字符标志
    // ECHOCTL 置位，则将字符'^'和字符 c+64 放入 tty 写队列中(也即会显示^C、^H 等)；否则将该字符
    // 直接放入 tty 写缓冲队列中。最后调用该 tty 的写操作函数。
212                 if (L_ECHO(tty)) {
213                         if (c==10) {
214                                 PUTCH(10,tty->write_q);
215                                 PUTCH(13,tty->write_q);
216                         } else if (c<32) {
217                                 if (L_ECHOCTL(tty)) {
218                                         PUTCH('^',tty->write_q);
219                                         PUTCH(c+64,tty->write_q);
220                                 }
221                         } else
222                                 PUTCH(c,tty->write_q);
223                         tty->write(tty);
224                 }
    // 将该字符放入辅助队列中。
225                 PUTCH(c,tty->secondary);
226         }
    // 唤醒等待该辅助缓冲队列的进程（如果有的话）。
227         wake_up(&tty->secondary.proc_list);
228 }
229
    //// tty 读函数，从终端辅助缓冲队列中读取指定数量的字符，放到用户指定的缓冲区中。
    // 参数：channel - 子设备号；buf - 用户缓冲区指针；nr - 欲读字节数。
    // 返回已读字节数。
230 int tty_read(unsigned channel, char * buf, int nr)
```

```
231 {
232         struct tty_struct * tty;
233         char c, * b=buf;
234         int minimum,time,flag=0;
235         long oldalarm;
236
    // 本版本 linux 内核的终端只有 3 个子设备，分别是控制台(0)、串口终端 1(1)和串口终端 2(2)。
    // 所以任何大于 2 的子设备号都是非法的。读的字节数当然也不能小于 0 的。
237         if (channel>2 || nr<0) return -1;
    // tty 指针指向子设备号对应 ttb_table 表中的 tty 结构。
238         tty = &tty_table[channel];
    // 下面首先保存进程原定时值，然后根据控制字符 VTIME 和 VMIN 设置读字符操作的超时定时值。
    // 在非规范模式下，这两个值是超时定时值。MIN 表示为了满足读操作，需要读取的最少字符数。
    // TIME 是一个十分之一秒计数的计时值。
    // 首先保存进程当前的(报警)定时值(滴答数)。
239         oldalarm = current->alarm;
    // 并设置读操作超时定时值 time 和需要最少读取的字符个数 minimum。
240         time = 10L*tty->termios.c_cc[VTIME];
241         minimum = tty->termios.c_cc[VMIN];
    // 如果设置了读超时定时值 time 但没有设置最少读取个数 minimum，那么在读到至少一个字符或者
    // 定时超时后读操作将立刻返回。所以这里置 minimum=1。
242         if (time && !minimum) {
243                 minimum=1;
    // 如果进程原定时值是 0 或者 time+当前系统时间值小于进程原定时值的话，则置重新设置进程定时
    // 值为 time+当前系统时间，并置 flag 标志。
244                 if (flag=(!oldalarm || time+jiffies<oldalarm))
245                         current->alarm = time+jiffies;
246         }
    // 如果设置的最少读取字符数>欲读的字符数，则令其等于此次欲读取的字符数。
247         if (minimum>nr)
248                 minimum=nr;
    // 当欲读的字节数>0，则循环执行以下操作。
249         while (nr>0) {
    // 如果 flag 不为 0(也即进程原定时值是 0 或者 time+当前系统时间值小于进程原定时值)并且进程此时
    // 以收到定时信号 SIGALRM，表明这里设置的定时时间已到，则复位进程的定时信号 SIGALRM，并中断
    // 循环。
250                 if (flag && (current->signal & ALRMMASK)) {
251                         current->signal &= ~ALRMMASK;
252                         break;
253                 }
    // 如果 flag 没有置位，或者已置位但当前进程有其他信号要处理，则退出，返回 0。
254                 if (current->signal)
255                         break;
    // 如果辅助缓冲队列(规范模式队列)为空，或者设置了规范模式标志并且辅助队列中字符数为 0 以及
    // 辅助模式缓冲队列空闲空间>20，则进入可中断睡眠状态，返回后继续处理。
256                 if (EMPTY(tty->secondary) || (L_CANON(tty) &&
257                 !tty->secondary.data && LEFT(tty->secondary)>20)) {
258                         sleep_if_empty(&tty->secondary);
259                         continue;
260                 }
    // 执行以下取字符操作，需读字符数 nr 依次递减，直到 nr=0 或者辅助缓冲队列为空。
261                 do {
    // 取辅助缓冲队列字符 c，并且缓冲队列 secondary->tail 指针向右移动一个字符位置（tail++）。
```

```
262                         GETCH(tty->secondary,c);
    // 如果该字符是文件结束符(^D)或者是换行符 NL(10)，则把辅助缓冲队列中含有字符行数值减 1。
263                         if (c==EOF_CHAR(tty) || c==10)
264                                 tty->secondary.data--;
    // 如果该字符是文件结束符(^D)并且规范模式标志置位，则返回已读字符数，并退出。
265                         if (c==EOF_CHAR(tty) && L_CANON(tty))
266                                 return (b-buf);
    // 否则说明是原始模式（非规范模式）操作，于是将该字符直接放入用户数据段缓冲区 buf 中，并把
    // 欲读字符数减 1。此时如果欲读字符数已为 0，则中断循环。
267                         else {
268                                 put_fs_byte(c,b++);
269                                 if (!--nr)
270                                         break;
271                         }
272                 } while (nr>0 && !EMPTY(tty->secondary));
    // 如果超时定时值 time 不为 0 并且规范模式标志没有置位(非规范模式)，那么：
273                 if (time && !L_CANON(tty))
    // 如果进程原定时值是 0 或者 time+当前系统时间值小于进程原定时值的话，则置重新设置进程定时值
    // 为 time+当前系统时间，并置 flag 标志，为读取下一个字符做好定时准备。否则表明进程原定时时间
    // 要比等待一个字符被读取的定时时间要小，可能没有等到字符到来进程原定时时间就到了。因此，
    // 此时这里需要恢复进程的原定时值（oldalarm）。
274                         if (flag=(!oldalarm || time+jiffies<oldalarm))
275                                 current->alarm = time+jiffies;
276                         else
277                                 current->alarm = oldalarm;
    // 如果规范模式标志置位，那么若已读到起码一个字符则中断循环。否则若已读取数大于或等于最少要
    // 求读取的字符数，则也中断循环。
278                 if (L_CANON(tty)) {
279                         if (b-buf)
280                                 break;
281                 } else if (b-buf >= minimum)
282                         break;
283         }
    // 读取 tty 字符循环操作结束，让进程的定时值恢复值。
284         current->alarm = oldalarm;
    // 如果进程有信号并且没有读取到任何字符，则返回出错号（被中断）。
285         if (current->signal && !(b-buf))
286                 return -EINTR;
287         return (b-buf);             // 返回已读取的字符数。
288 }
289
    //// tty 写函数。把用户缓冲区中的字符写入 tty 的写队列中。
    // 参数：channel - 子设备号；buf - 缓冲区指针；nr - 写字节数。
    // 返回已写字节数。
290 int tty_write(unsigned channel, char * buf, int nr)
291 {
292         static cr_flag=0;
293         struct tty_struct * tty;
294         char c, *b=buf;
295
    // 本版本 linux 内核的终端只有 3 个子设备，分别是控制台(0)、串口终端 1(1)和串口终端 2(2)。
    // 所以任何大于 2 的子设备号都是非法的。写的字节数当然也不能小于 0 的。
296         if (channel>2 || nr<0) return -1;
```

```
    // tty 指针指向子设备号对应 ttb_table 表中的 tty 结构。与第 238 行语句的作用相同。
297         tty = channel + tty_table;
    // 字符设备是一个一个字符进行处理的，所以这里对于 nr 大于 0 时对每个字符进行循环处理。
298         while (nr>0) {
    // 如果此时 tty 的写队列已满，则当前进程进入可中断的睡眠状态。
299                 sleep_if_full(&tty->write_q);
    // 如果当前进程有信号要处理，则退出，返回 0。
300                 if (current->signal)
301                         break;
    // 当要写的字节数>0 并且 tty 的写队列不满时，循环执行以下操作。
302                 while (nr>0 && !FULL(tty->write_q)) {
    // 从用户数据段内存中取一字节 c。
303                         c=get_fs_byte(b);
    // 如果终端输出模式标志集中的执行输出处理标志 OPOST 置位，则执行下列输出时处理过程。
304                         if (O_POST(tty)) {
    // 如果该字符是回车符'\r'(CR，13)并且回车符转换行符标志 OCRNL 置位，则将该字符换成换行符
    // '\n'(NL，10)；否则如果该字符是换行符'\n'(NL，10)并且换行转回车功能标志 ONLRET 置位的话，
    // 则将该字符换成回车符'\r'(CR，13)。
305                                 if (c=='\r' && O_CRNL(tty))
306                                         c='\n';
307                                 else if (c=='\n' && O_NLRET(tty))
308                                         c='\r';
    // 如果该字符是换行符'\n'并且回车标志 cr_flag 没有置位，换行转回车-换行标志 ONLCR 置位的话，
    // 则将 cr_flag 置位，并将一回车符放入写队列中。然后继续处理下一个字符。
309                                 if (c=='\n' && !cr_flag && O_NLCR(tty)) {
310                                         cr_flag = 1;
311                                         PUTCH(13,tty->write_q);
312                                         continue;
313                                 }
    // 如果小写转大写标志 OLCUC 置位的话，就将该字符转成大写字符。
314                                 if (O_LCUC(tty))
315                                         c=toupper(c);
316                         }
    // 用户数据缓冲指针 b 前进 1 字节；欲写字节数减 1 字节；复位 cr_flag 标志，并将该字节放入 tty
    // 写队列中。
317                         b++; nr--;
318                         cr_flag = 0;
319                         PUTCH(c,tty->write_q);
320                 }
    // 若字节全部写完，或者写队列已满，则程序执行到这里。调用对应 tty 的写函数，若还有字节要写，
    // 则等待写队列不满，所以调用调度程序，先去执行其他任务。
321                 tty->write(tty);
322                 if (nr>0)
323                         schedule();
324         }
325         return (b-buf);                 // 返回写入的字节数。
326 }
327
328 /*
329  * Jeh, sometimes I really like the 386.
330  * This routine is called from an interrupt,
331  * and there should be absolutely no problem
332  * with sleeping even in an interrupt (I hope).
```

```
333  * Of course, if somebody proves me wrong, I'll
334  * hate intel for all time :-). We'll have to
335  * be careful and see to reinstating the interrupt
336  * chips before calling this, though.
337  *
338  * I don't think we sleep here under normal circumstances
339  * anyway, which is good, as the task sleeping might be
340  * totally innocent.
341  */
    /*
     * 呵，有时我是真得很喜欢 386。该子程序是从一个中断处理程序中调用的，即使在
     * 中断处理程序中睡眠也应该绝对没有问题(我希望如此)。当然，如果有人证明我是
     * 错的，那么我将憎恨 intel 一辈子☺。但是我们必须小心，在调用该子程序之前需
     * 要恢复中断。
     *
     * 我不认为在通常环境下会处在这里睡眠，这样很好，因为任务睡眠是完全任意的。
     */
    //// tty 中断处理调用函数 - 执行 tty 中断处理。
    // 参数：tty - 指定的 tty 终端号（0，1 或 2）。
    // 将指定 tty 终端队列缓冲区中的字符复制成规范(熟)模式字符并存放在辅助队列(规范模式队列)中。
    // 在串口读字符中断(rs_io.s, 109)和键盘中断(kerboard.S, 69)中调用。
342 void do_tty_interrupt(int tty)
343 {
344         copy_to_cooked(tty_table+tty);
345 }
346
    //// 字符设备初始化函数。空，为以后扩展做准备。
347 void chr_dev_init(void)
348 {
349 }
350
```

7.8.3 其他信息

7.8.3.1 控制字符 VTIME、VMIN

在非规范模式下，这两个值是超时定时值和最小读取字符个数。MIN 表示为了满足读操作，需要读取的最少字符数。TIME 是一个十分之一秒计数的计时值。当这两个都设置的话，读操作将等待，直到至少读到一个字符，然后在以读取 MIN 个字符或者时间 TIME 在读取最后一个字符后超时。如果仅设置了 MIN，那么在读取 MIN 个字符之前读操作将不返回。如果仅设置了 TIME，那么在读到至少一个字符或者定时超时后读操作将立刻返回。如果两个都没有设置，则读操作将立刻返回，仅给出目前已读的字节数。详细说明参见 termios.h 文件。

7.9 tty_ioctl.c 程序

7.9.1 功能描述

本文件用于字符设备的控制操作，实现了函数（系统调用）tty_ioctl()。程序通过使用该函数可以修改指定终端 termios 结构中的设置标志等信息。

7.9.2 代码注释

程序 7-7 linux/kernel/chr_drv/tty_ioctl.c

```
1  /*
2   *  linux/kernel/chr_drv/tty_ioctl.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
8  #include <termios.h>      // 终端输入输出函数头文件。主要定义控制异步通信口的终端接口。
9
10 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12 #include <linux/tty.h>    // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
13
14 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
15 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
16 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
17
   // 这是波特率因子数组（或称为除数数组）。波特率与波特率因子的对应关系参见列表后的说明。
18 static unsigned short quotient[] = {
19         0, 2304, 1536, 1047, 857,
20         768, 576, 384, 192, 96,
21         64, 48, 24, 12, 6, 3
22 };
23
   //// 修改传输速率。
   // 参数：tty - 终端对应的 tty 数据结构。
   // 在除数锁存标志 DLAB(线路控制寄存器位 7)置位情况下，通过端口 0x3f8 和 0x3f9 向 UART 分别写入
   // 波特率因子低字节和高字节。
24 static void change_speed(struct tty_struct * tty)
25 {
26         unsigned short port,quot;
27
   // 对于串口终端，其 tty 结构的读缓冲队列 data 字段存放的是串行端口号(0x3f8 或 0x2f8)。
28         if (!(port = tty->read_q.data))
29                 return;
   // 从 tty 的 termios 结构控制模式标志集中取得设置的波特率索引号，据此从波特率因子数组中取得
   // 对应的波特率因子值。CBAUD 是控制模式标志集中波特率位屏蔽码。
30         quot = quotient[tty->termios.c_cflag & CBAUD];
31         cli();                          // 关中断。
32         outb_p(0x80,port+3);            /* set DLAB */  // 首先设置除数锁定标志 DLAB。
33         outb_p(quot & 0xff,port);       /* LS of divisor */  // 输出因子低字节。
34         outb_p(quot >> 8,port+1);       /* MS of divisor */  // 输出因子高字节。
35         outb(0x03,port+3);              /* reset DLAB */     // 复位 DLAB。
36         sti();                          // 开中断。
37 }
38
   //// 刷新 tty 缓冲队列。
   // 参数：gueue - 指定的缓冲队列指针。
```

```
    // 令缓冲队列的头指针等于尾指针，从而达到清空缓冲区(零字符)的目的。
39  static void flush(struct tty_queue * queue)
40  {
41          cli();
42          queue->head = queue->tail;
43          sti();
44  }
45
    //// 等待字符发送出去。
46  static void wait_until_sent(struct tty_struct * tty)
47  {
48          /* do nothing - not implemented */  /* 什么都没做 - 还未实现 */
49  }
50
    //// 发送 BREAK 控制符。
51  static void send_break(struct tty_struct * tty)
52  {
53          /* do nothing - not implemented */  /* 什么都没做 - 还未实现 */
54  }
55
    //// 取终端 termios 结构信息。
    // 参数：tty - 指定终端的 tty 结构指针；termios - 用户数据区 termios 结构缓冲区指针。
    // 返回 0 。
56  static int get_termios(struct tty_struct * tty, struct termios * termios)
57  {
58          int i;
59
    // 首先验证一下用户的缓冲区指针所指内存区是否足够，如不够则分配内存。
60          verify_area(termios, sizeof (*termios));
    // 复制指定 tty 结构中的 termios 结构信息到用户 termios 结构缓冲区。
61          for (i=0 ; i< (sizeof (*termios)) ; i++)
62                  put_fs_byte( ((char *)&tty->termios)[i] , i+(char *)termios );
63          return 0;
64  }
65
    //// 设置终端 termios 结构信息。
    // 参数：tty - 指定终端的 tty 结构指针；termios - 用户数据区 termios 结构指针。
    // 返回 0 。
66  static int set_termios(struct tty_struct * tty, struct termios * termios)
67  {
68          int i;
69
    // 首先复制用户数据区中 termios 结构信息到指定 tty 结构中。
70          for (i=0 ; i< (sizeof (*termios)) ; i++)
71                  ((char *)&tty->termios)[i]=get_fs_byte(i+(char *)termios);
    // 用户有可能已修改了 tty 的串行口传输波特率，所以根据 termios 结构中的控制模式标志 c_cflag
    // 修改串行芯片 UART 的传输波特率。
72          change_speed(tty);
73          return 0;
74  }
75
    //// 读取 termio 结构中的信息。
    // 参数：tty - 指定终端的 tty 结构指针；termio - 用户数据区 termio 结构缓冲区指针。
```

```
    // 返回 0。
 76 static int get_termio(struct tty_struct * tty, struct termio * termio)
 77 {
 78         int i;
 79         struct termio tmp_termio;
 80
    // 首先验证一下用户的缓冲区指针所指内存区是否足够，如不够则分配内存。
 81         verify_area(termio, sizeof (*termio));
    // 将 termios 结构的信息复制到 termio 结构中。目的是为了其中模式标志集的类型进行转换，也即
    // 从 termios 的长整数类型转换为 termio 的短整数类型。
 82         tmp_termio.c_iflag = tty->termios.c_iflag;
 83         tmp_termio.c_oflag = tty->termios.c_oflag;
 84         tmp_termio.c_cflag = tty->termios.c_cflag;
 85         tmp_termio.c_lflag = tty->termios.c_lflag;
    // 两种结构的 c_line 和 c_cc[]字段是完全相同的。
 86         tmp_termio.c_line = tty->termios.c_line;
 87         for(i=0 ; i < NCC ; i++)
 88                 tmp_termio.c_cc[i] = tty->termios.c_cc[i];
    // 最后复制指定 tty 结构中的 termio 结构信息到用户 termio 结构缓冲区。
 89         for (i=0 ; i< (sizeof (*termio)) ; i++)
 90                 put_fs_byte( ((char *)&tmp_termio)[i] , i+(char *)termio );
 91         return 0;
 92 }
 93
 94 /*
 95  * This only works as the 386 is low-byt-first
 96  */
    /*
     * 下面的 termio 设置函数仅在 386 低字节在前的方式下可用。
     */
    //// 设置终端 termio 结构信息。
    // 参数：tty - 指定终端的 tty 结构指针；termio - 用户数据区 termio 结构指针。
    // 将用户缓冲区 termio 的信息复制到终端的 termios 结构中。返回 0 。
 97 static int set_termio(struct tty_struct * tty, struct termio * termio)
 98 {
 99         int i;
100         struct termio tmp_termio;
101
    // 首先复制用户数据区中 termio 结构信息到临时 termio 结构中。
102         for (i=0 ; i< (sizeof (*termio)) ; i++)
103                 ((char *)&tmp_termio)[i]=get_fs_byte(i+(char *)termio);
    // 再将 termio 结构的信息复制到 tty 的 termios 结构中。目的是为了其中模式标志集的类型进行转换，
    // 也即从 termio 的短整数类型转换成 termios 的长整数类型。
104         *(unsigned short *)&tty->termios.c_iflag = tmp_termio.c_iflag;
105         *(unsigned short *)&tty->termios.c_oflag = tmp_termio.c_oflag;
106         *(unsigned short *)&tty->termios.c_cflag = tmp_termio.c_cflag;
107         *(unsigned short *)&tty->termios.c_lflag = tmp_termio.c_lflag;
    // 两种结构的 c_line 和 c_cc[]字段是完全相同的。
108         tty->termios.c_line = tmp_termio.c_line;
109         for(i=0 ; i < NCC ; i++)
110                 tty->termios.c_cc[i] = tmp_termio.c_cc[i];
    // 用户可能已修改了 tty 的串行口传输波特率，所以根据 termios 结构中的控制模式标志集 c_cflag
    // 修改串行芯片 UART 的传输波特率。
```

```
111         change_speed(tty);
112         return 0;
113 }
114
    //// tty 终端设备的 ioctl 函数。
    // 参数：dev - 设备号；cmd - ioctl 命令；arg - 操作参数指针。
115 int tty_ioctl(int dev, int cmd, int arg)
116 {
117         struct tty_struct * tty;
    // 首先取 tty 的子设备号。如果主设备号是 5(tty 终端)，则进程的 tty 字段即是子设备号；如果进程
    // 的 tty 子设备号是负数，表明该进程没有控制终端，也即不能发出该 ioctl 调用，出错死机。
118         if (MAJOR(dev) == 5) {
119                 dev=current->tty;
120                 if (dev<0)
121                         panic("tty_ioctl: dev<0");
    // 否则直接从设备号中取出子设备号。
122         } else
123                 dev=MINOR(dev);
    // 子设备号可以是 0(控制台终端)、1(串口 1 终端)、2(串口 2 终端)。
    // 让 tty 指向对应子设备号的 tty 结构。
124         tty = dev + tty_table;
    // 根据 tty 的 ioctl 命令进行分别处理。
125         switch (cmd) {
126                 case TCGETS:
    //取相应终端 termios 结构中的信息。
127                         return get_termios(tty,(struct termios *) arg);
128                 case TCSETSF:
    // 在设置 termios 的信息之前，需要先等待输出队列中所有数据处理完，并且刷新(清空)输入队列。
    // 再设置。
129                         flush(&tty->read_q); /* fallthrough */
130                 case TCSETSW:
    // 在设置终端 termios 的信息之前，需要先等待输出队列中所有数据处理完(耗尽)。对于修改参数
    // 会影响输出的情况，就需要使用这种形式。
131                         wait_until_sent(tty); /* fallthrough */
132                 case TCSETS:
    // 设置相应终端 termios 结构中的信息。
133                         return set_termios(tty,(struct termios *) arg);
134                 case TCGETA:
    // 取相应终端 termio 结构中的信息。
135                         return get_termio(tty,(struct termio *) arg);
136                 case TCSETAF:
    // 在设置 termio 的信息之前，需要先等待输出队列中所有数据处理完，并且刷新(清空)输入队列。
    // 再设置。
137                         flush(&tty->read_q); /* fallthrough */
138                 case TCSETAW:
    // 在设置终端 termio 的信息之前，需要先等待输出队列中所有数据处理完(耗尽)。对于修改参数
    // 会影响输出的情况，就需要使用这种形式。
139                         wait_until_sent(tty); /* fallthrough */ /* 继续执行 */
140                 case TCSETA:
    // 设置相应终端 termio 结构中的信息。
141                         return set_termio(tty,(struct termio *) arg);
142                 case TCSBRK:
    // 等待输出队列处理完毕(空)，如果参数值是 0，则发送一个 break。
```

```
143                         if (!arg) {
144                                 wait_until_sent(tty);
145                                 send_break(tty);
146                         }
147                         return 0;
148                 case TCXONC:
    // 开始/停止控制。如果参数值是 0，则挂起输出；如果是 1，则重新开启挂起的输出；如果是 2，则挂
起
    // 输入；如果是 3，则重新开启挂起的输入。
149                         return -EINVAL; /* not implemented */  /* 未实现 */
150                 case TCFLSH:
    //刷新已写输出但还没发送或已收但还没有读数据。如果参数是 0，则刷新(清空)输入队列；如果是 1，
    // 则刷新输出队列；如果是 2，则刷新输入和输出队列。
151                         if (arg==0)
152                                 flush(&tty->read_q);
153                         else if (arg==1)
154                                 flush(&tty->write_q);
155                         else if (arg==2) {
156                                 flush(&tty->read_q);
157                                 flush(&tty->write_q);
158                         } else
159                                 return -EINVAL;
160                         return 0;
161                 case TIOCEXCL:
    // 设置终端串行线路专用模式。
162                         return -EINVAL; /* not implemented */  /* 未实现 */
163                 case TIOCNXCL:
    // 复位终端串行线路专用模式。
164                         return -EINVAL; /* not implemented */  /* 未实现 */
165                 case TIOCSCTTY:
    // 设置 tty 为控制终端。(TIOCNOTTY - 禁止 tty 为控制终端)。
166                         return -EINVAL; /* set controlling term NI */  /* 设置控制终端 NI */
167                 case TIOCGPGRP:                                 // NI - Not Implemented。
    // 读取指定终端设备进程的组 id。首先验证用户缓冲区长度，然后复制 tty 的 pgrp 字段到用户缓冲区。
168                         verify_area((void *) arg,4);
169                         put_fs_long(tty->pgrp,(unsigned long *) arg);
170                         return 0;
171                 case TIOCSPGRP:
    // 设置指定终端设备进程的组 id。
172                         tty->pgrp=get_fs_long((unsigned long *) arg);
173                         return 0;
174                 case TIOCOUTQ:
    // 返回输出队列中还未送出的字符数。首先验证用户缓冲区长度，然后复制队列中字符数给用户。
175                         verify_area((void *) arg,4);
176                         put_fs_long(CHARS(tty->write_q),(unsigned long *) arg);
177                         return 0;
178                 case TIOCINQ:
    // 返回输入队列中还未读取的字符数。首先验证用户缓冲区长度，然后复制队列中字符数给用户。
179                         verify_area((void *) arg,4);
180                         put_fs_long(CHARS(tty->secondary),
181                                 (unsigned long *) arg);
182                         return 0;
183                 case TIOCSTI:
```

```
    // 模拟终端输入。该命令以一个指向字符的指针作为参数，并假装该字符是在终端上键入的。用户必须
    // 在该控制终端上具有超级用户权限或具有读许可权限。
184                         return -EINVAL; /* not implemented */  /* 未实现 */
185                 case TIOCGWINSZ:
    // 读取终端设备窗口大小信息（参见 termios.h 中的 winsize 结构）。
186                         return -EINVAL; /* not implemented */  /* 未实现 */
187                 case TIOCSWINSZ:
    // 设置终端设备窗口大小信息（参见 winsize 结构）。
188                         return -EINVAL; /* not implemented */  /* 未实现 */
189                 case TIOCMGET:
    // 返回 modem 状态控制引线的当前状态比特位标志集（参见 termios.h 中 185-196 行）。
190                         return -EINVAL; /* not implemented */  /* 未实现 */
191                 case TIOCMBIS:
    // 设置单个 modem 状态控制引线的状态(true 或 false)。
192                         return -EINVAL; /* not implemented */  /* 未实现 */
193                 case TIOCMBIC:
    // 复位单个 modem 状态控制引线的状态。
194                         return -EINVAL; /* not implemented */  /* 未实现 */
195                 case TIOCMSET:
    // 设置 modem 状态引线的状态。如果某一比特位置位，则 modem 对应的状态引线将置为有效。
196                         return -EINVAL; /* not implemented */  /* 未实现 */
197                 case TIOCGSOFTCAR:
    // 读取软件载波检测标志(1 - 开启；0 - 关闭)。
198                         return -EINVAL; /* not implemented */  /* 未实现 */
199                 case TIOCSSOFTCAR:
    // 设置软件载波检测标志(1 - 开启；0 - 关闭)。
200                         return -EINVAL; /* not implemented */  /* 未实现 */
201                 default:
202                         return -EINVAL;
203         }
204 }
205
```

7.9.3 其他信息

7.9.3.1 波特率与波特率因子

波特率 = 1.8432MHz /(16 * 波特率因子)。程序中波特率与波特率因子的对应关系见表 7–10 所示。

表 7 - 10 波特率与波特率因子对应表

波特率	波特率因子		波特率	波特率因子	
	MSB,LSB	合并值		MSB,LSB	合并值
50	0x09,0x00	2304	1200	0x00,0x60	96
75	0x06,0x00	1536	1800	0x00,0x40	64
110	0x04,0x17	1047	2400	0x00,0x30	48
134.5	0x03,0x59	857	4800	0x00,0x18	24
150	0x03,0x00	768	9600	0x00,0x1c	12
200	0x02,0x40	576	19200	0x00,0x06	6
300	0x01,0x80	384	38400	0x00,0x03	3
600	0x00,0xc0	192			

第8章 数学协处理器(math)

8.1 概述

内核目录 kernel/math 目录下包含数学协处理器仿真处理代码文件，但该程序目前还没有真正实现对数学协处理器的仿真代码，仅含有一个程序外壳，见列表 8-1 所示。

列表 8-1 linux/kernel/math 目录

	名称	大小	最后修改时间(GMT)	说明
	Makefile	936 bytes	1991-11-18 00:21:45	
	math_emulate.c	1023 bytes	1991-11-23 15:36:34	

8.2 Makefile 文件

8.2.1 功能描述

math 目录下程序的编译管理文件。

8.2.2 代码注释

程序 8-1 linux/kernel/math/Makefile

```
 1 #
 2 # Makefile for the FREAX-kernel character device drivers.
 3 #
 4 # Note! Dependencies are done automagically by 'make dep', which also
 5 # removes any old dependencies. DON'T put your own dependencies here
 6 # unless it's something special (ie not a .c file).
 7 #
   # FREAX(Linux)内核字符设备驱动程序的 Makefile 文件。
   # 注意！依赖关系是由'make dep'自动进行的，它也会自动去除原来的依赖信息。不要把你自己的
   # 依赖关系信息放在这里，除非是特别文件的（也即不是一个.c 文件的信息）。
 8
 9 AR      =gar    # GNU 的二进制文件处理程序，用于创建、修改以及从归档文件中抽取文件。
10 AS      =gas    # GNU 的汇编程序。
11 LD      =gld    # GNU 的连接程序。
12 LDFLAGS =-s -x  # 连接程序所有的参数，-s 输出文件中省略所有符号信息。-x 删除所有局部符号。
13 CC      =gcc    # GNU C 语言编译器。
   # 下一行是 C 编译程序选项。-Wall 显示所有的警告信息；-O 优化选项，优化代码长度和执行时间；
   # -fstrength-reduce 优化循环执行代码，排除重复变量；-fomit-frame-pointer 省略保存不必要
   # 的框架指针；-fcombine-regs 合并寄存器，减少寄存器类的使用；-finline-functions 将所有简
   # 单短小的函数代码嵌入调用程序中；-mstring-insns Linus 自己填加的优化选项，以后不再使用；
```

```
    # -nostdinc -I../include 不使用默认路径中的包含文件，而使用指定目录中的(../../include)。
14  CFLAGS  =-Wall -O -fstrength-reduce -fomit-frame-pointer -fcombine-regs \
15          -finline-functions -mstring-insns -nostdinc -I../../include
    # C 前处理选项。-E 只运行 C 前处理，对所有指定的 C 程序进行预处理并将处理结果输出到标准输
    # 出设备或指定的输出文件中；-nostdinc -I../../include 同前。
16  CPP     =gcc -E -nostdinc -I../../include
17
    # 下面的规则指示 make 利用下面的命令将所有的.c 文件编译生成.s 汇编程序。该规则的命令
    # 指使 gcc 采用 CFLAGS 所指定的选项对 C 代码编译后不进行汇编就停止（-S），从而产生与
    # 输入的各个 C 文件对应的汇编代码文件。默认情况下所产生的汇编程序文件名是原 C 文件名
    # 去掉.c 而加上.s 后缀。-o 表示其后是输出文件的名称。其中$*.s（或$@）是自动目标变量，
    # $<代表第一个先决条件，这里即是符合条件*.c 的文件。
18  .c.s:
19          $(CC) $(CFLAGS) \
20          -S -o $*.s $<
  # 下面规则表示将所有.s 汇编程序文件编译成.o 目标文件。22 行是实现该操作的具体命令。
21  .s.o:
22          $(AS) -c -o $*.o $<
23  .c.o:                       # 类似上面，*.c 文件-→*.o 目标文件。不进行连接。
24          $(CC) $(CFLAGS) \
25          -c -o $*.o $<
26
27  OBJS  = math_emulate.o    # 定义目标文件变量 OBJS。
28
29  math.a: $(OBJS)          # 在有了先决条件 OBJS 后使用下面的命令连接成目标 math.a 库文件。
30          $(AR) rcs math.a $(OBJS)
31          sync
32
    # 下面的规则用于清理工作。当执行'make clean'时，就会执行下面的命令，去除所有编译
    # 连接生成的文件。'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
33  clean:
34          rm -f core *.o *.a tmp_make
35          for i in *.c;do rm -f `basename $$i .c`.s;done
36
    # 下面得目标或规则用于检查各文件之间的依赖关系。方法如下：
    # 使用字符串编辑程序 sed 对 Makefile 文件（即是本文件）进行处理，输出为删除 Makefile
    # 文件中'### Dependencies'行后面的所有行，并生成 tmp_make 临时文件。然后对 kernel/math/
    # 目录下的每个 C 文件执行 gcc 预处理操作.
    # -M 标志告诉预处理程序输出描述每个目标文件相关性的规则，并且这些规则符合 make 语法。
    # 对于每一个源文件，预处理程序输出一个 make 规则，其结果形式是相应源程序文件的目标
    # 文件名加上其依赖关系--该源文件中包含的所有头文件列表。把预处理结果都添加到临时
    # 文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。
37  dep:
38          sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
39          (for i in *.c;do echo -n `echo $$i | sed 's,\.c,\.s,'`" "; \
40                  $(CPP) -M $$i;done) >> tmp_make
41          cp tmp_make Makefile
42
43  ### Dependencies:
```

8.3 math-emulation.c 程序

8.3.1 功能描述

数学协处理器仿真处理代码文件。该程序目前还没有实现对数学协处理器的仿真代码。仅实现了协处理器发生异常中断时调用的两个 C 函数。math_emulate()仅在用户程序中包含协处理器指令时，对进程设置协处理器异常信号。

8.3.2 代码注释

程序 8-2 linux/kernel/math/math_emulate.c

```
1  /*
2   * linux/kernel/math/math_emulate.c
3   *
4   * (C) 1991 Linus Torvalds
5   */
6
7  /*
8   * This directory should contain the math-emulation code.
9   * Currently only results in a signal.
10  */
    /*
     * 该目录里应该包含数学仿真代码。目前仅产生一个信号。
     */
11
12 #include <signal.h>        // 信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
13
14 #include <linux/sched.h>   // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                               // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
15 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
16 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
17
    //// 协处理器仿真函数。
    // 中断处理程序调用的 C 函数，参见(kernel/math/system_call.s，169 行)。
18 void math_emulate(long edi, long esi, long ebp, long sys_call_ret,
19         long eax,long ebx,long ecx,long edx,
20         unsigned short fs,unsigned short es,unsigned short ds,
21         unsigned long eip,unsigned short cs,unsigned long eflags,
22         unsigned short ss, unsigned long esp)
23 {
24         unsigned char first, second;
25
26 /* 0x0007 means user code space */
    /* 0x0007 表示用户代码空间 */
    // 选择符 0x000F 表示在局部描述符表中描述符索引值=1，即代码空间。如果段寄存器 cs 不等于 0x000F
    // 则表示 cs 一定是内核代码选择符，是在内核代码空间，则出错，显示此时的 cs:eip 值，并显示信息
    // “内核中需要数学仿真”，然后进入死机状态。
27         if (cs != 0x000F) {
28                 printk("math_emulate: %04x:%08x\n\r",cs,eip);
29                 panic("Math emulation needed in kernel");
30         }
```

```
    // 取用户数据区堆栈数据 first 和 second，显示这些数据，并给进程设置浮点异常信号 SIGFPE。
31          first = get_fs_byte((char *)((*&eip)++));
32          second = get_fs_byte((char *)((*&eip)++));
33          printk("%04x:%08x %02x %02x\n\r",cs,eip-2,first,second);
34          current->signal |= 1<<(SIGFPE-1);
35  }
36
    //// 协处理器出错处理函数。
    // 中断处理程序调用的 C 函数，参见(kernel/math/system_call.s，145 行)。
37  void math_error(void)
38  {
    // 协处理器指令。(以非等待形式)清除所有异常标志、忙标志和状态字位 7。
39          __asm__("fnclex");
    // 如果上个任务使用过协处理器，则向上个任务发送协处理器异常信号。
40          if (last_task_used_math)
41                  last_task_used_math->signal |= 1<<(SIGFPE-1);
42  }
43
```

第9章 文件系统(fs)

9.1 概述

本章涉及 linux 内核中文件系统的实现代码和用于块设备的高速缓冲区管理程序。在开发 linux 0.11 内核的文件系统时，Linus 主要参照了 Andrew S.Tanenbaum 著的《MINIX 操作系统设计与实现》一书，使用了其中的 MINIX 文件系统 1.0 版。因此在阅读本章内容时，可以参考该书有关 MINIX 文件系统的相关章节。而高速缓冲区的工作原理可参见 M.J.Bach 的《UNIX 操作系统设计》第三章内容。

列表 9-1 linux/fs 目录

	名称	大小	最后修改时间 (GMT)	说明
	Makefile	5053 bytes	1991-12-02 03:21:31	m
	bitmap.c	4042 bytes	1991-11-26 21:31:53	m
	block_dev.c	1422 bytes	1991-10-31 17:19:55	m
	buffer.c	9072 bytes	1991-12-06 20:21:00	m
	char_dev.c	2103 bytes	1991-11-19 09:10:22	m
	exec.c	9134 bytes	1991-12-01 20:01:01	m
	fcntl.c	1455 bytes	1991-10-02 14:16:29	m
	file_dev.c	1852 bytes	1991-12-01 19:02:43	m
	file_table.c	122 bytes	1991-10-02 14:16:29	m
	inode.c	6933 bytes	1991-12-06 20:16:35	m
	ioctl.c	977 bytes	1991-11-19 09:13:05	
	namei.c	16562 bytes	1991-11-25 19:19:59	m
	open.c	4340 bytes	1991-11-25 19:21:01	m
	pipe.c	2385 bytes	1991-10-18 19:02:33	m
	read_write.c	2802 bytes	1991-11-25 15:47:20	m
	stat.c	1175 bytes	1991-10-02 14:16:29	m
	super.c	5628 bytes	1991-12-06 20:10:12	m
	truncate.c	1148 bytes	1991-10-02 14:16:29	m

9.2 总体功能描述

本章所注释说明的程序量较大，但我们可以把它们从功能上分为四个部分。第一部分是有关高速缓冲区的管理程序，主要实现了对硬盘等块设备进行数据高速存取的函数。该部分内容集中在 buffer.c 程序中实现；第二部分代码描述了文件系统的低层通用函数。说明了文件索引节点的管理、磁盘数据块的分配和释放以及文件名与 i 节点的转换算法；第三部分程序是有关对文件中数据进行读写操作，包括对

字符设备、管道、块读写文件中数据的访问；第四部分的程序主要涉及文件的系统调用接口的实现，主要涉及文件打开、关闭、创建以及有关文件目录操作等的系统调用。

下面首先介绍一下 MINIX 文件系统的基本结构，然后分别对这四部分加以说明。

9.2.1 MINIX 文件系统

目前 MINIX 的版本是 2.0，所使用的文件系统是 2.0 版，它与其 1.5 版系统之前的版本不同，对其容量已经作了扩展。但由于本书注释的 linux 内核使用的是 MINIX 文件系统 1.0 版本，所以这里仅对其 1.0 版文件系统作简单介绍。

MINIX 文件系统与标准 UNIX 的文件系统基本相同。它由 6 个部分组成。对于一个 360K 的软盘，其各部分的分布见图 9-1 所示。

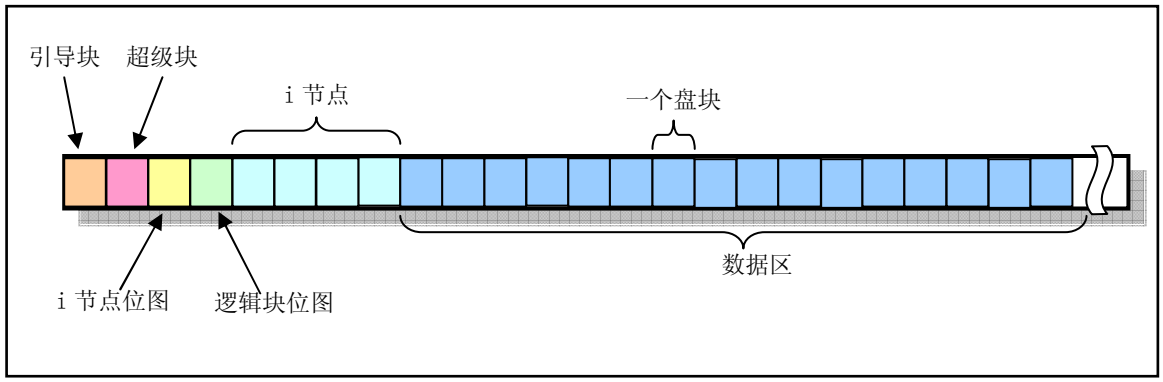

图 9-1 建有 MINIX 文件系统的一个 360K 软盘中文件系统各部分的布局示意图

图中，整个磁盘被划分成以 1KB 为单位的磁盘块，因此上图中共有 360 个磁盘块，每个方格表示一个磁盘块。在后面的说明我们会知道，在 MINIX 1.0 文件系统中，其磁盘块大小与逻辑块大小正好是一样的，也是 1KB 字节。因此 360KB 盘片也含有 360 个逻辑块。在后面的讨论中我们有时会混合使用这两个名称。

引导块是计算机加电启动时可由 ROM BIOS 自动读入的执行代码和数据。但并非所有盘都用于作为引导设备，所以对于不用于引导的盘片，这一盘块中可以不含代码。但任何盘片必须含有引导块，以保持 MINIX 文件系统格式的统一。

超级块用于存放盘设备上文件系统结构的信息，并说明各部分的大小。其结构见图 9-2 所示。其中，s_ninodes 表示设备上的 i 节点总数。s_nzones 表示设备上以逻辑块为单位的总逻辑块数。s_imap_blocks 和 s_zmap_blocks 分别表示 i 节点位图和逻辑块位图所占用的磁盘块数。s_firstdatazone 表示设备上数据区开始处占用的第一个逻辑块块号。s_log_zone_size 是使用 2 位底的对数表示的每个逻辑块包含的磁盘块数。对于 MINIX 1.0 文件系统该值为 0，因此其逻辑块的大小就等于磁盘块大小，都是 1KB。s_max_size 是以字节表示的最大文件长度。当然这个长度值将受到磁盘容量的限制。s_magic 是文件系统魔幻数，用以指明文件系统的类型。对于 MINIX 1.0 文件系统，它的魔幻数是 0x137f。

	字段名称	数据类型	说明
出现在盘上和内存中的字段	s_ninodes	short	i 节点数
	s_nzones	short	逻辑块数(或称为区块数)
	s_imap_blocks	short	i 节点位图所占块数
	s_zmap_blocks	short	逻辑块位图所占块数
	s_firstdatazone	short	数据区中第一个逻辑块块号
	s_log_zone_size	short	Log_2(磁盘块数/逻辑块)
	s_max_size	long	最大文件长度
	s_magic	short	文件系统幻数
仅在内存中使用的字段	s_imap[8]	buffer_head *	i 节点位图在高速缓冲块指针数组
	s_zmap[8]	buffer_head *	逻辑块位图在高速缓冲块指针数组
	s_dev	short	超级块所在设备号
	s_isup	m_inode *	被安装文件系统根目录 i 节点
	s_imount	m_inode *	该文件系统被安装到的 i 节点
	s_time	long	修改时间
	s_wait	task_struct *	等待本超级块的进程指针
	s_lock	char	锁定标志
	s_rd_only	char	只读标志
	s_dirt	char	已被修改(脏)标志

图 9-2 MINIX 的超级块结构

逻辑块位图用于描述盘上的每个数据盘块的使用情况，每个比特位代表盘上数据区中的一个逻辑块。因此，逻辑块位图的第一个比特位代表盘上数据区中第一个数据盘块，而非盘上的第一个磁盘块（引导块）。当一个数据盘块被占用时，则逻辑块位图中相应比特位被置位。与 i 节点位图相似的原因，逻辑块位图的。

从超级块的结构中我们还可以看出，逻辑块位图最多使用 8 块缓冲块（s_zmap[8]），而每块缓冲块大小是 1024 字节，每比特表示一个盘块的占用状态，因此一个缓冲块可代表 8192 个盘块。8 个缓冲块总共可表示 65536 个盘块，因此 MINIX 文件系统 1.0 所能支持的最大块设备容量（长度）是 64MB。

i 节点位图用于说明 i 节点是否被使用，同样是每个比特位代表一个 i 节点。对于 1K 大小的盘块来讲，一个盘块就可表示 8192 个 i 节点的使用状况。但第一个 i 节点位图块中只能表示 8191 个 i 节点状况，因为其中第一个比特位表示 0 号 i 节点，它并不存在，因此不用。

盘上的 i 节点部分存放着文件系统中文件或目录名的索引节点，每个文件或目录名都有一个 i 节点。每个 i 节点结构中存放着对应文件的相关信息，如文件宿主的 id(uid)、文件所属组 id（gid）、文件长度和访问修改时间等。整个结构共使用 32 个字节，见图 9-3 所示。

	字段名称	数据类型	说明
在盘上和内存中的字段，共 32 字节	i_mode	short	文件的类型和属性（rwx 位）
	i_uid	short	文件宿主的用户 id
	i_size	long	文件长度（字节）
	i_mtime	long	修改时间（从 1970.1.1:0 时算起，秒）
	i_gid	char	文件宿主的组 id
	i_nlinks	char	链接数（有多少个文件目录项指向该 i 节点）
	i_zone[9]	short	文件所占用的盘上逻辑块号数组。其中： zone[0]-zone[6]是直接块号； zone[7]是一次间接块号； zone[8]是二次（双重）间接块号。 注：zone 是区的意思，可译成区块或逻辑块。
仅在内存中使用的字段	i_wait	* task_struct	等待该 i 节点的进程。
	i_atime	long	最后访问时间。
	i_ctime	long	i 节点自身被修改时间。
	i_dev	short	i 节点所在的设备号。
	i_num	short	i 节点号。
	i_count	short	i 节点被引用的次数，0 表示空闲。
	i_lock	char	i 节点被锁定标志。
	i_dirt	char	i 节点已被修改（脏）标志。
	i_pipe	char	i 节点用作管道标志。
	i_mount	char	i 节点安装了其他文件系统标志。
	i_seek	char	搜索标志（lseek 操作时）。
	i_update	char	i 节点已更新标志。

图 9-3 MINIX 文件系统 1.0 版的 i 节点结构

i_mode 字段用来保存文件的类型和访问权限属性。其比特位 15-12 用于保存文件类型，位 11-9 保存执行文件时设置的信息，位 8-0 表示文件的访问权限。具体信息参见文件 include/sys/stat.h 和 include/fcntl.h。

文件中的数据是放在磁盘块的数据区中的，而一个文件名则通过对应的 i 节点与这些数据磁盘块相联系，这些盘块的号码就存放在 i 节点的逻辑块数组 i_zone[]中。其中，i_zone[]数组用于存放 i 节点对应文件的盘块号。i_zone[0]到 i_zone[6]用于存放文件开始的 7 个磁盘块号，称为直接块。若文件长度小于等于 7K 字节，则根据其 i 节点可以很快就找到它所使用的盘块。若文件大一些时，就需要用到一次间接块了（i_zone[7]），这个盘块中存放着附加的盘块号。对于 MINIX 文件系统它可以存放 512 个盘块号，因此可以寻址 512 个盘块。若文件还要大，则需要使用二次间接盘块（i_zone[8]）。二次间接块的一级盘块的作用类似与一次间接盘块，因此使用二次间接盘块可以寻址 512*512 个盘块。参见图 9-4 所示。

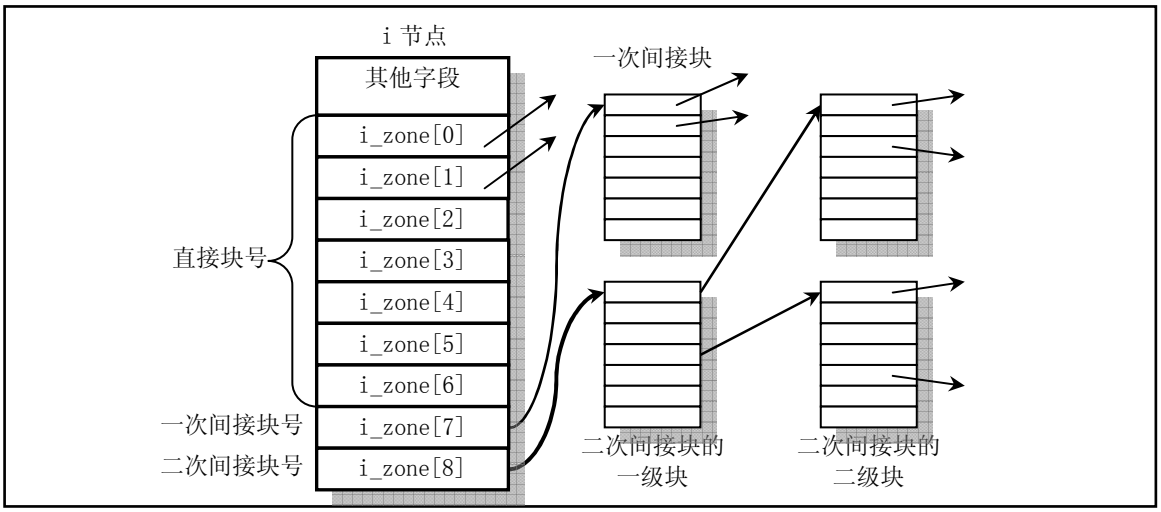

图 9-4 i 节点的逻辑块（区块）数组的功能

当所有 i 节点都被使用时，查找空闲 i 节点的函数会返回值 0，因此，i 节点位图最低比特位和 i 节点 0 都闲置不用，并在创建文件系统时将 i 节点 0 的比特位置位。

对于 PC 机来讲，一般以一个扇区的长度（512 字节）作为块设备的数据块长度。而 MINIX 文件系统则将连续的 2 个扇区数据（1024 字节）作为一个数据块来处理，称之为一个磁盘块或盘块。其长度与高速缓冲区中的缓冲块长度相同。编号是从盘上第一个盘块开始算起，也即引导块是 0 号盘块。而上述的逻辑块或区块，则是盘块的 2 的幂次倍数。一个逻辑块长度可以等于 1、2、4 或 8 个盘块长度。对于本书所讨论的 linux 内核，逻辑块的长度等于盘块长度。因此在代码注释中这两个术语含义相同。但是术语数据逻辑块（或数据盘块）则是指盘设备上数据部分中，从第一个数据盘块开始编号的盘块。

9.2.2 文件的类型与属性

UNIX 类操作系统中的文件通常可分为 6 类。如果在 shell 下执行"ls -l"命令，我们就可以从所列出的文件状态信息中知道文件的类型。见图 9-5 所示。

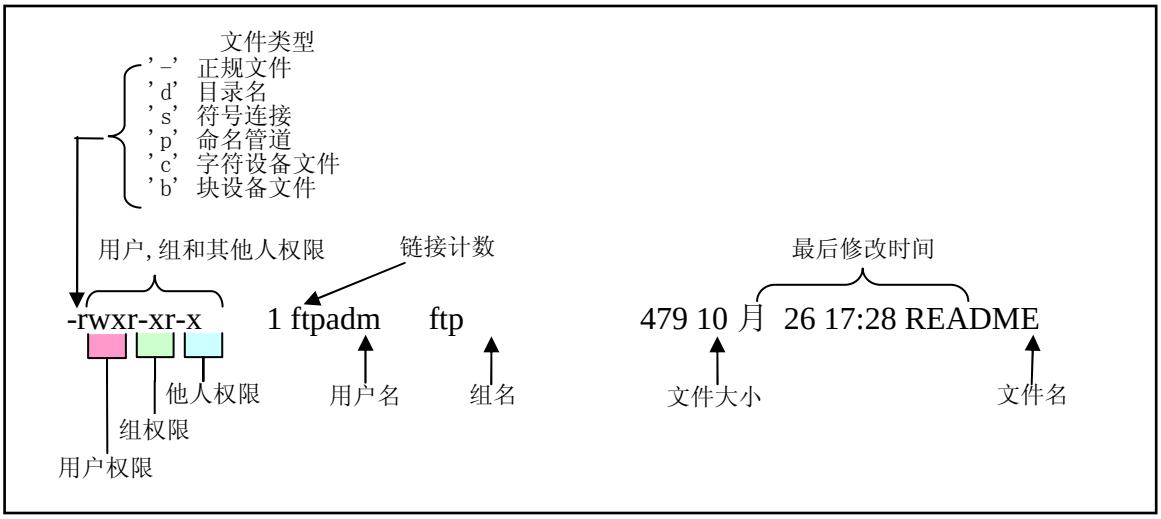

图 9-5 命令‘ls -l’显示的文件信息

图中，命令显示的第一个字节表示所列文件的类型。'-'表示该文件是一个正规（一般）文件。

正规文件（'-'）是一类文件系统对其不作解释的文件，包含有任何长度的字节流。例如源程序文件、

二进制执行文件、文档以及脚本文件。

目录（'d'）在 UNIX 文件系统中也是一种文件，但文件系统管理会对其内容进行解释，以使人们可以看到有那些文件包含在一个目录中，以及它们是如何组织在一起构成一个分层次的文件系统的。

符号连接（'s'）用于使用一个不同文件名来引用另一个文件。符号连接可以跨越一个文件系统而连接到另一个文件系统中的一个文件上。删除一个符号连接并不影响被连接的文件。另外还有一种连接方式称为“硬连接”。它与这里所说符号连接中被连接文件的地位相同，被作为一般文件对待，但不能跨越文件系统（或设备）进行连接，并且会递增文件的连接计数值。见下面对链接计数的说明。

命名管道（'p'）文件是系统创建有名管道时建立的文件。可用于无关进程之间的通信。

字符设备（'c'）文件用于以操作文件的方式访问字符设备，例如 tty 终端、内存设备以及网络设备。

块设备（'b'）文件用于访问象硬盘、软盘等的设备。在 UNIX 类操作系统中，块设备文件和字符设备文件一般均存放在系统的/dev 目录中。

在 linux 内核中，文件的类型信息保存在对应 i 节点的 i_mode 字段中，使用高 4 比特位来表示，并使用了一些判断文件类型宏，例如 S_ISBLK、S_ISDIR 等，这些宏在 include/sys/stat.h 中定义。

在图中文件类型字符后面是每三个字符一组构成的三组文件权限属性。用于表示文件宿主、同组用户和其他用户对文件的访问权限。'rwx'分别表示对文件可读、可写和可执行的许可权。对于目录文件，可执行表示可以进入目录。在对文件的权限进行操作时，一般使用八进制来表示它们。例如'755'表示文件宿主对文件可以读/写/执行，同组用户和其他人可以读和执行文件。在 linux 0.11 源代码中，文件权限信息也保存在对应 i 节点的 i_mode 字段中，使用该字段的低 9 比特位表示三组权限。并常使用变量 mode 来表示。有关文件权限的宏在 include/fcntl.h 中定义。

图中的'链接计数'位表示该文件被硬连接引用的次数。当计数减为零时，该文件即被删除。'用户名'表示该文件宿主的名称，'组名'是该用户所属组的名称。

9.2.3 高速缓冲区

高速缓冲区是文件系统访问块设备中数据的必经要道。为了访问文件系统等块设备上的数据，内核可以每次都访问块设备，进行读或写操作。但是每次 I/O 操作的时间与内存和 CPU 的处理速度相比是非常慢的。为了提高系统的性能，内核就在内存中开辟了一个高速数据缓冲区（池）（buffer cache），并将其划分成一个个与磁盘数据块大小相等的缓冲块来使用和管理，以期减少访问块设备的次数。在 linux 内核中，高速缓冲区位于内核代码和主内存区之间，参见图 2.6 所示。高速缓冲中存放着最近被使用过的各个块设备中的数据块。当需要从块设备中读取数据时，缓冲区管理程序首先会在高速缓冲中寻找。如果相应数据已经在缓冲中，就无需再从块设备上读。如果数据不在高速缓冲中，就发出读块设备的命令，将数据读到高速缓冲中。当需要把数据写到块设备中时，系统就会在高速缓冲区中申请一块空闲的缓冲块来临时存放这些数据。至于什么时候把数据真正地写到设备中去，则是通过设备数据同步实现的。

Linux 内核实现高速缓冲区的程序是 buffer.c。文件系统中其他程序通过指定需要访问的设备号和数据逻辑块号来调用它的块读写函数。这些接口函数有：块读取函数 bread()、块提前预读函数 breada()和页块读取函数 bread_page()。页块读取函数一次读取一页内存所能容纳的缓冲块数（4 块）。

9.2.4 文件系统底层函数

文件系统的底层处理函数包含在以下 4 个文件中：

- bitmap.c 程序包括对 i 节点位图和逻辑块位图进行释放和占用处理函数。操作 i 节点位图的函数是 free_inode()和 new_inode()，操作逻辑块位图的函数是 free_block()和 new_block()。
- inode.c 程序包括分配 i 节点函数 iget()和释放对内存 i 节点存取函数 iput()以及根据 i 节点信息取文件数据块在设备上对应的逻辑块号函数 bmap()。
- namei.c 程序主要包括函数 namei()。该函数使用 iget()、iput()和 bmap()将给定的文件路径名映射到其 i 节点。

- super.c 程序专门用于处理文件系统超级块，包括函数 get_super()、put_super()和 free_super()等。还包括几个文件系统加载/卸载处理函数和系统调用，如 sys_mount()等。

这些文件中函数之间的层次关系如图 9-6 所示。

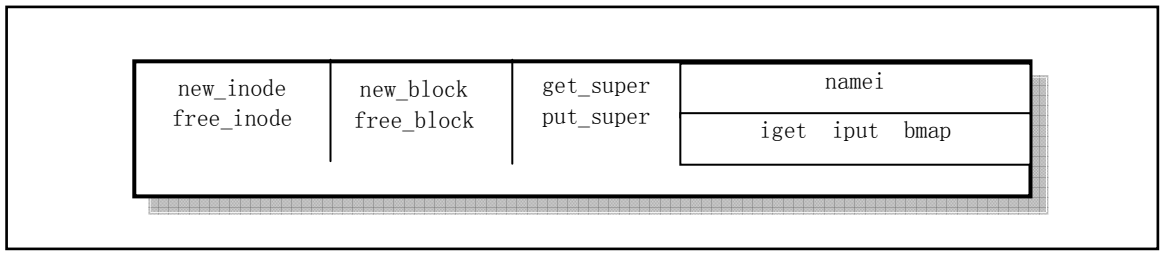

图 9-6 文件系统低层操作函数层次关系

9.2.5 文件中数据的访问操作

关于文件中数据的访问操作代码，主要涉及 5 个文件：block_dev.c、file_dev.c、char_dev.c、pipe.c 和 read_write.c。前 4 个文件可以认为是块设备、字符设备、管道设备和普通文件与文件读写系统调用的接口程序，它们共同实现了 read_write.c 中的 read()和 write()系统调用。通过对被操作文件属性的判断，这两个系统调用会分别调用这些文件中的相关处理函数进行操作。

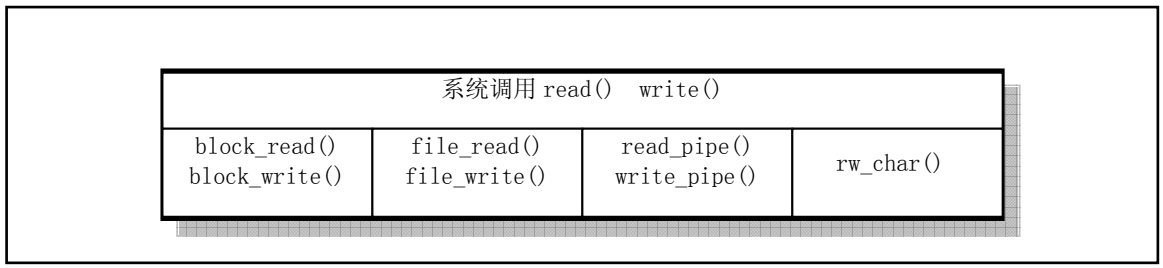

图 9-7 文件数据访问函数

block_dev.c 中的函数 block_read()和 block_write()是用于读写块设备特殊文件中的数据。所使用的参数指定了要访问的设备号、读写的起始位置和长度。

file_dev.c 中的 file_read()和 file_write()函数是用于访问一般的正规文件。通过指定文件对应的 i 节点和文件结构，从而可以知道文件所在的设备号和文件当前的读写指针。

pipe.c 文件中实现了管道读写函数 read_pipe()和 write_pipe()。另外还实现了创建无名管道的系统调用 pipe()。管道主要用于在进程之间按照先进先出的方式传送数据，也可以用于使进程同步执行。有两种类型的管道：有名管道和无名管道。有名管道是使用文件系统的 open 调用建立的，而无名管道则使用系统调用 pipe()来创建。在使用管道时，则都用正规文件的 read()、write()和 close()函数。只有发出 pipe 调用的后代，才能共享对无名管道的存取，而所有进程只要权限许可，都可以访问有名管道。

对于管道的读写，可以看成是一个进程从管道的一端写入数据，而另一个进程从管道的另一端读出数据。内核存取管道中数据的方式与存取一般正规文件中数据的方式完全一样。为管道分配存储空间和为正规文件分配空间的不同之处是，管道只使用 i 节点的直接块。内核将 i 节点的直接块作为一个循环队列来管理，通过修改读写指针来保证先进先出的顺序。

对于字符设备文件，系统调用 read()和 write()会调用 char_dev.c 中的 rw_char()函数来操作。字符设备包括控制台终端（tty）、串口终端(ttyx)和内存字符设备。

另外，内核使用文件结构 file 和文件表 file_table[]来管理对文件的操作访问。文件结构 file 如下所示。

```
struct file {
        unsigned short f_mode;          // 文件操作模式（RW 位）
        unsigned short f_flags;         // 文件打开和控制的标志。
        unsigned short f_count;         // 对应文件句柄（文件描述符）数。
        struct m_inode * f_inode;       // 指向对应 i 节点。
        off_t f_pos;                    // 文件当前读写指针位置。
};
```

用于在文件句柄与 i 节点之间建立关系。文件表是文件结构数组，在 linux 0.11 内核中文件表最多可有 64 项，因此整个系统同时最多打开 64 个文件。而每个进程最多可同时打开 20 个文件。

9.2.6 文件和目录管理系统调用

有关文件系统调用的上层实现，基本上包括图 9-8 中 5 个文件。

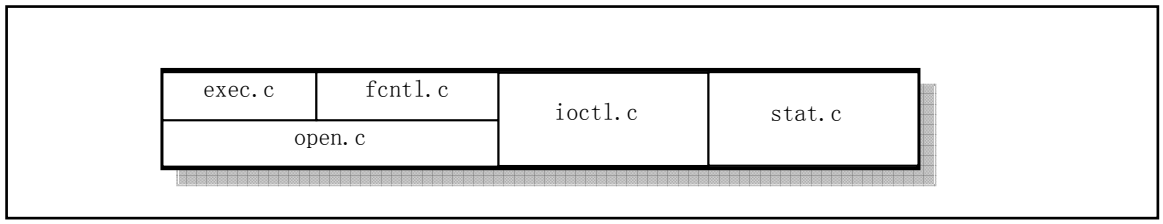

图 9-8 文件系统上层操作程序

open.c 文件用于实现与文件操作相关的系统调用。主要有文件的创建、打开和关闭，文件宿主和属性的修改、文件访问权限的修改、文件操作时间的修改和系统文件系统 root 的变动等。

exec.c 程序实现对二进制可执行文件和 shell 脚本文件的加载与执行。其中主要的函数是函数 do_execve()，它是系统中断调用(int 0x80)功能号__NR_execve()调用的 C 处理函数，是 exec()函数簇的主要实现函数。

fcntl.c 实现了文件控制系统调用 fcntl()和两个文件句柄(描述符)复制系统调用 dup()和 dup2()。dup2()指定了新句柄的数值，而 dup()则返回当前值最小的未用句柄。句柄复制操作主要用在文件的标准输入/输出重定向和管道操作方面。

ioctl.c 文件实现了输入/输出控制系统调用 ioctl()。主要调用 tty_ioctl()函数，对终端的 I/O 进行控制。

stat.c 文件用于实现取文件状态信息系统调用 stat()和 fstat()。stat()是利用文件名取信息，而 fstat()是使用文件句柄(描述符)来取信息。

9.3 Makefile 文件

9.3.1 功能描述

makefile 是文件系统子目录中程序编译的管理配置文件，供编译管理工具软件 make 使用。

9.3.2 代码注释

程序 9-1 linux/fs/Makefile

```
1 AR      =gar    # GNU 的二进制文件处理程序，用于创建、修改以及从归档文件中抽取文件。
2 AS      =gas    # GNU 的汇编程序。
3 CC      =gcc    # GNU C 语言编译器。
4 LD      =gld    # GNU 的连接程序。

  # C 编译程序选项。-Wall 显示所有的警告信息；-O 优化选项，优化代码长度和执行时间；
  # -fstrength-reduce 优化循环执行代码，排除重复变量；-fomit-frame-pointer 省略保存不必要
  # 的框架指针；-fcombine-regs 合并寄存器，减少寄存器类的使用；-mstring-insns Linus 自己
  # 填加的优化选项，以后不再使用；-nostdinc -I../include 不使用默认路径中的包含文件，而使
  # 用这里指定目录中的(../include)。
5 CFLAGS  =-Wall -O -fstrength-reduce -fcombine-regs -fomit-frame-pointer \
6         -mstring-insns -nostdinc -I../include

  # C 前处理选项。-E 只运行 C 前处理，对所有指定的 C 程序进行预处理并将处理结果输出到标准输
  # 出设备或指定的输出文件中；-nostdinc -I../include 同前。
7 CPP     =gcc -E -nostdinc -I../include
8
  # 下面的规则指示 make 利用下面的命令将所有的.c 文件编译生成.s 汇编程序。该规则的命令
  # 指使 gcc 采用 CFLAGS 所指定的选项对 C 代码编译后不进行汇编就停止（-S），从而产生与
  # 输入的各个 C 文件对应的汇编代码文件。默认情况下所产生的汇编程序文件名是原 C 文件名
  # 去掉.c 而加上.s 后缀。-o 表示其后是输出文件的名称。其中$*.s（或$@）是自动目标变量，
  # $<代表第一个先决条件，这里即是符合条件*.c 的文件。
9 .c.s:
10        $(CC) $(CFLAGS) \
11        -S -o $*.s $<
  # 将所有*.c 文件编译成*.o 目标文件。不进行连接。
12 .c.o:
13        $(CC) $(CFLAGS) \
14        -c -o $*.o $<
  # 下面规则表示将所有.s 汇编程序文件编译成.o 目标文件。16 行是实现该操作的具体命令。
15 .s.o:
16        $(AS) -o $*.o $<
17
  # 定义目标文件变量 OBJS。
18 OBJS=    open.o read_write.o inode.o file_table.o buffer.o super.o \
19        block_dev.o char_dev.o file_dev.o stat.o exec.o pipe.o namei.o \
20        bitmap.o fcntl.o ioctl.o truncate.o
21
  # 在有了先决条件 OBJS 后使用下面的命令连接成目标 fs.o
22 fs.o: $(OBJS)
23        $(LD) -r -o fs.o $(OBJS)
24
  # 下面的规则用于清理工作。当执行'make clean'时，就会执行 26--27 行上的命令，去除所有编译
  # 连接生成的文件。'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
25 clean:
26        rm -f core *.o *.a tmp_make
27        for i in *.c;do rm -f `basename $$i .c`.s;done
28
  # 下面得目标或规则用于检查各文件之间的依赖关系。方法如下：
  # 使用字符串编辑程序 sed 对 Makefile 文件（这里即是自己）进行处理，输出为删除 Makefile
  # 文件中'### Dependencies'行后面的所有行（下面从 35 开始的行），并生成 tmp_make
  # 临时文件（30 行的作用）。然后对 fs/目录下的每一个 C 文件执行 gcc 预处理操作.
  # -M 标志告诉预处理程序输出描述每个目标文件相关性的规则，并且这些规则符合 make 语法。
```

```
    # 对于每一个源文件，预处理程序输出一个 make 规则，其结果形式是相应源程序文件的目标
    # 文件名加上其依赖关系--该源文件中包含的所有头文件列表。把预处理结果都添加到临时
    # 文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。
29  dep:
30          sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
31          (for i in *.c;do $(CPP) -M $$i;done) >> tmp_make
32          cp tmp_make Makefile
33
34  ### Dependencies:
35  bitmap.o : bitmap.c ../include/string.h ../include/linux/sched.h \
36    ../include/linux/head.h ../include/linux/fs.h ../include/sys/types.h \
37    ../include/linux/mm.h ../include/signal.h ../include/linux/kernel.h
38  block_dev.o : block_dev.c ../include/errno.h ../include/linux/sched.h \
39    ../include/linux/head.h ../include/linux/fs.h ../include/sys/types.h \
40    ../include/linux/mm.h ../include/signal.h ../include/linux/kernel.h \
41    ../include/asm/segment.h ../include/asm/system.h
42  buffer.o : buffer.c ../include/stdarg.h ../include/linux/config.h \
43    ../include/linux/sched.h ../include/linux/head.h ../include/linux/fs.h \
44    ../include/sys/types.h ../include/linux/mm.h ../include/signal.h \
45    ../include/linux/kernel.h ../include/asm/system.h ../include/asm/io.h
46  char_dev.o : char_dev.c ../include/errno.h ../include/sys/types.h \
47    ../include/linux/sched.h ../include/linux/head.h ../include/linux/fs.h \
48    ../include/linux/mm.h ../include/signal.h ../include/linux/kernel.h \
49    ../include/asm/segment.h ../include/asm/io.h
50  exec.o : exec.c ../include/errno.h ../include/string.h \
51    ../include/sys/stat.h ../include/sys/types.h ../include/a.out.h \
52    ../include/linux/fs.h ../include/linux/sched.h ../include/linux/head.h \
53    ../include/linux/mm.h ../include/signal.h ../include/linux/kernel.h \
54    ../include/asm/segment.h
55  fcntl.o : fcntl.c ../include/string.h ../include/errno.h \
56    ../include/linux/sched.h ../include/linux/head.h ../include/linux/fs.h \
57    ../include/sys/types.h ../include/linux/mm.h ../include/signal.h \
58    ../include/linux/kernel.h ../include/asm/segment.h ../include/fcntl.h \
59    ../include/sys/stat.h
60  file_dev.o : file_dev.c ../include/errno.h ../include/fcntl.h \
61    ../include/sys/types.h ../include/linux/sched.h ../include/linux/head.h \
62    ../include/linux/fs.h ../include/linux/mm.h ../include/signal.h \
63    ../include/linux/kernel.h ../include/asm/segment.h
64  file_table.o : file_table.c ../include/linux/fs.h ../include/sys/types.h
65  inode.o : inode.c ../include/string.h ../include/sys/stat.h \
66    ../include/sys/types.h ../include/linux/sched.h ../include/linux/head.h \
67    ../include/linux/fs.h ../include/linux/mm.h ../include/signal.h \
68    ../include/linux/kernel.h ../include/asm/system.h
69  ioctl.o : ioctl.c ../include/string.h ../include/errno.h \
70    ../include/sys/stat.h ../include/sys/types.h ../include/linux/sched.h \
71    ../include/linux/head.h ../include/linux/fs.h ../include/linux/mm.h \
72    ../include/signal.h
73  namei.o : namei.c ../include/linux/sched.h ../include/linux/head.h \
74    ../include/linux/fs.h ../include/sys/types.h ../include/linux/mm.h \
75    ../include/signal.h ../include/linux/kernel.h ../include/asm/segment.h \
76    ../include/string.h ../include/fcntl.h ../include/errno.h \
77    ../include/const.h ../include/sys/stat.h
78  open.o : open.c ../include/string.h ../include/errno.h ../include/fcntl.h \
```

```
 79   ../include/sys/types.h ../include/utime.h ../include/sys/stat.h \
 80   ../include/linux/sched.h ../include/linux/head.h ../include/linux/fs.h \
 81   ../include/linux/mm.h ../include/signal.h ../include/linux/tty.h \
 82   ../include/termios.h ../include/linux/kernel.h ../include/asm/segment.h
 83 pipe.o : pipe.c ../include/signal.h ../include/sys/types.h \
 84   ../include/linux/sched.h ../include/linux/head.h ../include/linux/fs.h \
 85   ../include/linux/mm.h ../include/asm/segment.h
 86 read_write.o : read_write.c ../include/sys/stat.h ../include/sys/types.h \
 87   ../include/errno.h ../include/linux/kernel.h ../include/linux/sched.h \
 88   ../include/linux/head.h ../include/linux/fs.h ../include/linux/mm.h \
 89   ../include/signal.h ../include/asm/segment.h
 90 stat.o : stat.c ../include/errno.h ../include/sys/stat.h \
 91   ../include/sys/types.h ../include/linux/fs.h ../include/linux/sched.h \
 92   ../include/linux/head.h ../include/linux/mm.h ../include/signal.h \
 93   ../include/linux/kernel.h ../include/asm/segment.h
 94 super.o : super.c ../include/linux/config.h ../include/linux/sched.h \
 95   ../include/linux/head.h ../include/linux/fs.h ../include/sys/types.h \
 96   ../include/linux/mm.h ../include/signal.h ../include/linux/kernel.h \
 97   ../include/asm/system.h ../include/errno.h ../include/sys/stat.h
 98 truncate.o : truncate.c ../include/linux/sched.h ../include/linux/head.h \
 99   ../include/linux/fs.h ../include/sys/types.h ../include/linux/mm.h \
100   ../include/signal.h ../include/sys/stat.h
```

9.4 buffer.c 程序

9.4.1 功能描述

buffer.c 程序用于对高速缓冲区(池)进行操作和管理。高速缓冲区位于内核代码块和主内存区之间，见图 9-9 中所示。高速缓冲区在块设备与内核其他程序之间起着一个桥梁作用。除了块设备驱动程序以外，内核程序如果需要访问块设备中的数据，就都需要经过高速缓冲区来间接地操作。

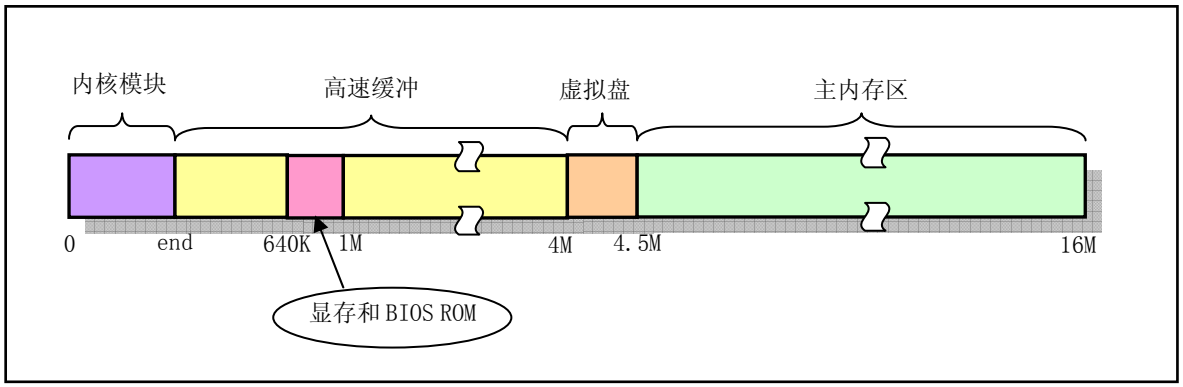

图 9-9 高速缓冲区在整个物理内存中所处的位置

图中高速缓冲区的起始位置从内核模块末段 end 标号开始，end 是内核模块链接期间由链接程序（ld）设置的一个值，内核代码中没有定义这个符号。当在连接生成 system 模块时，ld 程序的 digest_symbols() 函数会产生此符号。该函数主要用于对全局变量进行引用赋值，并且计算每个被连接文件的其始和大小，

其中也设置了 end 的值，它等于 data_start + datasize + bss_size，也即内核模块的末段。

整个高速缓冲区被划分成 1024 字节大小的缓冲块，正好与块设备上的磁盘逻辑块大小相同。高速缓冲采用 hash 表和空闲缓冲块队列进行操作管理。在缓冲区初始化过程中，从缓冲区的两端开始，同时分别设置缓冲块头结构和划分出对应的缓冲块。缓冲区的高端被划分成一个个 1024 字节的缓冲块，低端则分别建立起对应各缓冲块的缓冲头结构 buffer_head（include/linux/fs.h，68 行），用于描述对应缓冲块的属性和把所有缓冲头连接成链表。直到它们之间已经不能再划分出缓冲块为止，见图 9-10 所示。而各个 buffer_head 被链接成一个空闲缓冲块双向链表结构。详细结构见图 9-11 所示。缓冲块的缓冲头数据结构为：

```
struct buffer_head {
        char * b_data;                  // 指向该缓冲块中数据区（1024 字节)的指针。
        unsigned long b_blocknr;        // 块号。
        unsigned short b_dev;           // 数据源的设备号(0 = free)。
        unsigned char b_uptodate;       // 更新标志：表示数据是否已更新。
        unsigned char b_dirt;           // 修改标志：0- 未修改(clean)，1- 已修改(dirty)。
        unsigned char b_count;          // 使用该块的用户数。
        unsigned char b_lock;           // 缓冲区是否被锁定。0- ok, 1- locked
        struct task_struct * b_wait;    // 指向等待该缓冲区解锁的任务。
        struct buffer_head * b_prev;    // hash 队列上前一块（这四个指针用于缓冲区管理）。
        struct buffer_head * b_next;    // hash 队列上下一块。
        struct buffer_head * b_prev_free;   // 空闲表上前一块。
        struct buffer_head * b_next_free;   // 空闲表上下一块。
};
```

其中字段 b_lock 是缓冲块使用者操作的标志。表示相应缓冲块正被锁定。而字段 b_count 是缓冲管理程序 buffer 使用的计数值，表示相应缓冲块正被使用者引用的次数。当 b_count = 0 时，表示缓冲管理中相应缓冲块未被使用(free)，否则则表示它正在被使用着。对于程序申请的缓冲块，若缓冲管理程序 buffer 从 hash 表中能得到已存在的指定块时，就会将该块的 b_count 增 1（b_count++）。若缓冲块是重新申请得到的未被使用的块，则其头结构中的 b_count 被设置为等于 1。当程序释放其对一个块的引用时，该块的引用次数将相应地减 1（b_count--）。标志 b_lock 表示其他程序正在使用并锁定了指定的缓冲块，因此对于 b_lock 置位的缓冲块来讲，其 b_count 肯定大于 0。

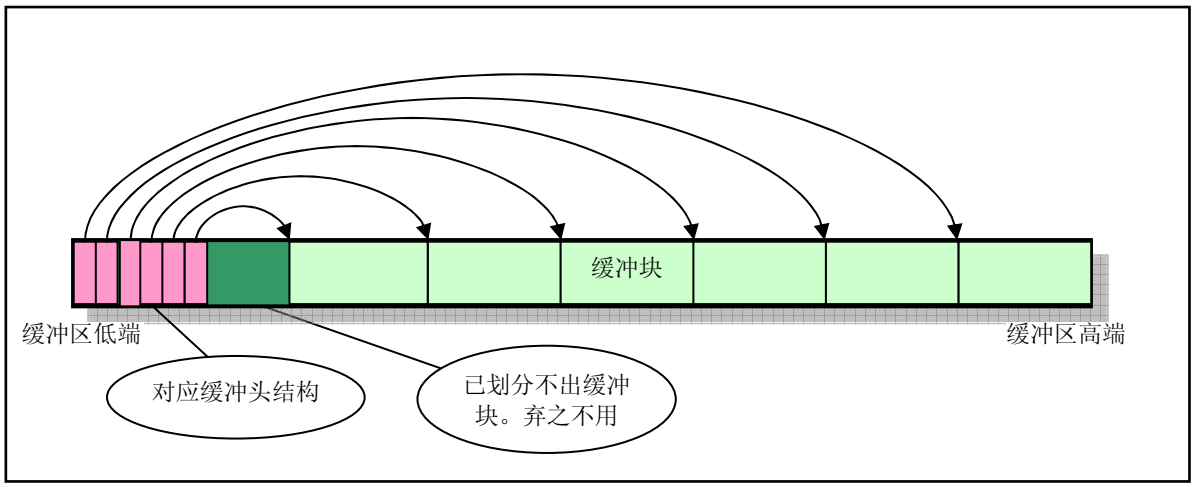

图 9-10 高速缓冲区的初始化

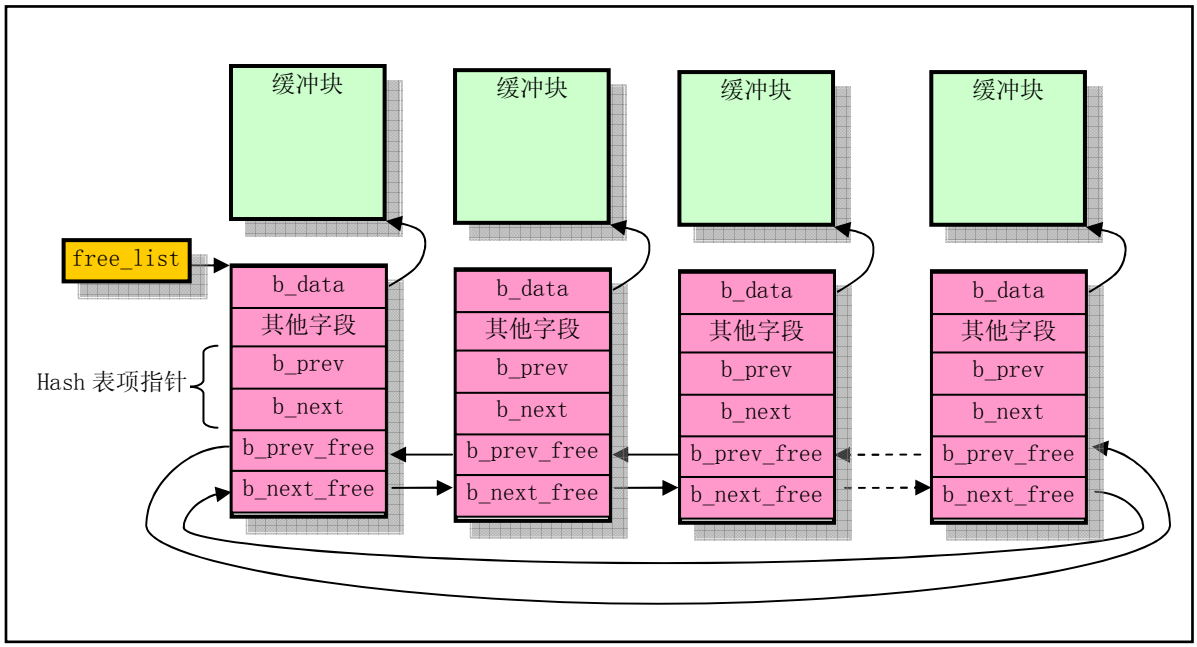

图 9-11 空闲缓冲块双向循环链表结构

缓冲头结构中“其他字段”包括块设备号、缓冲数据的逻辑块号，这两个字段唯一确定了缓冲块中数据对应的块设备和数据块。另外还有几个状态标志：数据有效（更新）标志、修改标志、数据被使用的进程数和本缓冲块是否上锁标志。

内核程序在使用高速缓冲区中的缓冲块时，是指定设备号(dev)和所要访问设备数据的逻辑块号(block)，通过调用 bread()、bread_page()或 breada()函数进行操作的。这几个函数都使用了缓冲区搜索管理函数 getblk()，该函数将在下面重点说明。在系统释放缓冲块时，需要调用 brelse()函数。这些缓冲区数据存取和管理函数的调用层次关系可用图 9-12 来描述。

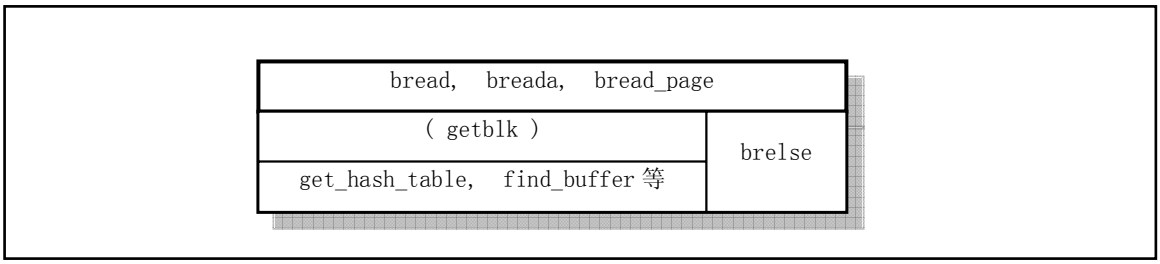

图 9-12 缓冲区管理函数之间的层次关系

为了能够快速地在缓冲区中寻找请求的数据块是否已经被读入到缓冲区中，buffer.c 程序使用了具有 307 个 buffer_head 指针项的 hash 表结构。上图中 buffer_head 结构的指针 b_prev、b_next 就是用于 hash 表中散列在同一项上多个缓冲块之间的双向连接。Hash 表所使用的散列函数由设备号和逻辑块号组合而成。程序中使用的具体函数是：(设备号^逻辑块号) Mod 307。对于动态变化的 hash 表结构某一时刻的状态可参见图 9-13 所示。

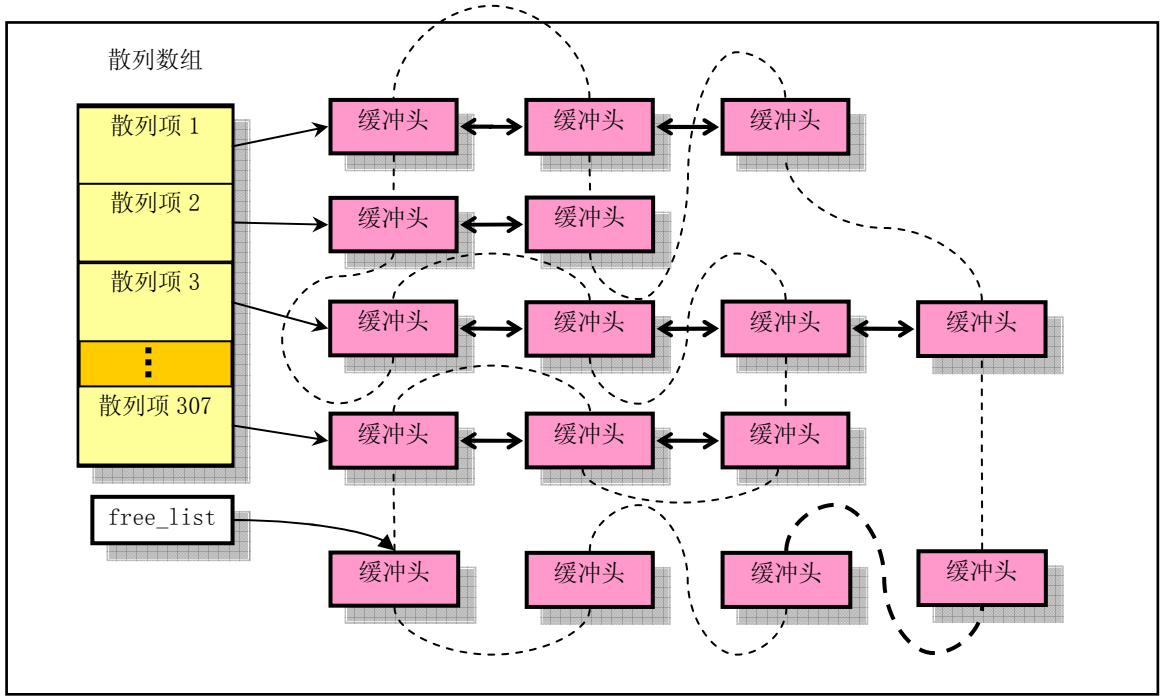

图 9-13 某一时刻内核中缓冲块散列队列示意图

其中，双箭头横线表示散列在同一 hash 表项中缓冲块头结构之间的双向链接指针。虚线表示当前连接在空闲缓冲块链表中空闲缓冲块之间的链接指针，free_list 是空闲链表的头指针。有关散列队列上缓冲块的操作方式，可参见《Unix 操作系统设计》一书第 3 章中的详细描述。

上面提及的三个函数在执行时都调用了缓冲块搜索函数 getblk()，以获取适合的缓冲块。该函数首先调用 get_hash_table()函数，在 hash 表队列中搜索指定设备号和逻辑块号的缓冲块是否已经存在。如果存在就立刻返回对应缓冲头结构的指针；如果不存在，则从空闲链表头开始，对空闲链表进行扫描，寻找一个空闲缓冲块。在寻找过程中还要对找到的空闲缓冲块作比较，根据赋予修改标志和锁定标志组合而成的权值，比较哪个空闲块最适合。若找到的空闲块既没有被修改也没有被锁定，就不用继续寻找了。若没有找到空闲块，则让当前进程进入睡眠状态，待继续执行时再次寻找。若该空闲块被锁定，则进程也需进入睡眠，等待其他进程解锁。若在睡眠等待的过程中，该缓冲块又被其他进程占用，那么只要再重头开始搜索缓冲块。否则判断该缓冲块是否已被修改过，若是，则将该块写盘，并等待该块解锁。此时如果该缓冲块又被别的进程占用，那么又一次全功尽弃，只好再重头开始执行 getblk()。在经历了以上折腾后，此时有可能出现另外一个意外情况，也就是在我们睡眠时，可能其他进程已经将我们所需要的缓冲块加进了 hash 队列中，因此这里需要最后一次搜索一下 hash 队列。如果真的在 hash 队列中找到了我们所需要的缓冲块，那么我们又得对找到的缓冲块进行以上判断处理，因此，又一次需要重头开始执行 getblk()。最后，我们才算找到了一块没有被进程使用、没有被上锁，而且是干净（修改标志未置位）的空闲缓冲块。于是我们就将该块的引用次数置 1，并复位其他几个标志，然后从空闲表中移出该块的缓冲头结构。在设置了该缓冲块所属的设备号和相应的逻辑号后，再将其插入 hash 表对应表项首部并链接到空闲队列的末尾处。最终，返回该缓冲块头的指针。整个 getblk()处理过程可参见图 9-14 所示。

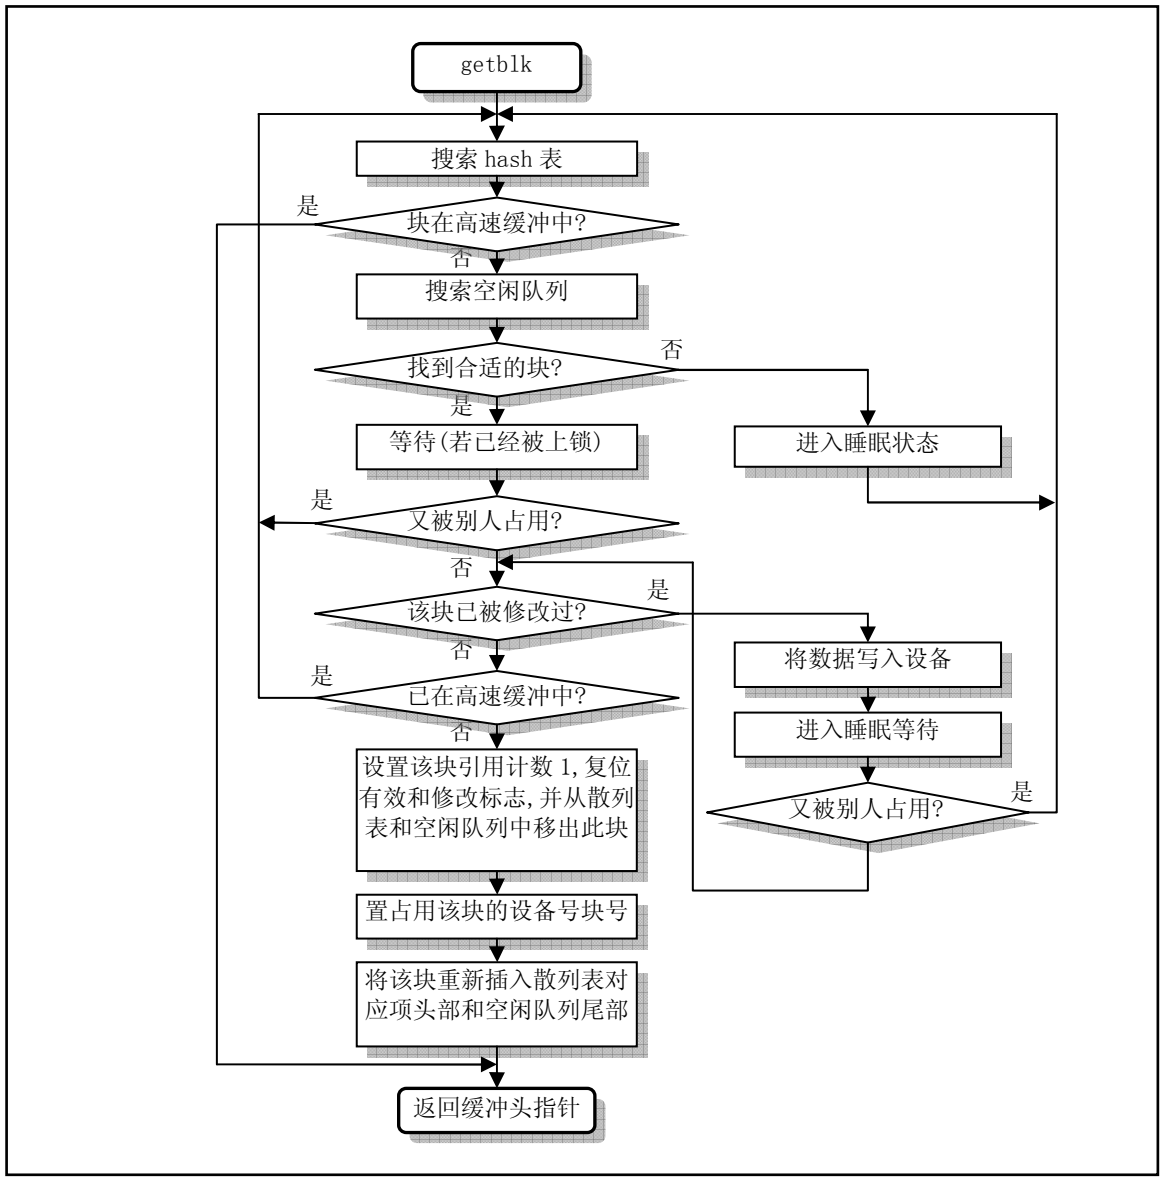

图 9-14 getblk()函数执行流程图

由以上处理我们可以看到，getblk()返回的缓冲块可能是一个新的空闲块，也可能正好是含有我们需要数据的缓冲块，它已经存在于高速缓冲区中。因此对于读取数据块操作(bread())，此时就要判断该缓冲块的更新标志，看看所含数据是否有效，如果有效就可以直接将该数据块返回给申请的程序。否则就需要调用设备的低层块读写函数（ll_rw_block()），并同时让自己进入睡眠状态，等待数据被读入缓冲块。在醒来后再判断数据是否有效了。如果有效，就可将此数据返给申请的程序，否则说明对设备的读操作失败了，没有取到数据。于是，释放该缓冲块，并返回 NULL 值。图 9-15 是 bread()函数的框图。breada()和 bread_page()函数与 bread()函数类似。

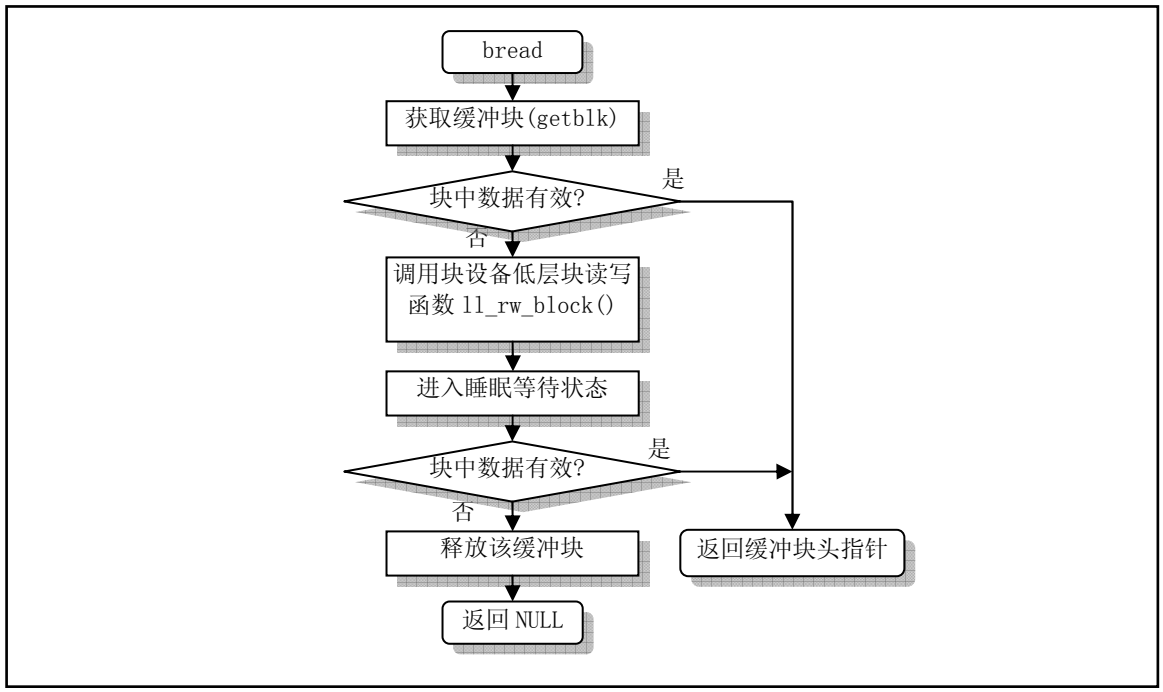

图 9-15 bread()函数执行流程框图

当程序不再需要使用一个缓冲块中的数据时，就调用 brelse()函数，释放该缓冲块并唤醒因等待该缓冲块而进入睡眠状态的进程。注意，空闲缓冲块链表中的缓冲块，并不是都是空闲的。只有当被写盘刷新、解锁且没有其他进程引用时（引用计数=0），才能挪作它用。

综上所述，高速缓冲区在提高对块设备的访问效率和增加数据共享方面起着重要的作用。除驱动程序以外，内核其他上层程序对块设备的读写操作需要经过高速缓冲区管理程序来间接地实现。它们之间的主要联系是通过高速缓冲区管理程序中的 bread()函数和块设备低层接口函数 ll_rw_block()来实现。上层程序若要访问块设备数据就通过 bread()向缓冲区管理程序申请。如果所需的数据已经在高速缓冲区中，管理程序就会将数据直接返回给程序。如果所需的数据暂时还不在缓冲区中，则管理程序会通过 ll_rw_block()向块设备驱动程序申请，同时让程序对应的进程睡眠等待。等到块设备驱动程序把指定的数据放入高速缓冲区后，管理程序才会返回给上层程序。见图 9-16 所示。

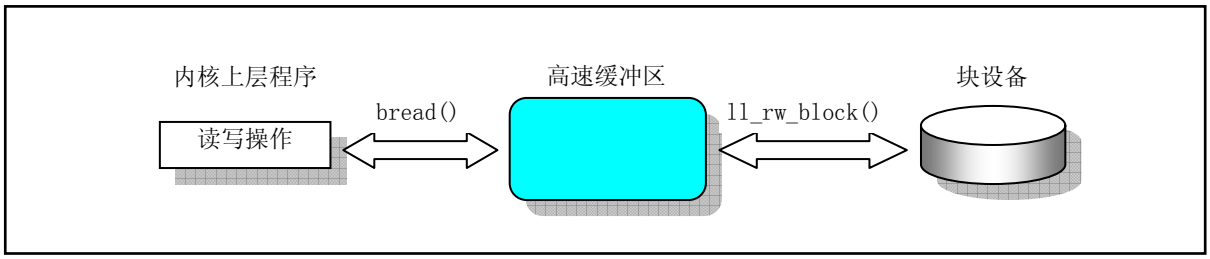

图 9-16 内核程序块设备访问操作

对于更新和同步（Synchronization）操作，其主要作用是让内存中的一些缓冲块内容与磁盘等块设备上的信息一致。sync_inodes（）的主要作用是把 i 节点表 inode_table 中的 i 节点信息与磁盘上的一致起来。但需要经过系统高速缓冲区这一中间环节。实际上，任何同步操作都被分成了两个阶段：

1. 数据结构信息与高速缓冲区中的缓冲块同步问题，由相关程序独立负责；
2. 高速缓冲区中数据块与磁盘对应块的同步问题，由这里的缓冲管理程序负责。

sync_inodes()函数不会直接与磁盘打交道，它只能前进到缓冲区这一步。即只负责是与缓冲区中的

一同步。剩下的需要缓冲管理程序负责。为了让 sync_inodes()知道哪些 i 节点与磁盘上的不同，就必须首先让缓冲区中内容与磁盘上的内容一致。这样 sync_indes()通过与当前磁盘在缓冲区中的最新数据比较才能知道哪些磁盘 inode 需要修改和更新。最后再进行第二次高速缓冲区与磁盘设备的同步操作，做到内存中的数据与块设备中的数据真正的同步。

9.4.2 代码注释

程序 9-2 linux/fs/buffer.c

```
 1 /*
 2  *  linux/fs/buffer.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  *  'buffer.c' implements the buffer-cache functions. Race-conditions have
 9  * been avoided by NEVER letting a interrupt change a buffer (except for the
10  * data, of course), but instead letting the caller do it. NOTE! As interrupts
11  * can wake up a caller, some cli-sti sequences are needed to check for
12  * sleep-on-calls. These should be extremely quick, though (I hope).
13  */
   /*
    * 'buffer.c'用于实现缓冲区高速缓存功能。通过不让中断过程改变缓冲区，而是让调用者
    * 来执行，避免了竞争条件（当然除改变数据以外）。注意！由于中断可以唤醒一个调用者，
    * 因此就需要开关中断指令（cli-sti）序列来检测等待调用返回。但需要非常地快(希望是这样)。
    */
14
15 /*
16  * NOTE! There is one discordant note here: checking floppies for
17  * disk change. This is where it fits best, I think, as it should
18  * invalidate changed floppy-disk-caches.
19  */
   /*
    * 注意！有一个程序应不属于这里：检测软盘是否更换。但我想这里是
    * 放置该程序最好的地方了，因为它需要使已更换软盘缓冲失效。
    */
20
21 #include <stdarg.h>       // 标准参数头文件。以宏的形式定义变量参数列表。主要说明了-个
                             // 类型(va_list)和三个宏(va_start, va_arg 和 va_end)，用于
                             // vsprintf、vprintf、vfprintf 函数。
22
23 #include <linux/config.h> // 内核配置头文件。定义键盘语言和硬盘类型（HD_TYPE）可选项。
24 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
25 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
26 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
27 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
28
29 extern int end;           // 由连接程序 ld 生成用于表明内核代码末端的变量。
30 struct buffer_head * start_buffer = (struct buffer_head *) &end;
31 struct buffer_head * hash_table[NR_HASH];        // NR_HASH = 307 项。
```

```
32 static struct buffer_head * free_list;
33 static struct task_struct * buffer_wait = NULL;
34 int NR_BUFFERS = 0;
35
   //// 等待指定缓冲区解锁。
36 static inline void wait_on_buffer(struct buffer_head * bh)
37 {
38         cli();                          // 关中断。
39         while (bh->b_lock)              // 如果已被上锁，则进程进入睡眠，等待其解锁。
40                 sleep_on(&bh->b_wait);
41         sti();                          // 开中断。
42 }
43
   //// 系统调用。同步设备和内存高速缓冲中数据。其中，sync_inodes()定义在 inode.c，59 行。
44 int sys_sync(void)
45 {
46         int i;
47         struct buffer_head * bh;
48
49         sync_inodes();      /* write out inodes into buffers */ /*将 i 节点写入高速缓冲*/
   // 扫描所有高速缓冲区，对于已被修改的缓冲块产生写盘请求，将缓冲中数据与设备中同步。
50         bh = start_buffer;
51         for (i=0 ; i<NR_BUFFERS ; i++,bh++) {
52                 wait_on_buffer(bh);             // 等待缓冲区解锁（如果已上锁的话）。
53                 if (bh->b_dirt)
54                         ll_rw_block(WRITE,bh);  // 产生写设备块请求。
55         }
56         return 0;
57 }
58
   //// 对指定设备进行高速缓冲数据与设备上数据的同步操作。
59 int sync_dev(int dev)
60 {
61         int i;
62         struct buffer_head * bh;
63
   // 为了让 i 节点同步函数 sync_inodes()知道哪些 inode 与磁盘上的不同，就必须首先让缓冲区中
   // 内容与磁盘上的内容一致。这样 sync_indes()通过与当前磁盘在缓冲区中的最新数据比较才能知
   // 道哪些磁盘 i 节点需要修改和更新。
64         bh = start_buffer;
65         for (i=0 ; i<NR_BUFFERS ; i++,bh++) {
66                 if (bh->b_dev != dev)
67                         continue;
68                 wait_on_buffer(bh);
69                 if (bh->b_dev == dev && bh->b_dirt)
70                         ll_rw_block(WRITE,bh);
71         }
   // 将 i 节点数据写入高速缓冲。让 i 节点表 inode_table 中的 inode 与缓冲中的信息同步。
72         sync_inodes();
   // 在高速缓冲中的数据更新之后，再把它们与设备中的数据同步。
73         bh = start_buffer;
74         for (i=0 ; i<NR_BUFFERS ; i++,bh++) {
75                 if (bh->b_dev != dev)
```

```
 76                         continue;
 77                 wait_on_buffer(bh);
 78                 if (bh->b_dev == dev && bh->b_dirt)
 79                         ll_rw_block(WRITE,bh);
 80         }
 81         return 0;
 82 }
 83
    //// 使指定设备在高速缓冲区中的数据无效。
    // 扫描高速缓冲中的所有缓冲块，对于指定设备的缓冲区，复位其有效(更新)标志和已修改标志。
 84 void inline invalidate_buffers(int dev)
 85 {
 86         int i;
 87         struct buffer_head * bh;
 88
 89         bh = start_buffer;
 90         for (i=0 ; i<NR_BUFFERS ; i++,bh++) {
 91                 if (bh->b_dev != dev)              // 如果不是指定设备的缓冲块，则
 92                         continue;                  // 继续扫描下一块。
 93                 wait_on_buffer(bh);                // 等待该缓冲区解锁（如果已被上锁）。
    // 由于进程执行过睡眠等待，所以需要再判断一下缓冲区是否是指定设备的。
 94                 if (bh->b_dev == dev)
 95                         bh->b_uptodate = bh->b_dirt = 0;
 96         }
 97 }
 98
 99 /*
100  * This routine checks whether a floppy has been changed, and
101  * invalidates all buffer-cache-entries in that case. This
102  * is a relatively slow routine, so we have to try to minimize using
103  * it. Thus it is called only upon a 'mount' or 'open'. This
104  * is the best way of combining speed and utility, I think.
105  * People changing diskettes in the middle of an operation deserve
106  * to loose :-)
107  *
108  * NOTE! Although currently this is only for floppies, the idea is
109  * that any additional removable block-device will use this routine,
110  * and that mount/open needn't know that floppies/whatever are
111  * special.
112  */
    /*
     * 该子程序检查一个软盘是否已经被更换，如果已经更换就使高速缓冲中与该软驱
     * 对应的所有缓冲区无效。该子程序相对来说较慢，所以我们要尽量少使用它。
     * 所以仅在执行'mount'或'open'时才调用它。我想这是将速度和实用性相结合的
     * 最好方法。若在操作过程当中更换软盘，会导致数据的丢失，这是咎由自取☺。
     *
     * 注意！尽管目前该子程序仅用于软盘，以后任何可移动介质的块设备都将使用该
     * 程序，mount/open 操作是不需要知道是否是软盘或其他什么特殊介质的。
     */
    //// 检查磁盘是否更换，如果已更换就使对应高速缓冲区无效。
113 void check_disk_change(int dev)
114 {
115         int i;
```

```
116
    // 是软盘设备吗？如果不是则退出。
117         if (MAJOR(dev) != 2)
118                 return;
    // 测试对应软盘是否已更换，如果没有则退出。floppy_change()在 blk_drv/floppy.c 第 139 行。
119         if (!floppy_change(dev & 0x03))
120                 return;
    // 软盘已经更换，所以释放对应设备的 i 节点位图和逻辑块位图所占的高速缓冲区；并使该设备的
    // i 节点和数据块信息所占的高速缓冲区无效。
121         for (i=0 ; i<NR_SUPER ; i++)
122                 if (super_block[i].s_dev == dev)
123                         put_super(super_block[i].s_dev);
124         invalidate_inodes(dev);
125         invalidate_buffers(dev);
126 }
127
    // hash 函数和 hash 表项的计算宏定义。
128 #define _hashfn(dev,block) (((unsigned)(dev^block))%NR_HASH)
129 #define hash(dev,block) hash_table[_hashfn(dev,block)]
130
    //// 从 hash 队列和空闲缓冲队列中移走指定的缓冲块。
131 static inline void remove_from_queues(struct buffer_head * bh)
132 {
133 /* remove from hash-queue */
    /* 从 hash 队列中移除缓冲块 */
134         if (bh->b_next)
135                 bh->b_next->b_prev = bh->b_prev;
136         if (bh->b_prev)
137                 bh->b_prev->b_next = bh->b_next;
    // 如果该缓冲区是该队列的头一个块，则让 hash 表的对应项指向本队列中的下一个缓冲区。
138         if (hash(bh->b_dev,bh->b_blocknr) == bh)
139                 hash(bh->b_dev,bh->b_blocknr) = bh->b_next;
140 /* remove from free list */
    /* 从空闲缓冲区表中移除缓冲块 */
141         if (!(bh->b_prev_free) || !(bh->b_next_free))
142                 panic("Free block list corrupted");
143         bh->b_prev_free->b_next_free = bh->b_next_free;
144         bh->b_next_free->b_prev_free = bh->b_prev_free;
    // 如果空闲链表头指向本缓冲区，则让其指向下一缓冲区。
145         if (free_list == bh)
146                 free_list = bh->b_next_free;
147 }
148
    //// 将指定缓冲区插入空闲链表尾并放入 hash 队列中。
149 static inline void insert_into_queues(struct buffer_head * bh)
150 {
151 /* put at end of free list */
    /* 放在空闲链表末尾处 */
152         bh->b_next_free = free_list;
153         bh->b_prev_free = free_list->b_prev_free;
154         free_list->b_prev_free->b_next_free = bh;
155         free_list->b_prev_free = bh;
156 /* put the buffer in new hash-queue if it has a device */
```

```
    /* 如果该缓冲块对应一个设备，则将其插入新 hash 队列中 */
157         bh->b_prev = NULL;
158         bh->b_next = NULL;
159         if (!bh->b_dev)
160                 return;
161         bh->b_next = hash(bh->b_dev,bh->b_blocknr);
162         hash(bh->b_dev,bh->b_blocknr) = bh;
163         bh->b_next->b_prev = bh;
164 }
165
    //// 在高速缓冲中寻找给定设备和指定块的缓冲区块。
    // 如果找到则返回缓冲区块的指针，否则返回 NULL。
166 static struct buffer_head * find_buffer(int dev, int block)
167 {
168         struct buffer_head * tmp;
169
170         for (tmp = hash(dev,block) ; tmp != NULL ; tmp = tmp->b_next)
171                 if (tmp->b_dev==dev && tmp->b_blocknr==block)
172                         return tmp;
173         return NULL;
174 }
175
176 /*
177  * Why like this, I hear you say... The reason is race-conditions.
178  * As we don't lock buffers (unless we are readint them, that is),
179  * something might happen to it while we sleep (ie a read-error
180  * will force it bad). This shouldn't really happen currently, but
181  * the code is ready.
182  */
    /*
     * 代码为什么会是这样子的？我听见你问... 原因是竞争条件。由于我们没有对
     * 缓冲区上锁（除非我们正在读取它们中的数据），那么当我们（进程）睡眠时
     * 缓冲区可能会发生一些问题（例如一个读错误将导致该缓冲区出错）。目前
     * 这种情况实际上是不会发生的，但处理的代码已经准备好了。
     */
    ////
183 struct buffer_head * get_hash_table(int dev, int block)
184 {
185         struct buffer_head * bh;
186
187         for (;;) {
    // 在高速缓冲中寻找给定设备和指定块的缓冲区，如果没有找到则返回 NULL，退出。
188                 if (!(bh=find_buffer(dev,block)))
189                         return NULL;
    // 对该缓冲区增加引用计数，并等待该缓冲区解锁（如果已被上锁）。
190                 bh->b_count++;
191                 wait_on_buffer(bh);
    // 由于经过了睡眠状态，因此有必要再验证该缓冲区块的正确性，并返回缓冲区头指针。
192                 if (bh->b_dev == dev && bh->b_blocknr == block)
193                         return bh;
    // 如果该缓冲区所属的设备号或块号在睡眠时发生了改变，则撤消对它的引用计数，重新寻找。
194                 bh->b_count--;
195         }
```

```
196 }
197
198 /*
199  * Ok, this is getblk, and it isn't very clear, again to hinder
200  * race-conditions. Most of the code is seldom used, (ie repeating),
201  * so it should be much more efficient than it looks.
202  *
203  * The algoritm is changed: hopefully better, and an elusive bug removed.
204  */
    /*
     * OK，下面是 getblk 函数，该函数的逻辑并不是很清晰，同样也是因为要考虑
     * 竞争条件问题。其中大部分代码很少用到，(例如重复操作语句)，因此它应该
     * 比看上去的样子有效得多。
     *
     * 算法已经作了改变：希望能更好，而且一个难以琢磨的错误已经去除。
     */
    // 下面宏定义用于同时判断缓冲区的修改标志和锁定标志，并且定义修改标志的权重要比锁定标志大。
205 #define BADNESS(bh) (((bh)->b_dirt<<1)+(bh)->b_lock)
    //// 取高速缓冲中指定的缓冲区。
    // 检查所指定的缓冲区是否已经在高速缓冲中，如果不在，就需要在高速缓冲中建立一个对应的新项。
    // 返回相应缓冲区头指针。
206 struct buffer_head * getblk(int dev,int block)
207 {
208         struct buffer_head * tmp, * bh;
209
210 repeat:
    // 搜索 hash 表，如果指定块已经在高速缓冲中，则返回对应缓冲区头指针，退出。
211         if (bh = get_hash_table(dev,block))
212                 return bh;
    // 扫描空闲数据块链表，寻找空闲缓冲区。
    // 首先让 tmp 指向空闲链表的第一个空闲缓冲区头。
213         tmp = free_list;
214         do {
    // 如果该缓冲区正被使用（引用计数不等于 0），则继续扫描下一项。
215                 if (tmp->b_count)
216                         continue;
    // 如果缓冲头指针 bh 为空，或者 tmp 所指缓冲头的标志(修改、锁定)权重小于 bh 头标志的权重，
    // 则让 bh 指向该 tmp 缓冲区头。如果该 tmp 缓冲区头表明缓冲区既没有修改也没有锁定标志置位，
    // 则说明已为指定设备上的块取得对应的高速缓冲区，则退出循环。
217                 if (!bh || BADNESS(tmp)<BADNESS(bh)) {
218                         bh = tmp;
219                         if (!BADNESS(tmp))
220                                 break;
221                 }
222 /* and repeat until we find something good */ /* 重复操作直到找到适合的缓冲区 */
223         } while ((tmp = tmp->b_next_free) != free_list);
    // 如果所有缓冲区都正被使用（所有缓冲区的头部引用计数都>0），则睡眠，等待有空闲的缓冲区可用。
224         if (!bh) {
225                 sleep_on(&buffer_wait);
226                 goto repeat;
227         }
    // 等待该缓冲区解锁（如果已被上锁的话）。
228         wait_on_buffer(bh);
```

```
    // 如果该缓冲区又被其他任务使用的话，只好重复上述过程。
229         if (bh->b_count)
230                 goto repeat;
    // 如果该缓冲区已被修改，则将数据写盘，并再次等待缓冲区解锁。如果该缓冲区又被其他任务使用
    // 的话，只好再重复上述过程。
231         while (bh->b_dirt) {
232                 sync_dev(bh->b_dev);
233                 wait_on_buffer(bh);
234                 if (bh->b_count)
235                         goto repeat;
236         }
237 /* NOTE!! While we slept waiting for this block, somebody else might */
238 /* already have added "this" block to the cache. check it */
    /* 注意！！当进程为了等待该缓冲块而睡眠时，其他进程可能已经将该缓冲块 */
     * 加入进高速缓冲中，所以要对此进行检查。*/
    // 在高速缓冲 hash 表中检查指定设备和块的缓冲区是否已经被加入进去。如果是的话，就再次重复
    // 上述过程。
239         if (find_buffer(dev,block))
240                 goto repeat;
241 /* OK, FINALLY we know that this buffer is the only one of it's kind, */
242 /* and that it's unused (b_count=0), unlocked (b_lock=0), and clean */
    /* OK，最终我们知道该缓冲区是指定参数的唯一一块，*/
    /* 而且还没有被使用(b_count=0)，未被上锁(b_lock=0)，并且是干净的（未被修改的）*/
    // 于是让我们占用此缓冲区。置引用计数为 1，复位修改标志和有效(更新)标志。
243         bh->b_count=1;
244         bh->b_dirt=0;
245         bh->b_uptodate=0;
    // 从 hash 队列和空闲块链表中移出该缓冲区头，让该缓冲区用于指定设备和其上的指定块。
246         remove_from_queues(bh);
247         bh->b_dev=dev;
248         bh->b_blocknr=block;
    // 然后根据此新的设备号和块号重新插入空闲链表和 hash 队列新位置处。并最终返回缓冲头指针。
249         insert_into_queues(bh);
250         return bh;
251 }
252
    //// 释放指定的缓冲区。
    // 等待该缓冲区解锁。引用计数递减 1。唤醒等待空闲缓冲区的进程。
253 void brelse(struct buffer_head * buf)
254 {
255         if (!buf)               // 如果缓冲头指针无效则返回。
256                 return;
257         wait_on_buffer(buf);
258         if (!(buf->b_count--))
259                 panic("Trying to free free buffer");
260         wake_up(&buffer_wait);
261 }
262
263 /*
264  * bread() reads a specified block and returns the buffer that contains
265  * it. It returns NULL if the block was unreadable.
266  */
    /*
```

```
 * 从设备上读取指定的数据块并返回含有数据的缓冲区。如果指定的块不存在
 * 则返回 NULL。
 */
//// 从指定设备上读取指定的数据块。
struct buffer_head * bread(int dev,int block)
{
        struct buffer_head * bh;

// 在高速缓冲中申请一块缓冲区。如果返回值是 NULL 指针，表示内核出错，死机。
        if (!(bh=getblk(dev,block)))
                panic("bread: getblk returned NULL\n");
// 如果该缓冲区中的数据是有效的（已更新的）可以直接使用，则返回。
        if (bh->b_uptodate)
                return bh;
// 否则调用 ll_rw_block()函数，产生读设备块请求。并等待缓冲区解锁。
        ll_rw_block(READ,bh);
        wait_on_buffer(bh);
// 如果该缓冲区已更新，则返回缓冲区头指针，退出。
        if (bh->b_uptodate)
                return bh;
// 否则表明读设备操作失败，释放该缓冲区，返回 NULL 指针，退出。
        brelse(bh);
        return NULL;
}

//// 复制内存块。
// 从 from 地址复制一块数据到 to 位置。
#define COPYBLK(from,to) \
__asm__("cld\n\t" \
        "rep\n\t" \
        "movsl\n\t" \
        ::"c" (BLOCK_SIZE/4),"S" (from),"D" (to) \
        :"cx","di","si")

/*
 * bread_page reads four buffers into memory at the desired address. It's
 * a function of its own, as there is some speed to be got by reading them
 * all at the same time, not waiting for one to be read, and then another
 * etc.
 */
/*
 * bread_page 一次读四个缓冲块内容读到内存指定的地址。它是一个完整的函数，
 * 因为同时读取四块可以获得速度上的好处，不用等着读一块，再读一块了。
 */
//// 读设备上一个页面（4 个缓冲块）的内容到内存指定的地址。
void bread_page(unsigned long address,int dev,int b[4])
{
        struct buffer_head * bh[4];
        int i;

// 循环执行 4 次，读一页内容。
        for (i=0 ; i<4 ; i++)
                if (b[i]) {
```

```
    // 取高速缓冲中指定设备和块号的缓冲区，如果该缓冲区数据无效则产生读设备请求。
303                         if (bh[i] = getblk(dev,b[i]))
304                                 if (!bh[i]->b_uptodate)
305                                         ll_rw_block(READ,bh[i]);
306                 } else
307                         bh[i] = NULL;
    // 将 4 块缓冲区上的内容顺序复制到指定地址处。
308         for (i=0 ; i<4 ; i++,address += BLOCK_SIZE)
309                 if (bh[i]) {
310                         wait_on_buffer(bh[i]);      // 等待缓冲区解锁(如果已被上锁的话)。
311                         if (bh[i]->b_uptodate)      // 如果该缓冲区中数据有效的话，则复制。
312                                 COPYBLK((unsigned long) bh[i]->b_data,address);
313                         brelse(bh[i]);              // 释放该缓冲区。
314                 }
315 }
316
317 /*
318  * Ok, breada can be used as bread, but additionally to mark other
319  * blocks for reading as well. End the argument list with a negative
320  * number.
321  */
    /*
     * OK，breada 可以象 bread 一样使用，但会另外预读一些块。该函数参数列表
     * 需要使用一个负数来表明参数列表的结束。
     */
    //// 从指定设备读取指定的一些块。
    // 成功时返回第 1 块的缓冲区头指针，否则返回 NULL。
322 struct buffer_head * breada(int dev,int first, ...)
323 {
324         va_list args;
325         struct buffer_head * bh, *tmp;
326
    // 取可变参数表中第 1 个参数（块号）。
327         va_start(args,first);
    // 取高速缓冲中指定设备和块号的缓冲区。如果该缓冲区数据无效，则发出读设备数据块请求。
328         if (!(bh=getblk(dev,first)))
329                 panic("bread: getblk returned NULL\n");
330         if (!bh->b_uptodate)
331                 ll_rw_block(READ,bh);
    // 然后顺序取可变参数表中其他预读块号，并作与上面同样处理，但不引用。注意，336 行上有一个 bug。
    // 其中的 bh 应该是 tmp。这个 bug 直到在 0.96 版的内核代码中才被纠正过来。
332         while ((first=va_arg(args,int))>=0) {
333                 tmp=getblk(dev,first);
334                 if (tmp) {
335                         if (!tmp->b_uptodate)
336                                 ll_rw_block(READA,bh);
    // 因为上句是预读随后的数据块，只需读进高速缓冲区但并不是马上就使用。因此需要将其引用计数
    // 递减释放掉。
337                         tmp->b_count--;
338                 }
339         }
    // 可变参数表中所有参数处理完毕。等待第 1 个缓冲区解锁（如果已被上锁）。
340         va_end(args);
```

```
341         wait_on_buffer(bh);
    // 如果缓冲区中数据有效，则返回缓冲区头指针，退出。否则释放该缓冲区，返回 NULL，退出。
342         if (bh->b_uptodate)
343                 return bh;
344         brelse(bh);
345         return (NULL);
346 }
347
    //// 缓冲区初始化函数。
    // 参数 buffer_end 是指定的缓冲区内存的末端。对于系统有 16MB 内存，则缓冲区末端设置为 4MB。
    // 对于系统有 8MB 内存，缓冲区末端设置为 2MB。
348 void buffer_init(long buffer_end)
349 {
350         struct buffer_head * h = start_buffer;
351         void * b;
352         int i;
353
    // 如果缓冲区高端等于 1Mb，则由于从 640KB-1MB 被显示内存和 BIOS 占用，因此实际可用缓冲区内存
    // 高端应该是 640KB。否则内存高端一定大于 1MB。
354         if (buffer_end == 1<<20)
355                 b = (void *) (640*1024);
356         else
357                 b = (void *) buffer_end;
    // 这段代码用于初始化缓冲区，建立空闲缓冲区环链表，并获取系统中缓冲块的数目。
    // 操作的过程是从缓冲区高端开始划分 1K 大小的缓冲块，与此同时在缓冲区低端建立描述该缓冲块
    // 的结构 buffer_head，并将这些 buffer_head 组成双向链表。
    // h 是指向缓冲头结构的指针，而 h+1 是指向内存地址连续的下一个缓冲头地址，也可以说是指向 h
    // 缓冲头的末端外。为了保证有足够长度的内存来存储一个缓冲头结构，需要 b 所指向的内存块
    // 地址 >= h 缓冲头的末端，也即要>=h+1。
358         while ( (b -= BLOCK_SIZE) >= ((void *) (h+1)) ) {
359                 h->b_dev = 0;                   // 使用该缓冲区的设备号。
360                 h->b_dirt = 0;                  // 脏标志，也即缓冲区修改标志。
361                 h->b_count = 0;                 // 该缓冲区引用计数。
362                 h->b_lock = 0;                  // 缓冲区锁定标志。
363                 h->b_uptodate = 0;              // 缓冲区更新标志（或称数据有效标志）。
364                 h->b_wait = NULL;               // 指向等待该缓冲区解锁的进程。
365                 h->b_next = NULL;               // 指向具有相同 hash 值的下一个缓冲头。
366                 h->b_prev = NULL;               // 指向具有相同 hash 值的前一个缓冲头。
367                 h->b_data = (char *) b;         // 指向对应缓冲区数据块（1024 字节）。
368                 h->b_prev_free = h-1;           // 指向链表中前一项。
369                 h->b_next_free = h+1;           // 指向链表中下一项。
370                 h++;                            // h 指向下一新缓冲头位置。
371                 NR_BUFFERS++;                   // 缓冲区块数累加。
372                 if (b == (void *) 0x100000)     // 如果地址 b 递减到等于 1MB，则跳过 384KB，
373                         b = (void *) 0xA0000;   // 让 b 指向地址 0xA0000(640KB)处。
374         }
375         h--;                                    // 让 h 指向最后一个有效缓冲头。
376         free_list = start_buffer;               // 让空闲链表头指向头一个缓冲区头。
377         free_list->b_prev_free = h;             // 链表头的 b_prev_free 指向前一项（即最后一项）。
378         h->b_next_free = free_list;             // h 的下一项指针指向第一项，形成一个环链。
    // 初始化 hash 表（哈希表、散列表），置表中所有的指针为 NULL。
379         for (i=0;i<NR_HASH;i++)
380                 hash_table[i]=NULL;
```

```
381 }
382
```

9.5 bitmap.c 程序

9.5.1 功能描述

本程序的功能和作用即简单又清晰，主要用于对 i 节点位图和逻辑块位图进行释放和占用处理。操作 i 节点位图的函数是 free_inode()和 new_inode()，操作逻辑块位图的函数是 free_block()和 new_block()。

函数 free_block()用于释放指定设备 dev 上数据区中的逻辑块 block。具体操作是复位指定逻辑块 block 对应逻辑块位图中的比特位。它首先取指定设备 dev 的超级块，并根据超级块上给出的设备数据逻辑块的范围，判断逻辑块号 block 的有效性。然后在高速缓冲区中进行查找，看看指定的逻辑块现在是否正在高速缓冲区中，若是，则将对应的缓冲块释放掉。接着计算 block 从数据区开始算起的数据逻辑块号（从 1 开始计数），并对逻辑块(区段)位图进行操作，复位对应的比特位。最后根据逻辑块号设置相应逻辑块位图在缓冲区中对应的缓冲块的已修改标志。

函数 new_block()用于向设备 dev 申请一个逻辑块，返回逻辑块号。并置位指定逻辑块 block 对应的逻辑块位图比特位。它首先取指定设备 dev 的超级块。然后对整个逻辑块位图进行搜索，寻找首个是 0 的比特位。若没有找到，则说明盘设备空间已用完，返回 0。否则将该比特位置为 1，表示占用对应的数据逻辑块。并将该比特位所在缓冲块的已修改标志置位。接着计算出数据逻辑块的盘块号，并在高速缓冲区中申请相应的缓冲块，并把该缓冲块清零。然后设置该缓冲块的已更新和已修改标志。最后释放该缓冲块，以便其他程序使用，并返回盘块号（逻辑块号）。

函数 free_inode()用于释放指定的 i 节点，并复位对应的 i 节点位图比特位；new_inode()用于为设备 dev 建立一个新 i 节点。返回该新 i 节点的指针。主要操作过程是在内存 i 节点表中获取一个空闲 i 节点表项，并从 i 节点位图中找一个空闲 i 节点。这两个函数的处理过程与上述两个函数类似，因此这里就不用再赘述。

9.5.2 代码注释

程序 9-3 linux/fs/bitmap.c

```
1  /*
2   *  linux/fs/bitmap.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /* bitmap.c contains the code that handles the inode and block bitmaps */
   /* bitmap.c 程序含有处理 i 节点和磁盘块位图的代码 */
8  #include <string.h>        // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
9                             // 主要使用了其中的 memset()函数。
10 #include <linux/sched.h>   // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                              // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12
   //// 将指定地址(addr)处的一块内存清零。嵌入汇编程序宏。
   // 输入：eax = 0，ecx = 数据块大小 BLOCK_SIZE/4，edi = addr。
13 #define clear_block(addr) \
```

```
14 __asm__("cld\n\t" \              // 清方向位。
15         "rep\n\t" \              // 重复执行存储数据（0）。
16         "stosl" \
17         ::"a" (0), "c" (BLOCK_SIZE/4), "D" ((long) (addr)):"cx", "di")
18
   //// 置位指定地址开始的第 nr 个位偏移处的比特位(nr 可以大于 32!)。返回原比特位（0 或 1）。
   // 输入：%0 - eax（返回值），%1 - eax(0)；%2 - nr，位偏移值；%3 - (addr)，addr 的内容。
19 #define set_bit(nr,addr) ({\
20 register int res __asm__("ax"); \
21 __asm__ __volatile__("btsl %2,%3\n\tsetb %%al": \
22 "=a" (res):"" (0), "r" (nr), "m" (*(addr))); \
23 res;})
24
   //// 复位指定地址开始的第 nr 位偏移处的比特位。返回原比特位的反码（1 或 0）。
   // 输入：%0 - eax（返回值），%1 - eax(0)；%2 - nr，位偏移值；%3 - (addr)，addr 的内容。
25 #define clear_bit(nr,addr) ({\
26 register int res __asm__("ax"); \
27 __asm__ __volatile__("btrl %2,%3\n\tsetnb %%al": \
28 "=a" (res):"" (0), "r" (nr), "m" (*(addr))); \
29 res;})
30
   //// 从 addr 开始寻找第 1 个 0 值比特位。
   // 输入：%0 - ecx(返回值)；%1 - ecx(0)；%2 - esi(addr)。
   // 在 addr 指定地址开始的位图中寻找第 1 个是 0 的比特位，并将其距离 addr 的比特位偏移值返回。
31 #define find_first_zero(addr) ({ \
32 int __res; \
33 __asm__("cld\n" \                  // 清方向位。
34         "1:\tlodsl\n\t" \          // 取[esi]➔eax。
35         "notl %%eax\n\t" \         // eax 中每位取反。
36         "bsfl %%eax,%%edx\n\t" \   // 从位 0 扫描 eax 中是 1 的第 1 个位，其偏移值➔edx。
37         "je 2f\n\t" \              // 如果 eax 中全是 0，则向前跳转到标号 2 处(40 行)。
38         "addl %%edx,%%ecx\n\t"\    // 偏移值加入 ecx(ecx 中是位图中首个是 0 的比特位的偏移值)
39         "jmp 3f\n" \               // 向前跳转到标号 3 处（结束）。
40         "2:\taddl $32,%%ecx\n\t" \ // 没有找到 0 比特位，则将 ecx 加上 1 个长字的位偏移量 32。
41         "cmpl $8192,%%ecx\n\t" \   // 已经扫描了 8192 位（1024 字节）了吗?
42         "jl 1b\n" \                // 若还没有扫描完 1 块数据，则向前跳转到标号 1 处，继续。
43         "3:" \                     // 结束。此时 ecx 中是位偏移量。
44         :"=c" (__res):"c" (0), "S" (addr):"ax", "dx", "si"); \
45 __res;})
46
   //// 释放设备 dev 上数据区中的逻辑块 block。
   // 复位指定逻辑块 block 的逻辑块位图比特位。
   // 参数：dev 是设备号，block 是逻辑块号（盘块号）。
47 void free_block(int dev, int block)
48 {
49         struct super_block * sb;
50         struct buffer_head * bh;
51
   // 取指定设备 dev 的超级块，如果指定设备不存在，则出错死机。
52         if (!(sb = get_super(dev)))
53                 panic("trying to free block on nonexistent device");
   // 若逻辑块号小于首个逻辑块号或者大于设备上总逻辑块数，则出错，死机。
54         if (block < sb->s_firstdatazone || block >= sb->s_nzones)
```

```
55                panic("trying to free block not in datazone");
   // 从 hash 表中寻找该块数据。若找到了则判断其有效性，并清已修改和更新标志，释放该数据块。
   // 该段代码的主要用途是如果该逻辑块当前存在于高速缓冲中，就释放对应的缓冲块。
   // 注意下面这段程序（L56-66）有问题，会造成数据块不能释放。因为当 b_count > 1 时，这段代码
   // 会仅打印一段信息而没有执行释放操作。应该作如下改动较合适：
   //     if (bh) {
   //          if (bh->b_count > 1) {        // 如果引用次数大于 1，则调用 brelse()，
   //                  brelse(bh);           // b_count--后即退出，该块还有人用。
   //                  return 0;
   //            }
   //            bh->b_dirt=0;               // 否则复位已修改和已更新标志。
   //            bh->b_uptodate=0;
   //            if (bh->b_count)            // 若此时 b_count 为 1，则调用 brelse()释放之。
   //                  brelse(bh);
   //    }
56          bh = get_hash_table(dev,block);
57          if (bh) {
58                  if (bh->b_count != 1) {
59                          printk("trying to free block (%04x:%d), count=%d\n",
60                                  dev,block,bh->b_count);
61                          return;
62                  }
63                  bh->b_dirt=0;             // 复位脏（已修改）标志位。
64                  bh->b_uptodate=0;         // 复位更新标志。
65                  brelse(bh);
66          }
   // 计算 block 在数据区开始算起的数据逻辑块号（从 1 开始计数）。然后对逻辑块(区块)位图进行操作，
   // 复位对应的比特位。若对应比特位原来即是 0，则出错，死机。
67          block -= sb->s_firstdatazone - 1 ;     // block = block - (   -1) ;
68          if (clear_bit(block&8191,sb->s_zmap[block/8192]->b_data)) {
69                  printk("block (%04x:%d) ",dev,block+sb->s_firstdatazone-1);
70                  panic("free_block: bit already cleared");
71          }
   // 置相应逻辑块位图所在缓冲区已修改标志。
72          sb->s_zmap[block/8192]->b_dirt = 1;
73  }
74
   ////向设备 dev 申请一个逻辑块（盘块，区块）。返回逻辑块号（盘块号）。
   // 置位指定逻辑块 block 的逻辑块位图比特位。
75  int new_block(int dev)
76  {
77          struct buffer_head * bh;
78          struct super_block * sb;
79          int i,j;
80
   // 从设备 dev 取超级块，如果指定设备不存在，则出错死机。
81          if (!(sb = get_super(dev)))
82                  panic("trying to get new block from nonexistant device");
   // 扫描逻辑块位图，寻找首个 0 比特位，寻找空闲逻辑块，获取放置该逻辑块的块号。
83          j = 8192;
84          for (i=0 ; i<8 ; i++)
85                  if (bh=sb->s_zmap[i])
86                          if ((j=find_first_zero(bh->b_data))<8192)
```

```
87                                      break;
    // 如果全部扫描完还没找到(i>=8 或 j>=8192)或者位图所在的缓冲块无效(bh=NULL)则 返回 0，
    // 退出（没有空闲逻辑块）。
88          if (i>=8 || !bh || j>=8192)
89                  return 0;
    // 设置新逻辑块对应逻辑块位图中的比特位，若对应比特位已经置位，则出错，死机。
90          if (set_bit(j,bh->b_data))
91                  panic("new_block: bit already set");
    // 置对应缓冲区块的已修改标志。如果新逻辑块大于该设备上的总逻辑块数，则说明指定逻辑块在
    // 对应设备上不存在。申请失败，返回 0，退出。
92          bh->b_dirt = 1;
93          j += i*8192 + sb->s_firstdatazone-1;
94          if (j >= sb->s_nzones)
95                  return 0;
    // 读取设备上的该新逻辑块数据（验证）。如果失败则死机。
96          if (!(bh=getblk(dev,j)))
97                  panic("new_block: cannot get block");
    // 新块的引用计数应为 1。否则死机。
98          if (bh->b_count != 1)
99                  panic("new block: count is != 1");
    // 将该新逻辑块清零，并置位更新标志和已修改标志。然后释放对应缓冲区，返回逻辑块号。
100         clear_block(bh->b_data);
101         bh->b_uptodate = 1;
102         bh->b_dirt = 1;
103         brelse(bh);
104         return j;
105 }
106
    //// 释放指定的 i 节点。
    // 复位对应 i 节点位图比特位。
107 void free_inode(struct m_inode * inode)
108 {
109         struct super_block * sb;
110         struct buffer_head * bh;
111
    // 如果 i 节点指针=NULL，则退出。
112         if (!inode)
113                 return;
    // 如果 i 节点上的设备号字段为 0，说明该节点无用，则用 0 清空对应 i 节点所占内存区，并返回。
114         if (!inode->i_dev) {
115                 memset(inode,0,sizeof(*inode));
116                 return;
117         }
    // 如果此 i 节点还有其他程序引用，则不能释放，说明内核有问题，死机。
118         if (inode->i_count>1) {
119                 printk("trying to free inode with count=%d\n",inode->i_count);
120                 panic("free_inode");
121         }
    // 如果文件目录项连接数不为 0，则表示还有其他文件目录项在使用该节点，不应释放，而应该放回等。
122         if (inode->i_nlinks)
123                 panic("trying to free inode with links");
    // 取 i 节点所在设备的超级块，测试设备是否存在。
124         if (!(sb = get_super(inode->i_dev)))
```

```
125                 panic("trying to free inode on nonexistent device");
    // 如果 i 节点号=0 或大于该设备上 i 节点总数，则出错（0 号 i 节点保留没有使用）。
126         if (inode->i_num < 1 || inode->i_num > sb->s_ninodes)
127                 panic("trying to free inode 0 or nonexistant inode");
    // 如果该 i 节点对应的节点位图不存在，则出错。
128         if (!(bh=sb->s_imap[inode->i_num>>13]))
129                 panic("nonexistent imap in superblock");
    // 复位 i 节点对应的节点位图中的比特位，如果该比特位已经等于 0，则出错。
130         if (clear_bit(inode->i_num&8191,bh->b_data))
131                 printk("free_inode: bit already cleared.\n\r");
    // 置 i 节点位图所在缓冲区已修改标志，并清空该 i 节点结构所占内存区。
132         bh->b_dirt = 1;
133         memset(inode,0,sizeof(*inode));
134 }
135
    //// 为设备 dev 建立一个新 i 节点。返回该新 i 节点的指针。
    // 在内存 i 节点表中获取一个空闲 i 节点表项，并从 i 节点位图中找一个空闲 i 节点。
136 struct m_inode * new_inode(int dev)
137 {
138         struct m_inode * inode;
139         struct super_block * sb;
140         struct buffer_head * bh;
141         int i,j;
142
    // 从内存 i 节点表(inode_table)中获取一个空闲 i 节点项(inode)。
143         if (!(inode=get_empty_inode()))
144                 return NULL;
    // 读取指定设备的超级块结构。
145         if (!(sb = get_super(dev)))
146                 panic("new_inode with unknown device");
    // 扫描 i 节点位图，寻找首个 0 比特位，寻找空闲节点，获取放置该 i 节点的节点号。
147         j = 8192;
148         for (i=0 ; i<8 ; i++)
149                 if (bh=sb->s_imap[i])
150                         if ((j=find_first_zero(bh->b_data))<8192)
151                                 break;
    // 如果全部扫描完还没找到，或者位图所在的缓冲块无效(bh=NULL)则 返回 0，退出（没有空闲 i 节点）。
152         if (!bh || j >= 8192 || j+i*8192 > sb->s_ninodes) {
153                 iput(inode);
154                 return NULL;
155         }
    // 置位对应新 i 节点的 i 节点位图相应比特位，如果已经置位，则出错。
156         if (set_bit(j,bh->b_data))
157                 panic("new_inode: bit already set");
    // 置 i 节点位图所在缓冲区已修改标志。
158         bh->b_dirt = 1;
    // 初始化该 i 节点结构。
159         inode->i_count=1;                   // 引用计数。
160         inode->i_nlinks=1;                  // 文件目录项链接数。
161         inode->i_dev=dev;                   // i 节点所在的设备号。
162         inode->i_uid=current->euid;         // i 节点所属用户 id。
163         inode->i_gid=current->egid;         // 组 id。
164         inode->i_dirt=1;                    // 已修改标志置位。
```

```
165         inode->i_num = j + i*8192;              // 对应设备中的 i 节点号。
166         inode->i_mtime = inode->i_atime = inode->i_ctime = CURRENT_TIME;  // 设置时间。
167         return inode;                           // 返回该 i 节点指针。
168 }
169
```

9.6 inode.c 程序

9.6.1 功能描述

该程序主要包括处理 i 节点的函数 iget()、iput()和块映射函数 bmap()，以及其他一些辅助函数。iget()、iput()和 bmap()主要用于 namei.c 程序的路径名到 i 节点的映射函数 namei()。

iget()函数用于从设备 dev 上读取指定节点号 nr 的 i 节点。其操作流程见下图 9-17 所示。该函数首先判断参数 dev 的有效性，并从 i 节点表中取一个空闲 i 节点。然后扫描 i 节点表，寻找指定节点号 nr 的 i 节点，并递增该 i 节点的引用次数。如果当前扫描的 i 节点的设备号不等于指定的设备号或者节点号不等于指定的节点号，则继续扫描。否则说明已经找到指定设备号和节点号的 i 节点，就等待该节点解锁（如果已上锁的话）。在等待该节点解锁的阶段，节点表可能会发生变化，此时如果该 i 节点的设备号不等于指定的设备号或者节点号不等于指定的节点号，则需要再次重新扫描整个 i 节点表。接下来判断该 i 节点是否是其他文件系统的安装点。

若该 i 节点是某个文件系统的安装点，则在超级块表中搜寻安装在此 i 节点的超级块。若没有找到相应的超级块，则显示出错信息，并释放函数开始获取的空闲节点，返回该 i 节点指针。若找到了相应的超级块，则将该 i 节点写盘。再从安装在此 i 节点文件系统的超级块上取设备号，并令 i 节点号为 1。然后重新再次扫描整个 i 节点表，来取该被安装文件系统的根节点。若该 i 节点不是其他文件系统的安装点，则说明已经找到了对应的 i 节点，因此此时可以放弃临时申请的空闲 i 节点，并返回找到的 i 节点。

如果在 i 节点表中没有找到指定的 i 节点，则利用前面申请的空闲 i 节点在 i 节点表中建立该节点。并从相应设备上读取该 i 节点信息。返回该 i 节点。

iput()函数所完成的功能正好与 iget()相反，它用于释放一个指定的 i 节点(回写入设备)。所执行操作流程也与 iget()类似。

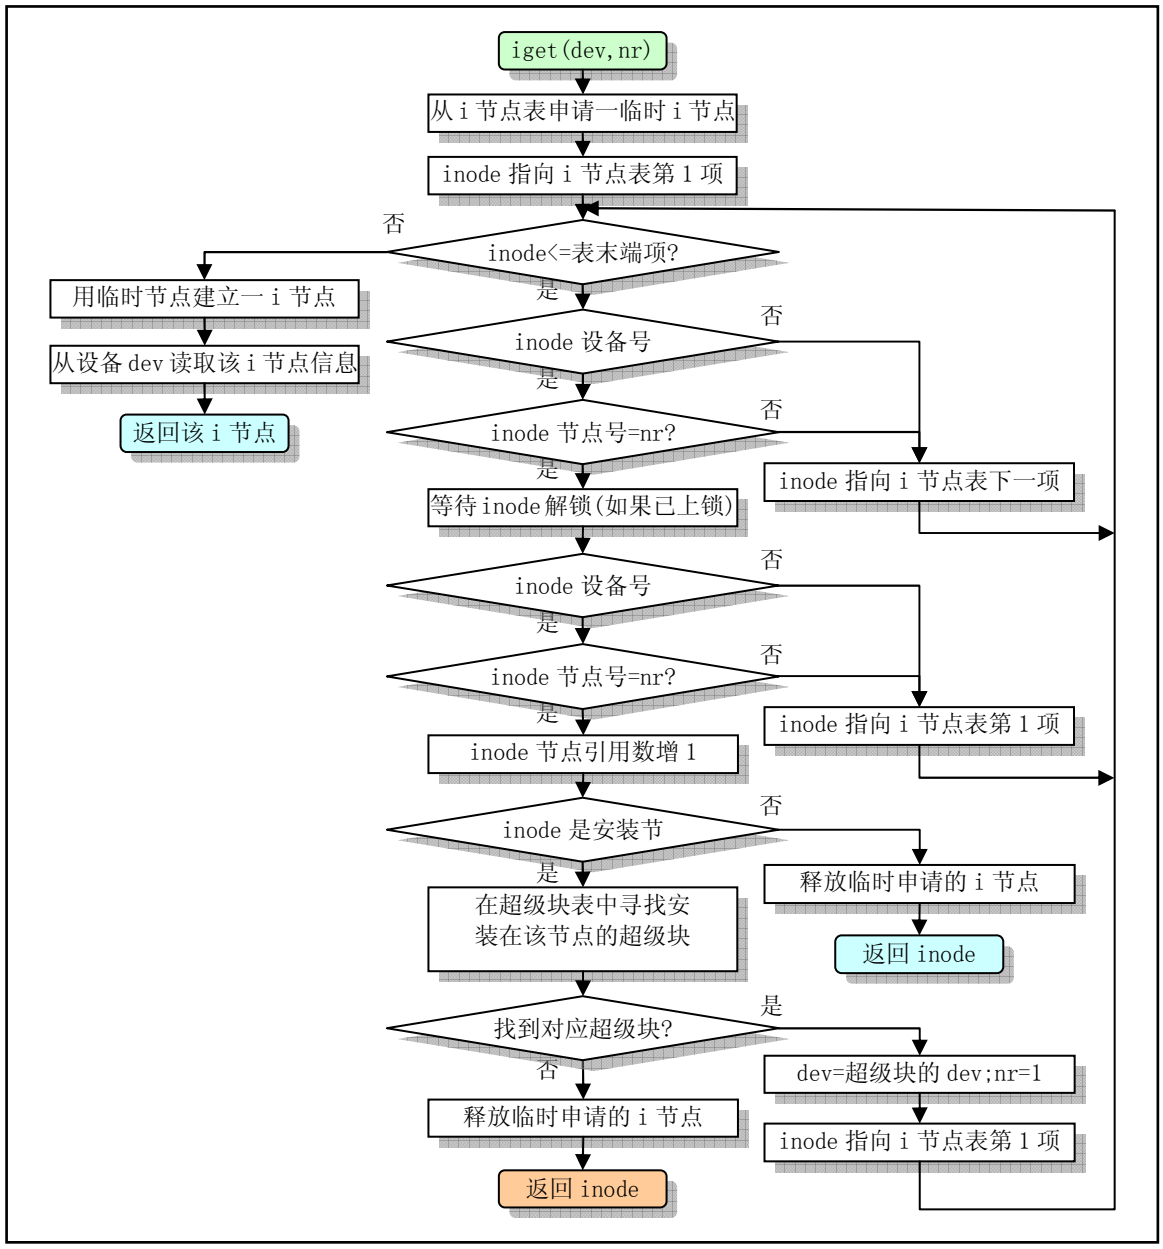

图 9-17 iget 函数操作流程图

_bmap()函数用于文件数据块映射到盘块的处理操作。所带的参数 inode 是文件的 i 节点指针，block 是文件中的数据块号，create 是创建标志，表示在对应文件数据块不存在的情况下，是否需要在盘上建立对应的盘块。该函数的返回值是文件数据块对应在设备上的逻辑块号（盘块号）。当 create=0 时，该函数就是 bmap()函数。当 create=1 时，它就是 create_block()函数。

正规文件中的数据是放在磁盘块的数据区中的，而一个文件名则通过对应的 i 节点与这些数据磁盘块相联系，这些盘块的号码就存放在 i 节点的逻辑块数组中。_bmap()函数主要是对 i 节点的逻辑块（区块）数组 i_zone[]进行处理，并根据 i_zone[]中所设置的逻辑块号（盘块号）来设置逻辑块位图的占用情况。参见“总体功能描述”一节中的图 9.x。正如前面所述，i_zone[0]至 i_zone[6]用于存放对应文件的直接逻辑块号；i_zone[7]用于存放一次间接逻辑块号；而 i_zone[8]用于存放二次间接逻辑块号。当文件较小时（小于 7K），就可以将文件所使用的盘块号直接存放在 i 节点的 7 个直接块项中；当文件稍大一些时（不超过 7K+512K），需要用到一次间接块项 i_zone[7]；当文件更大时，就需要用到二次间接块项 i_zone[8]了。因此，比较文件小时，linux 寻址盘块的速度就比较快一些。

9.6.2 代码注释

程序 9-4 linux/fs/inode.c

```
 1 /*
 2  *  linux/fs/inode.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <string.h>       // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
 8 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
 9
10 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12 #include <linux/mm.h>     // 内存管理头文件。含有页面大小定义和一些页面释放函数原型。
13 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
14
15 struct m_inode inode_table[NR_INODE]={{0,},};    // 内存中 i 节点表（NR_INODE=32 项）。
16
17 static void read_inode(struct m_inode * inode);
18 static void write_inode(struct m_inode * inode);
19
   //// 等待指定的 i 节点可用。
   // 如果 i 节点已被锁定，则将当前任务置为不可中断的等待状态。直到该 i 节点解锁。
20 static inline void wait_on_inode(struct m_inode * inode)
21 {
22         cli();
23         while (inode->i_lock)
24                 sleep_on(&inode->i_wait);
25         sti();
26 }
27
   //// 对指定的 i 节点上锁（锁定指定的 i 节点）。
   // 如果 i 节点已被锁定，则将当前任务置为不可中断的等待状态。直到该 i 节点解锁，然后对其上锁。
28 static inline void lock_inode(struct m_inode * inode)
29 {
30         cli();
31         while (inode->i_lock)
32                 sleep_on(&inode->i_wait);
33         inode->i_lock=1;                        // 置锁定标志。
34         sti();
35 }
36
   //// 对指定的 i 节点解锁。
   // 复位 i 节点的锁定标志，并明确地唤醒等待此 i 节点的进程。
37 static inline void unlock_inode(struct m_inode * inode)
38 {
39         inode->i_lock=0;
40         wake_up(&inode->i_wait);
41 }
42
```

```
   //// 释放内存中设备 dev 的所有 i 节点。
   // 扫描内存中的 i 节点表数组，如果是指定设备使用的 i 节点就释放之。
43 void invalidate_inodes(int dev)
44 {
45         int i;
46         struct m_inode * inode;
47
48         inode = 0+inode_table;                  // 让指针首先指向 i 节点表指针数组首项。
49         for(i=0 ; i<NR_INODE ; i++,inode++) {   // 扫描 i 节点表指针数组中的所有 i 节点。
50                 wait_on_inode(inode);           // 等待该 i 节点可用（解锁）。
51                 if (inode->i_dev == dev) {      // 如果是指定设备的 i 节点，则
52                         if (inode->i_count)     // 如果其引用数不为 0，则显示出错警告；
53                                 printk("inode in use on removed disk\n\r");
54                         inode->i_dev = inode->i_dirt = 0; // 释放该 i 节点(置设备号为 0 等)。
55                 }
56         }
57 }
58
   //// 同步所有 i 节点。
   // 同步内存与设备上的所有 i 节点信息。
59 void sync_inodes(void)
60 {
61         int i;
62         struct m_inode * inode;
63
64         inode = 0+inode_table;                  // 让指针首先指向 i 节点表指针数组首项。
65         for(i=0 ; i<NR_INODE ; i++,inode++) {   // 扫描 i 节点表指针数组。
66                 wait_on_inode(inode);           // 等待该 i 节点可用（解锁）。
67                 if (inode->i_dirt && !inode->i_pipe)  // 如果该 i 节点已修改且不是管道节点，
68                         write_inode(inode);           // 则写盘。
69         }
70 }
71
   //// 文件数据块映射到盘块的处理操作。(block 位图处理函数，bmap - block map)
   // 参数：inode - 文件的 i 节点；block - 文件中的数据块号；create - 创建标志。
   // 如果创建标志置位，则在对应逻辑块不存在时就申请新磁盘块。
   // 返回 block 数据块对应在设备上的逻辑块号（盘块号）。
72 static int _bmap(struct m_inode * inode,int block,int create)
73 {
74         struct buffer_head * bh;
75         int i;
76
   // 如果块号小于 0，则死机。
77         if (block<0)
78                 panic("_bmap: block<0");
   // 如果块号大于直接块数 + 间接块数 + 二次间接块数，超出文件系统表示范围，则死机。
79         if (block >= 7+512+512*512)
80                 panic("_bmap: block>big");

   // 如果该块号小于 7，则使用直接块表示。
81         if (block<7) {
   // 如果创建标志置位，并且 i 节点中对应该块的逻辑块（区段）字段为 0，则向相应设备申请一磁盘
   // 块（逻辑块，区块），并将盘上逻辑块号（盘块号）填入逻辑块字段中。然后设置 i 节点修改时间，
```

```
    // 置 i 节点已修改标志。最后返回逻辑块号。
 82                 if (create && !inode->i_zone[block])
 83                         if (inode->i_zone[block]=new_block(inode->i_dev)) {
 84                                 inode->i_ctime=CURRENT_TIME;
 85                                 inode->i_dirt=1;
 86                         }
 87                 return inode->i_zone[block];
 88         }

    // 如果该块号>=7，并且小于 7+512，则说明是一次间接块。下面对一次间接块进行处理。
 89         block -= 7;
 90         if (block<512) {
    // 如果是创建，并且该 i 节点中对应间接块字段为 0，表明文件是首次使用间接块，则需申请
    // 一磁盘块用于存放间接块信息，并将此实际磁盘块号填入间接块字段中。然后设置 i 节点
    // 已修改标志和修改时间。
 91                 if (create && !inode->i_zone[7])
 92                         if (inode->i_zone[7]=new_block(inode->i_dev)) {
 93                                 inode->i_dirt=1;
 94                                 inode->i_ctime=CURRENT_TIME;
 95                         }
    // 若此时 i 节点间接块字段中为 0，表明申请磁盘块失败，返回 0 退出。
 96                 if (!inode->i_zone[7])
 97                         return 0;
    // 读取设备上的一次间接块。
 98                 if (!(bh = bread(inode->i_dev,inode->i_zone[7])))
 99                         return 0;
    // 取该间接块上第 block 项中的逻辑块号（盘块号）。
100                 i = ((unsigned short *) (bh->b_data))[block];
    // 如果是创建并且间接块的第 block 项中的逻辑块号为 0 的话，则申请一磁盘块（逻辑块），并让
    // 间接块中的第 block 项等于该新逻辑块块号。然后置位间接块的已修改标志。
101                 if (create && !i)
102                         if (i=new_block(inode->i_dev)) {
103                                 ((unsigned short *) (bh->b_data))[block]=i;
104                                 bh->b_dirt=1;
105                         }
    // 最后释放该间接块，返回磁盘上新申请的对应 block 的逻辑块的块号。
106                 brelse(bh);
107                 return i;
108         }

    // 程序运行到此，表明数据块是二次间接块，处理过程与一次间接块类似。下面是对二次间接块的处理。
    // 将 block 再减去间接块所容纳的块数(512)。
109         block -= 512;
    // 如果是新创建并且 i 节点的二次间接块字段为 0，则需申请一磁盘块用于存放二次间接块的一级块
    // 信息，并将此实际磁盘块号填入二次间接块字段中。之后，置 i 节点已修改编制和修改时间。
110         if (create && !inode->i_zone[8])
111                 if (inode->i_zone[8]=new_block(inode->i_dev)) {
112                         inode->i_dirt=1;
113                         inode->i_ctime=CURRENT_TIME;
114                 }
    // 若此时 i 节点二次间接块字段为 0，表明申请磁盘块失败，返回 0 退出。
115         if (!inode->i_zone[8])
116                 return 0;
```

```
    // 读取该二次间接块的一级块。
117         if (!(bh=bread(inode->i_dev,inode->i_zone[8])))
118                 return 0;
    // 取该二次间接块的一级块上第(block/512)项中的逻辑块号。
119         i = ((unsigned short *)bh->b_data)[block>>9];
    // 如果是创建并且二次间接块的一级块上第(block/512)项中的逻辑块号为 0 的话，则需申请一磁盘
    // 块（逻辑块）作为二次间接块的二级块，并让二次间接块的一级块中第(block/512)项等于该二级
    // 块的块号。然后置位二次间接块的一级块已修改标志。并释放二次间接块的一级块。
120         if (create && !i)
121                 if (i=new_block(inode->i_dev)) {
122                         ((unsigned short *) (bh->b_data))[block>>9]=i;
123                         bh->b_dirt=1;
124                 }
125         brelse(bh);
    // 如果二次间接块的二级块块号为 0，表示申请磁盘块失败，返回 0 退出。
126         if (!i)
127                 return 0;
    // 读取二次间接块的二级块。
128         if (!(bh=bread(inode->i_dev,i)))
129                 return 0;
    // 取该二级块上第 block 项中的逻辑块号。(与上 511 是为了限定 block 值不超过 511)
130         i = ((unsigned short *)bh->b_data)[block&511];
    // 如果是创建并且二级块的第 block 项中的逻辑块号为 0 的话，则申请一磁盘块（逻辑块），作为
    // 最终存放数据信息的块。并让二级块中的第 block 项等于该新逻辑块块号(i)。然后置位二级块的
    // 已修改标志。
131         if (create && !i)
132                 if (i=new_block(inode->i_dev)) {
133                         ((unsigned short *) (bh->b_data))[block&511]=i;
134                         bh->b_dirt=1;
135                 }
    // 最后释放该二次间接块的二级块，返回磁盘上新申请的对应 block 的逻辑块的块号。
136         brelse(bh);
137         return i;
138 }
139
    //// 根据 i 节点信息取文件数据块 block 在设备上对应的逻辑块号。
140 int bmap(struct m_inode * inode,int block)
141 {
142         return _bmap(inode,block,0);
143 }
144
    //// 创建文件数据块 block 在设备上对应的逻辑块，并返回设备上对应的逻辑块号。
145 int create_block(struct m_inode * inode, int block)
146 {
147         return _bmap(inode,block,1);
148 }
149
    //// 释放一个 i 节点(回写入设备)。
150 void iput(struct m_inode * inode)
151 {
152         if (!inode)
153                 return;
154         wait_on_inode(inode);    // 等待 inode 节点解锁(如果已上锁的话)。
```

```
155         if (!inode->i_count)
156                 panic("iput: trying to free free inode");
    // 如果是管道 i 节点，则唤醒等待该管道的进程，引用次数减 1，如果还有引用则返回。否则释放
    // 管道占用的内存页面，并复位该节点的引用计数值、已修改标志和管道标志，并返回。
    // 对于 pipe 节点，inode->i_size 存放着物理内存页地址。参见 get_pipe_inode()，228，234 行。
157         if (inode->i_pipe) {
158                 wake_up(&inode->i_wait);
159                 if (--inode->i_count)
160                         return;
161                 free_page(inode->i_size);
162                 inode->i_count=0;
163                 inode->i_dirt=0;
164                 inode->i_pipe=0;
165                 return;
166         }
    // 如果 i 节点对应的设备号=0，则将此节点的引用计数递减 1，返回。
167         if (!inode->i_dev) {
168                 inode->i_count--;
169                 return;
170         }
    // 如果是块设备文件的 i 节点，此时逻辑块字段 0 中是设备号，则刷新该设备。并等待 i 节点解锁。
171         if (S_ISBLK(inode->i_mode)) {
172                 sync_dev(inode->i_zone[0]);
173                 wait_on_inode(inode);
174         }
175 repeat:
    // 如果 i 节点的引用计数大于 1，则递减 1。
176         if (inode->i_count>1) {
177                 inode->i_count--;
178                 return;
179         }
    // 如果 i 节点的链接数为 0，则释放该 i 节点的所有逻辑块，并释放该 i 节点。
180         if (!inode->i_nlinks) {
181                 truncate(inode);
182                 free_inode(inode);
183                 return;
184         }
    // 如果该 i 节点已作过修改，则更新该 i 节点，并等待该 i 节点解锁。
185         if (inode->i_dirt) {
186                 write_inode(inode);     /* we can sleep - so do again */
187                 wait_on_inode(inode);
188                 goto repeat;
189         }
    // i 节点引用计数递减 1。
190         inode->i_count--;
191         return;
192 }
193
    //// 从 i 节点表(inode_table)中获取一个空闲 i 节点项。
    // 寻找引用计数 count 为 0 的 i 节点，并将其写盘后清零，返回其指针。
194 struct m_inode * get_empty_inode(void)
195 {
196         struct m_inode * inode;
```

```
197         static struct m_inode * last_inode = inode_table;  // last_inode 指向 i 节点表第一项。
198         int i;
199
200         do {
    // 扫描 i 节点表。
201                 inode = NULL;
202                 for (i = NR_INODE; i ; i--) {
    // 如果 last_inode 已经指向 i 节点表的最后 1 项之后，则让其重新指向 i 节点表开始处。
203                         if (++last_inode >= inode_table + NR_INODE)
204                                 last_inode = inode_table;
    // 如果 last_inode 所指向的 i 节点的计数值为 0，则说明可能找到空闲 i 节点项。让 inode 指向
    // 该 i 节点。如果该 i 节点的已修改标志和锁定标志均为 0，则我们可以使用该 i 节点，于是退出循环。
205                         if (!last_inode->i_count) {
206                                 inode = last_inode;
207                                 if (!inode->i_dirt && !inode->i_lock)
208                                         break;
209                         }
210                 }
    // 如果没有找到空闲 i 节点(inode=NULL)，则将整个 i 节点表打印出来供调试使用，并死机。
211                 if (!inode) {
212                         for (i=0 ; i<NR_INODE ; i++)
213                                 printk("%04x: %6d\t",inode_table[i].i_dev,
214                                         inode_table[i].i_num);
215                         panic("No free inodes in mem");
216                 }
    // 等待该 i 节点解锁（如果又被上锁的话）。
217                 wait_on_inode(inode);
    // 如果该 i 节点已修改标志被置位的话，则将该 i 节点刷新，并等待该 i 节点解锁。
218                 while (inode->i_dirt) {
219                         write_inode(inode);
220                         wait_on_inode(inode);
221                 }
222         } while (inode->i_count);   // 如果 i 节点又被其他占用的话，则重新寻找空闲 i 节点。
    // 已找到空闲 i 节点项。则将该 i 节点项内容清零，并置引用标志为 1，返回该 i 节点指针。
223         memset(inode,0,sizeof(*inode));
224         inode->i_count = 1;
225         return inode;
226 }
227
    //// 获取管道节点。返回为 i 节点指针（如果是 NULL 则失败）。
    // 首先扫描 i 节点表，寻找一个空闲 i 节点项，然后取得一页空闲内存供管道使用。
    // 然后将得到的 i 节点的引用计数置为 2(读者和写者)，初始化管道头和尾，置 i 节点的管道类型表示。
228 struct m_inode * get_pipe_inode(void)
229 {
230         struct m_inode * inode;
231
232         if (!(inode = get_empty_inode()))        // 如果找不到空闲 i 节点则返回 NULL。
233                 return NULL;
234         if (!(inode->i_size=get_free_page())) {  // 节点的 i_size 字段指向缓冲区。
235                 inode->i_count = 0;              // 如果已没有空闲内存，则
236                 return NULL;                     // 释放该 i 节点，并返回 NULL。
237         }
238         inode->i_count = 2;     /* sum of readers/writers */  /* 读/写两者总计 */
```

```
239         PIPE_HEAD(*inode) = PIPE_TAIL(*inode) = 0;  // 复位管道头尾指针。
240         inode->i_pipe = 1;                          // 置节点为管道使用的标志。
241         return inode;                               // 返回 i 节点指针。
242 }
243
    //// 从设备上读取指定节点号的 i 节点。
    // nr - i 节点号。
244 struct m_inode * iget(int dev,int nr)
245 {
246         struct m_inode * inode, * empty;
247
248         if (!dev)
249                 panic("iget with dev==0");
    // 从 i 节点表中取一个空闲 i 节点。
250         empty = get_empty_inode();
    // 扫描 i 节点表。寻找指定节点号的 i 节点。并递增该节点的引用次数。
251         inode = inode_table;
252         while (inode < NR_INODE+inode_table) {
    // 如果当前扫描的 i 节点的设备号不等于指定的设备号或者节点号不等于指定的节点号，则继续扫描。
253                 if (inode->i_dev != dev || inode->i_num != nr) {
254                         inode++;
255                         continue;
256                 }
    // 找到指定设备号和节点号的 i 节点，等待该节点解锁（如果已上锁的话）。
257                 wait_on_inode(inode);
    // 在等待该节点解锁的阶段，节点表可能会发生变化，所以再次判断，如果发生了变化，则再次重新
    // 扫描整个 i 节点表。
258                 if (inode->i_dev != dev || inode->i_num != nr) {
259                         inode = inode_table;
260                         continue;
261                 }
    // 将该 i 节点引用计数增 1。
262                 inode->i_count++;
263                 if (inode->i_mount) {
264                         int i;
265
    // 如果该 i 节点是其他文件系统的安装点，则在超级块表中搜寻安装在此 i 节点的超级块。如果没有
    // 找到，则显示出错信息，并释放函数开始获取的空闲节点，返回该 i 节点指针。
266                         for (i = 0 ; i<NR_SUPER ; i++)
267                                 if (super_block[i].s_imount==inode)
268                                         break;
269                         if (i >= NR_SUPER) {
270                                 printk("Mounted inode hasn't got sb\n");
271                                 if (empty)
272                                         iput(empty);
273                                 return inode;
274                         }
    // 将该 i 节点写盘。从安装在此 i 节点文件系统的超级块上取设备号，并令 i 节点号为 1。然后重新
    // 扫描整个 i 节点表，取该被安装文件系统的根节点。
275                         iput(inode);
276                         dev = super_block[i].s_dev;
277                         nr = ROOT_INO;
278                         inode = inode_table;
```

```
279                         continue;
280                 }
    // 已经找到相应的 i 节点，因此放弃临时申请的空闲节点，返回该找到的 i 节点。
281                 if (empty)
282                         iput(empty);
283                 return inode;
284         }
    // 如果在 i 节点表中没有找到指定的 i 节点，则利用前面申请的空闲 i 节点在 i 节点表中建立该节点。
    // 并从相应设备上读取该 i 节点信息。返回该 i 节点。
285         if (!empty)
286                 return (NULL);
287         inode=empty;
288         inode->i_dev = dev;
289         inode->i_num = nr;
290         read_inode(inode);
291         return inode;
292 }
293
    //// 从设备上读取指定 i 节点的信息到内存中（缓冲区中）。
294 static void read_inode(struct m_inode * inode)
295 {
296         struct super_block * sb;
297         struct buffer_head * bh;
298         int block;
299
    // 首先锁定该 i 节点，取该节点所在设备的超级块。
300         lock_inode(inode);
301         if (!(sb=get_super(inode->i_dev)))
302                 panic("trying to read inode without dev");
    // 该 i 节点所在的逻辑块号 = (启动块+超级块) + i 节点位图占用的块数 + 逻辑块位图占用的块数 +
    // (i 节点号-1)/每块含有的 i 节点数。
303         block = 2 + sb->s_imap_blocks + sb->s_zmap_blocks +
304                 (inode->i_num-1)/INODES_PER_BLOCK;
    // 从设备上读取该 i 节点所在的逻辑块，并将该 inode 指针指向对应 i 节点信息。
305         if (!(bh=bread(inode->i_dev,block)))
306                 panic("unable to read i-node block");
307         *(struct d_inode *)inode =
308                 ((struct d_inode *)bh->b_data)
309                         [(inode->i_num-1)%INODES_PER_BLOCK];
    // 最后释放读入的缓冲区，并解锁该 i 节点。
310         brelse(bh);
311         unlock_inode(inode);
312 }
313
    //// 将指定 i 节点信息写入设备（写入缓冲区相应的缓冲块中，待缓冲区刷新时会写入盘中）。
314 static void write_inode(struct m_inode * inode)
315 {
316         struct super_block * sb;
317         struct buffer_head * bh;
318         int block;
319
    // 首先锁定该 i 节点，如果该 i 节点没有被修改过或者该 i 节点的设备号等于零，则解锁该 i 节点，
    // 并退出。
```

```
320         lock_inode(inode);
321         if (!inode->i_dirt || !inode->i_dev) {
322                 unlock_inode(inode);
323                 return;
324         }
    // 获取该 i 节点的超级块。
325         if (!(sb=get_super(inode->i_dev)))
326                 panic("trying to write inode without device");
    // 该 i 节点所在的逻辑块号 = (启动块+超级块) + i 节点位图占用的块数 + 逻辑块位图占用的块数 +
    // (i 节点号-1)/每块含有的 i 节点数。
327         block = 2 + sb->s_imap_blocks + sb->s_zmap_blocks +
328                 (inode->i_num-1)/INODES_PER_BLOCK;
    // 从设备上读取该 i 节点所在的逻辑块。
329         if (!(bh=bread(inode->i_dev,block)))
330                 panic("unable to read i-node block");
    // 将该 i 节点信息复制到逻辑块对应该 i 节点的项中。
331         ((struct d_inode *)bh->b_data)
332                 [(inode->i_num-1)%INODES_PER_BLOCK] =
333                         *(struct d_inode *)inode;
    // 置缓冲区已修改标志，而 i 节点修改标志置零。然后释放该含有 i 节点的缓冲区，并解锁该 i 节点。
334         bh->b_dirt=1;
335         inode->i_dirt=0;
336         brelse(bh);
337         unlock_inode(inode);
338 }
339
```

9.6.3 其他信息

无☺。

9.7 super.c 程序

9.7.1 功能描述

该文件描述了对文件系统中超级块操作的函数，这些函数属于文件系统低层函数，供上层的文件名和目录操作函数使用。主要有 get_super()、put_super()和 read_super()。另外还有 2 个有关文件系统加载/卸载系统调用 sys_umount()和 sys_mount()，以及根文件系统加载函数 mount_root()。其他一些辅助函数与 buffer.c 中的辅助函数的作用类似。

超级块中主要存放了有关整个文件系统的信息，其信息结构参见“总体功能描述”中的图 9.x。

get_super()函数用于在指定设备的条件下，在内存超级块数组中搜索对应的超级块，并返回相应超级块的指针。因此，在调用该函数时，该相应的文件系统必须已经被加载（mount），或者起码该超级块已经占用了超级块数组中的一项，否则返回 NULL。

put_super()用于释放指定设备的超级块。它把该超级块对应的文件系统的 i 节点位图和逻辑块位图所占用的缓冲块都释放掉。在调用 umount()卸载一个文件系统或者更换磁盘时将会调用该函数。

read_super()用于把指定设备的文件系统的超级块读入到缓冲区中，并登记到超级块数组中，同时也把文件系统的 i 节点位图和逻辑块位图读入内存超级块结构的相应数组中。最后并返回该超级块结构的指针。

sys_umount()系统调用用于卸载一个指定设备文件名的文件系统，而 sys_mount()则用于往一个目录

名上加载一个文件系统。

程序中最后一个函数 mount_root()是用于安装系统的根文件系统，并将在系统初始化时被调用。其具体操作流程图 9-18 所示。

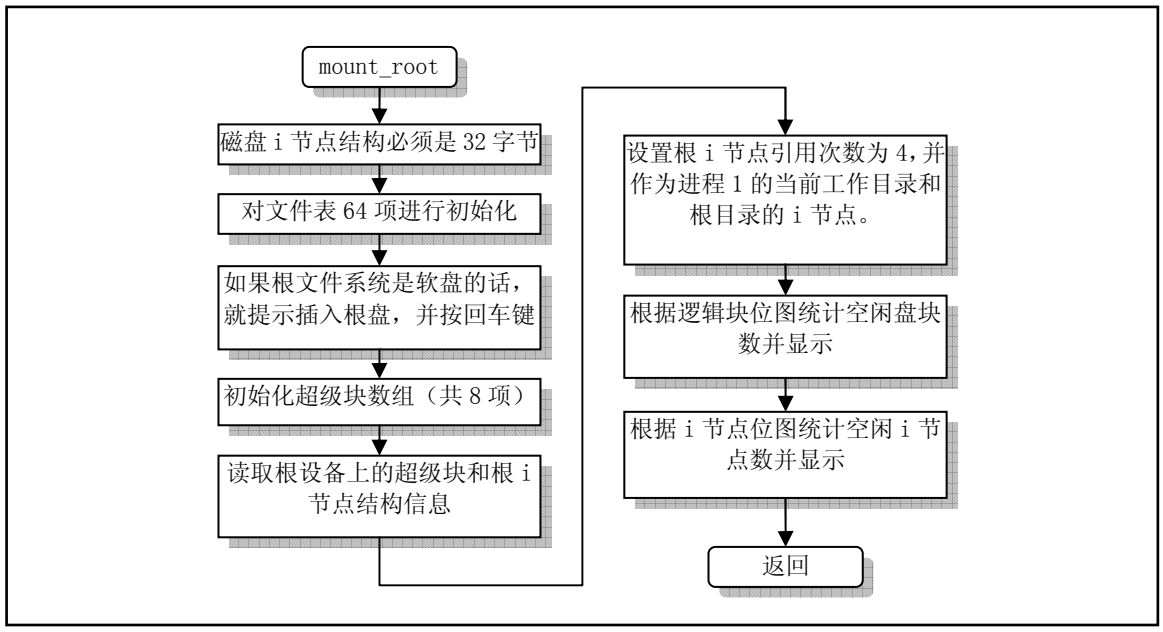

图 9-18 mount_root()函数的功能

该函数除了用于安装系统的根文件系统以外，还对内核使用文件系统起到初始化的作用。它对内存中超级块数组进行了初始化，还对文件描述符数组表 file_table[]进行了初始化，并对根文件系统中的空闲盘块数和空闲 i 节点数进行了统计并显示出来。

mount_root()函数是在系统执行初始化程序 main.c 中，在进程 0 创建了第一个子进程（进程 1）后被调用的，而且系统仅在这里调用它一次。具体的调用位置是在初始化函数 init()的 setup()函数中。setup()函数位于/kernel/blk_drv/hd.c 第 71 行开始。

9.7.2 代码注释

程序 9-5 linux/fs/super.c

```
 1 /*
 2  *  linux/fs/super.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * super.c contains code to handle the super-block tables.
 9  */
10 #include <linux/config.h> // 内核配置头文件。定义键盘语言和硬盘类型（HD_TYPE）可选项。
11 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
12 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
13 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
14
15 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
16 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
```

```
17
18 int sync_dev(int dev);     // 对指定设备执行高速缓冲与设备上数据的同步操作。(fs/buffer.c,59)
19 void wait_for_keypress(void);  // 等待击键。(kernel/chr_drv/tty_io.c, 140)
20
21 /* set_bit uses setb, as gas doesn't recognize setc */
   /* set_bit()使用了 setb 指令，因为汇编编译器 gas 不能识别指令 setc */
   //// 测试指定位偏移处比特位的值(0 或 1)，并返回该比特位值。(应该取名为 test_bit()更妥帖)
   // 嵌入式汇编宏。参数 bitnr 是比特位偏移值，addr 是测试比特位操作的起始地址。
   // %0 - ax(__res), %1 - 0, %2 - bitnr, %3 - addr
22 #define set_bit(bitnr,addr) ({ \
23 register int __res __asm__("ax"); \
24 __asm__("bt %2,%3;setb %%al":"=a" (__res):"a" (0),"r" (bitnr),"m" (*(addr))); \
25 __res; })
26
27 struct super_block super_block[NR_SUPER];   // 超级块结构数组（共 8 项）。
28 /* this is initialized in init/main.c */
   /* ROOT_DEV 已在 init/main.c 中被初始化 */
29 int ROOT_DEV = 0;
30
   //// 锁定指定的超级块。
31 static void lock_super(struct super_block * sb)
32 {
33         cli();                          // 关中断。
34         while (sb->s_lock)              // 如果该超级块已经上锁，则睡眠等待。
35                 sleep_on(&(sb->s_wait));
36         sb->s_lock = 1;                 // 给该超级块加锁（置锁定标志）。
37         sti();                          // 开中断。
38 }
39
   //// 对指定超级块解锁。（如果使用 ulock_super 这个名称则更妥帖）。
40 static void free_super(struct super_block * sb)
41 {
42         cli();                          // 关中断。
43         sb->s_lock = 0;                 // 复位锁定标志。
44         wake_up(&(sb->s_wait));         // 唤醒等待该超级块的进程。
45         sti();                          // 开中断。
46 }
47
   //// 睡眠等待超级块解锁。
48 static void wait_on_super(struct super_block * sb)
49 {
50         cli();                          // 关中断。
51         while (sb->s_lock)              // 如果超级块已经上锁，则睡眠等待。
52                 sleep_on(&(sb->s_wait));
53         sti();                          // 开中断。
54 }
55
   //// 取指定设备的超级块。返回该超级块结构指针。
56 struct super_block * get_super(int dev)
57 {
58         struct super_block * s;
59
   // 如果没有指定设备，则返回空指针。
```

```
60          if (!dev)
61                  return NULL;
    // s 指向超级块数组开始处。搜索整个超级块数组，寻找指定设备的超级块。
62          s = 0+super_block;
63          while (s < NR_SUPER+super_block)
    // 如果当前搜索项是指定设备的超级块，则首先等待该超级块解锁（若已经被其他进程上锁的话）。
    // 在等待期间，该超级块有可能被其他设备使用，因此此时需再判断一次是否是指定设备的超级块，
    // 如果是则返回该超级块的指针。否则就重新对超级块数组再搜索一遍，因此 s 重又指向超级块数组
    // 开始处。
64                  if (s->s_dev == dev) {
65                          wait_on_super(s);
66                          if (s->s_dev == dev)
67                                  return s;
68                          s = 0+super_block;
    // 如果当前搜索项不是，则检查下一项。如果没有找到指定的超级块，则返回空指针。
69                  } else
70                          s++;
71          return NULL;
72  }
73
    //// 释放指定设备的超级块。
    // 释放设备所使用的超级块数组项（置 s_dev=0），并释放该设备 i 节点位图和逻辑块位图所占用
    // 的高速缓冲块。如果超级块对应的文件系统是根文件系统，或者其 i 节点上已经安装有其他的文件
    // 系统，则不能释放该超级块。
74  void put_super(int dev)
75  {
76          struct super_block * sb;
77          struct m_inode * inode;
78          int i;
79
    // 如果指定设备是根文件系统设备，则显示警告信息“根系统盘改变了，准备生死决战吧”，并返回。
80          if (dev == ROOT_DEV) {
81                  printk("root diskette changed: prepare for armageddon\n\r");
82                  return;
83          }
    // 如果找不到指定设备的超级块，则返回。
84          if (!(sb = get_super(dev)))
85                  return;
    // 如果该超级块指明本文件系统所安装到的 i 节点还没有被处理过，则显示警告信息并返回。
    // 在 umount 操作中 s_imount 会先被置成 Null 以后才调用本函数，参见第 192 行。
86          if (sb->s_imount) {
87                  printk("Mounted disk changed - tssk, tssk\n\r");
88                  return;
89          }
    // 找到指定设备的超级块后，首先锁定该超级块，然后置该超级块对应的设备号字段为 0，也即即将
    // 放弃该超级块。
90          lock_super(sb);
91          sb->s_dev = 0;
    // 然后释放该设备 i 节点位图和逻辑块位图在缓冲区中所占用的缓冲块。
92          for(i=0;i<I_MAP_SLOTS;i++)
93                  brelse(sb->s_imap[i]);
94          for(i=0;i<Z_MAP_SLOTS;i++)
95                  brelse(sb->s_zmap[i]);
```

```
    // 最后对该超级块解锁，并返回。
 96         free_super(sb);
 97         return;
 98 }
 99
    //// 从设备上读取超级块到缓冲区中。
    // 如果该设备的超级块已经在高速缓冲中并且有效，则直接返回该超级块的指针。
100 static struct super_block * read_super(int dev)
101 {
102         struct super_block * s;
103         struct buffer_head * bh;
104         int i,block;
105
    // 如果没有指明设备，则返回空指针。
106         if (!dev)
107                 return NULL;
    // 首先检查该设备是否可更换过盘片（也即是否是软盘设备），如果更换过盘，则高速缓冲区有关该
    // 设备的所有缓冲块均失效，需要进行失效处理（释放原来加载的文件系统）。
108         check_disk_change(dev);
    // 如果该设备的超级块已经在高速缓冲中，则直接返回该超级块的指针。
109         if (s = get_super(dev))
110                 return s;
    // 否则，首先在超级块数组中找出一个空项(也即其 s_dev=0 的项)。如果数组已经占满则返回空指针。
111         for (s = 0+super_block ;; s++) {
112                 if (s >= NR_SUPER+super_block)
113                         return NULL;
114                 if (!s->s_dev)
115                         break;
116         }
    // 找到超级块空项后，就将该超级块用于指定设备，对该超级块的内存项进行部分初始化。
117         s->s_dev = dev;
118         s->s_isup = NULL;
119         s->s_imount = NULL;
120         s->s_time = 0;
121         s->s_rd_only = 0;
122         s->s_dirt = 0;
    // 然后锁定该超级块，并从设备上读取超级块信息到 bh 指向的缓冲区中。如果读超级块操作失败，
    // 则释放上面选定的超级块数组中的项，并解锁该项，返回空指针退出。
123         lock_super(s);
124         if (!(bh = bread(dev,1))) {
125                 s->s_dev=0;
126                 free_super(s);
127                 return NULL;
128         }
    // 将设备上读取的超级块信息复制到超级块数组相应项结构中。并释放存放读取信息的高速缓冲块。
129         *((struct d_super_block *) s) =
130                 *((struct d_super_block *) bh->b_data);
131         brelse(bh);
    // 如果读取的超级块的文件系统魔数字段内容不对，说明设备上不是正确的文件系统，因此同上面
    // 一样，释放上面选定的超级块数组中的项，并解锁该项，返回空指针退出。
    // 对于该版 linux 内核，只支持 minix 文件系统版本 1.0，其魔数是 0x137f。
132         if (s->s_magic != SUPER_MAGIC) {
133                 s->s_dev = 0;
```

```
134                 free_super(s);
135                 return NULL;
136         }
    // 下面开始读取设备上 i 节点位图和逻辑块位图数据。首先初始化内存超级块结构中位图空间。
137         for (i=0;i<I_MAP_SLOTS;i++)
138                 s->s_imap[i] = NULL;
139         for (i=0;i<Z_MAP_SLOTS;i++)
140                 s->s_zmap[i] = NULL;
    // 然后从设备上读取 i 节点位图和逻辑块位图信息，并存放在超级块对应字段中。
141         block=2;
142         for (i=0 ; i < s->s_imap_blocks ; i++)
143                 if (s->s_imap[i]=bread(dev,block))
144                         block++;
145                 else
146                         break;
147         for (i=0 ; i < s->s_zmap_blocks ; i++)
148                 if (s->s_zmap[i]=bread(dev,block))
149                         block++;
150                 else
151                         break;
    // 如果读出的位图逻辑块数不等于位图应该占有的逻辑块数，说明文件系统位图信息有问题，超级块
    // 初始化失败。因此只能释放前面申请的所有资源，返回空指针并退出。
152         if (block != 2+s->s_imap_blocks+s->s_zmap_blocks) {
    // 释放 i 节点位图和逻辑块位图占用的高速缓冲区。
153                 for(i=0;i<I_MAP_SLOTS;i++)
154                         brelse(s->s_imap[i]);
155                 for(i=0;i<Z_MAP_SLOTS;i++)
156                         brelse(s->s_zmap[i]);
    //释放上面选定的超级块数组中的项，并解锁该超级块项，返回空指针退出。
157                 s->s_dev=0;
158                 free_super(s);
159                 return NULL;
160         }
    // 否则一切成功。对于申请空闲 i 节点的函数来讲，如果设备上所有的 i 节点已经全被使用，则查找
    // 函数会返回 0 值。因此 0 号 i 节点是不能用的，所以这里将位图中的最低位设置为 1，以防止文件
    // 系统分配 0 号 i 节点。同样的道理，也将逻辑块位图的最低位设置为 1。
161         s->s_imap[0]->b_data[0] |= 1;
162         s->s_zmap[0]->b_data[0] |= 1;
    // 解锁该超级块，并返回超级块指针。
163         free_super(s);
164         return s;
165 }
166
    //// 卸载文件系统的系统调用函数。
    // 参数 dev_name 是设备文件名。
167 int sys_umount(char * dev_name)
168 {
169         struct m_inode * inode;
170         struct super_block * sb;
171         int dev;
172
    // 首先根据设备文件名找到对应的 i 节点，并取其中的设备号。
173         if (!(inode=namei(dev_name)))
```

```
174                 return -ENOENT;
175         dev = inode->i_zone[0];
    // 如果不是块设备文件，则释放刚申请的 i 节点 dev_i，返回出错码。
176         if (!S_ISBLK(inode->i_mode)) {
177                 iput(inode);
178                 return -ENOTBLK;
179         }
    // 释放设备文件名的 i 节点。
180         iput(inode);
    // 如果设备是根文件系统，则不能被卸载，返回出错号。
181         if (dev==ROOT_DEV)
182                 return -EBUSY;
    // 如果取设备的超级块失败，或者该设备文件系统没有安装过，则返回出错码。
183         if (!(sb=get_super(dev)) || !(sb->s_imount))
184                 return -ENOENT;
    // 如果超级块所指明的被安装到的 i 节点没有置位其安装标志，则显示警告信息。
185         if (!sb->s_imount->i_mount)
186                 printk("Mounted inode has i_mount=0\n");
    // 查找 i 节点表，看是否有进程在使用该设备上的文件，如果有则返回忙出错码。
187         for (inode=inode_table+0 ; inode<inode_table+NR_INODE ; inode++)
188                 if (inode->i_dev==dev && inode->i_count)
189                                 return -EBUSY;
    // 复位被安装到的 i 节点的安装标志，释放该 i 节点。
190         sb->s_imount->i_mount=0;
191         iput(sb->s_imount);
    // 置超级块中被安装 i 节点字段为空，并释放设备文件系统的根 i 节点，置超级块中被安装系统
    // 根 i 节点指针为空。
192         sb->s_imount = NULL;
193         iput(sb->s_isup);
194         sb->s_isup = NULL;
    // 释放该设备的超级块以及位图占用的缓冲块，并对该设备执行高速缓冲与设备上数据的同步操作。
195         put_super(dev);
196         sync_dev(dev);
197         return 0;
198 }
199
    //// 安装文件系统调用函数。
    // 参数 dev_name 是设备文件名，dir_name 是安装到的目录名，rw_flag 被安装文件的读写标志。
    // 将被加载的地方必须是一个目录名，并且对应的 i 节点没有被其他程序占用。
200 int sys_mount(char * dev_name, char * dir_name, int rw_flag)
201 {
202         struct m_inode * dev_i, * dir_i;
203         struct super_block * sb;
204         int dev;
205
    // 首先根据设备文件名找到对应的 i 节点，并取其中的设备号。
    // 对于块特殊设备文件，设备号在 i 节点的 i_zone[0]中。
206         if (!(dev_i=namei(dev_name)))
207                 return -ENOENT;
208         dev = dev_i->i_zone[0];
    // 如果不是块设备文件，则释放刚取得的 i 节点 dev_i，返回出错码。
209         if (!S_ISBLK(dev_i->i_mode)) {
210                 iput(dev_i);
```

```
211                 return -EPERM;
212         }
    // 释放该设备文件的 i 节点 dev_i。
213         iput(dev_i);
    // 根据给定的目录文件名找到对应的 i 节点 dir_i。
214         if (!(dir_i=namei(dir_name)))
215                 return -ENOENT;
    // 如果该 i 节点的引用计数不为 1（仅在这里引用），或者该 i 节点的节点号是根文件系统的节点
    // 号 1，则释放该 i 节点，返回出错码。
216         if (dir_i->i_count != 1 || dir_i->i_num == ROOT_INO) {
217                 iput(dir_i);
218                 return -EBUSY;
219         }
    // 如果该节点不是一个目录文件节点，则也释放该 i 节点，返回出错码。
220         if (!S_ISDIR(dir_i->i_mode)) {
221                 iput(dir_i);
222                 return -EPERM;
223         }
    // 读取将安装文件系统的超级块，如果失败则也释放该 i 节点，返回出错码。
224         if (!(sb=read_super(dev))) {
225                 iput(dir_i);
226                 return -EBUSY;
227         }
    // 如果将要被安装的文件系统已经安装在其他地方，则释放该 i 节点，返回出错码。
228         if (sb->s_imount) {
229                 iput(dir_i);
230                 return -EBUSY;
231         }
    // 如果将要安装到的 i 节点已经安装了文件系统(安装标志已经置位)，则释放该 i 节点，返回出错码。
232         if (dir_i->i_mount) {
233                 iput(dir_i);
234                 return -EPERM;
235         }
    // 被安装文件系统超级块的“被安装到 i 节点”字段指向安装到的目录名的 i 节点。
236         sb->s_imount=dir_i;
    // 设置安装位置 i 节点的安装标志和节点已修改标志。/* 注意！这里没有 iput(dir_i) */
237         dir_i->i_mount=1;                   /* 这将在 umount 内操作 */
238         dir_i->i_dirt=1;                /* NOTE! we don't iput(dir_i) */
239         return 0;                       /* we do that in umount */
240 }
241
    //// 安装根文件系统。
    // 该函数是在系统开机初始化设置时(sys_setup())调用的。( kernel/blk_drv/hd.c, 157 )
242 void mount_root(void)
243 {
244         int i,free;
245         struct super_block * p;
246         struct m_inode * mi;
247
    // 如果磁盘 i 节点结构不是 32 个字节，则出错，死机。该判断是用于防止修改源代码时的不一致性。
248         if (32 != sizeof (struct d_inode))
249                 panic("bad i-node size");
    // 初始化文件表数组（共 64 项，也即系统同时只能打开 64 个文件），将所有文件结构中的引用计数
```

```
    // 设置为 0。[??为什么放在这里初始化？因为根文件系统在这里加载☺]
250         for(i=0;i<NR_FILE;i++)
251                 file_table[i].f_count=0;
    // 如果根文件系统所在设备是软盘的话，就提示“插入根文件系统盘，并按回车键”，并等待按键。
252         if (MAJOR(ROOT_DEV) == 2) {
253                 printk("Insert root floppy and press ENTER");
254                 wait_for_keypress();
255         }
    // 初始化超级块数组（共 8 项）。
256         for(p = &super_block[0] ; p < &super_block[NR_SUPER] ; p++) {
257                 p->s_dev = 0;
258                 p->s_lock = 0;
259                 p->s_wait = NULL;
260         }
    // 如果读根设备上超级块失败，则显示信息，并死机。
261         if (!(p=read_super(ROOT_DEV)))
262                 panic("Unable to mount root");
    // 从设备上读取文件系统根 i 节点(1)，若失败则显示出错信息，死机。在 fs.h 中 ROOT_INO 定义为 1。
263         if (!(mi=iget(ROOT_DEV,ROOT_INO)))
264                 panic("Unable to read root i-node");
    // 该 i 节点引用次数递增 3 次。因为下面 266-268 行上也引用了该 i 节点。
265         mi->i_count += 3 ;      /* NOTE! it is logically used 4 times, not 1 */
                                    /* 注意！从逻辑上讲，它已被引用了 4 次，而不是 1 次 */
    // 置该超级块的被安装文件系统 i 节点和被安装到的 i 节点为该 i 节点。
266         p->s_isup = p->s_imount = mi;
    // 设置当前进程的当前工作目录和根目录 i 节点。此时当前进程是 1 号进程。
267         current->pwd = mi;
268         current->root = mi;
    // 统计该设备上空闲块数。首先令 i 等于超级块中表明的设备逻辑块总数。
269         free=0;
270         i=p->s_nzones;
    // 然后根据逻辑块位图中相应比特位的占用情况统计出空闲块数。这里宏函数 set_bit()只是在测试
    // 比特位，而非设置比特位。"i&8191"用于取得 i 节点号在当前块中的偏移值。"i>>13"是将 i 除以
    // 8192，也即除一个磁盘块包含的比特位数。
271         while (-- i >= 0)
272                 if (!set_bit(i&8191,p->s_zmap[i>>13]->b_data))
273                         free++;
    // 显示设备上空闲逻辑块数/逻辑块总数。
274         printk("%d/%d free blocks\n\r",free,p->s_nzones);
    // 统计设备上空闲 i 节点数。首先令 i 等于超级块中表明的设备上 i 节点总数+1。加 1 是将 0 节点
    // 也统计进去。
275         free=0;
276         i=p->s_ninodes+1;
    // 然后根据 i 节点位图中相应比特位的占用情况计算出空闲 i 节点数。
277         while (-- i >= 0)
278                 if (!set_bit(i&8191,p->s_imap[i>>13]->b_data))
279                         free++;
    // 显示设备上可用的空闲 i 节点数/i 节点总数。
280         printk("%d/%d free inodes\n\r",free,p->s_ninodes);
281 }
282
```

9.8 namei.c 程序

9.8.1 功能描述

该文件是 linux 0.11 内核中最长的函数，不过也只有 700 多行☺。本文件主要实现了根据目录名或文件名寻找到对应 i 节点的函数，以及一些关于目录的建立和删除、目录项的建立和删除等操作函数和系统调用。由于程序中几个主要函数的前面都有较详细的英文注释，而且各函数和系统调用的功能明了，所以这里就不再赘述。

9.8.2 代码注释

程序 9-6 linux/fs/namei.c

```
1  /*
2   *  linux/fs/namei.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  /*
8   * Some corrections by tytso.
9   */
   /*
    * tytso 作了一些纠正。
    */
10
11 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
12 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
13 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
14
15 #include <string.h>       // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
16 #include <fcntl.h>        // 文件控制头文件。用于文件及其描述符的操作控制常数符号的定义。
17 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
18 #include <const.h>        // 常数符号头文件。目前仅定义了 i 节点中 i_mode 字段的各标志位。
19 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
20
   // 访问模式宏。x 是 include/fcntl.h 第 7 行开始定义的文件访问标志。
   // 根据 x 值索引对应数值（数值表示 rwx 权限: r, w, rw, wxrwxrwx）(数值是 8 进制)。
21 #define ACC_MODE(x) ("\004\002\006\377"[(x)&O_ACCMODE])
22
23 /*
24  * comment out this line if you want names > NAME_LEN chars to be
25  * truncated. Else they will be disallowed.
26  */
    /*
    * 如果想让文件名长度>NAME_LEN 的字符被截掉，就将下面定义注释掉。
    */
27 /* #define NO_TRUNCATE */
28
```

```
29 #define MAY_EXEC 1          // 可执行(可进入)。
30 #define MAY_WRITE 2         // 可写。
31 #define MAY_READ 4          // 可读。
32
33 /*
34  *      permission()
35  *
36  * is used to check for read/write/execute permissions on a file.
37  * I don't know if we should look at just the euid or both euid and
38  * uid, but that should be easily changed.
39  */
   /*
    *     permission()
    * 该函数用于检测一个文件的读/写/执行权限。我不知道是否只需检查 euid，还是
    * 需要检查 euid 和 uid 两者，不过这很容易修改。
    */
   //// 检测文件访问许可权限。
   // 参数：inode - 文件对应的 i 节点；mask - 访问属性屏蔽码。
   // 返回：访问许可返回 1，否则返回 0。
40 static int permission(struct m_inode * inode,int mask)
41 {
42         int mode = inode->i_mode;     // 文件访问属性
43
44 /* special case: not even root can read/write a deleted file */
   /* 特殊情况：即使是超级用户(root)也不能读/写一个已被删除的文件 */
   // 如果 i 节点有对应的设备，但该 i 节点的连接数等于 0，则返回。
45         if (inode->i_dev && !inode->i_nlinks)
46                 return 0;
   // 否则，如果进程的有效用户 id(euid)与 i 节点的用户 id 相同，则取文件宿主的用户访问权限。
47         else if (current->euid==inode->i_uid)
48                 mode >>= 6;
   // 否则，如果进程的有效组 id(egid)与 i 节点的组 id 相同，则取组用户的访问权限。
49         else if (current->egid==inode->i_gid)
50                 mode >>= 3;
   // 如果上面所取的的访问权限与屏蔽码相同，或者是超级用户，则返回 1，否则返回 0。
51         if (((mode & mask & 0007) == mask) || suser())
52                 return 1;
53         return 0;
54 }
55
56 /*
57  * ok, we cannot use strncmp, as the name is not in our data space.
58  * Thus we'll have to use match. No big problem. Match also makes
59  * some sanity tests.
60  *
61  * NOTE! unlike strncmp, match returns 1 for success, 0 for failure.
62  */
   /*
    * ok，我们不能使用 strncmp 字符串比较函数，因为名称不在我们的数据空间(不在内核空间)。
    * 因而我们只能使用 match()。问题不大。match()同样也处理一些完整的测试。
    *
    * 注意！与 strncmp 不同的是 match()成功时返回 1，失败时返回 0。
    */
```

```
//// 指定长度字符串比较函数。
// 参数：len - 比较的字符串长度；name - 文件名指针；de - 目录项结构。
// 返回：相同返回 1，不同返回 0。
63 static int match(int len,const char * name,struct dir_entry * de)
64 {
65         register int same __asm__("ax");
66
// 如果目录项指针空，或者目录项 i 节点等于 0，或者要比较的字符串长度超过文件名长度，则返回 0。
67         if (!de || !de->inode || len > NAME_LEN)
68                 return 0;
// 如果要比较的长度 len 小于 NAME_LEN，但是目录项中文件名长度超过 len，则返回 0。
69         if (len < NAME_LEN && de->name[len])
70                 return 0;
// 下面嵌入汇编语句，在用户数据空间(fs)执行字符串的比较操作。
// %0 - eax(比较结果 same)；%1 - eax(eax 初值 0)；%2 - esi(名字指针)；%3 - edi(目录项名指针)；
// %4 - ecx(比较的字节长度值 len)。
71         __asm__("cld\n\t"                       // 清方向位。
72                 "fs ; repe ; cmpsb\n\t"         // 用户空间执行循环比较[esi++]和[edi++]操作，
73                 "setz %%al"                     // 若比较结果一样(z=0)则设置 al=1(same=eax)。
74                 :"=a" (same)
75                 :"" (0),"S" ((long) name),"D" ((long) de->name),"c" (len)
76                 :"cx","di","si");
77         return same;                            // 返回比较结果。
78 }
79
80 /*
81  *      find_entry()
82  *
83  * finds an entry in the specified directory with the wanted name. It
84  * returns the cache buffer in which the entry was found, and the entry
85  * itself (as a parameter - res_dir). It does NOT read the inode of the
86  * entry - you'll have to do that yourself if you want to.
87  *
88  * This also takes care of the few special cases due to '..'-traversal
89  * over a pseudo-root and a mount point.
90  */
/*
 *     find_entry()
 * 在指定的目录中寻找一个与名字匹配的目录项。返回一个含有找到目录项的高速
 * 缓冲区以及目录项本身(作为一个参数 - res_dir)。并不读目录项的 i 节点 - 如
 * 果需要的话需自己操作。
 *
 * '..'目录项，操作期间也会对几种特殊情况分别处理 - 比如横越一个伪根目录以
 * 及安装点。
 */
//// 查找指定目录和文件名的目录项。
// 参数：dir - 指定目录 i 节点的指针；name - 文件名；namelen - 文件名长度；
// 返回：高速缓冲区指针；res_dir - 返回的目录项结构指针；
91 static struct buffer_head * find_entry(struct m_inode ** dir,
92         const char * name, int namelen, struct dir_entry ** res_dir)
93 {
94         int entries;
95         int block,i;
```

```
 96          struct buffer_head * bh;
 97          struct dir_entry * de;
 98          struct super_block * sb;
 99
    // 如果定义了 NO_TRUNCATE，则若文件名长度超过最大长度 NAME_LEN，则返回。
100 #ifdef NO_TRUNCATE
101          if (namelen > NAME_LEN)
102                  return NULL;
    //如果没有定义 NO_TRUNCATE，则若文件名长度超过最大长度 NAME_LEN，则截短之。
103 #else
104          if (namelen > NAME_LEN)
105                  namelen = NAME_LEN;
106 #endif
    // 计算本目录中目录项项数 entries。置空返回目录项结构指针。
107          entries = (*dir)->i_size / (sizeof (struct dir_entry));
108          *res_dir = NULL;
    // 如果文件名长度等于 0，则返回 NULL，退出。
109          if (!namelen)
110                  return NULL;
111 /* check for '..', as we might have to do some "magic" for it */
    /* 检查目录项'..'，因为可能需要对其特别处理 */
112          if (namelen==2 && get_fs_byte(name)=='.' && get_fs_byte(name+1)=='.') {
113 /* '..' in a pseudo-root results in a faked '.' (just change namelen) */
    /* 伪根中的'..'如同一个假'.'(只需改变名字长度) */
    // 如果当前进程的根节点指针即是指定的目录，则将文件名修改为'.'，
114                  if ((*dir) == current->root)
115                          namelen=1;
    // 否则如果该目录的 i 节点号等于 ROOT_INO(1)的话，说明是文件系统根节点。则取文件系统的超级块。

116                  else if ((*dir)->i_num == ROOT_INO) {
117 /* '..' over a mount-point results in 'dir' being exchanged for the mounted
118    directory-inode. NOTE! We set mounted, so that we can iput the new dir */
    /* 在一个安装点上的'..'将导致目录交换到安装到文件系统的目录 i 节点。
       注意! 由于设置了 mounted 标志，因而我们能够取出该新目录 */
119                          sb=get_super((*dir)->i_dev);
    // 如果被安装到的 i 节点存在，则先释放原 i 节点，然后对被安装到的 i 节点进行处理。
    // 让*dir 指向该被安装到的 i 节点；该 i 节点的引用数加 1。
120                          if (sb->s_imount) {
121                                  iput(*dir);
122                                  (*dir)=sb->s_imount;
123                                  (*dir)->i_count++;
124                          }
125                  }
126          }
    // 如果该 i 节点所指向的第一个直接磁盘块号为 0，则返回 NULL，退出。
127          if (!(block = (*dir)->i_zone[0]))
128                  return NULL;
    // 从节点所在设备读取指定的目录项数据块，如果不成功，则返回 NULL，退出。
129          if (!(bh = bread((*dir)->i_dev,block)))
130                  return NULL;
    // 在目录项数据块中搜索匹配指定文件名的目录项，首先让 de 指向数据块，并在不超过目录中目录项
数
    // 的条件下，循环执行搜索。
```

```
131         i = 0;
132         de = (struct dir_entry *) bh->b_data;
133         while (i < entries) {
    // 如果当前目录项数据块已经搜索完，还没有找到匹配的目录项，则释放当前目录项数据块。
134                 if ((char *)de >= BLOCK_SIZE+bh->b_data) {
135                         brelse(bh);
136                         bh = NULL;
    // 在读入下一目录项数据块。若这块为空，则只要还没有搜索完目录中的所有目录项，就跳过该块，
    // 继续读下一目录项数据块。若该块不空，就让 de 指向该目录项数据块，继续搜索。
137                         if (!(block = bmap(*dir,i/DIR_ENTRIES_PER_BLOCK)) ||
138                             !(bh = bread((*dir)->i_dev,block))) {
139                                 i += DIR_ENTRIES_PER_BLOCK;
140                                 continue;
141                         }
142                         de = (struct dir_entry *) bh->b_data;
143                 }
    // 如果找到匹配的目录项的话，则返回该目录项结构指针和该目录项数据块指针，退出。
144                 if (match(namelen,name,de)) {
145                         *res_dir = de;
146                         return bh;
147                 }
    // 否则继续在目录项数据块中比较下一个目录项。
148                 de++;
149                 i++;
150         }
    // 若指定目录中的所有目录项都搜索完还没有找到相应的目录项，则释放目录项数据块，返回 NULL。
151         brelse(bh);
152         return NULL;
153 }
154
155 /*
156  *      add_entry()
157  *
158  * adds a file entry to the specified directory, using the same
159  * semantics as find_entry(). It returns NULL if it failed.
160  *
161  * NOTE!! The inode part of 'de' is left at 0 - which means you
162  * may not sleep between calling this and putting something into
163  * the entry, as someone else might have used it while you slept.
164  */
    /*
     *     add_entry()
     * 使用与 find_entry()同样的方法，往指定目录中添加一文件目录项。
     * 如果失败则返回 NULL。
     *
     * 注意！！'de'(指定目录项结构指针)的 i 节点部分被设置为 0 - 这表示
     * 在调用该函数和往目录项中添加信息之间不能睡眠，因为若睡眠那么其他
     * 人(进程)可能会使用了该目录项。
     */
    //// 根据指定的目录和文件名添加目录项。
    // 参数：dir - 指定目录的 i 节点；name - 文件名；namelen - 文件名长度；
    // 返回：高速缓冲区指针；res_dir - 返回的目录项结构指针；
165 static struct buffer_head * add_entry(struct m_inode * dir,
```

```
166         const char * name, int namelen, struct dir_entry ** res_dir)
167 {
168         int block,i;
169         struct buffer_head * bh;
170         struct dir_entry * de;
171
172         *res_dir = NULL;
    // 如果定义了 NO_TRUNCATE，则若文件名长度超过最大长度 NAME_LEN，则返回。
173 #ifdef NO_TRUNCATE
174         if (namelen > NAME_LEN)
175                 return NULL;
    //如果没有定义 NO_TRUNCATE，则若文件名长度超过最大长度 NAME_LEN，则截短之。
176 #else
177         if (namelen > NAME_LEN)
178                 namelen = NAME_LEN;
179 #endif
    // 如果文件名长度等于 0，则返回 NULL，退出。
180         if (!namelen)
181                 return NULL;
    // 如果该目录 i 节点所指向的第一个直接磁盘块号为 0，则返回 NULL 退出。
182         if (!(block = dir->i_zone[0]))
183                 return NULL;
    // 如果读取该磁盘块失败，则返回 NULL 并退出。
184         if (!(bh = bread(dir->i_dev,block)))
185                 return NULL;
    // 在目录项数据块中循环查找最后未使用的目录项。首先让目录项结构指针 de 指向高速缓冲的数据块
    // 开始处，也即第一个目录项。
186         i = 0;
187         de = (struct dir_entry *) bh->b_data;
188         while (1) {
    // 如果当前判别的目录项已经超出当前数据块，则释放该数据块，重新申请一块磁盘块 block。如果
    // 申请失败，则返回 NULL，退出。
189                 if ((char *)de >= BLOCK_SIZE+bh->b_data) {
190                         brelse(bh);
191                         bh = NULL;
192                         block = create_block(dir,i/DIR_ENTRIES_PER_BLOCK);
193                         if (!block)
194                                 return NULL;
    // 如果读取磁盘块返回的指针为空，则跳过该块继续。
195                         if (!(bh = bread(dir->i_dev,block))) {
196                                 i += DIR_ENTRIES_PER_BLOCK;
197                                 continue;
198                         }
    // 否则，让目录项结构指针 de 志向该块的高速缓冲数据块开始处。
199                         de = (struct dir_entry *) bh->b_data;
200                 }
    // 如果当前所操作的目录项序号 i*目录结构大小已经超过了该目录所指出的大小 i_size,则说明该第 i
    // 个目录项还未使用，我们可以使用它。于是对该目录项进行设置(置该目录项的 i 节点指针为空)。并
    // 更新该目录的长度值(加上一个目录项的长度，设置目录的 i 节点已修改标志，再更新该目录的改变
时
    // 间为当前时间。
201                 if (i*sizeof(struct dir_entry) >= dir->i_size) {
202                         de->inode=0;
```

```
203                         dir->i_size = (i+1)*sizeof(struct dir_entry);
204                         dir->i_dirt = 1;
205                         dir->i_ctime = CURRENT_TIME;
206                 }
    // 若该目录项的 i 节点为空，则表示找到一个还未使用的目录项。于是更新目录的修改时间为当前时间。
    // 并从用户数据区复制文件名到该目录项的文件名字段，置相应的高速缓冲块已修改标志。返回该目录
    // 项的指针以及该高速缓冲区的指针，退出。
207                 if (!de->inode) {
208                         dir->i_mtime = CURRENT_TIME;
209                         for (i=0; i < NAME_LEN ; i++)
210                                 de->name[i]=(i<namelen)?get_fs_byte(name+i):0;
211                         bh->b_dirt = 1;
212                         *res_dir = de;
213                         return bh;
214                 }
    // 如果该目录项已经被使用，则继续检测下一个目录项。
215                 de++;
216                 i++;
217         }
    // 执行不到这里。也许 Linus 在写这段代码时是先复制了上面 find_entry()的代码，而后修改的☺。
218         brelse(bh);
219         return NULL;
220 }
221
222 /*
223  *      get_dir()
224  *
225  * Getdir traverses the pathname until it hits the topmost directory.
226  * It returns NULL on failure.
227  */
    /*
     *      get_dir()
     * 该函数根据给出的路径名进行搜索，直到达到最顶端的目录。
     * 如果失败则返回 NULL。
     */
    //// 搜寻指定路径名的目录。
    // 参数：pathname - 路径名。
    // 返回：目录的 i 节点指针。失败时返回 NULL。
228 static struct m_inode * get_dir(const char * pathname)
229 {
230         char c;
231         const char * thisname;
232         struct m_inode * inode;
233         struct buffer_head * bh;
234         int namelen,inr,idev;
235         struct dir_entry * de;
236
    // 如果进程没有设定根 i 节点，或者该进程根 i 节点的引用为 0，则系统出错，死机。
237         if (!current->root || !current->root->i_count)
238                 panic("No root inode");
    // 如果进程的当前工作目录指针为空，或者该当前目录 i 节点的引用计数为 0，也是系统有问题，死机。
239         if (!current->pwd || !current->pwd->i_count)
240                 panic("No cwd inode");
```

```
    // 如果用户指定的路径名的第 1 个字符是'/'，则说明路径名是绝对路径名。则从根 i 节点开始操作。
241         if ((c=get_fs_byte(pathname))=='/') {
242                 inode = current->root;
243                 pathname++;
    // 否则若第一个字符是其他字符，则表示给定的是相对路径名。应从进程的当前工作目录开始操作。
    // 则取进程当前工作目录的 i 节点。
244         } else if (c)
245                 inode = current->pwd;
    // 否则表示路径名为空，出错。返回 NULL，退出。
246         else
247                 return NULL;    /* empty name is bad */   /* 空的路径名是错误的 */
    // 将取得的 i 节点引用计数增 1。
248         inode->i_count++;
249         while (1) {
    // 若该 i 节点不是目录节点，或者没有可进入的访问许可，则释放该 i 节点，返回 NULL，退出。
250                 thisname = pathname;
251                 if (!S_ISDIR(inode->i_mode) || !permission(inode,MAY_EXEC)) {
252                         iput(inode);
253                         return NULL;
254                 }
    // 从路径名开始起搜索检测字符，直到字符已是结尾符(NULL)或者是'/'，此时 namelen 正好是当前处
理
    // 目录名的长度。如果最后也是一个目录名，但其后没有加'/'，则不会返回该最后目录的 i 节点!
    // 比如：/var/log/httpd，将只返回 log/目录的 i 节点。
255                 for(namelen=0;(c=get_fs_byte(pathname++))&&(c!='/');namelen++)
256                         /* nothing */ ;
    // 若字符是结尾符 NULL，则表明已经到达指定目录，则返回该 i 节点指针，退出。
257                 if (!c)
258                         return inode;
    // 调用查找指定目录和文件名的目录项函数，在当前处理目录中寻找子目录项。如果没有找到，则释放
    // 该 i 节点，并返回 NULL，退出。
259                 if (!(bh = find_entry(&inode,thisname,namelen,&de))) {
260                         iput(inode);
261                         return NULL;
262                 }
    // 取该子目录项的 i 节点号 inr 和设备号 idev，释放包含该目录项的高速缓冲块和该 i 节点。
263                 inr = de->inode;
264                 idev = inode->i_dev;
265                 brelse(bh);
266                 iput(inode);
    // 取节点号 inr 的 i 节点信息，若失败，则返回 NULL，退出。否则继续以该子目录的 i 节点进行操作。
267                 if (!(inode = iget(idev,inr)))
268                         return NULL;
269         }
270 }
271
272 /*
273  *      dir_namei()
274  *
275  * dir_namei() returns the inode of the directory of the
276  * specified name, and the name within that directory.
277  */
    /*
```

```
 *      dir_namei()
 * dir_namei()函数返回指定目录名的 i 节点指针，以及在最顶层目录的名称。
 */
// 参数：pathname - 目录路径名；namelen - 路径名长度。
// 返回：指定目录名最顶层目录的 i 节点指针和最顶层目录名及其长度。
static struct m_inode * dir_namei(const char * pathname,
        int * namelen, const char ** name)
{
        char c;
        const char * basename;
        struct m_inode * dir;

// 取指定路径名最顶层目录的 i 节点，若出错则返回 NULL，退出。
        if (!(dir = get_dir(pathname)))
                return NULL;
// 对路径名 pathname 进行搜索检测，查处最后一个'/'后面的名字字符串，计算其长度，并返回最顶
// 层目录的 i 节点指针。
        basename = pathname;
        while (c=get_fs_byte(pathname++))
                if (c=='/')
                        basename=pathname;
        *namelen = pathname-basename-1;
        *name = basename;
        return dir;
}

/*
 *      namei()
 *
 * is used by most simple commands to get the inode of a specified name.
 * Open, link etc use their own routines, but this is enough for things
 * like 'chmod' etc.
 */
/*
 *      namei()
 * 该函数被许多简单的命令用于取得指定路径名称的 i 节点。open、link 等则使用它们
 * 自己的相应函数，但对于象修改模式'chmod'等这样的命令，该函数已足够用了。
 */
//// 取指定路径名的 i 节点。
// 参数：pathname - 路径名。
// 返回：对应的 i 节点。
struct m_inode * namei(const char * pathname)
{
        const char * basename;
        int inr,dev,namelen;
        struct m_inode * dir;
        struct buffer_head * bh;
        struct dir_entry * de;

// 首先查找指定路径的最顶层目录的目录名及其 i 节点，若不存在，则返回 NULL，退出。
        if (!(dir = dir_namei(pathname,&namelen,&basename)))
                return NULL;
// 如果返回的最顶层名字的长度是 0，则表示该路径名以一个目录名为最后一项。
```

```
313         if (!namelen)                       /* special case: '/usr/' etc */
314                 return dir;                 /* 对应于'/usr/'等情况 */
    // 在返回的顶层目录中寻找指定文件名的目录项的 i 节点。因为如果最后也是一个目录名，但其后没
    // 有加'/'，则不会返回该最后目录的 i 节点！比如：/var/log/httpd，将只返回 log/目录的 i 节点。
    // 因此 dir_namei()将不以'/'结束的最后一个名字当作一个文件名来看待。因此这里需要单独对这种
    // 情况使用寻找目录项 i 节点函数 find_entry()进行处理。
315         bh = find_entry(&dir,basename,namelen,&de);
316         if (!bh) {
317                 iput(dir);
318                 return NULL;
319         }
    // 取该目录项的 i 节点号和目录的设备号，并释放包含该目录项的高速缓冲区以及目录 i 节点。
320         inr = de->inode;
321         dev = dir->i_dev;
322         brelse(bh);
323         iput(dir);
    // 取对应节号的 i 节点，修改其被访问时间为当前时间，并置已修改标志。最后返回该 i 节点指针。
324         dir=iget(dev,inr);
325         if (dir) {
326                 dir->i_atime=CURRENT_TIME;
327                 dir->i_dirt=1;
328         }
329         return dir;
330 }
331
332 /*
333  *      open_namei()
334  *
335  * namei for open - this is in fact almost the whole open-routine.
336  */
    /*
     *     open_namei()
     * open()所使用的 namei 函数 - 这其实几乎是完整的打开文件程序。
     */
    //// 文件打开 namei 函数。
    // 参数：pathname - 文件路径名；flag - 文件打开标志；mode - 文件访问许可属性；
    // 返回：成功返回 0，否则返回出错码；res_inode - 返回的对应文件路径名的的 i 节点指针。
337 int open_namei(const char * pathname, int flag, int mode,
338         struct m_inode ** res_inode)
339 {
340         const char * basename;
341         int inr,dev,namelen;
342         struct m_inode * dir, *inode;
343         struct buffer_head * bh;
344         struct dir_entry * de;
345
    // 如果文件访问许可模式标志是只读(0)，但文件截 0 标志 O_TRUNC 却置位了，则改为只写标志。
346         if ((flag & O_TRUNC) && !(flag & O_ACCMODE))
347                 flag |= O_WRONLY;
    // 使用进程的文件访问许可屏蔽码，屏蔽掉给定模式中的相应位，并添上普通文件标志。
348         mode &= 0777 & ~current->umask;
349         mode |= I_REGULAR;
    // 根据路径名寻找到对应的 i 节点，以及最顶端文件名及其长度。
```

```
350         if (!(dir = dir_namei(pathname,&namelen,&basename)))
351                 return -ENOENT;
    // 如果最顶端文件名长度为 0(例如'/usr/'这种路径名的情况)，那么若打开操作不是创建、截 0，
    // 则表示打开一个目录名，直接返回该目录的 i 节点，并退出。
352         if (!namelen) {                 /* special case: '/usr/' etc */
353                 if (!(flag & (O_ACCMODE|O_CREAT|O_TRUNC))) {
354                         *res_inode=dir;
355                         return 0;
356                 }
    // 否则释放该 i 节点，返回出错码。
357                 iput(dir);
358                 return -EISDIR;
359         }
    // 在 dir 节点对应的目录中取文件名对应的目录项结构 de 和该目录项所在的高速缓冲区。
360         bh = find_entry(&dir,basename,namelen,&de);
    // 如果该高速缓冲指针为 NULL，则表示没有找到对应文件名的目录项，因此只可能是创建文件操作。
361         if (!bh) {
    // 如果不是创建文件，则释放该目录的 i 节点，返回出错号退出。
362                 if (!(flag & O_CREAT)) {
363                         iput(dir);
364                         return -ENOENT;
365                 }
    // 如果用户在该目录没有写的权力，则释放该目录的 i 节点，返回出错号退出。
366                 if (!permission(dir,MAY_WRITE)) {
367                         iput(dir);
368                         return -EACCES;
369                 }
    // 在目录节点对应的设备上申请一个新 i 节点，若失败，则释放目录的 i 节点，并返回没有空间出错码。
370                 inode = new_inode(dir->i_dev);
371                 if (!inode) {
372                         iput(dir);
373                         return -ENOSPC;
374                 }
    // 否则使用该新 i 节点，对其进行初始设置：置节点的用户 id；对应节点访问模式；置已修改标志。
375                 inode->i_uid = current->euid;
376                 inode->i_mode = mode;
377                 inode->i_dirt = 1;
    // 然后在指定目录 dir 中添加一新目录项。
378                 bh = add_entry(dir,basename,namelen,&de);
    // 如果返回的应该含有新目录项的高速缓冲区指针为 NULL，则表示添加目录项操作失败。于是将该
    // 新 i 节点的引用连接计数减 1；并释放该 i 节点与目录的 i 节点，返回出错码，退出。
379                 if (!bh) {
380                         inode->i_nlinks--;
381                         iput(inode);
382                         iput(dir);
383                         return -ENOSPC;
384                 }
    // 初始设置该新目录项：置 i 节点号为新申请到的 i 节点的号码；并置高速缓冲区已修改标志。然后
    // 释放该高速缓冲区，释放目录的 i 节点。返回新目录项的 i 节点指针，退出。
385                 de->inode = inode->i_num;
386                 bh->b_dirt = 1;
387                 brelse(bh);
388                 iput(dir);
```

```
389                 *res_inode = inode;
390                 return 0;
391         }
    // 若上面在目录中取文件名对应的目录项结构操作成功(也即 bh 不为 NULL)，取出该目录项的 i 节点号
    // 和其所在的设备号，并释放该高速缓冲区以及目录的 i 节点。
392         inr = de->inode;
393         dev = dir->i_dev;
394         brelse(bh);
395         iput(dir);
    // 如果独占使用标志 O_EXCL 置位，则返回文件已存在出错码，退出。
396         if (flag & O_EXCL)
397                 return -EEXIST;
    // 如果取该目录项对应 i 节点的操作失败，则返回访问出错码，退出。
398         if (!(inode=iget(dev,inr)))
399                 return -EACCES;
    // 若该 i 节点是一个目录的节点并且访问模式是只读或只写，或者没有访问的许可权限，则释放该 i
    // 节点，返回访问权限出错码，退出。
400         if ((S_ISDIR(inode->i_mode) && (flag & O_ACCMODE)) ||
401             !permission(inode,ACC_MODE(flag))) {
402                 iput(inode);
403                 return -EPERM;
404         }
    // 更新该 i 节点的访问时间字段为当前时间。
405         inode->i_atime = CURRENT_TIME;
    // 如果设立了截 0 标志，则将该 i 节点的文件长度截为 0。
406         if (flag & O_TRUNC)
407                 truncate(inode);
    // 最后返回该目录项 i 节点的指针，并返回 0（成功）。
408         *res_inode = inode;
409         return 0;
410 }
411
    //// 系统调用函数 - 创建一个特殊文件或普通文件节点(node)。
    // 创建名称为 filename，由 mode 和 dev 指定的文件系统节点(普通文件、设备特殊文件或命名管道)。
    // 参数：filename - 路径名；mode - 指定使用许可以及所创建节点的类型；dev - 设备号。
    // 返回：成功则返回 0，否则返回出错码。
412 int sys_mknod(const char * filename, int mode, int dev)
413 {
414         const char * basename;
415         int namelen;
416         struct m_inode * dir, * inode;
417         struct buffer_head * bh;
418         struct dir_entry * de;
419
    // 如果不是超级用户，则返回访问许可出错码。
420         if (!suser())
421                 return -EPERM;
    // 如果找不到对应路径名目录的 i 节点，则返回出错码。
422         if (!(dir = dir_namei(filename,&namelen,&basename)))
423                 return -ENOENT;
    // 如果最顶端的文件名长度为 0，则说明给出的路径名最后没有指定文件名，释放该目录 i 节点，返回
    // 出错码，退出。
424         if (!namelen) {
```

```
425                 iput(dir);
426                 return -ENOENT;
427         }
    // 如果在该目录中没有写的权限，则释放该目录的 i 节点，返回访问许可出错码，退出。
428         if (!permission(dir,MAY_WRITE)) {
429                 iput(dir);
430                 return -EPERM;
431         }
    // 如果对应路径名上最后的文件名的目录项已经存在，则释放包含该目录项的高速缓冲区，释放目录
    // 的 i 节点，返回文件已经存在出错码，退出。
432         bh = find_entry(&dir,basename,namelen,&de);
433         if (bh) {
434                 brelse(bh);
435                 iput(dir);
436                 return -EEXIST;
437         }
    // 申请一个新的 i 节点，如果不成功，则释放目录的 i 节点，返回无空间出错码，退出。
438         inode = new_inode(dir->i_dev);
439         if (!inode) {
440                 iput(dir);
441                 return -ENOSPC;
442         }
    // 设置该 i 节点的属性模式。如果要创建的是块设备文件或者是字符设备文件，则令 i 节点的直接块
    // 指针 0 等于设备号。
443         inode->i_mode = mode;
444         if (S_ISBLK(mode) || S_ISCHR(mode))
445                 inode->i_zone[0] = dev;
    // 设置该 i 节点的修改时间、访问时间为当前时间。
446         inode->i_mtime = inode->i_atime = CURRENT_TIME;
447         inode->i_dirt = 1;
    // 在目录中新添加一个目录项，如果失败(包含该目录项的高速缓冲区指针为 NULL)，则释放目录的
    // i 节点；所申请的 i 节点引用连接计数复位，并释放该 i 节点。返回出错码，退出。
448         bh = add_entry(dir,basename,namelen,&de);
449         if (!bh) {
450                 iput(dir);
451                 inode->i_nlinks=0;
452                 iput(inode);
453                 return -ENOSPC;
454         }
    // 令该目录项的 i 节点字段等于新 i 节点号，置高速缓冲区已修改标志，释放目录和新的 i 节点，释放
    // 高速缓冲区，最后返回 0(成功)。
455         de->inode = inode->i_num;
456         bh->b_dirt = 1;
457         iput(dir);
458         iput(inode);
459         brelse(bh);
460         return 0;
461 }
462
    //// 系统调用函数 - 创建目录。
    // 参数：pathname - 路径名；mode - 目录使用的权限属性。
    // 返回：成功则返回 0，否则返回出错码。
463 int sys_mkdir(const char * pathname, int mode)
```

```
464 {
465         const char * basename;
466         int namelen;
467         struct m_inode * dir, * inode;
468         struct buffer_head * bh, *dir_block;
469         struct dir_entry * de;
470
    // 如果不是超级用户，则返回访问许可出错码。
471         if (!suser())
472                 return -EPERM;
    // 如果找不到对应路径名目录的 i 节点，则返回出错码。
473         if (!(dir = dir_namei(pathname,&namelen,&basename)))
474                 return -ENOENT;
    // 如果最顶端的文件名长度为 0，则说明给出的路径名最后没有指定文件名，释放该目录 i 节点，返回
    // 出错码，退出。
475         if (!namelen) {
476                 iput(dir);
477                 return -ENOENT;
478         }
    // 如果在该目录中没有写的权限，则释放该目录的 i 节点，返回访问许可出错码，退出。
479         if (!permission(dir,MAY_WRITE)) {
480                 iput(dir);
481                 return -EPERM;
482         }
    // 如果对应路径名上最后的文件名的目录项已经存在，则释放包含该目录项的高速缓冲区，释放目录
    // 的 i 节点，返回文件已经存在出错码，退出。
483         bh = find_entry(&dir,basename,namelen,&de);
484         if (bh) {
485                 brelse(bh);
486                 iput(dir);
487                 return -EEXIST;
488         }
    // 申请一个新的 i 节点，如果不成功，则释放目录的 i 节点，返回无空间出错码，退出。
489         inode = new_inode(dir->i_dev);
490         if (!inode) {
491                 iput(dir);
492                 return -ENOSPC;
493         }
    // 置该新 i 节点对应的文件长度为 32(一个目录项的大小)，置节点已修改标志，以及节点的修改时间
    // 和访问时间。
494         inode->i_size = 32;
495         inode->i_dirt = 1;
496         inode->i_mtime = inode->i_atime = CURRENT_TIME;
    // 为该 i 节点申请一磁盘块，并令节点第一个直接块指针等于该块号。如果申请失败，则释放对应目录
    // 的 i 节点；复位新申请的 i 节点连接计数；释放该新的 i 节点，返回没有空间出错码，退出。
497         if (!(inode->i_zone[0]=new_block(inode->i_dev))) {
498                 iput(dir);
499                 inode->i_nlinks--;
500                 iput(inode);
501                 return -ENOSPC;
502         }
    // 置该新的 i 节点已修改标志。
503         inode->i_dirt = 1;
```

```
    // 读新申请的磁盘块。若出错，则释放对应目录的 i 节点；释放申请的磁盘块；复位新申请的 i 节点
    // 连接计数；释放该新的 i 节点，返回没有空间出错码，退出。
504         if (!(dir_block=bread(inode->i_dev,inode->i_zone[0]))) {
505                 iput(dir);
506                 free_block(inode->i_dev,inode->i_zone[0]);
507                 inode->i_nlinks--;
508                 iput(inode);
509                 return -ERROR;
510         }
    // 令 de 指向目录项数据块，置该目录项的 i 节点号字段等于新申请的 i 节点号，名字字段等于"."。
511         de = (struct dir_entry *) dir_block->b_data;
512         de->inode=inode->i_num;
513         strcpy(de->name,".");
    // 然后 de 指向下一个目录项结构，该结构用于存放上级目录的节点号和名字".."。
514         de++;
515         de->inode = dir->i_num;
516         strcpy(de->name,"..");
517         inode->i_nlinks = 2;
    // 然后设置该高速缓冲区已修改标志，并释放该缓冲区。
518         dir_block->b_dirt = 1;
519         brelse(dir_block);
    // 初始化设置新 i 节点的模式字段，并置该 i 节点已修改标志。
520         inode->i_mode = I_DIRECTORY | (mode & 0777 & ~current->umask);
521         inode->i_dirt = 1;
    // 在目录中新添加一个目录项，如果失败(包含该目录项的高速缓冲区指针为 NULL)，则释放目录的
    // i 节点；所申请的 i 节点引用连接计数复位，并释放该 i 节点。返回出错码，退出。
522         bh = add_entry(dir,basename,namelen,&de);
523         if (!bh) {
524                 iput(dir);
525                 free_block(inode->i_dev,inode->i_zone[0]);
526                 inode->i_nlinks=0;
527                 iput(inode);
528                 return -ENOSPC;
529         }
    // 令该目录项的 i 节点字段等于新 i 节点号，置高速缓冲区已修改标志，释放目录和新的 i 节点，释放
    // 高速缓冲区，最后返回 0(成功)。
530         de->inode = inode->i_num;
531         bh->b_dirt = 1;
532         dir->i_nlinks++;
533         dir->i_dirt = 1;
534         iput(dir);
535         iput(inode);
536         brelse(bh);
537         return 0;
538 }
539
540 /*
541  * routine to check that the specified directory is empty (for rmdir)
542  */
    /*
     * 用于检查指定的目录是否为空的子程序(用于 rmdir 系统调用函数)。
     */
    //// 检查指定目录是否是空的。
```

```
    // 参数：inode - 指定目录的 i 节点指针。
    // 返回：1 - 是空的；0 - 不空。
543 static int empty_dir(struct m_inode * inode)
544 {
545         int nr,block;
546         int len;
547         struct buffer_head * bh;
548         struct dir_entry * de;
549
    // 计算指定目录中现有目录项的个数(应该起码有 2 个，即"."和".."两个文件目录项)。
550         len = inode->i_size / sizeof (struct dir_entry);
    // 如果目录项个数少于 2 个或者该目录 i 节点的第 1 个直接块没有指向任何磁盘块号，或者相应磁盘
    // 块读不出，则显示警告信息“设备 dev 上目录错”，返回 0(失败)。
551         if (len<2 || !inode->i_zone[0] ||
552             !(bh=bread(inode->i_dev,inode->i_zone[0]))) {
553                 printk("warning - bad directory on dev %04x\n",inode->i_dev);
554                 return 0;
555         }
    // 让 de 指向含有读出磁盘块数据的高速缓冲区中第 1 项目录项。
556         de = (struct dir_entry *) bh->b_data;
    // 如果第 1 个目录项的 i 节点号字段值不等于该目录的 i 节点号，或者第 2 个目录项的 i 节点号字段
    // 为零，或者两个目录项的名字字段不分别等于"."和".."，则显示出错警告信息“设备 dev 上目录错”
    // 并返回 0。
557         if (de[0].inode != inode->i_num || !de[1].inode ||
558             strcmp(".",de[0].name) || strcmp("..",de[1].name)) {
559                 printk("warning - bad directory on dev %04x\n",inode->i_dev);
560                 return 0;
561         }
    // 令 nr 等于目录项序号；de 指向第三个目录项。
562         nr = 2;
563         de += 2;
    // 循环检测该目录中所有的目录项(len-2 个)，看有没有目录项的 i 节点号字段不为 0(被使用)。
564         while (nr<len) {
    // 如果该块磁盘块中的目录项已经检测完，则释放该磁盘块的高速缓冲区，读取下一块含有目录项的
    // 磁盘块。若相应块没有使用(或已经不用，如文件已经删除等)，则继续读下一块，若读不出，则出
    // 错，返回 0。否则让 de 指向读出块的首个目录项。
565                 if ((void *) de >= (void *) (bh->b_data+BLOCK_SIZE)) {
566                         brelse(bh);
567                         block=bmap(inode,nr/DIR_ENTRIES_PER_BLOCK);
568                         if (!block) {
569                                 nr += DIR_ENTRIES_PER_BLOCK;
570                                 continue;
571                         }
572                         if (!(bh=bread(inode->i_dev,block)))
573                                 return 0;
574                         de = (struct dir_entry *) bh->b_data;
575                 }
    // 如果该目录项的 i 节点号字段不等于 0，则表示该目录项目前正被使用，则释放该高速缓冲区，
    // 返回 0，退出。
576                 if (de->inode) {
577                         brelse(bh);
578                         return 0;
579                 }
```

```
    // 否则，若还没有查询完该目录中的所有目录项，则继续检测。
580                 de++;
581                 nr++;
582         }
    // 到这里说明该目录中没有找到已用的目录项(当然除了头两个以外)，则释放缓冲区，返回 1。
583         brelse(bh);
584         return 1;
585 }
586
    //// 系统调用函数 - 删除指定名称的目录。
    // 参数： name - 目录名(路径名)。
    // 返回：返回 0 表示成功，否则返回出错号。
587 int sys_rmdir(const char * name)
588 {
589         const char * basename;
590         int namelen;
591         struct m_inode * dir, * inode;
592         struct buffer_head * bh;
593         struct dir_entry * de;
594
    // 如果不是超级用户，则返回访问许可出错码。
595         if (!suser())
596                 return -EPERM;
    // 如果找不到对应路径名目录的 i 节点，则返回出错码。
597         if (!(dir = dir_namei(name,&namelen,&basename)))
598                 return -ENOENT;
    // 如果最顶端的文件名长度为 0，则说明给出的路径名最后没有指定文件名，释放该目录 i 节点，返回
    // 出错码，退出。
599         if (!namelen) {
600                 iput(dir);
601                 return -ENOENT;
602         }
    // 如果在该目录中没有写的权限，则释放该目录的 i 节点，返回访问许可出错码，退出。
603         if (!permission(dir,MAY_WRITE)) {
604                 iput(dir);
605                 return -EPERM;
606         }
    // 如果对应路径名上最后的文件名的目录项不存在，则释放包含该目录项的高速缓冲区，释放目录
    // 的 i 节点，返回文件已经存在出错码，退出。否则 dir 是包含要被删除目录名的目录 i 节点，de
    // 是要被删除目录的目录项结构。
607         bh = find_entry(&dir,basename,namelen,&de);
608         if (!bh) {
609                 iput(dir);
610                 return -ENOENT;
611         }
    // 取该目录项指明的 i 节点。若出错则释放目录的 i 节点，并释放含有目录项的高速缓冲区，返回
    // 出错号。
612         if (!(inode = iget(dir->i_dev, de->inode))) {
613                 iput(dir);
614                 brelse(bh);
615                 return -EPERM;
616         }
    // 若该目录设置了受限删除标志并且进程的有效用户 id 不等于该 i 节点的用户 id，则表示没有权限删
```

```
    // 除该目录，于是释放包含要删除目录名的目录 i 节点和该要删除目录的 i 节点，释放高速缓冲区，返
    // 回出错码。
617         if ((dir->i_mode & S_ISVTX) && current->euid &&
618             inode->i_uid != current->euid) {
619                 iput(dir);
620                 iput(inode);
621                 brelse(bh);
622                 return -EPERM;
623         }
    // 如果要被删除的目录项的 i 节点的设备号不等于包含该目录项的目录的设备号，或者该被删除目录的
    // 引用连接计数大于 1(表示有符号连接等)，则不能删除该目录，于是释放包含要删除目录名的目录
    // i 节点和该要删除目录的 i 节点，释放高速缓冲区，返回出错码。
624         if (inode->i_dev != dir->i_dev || inode->i_count>1) {
625                 iput(dir);
626                 iput(inode);
627                 brelse(bh);
628                 return -EPERM;
629         }
    // 如果要被删除目录的目录项 i 节点的节点号等于包含该需删除目录的 i 节点号，则表示试图删除"."
    // 目录。于是释放包含要删除目录名的目录 i 节点和该要删除目录的 i 节点，释放高速缓冲区，返回
    // 出错码。
630         if (inode == dir) {     /* we may not delete ".", but "../dir" is ok */
631                 iput(inode);    /* 我们不可以删除"."，但可以删除"../dir" */
632                 iput(dir);
633                 brelse(bh);
634                 return -EPERM;
635         }
    // 若要被删除的目录的 i 节点的属性表明这不是一个目录，则释放包含要删除目录名的目录 i 节点和
    // 该要删除目录的 i 节点，释放高速缓冲区，返回出错码。
636         if (!S_ISDIR(inode->i_mode)) {
637                 iput(inode);
638                 iput(dir);
639                 brelse(bh);
640                 return -ENOTDIR;
641         }
    // 若该需被删除的目录不空，则释放包含要删除目录名的目录 i 节点和该要删除目录的 i 节点，释放
    // 高速缓冲区，返回出错码。
642         if (!empty_dir(inode)) {
643                 iput(inode);
644                 iput(dir);
645                 brelse(bh);
646                 return -ENOTEMPTY;
647         }
    // 若该需被删除目录的 i 节点的连接数不等于 2，则显示警告信息。
648         if (inode->i_nlinks != 2)
649                 printk("empty directory has nlink!=2 (%d)",inode->i_nlinks);
    // 置该需被删除目录的目录项的 i 节点号字段为 0，表示该目录项不再使用，并置含有该目录项的高速
    // 缓冲区已修改标志，并释放该缓冲区。
650         de->inode = 0;
651         bh->b_dirt = 1;
652         brelse(bh);
    // 置被删除目录的 i 节点的连接数为 0，并置 i 节点已修改标志。
653         inode->i_nlinks=0;
```

```
654         inode->i_dirt=1;
    // 将包含被删除目录名的目录的 i 节点引用计数减 1，修改其改变时间和修改时间为当前时间，并置
    // 该节点已修改标志。
655         dir->i_nlinks--;
656         dir->i_ctime = dir->i_mtime = CURRENT_TIME;
657         dir->i_dirt=1;
    // 最后释放包含要删除目录名的目录 i 节点和该要删除目录的 i 节点，返回 0(成功)。
658         iput(dir);
659         iput(inode);
660         return 0;
661 }
662
    //// 系统调用函数 - 删除文件名以及可能也删除其相关的文件。
    // 从文件系统删除一个名字。如果是一个文件的最后一个连接，并且没有进程正打开该文件，则该文件
    // 也将被删除，并释放所占用的设备空间。
    // 参数：name - 文件名。
    // 返回：成功则返回 0，否则返回出错号。
663 int sys_unlink(const char * name)
664 {
665         const char * basename;
666         int namelen;
667         struct m_inode * dir, * inode;
668         struct buffer_head * bh;
669         struct dir_entry * de;
670
    // 如果找不到对应路径名目录的 i 节点，则返回出错码。
671         if (!(dir = dir_namei(name,&namelen,&basename)))
672                 return -ENOENT;
    // 如果最顶端的文件名长度为 0，则说明给出的路径名最后没有指定文件名，释放该目录 i 节点，返回
    // 出错码，退出。
673         if (!namelen) {
674                 iput(dir);
675                 return -ENOENT;
676         }
    // 如果在该目录中没有写的权限，则释放该目录的 i 节点，返回访问许可出错码，退出。
677         if (!permission(dir,MAY_WRITE)) {
678                 iput(dir);
679                 return -EPERM;
680         }
    // 如果对应路径名上最后的文件名的目录项不存在，则释放包含该目录项的高速缓冲区，释放目录
    // 的 i 节点，返回文件已经存在出错码，退出。否则 dir 是包含要被删除目录名的目录 i 节点，de
    // 是要被删除目录的目录项结构。
681         bh = find_entry(&dir,basename,namelen,&de);
682         if (!bh) {
683                 iput(dir);
684                 return -ENOENT;
685         }
    // 取该目录项指明的 i 节点。若出错则释放目录的 i 节点，并释放含有目录项的高速缓冲区，返回
    // 出错号。
686         if (!(inode = iget(dir->i_dev, de->inode))) {
687                 iput(dir);
688                 brelse(bh);
689                 return -ENOENT;
```

```
690         }
    // 如果该目录设置了受限删除标志并且用户不是超级用户，并且进程的有效用户 id 不等于被删除文件
    // 名 i 节点的用户 id，并且进程的有效用户 id 也不等于目录 i 节点的用户 id，则没有权限删除该文件
    // 名。则释放该目录 i 节点和该文件名目录项的 i 节点，释放包含该目录项的缓冲区，返回出错号。
691         if ((dir->i_mode & S_ISVTX) && !suser() &&
692             current->euid != inode->i_uid &&
693             current->euid != dir->i_uid) {
694                 iput(dir);
695                 iput(inode);
696                 brelse(bh);
697                 return -EPERM;
698         }
    // 如果该指定文件名是一个目录，则也不能删除，释放该目录 i 节点和该文件名目录项的 i 节点，释放
    // 包含该目录项的缓冲区，返回出错号。
699         if (S_ISDIR(inode->i_mode)) {
700                 iput(inode);
701                 iput(dir);
702                 brelse(bh);
703                 return -EPERM;
704         }
    // 如果该 i 节点的连接数已经为 0，则显示警告信息，修正其为 1。
705         if (!inode->i_nlinks) {
706                 printk("Deleting nonexistent file (%04x:%d), %d\n",
707                         inode->i_dev,inode->i_num,inode->i_nlinks);
708                 inode->i_nlinks=1;
709         }
    // 将该文件名的目录项中的 i 节点号字段置为 0，表示释放该目录项，并设置包含该目录项的缓冲区
    // 已修改标志，释放该高速缓冲区。
710         de->inode = 0;
711         bh->b_dirt = 1;
712         brelse(bh);
    // 该 i 节点的连接数减 1，置已修改标志，更新改变时间为当前时间。最后释放该 i 节点和目录的 i 节
    // 点，返回 0(成功)。
713         inode->i_nlinks--;
714         inode->i_dirt = 1;
715         inode->i_ctime = CURRENT_TIME;
716         iput(inode);
717         iput(dir);
718         return 0;
719 }
720
    //// 系统调用函数 - 为文件建立一个文件名。
    // 为一个已经存在的文件创建一个新连接(也称为硬连接 - hard link)。
    // 参数：oldname - 原路径名；newname - 新的路径名。
    // 返回：若成功则返回 0，否则返回出错号。
721 int sys_link(const char * oldname, const char * newname)
722 {
723         struct dir_entry * de;
724         struct m_inode * oldinode, * dir;
725         struct buffer_head * bh;
726         const char * basename;
727         int namelen;
728
```

```
    // 取原文件路径名对应的 i 节点 oldinode。如果为 0，则表示出错，返回出错号。
729         oldinode=namei(oldname);
730         if (!oldinode)
731                 return -ENOENT;
    // 如果原路径名对应的是一个目录名，则释放该 i 节点，返回出错号。
732         if (S_ISDIR(oldinode->i_mode)) {
733                 iput(oldinode);
734                 return -EPERM;
735         }
    // 查找新路径名的最顶层目录的 i 节点，并返回最后的文件名及其长度。如果目录的 i 节点没有找到，
    // 则释放原路径名的 i 节点，返回出错号。
736         dir = dir_namei(newname,&namelen,&basename);
737         if (!dir) {
738                 iput(oldinode);
739                 return -EACCES;
740         }
    // 如果新路径名中不包括文件名，则释放原路径名 i 节点和新路径名目录的 i 节点，返回出错号。
741         if (!namelen) {
742                 iput(oldinode);
743                 iput(dir);
744                 return -EPERM;
745         }
    // 如果新路径名目录的设备号与原路径名的设备号不一样，则也不能建立连接，于是释放新路径名
    // 目录的 i 节点和原路径名的 i 节点，返回出错号。
746         if (dir->i_dev != oldinode->i_dev) {
747                 iput(dir);
748                 iput(oldinode);
749                 return -EXDEV;
750         }
    // 如果用户没有在新目录中写的权限，则也不能建立连接，于是释放新路径名目录的 i 节点和原路径名
    // 的 i 节点，返回出错号。
751         if (!permission(dir,MAY_WRITE)) {
752                 iput(dir);
753                 iput(oldinode);
754                 return -EACCES;
755         }
    // 查询该新路径名是否已经存在，如果存在，则也不能建立连接，于是释放包含该已存在目录项的高速
    // 缓冲区，释放新路径名目录的 i 节点和原路径名的 i 节点，返回出错号。
756         bh = find_entry(&dir,basename,namelen,&de);
757         if (bh) {
758                 brelse(bh);
759                 iput(dir);
760                 iput(oldinode);
761                 return -EEXIST;
762         }
    // 在新目录中添加一个目录项。若失败则释放该目录的 i 节点和原路径名的 i 节点，返回出错号。
763         bh = add_entry(dir,basename,namelen,&de);
764         if (!bh) {
765                 iput(dir);
766                 iput(oldinode);
767                 return -ENOSPC;
768         }
    // 否则初始设置该目录项的 i 节点号等于原路径名的 i 节点号，并置包含该新添目录项的高速缓冲区
```

```
    // 已修改标志，释放该缓冲区，释放目录的 i 节点。
769         de->inode = oldinode->i_num;
770         bh->b_dirt = 1;
771         brelse(bh);
772         iput(dir);
    // 将原节点的应用计数加 1，修改其改变时间为当前时间，并设置 i 节点已修改标志，最后释放原
    // 路径名的 i 节点，并返回 0(成功)。
773         oldinode->i_nlinks++;
774         oldinode->i_ctime = CURRENT_TIME;
775         oldinode->i_dirt = 1;
776         iput(oldinode);
777         return 0;
778 }
779
```

9.9 file_table.c 程序

9.9.1 功能描述

该程序目前是空的，仅定义了文件表数组。

9.9.2 代码注释

程序 9-7 linux/fs/file_table.c

```
 1 /*
 2  *  linux/fs/file_table.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <linux/fs.h>     // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
 8
 9 struct file file_table[NR_FILE];  // 文件表数组(64 项)。
10
```

9.10 block_dev.c 程序

从这里开始的 4 个程序：block_dev.c、char_dev.c、pipe.c 和 file_dev.c 都是为随后的程序 read_write.c 服务的。read_write.c 程序主要实现了系统调用 write()和 read()。这 4 个程序可以看作是系统调用与块设备、字符设备、管道“设备”和文件系统“设备”的接口驱动程序。它们之间的关系可以用图 9-19 表示。系统调用 write()或 read()会根据参数所提供文件描述符的属性，判断出是哪种类型的文件，然后分别调用相应设备接口程序中的读/写函数，而这些函数随后会执行相应的驱动程序。

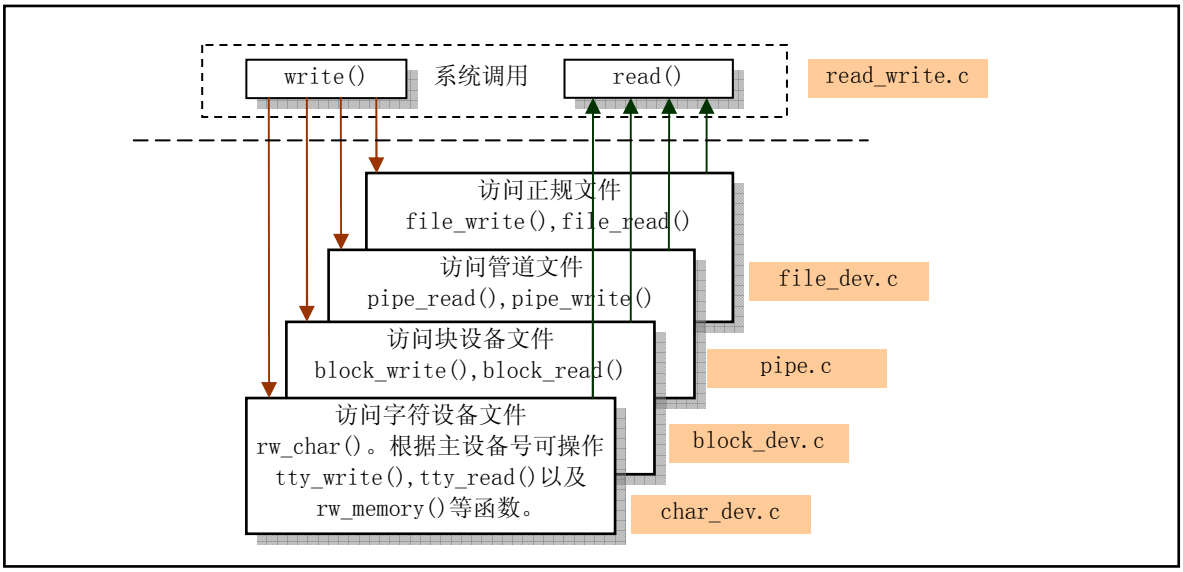

图 9-19 各种类型文件与文件系统和系统调用的接口函数

9.10.1 功能描述

block_dev.c 程序属于块设备文件数据访问操作类程序。该文件包括 block_read()和 block_write()两个块设备读写函数。这两个函数是供系统调用函数 read()和 write()调用的，其他地方没有引用。

由于块设备每次对磁盘读写是以盘块为单位的(与缓冲区中缓冲块长度相同)，因此函数 block_write()首先把参数中文件指针 pos 位置映射成数据块号和块中偏移量值，然后使用块读取函数 bread()或块预读函数 breada()将文件指针位置所在的数据块读入缓冲区的一个缓冲块中，然后根据本块中需要写的数据长度 chars，从用户数据缓冲中将数据复制到当前缓冲块的偏移位置开始处。如果还有需要写的数据，则再将下一块读入缓冲区的缓冲块中，并将用户数据复制到该缓冲块中，在第二次及以后写数据时，偏移量 offset 均为 0。参见图 9-20 所示。

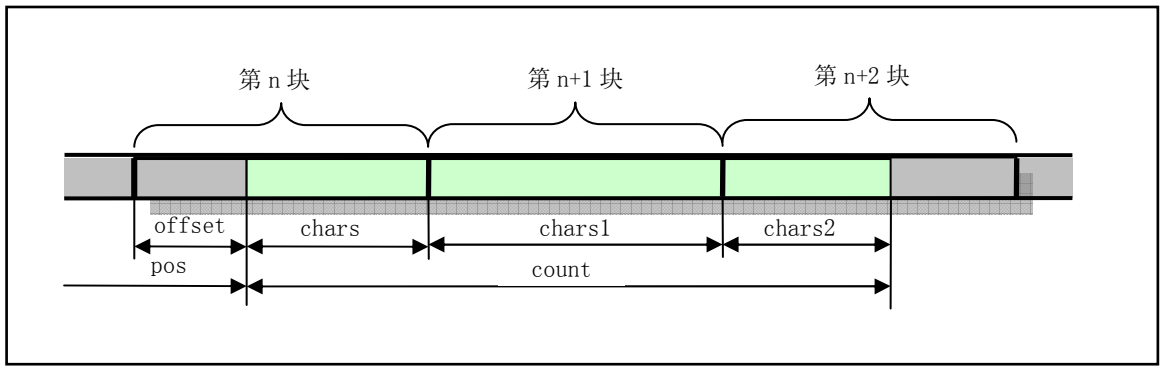

图 9-20 块数据读写操作指针位置示意图

用户的缓冲区是用户程序在开始执行时由系统分配的，或者是在执行过程中动态申请的。用户缓冲区使用的虚拟线性地址，在调用本函数之前，系统会将虚拟线性地址映射到主内存区中相应的内存页中。

函数 block_read()的操作方式与 block_write()相同，只是把数据从缓冲区复制到用户指定的地方。

9.10.2 代码注释

程序 9-8 linux/fs/block_dev.c

```
 1 /*
 2  *  linux/fs/block_dev.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
 8
 9 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
10 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
11 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
12 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
13
   //// 数据块写函数 - 向指定设备从给定偏移处写入指定长度字节数据。
   // 参数：dev - 设备号；pos - 设备文件中偏移量指针；buf - 用户地址空间中缓冲区地址；
   //       count - 要传送的字节数。
   // 对于内核来说，写操作是向高速缓冲区中写入数据，什么时候数据最终写入设备是由高速缓冲管理
   // 程序决定并处理的。另外，因为设备是以块为单位进行读写的，因此对于写开始位置不处于块起始
   // 处时，需要先将开始字节所在的整个块读出，然后将需要写的数据从写开始处填写满该块，再将完
   // 整的一块数据写盘（即交由高速缓冲程序去处理）。
14 int block_write(int dev, long * pos, char * buf, int count)
15 {
   // 由 pos 地址换算成开始读写块的块序号 block。并求出需读第 1 字节在该块中的偏移位置 offset。
16         int block = *pos >> BLOCK_SIZE_BITS;
17         int offset = *pos & (BLOCK_SIZE-1);
18         int chars;
19         int written = 0;
20         struct buffer_head * bh;
21         register char * p;
22
   // 针对要写入的字节数 count，循环执行以下操作，直到全部写入。
23         while (count>0) {
   // 计算在该块中可写入的字节数。如果需要写入的字节数填不满一块，则只需写 count 字节。
24                 chars = BLOCK_SIZE - offset;
25                 if (chars > count)
26                         chars=count;
   // 如果正好要写 1 块数据，则直接申请 1 块高速缓冲块，否则需要读入将被修改的数据块，并预读
   // 下两块数据，然后将块号递增 1。
27                 if (chars == BLOCK_SIZE)
28                         bh = getblk(dev,block);
29                 else
30                         bh = breada(dev,block,block+1,block+2,-1);
31                 block++;
   // 如果缓冲块操作失败，则返回已写字节数，如果没有写入任何字节，则返回出错号（负数）。
32                 if (!bh)
33                         return written?written:-EIO;
   // p 指向读出数据块中开始写的位置。若最后写入的数据不足一块，则需从块开始填写（修改）所需
   // 的字节，因此这里需置 offset 为零。
```

```
34                  p = offset + bh->b_data;
35                  offset = 0;
    // 将文件中偏移指针前移已写字节数。累加已写字节数 chars。传送计数值减去此次已传送字节数。
36                  *pos += chars;
37                  written += chars;
38                  count -= chars;
    // 从用户缓冲区复制 chars 字节到 p 指向的高速缓冲区中开始写入的位置。
39                  while (chars--->0)
40                          *(p++) = get_fs_byte(buf++);
    // 置该缓冲区块已修改标志，并释放该缓冲区（也即该缓冲区引用计数递减 1）。
41                  bh->b_dirt = 1;
42                  brelse(bh);
43          }
44          return written;                         // 返回已写入的字节数，正常退出。
45  }
46
    //// 数据块读函数 - 从指定设备和位置读入指定字节数的数据到高速缓冲中。
47  int block_read(int dev, unsigned long * pos, char * buf, int count)
48  {
    // 由 pos 地址换算成开始读写块的块序号 block。并求出需读第 1 字节在该块中的偏移位置 offset。
49          int block = *pos >> BLOCK_SIZE_BITS;
50          int offset = *pos & (BLOCK_SIZE-1);
51          int chars;
52          int read = 0;
53          struct buffer_head * bh;
54          register char * p;
55
    // 针对要读入的字节数 count，循环执行以下操作，直到全部读入。
56          while (count>0) {
    // 计算在该块中需读入的字节数。如果需要读入的字节数不满一块，则只需读 count 字节。
57                  chars = BLOCK_SIZE-offset;
58                  if (chars > count)
59                          chars = count;
    // 读入需要的数据块，并预读下两块数据，如果读操作出错，则返回已读字节数，如果没有读入任何
    // 字节，则返回出错号。然后将块号递增 1。
60                  if (!(bh = breada(dev,block,block+1,block+2,-1)))
61                          return read?read:-EIO;
62                  block++;
    // p 指向从设备读出数据块中需要读取的开始位置。若最后需要读取的数据不足一块，则需从块开始
    // 读取所需的字节，因此这里需将 offset 置零。
63                  p = offset + bh->b_data;
64                  offset = 0;
    // 将文件中偏移指针前移已读出字节数 chars。累加已读字节数。传送计数值减去此次已传送字节数。
65                  *pos += chars;
66                  read += chars;
67                  count -= chars;
    // 从高速缓冲区中 p 指向的开始位置复制 chars 字节数据到用户缓冲区，并释放该高速缓冲区。
68                  while (chars--->0)
69                          put_fs_byte(*(p++),buf++);
70                  brelse(bh);
71          }
72          return read;                        // 返回已读取的字节数，正常退出。
73  }
```

74

9.11 file_dev.c 程序

9.11.1 功能描述

该文件包括 file_read()和 file_write()两个函数。也是供系统调用函数 read()和 write()调用的，其他地方没有引用。与上一个文件 block_dev.c 类似，该文件也是用于访问文件数据。但是本程序中的函数是通过指定文件路径名方式进行操作。函数参数中给出的是文件 i 节点和文件结构信息，通过 i 节点中的信息来获取相应的设备号，由 file 结构，我们可以获得文件当前的读写指针位置。而上一个文件中的函数则是直接在参数中指定了设备号和文件中的读写位置，是专门用于对块设备文件进行操作的，例如/dev/fd0 设备文件。

9.11.2 代码注释

程序 9-9 linux/fs/file_dev.c

```
1  /*
2   *  linux/fs/file_dev.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)
8  #include <fcntl.h>        // 文件控制头文件。用于文件及其描述符的操作控制常数符号的定义。
9
10 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
13
14 #define MIN(a,b) (((a)<(b))?(a):(b))          // 取 a,b 中的最小值。
15 #define MAX(a,b) (((a)>(b))?(a):(b))          // 取 a,b 中的最大值。
16
   //// 文件读函数 - 根据 i 节点和文件结构，读设备数据。
   // 由 i 节点可以知道设备号，由 filp 结构可以知道文件中当前读写指针位置。buf 指定用户态中
   // 缓冲区的位置，count 为需要读取的字节数。返回值是实际读取的字节数，或出错号(小于 0)。
17 int file_read(struct m_inode * inode, struct file * filp, char * buf, int count)
18 {
19         int left,chars,nr;
20         struct buffer_head * bh;
21
   // 若需要读取的字节计数值小于等于零，则返回。
22         if ((left=count)<=0)
23                 return 0;
   // 若还需要读取的字节数不等于 0，就循环执行以下操作，直到全部读出。
24         while (left) {
   // 根据 i 节点和文件表结构信息，取数据块文件当前读写位置在设备上对应的逻辑块号 nr。若 nr 不
   // 为 0，则从 i 节点指定的设备上读取该逻辑块，如果读操作失败则退出循环。若 nr 为 0，表示指定
```

```
// 的数据块不存在，置缓冲块指针为 NULL。
25                  if (nr = bmap(inode,(filp->f_pos)/BLOCK_SIZE)) {
26                          if (!(bh=bread(inode->i_dev,nr)))
27                                  break;
28                  } else
29                          bh = NULL;
// 计算文件读写指针在数据块中的偏移值 nr，则该块中可读字节数为(BLOCK_SIZE-nr)，然后与还需
// 读取的字节数 left 作比较，其中小值即为本次需读的字节数 chars。若(BLOCK_SIZE-nr)大则说明
// 该块是需要读取的最后一块数据，反之则还需要读取一块数据。
30                  nr = filp->f_pos % BLOCK_SIZE;
31                  chars = MIN( BLOCK_SIZE-nr , left );
// 调整读写文件指针。指针前移此次将读取的字节数 chars。剩余字节计数相应减去 chars。
32                  filp->f_pos += chars;
33                  left -= chars;
// 若从设备上读到了数据，则将 p 指向读出数据块缓冲区中开始读取的位置，并且复制 chars 字节
// 到用户缓冲区 buf 中。否则往用户缓冲区中填入 chars 个 0 值字节。
34                  if (bh) {
35                          char * p = nr + bh->b_data;
36                          while (chars-->0)
37                                  put_fs_byte(*(p++),buf++);
38                          brelse(bh);
39                  } else {
40                          while (chars-->0)
41                                  put_fs_byte(0,buf++);
42                  }
43          }
// 修改该 i 节点的访问时间为当前时间。返回读取的字节数，若读取字节数为 0，则返回出错号。
44          inode->i_atime = CURRENT_TIME;
45          return (count-left)?(count-left):-ERROR;
46  }
47
//// 文件写函数 - 根据 i 节点和文件结构信息，将用户数据写入指定设备。
// 由 i 节点可以知道设备号，由 filp 结构可以知道文件中当前读写指针位置。buf 指定用户态中
// 缓冲区的位置，count 为需要写入的字节数。返回值是实际写入的字节数，或出错号(小于 0)。
48  int file_write(struct m_inode * inode, struct file * filp, char * buf, int count)
49  {
50          off_t pos;
51          int block,c;
52          struct buffer_head * bh;
53          char * p;
54          int i=0;
55
56  /*
57   * ok, append may not work when many processes are writing at the same time
58   * but so what. That way leads to madness anyway.
59   */
    /*
     * ok，当许多进程同时写时，append 操作可能不行，但那又怎样。不管怎样那样做会
     * 导致混乱一团。
     */
    // 如果是要向文件后添加数据，则将文件读写指针移到文件尾部。否则就将在文件读写指针处写入。
60          if (filp->f_flags & O_APPEND)
61                  pos = inode->i_size;
```

```
62          else
63                  pos = filp->f_pos;
    // 若已写入字节数 i 小于需要写入的字节数 count，则循环执行以下操作。
64          while (i<count) {
    // 创建数据块号(pos/BLOCK_SIZE)在设备上对应的逻辑块，并返回在设备上的逻辑块号。如果逻辑
    // 块号=0，则表示创建失败，退出循环。
65                  if (!(block = create_block(inode,pos/BLOCK_SIZE)))
66                          break;
    // 根据该逻辑块号读取设备上的相应数据块，若出错则退出循环。
67                  if (!(bh=bread(inode->i_dev,block)))
68                          break;
    // 求出文件读写指针在数据块中的偏移值 c，将 p 指向读出数据块缓冲区中开始读取的位置。置该
    // 缓冲区已修改标志。
69                  c = pos % BLOCK_SIZE;
70                  p = c + bh->b_data;
71                  bh->b_dirt = 1;
    // 从开始读写位置到块末共可写入 c=(BLOCK_SIZE-c)个字节。若 c 大于剩余还需写入的字节数
    // (count-i)，则此次只需再写入 c=(count-i)即可。
72                  c = BLOCK_SIZE-c;
73                  if (c > count-i) c = count-i;
    // 文件读写指针前移此次需写入的字节数。如果当前文件读写指针位置值超过了文件的大小，则
    // 修改 i 节点中文件大小字段，并置 i 节点已修改标志。
74                  pos += c;
75                  if (pos > inode->i_size) {
76                          inode->i_size = pos;
77                          inode->i_dirt = 1;
78                  }
    // 已写入字节计数累加此次写入的字节数 c。从用户缓冲区 buf 中复制 c 个字节到高速缓冲区中 p
    // 指向开始的位置处。然后释放该缓冲区。
79                  i += c;
80                  while (c-->0)
81                          *(p++) = get_fs_byte(buf++);
82                  brelse(bh);
83          }
    // 更改文件修改时间为当前时间。
84          inode->i_mtime = CURRENT_TIME;
    // 如果此次操作不是在文件尾添加数据，则把文件读写指针调整到当前读写位置，并更改 i 节点修改
    // 时间为当前时间。
85          if (!(filp->f_flags & O_APPEND)) {
86                  filp->f_pos = pos;
87                  inode->i_ctime = CURRENT_TIME;
88          }
    // 返回写入的字节数，若写入字节数为 0，则返回出错号-1。
89          return (i?i:-1);
90  }
91
```

9.12 pipe.c 程序

9.12.1 功能描述

管道操作是进程间通信的最基本方式。本程序包括管道文件读写操作函数 read_pipe()和 write_pipe()，同时实现了管道系统调用 sys_pipe()。这两个函数也是系统调用 read()和 write()的低层实现函数，也仅在 read_write.c 中使用。

在初始化管道时，管道 i 节点的 i_size 字段中被设置为指向管道缓冲区的指针，管道数据头部指针存放在 i_zone[0]字段中，而管道数据尾部指针存放在 i_zone[1]字段中。对于读管道操作，数据是从管道尾读出，并使管道尾指针前移读取字节数个位置；对于往管道中的写入操作，数据是向管道头部写入，并使管道头指针前移写入字节数个位置。参见下面的管道示意图 9-21 所示。

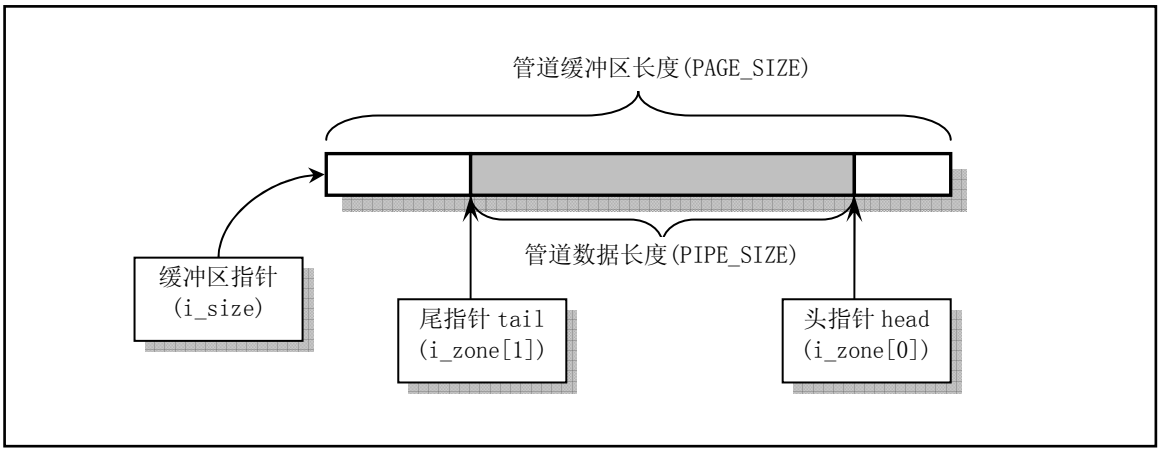

图 9-21 管道缓冲区操作示意图

read_pipe()用于读管道中的数据。若管道中没有数据，就唤醒写管道的进程，而自己则进入睡眠状态。若读到了数据，就相应地调整管道头指针，并把数据传到用户缓冲区中。当把管道中所有的数据都取走后，也要唤醒等待写管道的进程，并返回已读数据字节数。当管道写进程已退出管道操作时，函数就立刻退出，并返回已读的字节数。

write_pipe()函数的操作与读管道函数类似。

系统调用 sys_pipe()用于创建无名管道。它首先在系统的文件表中取得两个表项，然后在当前进程的文件描述符表中也同样寻找两个未使用的描述符表项，用来保存相应的文件结构指针。接着在系统中申请一个空闲 i 节点，同时获得管道使用的一个缓冲块。然后对相应的文件结构进行初始化，将一个文件结构设置为只读模式，另一个设置为只写模式。最后将两个文件描述符传给用户。

9.12.2 代码注释

程序 9-10 linux/fs/pipe.c

```
1 /*
2  *  linux/fs/pipe.c
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
7 #include <signal.h>        // 信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
```

```
 8
 9 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
10 #include <linux/mm.h>   /* for get_free_page */  /* 使用其中的 get_free_page */
                             // 内存管理头文件。含有页面大小定义和一些页面释放函数原型。
11 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
12
   //// 管道读操作函数。
   // 参数 inode 是管道对应的 i 节点，buf 是数据缓冲区指针，count 是读取的字节数。
13 int read_pipe(struct m_inode * inode, char * buf, int count)
14 {
15         int chars, size, read = 0;
16
   // 若欲读取的字节计数值 count 大于 0，则循环执行以下操作。
17         while (count>0) {
   // 若当前管道中没有数据(size=0)，则唤醒等待该节点的进程，如果已没有写管道者，则返回已读
   // 字节数，退出。否则在该 i 节点上睡眠，等待信息。
18                 while (!(size=PIPE_SIZE(*inode))) {
19                         wake_up(&inode->i_wait);
20                         if (inode->i_count != 2) /* are there any writers? */
21                                 return read;
22                         sleep_on(&inode->i_wait);
23                 }
   // 取管道尾到缓冲区末端的字节数 chars。如果其大于还需要读取的字节数 count，则令其等于 count。
   // 如果 chars 大于当前管道中含有数据的长度 size，则令其等于 size。
24                 chars = PAGE_SIZE-PIPE_TAIL(*inode);
25                 if (chars > count)
26                         chars = count;
27                 if (chars > size)
28                         chars = size;
   // 读字节计数减去此次可读的字节数 chars，并累加已读字节数。
29                 count -= chars;
30                 read += chars;
   // 令 size 指向管道尾部，调整当前管道尾指针（前移 chars 字节）。
31                 size = PIPE_TAIL(*inode);
32                 PIPE_TAIL(*inode) += chars;
33                 PIPE_TAIL(*inode) &= (PAGE_SIZE-1);
   // 将管道中的数据复制到用户缓冲区中。对于管道 i 节点，其 i_size 字段中是管道缓冲块指针。
34                 while (chars-->0)
35                         put_fs_byte(((char *)inode->i_size)[size++],buf++);
36         }
   // 唤醒等待该管道 i 节点的进程，并返回读取的字节数。
37         wake_up(&inode->i_wait);
38         return read;
39 }
40
   //// 管道写操作函数。
   // 参数 inode 是管道对应的 i 节点，buf 是数据缓冲区指针，count 是将写入管道的字节数。
41 int write_pipe(struct m_inode * inode, char * buf, int count)
42 {
43         int chars, size, written = 0;
44
   // 若将写入的字节计数值 count 还大于 0，则循环执行以下操作。
```

```
45          while (count>0) {
    // 若当前管道中没有已经满了(size=0)，则唤醒等待该节点的进程，如果已没有读管道者，则向进程
    // 发送 SIGPIPE 信号，并返回已写入的字节数并退出。若写入 0 字节，则返回-1。否则在该 i 节点上
    // 睡眠，等待管道腾出空间。
46                  while (!(size=(PAGE_SIZE-1)-PIPE_SIZE(*inode))) {
47                          wake_up(&inode->i_wait);
48                          if (inode->i_count != 2) { /* no readers */
49                                  current->signal |= (1<<(SIGPIPE-1));
50                                  return written?written:-1;
51                          }
52                          sleep_on(&inode->i_wait);
53                  }
    // 取管道头部到缓冲区末端空间字节数 chars。如果其大于还需要写入的字节数 count，则令其等于
    // count。如果 chars 大于当前管道中空闲空间长度 size，则令其等于 size。
54                  chars = PAGE_SIZE-PIPE_HEAD(*inode);
55                  if (chars > count)
56                          chars = count;
57                  if (chars > size)
58                          chars = size;
    // 写入字节计数减去此次可写入的字节数 chars，并累加已写字节数到 written。
59                  count -= chars;
60                  written += chars;
    // 令 size 指向管道数据头部，调整当前管道数据头部指针（前移 chars 字节）。
61                  size = PIPE_HEAD(*inode);
62                  PIPE_HEAD(*inode) += chars;
63                  PIPE_HEAD(*inode) &= (PAGE_SIZE-1);
    // 从用户缓冲区复制 chars 个字节到管道中。对于管道 i 节点，其 i_size 字段中是管道缓冲块指针。
64                  while (chars-->0)
65                          ((char *)inode->i_size)[size++]=get_fs_byte(buf++);
66          }
    // 唤醒等待该 i 节点的进程，返回已写入的字节数，退出。
67          wake_up(&inode->i_wait);
68          return written;
69  }
70
    //// 创建管道系统调用函数。
    // 在 fildes 所指的数组中创建一对文件句柄(描述符)。这对文件句柄指向一管道 i 节点。fildes[0]
    // 用于读管道中数据，fildes[1]用于向管道中写入数据。
    // 成功时返回 0，出错时返回-1。
71  int sys_pipe(unsigned long * fildes)
72  {
73          struct m_inode * inode;
74          struct file * f[2];
75          int fd[2];
76          int i,j;
77
    // 从系统文件表中取两个空闲项（引用计数字段为 0 的项），并分别设置引用计数为 1。
78          j=0;
79          for(i=0;j<2 && i<NR_FILE;i++)
80                  if (!file_table[i].f_count)
81                          (f[j++]=i+file_table)->f_count++;
    // 如果只有一个空闲项，则释放该项(引用计数复位)。
82          if (j==1)
```

```
83                  f[0]->f_count=0;
    // 如果没有找到两个空闲项，则返回-1。
84          if (j<2)
85                  return -1;
    // 针对上面取得的两个文件结构项，分别分配一文件句柄，并使进程的文件结构指针分别指向这两个
    // 文件结构。
86          j=0;
87          for(i=0;j<2 && i<NR_OPEN;i++)
88                  if (!current->filp[i]) {
89                          current->filp[ fd[j]=i ] = f[j];
90                          j++;
91                  }
    // 如果只有一个空闲文件句柄，则释放该句柄。
92          if (j==1)
93                  current->filp[fd[0]]=NULL;
    // 如果没有找到两个空闲句柄，则释放上面获取的两个文件结构项（复位引用计数值），并返回-1。
94          if (j<2) {
95                  f[0]->f_count=f[1]->f_count=0;
96                  return -1;
97          }
    // 申请管道 i 节点，并为管道分配缓冲区（1 页内存）。如果不成功，则相应释放两个文件句柄和文
    // 件结构项，并返回-1。
98          if (!(inode=get_pipe_inode())) {
99                  current->filp[fd[0]] =
100                         current->filp[fd[1]] = NULL;
101                 f[0]->f_count = f[1]->f_count = 0;
102                 return -1;
103         }
    // 初始化两个文件结构，都指向同一个 i 节点，读写指针都置零。第 1 个文件结构的文件模式置为读，
    // 第 2 个文件结构的文件模式置为写。
104         f[0]->f_inode = f[1]->f_inode = inode;
105         f[0]->f_pos = f[1]->f_pos = 0;
106         f[0]->f_mode = 1;               /* read */
107         f[1]->f_mode = 2;               /* write */
    // 将文件句柄数组复制到对应的用户数组中，并返回 0，退出。
108         put_fs_long(fd[0],0+fildes);
109         put_fs_long(fd[1],1+fildes);
110         return 0;
111 }
112
```

9.13 char_dev.c 程序

9.13.1 功能描述

char_dev.c 文件包括字符设备文件访问函数。主要有 rw_ttyx()、rw_tty()、rw_memory()和 rw_char()。另外还有一个设备读写函数指针表。该表的项号代表主设备号。

rw_ttyx()是串口终端设备读写函数，其主设备号是 4。通过调用 tty 的驱动程序实现了对串口终端的读写操作。

rw_tty()是控制台终端读写函数，主设备号是 5。实现原理与 rw_ttyx()相同，只是对进程能否进行控制台操作有所限制。

rw_memory()是内存设备文件读写函数，主设备号是 1。实现了对内存映像的字节操作。但 linux 0.11 版内核对次设备号是 0、1、2 的操作还没有实现。直到 0.96 版才开始实现次设备号 1 和 2 的读写操作。

rw_char()是字符设备读写操作的接口函数。其他字符设备通过该函数对字符设备读写函数指针表进行相应字符设备的操作。文件系统的操作函数 open()、read()等都通过它对所有字符设备文件进行操作。

9.13.2 代码注释

程序 9-11 linux/fs/char_dev.c

```
1  /*
2   *  linux/fs/char_dev.c
3   *
4   *  (C) 1991  Linus Torvalds
5   */
6
7  #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
8  #include <sys/types.h>    // 类型头文件。定义了基本的系统数据类型。
9
10 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12
13 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
14 #include <asm/io.h>       // io 头文件。定义硬件端口输入/输出宏汇编语句。
15
16 extern int tty_read(unsigned minor,char * buf,int count);     // 终端读。
17 extern int tty_write(unsigned minor,char * buf,int count);    // 终端写。
18
   // 定义字符设备读写函数指针类型。
19 typedef (*crw_ptr)(int rw,unsigned minor,char * buf,int count,off_t * pos);
20
   //// 串口终端读写操作函数。
   // 参数：rw - 读写命令；minor - 终端子设备号；buf - 缓冲区；cout - 读写字节数；
   //       pos - 读写操作当前指针，对于终端操作，该指针无用。
   // 返回：实际读写的字节数。
21 static int rw_ttyx(int rw,unsigned minor,char * buf,int count,off_t * pos)
22 {
23         return ((rw==READ)?tty_read(minor,buf,count):
24                 tty_write(minor,buf,count));
25 }
26
   //// 终端读写操作函数。
   // 同上 rw_ttyx()，只是增加了对进程是否有控制终端的检测。
27 static int rw_tty(int rw,unsigned minor,char * buf,int count, off_t * pos)
28 {
   // 若进程没有对应的控制终端，则返回出错号。
29         if (current->tty<0)
30                 return -EPERM;
   // 否则调用终端读写函数 rw_ttyx()，并返回实际读写字节数。
```

```
31          return rw_ttyx(rw,current->tty,buf,count,pos);
32  }
33
    //// 内存数据读写。未实现。
34  static int rw_ram(int rw,char * buf, int count, off_t *pos)
35  {
36          return -EIO;
37  }
38
    //// 内存数据读写操作函数。未实现。
39  static int rw_mem(int rw,char * buf, int count, off_t * pos)
40  {
41          return -EIO;
42  }
43
    //// 内核数据区读写函数。未实现。
44  static int rw_kmem(int rw,char * buf, int count, off_t * pos)
45  {
46          return -EIO;
47  }
48
    // 端口读写操作函数。
    // 参数：rw - 读写命令；buf - 缓冲区；cout - 读写字节数；pos - 端口地址。
    // 返回：实际读写的字节数。
49  static int rw_port(int rw,char * buf, int count, off_t * pos)
50  {
51          int i=*pos;
52
    // 对于所要求读写的字节数，并且端口地址小于 64k 时，循环执行单个字节的读写操作。
53          while (count-->0 && i<65536) {
    // 若是读命令，则从端口 i 中读取一字节内容并放到用户缓冲区中。
54                  if (rw==READ)
55                          put_fs_byte(inb(i),buf++);
    // 若是写命令，则从用户数据缓冲区中取一字节输出到端口 i。
56                  else
57                          outb(get_fs_byte(buf++),i);
    // 前移一个端口。[??]
58                  i++;
59          }
    // 计算读/写的字节数，并相应调整读写指针。
60          i -= *pos;
61          *pos += i;
    // 返回读/写的字节数。
62          return i;
63  }
64
    //// 内存读写操作函数。
65  static int rw_memory(int rw, unsigned minor, char * buf, int count, off_t * pos)
66  {
    // 根据内存设备子设备号，分别调用不同的内存读写函数。
67          switch(minor) {
68                  case 0:
69                          return rw_ram(rw,buf,count,pos);
```

```
70                  case 1:
71                          return rw_mem(rw,buf,count,pos);
72                  case 2:
73                          return rw_kmem(rw,buf,count,pos);
74                  case 3:
75                          return (rw==READ)?0:count;      /* rw_null */
76                  case 4:
77                          return rw_port(rw,buf,count,pos);
78                  default:
79                          return -EIO;
80          }
81  }
82
    // 定义系统中设备种数。
83  #define NRDEVS ((sizeof (crw_table))/(sizeof (crw_ptr)))
84
    // 字符设备读写函数指针表。
85  static crw_ptr crw_table[]={
86          NULL,           /* nodev */             /* 无设备(空设备) */
87          rw_memory,      /* /dev/mem etc */      /* /dev/mem 等 */
88          NULL,           /* /dev/fd */           /* /dev/fd 软驱 */
89          NULL,           /* /dev/hd */           /* /dev/hd 硬盘 */
90          rw_ttyx,        /* /dev/ttyx */         /* /dev/ttyx 串口终端 */
91          rw_tty,         /* /dev/tty */          /* /dev/tty 终端 */
92          NULL,           /* /dev/lp */           /* /dev/lp 打印机 */
93          NULL};          /* unnamed pipes */     /* 未命名管道 */
94
    //// 字符设备读写操作函数。
    // 参数：rw - 读写命令；dev - 设备号；buf - 缓冲区；count - 读写字节数；pos -读写指针。
    // 返回：实际读/写字节数。
95  int rw_char(int rw,int dev, char * buf, int count, off_t * pos)
96  {
97          crw_ptr call_addr;
98
    // 如果设备号超出系统设备数，则返回出错码。
99          if (MAJOR(dev)>=NRDEVS)
100                 return -ENODEV;
    // 若该设备没有对应的读/写函数，则返回出错码。
101         if (!(call_addr=crw_table[MAJOR(dev)]))
102                 return -ENODEV;
    // 调用对应设备的读写操作函数，并返回实际读/写的字节数。
103         return call_addr(rw,MINOR(dev),buf,count,pos);
104 }
105
```

9.14 read_write.c 程序

9.14.1 功能描述

该文件实现了文件操作系统调用 read()、write()和 lseek()。read()和 write()将根据不同的文件类型，

分别调用前面4个文件中实现的相应读写函数。因此本文件是前面4个文件中函数的上层接口实现。lseek()用于设置文件读写指针。

read()系统调用首先判断所给参数的有效性，然后根据文件的 i 节点信息判断文件的类型。若是管道文件则调用程序 pipe.c 中的读函数；若是字符设备文件，则调用 char_dev.c 中的 rw_char()字符读函数；如果是块设备文件，则执行 block_dev.c 程序中的块设备读操作，并返回读取的字节数；如果是目录文件或一般正规文件，则调用 file_dev.c 中的文件读函数 file_read()。write()系统调用的实现与 read()类似。

lseek()系统调用将对文件句柄对应文件结构中的当前读写指针进行修改。对于读写指针不能移动的文件和管道文件，将给出错误号，并立即返回。

9.14.2 代码注释

程序 9-12 linux/fs/read_write.c

```
 1 /*
 2  *  linux/fs/read_write.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
 8 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
 9 #include <sys/types.h>    // 类型头文件。定义了基本的系统数据类型。
10
11 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
12 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
13 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
14
   // 字符设备读写函数。
15 extern int rw_char(int rw,int dev, char * buf, int count, off_t * pos);
   // 读管道操作函数。
16 extern int read_pipe(struct m_inode * inode, char * buf, int count);
   // 写管道操作函数。
17 extern int write_pipe(struct m_inode * inode, char * buf, int count);
   // 块设备读操作函数。
18 extern int block_read(int dev, off_t * pos, char * buf, int count);
   // 块设备写操作函数。
19 extern int block_write(int dev, off_t * pos, char * buf, int count);
   // 读文件操作函数。
20 extern int file_read(struct m_inode * inode, struct file * filp,
21                 char * buf, int count);
   // 写文件操作函数。
22 extern int file_write(struct m_inode * inode, struct file * filp,
23                 char * buf, int count);
24
   //// 重定位文件读写指针系统调用函数。
   // 参数 fd 是文件句柄，offset 是新的文件读写指针偏移值，origin 是偏移的起始位置，是 SEEK_SET
   // (0，从文件开始处)、SEEK_CUR(1，从当前读写位置)、SEEK_END(2，从文件尾处)三者之一。
25 int sys_lseek(unsigned int fd,off_t offset, int origin)
26 {
27         struct file * file;
28         int tmp;
29
```

```
    // 如果文件句柄值大于程序最多打开文件数 NR_OPEN(20)，或者该句柄的文件结构指针为空，或者
    // 对应文件结构的 i 节点字段为空，或者指定设备文件指针是不可定位的，则返回出错码并退出。
30          if (fd >= NR_OPEN || !(file=current->filp[fd]) || !(file->f_inode)
31              || !IS_SEEKABLE(MAJOR(file->f_inode->i_dev)))
32                  return -EBADF;
    // 如果文件对应的 i 节点是管道节点，则返回出错码，退出。管道头尾指针不可随意移动!
33          if (file->f_inode->i_pipe)
34                  return -ESPIPE;
    // 根据设置的定位标志，分别重新定位文件读写指针。
35          switch (origin) {
    // origin = SEEK_SET，要求以文件起始处作为原点设置文件读写指针。若偏移值小于零，则出错返
    // 回错误码。否则设置文件读写指针等于 offset。
36                  case 0:
37                          if (offset<0) return -EINVAL;
38                          file->f_pos=offset;
39                          break;
    // origin = SEEK_CUR，要求以文件当前读写指针处作为原点重定位读写指针。如果文件当前指针加
    // 上偏移值小于 0，则返回出错码退出。否则在当前读写指针上加上偏移值。
40                  case 1:
41                          if (file->f_pos+offset<0) return -EINVAL;
42                          file->f_pos += offset;
43                          break;
    // origin = SEEK_END，要求以文件末尾作为原点重定位读写指针。此时若文件大小加上偏移值小于零
    // 则返回出错码退出。否则重定位读写指针为文件长度加上偏移值。
44                  case 2:
45                          if ((tmp=file->f_inode->i_size+offset) < 0)
46                                  return -EINVAL;
47                          file->f_pos = tmp;
48                          break;
    // origin 设置出错，返回出错码退出。
49                  default:
50                          return -EINVAL;
51          }
52          return file->f_pos;     // 返回重定位后的文件读写指针值。
53  }
54
    //// 读文件系统调用函数。
    // 参数 fd 是文件句柄，buf 是缓冲区，count 是欲读字节数。
55  int sys_read(unsigned int fd,char * buf,int count)
56  {
57          struct file * file;
58          struct m_inode * inode;
59
    // 如果文件句柄值大于程序最多打开文件数 NR_OPEN，或者需要读取的字节计数值小于 0，或者该句柄
    // 的文件结构指针为空，则返回出错码并退出。
60          if (fd>=NR_OPEN || count<0 || !(file=current->filp[fd]))
61                  return -EINVAL;
    // 若需读取的字节数 count 等于 0，则返回 0，退出
62          if (!count)
63                  return 0;
    // 验证存放数据的缓冲区内存限制。
64          verify_area(buf,count);
    // 取文件对应的 i 节点。若是管道文件，并且是读管道文件模式，则进行读管道操作，若成功则返回
```

```
    // 读取的字节数，否则返回出错码，退出。
 65         inode = file->f_inode;
 66         if (inode->i_pipe)
 67                 return (file->f_mode&1)?read_pipe(inode,buf,count):-EIO;
    // 如果是字符型文件，则进行读字符设备操作，返回读取的字符数。
 68         if (S_ISCHR(inode->i_mode))
 69                 return rw_char(READ,inode->i_zone[0],buf,count,&file->f_pos);
    // 如果是块设备文件，则执行块设备读操作，并返回读取的字节数。
 70         if (S_ISBLK(inode->i_mode))
 71                 return block_read(inode->i_zone[0],&file->f_pos,buf,count);
    // 如果是目录文件或者是常规文件，则首先验证读取数 count 的有效性并进行调整（若读取字节数加上
    // 文件当前读写指针值大于文件大小，则重新设置读取字节数为文件长度-当前读写指针值，若读取数
    // 等于 0，则返回 0 退出），然后执行文件读操作，返回读取的字节数并退出。
 72         if (S_ISDIR(inode->i_mode) || S_ISREG(inode->i_mode)) {
 73                 if (count+file->f_pos > inode->i_size)
 74                         count = inode->i_size - file->f_pos;
 75                 if (count<=0)
 76                         return 0;
 77                 return file_read(inode,file,buf,count);
 78         }
    // 否则打印节点文件属性，并返回出错码退出。
 79         printk("(Read)inode->i_mode=%06o\n\r",inode->i_mode);
 80         return -EINVAL;
 81 }
 82
 83 int sys_write(unsigned int fd,char * buf,int count)
 84 {
 85         struct file * file;
 86         struct m_inode * inode;
 87
    // 如果文件句柄值大于程序最多打开文件数 NR_OPEN，或者需要写入的字节计数小于 0，或者该句柄
    // 的文件结构指针为空，则返回出错码并退出。
 88         if (fd>=NR_OPEN || count <0 || !(file=current->filp[fd]))
 89                 return -EINVAL;
    // 若需读取的字节数 count 等于 0，则返回 0，退出
 90         if (!count)
 91                 return 0;
    // 取文件对应的 i 节点。若是管道文件，并且是写管道文件模式，则进行写管道操作，若成功则返回
    // 写入的字节数，否则返回出错码，退出。
 92         inode=file->f_inode;
 93         if (inode->i_pipe)
 94                 return (file->f_mode&2)?write_pipe(inode,buf,count):-EIO;
    // 如果是字符型文件，则进行写字符设备操作，返回写入的字符数，退出。
 95         if (S_ISCHR(inode->i_mode))
 96                 return rw_char(WRITE,inode->i_zone[0],buf,count,&file->f_pos);
    // 如果是块设备文件，则进行块设备写操作，并返回写入的字节数，退出。
 97         if (S_ISBLK(inode->i_mode))
 98                 return block_write(inode->i_zone[0],&file->f_pos,buf,count);
    // 若是常规文件，则执行文件写操作，并返回写入的字节数，退出。
 99         if (S_ISREG(inode->i_mode))
100                 return file_write(inode,file,buf,count);
    // 否则，显示对应节点的文件模式，返回出错码，退出。
101         printk("(Write)inode->i_mode=%06o\n\r",inode->i_mode);
```

```
102         return -EINVAL;
103 }
104
```

9.14.3 用户程序的读写操作

在看完上面程序后，我们应该可以清楚地理解一个用户程序中的读写操作是如何执行的。下面我们以内核中的读操作函数为例具体说明用户程序中的一个读文件函数调用是如何执行并完成的。

通常，应用程序不直接调用 Linux 的系统调用（System Calls），而是通过调用函数库（例如 libc.a）中的子程序进行操作的。但是若为了提高一些效率，当然也是可以直接进行调用的。对于一个基本的函数库来讲，通常需要提供以下一些基本函数或子程序的集合：

- 系统调用接口函数
- 内存分配管理函数
- 信号处理函数集
- 字符串处理函数
- 标准输入输出函数
- 其他函数集，如 bsd 函数、加解密函数、算术运算函数、终端操作函数和网络套接字函数集等。

在这些函数集中，系统调用函数是操作系统的底层接口函数。许多牵涉到系统调用的函数都会调用系统调用接口函数集中具有标准名称的系统函数，而不是直接使用 Linux 的系统终端调用接口。这样做可以很大程度上让一个函数库与其所在的操作系统无关，让函数库有较高的可移植性。对于一个新的函数库源代码，只要将其中涉及系统调用的部分（系统接口部分）替换成新操作系统的系统调用，就基本上能完成该函数库的移植工作。

库中的子程序可以看作是应用程序与内核系统之间的中间层，它的主要作用除了提供一些不属于内核的计算函数等功能函数外，还为应用程序执行系统调用提供“包裹函数”。这样做一来可以简化调用接口，是接口更简单容易记忆，二来可以在这些包裹函数中进行一些参数验证，出错处理，因此能使得程序更加可靠稳定。

对于 Linux 系统，所有输入输出都是通过读写文件完成的。因为所有的外围设备都是以文件形式在系统中呈现，这样使用统一的文件句柄就可以处理程序与外设之间的所有访问。在通常情况下，在读写一个文件之前我们需要首先使用打开文件（open file）操作来通知操作系统将要开始的行动。如果想在一个文件上执行写操作，那么你首先可能需要先创建这个文件或者将文件中以前的内容删除。操作系统还需要检查你是否有权限来执行这些操作。如果一切正常的话，打开操作会向程序返回一个文件描述符（file escriptor），文件描述符将替代文件名来确定所访问的文件，它与 MS-DOS 中文件句柄（file handle）作用一样。此时一个打开着的文件的所有信息都由系统来维护，用户程序只需要使用文件描述符来访问文件。

文件读写分别使用 read 和 write 系统调用，用户程序一般通过访问函数库中的 read 和 write 函数来执行这两个系统调用。这两个函数的定义如下：

```
int read(int fd, char *buf, int n);
int write(int fd, char *buf, int n);
```

这两个函数的头一个参数是文件描述符。第二个参数是一个字符缓冲阵列，用于存放读取或被写出的数据。第三个参数是需要读写的数据字节数。函数返回值是一次调用时传输的字节计数值。对于读文件操作，返回的值可能会比想要读的数据小。如果返回值是 0，则表示已经读到文件尾。如果返回-1，

则表示读操作遇到错误。对于写操作，返回的值是实际写入的字节数，如果该值与第三个参数指定的值不等，这表示写操作遇到了错误。对于读函数，它在函数库中的实现形式如下：

```
#define __LIBRARY__
#include <unistd.h>

_syscall3(int,read,int,fd,char *,buf,off_t,count)
```

其中_syscall3()是一个宏，定义在 unistd.h 头文件第 172 行开始处。若将该宏以上面的具体参数展开，我们可得到以下代码：

```
int read(int fd, char *buf, off_t count)
{
    long __res;
    __asm__ volatile (
        "int $0x80"
        : "=a" (__res)
        : "" (__NR_read), "b" ((long)(a)), "c" ((long)(b)), "d" ((long)(c)));
    if (__res>=0)
        return int __res;
    errno=-__res;
    return -1;
}
```

可以看出，这个展开的宏就是一个读操作函数的具体实现。从此处程序进入系统内核中执行。其中使用了嵌入汇编语句以功能号__NR_read（3）执行了 Linux 的系统中断调用 0x80。该中断调用在 eax（__res）寄存器中返回了实际读取的字节数。若返回的值小于 0，则表示此次读操作出错，于是将出错号取反后存入全局变量 errno 中，并向调用程序返回-1 值。

在 Linux 内核中，读操作在文件系统的 read_write.c 文件中实现。当执行了上述系统中断调用时，在该系统中断程序中就会去调用执行 read_write.c 文件中第 55 行开始的 sys_read()函数。sys_read()函数的原型定义如下：

int sys_read(unsigned int fd, char *buf, int count)

该函数首先判断参数的有效性。如果文件描述符值大于系统最多同时打开的最大文件数，或者需要读取的字节数值小于 0，或者该文件还没有执行过打开操作（此时文件描述符所索引的文件结构项指针为空），这返回一个负的出错代码。接着内核程序验证将要存放读取数据的缓冲区大小是否合适。在验证过程中，内核程序会根据指定的读取字节数对缓冲区 buf 的大小进行验证，如果 buf 太小，这系统会对其进行扩充。因此，若用户程序开辟的内存缓冲区太小的话就有可能冲毁后面的数据。

随后内核代码会从文件描述符对应的内部文件表结构中获得该文件的 i 节点结构，并根据节点中的标志信息对该文件进行分类判断，调用对应类型的读操作函数，并返回所读取的实际字节数。

- 如果该文件是管道文件，则调用读管道函数 read_pipe()（在 fs/pipe.c 中实现）进行操作。
- 如果是字符设备文件，则调用读字符设备操作函数 rw_char()（在 fs/char_dev.c 中实现）。该函数再会根据具体的字符设备子类型调用字符设备驱动程序或对内存字符设备进行操作。
- 如果是块设备文件，则调用块设备读操作函数 block_read()（在 fs/block_dev.c 中实现）。该函数则调用内存高速缓冲管理程序 fs/buffer.c 中的读块函数 bread()，最后调用到块设备驱动程序中的

ll_rw_block()函数执行实际的块设备读操作。

- 如果该文件是一般普通常规文件，则调用常规文件读函数 file_read()（在 fs/file_read.c 中实现）进行读数据操作。该函数与读块设备操作类似，最后也会去调用执行文件系统所在块设备的底层驱动程序访问函数 ll_rw_block()，但是 file_read()还需要维护相关的内部文件表结构中的信息，例如移动文件当前指针。

当读操作的系统调用返回时，函数库中的 read()函数就可以根据系统调用返回值来判断此次操作是否正确。若返回的值小于 0，则表示此次读操作出错，于是将出错号取反后存入全局变量 errno 中，并向应用程序返回-1 值。

9.15 truncte.c 程序

9.15.1 功能描述

本程序用于释放指定 i 节点在设备上占用的所有逻辑块，包括直接块、一次间接块和二次间接块。从而将文件的节点对应的文件长度截为 0，并释放占用的设备空间。i 节点中直接块和间接块的示意图见图 9-22 所示。

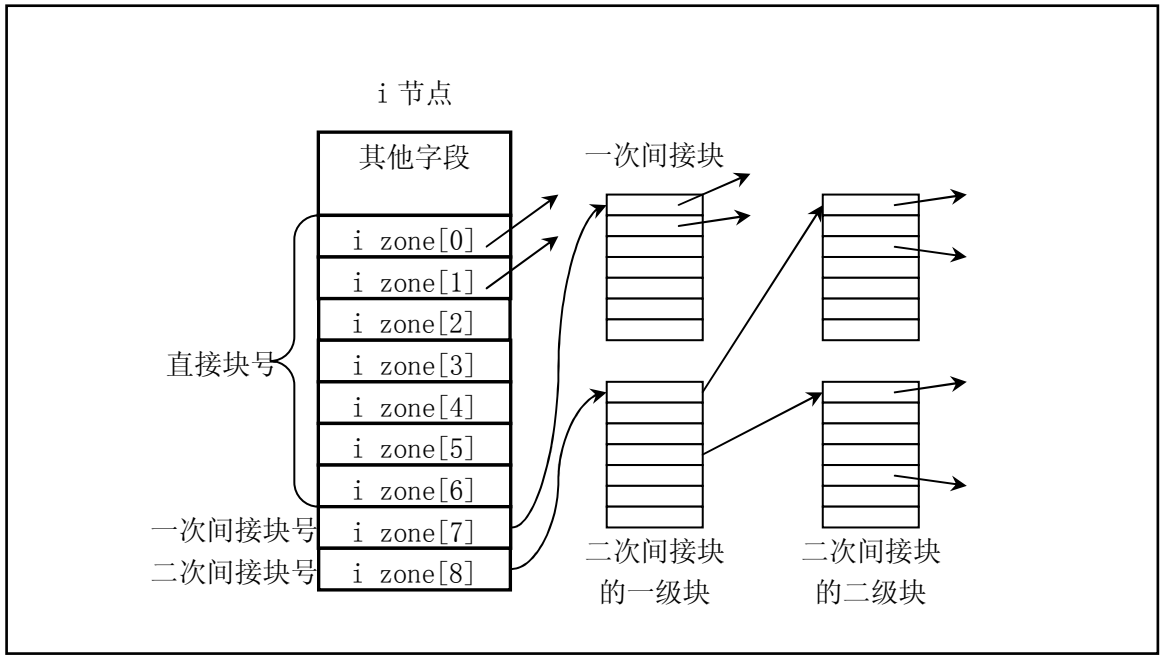

图 9-22 索引节点(i 节点)的逻辑块连接方式

9.15.2 代码注释

程序 9-13 linux/fs/truncate.c

```
1 /*
2  *  linux/fs/truncate.c
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
```

```
 7 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
 8
 9 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
10
   //// 释放一次间接块。
11 static void free_ind(int dev,int block)
12 {
13         struct buffer_head * bh;
14         unsigned short * p;
15         int i;
16
   // 如果逻辑块号为 0，则返回。
17         if (!block)
18                 return;
   // 读取一次间接块，并释放其上表明使用的所有逻辑块，然后释放该一次间接块的缓冲区。
19         if (bh=bread(dev,block)) {
20                 p = (unsigned short *) bh->b_data;  // 指向数据缓冲区。
21                 for (i=0;i<512;i++,p++)             // 每个逻辑块上可有 512 个块号。
22                         if (*p)
23                                 free_block(dev,*p); // 释放指定的逻辑块。
24                 brelse(bh);                         // 释放缓冲区。
25         }
   // 释放设备上的一次间接块。
26         free_block(dev,block);
27 }
28
   //// 释放二次间接块。
29 static void free_dind(int dev,int block)
30 {
31         struct buffer_head * bh;
32         unsigned short * p;
33         int i;
34
   // 如果逻辑块号为 0，则返回。
35         if (!block)
36                 return;
   // 读取二次间接块的一级块，并释放其上表明使用的所有逻辑块，然后释放该一级块的缓冲区。
37         if (bh=bread(dev,block)) {
38                 p = (unsigned short *) bh->b_data;  // 指向数据缓冲区。
39                 for (i=0;i<512;i++,p++)             // 每个逻辑块上可连接 512 个二级块。
40                         if (*p)
41                                 free_ind(dev,*p);   // 释放所有一次间接块。
42                 brelse(bh);                         // 释放缓冲区。
43         }
   // 最后释放设备上的二次间接块。
44         free_block(dev,block);
45 }
46
   //// 将节点对应的文件长度截为 0，并释放占用的设备空间。
47 void truncate(struct m_inode * inode)
48 {
49         int i;
```

```
50
   // 如果不是常规文件或者是目录文件，则返回。
51          if (!(S_ISREG(inode->i_mode) || S_ISDIR(inode->i_mode)))
52                  return;
   // 释放 i 节点的 7 个直接逻辑块，并将这 7 个逻辑块项全置零。
53          for (i=0;i<7;i++)
54                  if (inode->i_zone[i]) {                 // 如果块号不为 0，则释放之。
55                          free_block(inode->i_dev,inode->i_zone[i]);
56                          inode->i_zone[i]=0;
57                  }
58          free_ind(inode->i_dev,inode->i_zone[7]);        // 释放一次间接块。
59          free_dind(inode->i_dev,inode->i_zone[8]);       // 释放二次间接块。
60          inode->i_zone[7] = inode->i_zone[8] = 0;        // 逻辑块项 7、8 置零。
61          inode->i_size = 0;                              // 文件大小置零。
62          inode->i_dirt = 1;                              // 置节点已修改标志。
63          inode->i_mtime = inode->i_ctime = CURRENT_TIME; // 重置文件和节点修改时间为当前时间。
64  }
65
66
```

9.16 open.c 程序

9.16.1 功能描述

本文件实现了许多与文件操作相关的系统调用。主要有文件的创建、打开和关闭，文件宿主和属性的修改、文件访问权限的修改、文件操作时间的修改和系统文件系统 root 的变动等。

9.16.2 代码注释

程序 9-14 linux/fs/open.c

```
 1  /*
 2   *  linux/fs/open.c
 3   *
 4   *  (C) 1991  Linus Torvalds
 5   */
 6
 7  #include <string.h>       // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
 8  #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
 9  #include <fcntl.h>        // 文件控制头文件。用于文件及其描述符的操作控制常数符号的定义。
10  #include <sys/types.h>    // 类型头文件。定义了基本的系统数据类型。
11  #include <utime.h>        // 用户时间头文件。定义了访问和修改时间结构以及 utime()原型。
12  #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
13
14  #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                              // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
15  #include <linux/tty.h>    // tty 头文件，定义了有关 tty_io，串行通信方面的参数、常数。
16  #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
17  #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
```

```
18
    // 取文件系统信息系统调用函数。
19  int sys_ustat(int dev, struct ustat * ubuf)
20  {
21          return -ENOSYS;
22  }
23
    //// 设置文件访问和修改时间。
    // 参数 filename 是文件名，times 是访问和修改时间结构指针。
    // 如果 times 指针不为 NULL，则取 utimbuf 结构中的时间信息来设置文件的访问和修改时间。如果
    // times 指针是 NULL，则取系统当前时间来设置指定文件的访问和修改时间域。
24  int sys_utime(char * filename, struct utimbuf * times)
25  {
26          struct m_inode * inode;
27          long actime,modtime;
28
    // 根据文件名寻找对应的 i 节点，如果没有找到，则返回出错码。
29          if (!(inode=namei(filename)))
30                  return -ENOENT;
    // 如果访问和修改时间数据结构指针不为 NULL，则从结构中读取用户设置的时间值。
31          if (times) {
32                  actime = get_fs_long((unsigned long *) &times->actime);
33                  modtime = get_fs_long((unsigned long *) &times->modtime);
    // 否则将访问和修改时间置为当前时间。
34          } else
35                  actime = modtime = CURRENT_TIME;
    // 修改 i 节点中的访问时间字段和修改时间字段。
36          inode->i_atime = actime;
37          inode->i_mtime = modtime;
    // 置 i 节点已修改标志，释放该节点，并返回 0。
38          inode->i_dirt = 1;
39          iput(inode);
40          return 0;
41  }
42
43  /*
44   * XXX should we use the real or effective uid?  BSD uses the real uid,
45   * so as to make this call useful to setuid programs.
46   */
    /*
     * 文件属性 XXX，我们该用真实用户 id 还是有效用户 id？BSD 系统使用了真实用户 id，
     * 以使该调用可以供 setuid 程序使用。（注：POSIX 标准建议使用真实用户 ID）
     */
    //// 检查对文件的访问权限。
    // 参数 filename 是文件名，mode 是屏蔽码，由 R_OK(4)、W_OK(2)、X_OK(1)和 F_OK(0)组成。
    // 如果请求访问允许的话，则返回 0，否则返回出错码。
47  int sys_access(const char * filename,int mode)
48  {
49          struct m_inode * inode;
50          int res, i_mode;
51
    // 屏蔽码由低 3 位组成，因此清除所有高比特位。
52          mode &= 0007;
```

```
    // 如果文件名对应的 i 节点不存在，则返回出错码。
53          if (!(inode=namei(filename)))
54                  return -EACCES;
    // 取文件的属性码，并释放该 i 节点。
55          i_mode = res = inode->i_mode & 0777;
56          iput(inode);
    // 如果当前进程是该文件的宿主，则取文件宿主属性。
57          if (current->uid == inode->i_uid)
58                  res >>= 6;
    // 否则如果当前进程是与该文件同属一组，则取文件组属性。
59          else if (current->gid == inode->i_gid)
60                  res >>= 6;
    // 如果文件属性具有查询的属性位，则访问许可，返回 0。
61          if ((res & 0007 & mode) == mode)
62                  return 0;
63          /*
64           * XXX we are doing this test last because we really should be
65           * swapping the effective with the real user id (temporarily),
66           * and then calling suser() routine.  If we do call the
67           * suser() routine, it needs to be called last.
68           */
            /*
             * XXX 我们最后才做下面的测试，因为我们实际上需要交换有效用户 id 和
             * 真实用户 id（临时地），然后才调用 suser()函数。如果我们确实要调用
             * suser()函数，则需要最后才被调用。
             */
    // 如果当前用户 id 为 0（超级用户）并且屏蔽码执行位是 0 或文件可以被任何人访问，则返回 0。
69          if ((!current->uid) &&
70              (!(mode & 1) || (i_mode & 0111)))
71                  return 0;
    // 否则返回出错码。
72          return -EACCES;
73  }
74
    //// 改变当前工作目录系统调用函数。
    // 参数 filename 是目录名。
    // 操作成功则返回 0，否则返回出错码。
75  int sys_chdir(const char * filename)
76  {
77          struct m_inode * inode;
78
    // 如果文件名对应的 i 节点不存在，则返回出错码。
79          if (!(inode = namei(filename)))
80                  return -ENOENT;
    // 如果该 i 节点不是目录的 i 节点，则释放该节点，返回出错码。
81          if (!S_ISDIR(inode->i_mode)) {
82                  iput(inode);
83                  return -ENOTDIR;
84          }
    // 释放当前进程原工作目录 i 节点，并指向该新置的工作目录 i 节点。返回 0。
85          iput(current->pwd);
86          current->pwd = inode;
87          return (0);
```

```
88 }
89
   //// 改变根目录系统调用函数。
   // 将指定的路径名改为根目录'/'。
   // 如果操作成功则返回 0，否则返回出错码。
90 int sys_chroot(const char * filename)
91 {
92         struct m_inode * inode;
93
   // 如果文件名对应的 i 节点不存在，则返回出错码。
94         if (!(inode=namei(filename)))
95                 return -ENOENT;
   // 如果该 i 节点不是目录的 i 节点，则释放该节点，返回出错码。
96         if (!S_ISDIR(inode->i_mode)) {
97                 iput(inode);
98                 return -ENOTDIR;
99         }
   // 释放当前进程的根目录 i 节点，并重置为这里指定目录名的 i 节点，返回 0。
100        iput(current->root);
101        current->root = inode;
102        return (0);
103 }
104
   //// 修改文件属性系统调用函数。
   // 参数 filename 是文件名，mode 是新的文件属性。
   // 若操作成功则返回 0，否则返回出错码。
105 int sys_chmod(const char * filename,int mode)
106 {
107        struct m_inode * inode;
108
   // 如果文件名对应的 i 节点不存在，则返回出错码。
109        if (!(inode=namei(filename)))
110                return -ENOENT;
   // 如果当前进程的有效用户 id 不等于文件 i 节点的用户 id，并且当前进程不是超级用户，则释放该
   // 文件 i 节点，返回出错码。
111        if ((current->euid != inode->i_uid) && !suser()) {
112                iput(inode);
113                return -EACCES;
114        }
   // 重新设置 i 节点的文件属性，并置该 i 节点已修改标志。释放该 i 节点，返回 0。
115        inode->i_mode = (mode & 07777) | (inode->i_mode & ~07777);
116        inode->i_dirt = 1;
117        iput(inode);
118        return 0;
119 }
120
   //// 修改文件宿主系统调用函数。
   // 参数 filename 是文件名，uid 是用户标识符(用户 id)，gid 是组 id。
   // 若操作成功则返回 0，否则返回出错码。
121 int sys_chown(const char * filename,int uid,int gid)
122 {
123        struct m_inode * inode;
124
```

```
    // 如果文件名对应的 i 节点不存在，则返回出错码。
125         if (!(inode=namei(filename)))
126                 return -ENOENT;
    // 若当前进程不是超级用户，则释放该 i 节点，返回出错码。
127         if (!suser()) {
128                 iput(inode);
129                 return -EACCES;
130         }
    // 设置文件对应 i 节点的用户 id 和组 id，并置 i 节点已经修改标志，释放该 i 节点，返回 0。
131         inode->i_uid=uid;
132         inode->i_gid=gid;
133         inode->i_dirt=1;
134         iput(inode);
135         return 0;
136 }
137
    //// 打开（或创建）文件系统调用函数。
    // 参数 filename 是文件名，flag 是打开文件标志：只读 O_RDONLY、只写 O_WRONLY 或读写 O_RDWR，
    // 以及 O_CREAT、O_EXCL、O_APPEND 等其他一些标志的组合，若本函数创建了一个新文件，则 mode
    // 用于指定使用文件的许可属性，这些属性有 S_IRWXU(文件宿主具有读、写和执行权限)、S_IRUSR
    // (用户具有读文件权限)、S_IRWXG(组成员具有读、写和执行权限)等等。对于新创建的文件，这些
    // 属性只应用于将来对文件的访问，创建了只读文件的打开调用也将返回一个可读写的文件句柄。
    // 若操作成功则返回文件句柄(文件描述符)，否则返回出错码。(参见 sys/stat.h, fcntl.h)
138 int sys_open(const char * filename,int flag,int mode)
139 {
140         struct m_inode * inode;
141         struct file * f;
142         int i,fd;
143
    // 将用户设置的模式与进程的模式屏蔽码相与，产生许可的文件模式。
144         mode &= 0777 & ~current->umask;
    // 搜索进程结构中文件结构指针数组，查找一个空闲项，若已经没有空闲项，则返回出错码。
145         for(fd=0 ; fd<NR_OPEN ; fd++)
146                 if (!current->filp[fd])
147                         break;
148         if (fd>=NR_OPEN)
149                 return -EINVAL;
    // 设置执行时关闭文件句柄位图，复位对应比特位。
150         current->close_on_exec &= ~(1<<fd);
    // 令 f 指向文件表数组开始处。搜索空闲文件结构项(句柄引用计数为 0 的项)，若已经没有空闲
    // 文件表结构项，则返回出错码。
151         f=0+file_table;
152         for (i=0 ; i<NR_FILE ; i++,f++)
153                 if (!f->f_count) break;
154         if (i>=NR_FILE)
155                 return -EINVAL;
    // 让进程的对应文件句柄的文件结构指针指向搜索到的文件结构，并令句柄引用计数递增 1。
156         (current->filp[fd]=f)->f_count++;
    // 调用函数执行打开操作，若返回值小于 0，则说明出错，释放刚申请到的文件结构，返回出错码。
157         if ((i=open_namei(filename,flag,mode,&inode))<0) {
158                 current->filp[fd]=NULL;
159                 f->f_count=0;
160                 return i;
```

```
161         }
162 /* ttys are somewhat special (ttyxx major==4, tty major==5) */
    /* ttys 有些特殊（ttyxx 主号==4，tty 主号==5）*/
    // 如果是字符设备文件，那么如果设备号是 4 的话，则设置当前进程的 tty 号为该 i 节点的子设备号。
    // 并设置当前进程 tty 对应的 tty 表项的父进程组号等于进程的父进程组号。
163         if (S_ISCHR(inode->i_mode))
164                 if (MAJOR(inode->i_zone[0])==4) {
165                         if (current->leader && current->tty<0) {
166                                 current->tty = MINOR(inode->i_zone[0]);
167                                 tty_table[current->tty].pgrp = current->pgrp;
168                         }
    // 否则如果该字符文件设备号是 5 的话，若当前进程没有 tty，则说明出错，释放 i 节点和申请到的
    // 文件结构，返回出错码。
169                 } else if (MAJOR(inode->i_zone[0])==5)
170                         if (current->tty<0) {
171                                 iput(inode);
172                                 current->filp[fd]=NULL;
173                                 f->f_count=0;
174                                 return -EPERM;
175                         }
176 /* Likewise with block-devices: check for floppy_change */
    /* 同样对于块设备文件：需要检查盘片是否被更换 */
    // 如果打开的是块设备文件，则检查盘片是否更换，若更换则需要是高速缓冲中对应该设备的所有
    // 缓冲块失效。
177         if (S_ISBLK(inode->i_mode))
178                 check_disk_change(inode->i_zone[0]);
    // 初始化文件结构。置文件结构属性和标志，置句柄引用计数为 1，设置 i 节点字段，文件读写指针
    // 初始化为 0。返回文件句柄。
179         f->f_mode = inode->i_mode;
180         f->f_flags = flag;
181         f->f_count = 1;
182         f->f_inode = inode;
183         f->f_pos = 0;
184         return (fd);
185 }
186
    //// 创建文件系统调用函数。
    // 参数 pathname 是路径名，mode 与上面的 sys_open()函数相同。
    // 成功则返回文件句柄，否则返回出错码。
187 int sys_creat(const char * pathname, int mode)
188 {
189         return sys_open(pathname, O_CREAT | O_TRUNC, mode);
190 }
191
    // 关闭文件系统调用函数。
    // 参数 fd 是文件句柄。
    // 成功则返回 0，否则返回出错码。
192 int sys_close(unsigned int fd)
193 {
194         struct file * filp;
195
    // 若文件句柄值大于程序同时能打开的文件数，则返回出错码。
196         if (fd >= NR_OPEN)
```

```
197                 return -EINVAL;
    // 复位进程的执行时关闭文件句柄位图对应位。
198         current->close_on_exec &= ~(1<<fd);
    // 若该文件句柄对应的文件结构指针是 NULL，则返回出错码。
199         if (!(filp = current->filp[fd]))
200                 return -EINVAL;
    // 置该文件句柄的文件结构指针为 NULL。
201         current->filp[fd] = NULL;
    // 若在关闭文件之前，对应文件结构中的句柄引用计数已经为 0，则说明内核出错，死机。
202         if (filp->f_count == 0)
203                 panic("Close: file count is 0");
    // 否则将对应文件结构的句柄引用计数减 1，如果还不为 0，则返回 0（成功）。若已等于 0，说明该
    // 文件已经没有句柄引用，则释放该文件 i 节点，返回 0。
204         if (--filp->f_count)
205                 return (0);
206         iput(filp->f_inode);
207         return (0);
208 }
209
```

9.17 exec.c 程序

9.17.1 功能描述

本源程序实现对二进制可执行文件和 shell 脚本文件的加载与执行。其中主要的函数是函数 do_execve()，它是系统中断调用(int 0x80)功能号__NR_execve()调用的 C 处理函数，是 exec()函数簇的主要实现函数。其主要功能为：

- 执行对命令行参数和环境参数空间页面的初始化操作 -- 设置初始空间起始指针；初始化空间页面指针数组为(NULl)；根据执行文件名取执行对象的 i 节点；计算参数个数和环境变量个数；检查文件类型，执行权限；
- 根据执行文件开始部分的头数据结构，对其中信息进行处理 -- 根据被执行文件 i 节点读取文件头部信息；若是 Shell 脚本程序（第一行以#!开始），则分析 Shell 程序名及其参数，并以被执行文件作为参数执行该执行的 Shell 程序；执行根据文件的幻数以及段长度等信息判断是否可执行；
- 对当前调用进程进行运行新文件前初始化操作 -- 指向新执行文件的 i 节点；复位信号处理句柄；根据头结构信息设置局部描述符基址和段长；设置参数和环境参数页面指针；修改进程各执行字段内容；
- 替换堆栈上原调用 execve()程序的返回地址为新执行程序运行地址，运行新加载的程序。

在 execve()执行过程中，系统会清掉 fork()复制的原程序的页目录和页表项，并释放对应页面。系统仅为新加载的程序代码重新设置进程数据结构中的信息并设置执行代码执行点，而此时并不从块设备上加载新程序的代码和数据。当该过程返回时即开始执行新的程序，但一开始执行肯定会引起缺页异常中断发生。因为代码和数据还未被从块设备上读入内存。缺页异常处理过程会根据引起异常的线性地址在主内存区为新程序中申请内存页面（内存帧）并从块设备上读入指定页面。同时还为该线性地址设置对应的页目录项和页表项。

关于命令行参数和环境参数的含义解释如下。当用户在命令提示符下键入一个命令时，所指定执行的程序会从该命令行上接受键入的命令行参数。例如当用户键入以下文件名列表命令时：

ls -l /home/john/

shell 进程会创建一个新进程并在其中执行/bin/ls 命令。在加载/bin/ls 执行文件时命令行上的三个参数 ls、-l 和/home/john/将被新进程继承下来。在支持 C 的环境中，当调用程序的主函数 main()时它会带有两个参数。

int main(int argc, char *argv[])

第一个是执行程序时命令行上参数的个数值，通常记为 argc（argument count），第二个是指向包含字符串参数的指针数组（argv -- argument vector）。每个字符串代表一个参数，并且 argv 数组的结尾总是以空指针来结束。通常，argv[0]是被执行的程序名，因此 argc 的值至少是 1。对于上面的例子，此时 argc=3，argv[0]、argv[1]和 argv[2]分别是'ls'、'-l'和'/home/john/'。而 argv[3] = NULL。见图 9-23 所示。

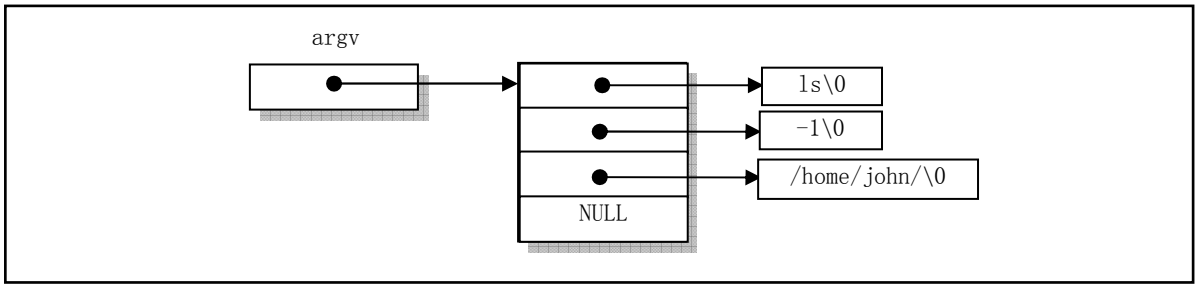

图 9-23 命令行参数指针数组 argv[]

main()还有第三个可选参数，该参数中包含环境变量（enviroment variable）参数，用于定制执行程序的环境设置并为其提供环境设置参数值。它也是一个指向包含字符串参数的指针数组，并以 NULL 结束，只是这些字符串是环境变量值。当程序需要明确用到环境变量时，main()的声明为：

int main(int argc, char *argv[], char *envp[])

环境字符串的形式为：

VAR_NAME=somevalue

其中 VAR_NAME 表示一个环境变量的名称，而等号后面的串代表给这个环境变量所赋的值。在命令行提示符下键入 shell 内部命令 set 可以显示出当前环境中设置的环境参数列表。在程序开始执行前，命令行参数和环境字符串被放置在用户堆栈顶端的地方，见下面说明。

execve()函数有大量对命令行参数和环境空间的处理操作，参数和环境空间共可有 MAX_ARG_PAGES 个页面，总长度可达 128kB 字节。在该空间中存放数据的方式类似于堆栈操作，即是从假设的 128kB 空间末端处逆向开始存放参数或环境变量字符串的。在初始时，程序定义了一个指向该空间末端(128kB-4 字节)处空间内偏移值 p，该偏移值随着存放数据的增多而后退，由图 9-24 中可以看出，p 明确地指出了当前参数环境空间中还剩余多少可用空间。copy_string()函数用于从用户内存空间拷

贝命令行参数和环境字符串到内核空闲页面中。在分析函数 copy_string()时，可参照此图。

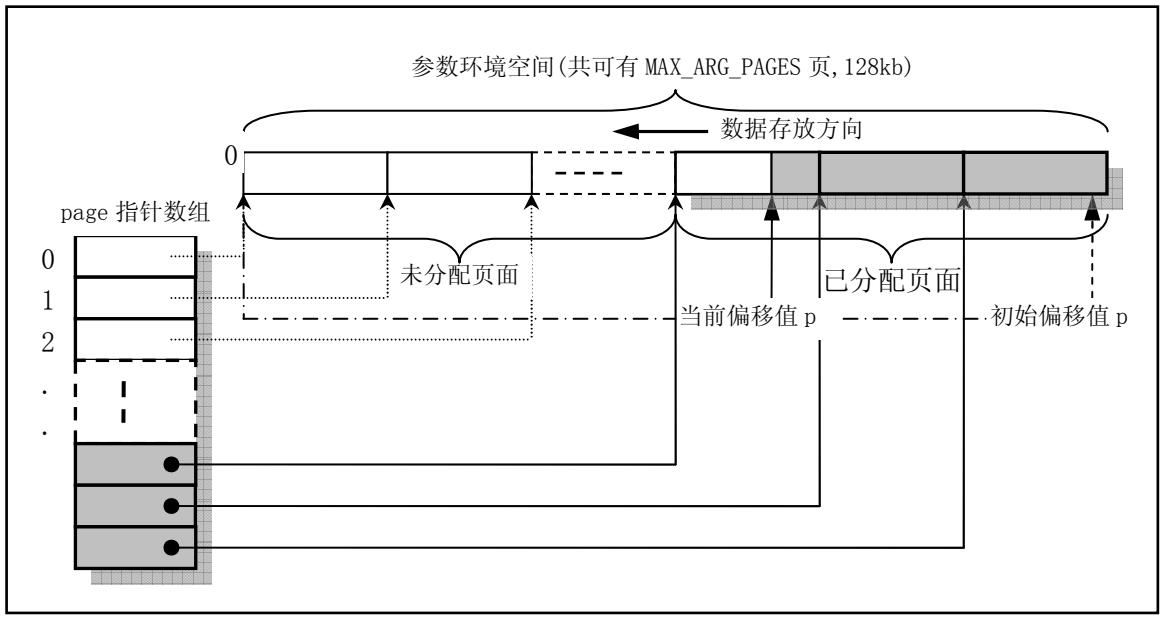

图 9-24 参数和环境变量字符串空间

create_tables()函数用于根据给定的当前堆栈指针值 p 以及参数变量个数值 argc 和环境变量个数 envc，在新的程序堆栈中创建环境和参数变量指针表，并返回此时的堆栈指针值 sp。创建完毕后堆栈指针表的形式见下图 9-25 所示。

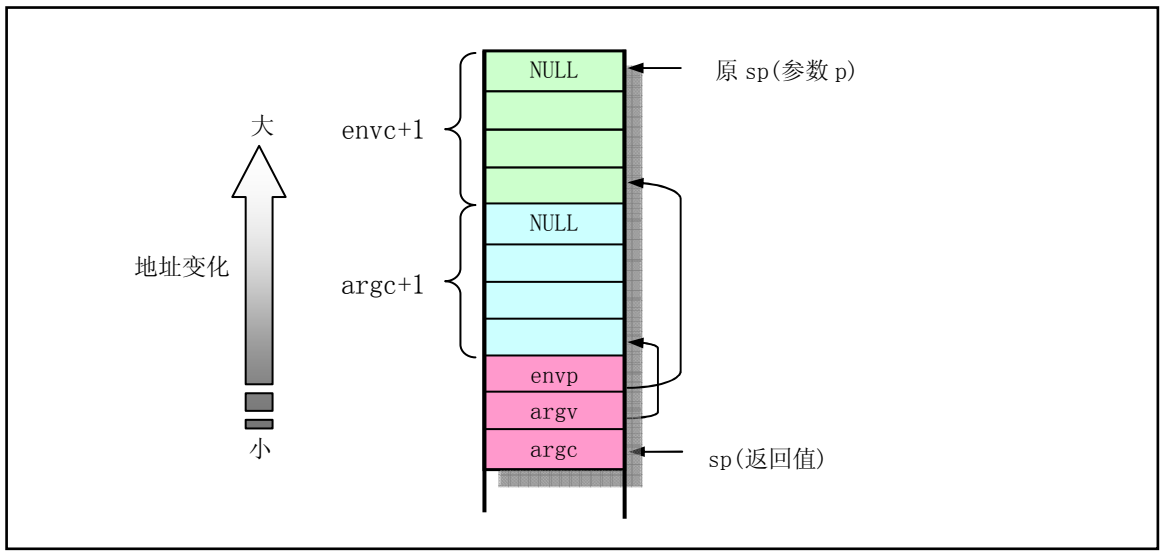

图 9-25 新程序堆栈中指针表示意图

9.17.2 代码注释

程序 9-15 linux/fs/exec.c

```
1 /*
2  *  linux/fs/exec.c
3  *
```

```
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * #!-checking implemented by tytso.
 9  */
   /*
    * #!开始的程序检测部分是由 tytso 实现的。
    */
10
11 /*
12  * Demand-loading implemented 01.12.91 - no need to read anything but
13  * the header into memory.  The inode of the executable is put into
14  * "current->executable", and page faults do the actual loading.  Clean.
15  *
16  * Once more I can proudly say that linux stood up to being changed: it
17  * was less than 2 hours work to get demand-loading completely implemented.
18  */
   /*
    * 需求时加载是于 1991.12.1 实现的 - 只需将执行文件头部分读进内存而无须
    * 将整个执行文件都加载进内存。执行文件的 i 节点被放在当前进程的可执行字段中
    * ("current->executable")，而页异常会进行执行文件的实际加载操作以及清理工作。
    *
    * 我可以再一次自豪地说，linux 经得起修改：只用了不到 2 小时的工作时间就完全
    * 实现了需求加载处理。
    */
19
20 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
21 #include <string.h>       // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
22 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
23 #include <a.out.h>        // a.out 头文件。定义了 a.out 执行文件格式和一些宏。
24
25 #include <linux/fs.h>     // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
26 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
27 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
28 #include <linux/mm.h>     // 内存管理头文件。含有页面大小定义和一些页面释放函数原型。
29 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
30
31 extern int sys_exit(int exit_code);  // 程序退出系统调用。
32 extern int sys_close(int fd);        // 文件关闭系统调用。
33
34 /*
35  * MAX_ARG_PAGES defines the number of pages allocated for arguments
36  * and envelope for the new program. 32 should suffice, this gives
37  * a maximum env+arg of 128kB !
38  */
   /*
    * MAX_ARG_PAGES 定义了新程序分配给参数和环境变量使用的内存最大页数。
    * 32 页内存应该足够了，这使得环境和参数(env+arg)空间的总合达到 128kB!
    */
39 #define MAX_ARG_PAGES 32
40
```

```
41 /*
42  * create_tables() parses the env- and arg-strings in new user
43  * memory and creates the pointer tables from them, and puts their
44  * addresses on the "stack", returning the new stack pointer value.
45  */
   /*
    * create_tables()函数在新用户内存中解析环境变量和参数字符串，由此
    * 创建指针表，并将它们的地址放到"堆栈"上，然后返回新栈的指针值。
    */
   //// 在新用户堆栈中创建环境和参数变量指针表。
   // 参数：p - 以数据段为起点的参数和环境信息偏移指针；argc - 参数个数；envc -环境变量数。
   // 返回：堆栈指针。
46 static unsigned long * create_tables(char * p,int argc,int envc)
47 {
48         unsigned long *argv,*envp;
49         unsigned long * sp;
50
   // 堆栈指针是以 4 字节（1 节）为边界寻址的，因此这里让 sp 为 4 的整数倍。
51         sp = (unsigned long *) (0xfffffffc & (unsigned long) p);
   // sp 向下移动，空出环境参数占用的空间个数，并让环境参数指针 envp 指向该处。
52         sp -= envc+1;
53         envp = sp;
   // sp 向下移动，空出命令行参数指针占用的空间个数，并让 argv 指针指向该处。
   // 下面指针加 1，sp 将递增指针宽度字节值。
54         sp -= argc+1;
55         argv = sp;
   // 将环境参数指针 envp 和命令行参数指针以及命令行参数个数压入堆栈。
56         put_fs_long((unsigned long)envp,--sp);
57         put_fs_long((unsigned long)argv,--sp);
58         put_fs_long((unsigned long)argc,--sp);
   // 将命令行各参数指针放入前面空出来的相应地方，最后放置一个 NULL 指针。
59         while (argc-->0) {
60                 put_fs_long((unsigned long) p,argv++);
61                 while (get_fs_byte(p++)) /* nothing */ ;  // p 指针前移 4 字节。
62         }
63         put_fs_long(0,argv);
   // 将环境变量各指针放入前面空出来的相应地方，最后放置一个 NULL 指针。
64         while (envc-->0) {
65                 put_fs_long((unsigned long) p,envp++);
66                 while (get_fs_byte(p++)) /* nothing */ ;
67         }
68         put_fs_long(0,envp);
69         return sp;                      // 返回构造的当前新堆栈指针。
70 }
71
72 /*
73  * count() counts the number of arguments/envelopes
74  */
   /*
    * count()函数计算命令行参数/环境变量的个数。
    */
   //// 计算参数个数。
   // 参数：argv - 参数指针数组，最后一个指针项是 NULL。
```

```
    // 返回：参数个数。
 75 static int count(char ** argv)
 76 {
 77         int i=0;
 78         char ** tmp;
 79
 80         if (tmp = argv)
 81                 while (get_fs_long((unsigned long *) (tmp++)))
 82                         i++;
 83
 84         return i;
 85 }
 86
 87 /*
 88  * 'copy_string()' copies argument/envelope strings from user
 89  * memory to free pages in kernel mem. These are in a format ready
 90  * to be put directly into the top of new user memory.
 91  *
 92  * Modified by TYT, 11/24/91 to add the from_kmem argument, which specifies
 93  * whether the string and the string array are from user or kernel segments:
 94  *
 95  * from_kmem     argv *        argv **
 96  *    0          user space    user space
 97  *    1          kernel space  user space
 98  *    2          kernel space  kernel space
 99  *
100  * We do this by playing games with the fs segment register.  Since it
101  * it is expensive to load a segment register, we try to avoid calling
102  * set_fs() unless we absolutely have to.
103  */
    /*
     * 'copy_string()'函数从用户内存空间拷贝参数和环境字符串到内核空闲页面内存中。
     * 这些已具有直接放到新用户内存中的格式。
     *
     * 由 TYT(Tytso)于 1991.12.24 日修改，增加了 from_kmem 参数，该参数指明了字符串或
     * 字符串数组是来自用户段还是内核段。
     *
     * from_kmem    argv *       argv **
     *    0         用户空间     用户空间
     *    1         内核空间     用户空间
     *    2         内核空间     内核空间
     *
     * 我们是通过巧妙处理 fs 段寄存器来操作的。由于加载一个段寄存器代价太大，所以
     * 我们尽量避免调用 set_fs()，除非实在必要。
     */
    //// 复制指定个数的参数字符串到参数和环境空间。
    // 参数：argc - 欲添加的参数个数；argv - 参数指针数组；page - 参数和环境空间页面指针数组。
    //       p -在参数表空间中的偏移指针，始终指向已复制串的头部；from_kmem - 字符串来源标志。
    // 在 do_execve()函数中，p 初始化为指向参数表(128kB)空间的最后一个长字处，参数字符串
    // 是以堆栈操作方式逆向往其中复制存放的，因此 p 指针会始终指向参数字符串的头部。
    // 返回：参数和环境空间当前头部指针。
104 static unsigned long copy_strings(int argc,char ** argv,unsigned long *page,
105                 unsigned long p, int from_kmem)
```

```
106 {
107         char *tmp, *pag;
108         int len, offset = 0;
109         unsigned long old_fs, new_fs;
110
111         if (!p)
112                 return 0;       /* bullet-proofing */  /* 偏移指针验证 */
    // 取 ds 寄存器值到 new_fs，并保存原 fs 寄存器值到 old_fs。
113         new_fs = get_ds();
114         old_fs = get_fs();
    // 如果字符串和字符串数组来自内核空间，则设置 fs 段寄存器指向内核数据段（ds）。
115         if (from_kmem==2)
116                 set_fs(new_fs);
    // 循环处理各个参数，从最后一个参数逆向开始复制，复制到指定偏移地址处。
117         while (argc-- > 0) {
    // 如果字符串在用户空间而字符串数组在内核空间，则设置 fs 段寄存器指向内核数据段（ds）。
118                 if (from_kmem == 1)
119                         set_fs(new_fs);
    // 从最后一个参数开始逆向操作，取 fs 段中最后一参数指针到 tmp，如果为空，则出错死机。
120                 if (!(tmp = (char *)get_fs_long(((unsigned long *)argv)+argc)))
121                         panic("argc is wrong");
    // 如果字符串在用户空间而字符串数组在内核空间，则恢复 fs 段寄存器原值。
122                 if (from_kmem == 1)
123                         set_fs(old_fs);
    // 计算该参数字符串长度 len，并使 tmp 指向该参数字符串末端。
124                 len=0;          /* remember zero-padding */
125                 do {            /* 我们知道串是以 NULL 字节结尾的 */
126                         len++;
127                 } while (get_fs_byte(tmp++));
    // 如果该字符串长度超过此时参数和环境空间中还剩余的空闲长度，则恢复 fs 段寄存器并返回 0。
128                 if (p-len < 0) {        /* this shouldn't happen - 128kB */
129                         set_fs(old_fs); /* 不会发生-因为有 128kB 的空间 */
130                         return 0;
131                 }
    // 复制 fs 段中当前指定的参数字符串，是从该字符串尾逆向开始复制。
132                 while (len) {
133                         --p; --tmp; --len;
    // 函数刚开始执行时，偏移变量 offset 被初始化为 0，因此若 offset-1<0，说明是首次复制字符串，
    // 则令其等于 p 指针在页面内的偏移值，并申请空闲页面。
134                         if (--offset < 0) {
135                                 offset = p % PAGE_SIZE;
    // 如果字符串和字符串数组在内核空间，则恢复 fs 段寄存器原值。
136                                 if (from_kmem==2)
137                                         set_fs(old_fs);
    // 如果当前偏移值 p 所在的串空间页面指针数组项 page[p/PAGE_SIZE]==0，表示相应页面还不存在，
    // 则需申请新的内存空闲页面，将该页面指针填入指针数组，并且也使 pag 指向该新页面，若申请不
    // 到空闲页面则返回 0。
138                                 if (!(pag = (char *) page[p/PAGE_SIZE]) &&
139                                     !(pag = (char *) page[p/PAGE_SIZE] =
140                                       (unsigned long *) get_free_page()))
141                                         return 0;
    // 如果字符串和字符串数组来自内核空间，则设置 fs 段寄存器指向内核数据段（ds）。
142                                 if (from_kmem==2)
```

```
143                                     set_fs(new_fs);
144
145                         }
    // 从 fs 段中复制参数字符串中一字节到 pag+offset 处。
146                         *(pag + offset) = get_fs_byte(tmp);
147                 }
148         }
    // 如果字符串和字符串数组在内核空间，则恢复 fs 段寄存器原值。
149         if (from_kmem==2)
150                 set_fs(old_fs);
    // 最后，返回参数和环境空间中已复制参数信息的头部偏移值。
151         return p;
152 }
153
    //// 修改局部描述符表中的描述符基址和段限长，并将参数和环境空间页面放置在数据段末端。
    // 参数：text_size - 执行文件头部中 a_text 字段给出的代码段长度值；
    //       page - 参数和环境空间页面指针数组。
    // 返回：数据段限长值(64MB)。
154 static unsigned long change_ldt(unsigned long text_size,unsigned long * page)
155 {
156         unsigned long code_limit,data_limit,code_base,data_base;
157         int i;
158
    // 根据执行文件头部 a_text 值，计算以页面长度为边界的代码段限长。并设置数据段长度为 64MB。
159         code_limit = text_size+PAGE_SIZE -1;
160         code_limit &= 0xFFFFF000;
161         data_limit = 0x4000000;
    // 取当前进程中局部描述符表代码段描述符中代码段基址，代码段基址与数据段基址相同。
162         code_base = get_base(current->ldt[1]);
163         data_base = code_base;
    // 重新设置局部表中代码段和数据段描述符的基址和段限长。
164         set_base(current->ldt[1],code_base);
165         set_limit(current->ldt[1],code_limit);
166         set_base(current->ldt[2],data_base);
167         set_limit(current->ldt[2],data_limit);
168 /* make sure fs points to the NEW data segment */
    /* 要确信 fs 段寄存器已指向新的数据段 */
    // fs 段寄存器中放入局部表数据段描述符的选择符(0x17)。
169         __asm__("pushl $0x17\n\tpop %%fs"::);
    // 将参数和环境空间已存放数据的页面（共可有 MAX_ARG_PAGES 页，128kB）放到数据段线性地址的
    // 末端。是调用函数 put_page()进行操作的（mm/memory.c, 197）。
170         data_base += data_limit;
171         for (i=MAX_ARG_PAGES-1 ; i>=0 ; i--) {
172                 data_base -= PAGE_SIZE;
173                 if (page[i])                            // 如果该页面存在，
174                         put_page(page[i],data_base);    // 就放置该页面。
175         }
176         return data_limit;                              // 最后返回数据段限长(64MB)。
177 }
178
179 /*
180  * 'do_execve()' executes a new program.
181  */
```

```
    /*
     * 'do_execve()'函数执行一个新程序。
     */
    //// execve()系统中断调用函数。加载并执行子进程（其他程序）。
    // 该函数系统中断调用(int 0x80)功能号__NR_execve 调用的函数。
    // 参数：eip - 指向堆栈中调用系统中断的程序代码指针 eip 处，参见 kernel/system_call.s 程序
    // 开始部分的说明；tmp - 系统中断中在调用_sys_execve 时的返回地址，无用；
    //       filename - 被执行程序文件名；argv - 命令行参数指针数组；envp - 环境变量指针数组。
    // 返回：如果调用成功，则不返回；否则设置出错号，并返回-1。
182 int do_execve(unsigned long * eip,long tmp,char * filename,
183         char ** argv, char ** envp)
184 {
185         struct m_inode * inode;                 // 内存中 I 节点指针结构变量。
186         struct buffer_head * bh;                // 高速缓存块头指针。
187         struct exec ex;                         // 执行文件头部数据结构变量。
188         unsigned long page[MAX_ARG_PAGES];      // 参数和环境字符串空间的页面指针数组。
189         int i,argc,envc;
190         int e_uid, e_gid;                       // 有效用户 id 和有效组 id。
191         int retval;                             // 返回值。
192         int sh_bang = 0;                        // 控制是否需要执行脚本处理代码。
    // 参数和环境字符串空间中的偏移指针，初始化为指向该空间的最后一个长字处。
193         unsigned long p=PAGE_SIZE*MAX_ARG_PAGES-4;
194
    // eip[1]中是原代码段寄存器 cs，其中的选择符不可以是内核段选择符，也即内核不能调用本函数。
195         if ((0xffff & eip[1]) != 0x000f)
196                 panic("execve called from supervisor mode");
    // 初始化参数和环境串空间的页面指针数组（表）。
197         for (i=0 ; i<MAX_ARG_PAGES ; i++)       /* clear page-table */
198                 page[i]=0;
    // 取可执行文件的对应 i 节点号。
199         if (!(inode=namei(filename)))           /* get executables inode */
200                 return -ENOENT;
    // 计算参数个数和环境变量个数。
201         argc = count(argv);
202         envc = count(envp);
203
    // 执行文件必须是常规文件。若不是常规文件则置出错返回码，跳转到 exec_error2(第 347 行)。
204 restart_interp:
205         if (!S_ISREG(inode->i_mode)) {  /* must be regular file */
206                 retval = -EACCES;
207                 goto exec_error2;
208         }
    // 以下检查被执行文件的执行权限。根据其属性(对应 i 节点的 uid 和 gid)，看本进程是否有权执行它。
209         i = inode->i_mode;                      // 取文件属性字段值。
    // 如果文件的设置用户 ID 标志（set-user-id）置位的话，则后面执行进程的有效用户 ID（euid）就
    // 设置为文件的用户 ID，否则设置成当前进程的 euid。这里将该值暂时保存在 e_uid 变量中。
    // 如果文件的设置组 ID 标志（set-group-id）置位的话，则执行进程的有效组 ID（egid）就设置为
    // 文件的组 ID。否则设置成当前进程的 egid。
210         e_uid = (i & S_ISUID) ? inode->i_uid : current->euid;
211         e_gid = (i & S_ISGID) ? inode->i_gid : current->egid;
    // 如果文件属于运行进程的用户，则把文件属性字右移 6 位，则最低 3 位是文件宿主的访问权限标志。
    // 否则的话如果文件与运行进程的用户属于同组，则使属性字最低 3 位是文件组用户的访问权限标志。
    // 否则属性字最低 3 位是其他用户访问该文件的权限。
```

```
212         if (current->euid == inode->i_uid)
213                 i >>= 6;
214         else if (current->egid == inode->i_gid)
215                 i >>= 3;
    // 如果上面相应用户没有执行权并且其他用户也没有任何权限，并且不是超级用户，则表明该文件不
    // 能被执行。于是置不可执行出错码，跳转到 exec_error2 处去处理。
216         if (!(i & 1) &&
217             !((inode->i_mode & 0111) && suser())) {
218                 retval = -ENOEXEC;
219                 goto exec_error2;
220         }
    // 读取执行文件的第一块数据到高速缓冲区，若出错则置出错码，跳转到 exec_error2 处去处理。
221         if (!(bh = bread(inode->i_dev,inode->i_zone[0]))) {
222                 retval = -EACCES;
223                 goto exec_error2;
224         }
    // 下面对执行文件的头结构数据进行处理，首先让 ex 指向执行头部分的数据结构。
225         ex = *((struct exec *) bh->b_data);     /* read exec-header */ /* 读取执行头部分 */
    // 如果执行文件开始的两个字节为'#!'，并且 sh_bang 标志没有置位，则处理脚本文件的执行。
226         if ((bh->b_data[0] == '#') && (bh->b_data[1] == '!') && (!sh_bang)) {
227                 /*
228                  * This section does the #! interpretation.
229                  * Sorta complicated, but hopefully it will work.  -TYT
230                  */
                /*
                 * 这部分处理对'#!'的解释，有些复杂，但希望能工作。-TYT
                 */
231
232                 char buf[1023], *cp, *interp, *i_name, *i_arg;
233                 unsigned long old_fs;
234
    // 复制执行程序头一行字符'#!'后面的字符串到 buf 中，其中含有脚本处理程序名。
235                 strncpy(buf, bh->b_data+2, 1022);
    // 释放高速缓冲块和该执行文件 i 节点。
236                 brelse(bh);
237                 iput(inode);
    // 取第一行内容，并删除开始的空格、制表符。
238                 buf[1022] = '\0';
239                 if (cp = strchr(buf, '\n')) {
240                         *cp = '\0';
241                         for (cp = buf; (*cp == ' ') || (*cp == '\t'); cp++);
242                 }
    // 若该行没有其他内容，则出错。置出错码，跳转到 exec_error1 处。
243                 if (!cp || *cp == '\0') {
244                         retval = -ENOEXEC; /* No interpreter name found */
245                         goto exec_error1;
246                 }
    // 否则就得到了开头是脚本解释执行程序名称的一行内容。
247                 interp = i_name = cp;
    // 下面分析该行。首先取第一个字符串，其应该是脚本解释程序名，iname 指向该名称。
248                 i_arg = 0;
249                 for ( ; *cp && (*cp != ' ') && (*cp != '\t'); cp++) {
250                         if (*cp == '/')
```

```
251                             i_name = cp+1;
252                     }
    // 若文件名后还有字符，则应该是参数串，令 i_arg 指向该串。
253                     if (*cp) {
254                             *cp++ = '\0';
255                             i_arg = cp;
256                     }
257                     /*
258                      * OK, we've parsed out the interpreter name and
259                      * (optional) argument.
260                      */
                        /*
                         * OK，我们已经解析出解释程序的文件名以及(可选的)参数。
                         */
    // 若 sh_bang 标志没有设置，则设置它，并复制指定个数的环境变量串和参数串到参数和环境空间中。
261                     if (sh_bang++ == 0) {
262                             p = copy_strings(envc, envp, page, p, 0);
263                             p = copy_strings(--argc, argv+1, page, p, 0);
264                     }
265                     /*
266                      * Splice in (1) the interpreter's name for argv[0]
267                      *           (2) (optional) argument to interpreter
268                      *           (3) filename of shell script
269                      *
270                      * This is done in reverse order, because of how the
271                      * user environment and arguments are stored.
272                      */
                        /*
                         * 拼接 (1) argv[0]中放解释程序的名称
                         *      (2) (可选的)解释程序的参数
                         *      (3) 脚本程序的名称
                         *
                         * 这是以逆序进行处理的，是由于用户环境和参数的存放方式造成的。
                         */
    // 复制脚本程序文件名到参数和环境空间中。
273                     p = copy_strings(1, &filename, page, p, 1);
    // 复制解释程序的参数到参数和环境空间中。
274                     argc++;
275                     if (i_arg) {
276                             p = copy_strings(1, &i_arg, page, p, 2);
277                             argc++;
278                     }
    // 复制解释程序文件名到参数和环境空间中。若出错，则置出错码，跳转到 exec_error1。
279                     p = copy_strings(1, &i_name, page, p, 2);
280                     argc++;
281                     if (!p) {
282                             retval = -ENOMEM;
283                             goto exec_error1;
284                     }
285                     /*
286                      * OK, now restart the process with the interpreter's inode.
287                      */
                        /*
```

```
                 * OK，现在使用解释程序的 i 节点重启进程。
                 */
    // 保留原 fs 段寄存器（原指向用户数据段），现置其指向内核数据段。
288                 old_fs = get_fs();
289                 set_fs(get_ds());
    // 取解释程序的 i 节点，并跳转到 restart_interp 处重新处理。
290                 if (!(inode=namei(interp))) { /* get executables inode */
291                         set_fs(old_fs);
292                         retval = -ENOENT;
293                         goto exec_error1;
294                 }
295                 set_fs(old_fs);
296                 goto restart_interp;
297         }
    // 释放该缓冲区。
298         brelse(bh);
    // 下面对执行头信息进行处理。
    // 对于下列情况，将不执行程序：如果执行文件不是需求页可执行文件(ZMAGIC)、或者代码重定位部分
    // 长度 a_trsize 不等于 0、或者数据重定位信息长度不等于 0、或者代码段+数据段+堆段长度超过 50MB、
    // 或者 i 节点表明的该执行文件长度小于代码段+数据段+符号表长度+执行头部分长度的总和。
299         if (N_MAGIC(ex) != ZMAGIC || ex.a_trsize || ex.a_drsize ||
300                 ex.a_text+ex.a_data+ex.a_bss>0x3000000 ||
301                 inode->i_size < ex.a_text+ex.a_data+ex.a_syms+N_TXTOFF(ex)) {
302                 retval = -ENOEXEC;
303                 goto exec_error2;
304         }
    // 如果执行文件执行头部分长度不等于一个内存块大小（1024 字节），也不能执行。转 exec_error2。
305         if (N_TXTOFF(ex) != BLOCK_SIZE) {
306                 printk("%s: N_TXTOFF != BLOCK_SIZE. See a.out.h.", filename);
307                 retval = -ENOEXEC;
308                 goto exec_error2;
309         }
    // 如果 sh_bang 标志没有设置，则复制指定个数的环境变量字符串和参数到参数和环境空间中。
    // 若 sh_bang 标志已经设置，则表明是将运行脚本程序，此时环境变量页面已经复制，无须再复制。
310         if (!sh_bang) {
311                 p = copy_strings(envc,envp,page,p,0);
312                 p = copy_strings(argc,argv,page,p,0);
    // 如果 p=0，则表示环境变量与参数空间页面已经被占满，容纳不下了。转至出错处理处。
313                 if (!p) {
314                         retval = -ENOMEM;
315                         goto exec_error2;
316                 }
317         }
318 /* OK, This is the point of no return */
    /* OK，下面开始就没有返回的地方了 */
    // 如果原程序也是一个执行程序，则释放其 i 节点，并让进程 executable 字段指向新程序 i 节点。
319         if (current->executable)
320                 iput(current->executable);
321         current->executable = inode;
    // 清复位所有信号处理句柄。但对于 SIG_IGN 句柄不能复位，因此在 322 与 323 行之间需添加一条
    // if 语句：if (current->sa[I].sa_handler != SIG_IGN)。这是源代码中的一个 bug。
322         for (i=0 ; i<32 ; i++)
323                 current->sigaction[i].sa_handler = NULL;
```

```
    // 根据执行时关闭(close_on_exec)文件句柄位图标志，关闭指定的打开文件，并复位该标志。
324         for (i=0 ; i<NR_OPEN ; i++)
325                 if ((current->close_on_exec>>i)&1)
326                         sys_close(i);
327         current->close_on_exec = 0;
    // 根据指定的基地址和限长，释放原来进程代码段和数据段所对应的内存页表指定的内存块及页表本
身。
    // 此时被执行程序没有占用主内存区任何页面。在执行时会引起内存管理程序执行缺页处理而为其申请
    // 内存页面，并把程序读入内存。
328         free_page_tables(get_base(current->ldt[1]),get_limit(0x0f));
329         free_page_tables(get_base(current->ldt[2]),get_limit(0x17));
    // 如果“上次任务使用了协处理器”指向的是当前进程，则将其置空，并复位使用了协处理器的标志。
330         if (last_task_used_math == current)
331                 last_task_used_math = NULL;
332         current->used_math = 0;
    // 根据 a_text 修改局部表中描述符基址和段限长，并将参数和环境空间页面放置在数据段末端。
    // 执行下面语句之后，p 此时是以数据段起始处为原点的偏移值，仍指向参数和环境空间数据开始处，
    // 也即转换成为堆栈的指针。
333         p += change_ldt(ex.a_text,page)-MAX_ARG_PAGES*PAGE_SIZE;
    // create_tables()在新用户堆栈中创建环境和参数变量指针表，并返回该堆栈指针。
334         p = (unsigned long) create_tables((char *)p,argc,envc);
    // 修改当前进程各字段为新执行程序的信息。令进程代码段尾值字段 end_code = a_text；令进程数据
    // 段尾字段 end_data = a_data + a_text；令进程堆结尾字段 brk = a_text + a_data + a_bss。
335         current->brk = ex.a_bss +
336                 (current->end_data = ex.a_data +
337                 (current->end_code = ex.a_text));
    // 设置进程堆栈开始字段为堆栈指针所在的页面，并重新设置进程的有效用户 id 和有效组 id。
338         current->start_stack = p & 0xfffff000;
339         current->euid = e_uid;
340         current->egid = e_gid;
    // 初始化一页 bss 段数据，全为零。
341         i = ex.a_text+ex.a_data;
342         while (i&0xfff)
343                 put_fs_byte(0,(char *) (i++));
    // 将原调用系统中断的程序在堆栈上的代码指针替换为指向新执行程序的入口点，并将堆栈指针替换
    // 为新执行程序的堆栈指针。返回指令将弹出这些堆栈数据并使得 CPU 去执行新的执行程序，因此不会
    // 返回到原调用系统中断的程序中去了。
344         eip[0] = ex.a_entry;            /* eip, magic happens :-) */ /* eip，魔法起作用了*/
345         eip[3] = p;                     /* stack pointer */          /* esp，堆栈指针 */
346         return 0;
347 exec_error2:
348         iput(inode);
349 exec_error1:
350         for (i=0 ; i<MAX_ARG_PAGES ; i++)
351                 free_page(page[i]);
352         return(retval);
353 }
354
```

9.17.3 其他信息

9.17.3.1 a.out 执行文件格式

Linux 内核 0.11 版仅支持 a.out(Assembley & link editor output)执行文件格式，虽然这种格式目前已经

渐渐不用，而使用功能更为齐全的 ELF（Executable and Link Format）格式，但是由于其简单性，作为学习入门的材料正好比较适用。下面全面介绍一下 a.out 格式。

在头文件<a.out.h>中声明了三个数据结构以及一些宏函数。这些数据结构描述了系统上可执行的机器码文件（二进制文件）。

一个执行文件共可有七个部分（七节）组成。按照顺序，这些部分是：

执行头部分(exec header)

执行文件头部分。该部分中含有一些参数，内核使用这些参数将执行文件加载到内存中并执行，而链接程序(ld)使用这些参数将一些二进制目标文件组合成一个可执行文件。这是唯一必要的组成部分。

代码段部分(text segment)

含有程序执行使被加载到内存中的指令代码和相关数据。可以以只读形式进行加载。

数据段部分(data segment)

这部分含有已经初始化过的数据，总是被加载到可读写的内存中。

代码重定位部分(text relocations)

这部分含有供链接程序使用的记录数据。在组合二进制目标文件时用于定位代码段中的指针或地址。

数据重定位部分(data relocations)

与代码重定位部分的作用类似，但是是用于数据段中指针的重定位。

符号表部分(simbol table)

这部分同样含有供链接程序使用的记录数据，用于在二进制目标文件之间对命名的变量和函数（符号）进行交叉引用。

字符串表部分(string table)

该部分含有与符号名相对应的字符串。

每个二进制执行文件均以一个执行数据结构（exec structure）开始。该数据结构的形式如下：

```
struct exec {
        unsigned long a_midmag;
        unsigned long a_text;
        unsigned long a_data;
        unsigned long a_bss;
        unsigned long a_syms;
        unsigned long a_entry;
        unsigned long a_trsize;
        unsigned long a_drsize;
};
```

各个字段的功能如下：

a_midmag - 该字段含有被 N_GETFLAG()、N_GETMID 和 N_GETMAGIC()访问的子部分，是由链接程序在运行时加载到进程地址空间。宏 N_GETMID()用于返回机器标识符(machine-id)，指示出二进制文件将在什么机器上运行。N_GETMAGIC()宏指明魔数，它唯一地确定了二进制执行文件与其他加载的文件之间的区别。字段中必须包含以下值之一：

- OMAGIC - 表示代码和数据段紧随在执行头后面并且是连续存放的。内核将代码和数据段都加载到可读写内存中。
- NMAGIC - 同 OMAGIC 一样，代码和数据段紧随在执行头后面并且是连续存放的。然而内核将代码加载到了只读内存中，并把数据段加载到代码段后下一页可读写内存边界开始。
- ZMAGIC - 内核在必要时从二进制执行文件中加载独立的页面。执行头部、代码段和数据段都被链接程序处理成多个页面大小的块。内核加载的代码页面时只读的，而数据段的页面是可写的。

a_text - 该字段含有代码段的长度值，字节数。

a_data - 该字段含有数据段的长度值，字节数。

a_bss - 含有‘bss 段’的长度，内核用其设置在数据段后初始的 break（brk）。内核在加载程序时，这段可写内存显现出处于数据段后面，并且初始时为全零。

a_syms - 含有符号表部分的字节长度值。

a_entry - 含有内核将执行文件加载到内存中以后，程序执行起始点的内存地址。

a_trsize - 该字段含有代码重定位表的大小，是字节数。

a_drsize - 该字段含有数据重定位表的大小，是字节数。

在 a.out.h 头文件中定义了几个宏，这些宏使用 exec 结构来测试一致性或者定位执行文件中各个部分（节）的位置偏移值。这些宏有：

- N_BADMAG(exec) 如果 a_magic 字段不能被识别，则返回非零值。
- N_TXTOFF(exec) 代码段的起始位置字节偏移值。
- N_DATOFF(exec) 数据段的起始位置字节偏移值。
- N_DRELOFF(exec) 数据重定位表的起始位置字节偏移值。
- N_TRELOFF(exec) 代码重定位表的起始位置字节偏移值。
- N_SYMOFF(exec) 符号表的起始位置字节偏移值。
- N_STROFF(exec) 字符串表的起始位置字节偏移值。

重定位记录具有标准格式，它使用重定位信息(relocation_info)结构来描述：

```
struct relocation_info {
        int             r_address;
        unsigned int    r_symbolnum : 24,
                        r_pcrel : 1,
                        r_length : 2,
                        r_extern : 1,
                        r_baserel : 1,
                        r_jmptable : 1,
                        r_relative : 1,
                        r_copy : 1;
};
```

该结构中各字段的含义如下：

r_address - 该字段含有需要链接程序处理（编辑）的指针的字节偏移值。代码重定位的偏移值是从代码段开始处计数的，数据重定位的偏移值是从数据段开始处计算的。链接程序会将已经存储在该偏移处的值与使用重定位记录计算出的新值相加。

r_symbolnum - 该字段含有符号表中一个符号结构的序号值（不是字节偏移值）。链接程序在算出符号的绝对地址以后，就将该地址加到正在进行重定位的指针上。（如果 r_extern 比特位是 0，那么情况就不同，见下面。）

r_pcrel - 如果设置了该位，链接程序就认为正在更新一个指针，该指针使用 pc 相关寻址方式，是属于机器码指令部分。当运行程序使用这个被重定位的指针时，该指针的地址被隐式地加到该指针上。

r_length - 该字段含有指针长度的 2 的次方值：0 表示 1 字节长，1 表示 2 字节长，2 表示 4 字节长。

r_extern - 如果被置位，表示该重定位需要一个外部引用；此时链接程序必须使用一个符号地址来更新相应指针。当该位是 0 时，则重定位是“局部”的；链接程序更新指针以反映各个段加载地址中的变化，而不是反映一个符号值的变化（除非同时设置了 r_baserel，见下面）。在这种情况下，r_symbolnum 字段的内容是一个 n_type 值（见下面）；这类字段告诉链接程序被重定位的指针指向那个段。

r_baserel - 如果设置了该位，则 r_symbolnum 字段指定的符号将被重定位成全局偏移表(Global Offset

Table)中的一个偏移值。在运行时刻，全局偏移表该偏移处被设置为符号的地址。

r_jmptable - 如果被置位，则 r_symbolnum 字段指定的符号将被重定位成过程链接表(Procedure Linkage Table)中的一个偏移值。

r_relative - 如果被置位，则说明此重定位与该目标文件将成为其组成部分的映像文件在运行时被加载的地址相关。这类重定位仅在共享目标文件中出现。

r_copy - 如果被置位，该重定位记录指定了一个符号，该符号的内容将被复制到 r_address 指定的地方。该复制操作是通过共享目标模块中一个合适的数据项中的运行时刻链接程序完成的。

符号将名称映射为地址（或者更通俗地讲是字符串映射到值）。由于链接程序对地址的调整，一个符号的名称必须用来表示其地址，直到已被赋予一个绝对地址值。符号是由符号表中固定长度的记录以及字符串表中的可变长度名称组成。符号表是 nlist 结构的一个数组，如下所示：

```
struct nlist {
        union {
                char    *n_name;
                long    n_strx;
        } n_un;
        unsigned char   n_type;
        char            n_other;
        short           n_desc;
        unsigned long   n_value;
};
```

其中各字段的含义为：

n_un.n_strx - 含有本符号的名称在字符串表中的字节偏移值。当程序使用 nlist()函数访问一个符号表时，该字段被替换为 n_un.n_name 字段，这是内存中字符串的指针。

n_type - 用于链接程序确定如何更新符号的值。使用位屏蔽(bitmasks)可以将 n_type 字段分割成三个子字段，对于 N_EXT 类型位置位的符号，链接程序将它们看作是“外部的”符号，并且允许其他二进制目标文件对它们的引用。N_TYPE 屏蔽码用于链接程序感兴趣的比特位：

- N_UNDF - 一个未定义的符号。链接程序必须在其他二进制目标文件中定位一个具有相同名称的外部符号，以确定该符号的绝对数据值。特殊情况下，如果 n_type 字段是非零值，并且没有二进制文件定义了这个符号，则链接程序在 BSS 段中将该符号解析为一个地址，保留长度等于 n_value 的字节。如果符号在多于一个二进制目标文件中都没有定义并且这些二进制目标文件对其长度值不一致，则链接程序将选择所有二进制目标文件中最大的长度。
- N_ABS - 一个绝对符号。链接程序不会更新一个绝对符号。
- N_TEXT - 一个代码符号。该符号的值是代码地址，链接程序在合并二进制目标文件时会更新其值。
- N_DATA - 一个数据符号；与 N_TEXT 类似，但是用于数据地址。对应代码和数据符号的值不是文件的偏移值而是地址；为了找出文件的偏移，就有必要确定相关部分开始加载的地址并减去它，然后加上该部分的偏移。
- N_BSS - 一个 BSS 符号；与代码或数据符号类似，但在二进制目标文件中没有对应的偏移。
- N_FN - 一个文件名符号。在合并二进制目标文件时，链接程序会将该符号插入在二进制文件中的符号之前。符号的名称就是给予链接程序的文件名，而其值是二进制文件中首个代码段地址。链接和加载时不需要文件名符号，但对于调式程序非常有用。
- N_STAB - 屏蔽码用于选择符号调式程序(例如 gdb)感兴趣的位；其值在 stab()中说明。

n_other - 该字段按照 n_type 确定的段，提供有关符号重定位操作的符号独立性信息。目前，n_other 字段的最低 4 位含有两个值之一：AUX_FUNC 和 AUX_OBJECT（有关定义参见<link.h>）。AUX_FUNC

将符号与可调用的函数相关，AUX_OBJECT 将符号与数据相关，而不管它们是位于代码段还是数据段。该字段主要用于链接程序 ld，用于动态可执行程序的创建。

n_desc - 保留给调式程序使用；链接程序不对其进行处理。不同的调试程序将该字段用作不同的用途。

n_value - 含有符号的值。对于代码、数据和 BSS 符号，这是一个地址；对于其他符号（例如调式程序符号），值可以是任意的。

字符串表是由长度为 u_int32_t 后跟一 null 结尾的符号字符串组成。长度代表整个表的字节大小，所以在 32 位的机器上其最小值（或者是第 1 个字符串的偏移）总是 4。

9.18 stat.c 程序

9.18.1 功能描述

该程序实现取文件状态信息系统调用 stat()和 fstat()，并将信息存放在用户的文件状态结构缓冲区中。stat()是利用文件名取信息，而 fstat()是使用文件句柄(描述符)来取信息。

9.18.2 代码注释

程序 9-16 linux/fs/stat.c

```
 1 /*
 2  *  linux/fs/stat.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
 8 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
 9
10 #include <linux/fs.h>     // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
11 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
12 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
13 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
14
   //// 复制文件状态信息。
   // 参数 inode 是文件对应的 i 节点，statbuf 是 stat 文件状态结构指针，用于存放取得的状态信息。
15 static void cp_stat(struct m_inode * inode, struct stat * statbuf)
16 {
17         struct stat tmp;
18         int i;
19
   // 首先验证(或分配)存放数据的内存空间。
20         verify_area(statbuf,sizeof (* statbuf));
   // 然后临时复制相应节点上的信息。
21         tmp.st_dev = inode->i_dev;        // 文件所在的设备号。
22         tmp.st_ino = inode->i_num;        // 文件 i 节点号。
23         tmp.st_mode = inode->i_mode;      // 文件属性。
```

```
24          tmp.st_nlink = inode->i_nlinks;    // 文件的连接数。
25          tmp.st_uid = inode->i_uid;         // 文件的用户 id。
26          tmp.st_gid = inode->i_gid;         // 文件的组 id。
27          tmp.st_rdev = inode->i_zone[0];    // 设备号(如果文件是特殊的字符文件或块文件)。
28          tmp.st_size = inode->i_size;       // 文件大小（字节数）（如果文件是常规文件）。
29          tmp.st_atime = inode->i_atime;     // 最后访问时间。
30          tmp.st_mtime = inode->i_mtime;     // 最后修改时间。
31          tmp.st_ctime = inode->i_ctime;     // 最后节点修改时间。
    // 最后将这些状态信息复制到用户缓冲区中。
32          for (i=0 ; i<sizeof (tmp) ; i++)
33                  put_fs_byte(((char *) &tmp)[i],&((char *) statbuf)[i]);
34  }
35
    //// 文件状态系统调用函数 - 根据文件名获取文件状态信息。
    // 参数 filename 是指定的文件名，statbuf 是存放状态信息的缓冲区指针。
    // 返回 0，若出错则返回出错码。
36  int sys_stat(char * filename, struct stat * statbuf)
37  {
38          struct m_inode * inode;
39
    // 首先根据文件名找出对应的 i 节点，若出错则返回错误码。
40          if (!(inode=namei(filename)))
41                  return -ENOENT;
    // 将 i 节点上的文件状态信息复制到用户缓冲区中，并释放该 i 节点。
42          cp_stat(inode,statbuf);
43          iput(inode);
44          return 0;
45  }
46
    //// 文件状态系统调用 - 根据文件句柄获取文件状态信息。
    // 参数 fd 是指定文件的句柄(描述符)，statbuf 是存放状态信息的缓冲区指针。
    // 返回 0，若出错则返回出错码。
47  int sys_fstat(unsigned int fd, struct stat * statbuf)
48  {
49          struct file * f;
50          struct m_inode * inode;
51
    // 如果文件句柄值大于一个程序最多打开文件数 NR_OPEN，或者该句柄的文件结构指针为空，或者
    // 对应文件结构的 i 节点字段为空，则出错，返回出错码并退出。
52          if (fd >= NR_OPEN || !(f=current->filp[fd]) || !(inode=f->f_inode))
53                  return -EBADF;
    // 将 i 节点上的文件状态信息复制到用户缓冲区中。
54          cp_stat(inode,statbuf);
55          return 0;
56  }
57
```

9.19 fcntl.c 程序

9.19.1 功能描述

从本节开始注释的一些文件，都属于对目录和文件进行操作的上层处理程序。

本文件fcntl.c实现了文件控制系统调用fcntl()和两个文件句柄(描述符)复制系统调用dup()和dup2()。dup2()指定了新句柄的数值，而dup()则返回当前值最小的未用句柄。句柄复制操作主要用在文件的标准输入/输出重定向和管道操作方面。

9.19.2 代码注释

程序 9-17 linux/fs/fcntl.c

```
 1 /*
 2  *  linux/fs/fcntl.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <string.h>       // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
 8 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
 9 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
10 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
11 #include <asm/segment.h>  // 段操作头文件。定义了有关段寄存器操作的嵌入式汇编函数。
12
13 #include <fcntl.h>        // 文件控制头文件。用于文件及其描述符的操作控制常数符号的定义。
14 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
15
16 extern int sys_close(int fd);     // 关闭文件系统调用。(fs/open.c, 192)
17
   //// 复制文件句柄(描述符)。
   // 参数 fd 是欲复制的文件句柄，arg 指定新文件句柄的最小数值。
   // 返回新文件句柄或出错码。
18 static int dupfd(unsigned int fd, unsigned int arg)
19 {
   // 如果文件句柄值大于一个程序最多打开文件数 NR_OPEN，或者该句柄的文件结构不存在，则出错，
   // 返回出错码并退出。
20         if (fd >= NR_OPEN || !current->filp[fd])
21                 return -EBADF;
   // 如果指定的新句柄值 arg 大于最多打开文件数，则出错，返回出错码并退出。
22         if (arg >= NR_OPEN)
23                 return -EINVAL;
   // 在当前进程的文件结构指针数组中寻找索引号大于等于 arg 但还没有使用的项。
24         while (arg < NR_OPEN)
25                 if (current->filp[arg])
26                         arg++;
27                 else
28                         break;
   // 如果找到的新句柄值 arg 大于最多打开文件数，则出错，返回出错码并退出。
```

```
29          if (arg >= NR_OPEN)
30                  return -EMFILE;
    // 在执行时关闭标志位图中复位该句柄位。也即在运行 exec()类函数时不关闭该句柄。
31          current->close_on_exec &= ~(1<<arg);
    // 令该文件结构指针等于原句柄 fd 的指针，并将文件引用计数增 1。
32          (current->filp[arg] = current->filp[fd])->f_count++;
33          return arg;             // 返回新的文件句柄。
34  }
35
    //// 复制文件句柄系统调用函数。
    // 复制指定文件句柄 oldfd，新句柄值等于 newfd。如果 newfd 已经打开，则首先关闭之。
36  int sys_dup2(unsigned int oldfd, unsigned int newfd)
37  {
38          sys_close(newfd);               // 若句柄 newfd 已经打开，则首先关闭之。
39          return dupfd(oldfd,newfd);      // 复制并返回新句柄。
40  }
41
    //// 复制文件句柄系统调用函数。
    // 复制指定文件句柄 oldfd，新句柄的值是当前最小的未用句柄。
42  int sys_dup(unsigned int fildes)
43  {
44          return dupfd(fildes,0);
45  }
46
    //// 文件控制系统调用函数。
    // 参数 fd 是文件句柄，cmd 是操作命令(参见 include/fcntl.h，23-30 行)。
47  int sys_fcntl(unsigned int fd, unsigned int cmd, unsigned long arg)
48  {
49          struct file * filp;
50
    // 如果文件句柄值大于一个进程最多打开文件数 NR_OPEN，或者该句柄的文件结构指针为空，则出错，
    // 返回出错码并退出。
51          if (fd >= NR_OPEN || !(filp = current->filp[fd]))
52                  return -EBADF;
    // 根据不同命令 cmd 进行分别处理。
53          switch (cmd) {
54                  case F_DUPFD:       // 复制文件句柄。
55                          return dupfd(fd,arg);
56                  case F_GETFD:       // 取文件句柄的执行时关闭标志。
57                          return (current->close_on_exec>>fd)&1;
58                  case F_SETFD:       // 设置句柄执行时关闭标志。arg 位 0 置位是设置，否则关闭。
59                          if (arg&1)
60                                  current->close_on_exec |= (1<<fd);
61                          else
62                                  current->close_on_exec &= ~(1<<fd);
63                          return 0;
64                  case F_GETFL:       // 取文件状态标志和访问模式。
65                          return filp->f_flags;
66                  case F_SETFL:       // 设置文件状态和访问模式(根据 arg 设置添加、非阻塞标志)。
67                          filp->f_flags &= ~(O_APPEND | O_NONBLOCK);
68                          filp->f_flags |= arg & (O_APPEND | O_NONBLOCK);
69                          return 0;
70                  case F_GETLK:   case F_SETLK:   case F_SETLKW:     // 未实现。
```

```
71                      return -1;
72              default:
73                      return -1;
74      }
75 }
76
```

9.20 ioctl.c 程序

9.20.1 功能描述

ioctl.c 文件实现了输入/输出控制系统调用 ioctl()。主要调用 tty_ioctl()函数，对终端的 I/O 进行控制。

9.20.2 代码注释

程序 9-18 linux/fs/ioctl.c

```
 1 /*
 2  *  linux/fs/ioctl.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <string.h>       // 字符串头文件。主要定义了一些有关字符串操作的嵌入函数。
 8 #include <errno.h>        // 错误号头文件。包含系统中各种出错号。(Linus 从 minix 中引进的)。
 9 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
10
11 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
12
13 extern int tty_ioctl(int dev, int cmd, int arg);  // 终端 ioctl(chr_drv/tty_ioctl.c, 115)。
14
   // 定义输入输出控制(ioctl)函数指针。
15 typedef int (*ioctl_ptr)(int dev,int cmd,int arg);
16
   // 定义系统中设备种数。
17 #define NRDEVS ((sizeof (ioctl_table))/(sizeof (ioctl_ptr)))
18
   // ioctl 操作函数指针表。
19 static ioctl_ptr ioctl_table[]={
20         NULL,           /* nodev */
21         NULL,           /* /dev/mem */
22         NULL,           /* /dev/fd */
23         NULL,           /* /dev/hd */
24         tty_ioctl,      /* /dev/ttyx */
25         tty_ioctl,      /* /dev/tty */
26         NULL,           /* /dev/lp */
27         NULL};          /* named pipes */
28
29
```

```
   //// 系统调用函数 - 输入输出控制函数。
   // 参数：fd - 文件描述符；cmd - 命令码；arg - 参数。
   // 返回：成功则返回 0，否则返回出错码。
30 int sys_ioctl(unsigned int fd, unsigned int cmd, unsigned long arg)
31 {
32         struct file * filp;
33         int dev,mode;
34
   // 如果文件描述符超出可打开的文件数，或者对应描述符的文件结构指针为空，则返回出错码，退出。
35         if (fd >= NR_OPEN || !(filp = current->filp[fd]))
36                 return -EBADF;
   // 取对应文件的属性。如果该文件不是字符文件，也不是块设备文件，则返回出错码，退出。
37         mode=filp->f_inode->i_mode;
38         if (!S_ISCHR(mode) && !S_ISBLK(mode))
39                 return -EINVAL;
   // 从字符或块设备文件的 i 节点中取设备号。如果设备号大于系统现有的设备数，则返回出错号。
40         dev = filp->f_inode->i_zone[0];
41         if (MAJOR(dev) >= NRDEVS)
42                 return -ENODEV;
   // 如果该设备在 ioctl 函数指针表中没有对应函数，则返回出错码。
43         if (!ioctl_table[MAJOR(dev)])
44                 return -ENOTTY;
   // 否则返回实际 ioctl 函数返回码，成功则返回 0，否则返回出错码。
45         return ioctl_table[MAJOR(dev)](dev,cmd,arg);
46 }
47
```

第10章 内存管理(mm)

10.1 概述

在 Intel 80x86 体系结构中，Linux 内核的内存管理程序采用了分页管理方式。利用页目录和页表结构处理内核中其他部分代码对内存的申请和释放操作。内存的管理是以内存页面为单位进行的，一个内存页面是指地址连续的 4K 字节物理内存。通过页目录项和页表项，可以寻址和管理指定页面的使用情况。在 Linux 0.11 的内存管理目录中共有三个文件，如列表 10-1 中所示：

列表 10-1 内存管理子目录文件列表

	名称	大小	最后修改时间(GMT)	说明
	Makefile	813 bytes	1991-12-02 03:21:45	m
	memory.c	11223 bytes	1991-12-03 00:48:01	m
	page.s	508 bytes	1991-10-02 14:16:30	m

其中，page.s 文件比较短，仅包含内存页异常的中断处理过程（int 14）。主要实现了对缺页和页写保护的处理。memory.c 是内存页面管理的核心文件，用于内存的初始化操作、页目录和页表的管理和内核其他部分对内存的申请处理过程。

10.2 总体功能描述

在 Intel 80X86 CPU 中，程序在寻址过程中使用的是由段和偏移值构成的地址。该地址并不能直接用来寻址物理内存地址，因此被称为虚拟地址。为了能寻址物理内存，就需要一种地址变换机制将虚拟地址映射或变换到物理内存中，这种地址变换机制就是内存管理的主要功能之一（内存管理的另外一个主要功能是内存的寻址保护机制。由于篇幅所限，本章不对其进行讨论）。虚拟地址通过段管理机制首先变换成一种中间地址形式—CPU 32 位的线性地址，然后使用分页管理机制将此线性地址映射到物理地址。

为了弄清 Linux 内核对内存的管理操作方式，我们需要了解内存分页管理的工作原理，了解其寻址的机制。分页管理的目的是将物理内存页面映射到某一线性地址处。在分析本章的内存管理程序时，需明确区分清楚给定的地址是指线性地址还是实际物理内存的地址。

10.2.1 内存分页管理机制

在 Intel 80x86 的系统中，内存分页管理是通过页目录表和内存页表所组成的二级表进行的。见图 10-1 所示。

其中页目录表和页表的结构是一样的，表项结构也相同。页目录表中的每个表项（简称页目录项）（4 字节）用来寻址一个页表，而每个页表项（4 字节）用来指定一页物理内存页。因此，当指定了一个页目录项和一个页表项，我们就可以唯一地确定所对应的物理内存页。页目录表占用一页内存，因此最

多可以寻址 1024 个页表。而每个页表也同样占用一页内存，因此一个页表可以寻址最多 1024 个物理内存页面。这样在 80386 中，一个页目录表所寻址的所有页表共可以寻址 1024 X 1024 X 4096 = 4G 的内存空间。在 Linux 0.11 内核中，所有进程都使用一个页目录表，而每个进程都有自己的页表。

对于应用进程或内核其他部分来讲，在申请内存时使用的是线性地址。接下来我们就要问了：“那么，一个线性地址如何使用这两个表来映射到一个物理地址上呢？”。为了使用分页机制，一个 32 位的线性地址被分成了三个部分，分别用来指定一个页目录项、一个页表项和对应物理内存页上的偏移地址，从而能间接地寻址到线性地址指定的物理内存位置。见图 10-2 所示。

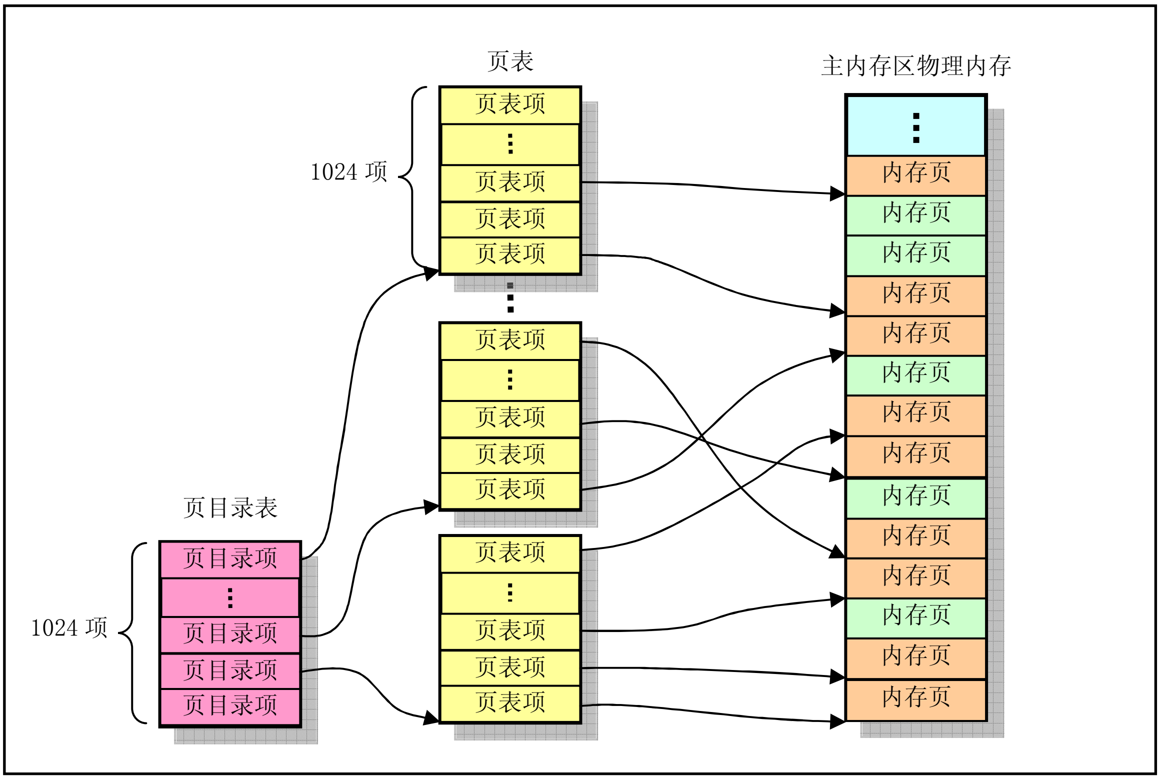

图 10-1 页目录表和页表结构示意图

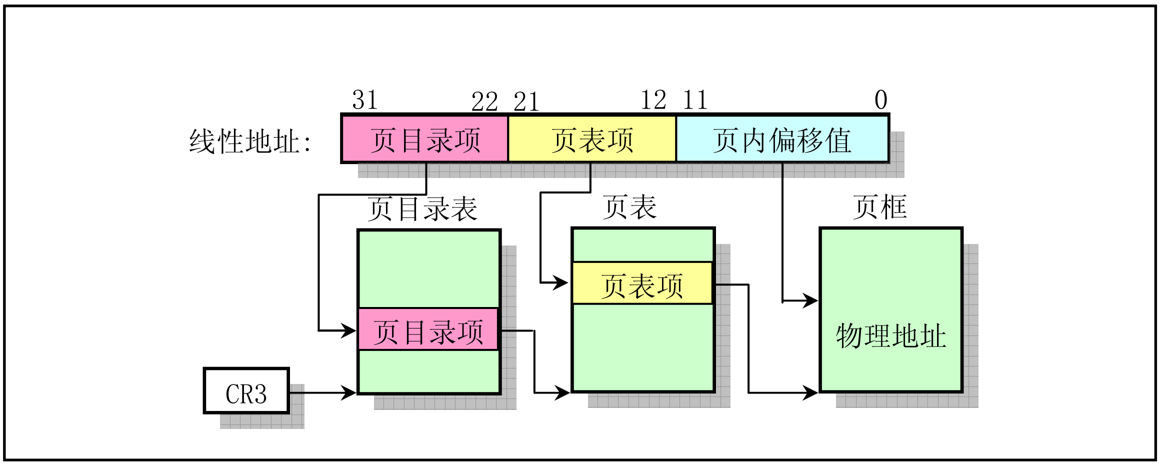

图 10-2 线性地址变换示意图

线性地址的位 31-22 共 10 个比特用来确定页目录中的目录项，位 21-12 用来寻址页目录项指定的页表中的页表项，最后的 12 个比特正好用作页表项指定的一页物理内存中的偏移地址。

在内存管理的函数中，大量使用了从线性地址到实际物理地址的变换计算。对于给定一个进程的线性地址，通过图 10-2 中所示的地址变换关系，我们可以很容易地找到该线性地址对应的页目录项。若该目录项有效（被使用），则该目录项中的页框地址指定了一个页表在物理内存中的基址，那么结合线性地址中的页表项指针，若该页表项有效，则根据该页表项中的指定的页框地址，我们就可以最终确定指定线性地址对应的实际物理内存页的地址。反之，如果需要从一个已知被使用的物理内存页地址，寻找对应的线性地址，则需要对整个页目录表和所有页表进行搜索。若该物理内存页被共享，我们就可能会找到多个对应的线性地址来。图 10-3 用形象的方法示出了一个给定的线性地址是如何映射到物理内存页上的。对于第一个进程（任务 0），其页表是在页目录表之后，共 4 页。对于应用程序的进程，其页表所使用的内存是在进程创建时向内存管理程序申请的，因此是在主内存区中。

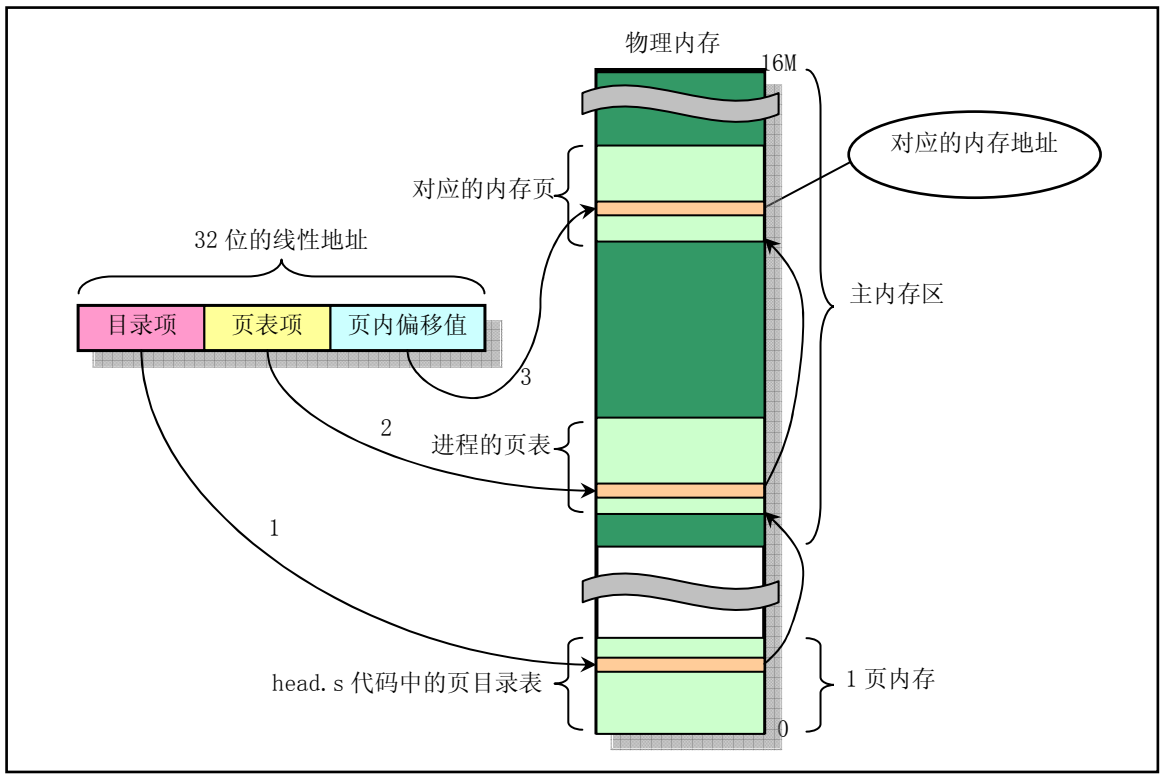

图 10-3 线性地址对应的物理地址

一个系统中可以同时存在多个页目录表，而在某个时刻只有一个页目录表可用。当前的页目录表是用 CPU 的寄存器 CR3 来确定的，它存储着当前页目录表的物理内存地址。但在本书所讨论的 Linux 内核中只使用了一个页目录表。

在图 10.1 中我们看到，每个页表项对应的物理内存页在 4G 的地址范围内是随机的，是由页表项中页框地址内容确定的，也即是由内存管理程序通过设置页表项确定的。每个表项由页框地址、访问标志位、脏（已改写）标志位和存在标志位等构成。表项的结构可参见图 10-4 所示。

31 12	11								0
页框地址 位 31..12 (PAGE FRAME ADDRESS)	可用 (AVAIL)	0	0	D	A	0	0	U/S	R/W	P

图 10-4 页目录和页表表项结构

其中，页框地址(PAGE FRAME ADDRESS)指定了一页内存的物理起始地址。因为内存页是位于 4K 边界上的，所以其低 12 比特总是 0，因此表项的低 12 比特可作它用。在一个页目录表中，表项的页框地址是一个页表的起始地址；在第二级页表中，页表项的页框地址则包含期望内存操作的物理内存页地址。

图中的存在位（PRESENT – P）确定了一个页表项是否可以用于地址转换过程。P=1 表示该项可用。当目录表项或第二级表项的 P=0 时，则该表项是无效的，不能用于地址转换过程。此时该表项的所有其他比特位都可供程序使用；处理器不对这些位进行测试。

当 CPU 试图使用一个页表项进行地址转换时，如果此时任意一级页表项的 P=0，则处理器就会发出页异常信号。此时缺页中断异常处理程序就可以把所请求的页加入到物理内存中，并且导致异常的指令会被重新执行。

已访问（Accessed – A）和已修改（Dirty – D）比特位用于提供有关页使用的信息。除了页目录项中的已修改位，这些比特位将由硬件置位，但不复位。

在对一页内存进行读或写操作之前，CPU 将设置相关的目录和二级页表项的已访问位。在向一个二级页表项所涵盖的地址进行写操作之前，处理器将设置该二级页表项的已修改位，而页目录项中的已修改位是不用的。当所需求的内存超出实际物理内存量时，内存管理程序就可以使用这些位来确定那些页可以从内存中取走，以腾出空间。内存管理程序还需负责检测和复位这些比特位。

读/写位（Read/Write – R/W）和用户/超级用户位（User/Supervisor – U/S）并不用于地址转换，但用于分页级的保护机制，是由 CPU 在地址转换过程中同时操作的。

10.2.2 Linux 中物理内存的管理和分配

有了以上概念，我们就可以说明 Linux 进行内存管理的方法了。但还需要了解一下 Linux 0.11 内核使用内存空间的情况。对于 Linux 0.11 内核，它默认最多支持 16M 物理内存。在一个具有 16MB 内存的 80x86 计算机系统中，Linux 内核占用物理内存最前段的一部分，图中 end 标示出内核模块结束的位置。随后是高速缓冲区，它的最高内存地址为 4M 。高速缓冲区被显示内存和 ROM BIOS 分成两段。剩余的内存部分称为主内存区。主内存区就是由本章的程序进行分配管理的。若系统中还存在 RAM 虚拟盘时，则主内存区前段还要扣除虚拟盘所占的内存空间。当需要使用主内存区时就需要向本章的内存管理程序申请，所申请的基本单位是内存页。整个物理内存各部分的功能示意图如图 10-5 所示。

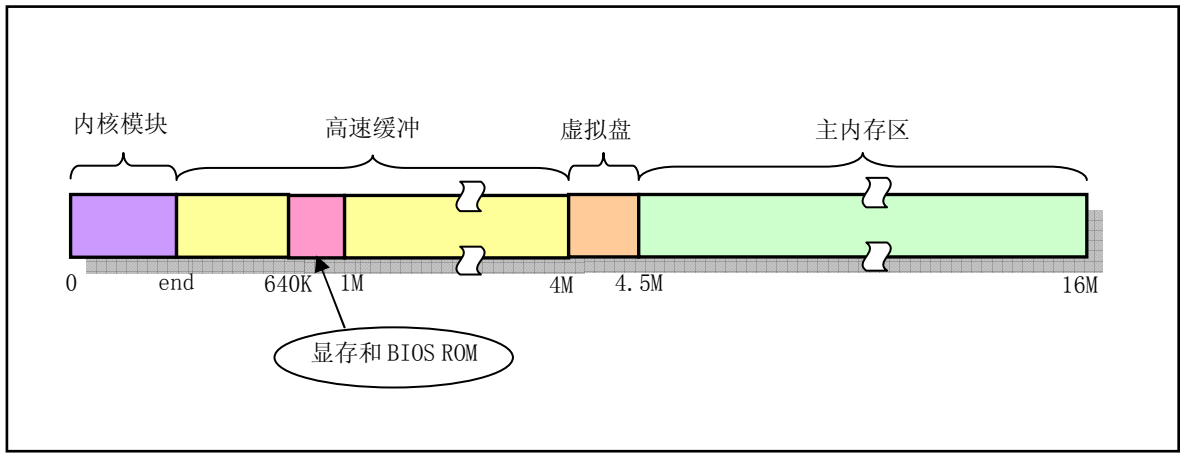

图 10-5 主内存区域示意图

在启动引导一章中，我们已经知道，Linux 的页目录和页表是在程序 head.s 中设置的。head.s 程序在物理地址 0 处存放了一个页目录表，紧随其后是 4 个页表。这 4 个页表将被用于任务 0，其他的派生进程将在主内存区申请内存页来存放自己的页表。本章中的两个程序就是用于对这些表进行操作，从而实

现主内存区中内存的分配使用。

为了节约物理内存，在调用 fork()生成新进程时，新进程与原进程会共享同一内存区。只有当其中一个进程进行写操作时，系统才会为其另外分配内存页面。这就是写时复制的概念。

page.s 程序用于实现页异常中断处理过程（int 14）。该中断处理过程对由于缺页和页写保护引起的中断分别调用 memory.c 中的 do_no_page()和 do_wp_page()函数进行处理。do_no_page()会把需要的页面从块设备中取到内存指定位置处。在共享内存页面情况下，do_wp_page()会复制被写的页面（copy on write，写时复制），从而也取消了对页面的共享。

10.2.3 Linux 内核对线性地址空间的使用分配

在阅读本章代码时，我们还需要了解一个执行程序进程的代码和数据在虚拟的线性地址空间中的分布情况，参见下面图 10-6 所示。

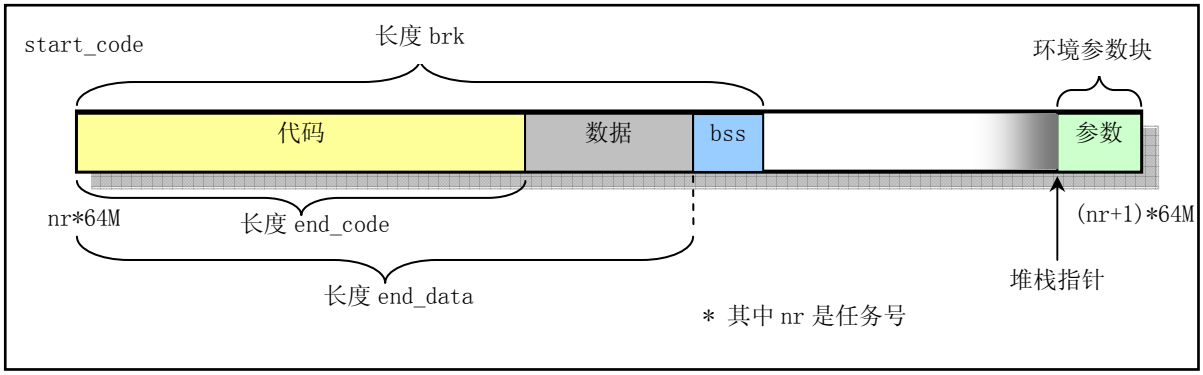

图 10-6 进程在线性地址空间中的分布

每个进程在线性地址中都是从 nr*64M 的地址位置开始（nr 是任务号），占用线性地址空间的范围是 64M。其中最后部的环境参数数据块最长为 128K，其左面起始堆栈指针。在进程创建时 bss 段的第一页被初始化为全 0 。

10.2.4 关于写时复制（copy on write）机制

当进程 A 使用系统调用 fock 创建一个子进程 B 时，由于子进程 B 实际上是父进程 A 的一个拷贝，因此会拥有与父进程相同的物理页面。也即为了达到节约内存和加快创建速度的目标，fork()函数会让子进程 B 以只读方式共享父进程 A 的物理页面。同时将父进程 A 对这些物理页面的访问权限也设成只读。详见 memory.c 程序中的 copy_page_tables()函数。这样一来，当父进程 A 或子进程 B 任何一方对这些以共享的物理页面执行写操作时，都会产生页面出错异常(page_fault int14)中断，此时 CPU 会执行系统提供的异常处理函数 do_wp_page()来试图解决这个异常。这就是写时复制机制。

do_wp_page()会对这块导致写入异常中断的物理页面进行取消共享操作（使用 un_wp_page()函数），为写进程复制一新的物理页面，使父进程 A 和子进程 B 各自拥有一块内容相同的物理页面。这时才真正地进行了复制操作(只复制这一块物理页面)。并且把将要执行写入操作的这块物理页面标记成可以写访问的。最后，从异常处理函数中返回时，CPU 就会重新执行刚才导致异常的写入操作指令，使进程能够继续执行下去。

因此，对于进程在自己的虚拟地址范围内进行写操作时，就会使用上面这种被动的写时复制操作，也即：写操作 -> 页面异常中断 -> 处理写保护异常 -> 重新执行写操作。而对于系统内核代码，当在某个进程的虚拟地址范围内执行写操作时，例如，进程调用某个系统调用，而该系统调用会将数据复制到进程的缓冲区域中，则会主动地调用内存页面验证函数 write_verify()，来判断是否有页面共享的情况存在，如果有，就进行页面的写时复制操作。

另外，值得注意的一点是在 Linux 0.11 内核中，在内核地址空间执行 fork()来创建进程使并没有采用写时复制技术。因此当进程 0（idle 进程）在内核空间创建进程 1（init 进程）时将使用同一段代码和数据段，包括其中的堆栈区域。不会在进程 1 需要写操作时为其另外分配内存。

10.3 Makefile 文件

10.3.1 功能描述

本文件是 mm 目录中程序的编译管理配置文件，共 make 程序使用。

10.3.2 代码注释

程序 10-1 linux/mm/Makefile

```
1  CC      =gcc    # GNU C 语言编译器。
2  CFLAGS  =-O -Wall -fstrength-reduce -fcombine-regs -fomit-frame-pointer \
3          -finline-functions -nostdinc -I../include
   # C 编译程序选项。-Wall 显示所有的警告信息；-O 优化选项，优化代码长度和执行时间；
   # -fstrength-reduce 优化循环执行代码，排除重复变量；-fomit-frame-pointer 省略保存不必要
   # 的框架指针；-fcombine-regs 合并寄存器，减少寄存器类的使用；-finline-functions 将所有简
   # 单短小的函数代码嵌入调用程序中；-nostdinc -I../include 不使用默认路径中的包含文件，而
   # 使用这里指定目录中的(../include)。
4  AS      =gas    # GNU 的汇编程序。
5  AR      =gar    # GNU 的二进制文件处理程序，用于创建、修改以及从归档文件中抽取文件。
6  LD      =gld    # GNU 的连接程序。
7  CPP     =gcc -E -nostdinc -I../include
   # C 前处理选项。-E 只运行 C 前处理，对所有指定的 C 程序进行预处理并将处理结果输出到标准输
   # 出设备或指定的输出文件中；-nostdinc -I../include 同前。
8
   # 下面的规则指示 make 利用下面的命令将所有的.c 文件编译生成.s 汇编程序。该规则的命令
   # 指使 gcc 采用 CFLAGS 所指定的选项对 C 代码编译后不进行汇编就停止（-S），从而产生与
   # 输入的各个 C 文件对应的汇编代码文件。默认情况下所产生的汇编程序文件名是原 C 文件名
   # 去掉.c 而加上.s 后缀。-o 表示其后是输出文件的名称。其中$*.s（或$@）是自动目标变量，
   # $<代表第一个先决条件，这里即是符合条件*.c 的文件。
9  .c.o:
10         $(CC) $(CFLAGS) \
11         -c -o $*.o $<
  # 下面规则表示将所有.s 汇编程序文件编译成.o 目标文件。22 行是实现该操作的具体命令。
12 .s.o:
13         $(AS) -o $*.o $<
14 .c.s:                        # 类似上面，*.c 文件-→*.s 汇编程序文件。不进行连接。
15         $(CC) $(CFLAGS) \
16         -S -o $*.s $<
17
18 OBJS    = memory.o page.o    # 定义目标文件变量 OBJS。
19
20 all: mm.o
21
22 mm.o: $(OBJS)          # 在有了先决条件 OBJS 后使用下面的命令连接成目标 mm.o
23         $(LD) -r -o mm.o $(OBJS)
24
   # 下面的规则用于清理工作。当执行'make clean'时，就会执行 26--27 行上的命令，去除所有编译
```

```
    # 连接生成的文件。'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
25 clean:
26         rm -f core *.o *.a tmp_make
27         for i in *.c;do rm -f `basename $$i .c`.s;done
28
    # 下面得目标或规则用于检查各文件之间的依赖关系。方法如下：
    # 使用字符串编辑程序 sed 对 Makefile 文件（这里即是自己）进行处理，输出为删除 Makefile
    # 文件中'### Dependencies'行后面的所有行（下面从 35 开始的行），并生成 tmp_make
    # 临时文件（30 行的作用）。然后对 mm/目录下的每一个 C 文件执行 gcc 预处理操作.
    # -M 标志告诉预处理程序输出描述每个目标文件相关性的规则，并且这些规则符合 make 语法。
    # 对于每一个源文件，预处理程序输出一个 make 规则，其结果形式是相应源程序文件的目标
    # 文件名加上其依赖关系--该源文件中包含的所有头文件列表。把预处理结果都添加到临时
    # 文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。

29 dep:
30         sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
31         (for i in *.c;do $(CPP) -M $$i;done) >> tmp_make
32         cp tmp_make Makefile
33
34 ### Dependencies:
35 memory.o : memory.c ../include/signal.h ../include/sys/types.h \
36   ../include/asm/system.h ../include/linux/sched.h ../include/linux/head.h \
37   ../include/linux/fs.h ../include/linux/mm.h ../include/linux/kernel.h
```

10.4 memory.c 程序

10.4.1 功能描述

本程序进行内存分页的管理。实现了对主内存区内存的动态分配和收回操作。对于物理内存的管理，内核使用了一个字节数组（mem_map[]）来表示主内存区中所有物理内存页的状态。每个字节描述一个物理内存页的占用状态。其中的值表示被占用的次数，0 表示对应的物理内存空闲着。当申请一页物理内存时，就将对应字节的值增 1。对于进程虚拟线性地址的管理，内核使用了处理器的页目录表和页表结构来管理。而物理内存页与进程线性地址之间的映射关系则是通过修改页目录和页表项的内容来处理。下面对程序中所提供的几个主要函数进行详细说明。

get_free_page()和 free_page()这两个函数是专门用来管理主内存区中物理内存的占用和空闲情况，与每个进程的线性地址无关。

get_free_page()函数用于在主内存区中申请一页空闲内存页，并返回物理内存页的起始地址。它首先扫描内存页面字节图数组 mem_map[]，寻找值是 0 的字节项（对应空闲页面）。若无则返回 0 结束，表示物理内存已使用完。若找到值为 0 的字节，则将其置 1，并换算出对应空闲页面的起始地址。然后对该内存页面作清零操作。最后返回该空闲页面的物理内存起始地址。

free_page()用于释放指定地址处的一页物理内存。它首先判断指定的内存地址是否<1M，若是则返回，因为 1M 以内是内核专用的；若指定的物理内存地址大于或等于实际内存最高端地址，则显示出错信息；然后由指定的内存地址换算出页面号: (addr - 1M)/4K；接着判断页面号对应的 mem_map[]字节项是否为 0，若不为 0，则减 1 返回；否则对该字节项清零，并显示“试图释放一空闲页面”的出错信息。

free_page_tables()和 copy_page_tables()这两个函数则以一个页表对应的物理内存块（4M）为单位，释放或复制指定线性地址和长度（页表个数）对应的物理内存页块。不仅对管理线性地址的页目录和页表中的对应项内容进行修改，而且也对每个页表中所有页表项对应的物理内存页进行释放或占用操作。

free_page_tables()用于释放指定线性地址和长度（页表个数）对应的物理内存页。它首先判断指定的线性地址是否在 4M 的边界上，若不是则显示出错信息，并死机；然后判断指定的地址值是否=0，若是，则显示出错信息“试图释放内核和缓冲区所占用的空间”，并死机；接着计算在页目录表中所占用的目录项数 size，也即页表个数，并计算对应的起始目录项号；然后从对应起始目录项开始，释放所占用的所有 size 个目录项；同时释放对应目录项所指的页表中的所有页表项和相应的物理内存页；最后刷新页变换高速缓冲。

copy_page_tables()用于复制指定线性地址和长度（页表个数）内存对应的页目录项和页表，从而被复制的页目录和页表对应的原物理内存区被共享使用。该函数首先验证指定的源线性地址和目的线性地址是否都在 4Mb 的内存边界地址上，否则就显示出错信息，并死机；然后由指定线性地址换算出对应的起始页目录项（from_dir, to_dir）；并计算需复制的内存区占用的页表数（即页目录项数）；接着开始分别将原目录项和页表项复制到新的空闲目录项和页表项中。页目录表只有一个，而新进程的页表需要申请空闲内存页面来存放；此后再将原始和新的页目录和页表项都设置成只读的页面。当有写操作时就利用页异常中断调用，执行写时复制操作。最后对共享物理内存页对应的字节图数组 mem_map[]的标志进行增 1 操作。

put_page()用于将一指定的物理内存页面映射到指定的线性地址处。它首先判断指定的内存页面地址的有效性，要在 1M 和系统最高端内存地址之外，否则发出警告；然后计算该指定线性地址在页目录表中对应的目录项；此时若该目录项有效（P=1），则取其对应页表的地址；否则申请空闲页给页表使用，并设置该页表中对应页表项的属性。最后仍返回指定的物理内存页面地址。

do_wp_page()是页异常中断过程（在 mm/page.s 中实现）中调用的页写保护处理函数。它首先判断地址是否在进程的代码区域，若是则终止程序（代码不能被改动）；然后执行写时复制页面的操作（Copy on Write）。

do_no_page()是页异常中断过程中调用的缺页处理函数。它首先判断指定的线性地址在一个进程空间中相对于进程基址的偏移长度值。如果它大于代码加数据长度，或者进程刚开始创建，则立刻申请一页物理内存，并映射到进程线性地址中，然后返回；接着尝试进行页面共享操作，若成功，则立刻返回；否则申请一页内存并从设备中读入一页信息；若加入该页信息时，指定线性地址+1 页长度超过了进程代码加数据的长度，则将超过的部分清零。然后将该页映射到指定的线性地址处。

get_empty_page()用于取得一页空闲物理内存并映射到指定线性地址处。主要使用了 get_free_page()和 put_page()函数来实现该功能。

10.4.2 代码注释

程序 10-2 linux/mm/memory.c

```
 1 /*
 2  *  linux/mm/memory.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * demand-loading started 01.12.91 - seems it is high on the list of
 9  * things wanted, and it should be easy to implement. - Linus
10  */
   /*
    * 需求加载是从 01.12.91 开始编写的 - 在程序编制表中似乎是最重要的程序，
    * 并且应该是很容易编制的 - linus
    */
```

```
11
12 /*
13  * Ok, demand-loading was easy, shared pages a little bit tricker. Shared
14  * pages started 02.12.91, seems to work. - Linus.
15  *
16  * Tested sharing by executing about 30 /bin/sh: under the old kernel it
17  * would have taken more than the 6M I have free, but it worked well as
18  * far as I could see.
19  *
20  * Also corrected some "invalidate()"s - I wasn't doing enough of them.
21  */
   /*
    * OK，需求加载是比较容易编写的，而共享页面却需要有点技巧。共享页面程序是
    * 02.12.91 开始编写的，好象能够工作 - Linus。
    *
    * 通过执行大约 30 个/bin/sh 对共享操作进行了测试：在老内核当中需要占用多于
    * 6M 的内存，而目前却不用。现在看来工作得很好。
    *
    * 对"invalidate()"函数也进行了修正 - 在这方面我还做的不够。
    */
22
23 #include <signal.h>       // 信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
24
25 #include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。
26
27 #include <linux/sched.h>  // 调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，
                             // 还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。
28 #include <linux/head.h>   // head 头文件，定义了段描述符的简单结构，和几个选择符常量。
29 #include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
30
31 volatile void do_exit(long code);  // 进程退出处理函数，在 kernel/exit.c，102 行。
32
   //// 显示内存已用完出错信息，并退出。
33 static inline volatile void oom(void)
34 {
35         printk("out of memory\n\r");
36         do_exit(SIGSEGV);         // do_exit()应该使用退出代码，这里用了信号值 SIGSEGV(11)
37 }                                 // 相同值的出错码含义是“资源暂时不可用”，正好同义。
38
   // 刷新页变换高速缓冲宏函数。
   // 为了提高地址转换的效率，CPU 将最近使用的页表数据存放在芯片中高速缓冲中。在修改过页表
   // 信息之后，就需要刷新该缓冲区。这里使用重新加载页目录基址寄存器 cr3 的方法来进行刷新。
   // 下面 eax = 0，是页目录的基址。
39 #define invalidate() \
40 __asm__("movl %%eax,%%cr3"::"a" (0))
41
42 /* these are not to be changed without changing head.s etc */
   /* 下面定义若需要改动，则需要与 head.s 等文件中的相关信息一起改变 */
   // linux 0.11 内核默认支持的最大内存容量是 16M，可以修改这些定义以适合更多的内存。
43 #define LOW_MEM 0x100000                    // 内存低端（1MB）。
44 #define PAGING_MEMORY (15*1024*1024)        // 分页内存 15MB。主内存区最多 15M。
45 #define PAGING_PAGES (PAGING_MEMORY>>12)    // 分页后的物理内存页数。
46 #define MAP_NR(addr) (((addr)-LOW_MEM)>>12) // 指定内存地址映射为页号。
```

```
47 #define USED 100                                    // 页面被占用标志，参见 405 行。
48
   // CODE_SPACE(addr) ((((addr)+0xfff)&~0xfff) < current->start_code + current->end_code)。
   // 该宏用于判断给定地址是否位于当前进程的代码段中，参见 252 行。
49 #define CODE_SPACE(addr) ((((addr)+4095)&~4095) < \
50 current->start_code + current->end_code)
51
52 static long HIGH_MEMORY = 0;                        // 全局变量，存放实际物理内存最高端地址。
53
   // 复制 1 页内存（4K 字节）。
54 #define copy_page(from,to) \
55 __asm__("cld ; rep ; movsl"::"S" (from),"D" (to),"c" (1024):"cx","di","si")
56
   // 内存映射字节图(1 字节代表 1 页内存)，每个页面对应的字节用于标志页面当前被引用（占用）次数。
   // 它最大可以映射 15Mb 的内存空间。在初始化函数 mem_init()中，对于不能用作主内存区页面的位置
   // 均都预先被设置成 USED（100）。
57 static unsigned char mem_map [ PAGING_PAGES ] = {0,};
58
59 /*
60  * Get physical address of first (actually last :-) free page, and mark it
61  * used. If no free pages left, return 0.
62  */
   /*
    * 获取首个(实际上是最后 1 个:-)空闲页面，并标记为已使用。如果没有空闲页面，
    * 就返回 0。
    */
   //// 取空闲页面。如果已经没有可用内存了，则返回 0。
   // 输入：%1(ax=0) - 0；%2(LOW_MEM)；%3(cx=PAGING_PAGES)；%4(edi=mem_map+PAGING_PAGES-1)。
   // 输出：返回%0(ax=页面起始地址)。
   // 上面%4 寄存器实际指向 mem_map[]内存字节图的最后一个字节。本函数从字节图末端开始向前扫描
   // 所有页面标志（页面总数为 PAGING_PAGES），若有页面空闲（其内存映像字节为 0）则返回页面地址。
   // 注意！本函数只是指出在主内存区的一页空闲页面，但并没有映射到某个进程的线性地址去。后面
   // 的 put_page()函数就是用来作映射的。
63 unsigned long get_free_page(void)
64 {
65 register unsigned long __res asm("ax");
66
67 __asm__("std ; repne ; scasb\n\t"     // 方向位置位，将 al(0)与对应每个页面的(di)内容比较，
68         "jne 1f\n\t"                  // 如果没有等于 0 的字节，则跳转结束（返回 0）。
69         "movb $1,1(%%edi)\n\t         // 1 ==>[1+edi]，将对应页面的内存映像比特位置 1。
70         "sall $12,%%ecx\n\t"          // 页面数*4K = 相对页面起始地址。
71         "addl %2,%%ecx\n\t"           // 再加上低端内存地址，即获得页面实际物理起始地址。
72         "movl %%ecx,%%edx\n\t"        // 将页面实际起始地址➔edx 寄存器。
73         "movl $1024,%%ecx\n\t"        // 寄存器 ecx 置计数值 1024。
74         "leal 4092(%%edx),%%edi\n\t"  // 将 4092+edx 的位置➔edi(该页面的末端)。
75         "rep ; stosl\n\t"             // 将 edi 所指内存清零（反方向，也即将该页面清零）。
76         "movl %%edx,%%eax\n"          // 将页面起始地址➔eax（返回值）。
77         "1:"
78         :"=a" (__res)
79         :"" (0),"i" (LOW_MEM),"c" (PAGING_PAGES),
80         "D" (mem_map+PAGING_PAGES-1)
81         :"di","cx","dx");
82 return __res;                         // 返回空闲页面地址（如果无空闲也则返回 0）。
```

```
 83 }
 84
 85 /*
 86  * Free a page of memory at physical address 'addr'. Used by
 87  * 'free_page_tables()'
 88  */
    /*
     * 释放物理地址'addr'开始的一页内存。用于函数'free_page_tables()'。
     */
    //// 释放物理地址 addr 开始的一页面内存。
    // 1MB 以下的内存空间用于内核程序和缓冲，不作为分配页面的内存空间。
 89 void free_page(unsigned long addr)
 90 {
 91         if (addr < LOW_MEM) return;  // 如果物理地址 addr 小于内存低端（1MB），则返回。
 92         if (addr >= HIGH_MEMORY)     // 如果物理地址 addr>=内存最高端，则显示出错信息。
 93                 panic("trying to free nonexistent page");
 94         addr -= LOW_MEM;             // 物理地址减去低端内存位置，再除以 4KB，得页面号。
 95         addr >>= 12;
 96         if (mem_map[addr]--) return; // 如果对应内存页面映射字节不等于 0，则减 1 返回。
 97         mem_map[addr]=0;             // 否则置对应页面映射字节为 0，并显示出错信息，死机。
 98         panic("trying to free free page");
 99 }
100
101 /*
102  * This function frees a continuos block of page tables, as needed
103  * by 'exit()'. As does copy_page_tables(), this handles only 4Mb blocks.
104  */
    /*
     * 下面函数释放页表连续的内存块，'exit()'需要该函数。与 copy_page_tables()
     * 类似，该函数仅处理 4Mb 的内存块。
     */
    //// 根据指定的线性地址和限长（页表个数），释放对应内存页表所指定的内存块并置表项空闲。
    // 页目录位于物理地址 0 开始处，共 1024 项，占 4K 字节。每个目录项指定一个页表。
    // 页表从物理地址 0x1000 处开始（紧接着目录空间），每个页表有 1024 项，也占 4K 内存。
    // 每个页表项对应一页物理内存（4K）。目录项和页表项的大小均为 4 个字节。
    // 参数：from - 起始基地址；size - 释放的长度。
105 int free_page_tables(unsigned long from,unsigned long size)
106 {
107         unsigned long *pg_table;
108         unsigned long * dir, nr;
109
110         if (from & 0x3fffff)                    // 要释放内存块的地址需以 4M 为边界。
111                 panic("free_page_tables called with wrong alignment");
112         if (!from)                              // 出错，试图释放内核和缓冲所占空间。
113                 panic("Trying to free up swapper memory space");
    // 计算所占页目录项数(4M 的进位整数倍)，也即所占页表数。
114         size = (size + 0x3fffff) >> 22;
    // 下面一句计算起始目录项。对应的目录项号=from>>22，因每项占 4 字节，并且由于页目录是从
    // 物理地址 0 开始，因此实际的目录项指针=目录项号<<2，也即(from>>20)。与上 0xffc 确保
    // 目录项指针范围有效。
115         dir = (unsigned long *) ((from>>20) & 0xffc); /* _pg_dir = 0 */
116         for ( ; size-->0 ; dir++) {             // size 现在是需要被释放内存的目录项数。
117                 if (!(1 & *dir))                // 如果该目录项无效(P 位=0)，则继续。
```

```
118                     continue;               // 目录项的位 0(P 位)表示对应页表是否存在。
119             pg_table = (unsigned long *) (0xfffff000 & *dir);  // 取目录项中页表地址。
120             for (nr=0 ; nr<1024 ; nr++) {   // 每个页表有 1024 个页项。
121                     if (1 & *pg_table)      // 若该页表项有效(P 位=1)，则释放对应内存页。
122                             free_page(0xfffff000 & *pg_table);
123                     *pg_table = 0;          // 该页表项内容清零。
124                     pg_table++;             // 指向页表中下一项。
125             }
126             free_page(0xfffff000 & *dir);   // 释放该页表所占内存页面。
127             *dir = 0;                       // 对相应页表的目录项清零。
128         }
129         invalidate();                       // 刷新页变换高速缓冲。
130         return 0;
131 }
132
133 /*
134  *  Well, here is one of the most complicated functions in mm. It
135  * copies a range of linerar addresses by copying only the pages.
136  * Let's hope this is bug-free, 'cause this one I don't want to debug :-)
137  *
138  * Note! We don't copy just any chunks of memory - addresses have to
139  * be divisible by 4Mb (one page-directory entry), as this makes the
140  * function easier. It's used only by fork anyway.
141  *
142  * NOTE 2!! When from==0 we are copying kernel space for the first
143  * fork(). Then we DONT want to copy a full page-directory entry, as
144  * that would lead to some serious memory waste - we just copy the
145  * first 160 pages - 640kB. Even that is more than we need, but it
146  * doesn't take any more memory - we don't copy-on-write in the low
147  * 1 Mb-range, so the pages can be shared with the kernel. Thus the
148  * special case for nr=xxxx.
149  */
    /*
     * 好了，下面是内存管理 mm 中最为复杂的程序之一。它通过只复制内存页面
     * 来拷贝一定范围内线性地址中的内容。希望代码中没有错误，因为我不想
     * 再调试这块代码了☺。
     *
     * 注意！我们并不复制任何内存块 - 内存块的地址需要是 4Mb 的倍数（正好
     * 一个页目录项对应的内存大小），因为这样处理可使函数很简单。不管怎样，
     * 它仅被 fork()使用（fork.c 第 56 行）。
     *
     * 注意 2！！当 from==0 时，是在为第一次 fork()调用复制内核空间。此时我们
     * 不想复制整个页目录项对应的内存，因为这样做会导致内存严重的浪费 - 我们
     * 只复制头 160 个页面 - 对应 640kB。即使是复制这些页面也已经超出我们的需求，
     * 但这不会占用更多的内存 - 在低 1Mb 内存范围内我们不执行写时复制操作，所以
     * 这些页面可以与内核共享。因此这是 nr=xxxx 的特殊情况（nr 在程序中指页面数）。
     */
    //// 复制指定线性地址和长度（页表个数）内存对应的页目录项和页表项，从而被复制的页目录和
    //// 页表对应的原物理内存区被共享使用。
    // 复制指定地址和长度的内存对应的页目录项和页表项。需申请页面来存放新页表，原内存区被共享;
    // 此后两个进程将共享内存区，直到有一个进程执行写操作时，才分配新的内存页（写时复制机制）。
    // 参数 from, to 是线性地址，size 是需要复制（共享）的内存长度，单位是字节。
150 int copy_page_tables(unsigned long from,unsigned long to,long size)
```

```
151 {
152         unsigned long * from_page_table;
153         unsigned long * to_page_table;
154         unsigned long this_page;
155         unsigned long * from_dir, * to_dir;
156         unsigned long nr;
157
    // 源地址和目的地址都需要是在 4Mb 的边界地址上。否则出错，死机。作这样的要求是因为一个页表
    // 的 1024 项可管理 4Mb 内存。源地址 from 和目的地址 to 只有满足这个要求才能保证从一个页表的
    // 第 1 项开始复制页表项，并且新页表的最初所有项都是有效的。
158         if ((from&0x3fffff) || (to&0x3fffff))
159                 panic("copy_page_tables called with wrong alignment");
    // 取得源地址和目的地址的目录项指针(from_dir 和 to_dir)。参见对 115 句的注释。
160         from_dir = (unsigned long *) ((from>>20) & 0xffc); /* _pg_dir = 0 */
161         to_dir = (unsigned long *) ((to>>20) & 0xffc);
    // 计算要复制的内存块占用的页表数（也即目录项数）。
162         size = ((unsigned) (size+0x3fffff)) >> 22;
    // 下面开始对每个占用的页目录项依次申请一页内存来保存对应的页表，并进行页表复制操作。
163         for( ; size-->0 ; from_dir++,to_dir++) {
    // 如果目的目录项指定的页表已经存在(P=1)，则出错，死机。
164                 if (1 & *to_dir)
165                         panic("copy_page_tables: already exist");
    // 如果此源目录项未被使用，则不用复制对应页表，跳过。
166                 if (!(1 & *from_dir))
167                         continue;
    // 取当前源目录项中页表的地址➔from_page_table。
168                 from_page_table = (unsigned long *) (0xfffff000 & *from_dir);
    // 为保存目的目录项对应的页表，在主内存区中申请一页空闲内存页。如果返回是 0 则说明没有申请
    // 到空闲内存页面，内存不够。于是返回值=-1，退出。
169                 if (!(to_page_table = (unsigned long *) get_free_page()))
170                         return -1;      /* Out of memory, see freeing */
    // 设置目的目录项信息。7 是标志信息，表示(Usr, R/W, Present)。
171                 *to_dir = ((unsigned long) to_page_table) | 7;
    // 针对当前处理的页表，设置需要复制的页面项数。如果是在内核空间，则仅需复制头 160 页的 160
    // 个页表项，对应开始的 640KB 物理内存。否则需要复制一个页表中的所有 1024 个页表项（4MB）。
172                 nr = (from==0)?0xA0:1024;
    // 对于当前页表，开始复制指定数目 nr 个内存页面表项。
173                 for ( ; nr-- > 0 ; from_page_table++,to_page_table++) {
174                         this_page = *from_page_table;  // 取源页表项内容。
175                         if (!(1 & this_page))      // 如果当前源页面没有使用，则不用复制。
176                                 continue;
    // 复位页表项中 R/W 标志(置 0)。（如果 U/S 位是 0，则 R/W 就没有作用。如果 U/S 是 1，而 R/W 是 0，
    // 那么运行在用户层的代码就只能读页面。如果 U/S 和 R/W 都置位，则就有写的权限）
177                         this_page &= ~2;
178                         *to_page_table = this_page;    // 将该页表项复制到目的页表中。
    // 如果该页表项所指页面的地址在 1MB 以上，则需要设置内存页面映射数组 mem_map[]，于是计算
    // 页面号，并以它为索引在页面映射数组相应项中增加引用次数。而对于位于 1MB 以下的页面，说明
    // 是内核页面，因此不需要对 mem_map[]进行设置。因为 mem_map[]仅用于管理主内存区中的页面使用
    // 情况。因此对于内核移动到任务 0 中并且调用 fork()创建任务 1 时（用于运行 init()），由于此时
    // 复制的页面还仍然都在内核代码区域，因此以下判断中的语句不会执行，任务 0 的页面仍然可以随时
    // 读写。只有当调用 fork()的父进程代码处于主内存区（页面位置大于 1MB）时才会执行。这种情况需
    // 要在进程调用了 execve()，装载并执行了新程序代码时才会出现。
179                         if (this_page > LOW_MEM) {
```

```
    // 下面这句的含义是令源页表项所指内存页也为只读。因为现在开始有两个进程共用内存区了。
    // 若其中一个内存需要进行写操作，则可以通过页异常的写保护处理，为执行写操作的进程分配
    // 一页新的空闲页面，也即进行写时复制（Copy on Write）的操作。
180                                 *from_page_table = this_page; // 令源页表项也只读。
181                                 this_page -= LOW_MEM;
182                                 this_page >>= 12;
183                                 mem_map[this_page]++;
184                         }
185                 }
186         }
187         invalidate();                           // 刷新页变换高速缓冲。
188         return 0;
189 }
190
191 /*
192  * This function puts a page in memory at the wanted address.
193  * It returns the physical address of the page gotten, 0 if
194  * out of memory (either when trying to access page-table or
195  * page.)
196  */
    /*
     * 下面函数将一内存页面放置（映射）到指定线性地址处。它返回页面的物理地址，如果
     * 内存不够(在访问页表或页面时)，则返回 0。
     */
    //// 把一物理内存页面映射到指定的线性地址处。
    // 主要工作是在页目录和页表中设置指定页面的信息。若成功则返回页面地址。
    // 在缺页异常的 C 函数 do_no_page()中会调用此函数。对于缺页引起的异常，由于任何缺页缘故而
    // 对页表作修改时，并不需要刷新 CPU 的页变换缓冲（或称 Translation Lookaside Buffer，TLB），
    // 即使页表项中标志 P 被从 0 修改成 1。因为无效页项不会被缓冲，因此当修改了一个无效的页表项
    // 时不需要刷新。在此就表现为不用调用 Invalidate()函数。
    // 参数 page 是分配的主内存区中页面（页帧，页框）的指针；address 是线性地址。
197 unsigned long put_page(unsigned long page,unsigned long address)
198 {
199         unsigned long tmp, *page_table;
200
201 /* NOTE !!! This uses the fact that _pg_dir=0 */
    /* 注意!!!这里使用了页目录基址_pg_dir=0 的条件 */
202
    // 如果申请的页面位置低于 LOW_MEM(1MB)或超出系统实际含有内存高端 HIGH_MEMORY，则发出警告。
    // LOW_MEM 是主内存区可能有的最小起始位置（当系统物理内存小于或等于 6MB 时）。
203         if (page < LOW_MEM || page >= HIGH_MEMORY)
204                 printk("Trying to put page %p at %p\n",page,address);
    // 如果申请的页面在内存页面映射字节图中没有置位，则显示警告信息。
205         if (mem_map[(page-LOW_MEM)>>12] != 1)
206                 printk("mem_map disagrees with %p at %p\n",page,address);
    // 计算指定地址在页目录表中对应的目录项指针。
207         page_table = (unsigned long *) ((address>>20) & 0xffc);
    // 如果该目录项有效(P=1)(也即指定的页表在内存中)，则从中取得指定页表的地址➔page_table。
208         if ((*page_table)&1)
209                 page_table = (unsigned long *) (0xfffff000 & *page_table);
210         else {
    // 否则，申请空闲页面给页表使用，并在对应目录项中置相应标志 7（User, U/S, R/W）。然后将
    // 该页表的地址➔page_table。
```

```
211                 if (!(tmp=get_free_page()))
212                         return 0;
213                 *page_table = tmp|7;
214                 page_table = (unsigned long *) tmp;
215         }
    // 在页表中设置指定地址的物理内存页面的页表项内容。每个页表共可有 1024 项(0x3ff)。
216         page_table[(address>>12) & 0x3ff] = page | 7;
217 /* no need for invalidate */
    /* 不需要刷新页变换高速缓冲 */
218         return page;        // 返回页面地址。
219 }
220
    //// 取消写保护页面函数。用于页异常中断过程中写保护异常的处理（写时复制）。
    // 输入参数为页表项指针，是线性地址。
    // [ un_wp_page 意思是取消页面的写保护：Un-Write Protected。]
    // 在程序创建进程时，新进程与原进程共享代码和数据内存页面。而当新进程或原进程需要向内存
    // 页面写数据时 CPU 就会检测到这个情况并产生页面写保护异常。于是在这个函数中内核就会首先
    // 判断要写的页面是否被共享。若是则需要重新申请一新页面给写进程单独使用。共享被取消。
221 void un_wp_page(unsigned long * table_entry)
222 {
223         unsigned long old_page,new_page;
224
225         old_page = 0xfffff000 & *table_entry;  // 取指定页表项内物理页面位置（地址）。
    // 如果原页面地址大于内存低端 LOW_MEM(1Mb)，并且其在页面映射字节图数组中值为 1（表示仅
    // 被引用 1 次，页面没有被共享），则在该页面的页表项中置 R/W 标志（可写），并刷新页变换
    // 高速缓冲，然后返回。
    // 判断原页面地址是否大于内存低端的作用是看原页面是否在主内存区中。如果该内存页面此时
    // 只被一个进程使用,就直接把属性改为可写即可，不用再重新新申请一个新页面。
226         if (old_page >= LOW_MEM && mem_map[MAP_NR(old_page)]==1) {
227                 *table_entry |= 2;
228                 invalidate();
229                 return;
230         }
    // 否则，在主内存区内申请一页空闲页面。
231         if (!(new_page=get_free_page()))
232                 oom();                          // Out of Memory。内存不够处理。
    // 如果原页面大于内存低端（则意味着 mem_map[]>1，页面是共享的），则将原页面的页面映射
    // 数组值递减 1。然后将指定页表项内容更新为新页面的地址，并置可读写等标志(U/S, R/W, P)。
    // 刷新页变换高速缓冲。最后将原页面内容复制到新页面。
233         if (old_page >= LOW_MEM)
234                 mem_map[MAP_NR(old_page)]--;
235         *table_entry = new_page | 7;
236         invalidate();
237         copy_page(old_page,new_page);
238 }
239
240 /*
241  * This routine handles present pages, when users try to write
242  * to a shared page. It is done by copying the page to a new address
243  * and decrementing the shared-page counter for the old page.
244  *
245  * If it's in code space we exit with a segment error.
246  */
```

```
    /*
     * 当用户试图往一个共享页面上写时，该函数处理已存在的内存页面，（写时复制）
     * 它是通过将页面复制到一个新地址上并递减原页面的共享页面计数值实现的。
     *
     * 如果它在代码空间，我们就以段错误信息退出。
     */
    //// 页异常中断处理调用的 C 函数。写共享页面处理函数。在 page.s 程序中被调用。
    // 参数 error_code 是由 CPU 自动产生，address 是页面线性地址。
    // 写共享页面时，需复制页面（写时复制）。
247 void do_wp_page(unsigned long error_code,unsigned long address)
248 {
249 #if 0
250 /* we cannot do this yet: the estdio library writes to code space */
251 /* stupid, stupid. I really want the libc.a from GNU */
    /* 我们现在还不能这样做：因为 estdio 库会在代码空间执行写操作 */
    /* 真是太愚蠢了。我真想从 GNU 得到 libc.a 库。*/
252         if (CODE_SPACE(address))        // 如果地址位于代码空间，则终止执行程序。
253                 do_exit(SIGSEGV);
254 #endif
    // 处理取消页面保护。参数指定页面在页表中的页表项指针，其计算方法是：
    // ((address>>10) & 0xffc)：计算指定地址的页面在页表中的偏移地址；
    // (0xfffff000 & *((address>>20) &0xffc))：取目录项中页表的地址值，
    // 其中((address>>20) &0xffc)计算页面所在页表的目录项指针；
    // 两者相加即得指定地址对应页面的页表项指针。这里对共享的页面进行复制。
255         un_wp_page((unsigned long *)
256                 (((address>>10) & 0xffc) + (0xfffff000 &
257                 *((unsigned long *) ((address>>20) &0xffc)))));
258
259 }
260
    //// 写页面验证。
    // 若页面不可写，则复制页面。在 fork.c 第 34 行被调用。
261 void write_verify(unsigned long address)
262 {
263         unsigned long page;
264
    // 判断指定地址所对应页目录项的页表是否存在(P)，若不存在(P=0)则返回。
265         if (!( (page = *((unsigned long *) ((address>>20) & 0xffc)) )&1))
266                 return;
    // 取页表的地址，加上指定地址的页面在页表中的页表项偏移值，得对应物理页面的页表项指针。
267         page &= 0xfffff000;
268         page += ((address>>10) & 0xffc);
    // 如果该页面不可写(标志 R/W 没有置位)，则执行共享检验和复制页面操作（写时复制）。
269         if ((3 & *(unsigned long *) page) == 1)  /* non-writeable, present */
270                 un_wp_page((unsigned long *) page);
271         return;
272 }
273
    //// 取得一页空闲内存并映射到指定线性地址处。
    // 与 get_free_page()不同。get_free_page()仅是申请取得了主内存区的一页物理内存。而该函数
    // 不仅是获取到一页物理内存页面，还进一步调用 put_page()，将物理页面映射到指定的线性地址
    // 处。
274 void get_empty_page(unsigned long address)
```

```
275 {
276         unsigned long tmp;
277
    // 若不能取得一空闲页面，或者不能将页面放置到指定地址处，则显示内存不够的信息。
    // 279 行上英文注释的含义是：free_page()函数的参数是 0（tmp 是 0）也没有关系，该函数会忽
    // 略它并正常返回。
278         if (!(tmp=get_free_page()) || !put_page(tmp,address)) {
279                 free_page(tmp);         /* 0 is ok - ignored */
280                 oom();
281         }
282 }
283
284 /*
285  * try_to_share() checks the page at address "address" in the task "p",
286  * to see if it exists, and if it is clean. If so, share it with the current
287  * task.
288  *
289  * NOTE! This assumes we have checked that p != current, and that they
290  * share the same executable.
291  */
    /*
     * try_to_share()在任务"p"中检查位于地址"address"处的页面，看页面是否存在，是否干净。
     * 如果是干净的话，就与当前任务共享。
     *
     * 注意！这里我们已假定 p !=当前任务，并且它们共享同一个执行程序。
     */
    //// 尝试对当前进程指定地址处的页面进行共享处理。
    // 当前进程与进程 p 是同一执行代码，也可以认为当前进程是由 p 进程执行 fork 操作产生的进程，
    // 因此它们的代码内容一样。如果未对数据段内容作过修改那么数据段内容也一样。参数 address
    // 是进程中的逻辑地址，是当前进程欲与 p 进程共享页面的逻辑页面地址。进程 p 是将被共享页面
    // 的进程。如果 p 进程 address 处的页面存在并且没有被修改过的话，就让当前进程与 p 进程共享
    // 之。同时还需要验证指定的地址处是否已经申请了页面，若是则出错，死机。
    // 返回 1-页面共享处理成功，0-失败。
292 static int try_to_share(unsigned long address, struct task_struct * p)
293 {
294         unsigned long from;
295         unsigned long to;
296         unsigned long from_page;
297         unsigned long to_page;
298         unsigned long phys_addr;
299
    // 求进程指定地址 address 处的'逻辑'页目录项号，即以进程空间（0--64MB）算出的页目录项号。
300         from_page = to_page = ((address>>20) & 0xffc);
    // '逻辑'页目录项号加上进程 p 的代码在 CPU 4G 线性空间中起始地址处的页目录项，得到进程 p 中
    // 地址 address 处页面所对应的 4G 线性空间中的实际页目录项。
301         from_page += ((p->start_code>>20) & 0xffc);
    // '逻辑'页目录项号加上当前进程代码在 CPU 4G 线性空间中起始地址处的页目录项，得到当前进程
    // 中地址 address 处所对应的 4G 线性空间中的实际页目录项。
302         to_page += ((current->start_code>>20) & 0xffc);
303 /* is there a page-directory at from? */
    /* 在 from 处是否存在页目录？*/
    // *** 对 p 进程页面进行操作。
    // 取页目录项内容。如果该目录项无效(P=0)，则返回。否则取该目录项对应页表地址➔from。
```

```
304         from = *(unsigned long *) from_page;
305         if (!(from & 1))
306                 return 0;
307         from &= 0xfffff000;
    // 计算地址对应的页表项指针值，并取出该页表项内容➔phys_addr。
308         from_page = from + ((address>>10) & 0xffc);
309         phys_addr = *(unsigned long *) from_page;
310 /* is the page clean and present? */
    /* 页面干净并且存在吗？*/
    // 0x41 对应页表项中的 Dirty 和 Present 标志。如果页面不干净或无效则返回。
311         if ((phys_addr & 0x41) != 0x01)
312                 return 0;
    // 取页面的地址➔phys_addr。如果该页面地址不存在或小于内存低端(1M)也返回退出。
313         phys_addr &= 0xfffff000;
314         if (phys_addr >= HIGH_MEMORY || phys_addr < LOW_MEM)
315                 return 0;
    // *** 对当前进程页面进行操作。
    // 取页目录项内容➔to。如果该目录项无效(P=0)，则取空闲页面，并更新 to_page 所指的目录项。
316         to = *(unsigned long *) to_page;
317         if (!(to & 1))
318                 if (to = get_free_page())
319                         *(unsigned long *) to_page = to | 7;
320                 else
321                         oom();
    // 取对应页表地址➔to，页表项地址➔to_page。如果对应的页面已经存在，则出错，死机。
322         to &= 0xfffff000;
323         to_page = to + ((address>>10) & 0xffc);
324         if (1 & *(unsigned long *) to_page)
325                 panic("try_to_share: to_page already exists");
326 /* share them: write-protect */
    /* 对它们进行共享处理：写保护 */
    // 对 p 进程中页面置写保护标志(置 R/W=0 只读)。并且当前进程中的对应页表项指向它。
327         *(unsigned long *) from_page &= ~2;
328         *(unsigned long *) to_page = *(unsigned long *) from_page;
    // 刷新页变换高速缓冲。
329         invalidate();
    // 计算所操作页面的页面号，并将对应页面映射数组项中的引用递增 1。
330         phys_addr -= LOW_MEM;
331         phys_addr >>= 12;
332         mem_map[phys_addr]++;
333         return 1;
334 }
335
336 /*
337  * share_page() tries to find a process that could share a page with
338  * the current one. Address is the address of the wanted page relative
339  * to the current data space.
340  *
341  * We first check if it is at all feasible by checking executable->i_count.
342  * It should be >1 if there are other tasks sharing this inode.
343  */
    /*
     * share_page()试图找到一个进程，它可以与当前进程共享页面。参数 address 是
```

```
     * 当前数据空间中期望共享的某页面地址。
     *
     * 首先我们通过检测 executable->i_count 来查证是否可行。如果有其他任务已共享
     * 该 inode，则它应该大于 1。
     */
    //// 共享页面。在缺页处理时看看能否共享页面。
    // 返回 1 - 成功，0 - 失败。
344 static int share_page(unsigned long address)
345 {
346         struct task_struct ** p;
347
    // 如果是不可执行的，则返回。excutable 是执行进程的内存 i 节点结构。
348         if (!current->executable)
349                 return 0;
    // 如果只能单独执行(executable->i_count=1)，也退出。
350         if (current->executable->i_count < 2)
351                 return 0;
    // 搜索任务数组中所有任务。寻找与当前进程可共享页面的进程，并尝试对指定地址的页面进行共享。
352         for (p = &LAST_TASK ; p > &FIRST_TASK ; --p) {
353                 if (!*p)                        // 如果该任务项空闲，则继续寻找。
354                         continue;
355                 if (current == *p)              // 如果就是当前任务，也继续寻找。
356                         continue;
357                 if ((*p)->executable != current->executable) // 如果 executable 不等，也继续。
358                         continue;
359                 if (try_to_share(address,*p)) // 尝试共享页面。
360                         return 1;
361         }
362         return 0;
363 }
364
    //// 页异常中断处理调用的函数。处理缺页异常情况。在 page.s 程序中被调用。
    // 参数 error_code 是由 CPU 自动产生，address 是页面线性地址。
365 void do_no_page(unsigned long error_code,unsigned long address)
366 {
367         int nr[4];
368         unsigned long tmp;
369         unsigned long page;
370         int block,i;
371
372         address &= 0xfffff000;          // 页面地址。
    // 首先算出指定线性地址在进程空间中相对于进程基址的偏移长度值。
373         tmp = address - current->start_code;
    // 若当前进程的 executable 空，或者指定地址超出代码+数据长度，则申请一页物理内存，并映射
    // 到指定的线性地址处。executable 是进程的 i 节点结构。如果该值为 0，表明进程刚开始设置，
    // 需要内存；而指定的线性地址超出代码加数据长度，表明进程在申请新的内存空间，也需要给予。
    // 因此就直接调用 get_empty_page()函数，申请一页物理内存并映射到指定线性地址处即可。
    // start_code 是进程代码段地址，end_data 是代码加数据长度。对于 Linux 内核，它的代码段和
    // 数据段是起始基址是相同的。
374         if (!current->executable || tmp >= current->end_data) {
375                 get_empty_page(address);
376                 return;
377         }
```

```
    // 如果尝试共享页面成功，则退出。
378         if (share_page(tmp))
379                 return;
    // 取空闲页面，如果内存不够了，则显示内存不够，终止进程。
380         if (!(page = get_free_page()))
381                 oom();
382 /* remember that 1 block is used for header */
    /* 记住，（程序）头要使用 1 个数据块 */
    // 因为块设备上存放的执行文件映像第 1 块数据是程序头，因此在读取该文件时需要跳过第 1 块数据。
    // 首先计算缺页所在的数据块项。BLOCK_SIZE = 1024 字节，因此一页内存需要 4 个数据块。
383         block = 1 + tmp/BLOCK_SIZE;
    // 根据 i 节点信息，取数据块在设备上的对应的逻辑块号。
384         for (i=0 ; i<4 ; block++,i++)
385                 nr[i] = bmap(current->executable,block);
    // 读设备上一个页面的数据（4 个逻辑块）到指定物理地址 page 处。
386         bread_page(page,current->executable->i_dev,nr);
    // 在增加了一页内存后，该页内存的部分可能会超过进程的 end_data 位置。下面的循环即是对物理
    // 页面超出的部分进行清零处理。
387         i = tmp + 4096 - current->end_data;
388         tmp = page + 4096;
389         while (i-- > 0) {
390                 tmp--;
391                 *(char *)tmp = 0;
392         }
    // 如果把物理页面映射到指定线性地址的操作成功，就返回。否则就释放内存页，显示内存不够。
393         if (put_page(page,address))
394                 return;
395         free_page(page);
396         oom();
397 }
398
    //// 物理内存初始化。
    // 参数：start_mem - 可用作分页处理的物理内存起始位置（已去除 RAMDISK 所占内存空间等）。
    //       end_mem   - 实际物理内存最大地址。
    // 在该版的 Linux 内核中，最多能使用 16Mb 的物理内存，大于 16Mb 的内存将不于考虑，弃置不用。
    // 对于具有 16Mb 物理内存的系统，在没有 RAMDISK 的情况下 start_mem 通常是 4Mb，end_mem 是 16Mb。
    // 0 - 1Mb 内存空间用于内核系统（其实是 0-640Kb）。
399 void mem_init(long start_mem, long end_mem)
400 {
401         int i;
402
403         HIGH_MEMORY = end_mem;                  // 设置内存最高端。
    // 首先置对应从 1Mb 到 16Mb 范围的所有页面为已占用状态，即将页面映射数组全置成 USED(100)。
404         for (i=0 ; i<PAGING_PAGES ; i++)
405                 mem_map[i] = USED;
    // 然后计算可使用起始内存页面号 i 和可作为主内存区进行分页处理的内存大小。从而计算出可用于
    // 分页处理的页面数。
406         i = MAP_NR(start_mem);                  // 得到可用起始页面号。
407         end_mem -= start_mem;
408         end_mem >>= 12;                         // 得到可用于分页处理的页面数。
    // 最后将这些可用页面对应的页面映射数组项清零。对于有 16Mb 的系统，mem_map[]中对应 4Mb-16Mb
    // 的项被清零。
409         while (end_mem-->0)
```

```
410                 mem_map[i++]=0;
411 }
412
    // 计算内存空闲页面数并显示。
413 void calc_mem(void)
414 {
415         int i,j,k,free=0;
416         long * pg_tbl;
417
    // 扫描内存页面映射数组 mem_map[]，获取空闲页面数并显示。
418         for(i=0 ; i<PAGING_PAGES ; i++)
419                 if (!mem_map[i]) free++;
420         printk("%d pages free (of %d)\n\r",free,PAGING_PAGES);
    // 扫描所有页目录项（除 0，1 项），如果页目录项有效，则统计对应页表中有效页面数，并显示。
421         for(i=2 ; i<1024 ; i++) {
422                 if (1&pg_dir[i]) {
423                         pg_tbl=(long *) (0xfffff000 & pg_dir[i]);
424                         for(j=k=0 ; j<1024 ; j++)
425                                 if (pg_tbl[j]&1)
426                                         k++;
427                         printk("Pg-dir[%d] uses %d pages\n",i,k);
428                 }
429         }
430 }
431
```

10.5 page.s 程序

10.5.1 功能描述

该文件包括页异常中断处理程序（中断 14），主要分两种情况处理。一是由于缺页引起的页异常中断，通过调用 do_no_page(error_code, address)来处理；二是由页写保护引起的页异常，此时调用页写保护处理函数 do_wp_page(error_code, address)进行处理。其中的出错码(error_code)是由 CPU 自动产生并压入堆栈的，出现异常时访问的线性地址是从控制寄存器 CR2 中取得的。CR2 是专门用来存放页出错时的线性地址。

10.5.2 代码注释

程序 10-3 linux/mm/page.s

```
 1 /*
 2  *  linux/mm/page.s
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * page.s contains the low-level page-exception code.
 9  * the real work is done in mm.c
10  */
```

```
/*
 * page.s 程序包含底层页异常处理代码。实际的工作在 memory.c 中完成。
 */
11
12 .globl _page_fault
13
14 _page_fault:
15         xchgl %eax,(%esp)     # 取出错码到 eax。
16         pushl %ecx
17         pushl %edx
18         push %ds
19         push %es
20         push %fs
21         movl $0x10,%edx       # 置内核数据段选择符。
22         mov %dx,%ds
23         mov %dx,%es
24         mov %dx,%fs
25         movl %cr2,%edx        # 取引起页面异常的线性地址
26         pushl %edx            # 将该线性地址和出错码压入堆栈，作为调用函数的参数。
27         pushl %eax
28         testl $1,%eax         # 测试标志 P，如果不是缺页引起的异常则跳转。
29         jne 1f
30         call _do_no_page      # 调用缺页处理函数（mm/memory.c,365 行）。
31         jmp 2f
32 1:      call _do_wp_page      # 调用写保护处理函数（mm/memory.c,247 行）。
33 2:      addl $8,%esp          # 丢弃压入栈的两个参数。
34         pop %fs
35         pop %es
36         pop %ds
37         popl %edx
38         popl %ecx
39         popl %eax
40         iret
```

10.5.3 其他信息

10.5.3.1 页异常的处理

当处理器在转换线性地址到物理地址的过程中检测到以下两种条件时，就会发生页异常中断，中断 14。

- 当 CPU 发现对应页目录项或页表项的存在位（Present）标志为 0。
- 当前进程没有访问指定页面的权限。

对于页异常处理中断，CPU 提供了两项信息用来诊断页异常和从中恢复运行。

(1) 放在堆栈上的出错码。该出错码指出了异常是由于页不存在引起的还是违反了访问权限引起的；在发生异常时 CPU 的当前特权层；以及是读操作还是写操作。出错码的格式是一个 32 位的长字。但只用了最后的 3 个比特位。分别说明导致异常发生时的原因：

位 2(U/S) - 0 表示在超级用户模式下执行，1 表示在用户模式下执行；

位 1(W/R) - 0 表示读操作，1 表示写操作；

位 0(P) - 0 表示页不存在，1 表示页级保护。

(2) CR2(控制寄存器 2)。CPU 将造成异常的用于访问的线性地址存放在 CR2 中。异常处理程序可以使用这个地址来定位相应的页目录和页表项。如果在页异常处理程序执行期间允许发生另一个页异常，那么处理程序应该将 CR2 压入堆栈中。

第11章 头文件(include)

11.1 概述

程序在使用一个函数之前，应该首先声明该函数。为了便于使用，通常的做法是把同一类函数或数据结构以及常数的声明放在一个头文件（header file）中。头文件中也可以包括任何相关的类型定义和宏（macros）。在程序源代码文件中则使用预处理指令“#include”来引用相关的头文件。

在一般应用程序源代码中，头文件与开发环境中的库文件有着不可分割的紧密联系，库中的每个函数都需要在头文件中加以声明。应用程序开发环境中的头文件（通常放置在系统/usr/include/目录中）可以看作是其所提供函数库（例如 libc.a）中函数的一个组成部分，是库函数的使用说明或接口声明。在编译器把源代码程序转换成目标模块后，链接程序（linker）会把程序所有的目标模块组合在一起，包括用到的任何库文件中的模块。从而构成一个可执行的程序。

对于标准 C 函数库来讲，其最基本的头文件有 15 个。每个头文件都表示出一类特定函数的功能说明或结构定义，例如 I/O 操作函数、字符处理函数等。有关标准函数库的详细说明及其实现可参照 Plauger 编著的《The Standard C Library》一书。

而对于本书所描述的内核源代码，其中涉及到的头文件则可以看作是对内核及其函数库所提供服务的一个概要说明，是内核及其相关程序专用的头文件。在这些头文件中主要描述了内核所用到的所有数据结构、初始化数据、常数和宏定义，也包括少量的程序代码。

11.2 include/目录下的文件

内核所用到的头文件都保存在 include/目录下。该目录下的文件见列表 11.1 所示。这里需要说明一点：为了方便使用和兼容性，Linus 在编制内核程序头文件时所使用的命名方式与标准 C 库头文件的命名方式相似，许多头文件的名称甚至其中的一些内容都与标准 C 库的头文件基本相同，但这些内核头文件仍然是内核源代码或与内核有紧密联系的程序专用的。在一个 Linux 系统中，它们与标准库的头文件并存。通常的做法是将这些头文件放置在标准库头文件目录中的子目录下，以让需要用到内核数据结构或常数的程序使用。

另外，也由于版权问题，Linus 试图重新编制一些头文件以取代具有版权限制的标准 C 库的头文件。因此这些内核源代码中的头文件与开发环境中的头文件有一些重叠的地方。在 Linux 系统中，列表 11-1 中的 asm/、linux/和 sys/三个子目录下的内核头文件通常需要复制到标准 C 库头文件所在的目录（/usr/include）中，而其他一些文件若与标准库的头文件没有冲突则可以直接放到标准库头文件目录下，或者改放到这里的三个子目录中。

asm/目录下主要用于存放与计算机体系结构密切相关的函数声明或数据结构的头文件。linux/目录下是 Linux 内核程序使用的一些头文件。而 sys/目录下存放着 5 个与内核资源相关头文件。

Linux 0.11 版内核中共有 32 个头文件(*.h)，其中 asm/子目录中含有 4 个，linux/子目录中含有 10 个，sys/子目录中含有 5 个。从下一节开始我们首先描述 include/目录下的 13 个头文件，然后依次说明每个子目录中的文件。说明顺序按照文件名称排序进行。

列表 11-1 linux/include/目录下的文件

	名称	大小	最后修改时间(GMT)	说明
	asm/		1991-09-17 13:08:31	
	linux/		1991-11-02 13:35:49	
	sys/		1991-09-17 15:06:07	
	a.out.h	6047 bytes	1991-09-17 15:10:49	m
	const.h	321 bytes	1991-09-17 15:12:39	m
	ctype.h	1049 bytes	1991-11-07 17:30:47	m
	errno.h	1268 bytes	1991-09-17 15:04:15	m
	fcntl.h	1374 bytes	1991-09-17 15:12:39	m
	signal.h	1762 bytes	1991-09-22 19:58:04	m
	stdarg.h	780 bytes	1991-09-17 15:02:23	m
	stddef.h	286 bytes	1991-09-17 15:02:17	m
	string.h	7881 bytes	1991-09-17 15:04:09	m
	termios.h	5325 bytes	1991-11-25 20:02:08	m
	time.h	734 bytes	1991-09-17 15:02:02	m
	unistd.h	6410 bytes	1991-11-25 20:18:55	m
	utime.h	225 bytes	1991-09-17 15:03:38	m

11.3 a.out.h 文件

11.3.1 功能描述

a.out.h 文件不属于标准 C 库，是内核专用的头文件。但由于与标准库的头文件名没有冲突，因此在 Linux 系统中一般可以放置/usr/include/目录下，以供涉及相关内容的程序使用。该头文件主要定义了二进制执行文件 a.out(Assembley out)的格式。其中包括三个数据结构和一些宏函数。

从 Linux 0.9x 版内核开始（从 0.96 开始），系统直接采用了 GNU 的头文件 a.out.h。因此造成在 Linux 0.9x 下编译的程序不能在 Linux 0.1x 系统上运行。下面分析一下两个 a.out 头文件的区别之处，并说明如何让 0.9x 下的执行文件也能在 0.1x 下运行。

本文件与 GNU 的 a.out.h 文件的主要区别在于 exec 结构的第一个字段 a_magic。GNU 的该文件字段名称是 a_info，并且把该字段又分成 3 个子域：标志域（Flags）、机器类型域（Machine Type）和魔数域（Magic Number）。同时为机器类型域定义了相应的宏 N_MACHTYPE 和 N_FLAGS。见图 11-1 所示。

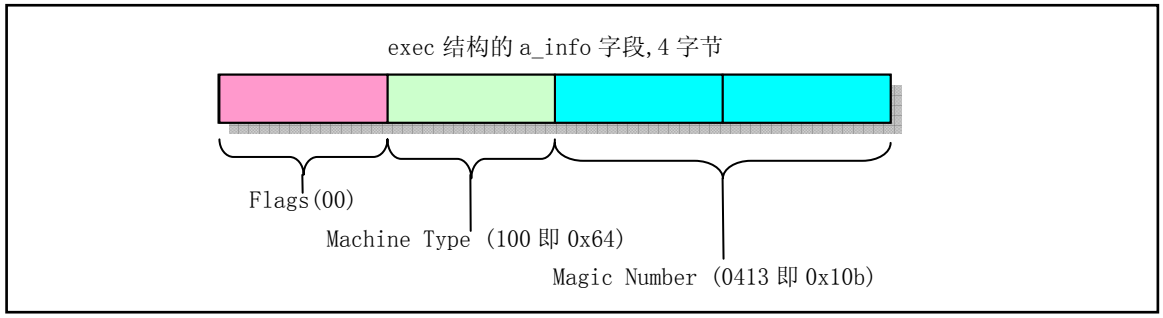

图 11-1 执行文件头结构 exec 中的第一个字段 a_magic（a_info）

在 Linux 0.9x 系统中，对于采用静态库连接的执行文件，图中各域注释中括号内的值是该字段的默认值。这种二进制执行文件开始处的 4 个字节是：

0x0b, 0x01, 0x64, 0x00

而这里的头文件仅定义了魔数域。因此，在 Linux 0.1x 系统中一个 a.out 格式的二进制执行文件开始的 4 个字节是：

0x0b, 0x01, 0x00, 0x00

可以看出，采用 GNU 的 a.out 格式的执行文件与 Linux 0.1x 系统上编译出的执行文件的区别仅在机器类型域。因此我们可以把 Linux 0.9x 上的 a.out 格式执行文件的机器类型域（第 3 个字节）清零，让其运行在 0.1x 系统中。只要被移植的执行文件所调用的系统调用都已经在 0.1x 系统中实现即可。在开始组建 Linux 0.1x 根文件系统中的很多命令时，作者就采用了这种方法。

GNU 的 a.out.h 头文件与这里的 a.out.h 头文件在其他方面没有什么区别。另外，可以参考列表后对 BSD 系统 a.out.h 文件的说明。

11.3.2 代码注释

程序 11-1 linux/include/a.out.h

```
 1 #ifndef _A_OUT_H
 2 #define _A_OUT_H
 3
 4 #define __GNU_EXEC_MACROS__
 5
   // 执行文件头结构。
   // ============================
   // unsigned long a_magic        // 执行文件魔数。使用 N_MAGIC 等宏访问。
   // unsigned a_text              // 代码长度，字节数。
   // unsigned a_data              // 数据长度，字节数。
   // unsigned a_bss               // 文件中的未初始化数据区长度，字节数。
   // unsigned a_syms              // 文件中的符号表长度，字节数。
   // unsigned a_entry             // 执行开始地址。
   // unsigned a_trsize            // 代码重定位信息长度，字节数。
   // unsigned a_drsize            // 数据重定位信息长度，字节数。
   // ----------------------------
 6 struct exec {
 7   unsigned long a_magic;        /* Use macros N_MAGIC, etc for access */
 8   unsigned a_text;              /* length of text, in bytes */
 9   unsigned a_data;              /* length of data, in bytes */
10   unsigned a_bss;               /* length of uninitialized data area for file, in bytes */
11   unsigned a_syms;              /* length of symbol table data in file, in bytes */
12   unsigned a_entry;             /* start address */
13   unsigned a_trsize;            /* length of relocation info for text, in bytes */
14   unsigned a_drsize;            /* length of relocation info for data, in bytes */
15 };
```

```
16
   // 用于取执行结构中的魔数。
17 #ifndef N_MAGIC
18 #define N_MAGIC(exec) ((exec).a_magic)
19 #endif
20
21 #ifndef OMAGIC
22 /* Code indicating object file or impure executable.  */
   /* 指明为目标文件或者不纯的可执行文件的代号 */
23 #define OMAGIC 0407
   // 历史上，最早在 PDP-11 计算机上，魔数（幻数）是八进制数 0407。它位于执行程序头结构的开始处。
   // 原本是 PDP-11 的一条跳转指令，表示跳转到随后 7 个字后的代码开始处。这样加载程序(loader)就
   // 可以在把执行文件放入内存后直接跳转到指令开始处运行。现在已没有程序使用这种方法了，但这个
   // 八进制数却作为识别文件类型的标志（魔数）保留了下来。OMAGIC 可以认为是 Old Magic 的意思。
24 /* Code indicating pure executable.  */
   /* 指明为纯可执行文件的代号 */          // New Magic，1975 年以后开始使用。涉及虚存机制。
25 #define NMAGIC 0410
26 /* Code indicating demand-paged executable.  */
   /* 指明为需求分页处理的可执行文件 */    // 其头结构占用一页（4K）。
27 #define ZMAGIC 0413
28 #endif /* not OMAGIC */
29 // 另外还有一个 QMAGIC，是为了节约磁盘容量，把盘上执行文件的头结构与代码紧凑存放。
   // 如果魔数不能被识别，则返回真。
30 #ifndef N_BADMAG
31 #define N_BADMAG(x)                                     \
32  (N_MAGIC(x) != OMAGIC && N_MAGIC(x) != NMAGIC          \
33   && N_MAGIC(x) != ZMAGIC)
34 #endif
35
36 #define _N_BADMAG(x)                                    \
37  (N_MAGIC(x) != OMAGIC && N_MAGIC(x) != NMAGIC          \
38   && N_MAGIC(x) != ZMAGIC)
39
   // 程序头在内存中的偏移位置。
40 #define _N_HDROFF(x) (SEGMENT_SIZE - sizeof (struct exec))
41
   // 代码起始偏移值。
42 #ifndef N_TXTOFF
43 #define N_TXTOFF(x) \
44  (N_MAGIC(x) == ZMAGIC ? _N_HDROFF((x)) + sizeof (struct exec) : sizeof (struct exec))
45 #endif
46
   // 数据起始偏移值。
47 #ifndef N_DATOFF
48 #define N_DATOFF(x) (N_TXTOFF(x) + (x).a_text)
49 #endif
50
   // 代码重定位信息偏移值。
51 #ifndef N_TRELOFF
52 #define N_TRELOFF(x) (N_DATOFF(x) + (x).a_data)
53 #endif
54
   // 数据重定位信息偏移值。
```

```
55 #ifndef N_DRELOFF
56 #define N_DRELOFF(x) (N_TRELOFF(x) + (x).a_trsize)
57 #endif
58
   // 符号表偏移值。
59 #ifndef N_SYMOFF
60 #define N_SYMOFF(x) (N_DRELOFF(x) + (x).a_drsize)
61 #endif
62
   // 字符串信息偏移值。
63 #ifndef N_STROFF
64 #define N_STROFF(x) (N_SYMOFF(x) + (x).a_syms)
65 #endif
66
67 /* Address of text segment in memory after it is loaded.  */
   /* 代码段加载到内存中后的地址 */
68 #ifndef N_TXTADDR
69 #define N_TXTADDR(x) 0
70 #endif
71
72 /* Address of data segment in memory after it is loaded.
73    Note that it is up to you to define SEGMENT_SIZE
74    on machines not listed here.  */
   /* 数据段加载到内存中后的地址。
      注意，对于下面没有列出名称的机器，需要你自己来定义
      对应的 SEGMENT_SIZE */
75 #if defined(vax) || defined(hp300) || defined(pyr)
76 #define SEGMENT_SIZE PAGE_SIZE
77 #endif
78 #ifdef  hp300
79 #define PAGE_SIZE       4096
80 #endif
81 #ifdef  sony
82 #define SEGMENT_SIZE    0x2000
83 #endif  /* Sony.  */
84 #ifdef is68k
85 #define SEGMENT_SIZE 0x20000
86 #endif
87 #if defined(m68k) && defined(PORTAR)
88 #define PAGE_SIZE 0x400
89 #define SEGMENT_SIZE PAGE_SIZE
90 #endif
91
92 #define PAGE_SIZE 4096
93 #define SEGMENT_SIZE 1024
94
   // 以段为界的大小。
95 #define _N_SEGMENT_ROUND(x) (((x) + SEGMENT_SIZE - 1) & ~(SEGMENT_SIZE - 1))
96
   // 代码段尾地址。
97 #define _N_TXTENDADDR(x) (N_TXTADDR(x)+(x).a_text)
98
   // 数据开始地址。
```

```
 99 #ifndef N_DATADDR
100 #define N_DATADDR(x) \
101     (N_MAGIC(x)==OMAGIC? (_N_TXTENDADDR(x)) \
102      : (_N_SEGMENT_ROUND (_N_TXTENDADDR(x))))
103 #endif
104
105 /* Address of bss segment in memory after it is loaded.  */
    /* bss 段加载到内存以后的地址 */
106 #ifndef N_BSSADDR
107 #define N_BSSADDR(x) (N_DATADDR(x) + (x).a_data)
108 #endif
109
    // nlist 结构。符号表记录结构。
110 #ifndef N_NLIST_DECLARED
111 struct nlist {
112   union {
113     char *n_name;
114     struct nlist *n_next;
115     long n_strx;
116   } n_un;
117   unsigned char n_type;             // 该字节分成 3 个字段，146-154 行是相应字段的屏蔽码。
118   char n_other;
119   short n_desc;
120   unsigned long n_value;
121 };
122 #endif
123
    // 下面定义 exec 结构中的变量偏移值。
124 #ifndef N_UNDF
125 #define N_UNDF 0
126 #endif
127 #ifndef N_ABS
128 #define N_ABS 2
129 #endif
130 #ifndef N_TEXT
131 #define N_TEXT 4
132 #endif
133 #ifndef N_DATA
134 #define N_DATA 6
135 #endif
136 #ifndef N_BSS
137 #define N_BSS 8
138 #endif
139 #ifndef N_COMM
140 #define N_COMM 18
141 #endif
142 #ifndef N_FN
143 #define N_FN 15
144 #endif
145
    // 以下 3 个常量定义是 nlist 结构中 n_type 变量的屏蔽码（八进程表示）。
146 #ifndef N_EXT
147 #define N_EXT 1
```

```
148 #endif
149 #ifndef N_TYPE
150 #define N_TYPE 036
151 #endif
152 #ifndef N_STAB
153 #define N_STAB 0340
154 #endif
155
156 /* The following type indicates the definition of a symbol as being
157    an indirect reference to another symbol.  The other symbol
158    appears as an undefined reference, immediately following this symbol.
159
160    Indirection is asymmetrical.  The other symbol's value will be used
161    to satisfy requests for the indirect symbol, but not vice versa.
162    If the other symbol does not have a definition, libraries will
163    be searched to find a definition.  */
    /* 下面的类型指明了符号的定义作为对另一个符号的间接引用。紧接该符号的其他
     * 的符号呈现为未定义的引用。
     *
     * 间接性是不对称的。其他符号的值将被用于满足间接符号的请求，但反之不然。
     * 如果其他符号并没有定义，则将搜索库来寻找一个定义 */
164 #define N_INDR 0xa
165
166 /* The following symbols refer to set elements.
167    All the N_SET[ATDB] symbols with the same name form one set.
168    Space is allocated for the set in the text section, and each set
169    element's value is stored into one word of the space.
170    The first word of the space is the length of the set (number of elements).
171
172    The address of the set is made into an N_SETV symbol
173    whose name is the same as the name of the set.
174    This symbol acts like a N_DATA global symbol
175    in that it can satisfy undefined external references.  */
    /* 下面的符号与集合元素有关。所有具有相同名称 N_SET[ATDB]的符号
       形成一个集合。在代码部分中已为集合分配了空间，并且每个集合元素
       的值存放在一个字（word）的空间。空间的第一个字存有集合的长度（集合元素数目）。

       集合的地址被放入一个 N_SETV 符号，它的名称与集合同名。
       在满足未定义的外部引用方面，该符号的行为象一个 N_DATA 全局符号。*/
176
177 /* These appear as input to LD, in a .o file.  */
    /* 以下这些符号在目标文件中是作为链接程序 LD 的输入。*/
178 #define N_SETA  0x14            /* Absolute set element symbol */
                                    /* 绝对集合元素符号 */
179 #define N_SETT  0x16            /* Text set element symbol */
                                    /* 代码集合元素符号 */
180 #define N_SETD  0x18            /* Data set element symbol */
                                    /* 数据集合元素符号 */
181 #define N_SETB  0x1A            /* Bss set element symbol */
                                    /* Bss 集合元素符号 */
182
183 /* This is output from LD.  */
    /* 下面是 LD 的输出。*/
```

```
184 #define N_SETV  0x1C            /* Pointer to set vector in data area.  */
                                    /* 指向数据区中集合向量。*/
185
186 #ifndef N_RELOCATION_INFO_DECLARED
187
188 /* This structure describes a single relocation to be performed.
189    The text-relocation section of the file is a vector of these structures,
190    all of which apply to the text section.
191    Likewise, the data-relocation section applies to the data section.  */
    /* 下面的结构描述执行一个重定位的操作。
       文件的代码重定位部分是这些结构的一个向量，所有这些适用于代码部分。
       类似地，数据重定位部分适用于数据部分。*/
192
    // 重定位信息结构。
193 struct relocation_info
194 {
195   /* Address (within segment) to be relocated.  */
      /* 需要重定位的地址（在段内）。*/
196   int r_address;
197   /* The meaning of r_symbolnum depends on r_extern.  */
      /* r_symbolnum 的含义与 r_extern 有关。*/
198   unsigned int r_symbolnum:24;
199   /* Nonzero means value is a pc-relative offset
200      and it should be relocated for changes in its own address
201      as well as for changes in the symbol or section specified.  */
      /* 非零意味着值是一个 pc 相关的偏移值，因而在其自己地址空间
         以及符号或指定的节改变时，需要被重定位 */
202   unsigned int r_pcrel:1;
203   /* Length (as exponent of 2) of the field to be relocated.
204      Thus, a value of 2 indicates 1<<2 bytes.  */
      /* 需要被重定位的字段长度（是 2 的次方）。
         因此，若值是 2 则表示 1<<2 字节数。*/
205   unsigned int r_length:2;
206   /* 1 => relocate with value of symbol.
207         r_symbolnum is the index of the symbol
208         in file's the symbol table.
209      0 => relocate with the address of a segment.
210         r_symbolnum is N_TEXT, N_DATA, N_BSS or N_ABS
211         (the N_EXT bit may be set also, but signifies nothing).  */
      /* 1 => 以符号的值重定位。
            r_symbolnum 是文件符号表中符号的索引。
         0 => 以段的地址进行重定位。
            r_symbolnum 是 N_TEXT、N_DATA、N_BSS 或 N_ABS
            (N_EXT 比特位也可以被设置，但是毫无意义)。*/
212   unsigned int r_extern:1;
213   /* Four bits that aren't used, but when writing an object file
214      it is desirable to clear them.  */
      /* 没有使用的 4 个比特位，但是当进行写一个目标文件时
         最好将它们复位掉。*/
215   unsigned int r_pad:4;
216 };
217 #endif /* no N_RELOCATION_INFO_DECLARED.  */
218
```

```
219
220 #endif /* __A_OUT_GNU_H__ */
221
```

11.3.3 其他信息

11.3.3.1 a.out 执行文件格式

Linux 内核 0.11 版仅支持 a.out(Assembley out)执行文件格式，虽然这种格式目前已经渐渐不用，而使用功能更为齐全的 ELF（Executable and Link Format）格式，但是由于其简单性，作为学习入门的材料正好比较适用。下面全面介绍一下 a.out 格式。

在头文件<a.out.h>中声明了三个数据结构以及一些宏函数。这些数据结构描述了系统上可执行的机器码文件（二进制文件）。

一个执行文件共可有七个部分（七节）组成。按照顺序，这些部分是：

执行头部分(exec header)。执行文件头部分。该部分中含有一些参数，内核使用这些参数将执行文件加载到内存中并执行，而链接程序(ld)使用这些参数将一些二进制目标文件组合成一个可执行文件。这是唯一必要的组成部分。

代码段部分(text segment)。 含有程序执行使被加载到内存中的指令代码和相关数据。可以以只读形式进行加载。

数据段部分(data segment)。这部分含有已经初始化过的数据，总是被加载到可读写的内存中。

代码重定位部分(text relocations)。这部分含有供链接程序使用的记录数据。在组合二进制目标文件时用于定位代码段中的指针或地址。

数据重定位部分(data relocations)。与代码重定位部分的作用类似，但是是用于数据段中指针的重定位。

符号表部分(simbol table)。这部分同样含有供链接程序使用的记录数据，用于在二进制目标文件之间对命名的变量和函数（符号）进行交叉引用。

字符串表部分(string table)。该部分含有与符号名相对应的字符串。

每个二进制执行文件均以一个执行数据结构（exec structure）开始。该数据结构的形式如下：

```
struct exec {
        unsigned long a_midmag;         // a_magic 或 a_info
        unsigned long a_text;
        unsigned long a_data;
        unsigned long a_bss;
        unsigned long a_syms;
        unsigned long a_entry;
        unsigned long a_trsize;
        unsigned long a_drsize;
};
```

各个字段的功能如下：

a_midmag　　该字段含有被 N_GETFLAG()、N_GETMID 和 N_GETMAGIC()访问的子部分，是由链接程序在运行时加载到进程地址空间。宏 N_GETMID()用于返回机器标识符(machine-id)，指示出二进制文件将在什么机器上运行。N_GETMAGIC()宏指明魔数，它唯一地确定了二进制执行文件与其他加载的文件之间的区别。字段中必须包含以下值之一：

OMAGIC　　表示代码和数据段紧随在执行头后面并且是连续存放的。内核将代码和数据段都加载到可读写内存中。

NMAGIC　　同 OMAGIC 一样，代码和数据段紧随在执行头后面并且是连续存放的。然而内核将代码

加载到了只读内存中，并把数据段加载到代码段后下一页可读写内存边界开始。
ZMAGIC内核在必要时从二进制执行文件中加载独立的页面。执行头部、代码段和数据段都被链接程序处理成多个页面大小的块。内核加载的代码页面时只读的，而数据段的页面是可写的。

a_text　　该字段含有代码段的长度值，字节数。

a_data　　该字段含有数据段的长度值，字节数。

a_bss　　含有‘bss 段’的长度，内核用其设置在数据段后初始的 break（brk）。内核在加载程序时，这段可写内存显现出处于数据段后面，并且初始时为全零。

a_syms　　含有符号表部分的字节长度值。

a_entry　　含有内核将执行文件加载到内存中以后，程序执行起始点的内存地址。

a_trsize　该字段含有代码重定位表的大小，是字节数。

a_drsize　该字段含有数据重定位表的大小，是字节数。

在 a.out.h 头文件中定义了几个宏，这些宏使用 exec 结构来测试一致性或者定位执行文件中各个部分（节）的位置偏移值。这些宏有：

N_BADMAG(exec)　　如果 a_magic 字段不能被识别，则返回非零值。

N_TXTOFF(exec)　代码段的起始位置字节偏移值。

N_DATOFF(exec)　数据段的起始位置字节偏移值。

N_DRELOFF(exec)　　数据重定位表的起始位置字节偏移值。

N_TRELOFF(exec)　　代码重定位表的起始位置字节偏移值。

N_SYMOFF(exec)　符号表的起始位置字节偏移值。

N_STROFF(exec)　字符串表的起始位置字节偏移值。

重定位记录具有标准格式，它使用重定位信息(relocation_info)结构来描述：

```
struct relocation_info {
        int             r_address;
        unsigned int    r_symbolnum : 24,
                        r_pcrel : 1,
                        r_length : 2,
                        r_extern : 1,
                        r_baserel : 1,
                        r_jmptable : 1,
                        r_relative : 1,
                        r_copy : 1;
};
```

该结构中各字段的含义如下：

r_address　　该字段含有需要链接程序处理（编辑）的指针的字节偏移值。代码重定位的偏移值是从代码段开始处计数的，数据重定位的偏移值是从数据段开始处计算的。链接程序会将已经存储在该偏移处的值与使用重定位记录计算出的新值相加。

r_symbolnum　　该字段含有符号表中一个符号结构的序号值（不是字节偏移值）。链接程序在算出符号的绝对地址以后，就将该地址加到正在进行重定位的指针上。（如果 r_extern 比特位是 0，那么情况就不同，见下面。）

r_pcrel　　如果设置了该位，链接程序就认为正在更新一个指针，该指针使用 pc 相关寻址方式，是属于机器码指令部分。当运行程序使用这个被重定位的指针时，该指针的地址被隐式地加到该指针上。

r_length　该字段含有指针长度的 2 的次方值：0 表示 1 字节长，1 表示 2 字节长，2 表示 4 字节长。

r_extern　如果被置位，表示该重定位需要一个外部引用；此时链接程序必须使用一个符号地址来更新相应指针。当该位是 0 时，则重定位是“局部”的；链接程序更新指针以反映各个段加载地址中的变化，而不是反映一个符号值的变化（除非同时设置了 r_baserel，见下面）。在这种情况下，r_symbolnum 字段的内容是一个 n_type 值（见下面）；这类字段告诉链接程序被重定位的指针指向那个段。

r_baserel　如果设置了该位，则 r_symbolnum 字段指定的符号将被重定位成全局偏移表(Global Offset Table)中的一个偏移值。在运行时刻，全局偏移表该偏移处被设置为符号的地址。

r_jmptable　如果被置位，则 r_symbolnum 字段指定的符号将被重定位成过程链接表(Procedure Linkage Table)中的一个偏移值。

r_relative　如果被置位，则说明此重定位与该目标文件将成为其组成部分的映像文件在运行时被加载的地址相关。这类重定位仅在共享目标文件中出现。

r_copy　如果被置位，该重定位记录指定了一个符号，该符号的内容将被复制到 r_address 指定的地方。该复制操作是通过共享目标模块中一个合适的数据项中的运行时刻链接程序完成的。

符号将名称映射为地址（或者更通俗地讲是字符串映射到值）。由于链接程序对地址的调整，一个符号的名称必须用来表示其地址，直到已被赋予一个绝对地址值。符号是由符号表中固定长度的记录以及字符串表中的可变长度名称组成。符号表是 nlist 结构的一个数组，如下所示：

```
struct nlist {
        union {
                char    *n_name;
                long    n_strx;
        } n_un;
        unsigned char   n_type;
        char            n_other;
        short           n_desc;
        unsigned long   n_value;
};
```

其中各字段的含义为：

n_un.n_strx　含有本符号的名称在字符串表中的字节偏移值。当程序使用 nlist()函数访问一个符号表时，该字段被替换为 n_un.n_name 字段，这是内存中字符串的指针。

n_type　用于链接程序确定如何更新符号的值。使用位屏蔽(bitmasks)可以将 n_type 字段分割成三个子字段，对于 N_EXT 类型位置位的符号，链接程序将它们看作是“外部的”符号，并且允许其他二进制目标文件对它们的引用。N_TYPE 屏蔽码用于链接程序感兴趣的比特位：

N_UNDF一个未定义的符号。链接程序必须在其他二进制目标文件中定位一个具有相同名称的外部符号，以确定该符号的绝对数据值。特殊情况下，如果 n_type 字段是非零值，并且没有二进制文件定义了这个符号，则链接程序在 BSS 段中将该符号解析为一个地址，保留长度等于 n_value 的字节。如果符号在多于一个二进制目标文件中都没有定义并且这些二进制目标文件对其长度值不一致，则链接程序将选择所有二进制目标文件中最大的长度。

N_ABS　一个绝对符号。链接程序不会更新一个绝对符号。

N_TEXT 一个代码符号。该符号的值是代码地址，链接程序在合并二进制目标文件时会更新其值。

N_DATA 一个数据符号；与 N_TEXT 类似，但是用于数据地址。对应代码和数据符号的值不是文件的偏移值而是地址；为了找出文件的偏移，就有必要确定相关部分开始加载的地址并减去它，然后加上该部分的偏移。

N_BSS　一个 BSS 符号；与代码或数据符号类似，但在二进制目标文件中没有对应的偏移。

N_FN　一个文件名符号。在合并二进制目标文件时，链接程序会将该符号插入在二进制文件中的符号之前。符号的名称就是给予链接程序的文件名，而其值是二进制文件中首个代码段地址。链接和加载时不需要文件名符号，但对于调式程序非常有用。
N_STAB 屏蔽码用于选择符号调式程序(例如 gdb)感兴趣的位；其值在 stab()中说明。

n_other　该字段按照 n_type 确定的段，提供有关符号重定位操作的符号独立性信息。目前，n_other 字段的最低 4 位含有两个值之一：AUX_FUNC 和 AUX_OBJECT（有关定义参见<link.h>）。AUX_FUNC 将符号与可调用的函数相关，AUX_OBJECT 将符号与数据相关，而不管它们是位于代码段还是数据段。该字段主要用于链接程序 ld，用于动态可执行程序的创建。

n_desc　保留给调式程序使用；链接程序不对其进行处理。不同的调试程序将该字段用作不同的用途。

n_value　含有符号的值。对于代码、数据和 BSS 符号，这是一个地址；对于其他符号（例如调式程序符号），值可以是任意的。

字符串表是由长度为 u_int32_t 后跟一 null 结尾的符号字符串组成。长度代表整个表的字节大小，所以在 32 位的机器上其最小值（或者是第 1 个字符串的偏移）总是 4。

11.4 const.h 文件

11.4.1 功能描述

该文件定义了 i 节点中文件属性和类型 i_mode 字段所用到的一些标志位常量符号。

11.4.2 代码注释

程序 11-2 linux/include/const.h

```
 1 #ifndef _CONST_H
 2 #define _CONST_H
 3
 4 #define BUFFER_END 0x200000          // 定义缓冲使用内存的末端(代码中没有使用该常量)。
 5
   // i 节点数据结构中 i_mode 字段的各标志位。
 6 #define I_TYPE          0170000      // 指明 i 节点类型。
 7 #define I_DIRECTORY     0040000      // 是目录文件。
 8 #define I_REGULAR       0100000      // 常规文件，不是目录文件或特殊文件。
 9 #define I_BLOCK_SPECIAL 0060000      // 块设备特殊文件。
10 #define I_CHAR_SPECIAL  0020000      // 字符设备特殊文件。
11 #define I_NAMED_PIPE    0010000      // 命名管道。
12 #define I_SET_UID_BIT   0004000      // 在执行时设置有效用户 id 类型。
13 #define I_SET_GID_BIT   0002000      // 在执行时设置有效组 id 类型。
14
15 #endif
16
```

11.5 ctype.h 文件

11.5.1 功能描述

该文件是关于字符测试和处理的头文件，也是标准 C 库的头文件之一。其中定义了一些有关字符类型判断和转换的宏。例如判断一个字符 c 是一个数字字符（isdigit(c)）还是一个空格（isspace(c)）。在处理过程中使用了一个数组（表）(在 lib/ctype.c 中)，该数组定义了 ASCII 码表中所有字符的属性和类型。当使用宏时，字符是作为一个表(__ctype)中的索引，从表中获取一个字节，于是可得到相关的比特位。

另外，以两个下划线开头或者以一个下划线再加一个大写字母开头的宏名称通常都保留给头文件的编制者使用。例如名称__abc 和_SP。

11.5.2 代码注释

程序 11-3 linux/include/ctype.h

```
 1 #ifndef _CTYPE_H
 2 #define _CTYPE_H
 3
 4 #define _U      0x01    /* upper */          // 该比特位用于大写字符[A-Z]。
 5 #define _L      0x02    /* lower */          // 该比特位用于小写字符[a-z]。
 6 #define _D      0x04    /* digit */          // 该比特位用于数字[0-9]。
 7 #define _C      0x08    /* cntrl */          // 该比特位用于控制字符。
 8 #define _P      0x10    /* punct */          // 该比特位用于标点字符。
 9 #define _S      0x20    /* white space (space/lf/tab) */ // 用于空白字符，如空格、\t、\n 等。
10 #define _X      0x40    /* hex digit */      // 该比特位用于十六进制数字。
11 #define _SP     0x80    /* hard space (0x20) */  // 该比特位用于空格字符(0x20)。
12
13 extern unsigned char _ctype[];          // 字符特性数组(表)，定义了各个字符对应上面的属性。
14 extern char _ctmp;                      // 一个临时字符变量(在 lib/ctype.c 中定义)。
15
   // 下面是一些确定字符类型的宏。
16 #define isalnum(c) ((_ctype+1)[c]&(_U|_L|_D))        // 是字符或数字[A-Z]、[a-z]或[0-9]。
17 #define isalpha(c) ((_ctype+1)[c]&(_U|_L))           // 是字符。
18 #define iscntrl(c) ((_ctype+1)[c]&(_C))              // 是控制字符。
19 #define isdigit(c) ((_ctype+1)[c]&(_D))              // 是数字。
20 #define isgraph(c) ((_ctype+1)[c]&(_P|_U|_L|_D))     // 是图形字符。
21 #define islower(c) ((_ctype+1)[c]&(_L))              // 是小写字符。
22 #define isprint(c) ((_ctype+1)[c]&(_P|_U|_L|_D|_SP)) // 是可打印字符。
23 #define ispunct(c) ((_ctype+1)[c]&(_P))              // 是标点符号。
24 #define isspace(c) ((_ctype+1)[c]&(_S))              // 是空白字符如空格,\f,\n,\r,\t,\v。
25 #define isupper(c) ((_ctype+1)[c]&(_U))              // 是大写字符。
26 #define isxdigit(c) ((_ctype+1)[c]&(_D|_X))          // 是十六进制数字。
27
28 #define isascii(c) (((unsigned) c)<=0x7f)            // 是 ASCII 字符。
29 #define toascii(c) (((unsigned) c)&0x7f)             // 转换成 ASCII 字符。
   // 以上两个定义中，宏参数前使用了前缀(unsigned)，因此 c 应该加括号，即表示成(c)。
   // 因为在程序中 c 可能是一个复杂的表达式。例如，如果参数是 a + b，若不加括号，则在宏定义中
   // 变成了：(unsigned) a + b。这显然不对。加了括号就能正确表示成(unsigned)(a + b)。
30
31 #define tolower(c) (_ctmp=c,isupper(_ctmp)?_ctmp-('A'-'a'):_ctmp)  // 转换成对应小写字符。
```

```
32 #define toupper(c) (_ctmp=c,islower(_ctmp)?_ctmp-('a'-'A'):_ctmp)  // 转换成对应大写字符。
33 // 以上两个宏定义中使用一个临时变量_ctmp 的原因是：在宏定义中，宏的参数只能被使用一次。
   // 但对于多线程来说这是不安全的，因为两个或多个线程可能在同一时刻使用这个公共临时变量。
   // 因此从 Linux 2.2.x 版本开始更改为使用两个函数来取代这两个宏定义。
34 #endif
35
```

11.6 errno.h 文件

11.6.1 功能描述

在系统或者标准 C 语言中有个名为 errno 的变量，关于在 C 标准中是否需要这个变量，在 C 标准化组织（X3J11）中引起了很大争论。但是争论的结果是没有去掉 errno，反而创建了名称为“errno.h”的头文件。因为标准化组织希望每个库函数或数据对象都需要在一个相应的标准头文件中作出声明。

主要原因在于：对于内核中的每个系统调用，如果其返回值就是指定系统调用的结果值的话，就很难报告出错情况。如果让每个函数返回一个对/错指示值，而结果值另行返回，就不能很方便地得到系统调用的结果值。解决的办法之一是将这两种方式加以组合：对于一个特定的系统调用，可以指定一个与有效结果值范围有区别的出错返回值。例如对于指针可以采用 null 值，对于 pid 可以返回-1 值。在许多其他情况下，只要不与结果值冲突都可以采用-1 来表示出错值。但是标准 C 库函数返回值仅告知是否发生出错，还必须从其他地方了解出错的类型，因此采用了 errno 这个变量。为了与标准 C 库的设计机制兼容，Linux 内核中的库文件也采用了这种处理方法。因此也借用了标准 C 的这个头文件。相关例子可参见 lib/open.c 程序以及 unistd.h 中的系统调用宏定义。在某些情况下，程序虽然从返回的-1 值知道出错了，但想知道具体的出错号，就可以通过读取 errno 的值来确定最后一次错误的出错号。

本文件虽然只是定义了 Linux 系统中的一些出错码（出错号）的常量符号，而且 Linus 考虑程序的兼容性也想把这些符号定义成与 POSIX 标准中的一样。但是不要小看这个简单的代码，该文件也是 SCO 公司指责 Linux 操作系统侵犯其版权所列出的文件的之一。为了研究这个侵权问题，在 2003 年 12 月份，10 多个当前 Linux 内核的顶级开发人员在网上商讨对策。其中包括 Linus、Alan Cox、H.J.Lu、Mitchell Blank Jr。由于当前内核版本（2.4.x）中的 errno.h 文件从 0.96c 版内核开始就没有变化过，他们就一直“跟踪”到这些老版本的内核代码中。最后 Linus 发现该文件是从 H.J.Lu 当时维护的 Libc 2.x 库中利用程序自动生成的，其中包括了一些与 SCO 拥有版权的 UNIX 老版本（V6、V7 等）相同的变量名。

11.6.2 代码注释

程序 11-4 linux/include/errno.h

```
1 #ifndef _ERRNO_H
2 #define _ERRNO_H
3
4 /*
5  * ok, as I hadn't got any other source of information about
6  * possible error numbers, I was forced to use the same numbers
7  * as minix.
8  * Hopefully these are posix or something. I wouldn't know (and posix
9  * isn't telling me - they want $$$ for their f***ing standard).
10 *
11 * We don't use the _SIGN cludge of minix, so kernel returns must
```

```
12  * see to the sign by themselves.
13  *
14  * NOTE! Remember to change strerror() if you change this file!
15  */
    /*
     * ok，由于我没有得到任何其他有关出错号的资料，我只能使用与 minix 系统
     * 相同的出错号了。
     * 希望这些是 POSIX 兼容的或者在一定程度上是这样的，我不知道（而且 POSIX
     * 没有告诉我 - 要获得他们的混蛋标准需要出钱）。
     *
     * 我们没有使用 minix 那样的_SIGN 簇，所以内核的返回值必须自己辨别正负号。
     *
     * 注意！如果你改变该文件的话，记着也要修改 strerror()函数。
     */
16
    // 系统调用以及很多库函数返回一个特殊的值以表示操作失败或出错。这个值通常选择-1 或者其他
    // 一些特定的值来表示。但是这个返回值仅说明错误发生了。如果需要知道出错的类型，就需要查看
    // 表示系统出错号的变量 errno。该变量即在 errno.h 文件中声明。在程序开始执行时该变量值被初
    // 始化为 0。
17  extern int errno;
18
    // 在出错时，系统调用会把出错号放在变量 errno 中（负值），然后返回-1。因此程序若需要知道具体
    // 错误号，就需要查看 errno 的值。
19  #define ERROR           99              // 一般错误。
20  #define EPERM           1               // 操作没有许可。
21  #define ENOENT          2               // 文件或目录不存在。
22  #define ESRCH           3               // 指定的进程不存在。
23  #define EINTR           4               // 中断的函数调用。
24  #define EIO             5               // 输入/输出错。
25  #define ENXIO           6               // 指定设备或地址不存在。
26  #define E2BIG           7               // 参数列表太长。
27  #define ENOEXEC         8               // 执行程序格式错误。
28  #define EBADF           9               // 文件句柄(描述符)错误。
29  #define ECHILD          10              // 子进程不存在。
30  #define EAGAIN          11              // 资源暂时不可用。
31  #define ENOMEM          12              // 内存不足。
32  #define EACCES          13              // 没有许可权限。
33  #define EFAULT          14              // 地址错。
34  #define ENOTBLK         15              // 不是块设备文件。
35  #define EBUSY           16              // 资源正忙。
36  #define EEXIST          17              // 文件已存在。
37  #define EXDEV           18              // 非法连接。
38  #define ENODEV          19              // 设备不存在。
39  #define ENOTDIR         20              // 不是目录文件。
40  #define EISDIR          21              // 是目录文件。
41  #define EINVAL          22              // 参数无效。
42  #define ENFILE          23              // 系统打开文件数太多。
43  #define EMFILE          24              // 打开文件数太多。
44  #define ENOTTY          25              // 不恰当的 IO 控制操作(没有 tty 终端)。
45  #define ETXTBSY         26              // 不再使用。
46  #define EFBIG           27              // 文件太大。
47  #define ENOSPC          28              // 设备已满（设备已经没有空间）。
48  #define ESPIPE          29              // 无效的文件指针重定位。
```

```
49 #define EROFS           30              // 文件系统只读。
50 #define EMLINK          31              // 连接太多。
51 #define EPIPE           32              // 管道错。
52 #define EDOM            33              // 域(domain)出错。
53 #define ERANGE          34              // 结果太大。
54 #define EDEADLK         35              // 避免资源死锁。
55 #define ENAMETOOLONG    36              // 文件名太长。
56 #define ENOLCK          37              // 没有锁定可用。
57 #define ENOSYS          38              // 功能还没有实现。
58 #define ENOTEMPTY       39              // 目录不空。
59
60 #endif
61
```

11.7 fcntl.h 文件

11.7.1 功能描述

文件控制选项头文件。主要定义了函数 fcntl()和 open()中用到的一些选项。

11.7.2 代码注释

程序 11-5 linux/include/fcntl.h

```
 1 #ifndef _FCNTL_H
 2 #define _FCNTL_H
 3
 4 #include <sys/types.h>     // 类型头文件。定义了基本的系统数据类型。
 5
 6 /* open/fcntl - NOCTTY, NDELAY isn't implemented yet */
   /* open/fcntl - NOCTTY 和 NDELAY 现在还没有实现 */
 7 #define O_ACCMODE       00003                   // 文件访问模式屏蔽码。
   // 打开文件 open()和文件控制 fcntl()函数使用的文件访问模式。同时只能使用三者之一。
 8 #define O_RDONLY          00                    // 以只读方式打开文件。
 9 #define O_WRONLY          01                    // 以只写方式打开文件。
10 #define O_RDWR            02                    // 以读写方式打开文件。
   // 下面是文件创建标志，用于 open()。可与上面访问模式用'位或'的方式一起使用。
11 #define O_CREAT         00100   /* not fcntl */ // 如果文件不存在就创建。
12 #define O_EXCL          00200   /* not fcntl */ // 独占使用文件标志。
13 #define O_NOCTTY        00400   /* not fcntl */ // 不分配控制终端。
14 #define O_TRUNC         01000   /* not fcntl */ // 若文件已存在且是写操作，则长度截为 0。
15 #define O_APPEND        02000                   // 以添加方式打开，文件指针置为文件尾。
16 #define O_NONBLOCK      04000   /* not fcntl */ // 非阻塞方式打开和操作文件。
17 #define O_NDELAY        O_NONBLOCK              // 非阻塞方式打开和操作文件。
18
19 /* Defines for fcntl-commands. Note that currently
20  * locking isn't supported, and other things aren't really
21  * tested.
22  */
```

```
   /* 下面定义了 fcntl 的命令。注意目前锁定命令还没有支持，而其他
    * 命令实际上还没有测试过。
    */
   // 文件句柄(描述符)操作函数 fcntl()的命令。
23 #define F_DUPFD         0       /* dup */           // 拷贝文件句柄为最小数值的句柄。
24 #define F_GETFD         1       /* get f_flags */   // 取文件句柄标志。
25 #define F_SETFD         2       /* set f_flags */   // 设置文件句柄标志。
26 #define F_GETFL         3       /* more flags (cloexec) */  // 取文件状态标志和访问模式。
27 #define F_SETFL         4                                   // 设置文件状态标志和访问模式。
   // 下面是文件锁定命令。fcntl()的第三个参数 lock 是指向 flock 结构的指针。
28 #define F_GETLK         5       /* not implemented */  // 返回阻止锁定的 flock 结构。
29 #define F_SETLK         6       // 设置(F_RDLCK 或 F_WRLCK)或清除(F_UNLCK)锁定。
30 #define F_SETLKW        7       // 等待设置或清除锁定。
31
32 /* for F_[GET|SET]FL */
   /* 用于 F_GETFL 或 F_SETFL */
   // 在执行 exec()簇函数时关闭文件句柄。(执行时关闭 - Close On EXECution)
33 #define FD_CLOEXEC      1       /* actually anything with low bit set goes */
                                   /* 实际上只要低位为 1 即可 */
34
35 /* Ok, these are locking features, and aren't implemented at any
36  * level. POSIX wants them.
37  */
   /* OK，以下是锁定类型，任何函数中都还没有实现。POSIX 标准要求这些类型。
    */
38 #define F_RDLCK         0       // 共享或读文件锁定。
39 #define F_WRLCK         1       // 独占或写文件锁定。
40 #define F_UNLCK         2       // 文件解锁。
41
42 /* Once again - not implemented, but ... */
   /* 同样 - 也还没有实现，但是... */
   // 文件锁定操作数据结构。描述了受影响文件段的类型(l_type)、开始偏移(l_whence)、
   // 相对偏移(l_start)、锁定长度(l_len)和实施锁定的进程 id。
43 struct flock {
44         short l_type;           // 锁定类型（F_RDLCK，F_WRLCK，F_UNLCK）。
45         short l_whence;         // 开始偏移(SEEK_SET，SEEK_CUR 或 SEEK_END)。
46         off_t l_start;          // 阻塞锁定的开始处。相对偏移（字节数）。
47         off_t l_len;            // 阻塞锁定的大小；如果是 0 则为到文件末尾。
48         pid_t l_pid;            // 加锁的进程 id。
49 };
50
   // 以下是使用上述标志或命令的函数原型。
   // 创建新文件或重写一个已存在文件。
   // 参数 filename 是欲创建文件的文件名，mode 是创建文件的属性（参见 include/sys/stat.h）。
51 extern int creat(const char * filename,mode_t mode);
   // 文件句柄操作，会影响文件的打开。
   // 参数 fildes 是文件句柄，cmd 是操作命令，见上面 23-30 行。
52 extern int fcntl(int fildes,int cmd, ...);
   // 打开文件。在文件与文件句柄之间建立联系。
   // 参数 filename 是欲打开文件的文件名，flags 是上面 7-17 行上的标志的组合。
53 extern int open(const char * filename, int flags, ...);
54
55 #endif
```

56

11.8 signal.h 文件

11.8.1 功能描述

信号提供了一种处理异步事件的方法。信号也被称为是一种软中断。通过向一个进程发送信号，我们可以控制进程的执行状态（暂停、继续或终止）。本文件定义了内核中使用的所有信号的名称和基本操作函数。其中最为重要的函数是改变指定信号处理方式的函数 signal()和 sigaction()。

从本文件中可以看出，Linux 内核实现了 POSIX.1 所要求的所有 20 个信号。因此我们可以说 Linux 在一开始设计时就已经完全考虑到与标准的兼容性了。具体函数的实现见程序 kernel/signal.c。

11.8.2 文件注释

程序 11-6 linux/include/signal.h

```
 1 #ifndef _SIGNAL_H
 2 #define _SIGNAL_H
 3
 4 #include <sys/types.h>                  // 类型头文件。定义了基本的系统数据类型。
 5
 6 typedef int sig_atomic_t;               // 定义信号原子操作类型。
 7 typedef unsigned int sigset_t;          /* 32 bits */  // 定义信号集类型。
 8
 9 #define _NSIG             32            // 定义信号种类 -- 32 种。
10 #define NSIG              _NSIG          // NSIG = _NSIG
11
   // 以下这些是 Linux 0.11 内核中定义的信号。其中包括了 POSIX.1 要求的所有 20 个信号。
12 #define SIGHUP             1            // Hang Up     -- 挂断控制终端或进程。
13 #define SIGINT             2            // Interrupt   -- 来自键盘的中断。
14 #define SIGQUIT            3            // Quit        -- 来自键盘的退出。
15 #define SIGILL             4            // Illeagle    -- 非法指令。
16 #define SIGTRAP            5            // Trap        -- 跟踪断点。
17 #define SIGABRT            6            // Abort       -- 异常结束。
18 #define SIGIOT             6            // IO Trap     -- 同上。
19 #define SIGUNUSED          7            // Unused      -- 没有使用。
20 #define SIGFPE             8            // FPE         -- 协处理器出错。
21 #define SIGKILL            9            // Kill        -- 强迫进程终止。
22 #define SIGUSR1           10            // User1       -- 用户信号 1，进程可使用。
23 #define SIGSEGV           11            // Segment Violation -- 无效内存引用。
24 #define SIGUSR2           12            // User2       -- 用户信号 2，进程可使用。
25 #define SIGPIPE           13            // Pipe        -- 管道写出错，无读者。
26 #define SIGALRM           14            // Alarm       -- 实时定时器报警。
27 #define SIGTERM           15            // Terminate   -- 进程终止。
28 #define SIGSTKFLT         16            // Stack Fault -- 栈出错（协处理器）。
29 #define SIGCHLD           17            // Child       -- 子进程停止或被终止。
30 #define SIGCONT           18            // Continue    -- 恢复进程继续执行。
31 #define SIGSTOP           19            // Stop        -- 停止进程的执行。
32 #define SIGTSTP           20            // TTY Stop    -- tty 发出停止进程，可忽略。
33 #define SIGTTIN           21            // TTY In      -- 后台进程请求输入。
```

```
34 #define SIGTTOU         22              // TTY Out      -- 后台进程请求输出。
35
36 /* Ok, I haven't implemented sigactions, but trying to keep headers POSIX */
   /* OK，我还没有实现 sigactions 的编制，但在头文件中仍希望遵守 POSIX 标准 */
37 #define SA_NOCLDSTOP    1           // 当子进程处于停止状态，就不对 SIGCHLD 处理。
38 #define SA_NOMASK       0x40000000  // 不阻止在指定的信号处理程序(信号句柄)中再收到该信号。
39 #define SA_ONESHOT      0x80000000  // 信号句柄一旦被调用过就恢复到默认处理句柄。
40
   // 以下常量用于 sigprocmask(how, )-- 改变阻塞信号集(屏蔽码)。用于改变该函数的行为。
41 #define SIG_BLOCK           0   /* for blocking signals */
                                   // 在阻塞信号集中加上给定的信号集。
42 #define SIG_UNBLOCK         1   /* for unblocking signals */
                                   // 从阻塞信号集中删除指定的信号集。
43 #define SIG_SETMASK         2   /* for setting the signal mask */
                                   // 设置阻塞信号集（信号屏蔽码）。
44
   // 以下两个常数符号都表示指向无返回值的函数指针，且都有一个 int 整型参数。这两个指针值是
   // 逻辑上讲实际上不可能出现的函数地址值。可作为下面 signal 函数的第二个参数。用于告知内核，
   // 让内核处理信号或忽略对信号的处理。使用方法可参见 kernel/signal.c 程序，第 94-96 行。
45 #define SIG_DFL         ((void (*)(int))0)      /* default signal handling */
                                                   // 默认的信号处理程序（信号句柄）。
46 #define SIG_IGN         ((void (*)(int))1)      /* ignore signal */
                                                   // 忽略信号的处理程序。
47
   // 下面是 sigaction 的数据结构。
   // sa_handler 是对应某信号指定要采取的行动。可以用上面的 SIG_DFL，或 SIG_IGN 来忽略该信号，
   // 也可以是指向处理该信号函数的一个指针。
   // sa_mask 给出了对信号的屏蔽码，在信号程序执行时将阻塞对这些信号的处理。
   // sa_flags 指定改变信号处理过程的信号集。它是由 37-39 行的位标志定义的。
   // sa_restorer 是恢复函数指针，由函数库 Libc 提供，用于清理用户态堆栈。参见 kernel/signal.c
   // 另外，引起触发信号处理的信号也将被阻塞，除非使用了 SA_NOMASK 标志。
48 struct sigaction {
49         void (*sa_handler)(int);
50         sigset_t sa_mask;
51         int sa_flags;
52         void (*sa_restorer)(void);
53 };
54
   // 下面 signal 函数用于是为信号_sig 安装一新的信号处理程序（信号句柄），与 sigaction()类似。
   // 该函数含有两个参数：指定需要捕获的信号_sig；具有一个参数且无返回值的函数指针_func。
   // 该函数返回值也是具有一个 int 参数（最后一个(int)）且无返回值的函数指针，它是处理该
   // 信号的原处理句柄。
55 void (*signal(int _sig, void (*_func)(int)))(int);
   // 下面两函数用于发送信号。kill()用于向任何进程或进程组发送任何信号（kernel/exit.c，60 行）。
   // raise()用于向当前进程自身发送信号。其作用等价于 kill(getpid(),sig)。
56 int raise(int sig);
57 int kill(pid_t pid, int sig);
   // 在进程的任务结构中除有一个以比特位表示当前进程待处理的 32 位信号字段 signal 以外，还有一
   // 个同样以比特位表示的用于屏蔽进程当前阻塞信号集合（屏蔽信号集）的字段 blocked，也是 32 位，
   // 每个比特代表一个对应的阻塞信号。修改进程的屏蔽信号集可以阻塞或解除阻塞所指定的信号。以下
   // 五个函数就是用于操作进程屏蔽信号集，虽然简单实现起来很简单，但本版本内核中还未实现。
   // sigaddset()和 sigdelset()用于对信号集中的信号进行增、删修改。sigaddset()用于向 mask 指向
   // 的信号集中增加指定的信号 signo。sigdelset 则反之。
```

```
    // sigemptyset()和 sigfillset()用于初始化进程屏蔽信号集。每个程序在使用信号集前，都需要使用
    // 这两个函数之一对屏蔽信号集进行初始化。sigemptyset()用于清空屏蔽的所有信号，也即响应所有
    // 的信号。sigfillset()向信号集中置入所有信号，也即屏蔽所有信号。当然 SIGINT 和 SIGSTOP 是屏
    // 蔽不了的。
    // sigismember()用于测试一个指定信号是否在信号集中（1 - 是，0 - 不是，-1 - 出错）。
58  int sigaddset(sigset_t *mask, int signo);
59  int sigdelset(sigset_t *mask, int signo);
60  int sigemptyset(sigset_t *mask);
61  int sigfillset(sigset_t *mask);
62  int sigismember(sigset_t *mask, int signo); /* 1 - is, 0 - not, -1 error */
    // 对 set 中的信号进行检测，看是否有挂起的信号。在 set 中返回进程中当前被阻塞的信号集。
63  int sigpending(sigset_t *set);
    // 下面函数用于改变进程目前被阻塞的信号集（信号屏蔽码）。若 oldset 不是 NULL，则通过其返回
    // 进程当前屏蔽信号集。若 set 指针不是 NULL，则根据 how（41-43 行）指示修改进程屏蔽信号集。
64  int sigprocmask(int how, sigset_t *set, sigset_t *oldset);
    // 下面函数用 sigmask 临时替换进程的信号屏蔽码,然后暂停该进程直到收到一个信号。若捕捉到某
    // 一信号并从该信号处理程序中返回，则该函数也返回，并且信号屏蔽码会恢复到调用调用前的值。
65  int sigsuspend(sigset_t *sigmask);
    // sigaction()用于改变进程在收到指定信号时所采取的行动。参见对 kernel/signal.c 程序的说明。
66  int sigaction(int sig, struct sigaction *act, struct sigaction *oldact);
67
68  #endif /* _SIGNAL_H */
69
```

11.9 stdarg.h 文件

11.9.1 功能描述

C 语言的最大特点之一是允许编程人员自定义参数数目可变的函数。为了访问这些可变参数列表中的参数，就需要用到 stdarg.h 文件中的宏。stdarg.h 头文件是 C 标准化组织根据 BSD 系统的 varargs.h 文件修改而成。

stdarg.h 是标准参数头文件。它以宏的形式定义变量参数列表。主要说明了-个类型(va_list)和三个宏(va_start, va_arg 和 va_end)，用于 vsprintf、vprintf、vfprintf 函数。在阅读该文件时，需要首先理解变参函数的使用方法，可参见 kernel/vsprintf.c 列表后的说明。

11.9.2 代码注释

程序 11-7 linux/include/stdarg.h

```
1   #ifndef _STDARG_H
2   #define _STDARG_H
3
4   typedef char *va_list;  // 定义 va_list 是一个字符指针类型。
5
6   /* Amount of space required in an argument list for an arg of type TYPE.
7      TYPE may alternatively be an expression whose type is used.  */
    /* 下面给出了类型为 TYPE 的 arg 参数列表所要求的空间容量。
       TYPE 也可以是使用该类型的一个表达式 */
8
    // 下面这句定义了取整后的 TYPE 类型的字节长度值。是 int 长度(4)的倍数。
9   #define __va_rounded_size(TYPE)  \
```

```
10    (((sizeof (TYPE) + sizeof (int) - 1) / sizeof (int)) * sizeof (int))
11
    // 下面这个宏初始化指针 AP，使其指向传给函数的可变参数表的第一个参数。
    // 在第一次调用 va_arg 或 va_end 之前，必须首先调用该函数。参数 LASTARG 是函数定义中最右边参数
    // 的标识符，即'...'左边的一个标识符。AP 是可变参数表参数指针，LASTARG 是最后一个指定参数。
    // &(LASTARG)用于取其地址（即其指针），并且该指针是字符类型。加上 LASTARG 的宽度值后 AP 就是
    // 可变参数表中第一个参数的指针。该宏没有返回值。
    // 17 行上的函数 __builtin_saveregs()是在 gcc 的库程序 libgcc2.c 中定义的，用于保存寄存器。
    // 相关说明参见 gcc 手册“Target Description Macros”章中“Implementing the Varargs Macros”
    // 小节。
12  #ifndef __sparc__
13  #define va_start(AP, LASTARG)                                          \
14   (AP = ((char *) &(LASTARG) + __va_rounded_size (LASTARG)))
15  #else
16  #define va_start(AP, LASTARG)                                          \
17   (__builtin_saveregs (),                                               \
18    AP = ((char *) &(LASTARG) + __va_rounded_size (LASTARG)))
19  #endif
20
    // 下面该宏用于被调用函数完成一次正常返回。va_end 可以修改 AP 使其在重新调用
    // va_start 之前不能被使用。va_end 必须在 va_arg 读完所有的参数后再被调用。
21  void va_end (va_list);          /* Defined in gnulib */  /* 在 gnulib 中定义 */
22  #define va_end(AP)
23
    // 下面该宏用于扩展表达式使其与下一个被传递参数具有相同的类型和值。
    // 对于缺省值，va_arg 可以用字符、无符号字符和浮点类型。
    // 在第一次使用 va_arg 时，它返回表中的第一个参数，后续的每次调用都将返回表中的
    // 下一个参数。这是通过先访问 AP，然后把它增加以指向下一项来实现的。
    // va_arg 使用 TYPE 来完成访问和定位下一项，每调用一次 va_arg，它就修改 AP 以指示
    // 表中的下一参数。
24  #define va_arg(AP, TYPE)                                               \
25   (AP += __va_rounded_size (TYPE),                                      \
26    *((TYPE *) (AP - __va_rounded_size (TYPE))))
27
28  #endif /* _STDARG_H */
29
```

11.10 stddef.h 文件

11.10.1 功能描述

stddef.h 头文件的名称也是有 C 标准化组织（X3J11）创建的，含义是标准（std）定义(def)。主要用于存放一些“标准定义”。另外一个内容容易混淆的头文件是 stdlib.h，也是由标准化组织建立的。stdlib.h 主要用来声明一些不与其他头文件类型相关的各种函数。但这两个头文件中的内容常常让人搞不清哪些声明在哪个头文件中。

标准化组织中的一些成员认为在那些不能完全支持标准 C 库的独立环境中，C 语言也应该成为一种有用的编程语言。对于一个独立环境，C 标准要求其提供 C 语言的所有属性，而对于标准 C 库来说，这样的实现仅需提供支持 4 个头文件中的功能：float.h、limits.h、stdarg.h 和 stddef.h。这个要求明确了 stddef.h

文件应该包含些什么内容，而其他三个头文件基本上用于较为特殊的方面：
float.h　描述浮点表示特性；
limits.h　描述整型表示特性；
stdarg.h　提供用于访问可变参数列表的宏定义。
而独立环境中使用的任何其他类型或宏定义都应该放在 stddef.h 文件中。但是后来的组织成员则放宽了这些限制，导致有些定义在多个头文件中出现。例如，宏定义 NULL 还出现在其他 4 个头文件中。因此，为了防止冲突，stddef.h 文件中在定义 NULL 之前首先使用 undef 指令取消原先的定义（第 14 行）。

在本文件中定义的类型和宏还有一个共同点：这些定义曾经试图被包含在 C 语言的特性中，但后来由于各种编译器都以各自的方式定义这些信息，很难编写出能取代所有这些定义的代码来，因此就放弃了。

在 Linux 0.11 内核中很少使用该文件。

11.10.2 代码注释

程序 11-8 linux/include/stddef.h

```
 1 #ifndef _STDDEF_H
 2 #define _STDDEF_H
 3
 4 #ifndef _PTRDIFF_T
 5 #define _PTRDIFF_T
 6 typedef long ptrdiff_t;                // 两个指针相减结果的类型。
 7 #endif
 8
 9 #ifndef _SIZE_T
10 #define _SIZE_T
11 typedef unsigned long size_t;          // sizeof 返回的类型。
12 #endif
13
14 #undef NULL
15 #define NULL ((void *)0)               // 空指针。
16
   // 下面定义了一个计算某成员在类型中偏移位置的宏。使用该宏可以确定一个成员（字段）在包含
   // 它的结构类型中从结构开始处算起的字节偏移量。宏的结果是类型为 size_t 的整数常数表达式。
   // 这里是一个技巧用法。((TYPE *)0)是将一个整数 0 类型投射（type cast）成数据对象指针类型，
   // 然后在该结果上进行运算。详细说明请参见 P.J.Plauger 著的《The Standard C Library》一书。
17 #define offsetof(TYPE, MEMBER) ((size_t) &((TYPE *)0)->MEMBER)
18
19 #endif
20
```

11.11 string.h 文件

11.11.1 功能描述

该头文件中以内嵌函数的形式定义了所有字符串操作函数，为了提高执行速度使用了内嵌汇编程序。另外，在开始处还定义了一个 NULL 宏和一个 SIZE_T 类型。

在标准 C 库中也提供同样名称的头文件，但函数实现是在标准 C 库中，并且其相应的头文件中只包含相关函数的声明。而对于下面列出的 string.h 文件，Linus 虽然给出每个函数的实现，但是每个函数都有一个'extern'前缀，因此对于包含这个头文件的程序，其实只使用了函数声明部分而其实现体被忽略。而实现这些函数真正的地方是在内核专用库 lib.a 中，参见 lib/string.c 程序。在那个 string.c 中，程序首先将'extern'和'inline'等定义为空，再包含 string.h 头文件，因此，string.c 程序中实际上包含了 string.h 头文件中声明函数的具体实现代码。

11.11.2 代码注释

程序 11-9 linux/include/string.h

```
 1 #ifndef _STRING_H_
 2 #define _STRING_H_
 3
 4 #ifndef NULL
 5 #define NULL ((void *) 0)
 6 #endif
 7
 8 #ifndef _SIZE_T
 9 #define _SIZE_T
10 typedef unsigned int size_t;
11 #endif
12
13 extern char * strerror(int errno);
14
15 /*
16  * This string-include defines all string functions as inline
17  * functions. Use gcc. It also assumes ds=es=data space, this should be
18  * normal. Most of the string-functions are rather heavily hand-optimized,
19  * see especially strtok,strstr,str[c]spn. They should work, but are not
20  * very easy to understand. Everything is done entirely within the register
21  * set, making the functions fast and clean. String instructions have been
22  * used through-out, making for "slightly" unclear code :-)
23  *
24  *              (C) 1991 Linus Torvalds
25  */
   /*
    * 这个字符串头文件以内嵌函数的形式定义了所有字符串操作函数。使用 gcc 时，同时
    * 假定了 ds=es=数据空间，这应该是常规的。绝大多数字符串函数都是经手工进行大量
    * 优化的，尤其是函数 strtok、strstr、str[c]spn。它们应该能正常工作，但却不是那
    * 么容易理解。所有的操作基本上都是使用寄存器集来完成的，这使得函数即快又整洁。
    * 所有地方都使用了字符串指令，这又使得代码“稍微”难以理解☺
    *
    *              (C) 1991 Linus Torvalds
    */
26
   //// 将一个字符串(src)拷贝到另一个字符串(dest)，直到遇到 NULL 字符后停止。
   // 参数：dest - 目的字符串指针，src - 源字符串指针。
   // %0 - esi(src)，%1 - edi(dest)。
27 extern inline char * strcpy(char * dest,const char *src)
28 {
29 __asm__("cld\n"                         // 清方向位。
30         "1:\tlodsb\n\t"                  // 加载 DS:[esi]处 1 字节➔al，并更新 esi。
```

```
31          "stosb\n\t"                 // 存储字节 al➔ES:[edi]，并更新 edi。
32          "testb %%al,%%al\n\t"       // 刚存储的字节是 0?
33          "jne 1b"                    // 不是则向后跳转到标号 1 处，否则结束。
34          ::"S" (src),"D" (dest):"si","di","ax");
35  return dest;                        // 返回目的字符串指针。
36  }
37
    //// 拷贝源字符串 count 个字节到目的字符串。
    // 如果源串长度小于 count 个字节，就附加空字符(NULL)到目的字符串。
    // 参数：dest - 目的字符串指针，src - 源字符串指针，count - 拷贝字节数。
    // %0 - esi(src)，%1 - edi(dest)，%2 - ecx(count)。
38  extern inline char * strncpy(char * dest,const char *src,int count)
39  {
40  __asm__("cld\n"                     // 清方向位。
41          "1:\tdecl %2\n\t"           // 寄存器 ecx--（count--）。
42          "js 2f\n\t"                 // 如果 count<0 则向前跳转到标号 2，结束。
43          "lodsb\n\t"                 // 取 ds:[esi]处 1 字节➔al，并且 esi++。
44          "stosb\n\t"                 // 存储该字节➔es:[edi]，并且 edi++。
45          "testb %%al,%%al\n\t"       // 该字节是 0?
46          "jne 1b\n\t"                // 不是，则向前跳转到标号 1 处继续拷贝。
47          "rep\n\t"                   // 否则，在目的串中存放剩余个数的空字符。
48          "stosb\n"
49          "2:"
50          ::"S" (src),"D" (dest),"c" (count):"si","di","ax","cx");
51  return dest;                        // 返回目的字符串指针。
52  }
53
    //// 将源字符串拷贝到目的字符串的末尾处。
    // 参数：dest - 目的字符串指针，src - 源字符串指针。
    // %0 - esi(src)，%1 - edi(dest)，%2 - eax(0)，%3 - ecx(-1)。
54  extern inline char * strcat(char * dest,const char * src)
55  {
56  __asm__("cld\n\t"                   // 清方向位。
57          "repne\n\t"                 // 比较 al 与 es:[edi]字节，并更新 edi++，
58          "scasb\n\t"                 // 直到找到目的串中是 0 的字节，此时 edi 已指向后 1 字节。
59          "decl %1\n"                 // 让 es:[edi]指向 0 值字节。
60          "1:\tlodsb\n\t"             // 取源字符串字节 ds:[esi]➔al，并 esi++。
61          "stosb\n\t"                 // 将该字节存到 es:[edi]，并 edi++。
62          "testb %%al,%%al\n\t"       // 该字节是 0?
63          "jne 1b"                    // 不是，则向后跳转到标号 1 处继续拷贝，否则结束。
64          ::"S" (src),"D" (dest),"a" (0),"c" (0xffffffff):"si","di","ax","cx");
65  return dest;                        // 返回目的字符串指针。
66  }
67
    //// 将源字符串的 count 个字节复制到目的字符串的末尾处，最后添一空字符。
    // 参数：dest - 目的字符串，src - 源字符串，count - 欲复制的字节数。
    // %0 - esi(src)，%1 - edi(dest)，%2 - eax(0)，%3 - ecx(-1)，%4 - (count)。
68  extern inline char * strncat(char * dest,const char * src,int count)
69  {
70  __asm__("cld\n\t"                   // 清方向位。
71          "repne\n\t"                 // 比较 al 与 es:[edi]字节，edi++。
72          "scasb\n\t"                 // 直到找到目的串的末端 0 值字节。
73          "decl %1\n\t"               // edi 指向该 0 值字节。
```

```
74          "movl %4,%3\n"              // 欲复制字节数➔ecx。
75          "1:\tdecl %3\n\t"           // ecx--（从 0 开始计数）。
76          "js 2f\n\t"                 // ecx <0 ?，是则向前跳转到标号 2 处。
77          "lodsb\n\t"                 // 否则取 ds:[esi]处的字节➔al，esi++。
78          "stosb\n\t"                 // 存储到 es:[edi]处，edi++。
79          "testb %%al,%%al\n\t"       // 该字节值为 0?
80          "jne 1b\n"                  // 不是则向后跳转到标号 1 处，继续复制。
81          "2:\txorl %2,%2\n\t"        // 将 al 清零。
82          "stosb"                     // 存到 es:[edi]处。
83          ::"S" (src),"D" (dest),"a" (0),"c" (0xffffffff),"g" (count)
84          :"si","di","ax","cx");
85  return dest;                        // 返回目的字符串指针。
86  }
87
    //// 将一个字符串与另一个字符串进行比较。
    // 参数：cs - 字符串 1，ct - 字符串 2。
    // %0 - eax(__res)返回值，%1 - edi(cs)字符串 1 指针，%2 - esi(ct)字符串 2 指针。
    // 返回：如果串 1 > 串 2，则返回 1；串 1 = 串 2，则返回 0；串 1 < 串 2，则返回-1。
88  extern inline int strcmp(const char * cs,const char * ct)
89  {
90  register int __res __asm__("ax");   // __res 是寄存器变量(eax)。
91  __asm__("cld\n"                     // 清方向位。
92          "1:\tlodsb\n\t"             // 取字符串 2 的字节 ds:[esi]➔al，并且 esi++。
93          "scasb\n\t"                 // al 与字符串 1 的字节 es:[edi]作比较，并且 edi++。
94          "jne 2f\n\t"                // 如果不相等，则向前跳转到标号 2。
95          "testb %%al,%%al\n\t"       // 该字节是 0 值字节吗（字符串结尾）？
96          "jne 1b\n\t"                // 不是，则向后跳转到标号 1，继续比较。
97          "xorl %%eax,%%eax\n\t"      // 是，则返回值 eax 清零，
98          "jmp 3f\n"                  // 向前跳转到标号 3，结束。
99          "2:\tmovl $1,%%eax\n\t"     // eax 中置 1。
100         "jl 3f\n\t"                 // 若前面比较中串 2 字符<串 1 字符，则返回正值，结束。
101         "negl %%eax\n"              // 否则 eax = -eax，返回负值，结束。
102         "3:"
103         :"=a" (__res):"D" (cs),"S" (ct):"si","di");
104 return __res;                       // 返回比较结果。
105 }
106
    //// 字符串 1 与字符串 2 的前 count 个字符进行比较。
    // 参数：cs - 字符串 1，ct - 字符串 2，count - 比较的字符数。
    // %0 - eax(__res)返回值，%1 - edi(cs)串 1 指针，%2 - esi(ct)串 2 指针，%3 - ecx(count)。
    // 返回：如果串 1 > 串 2，则返回 1；串 1 = 串 2，则返回 0；串 1 < 串 2，则返回-1。
107 extern inline int strncmp(const char * cs,const char * ct,int count)
108 {
109 register int __res __asm__("ax");   // __res 是寄存器变量(eax)。
110 __asm__("cld\n"                     // 清方向位。
111         "1:\tdecl %3\n\t"           // count--。
112         "js 2f\n\t"                 // 如果 count<0，则向前跳转到标号 2。
113         "lodsb\n\t"                 // 取串 2 的字符 ds:[esi]➔al，并且 esi++。
114         "scasb\n\t"                 // 比较 al 与串 1 的字符 es:[edi]，并且 edi++。
115         "jne 3f\n\t"                // 如果不相等，则向前跳转到标号 3。
116         "testb %%al,%%al\n\t"       // 该字符是 NULL 字符吗?
117         "jne 1b\n"                  // 不是，则向后跳转到标号 1，继续比较。
118         "2:\txorl %%eax,%%eax\n\t"  // 是 NULL 字符，则 eax 清零（返回值）。
```

```
119         "jmp 4f\n"                  // 向前跳转到标号 4，结束。
120         "3:\tmovl $1,%%eax\n\t"     // eax 中置 1。
121         "jl 4f\n\t"                 // 如果前面比较中串 2 字符<串 2 字符，则返回 1，结束。
122         "negl %%eax\n"              // 否则 eax = -eax，返回负值，结束。
123         "4:"
124         :"=a" (__res):"D" (cs),"S" (ct),"c" (count):"si","di","cx");
125 return __res;                       // 返回比较结果。
126 }
127
    //// 在字符串中寻找第一个匹配的字符。
    // 参数：s - 字符串，c - 欲寻找的字符。
    // %0 - eax(__res)，%1 - esi(字符串指针 s)，%2 - eax(字符 c)。
    // 返回：返回字符串中第一次出现匹配字符的指针。若没有找到匹配的字符，则返回空指针。
128 extern inline char * strchr(const char * s,char c)
129 {
130 register char * __res __asm__("ax"); // __res 是寄存器变量(eax)。
131 __asm__("cld\n\t"                   // 清方向位。
132         "movb %%al,%%ah\n"          // 将欲比较字符移到 ah。
133         "1:\tlodsb\n\t"             // 取字符串中字符 ds:[esi]➔al，并且 esi++。
134         "cmpb %%ah,%%al\n\t"        // 字符串中字符 al 与指定字符 ah 相比较。
135         "je 2f\n\t"                 // 若相等，则向前跳转到标号 2 处。
136         "testb %%al,%%al\n\t"       // al 中字符是 NULL 字符吗？（字符串结尾？）
137         "jne 1b\n\t"                // 若不是，则向后跳转到标号 1，继续比较。
138         "movl $1,%1\n"              // 是，则说明没有找到匹配字符，esi 置 1。
139         "2:\tmovl %1,%0\n\t"        // 将指向匹配字符后一个字节处的指针值放入 eax
140         "decl %0"                   // 将指针调整为指向匹配的字符。
141         :"=a" (__res):"S" (s),"" (c):"si");
142 return __res;                       // 返回指针。
143 }
144
    //// 寻找字符串中指定字符最后一次出现的地方。（反向搜索字符串）
    // 参数：s - 字符串，c - 欲寻找的字符。
    // %0 - edx(__res)，%1 - edx(0)，%2 - esi(字符串指针 s)，%3 - eax(字符 c)。
    // 返回：返回字符串中最后一次出现匹配字符的指针。若没有找到匹配的字符，则返回空指针。
145 extern inline char * strrchr(const char * s,char c)
146 {
147 register char * __res __asm__("dx"); // __res 是寄存器变量(edx)。
148 __asm__("cld\n\t"                   // 清方向位。
149         "movb %%al,%%ah\n"          // 将欲寻找的字符移到 ah。
150         "1:\tlodsb\n\t"             // 取字符串中字符 ds:[esi]➔al，并且 esi++。
151         "cmpb %%ah,%%al\n\t"        // 字符串中字符 al 与指定字符 ah 作比较。
152         "jne 2f\n\t"                // 若不相等，则向前跳转到标号 2 处。
153         "movl %%esi,%0\n\t"         // 将字符指针保存到 edx 中。
154         "decl %0\n"                 // 指针后退一位，指向字符串中匹配字符处。
155         "2:\ttestb %%al,%%al\n\t"   // 比较的字符是 0 吗（到字符串尾）？
156         "jne 1b"                    // 不是则向后跳转到标号 1 处，继续比较。
157         :"=d" (__res):"" (0),"S" (s),"a" (c):"ax","si");
158 return __res;                       // 返回指针。
159 }
160
    //// 在字符串 1 中寻找第 1 个字符序列，该字符序列中的任何字符都包含在字符串 2 中。
    // 参数：cs - 字符串 1 指针，ct - 字符串 2 指针。
    // %0 - esi(__res)，%1 - eax(0)，%2 - ecx(-1)，%3 - esi(串 1 指针 cs)，%4 - (串 2 指针 ct)。
```

```
    // 返回字符串 1 中包含字符串 2 中任何字符的首个字符序列的长度值。
161 extern inline int strspn(const char * cs, const char * ct)
162 {
163 register char * __res __asm__("si"); // __res 是寄存器变量(esi)。
164 __asm__("cld\n\t"                    // 清方向位。
165         "movl %4,%%edi\n\t"          // 首先计算串 2 的长度。串 2 指针放入 edi 中。
166         "repne\n\t"                  // 比较 al(0)与串 2 中的字符（es:[edi]），并 edi++。
167         "scasb\n\t"                  // 如果不相等就继续比较(ecx 逐步递减)。
168         "notl %%ecx\n\t"             // ecx 中每位取反。
169         "decl %%ecx\n\t"             // ecx--，得串 2 的长度值。
170         "movl %%ecx,%%edx\n"         // 将串 2 的长度值暂放入 edx 中。
171         "1:\tlodsb\n\t"              // 取串 1 字符 ds:[esi]➔al，并且 esi++。
172         "testb %%al,%%al\n\t"        // 该字符等于 0 值吗（串 1 结尾）？
173         "je 2f\n\t"                  // 如果是，则向前跳转到标号 2 处。
174         "movl %4,%%edi\n\t"          // 取串 2 头指针放入 edi 中。
175         "movl %%edx,%%ecx\n\t"       // 再将串 2 的长度值放入 ecx 中。
176         "repne\n\t"                  // 比较 al 与串 2 中字符 es:[edi]，并且 edi++。
177         "scasb\n\t"                  // 如果不相等就继续比较。
178         "je 1b\n"                    // 如果相等，则向后跳转到标号 1 处。
179         "2:\tdecl %0"                // esi--，指向最后一个包含在串 2 中的字符。
180         :"=S" (__res):"a" (0),"c" (0xffffffff),"" (cs),"g" (ct)
181         :"ax","cx","dx","di");
182 return __res-cs;                     // 返回字符序列的长度值。
183 }
184
    //// 寻找字符串 1 中不包含字符串 2 中任何字符的首个字符序列。
    // 参数：cs - 字符串 1 指针，ct - 字符串 2 指针。
    // %0 - esi(__res)，%1 - eax(0)，%2 - ecx(-1)，%3 - esi(串 1 指针 cs)，%4 - (串 2 指针 ct)。
    // 返回字符串 1 中不包含字符串 2 中任何字符的首个字符序列的长度值。
185 extern inline int strcspn(const char * cs, const char * ct)
186 {
187 register char * __res __asm__("si"); // __res 是寄存器变量(esi)。
188 __asm__("cld\n\t"                    // 清方向位。
189         "movl %4,%%edi\n\t"          // 首先计算串 2 的长度。串 2 指针放入 edi 中。
190         "repne\n\t"                  // 比较 al(0)与串 2 中的字符（es:[edi]），并 edi++。
191         "scasb\n\t"                  // 如果不相等就继续比较(ecx 逐步递减)。
192         "notl %%ecx\n\t"             // ecx 中每位取反。
193         "decl %%ecx\n\t"             // ecx--，得串 2 的长度值。
194         "movl %%ecx,%%edx\n"         // 将串 2 的长度值暂放入 edx 中。
195         "1:\tlodsb\n\t"              // 取串 1 字符 ds:[esi]➔al，并且 esi++。
196         "testb %%al,%%al\n\t"        // 该字符等于 0 值吗（串 1 结尾）？
197         "je 2f\n\t"                  // 如果是，则向前跳转到标号 2 处。
198         "movl %4,%%edi\n\t"          // 取串 2 头指针放入 edi 中。
199         "movl %%edx,%%ecx\n\t"       // 再将串 2 的长度值放入 ecx 中。
200         "repne\n\t"                  // 比较 al 与串 2 中字符 es:[edi]，并且 edi++。
201         "scasb\n\t"                  // 如果不相等就继续比较。
202         "jne 1b\n"                   // 如果不相等，则向后跳转到标号 1 处。
203         "2:\tdecl %0"                // esi--，指向最后一个包含在串 2 中的字符。
204         :"=S" (__res):"a" (0),"c" (0xffffffff),"" (cs),"g" (ct)
205         :"ax","cx","dx","di");
206 return __res-cs;                     // 返回字符序列的长度值。
207 }
208
```

```
    //// 在字符串 1 中寻找首个包含在字符串 2 中的任何字符。
    // 参数：cs - 字符串 1 的指针，ct - 字符串 2 的指针。
    // %0 -esi(__res)，%1 -eax(0)，%2 -ecx(0xffffffff)，%3 -esi(串 1 指针 cs)，%4 -(串 2 指针 ct)。
    // 返回字符串 1 中首个包含字符串 2 中字符的指针。
209 extern inline char * strpbrk(const char * cs,const char * ct)
210 {
211 register char * __res __asm__("si"); // __res 是寄存器变量(esi)。
212 __asm__("cld\n\t"                     // 清方向位。
213         "movl %4,%%edi\n\t"           // 首先计算串 2 的长度。串 2 指针放入 edi 中。
214         "repne\n\t"                   // 比较 al(0)与串 2 中的字符（es:[edi]），并 edi++。
215         "scasb\n\t"                   // 如果不相等就继续比较(ecx 逐步递减)。
216         "notl %%ecx\n\t"              // ecx 中每位取反。
217         "decl %%ecx\n\t"              // ecx--，得串 2 的长度值。
218         "movl %%ecx,%%edx\n"          // 将串 2 的长度值暂放入 edx 中。
219         "1:\tlodsb\n\t"               // 取串 1 字符 ds:[esi]➔al，并且 esi++。
220         "testb %%al,%%al\n\t"         // 该字符等于 0 值吗（串 1 结尾）？
221         "je 2f\n\t"                   // 如果是，则向前跳转到标号 2 处。
222         "movl %4,%%edi\n\t"           // 取串 2 头指针放入 edi 中。
223         "movl %%edx,%%ecx\n\t"        // 再将串 2 的长度值放入 ecx 中。
224         "repne\n\t"                   // 比较 al 与串 2 中字符 es:[edi]，并且 edi++。
225         "scasb\n\t"                   // 如果不相等就继续比较。
226         "jne 1b\n\t"                  // 如果不相等，则向后跳转到标号 1 处。
227         "decl %0\n\t"                 // esi--，指向一个包含在串 2 中的字符。
228         "jmp 3f\n"                    // 向前跳转到标号 3 处。
229         "2:\txorl %0,%0\n"            // 没有找到符合条件的，将返回值为 NULL。
230         "3:"
231         :"=S" (__res):"a" (0),"c" (0xffffffff),"" (cs),"g" (ct)
232         :"ax","cx","dx","di");
233 return __res;                         // 返回指针值。
234 }
235
    //// 在字符串 1 中寻找首个匹配整个字符串 2 的字符串。
    // 参数：cs - 字符串 1 的指针，ct - 字符串 2 的指针。
    // %0 -eax(__res)，%1 -eax(0)，%2 -ecx(0xffffffff)，%3 -esi(串 1 指针 cs)，%4 -(串 2 指针 ct)。
    // 返回：返回字符串 1 中首个匹配字符串 2 的字符串指针。
236 extern inline char * strstr(const char * cs,const char * ct)
237 {
238 register char * __res __asm__("ax"); // __res 是寄存器变量(eax)。
239 __asm__("cld\n\t" \                   // 清方向位。
240         "movl %4,%%edi\n\t"           // 首先计算串 2 的长度。串 2 指针放入 edi 中。
241         "repne\n\t"                   // 比较 al(0)与串 2 中的字符（es:[edi]），并 edi++。
242         "scasb\n\t"                   // 如果不相等就继续比较(ecx 逐步递减)。
243         "notl %%ecx\n\t"              // ecx 中每位取反。
244         "decl %%ecx\n\t"              /* NOTE! This also sets Z if searchstring='' */
                                          /* 注意！如果搜索串为空，将设置 Z 标志 */ // 得串 2 的长度值。
245         "movl %%ecx,%%edx\n"          // 将串 2 的长度值暂放入 edx 中。
246         "1:\tmovl %4,%%edi\n\t"       // 取串 2 头指针放入 edi 中。
247         "movl %%esi,%%eax\n\t"        // 将串 1 的指针复制到 eax 中。
248         "movl %%edx,%%ecx\n\t"        // 再将串 2 的长度值放入 ecx 中。
249         "repe\n\t"                    // 比较串 1 和串 2 字符(ds:[esi],es:[edi])，esi++,edi++。
250         "cmpsb\n\t"                   // 若对应字符相等就一直比较下去。
251         "je 2f\n\t"                   /* also works for empty string, see above */
                                          /* 对空串同样有效，见上面 */ // 若全相等，则转到标号 2。
```

```
252         "xchgl %%eax,%%esi\n\t"     // 串 1 头指针➔esi，比较结果的串 1 指针➔eax。
253         "incl %%esi\n\t"            // 串 1 头指针指向下一个字符。
254         "cmpb $0,-1(%%eax)\n\t"     // 串 1 指针(eax-1)所指字节是 0 吗?
255         "jne 1b\n\t"                // 不是则跳转到标号 1，继续从串 1 的第 2 个字符开始比较。
256         "xorl %%eax,%%eax\n\t"      // 清 eax，表示没有找到匹配。
257         "2:"
258         :"=a" (__res):"" (0),"c" (0xffffffff),"S" (cs),"g" (ct)
259         :"cx","dx","di","si");
260 return __res;                       // 返回比较结果。
261 }
262
    //// 计算字符串长度。
    // 参数：s - 字符串。
    // %0 - ecx(__res)，%1 - edi(字符串指针 s)，%2 - eax(0)，%3 - ecx(0xffffffff)。
    // 返回：返回字符串的长度。
263 extern inline int strlen(const char * s)
264 {
265 register int __res __asm__("cx");   // __res 是寄存器变量(ecx)。
266 __asm__("cld\n\t"                   // 清方向位。
267         "repne\n\t"                 // al(0)与字符串中字符 es:[edi]比较，
268         "scasb\n\t"                 // 若不相等就一直比较。
269         "notl %0\n\t"               // ecx 取反。
270         "decl %0"                   // ecx--，得字符串得长度值。
271         :"=c" (__res):"D" (s),"a" (0),"" (0xffffffff):"di");
272 return __res;                       // 返回字符串长度值。
273 }
274
275 extern char * ___strtok;        // 用于临时存放指向下面被分析字符串 1(s)的指针。
276
    //// 利用字符串 2 中的字符将字符串 1 分割成标记(tokern)序列。
    // 将串 1 看作是包含零个或多个单词(token)的序列，并由分割符字符串 2 中的一个或多个字符分开。
    // 第一次调用 strtok()时，将返回指向字符串 1 中第 1 个 token 首字符的指针，并在返回 token 时将
    // 一 null 字符写到分割符处。后续使用 null 作为字符串 1 的调用，将用这种方法继续扫描字符串 1，
    // 直到没有 token 为止。在不同的调用过程中，分割符串 2 可以不同。
    // 参数：s - 待处理的字符串 1，ct - 包含各个分割符的字符串 2。
    // 汇编输出：%0 - ebx(__res)，%1 - esi(__strtok)；
    // 汇编输入：%2 - ebx(__strtok)，%3 - esi(字符串 1 指针 s)，%4 - （字符串 2 指针 ct）。
    // 返回：返回字符串 s 中第 1 个 token，如果没有找到 token，则返回一个 null 指针。
    // 后续使用字符串 s 指针为 null 的调用，将在原字符串 s 中搜索下一个 token。
277 extern inline char * strtok(char * s,const char * ct)
278 {
279 register char * __res __asm__("si");
280 __asm__("testl %1,%1\n\t"           // 首先测试 esi(字符串 1 指针 s)是否是 NULL。
281         "jne 1f\n\t"                // 如果不是，则表明是首次调用本函数，跳转标号 1。
282         "testl %0,%0\n\t"           // 如果是 NULL，则表示此次是后续调用，测 ebx(__strtok)。
283         "je 8f\n\t"                 // 如果 ebx 指针是 NULL，则不能处理，跳转结束。
284         "movl %0,%1\n"              // 将 ebx 指针复制到 esi。
285         "1:\txorl %0,%0\n\t"        // 清 ebx 指针。
286         "movl $-1,%%ecx\n\t"        // 置 ecx = 0xffffffff。
287         "xorl %%eax,%%eax\n\t"      // 清零 eax。
288         "cld\n\t"                   // 清方向位。
289         "movl %4,%%edi\n\t"         // 下面求字符串 2 的长度。edi 指向字符串 2。
290         "repne\n\t"                 // 将 al(0)与 es:[edi]比较，并且 edi++。
```

```
291         "scasb\n\t"                 // 直到找到字符串 2 的结束 null 字符，或计数 ecx==0。
292         "notl %%ecx\n\t"            // 将 ecx 取反，
293         "decl %%ecx\n\t"            // ecx--，得到字符串 2 的长度值。
294         "je 7f\n\t"                   /* empty delimeter-string */
                                        /* 分割符字符串空 */ // 若串 2 长度为 0，则转标号 7。
295         "movl %%ecx,%%edx\n"        // 将串 2 长度暂存入 edx。
296         "2:\tlodsb\n\t"             // 取串 1 的字符 ds:[esi]➔al，并且 esi++。
297         "testb %%al,%%al\n\t"       // 该字符为 0 值吗(串 1 结束)？
298         "je 7f\n\t"                 // 如果是，则跳转标号 7。
299         "movl %4,%%edi\n\t"         // edi 再次指向串 2 首。
300         "movl %%edx,%%ecx\n\t"      // 取串 2 的长度值置入计数器 ecx。
301         "repne\n\t"                 // 将 al 中串 1 的字符与串 2 中所有字符比较，
302         "scasb\n\t"                 // 判断该字符是否为分割符。
303         "je 2b\n\t"                 // 若能在串 2 中找到相同字符（分割符），则跳转标号 2。
304         "decl %1\n\t"               // 若不是分割符，则串 1 指针 esi 指向此时的该字符。
305         "cmpb $0,(%1)\n\t"          // 该字符是 NULL 字符吗？
306         "je 7f\n\t"                 // 若是，则跳转标号 7 处。
307         "movl %1,%0\n"              // 将该字符的指针 esi 存放在 ebx。
308         "3:\tlodsb\n\t"             // 取串 1 下一个字符 ds:[esi]➔al，并且 esi++。
309         "testb %%al,%%al\n\t"       // 该字符是 NULL 字符吗？
310         "je 5f\n\t"                 // 若是，表示串 1 结束，跳转到标号 5。
311         "movl %4,%%edi\n\t"         // edi 再次指向串 2 首。
312         "movl %%edx,%%ecx\n\t"      // 串 2 长度值置入计数器 ecx。
313         "repne\n\t"                 // 将 al 中串 1 的字符与串 2 中每个字符比较，
314         "scasb\n\t"                 // 测试 al 字符是否是分割符。
315         "jne 3b\n\t"                // 若不是分割符则跳转标号 3，检测串 1 中下一个字符。
316         "decl %1\n\t"               // 若是分割符，则 esi--，指向该分割符字符。
317         "cmpb $0,(%1)\n\t"          // 该分割符是 NULL 字符吗？
318         "je 5f\n\t"                 // 若是，则跳转到标号 5。
319         "movb $0,(%1)\n\t"          // 若不是，则将该分割符用 NULL 字符替换掉。
320         "incl %1\n\t"               // esi 指向串 1 中下一个字符，也即剩余串首。
321         "jmp 6f\n"                  // 跳转标号 6 处。
322         "5:\txorl %1,%1\n"          // esi 清零。
323         "6:\tcmpb $0,(%0)\n\t"      // ebx 指针指向 NULL 字符吗？
324         "jne 7f\n\t"                // 若不是，则跳转标号 7。
325         "xorl %0,%0\n"              // 若是，则让 ebx=NULL。
326         "7:\ttestl %0,%0\n\t"       // ebx 指针为 NULL 吗？
327         "jne 8f\n\t"                // 若不是则跳转 8，结束汇编代码。
328         "movl %0,%1\n"              // 将 esi 置为 NULL。
329         "8:"
330         :"=b" (__res),"=S" (___strtok)
331         :"" (___strtok),"1" (s),"g" (ct)
332         :"ax","cx","dx","di");
333 return __res;                       // 返回指向新 token 的指针。
334 }
335
    //// 内存块复制。从源地址 src 处开始复制 n 个字节到目的地址 dest 处。
    // 参数：dest - 复制的目的地址，src - 复制的源地址，n - 复制字节数。
    // %0 - ecx(n)，%1 - esi(src)，%2 - edi(dest)。
336 extern inline void * memcpy(void * dest,const void * src, int n)
337 {
338 __asm__("cld\n\t"                   // 清方向位。
339         "rep\n\t"                   // 重复执行复制 ecx 个字节，
```

```
340         "movsb"                         // 从 ds:[esi]到 es:[edi]，esi++，edi++。
341         ::"c" (n),"S" (src),"D" (dest)
342         :"cx","si","di");
343 return dest;                           // 返回目的地址。
344 }
345
    //// 内存块移动。同内存块复制，但考虑移动的方向。
    // 参数：dest - 复制的目的地址，src - 复制的源地址，n - 复制字节数。
    // 若 dest<src 则：%0 - ecx(n)，%1 - esi(src)，%2 - edi(dest)。
    // 否则：%0 - ecx(n)，%1 - esi(src+n-1)，%2 - edi(dest+n-1)。
    // 这样操作是为了防止在复制时错误地重叠覆盖。
346 extern inline void * memmove(void * dest,const void * src, int n)
347 {
348 if (dest<src)
349 __asm__("cld\n\t"                       // 清方向位。
350         "rep\n\t"                       // 从 ds:[esi]到 es:[edi]，并且 esi++，edi++，
351         "movsb"                         // 重复执行复制 ecx 字节。
352         ::"c" (n),"S" (src),"D" (dest)
353         :"cx","si","di");
354 else
355 __asm__("std\n\t"                       // 置方向位，从末端开始复制。
356         "rep\n\t"                       // 从 ds:[esi]到 es:[edi]，并且 esi--，edi--，
357         "movsb"                         // 复制 ecx 个字节。
358         ::"c" (n),"S" (src+n-1),"D" (dest+n-1)
359         :"cx","si","di");
360 return dest;
361 }
362
    //// 比较 n 个字节的两块内存（两个字符串），即使遇上 NULL 字节也不停止比较。
    // 参数：cs - 内存块 1 地址，ct - 内存块 2 地址，count - 比较的字节数。
    // %0 - eax(__res)，%1 - eax(0)，%2 - edi(内存块 1)，%3 - esi(内存块 2)，%4 - ecx(count)。
    // 返回：若块 1>块 2 返回 1；块 1<块 2，返回-1；块 1==块 2，则返回 0。
363 extern inline int memcmp(const void * cs,const void * ct,int count)
364 {
365 register int __res __asm__("ax");      // __res 是寄存器变量。
366 __asm__("cld\n\t"                       // 清方向位。
367         "repe\n\t"                      // 如果相等则重复，
368         "cmpsb\n\t"                     // 比较 ds:[esi]与 es:[edi]的内容，并且 esi++，edi++。
369         "je 1f\n\t"                     // 如果都相同，则跳转到标号 1，返回 0(eax)值
370         "movl $1,%%eax\n\t"             // 否则 eax 置 1，
371         "jl 1f\n\t"                     // 若内存块 2 内容的值<内存块 1，则跳转标号 1。
372         "negl %%eax\n"                  // 否则 eax = -eax。
373         "1:"
374         :"=a" (__res):"" (0),"D" (cs),"S" (ct),"c" (count)
375         :"si","di","cx");
376 return __res;                          // 返回比较结果。
377 }
378
    //// 在 n 字节大小的内存块(字符串)中寻找指定字符。
    // 参数：cs - 指定内存块地址，c - 指定的字符，count - 内存块长度。
    // %0 - edi(__res)，%1 - eax(字符 c)，%2 - edi(内存块地址 cs)，%3 - ecx(字节数 count)。
    // 返回第一个匹配字符的指针，如果没有找到，则返回 NULL 字符。
379 extern inline void * memchr(const void * cs,char c,int count)
```

```
380 {
381 register void * __res __asm__("di"); // __res 是寄存器变量。
382 if (!count)                           // 如果内存块长度==0，则返回 NULL，没有找到。
383         return NULL;
384 __asm__("cld\n\t"                     // 清方向位。
385         "repne\n\t"                   // 如果不相等则重复执行下面语句，
386         "scasb\n\t"                   // al 中字符与 es:[edi]字符作比较，并且 edi++，
387         "je 1f\n\t"                   // 如果相等则向前跳转到标号 1 处。
388         "movl $1,%0\n"                // 否则 edi 中置 1。
389         "1:\tdecl %0"                 // 让 edi 指向找到的字符（或是 NULL）。
390         :"=D" (__res):"a" (c),"D" (cs),"c" (count)
391         :"cx");
392 return __res;                         // 返回字符指针。
393 }
394
    //// 用字符填写指定长度内存块。
    // 用字符 c 填写 s 指向的内存区域，共填 count 字节。
    // %0 - eax(字符 c)，%1 - edi(内存地址)，%2 - ecx(字节数 count)。
395 extern inline void * memset(void * s,char c,int count)
396 {
397 __asm__("cld\n\t"                     // 清方向位。
398         "rep\n\t"                     // 重复 ecx 指定的次数，执行
399         "stosb"                       // 将 al 中字符存入 es:[edi]中，并且 edi++。
400         ::"a" (c),"D" (s),"c" (count)
401         :"cx","di");
402 return s;
403 }
404
405 #endif
406
```

11.12 termios.h 文件

11.12.1 功能描述

该文件含有终端 I/O 接口定义。包括 termios 数据结构和一些对通用终端接口设置的函数原型。这些函数用来读取或设置终端的属性、线路控制、读取或设置波特率以及读取或设置终端前端进程的组 id。虽然这是 linux 早期的头文件，但已完全符合目前的 POSIX 标准，并作了适当的扩展。

在该文件中定义的两个终端数据结构 termio 和 termios 是分别属于两类 UNIX 系列（或刻隆），termio 是在 AT&T 系统 V 中定义的，而 termios 是 POSIX 标准指定的。两个结构基本一样，只是 termio 使用短整数类型定义模式标志集，而 termios 使用长整数定义模式标志集。由于目前这两种结构都在使用，因此为了兼容性，大多数系统都同时支持它们。另外，以前使用的是一类似的 sgtty 结构，目前已基本不用。

11.12.2 代码注释

程序 11-10 linux/include/termios.h

```
 1 #ifndef _TERMIOS_H
 2 #define _TERMIOS_H
 3
 4 #define TTY_BUF_SIZE 1024            // tty 中的缓冲区长度。
 5
 6 /* 0x54 is just a magic number to make these relatively uniqe ('T') */
   /* 0x54 只是一个魔数，目的是为了使这些常数唯一('T') */
 7
   // tty 设备的 ioctl 调用命令集。ioctl 将命令编码在低位字中。
   // 下面名称 TC[*]的含义是 tty 控制命令。
   // 取相应终端 termios 结构中的信息(参见 tcgetattr())。
 8 #define TCGETS          0x5401
   // 设置相应终端 termios 结构中的信息(参见 tcsetattr(), TCSANOW)。
 9 #define TCSETS          0x5402
   // 在设置终端 termios 的信息之前，需要先等待输出队列中所有数据处理完(耗尽)。对于修改参数
   // 会影响输出的情况，就需要使用这种形式(参见 tcsetattr(), TCSADRAIN 选项)。
10 #define TCSETSW         0x5403
   // 在设置 termios 的信息之前，需要先等待输出队列中所有数据处理完，并且刷新(清空)输入队列。
   // 再设置（参见 tcsetattr(), TCSAFLUSH 选项）。
11 #define TCSETSF         0x5404
   // 取相应终端 termio 结构中的信息(参见 tcgetattr())。
12 #define TCGETA          0x5405
   // 设置相应终端 termio 结构中的信息(参见 tcsetattr(), TCSANOW 选项)。
13 #define TCSETA          0x5406
   // 在设置终端 termio 的信息之前，需要先等待输出队列中所有数据处理完(耗尽)。对于修改参数
   // 会影响输出的情况，就需要使用这种形式(参见 tcsetattr(), TCSADRAIN 选项)。
14 #define TCSETAW         0x5407
   // 在设置 termio 的信息之前，需要先等待输出队列中所有数据处理完，并且刷新(清空)输入队列。
   // 再设置（参见 tcsetattr(), TCSAFLUSH 选项）。
15 #define TCSETAF         0x5408
   // 等待输出队列处理完毕(空)，如果参数值是 0，则发送一个 break（参见 tcsendbreak()，tcdrain()）。
16 #define TCSBRK          0x5409
   // 开始/停止控制。如果参数值是 0，则挂起输出；如果是 1，则重新开启挂起的输出；如果是 2，则挂
起
   // 输入；如果是 3，则重新开启挂起的输入（参见 tcflow()）。
17 #define TCXONC          0x540A
   //刷新已写输出但还没发送或已收但还没有读数据。如果参数是 0，则刷新(清空)输入队列；如果是 1，
   // 则刷新输出队列；如果是 2，则刷新输入和输出队列（参见 tcflush()）。
18 #define TCFLSH          0x540B
   // 下面名称 TIOC[*]的含义是 tty 输入输出控制命令。
   // 设置终端串行线路专用模式。
19 #define TIOCEXCL        0x540C
   // 复位终端串行线路专用模式。
20 #define TIOCNXCL        0x540D
   // 设置 tty 为控制终端。(TIOCNOTTY - 禁止 tty 为控制终端)。
21 #define TIOCSCTTY       0x540E
   // 读取指定终端设备进程的组 id(参见 tcgetpgrp())。
22 #define TIOCGPGRP       0x540F
   // 设置指定终端设备进程的组 id(参见 tcsetpgrp())。
23 #define TIOCSPGRP       0x5410
   // 返回输出队列中还未送出的字符数。
24 #define TIOCOUTQ        0x5411
   // 模拟终端输入。该命令以一个指向字符的指针作为参数，并假装该字符是在终端上键入的。用户必须
```

```
    // 在该控制终端上具有超级用户权限或具有读许可权限。
25  #define TIOCSTI         0x5412
    // 读取终端设备窗口大小信息（参见 winsize 结构）。
26  #define TIOCGWINSZ      0x5413
    // 设置终端设备窗口大小信息（参见 winsize 结构）。
27  #define TIOCSWINSZ      0x5414
    // 返回 modem 状态控制引线的当前状态比特位标志集（参见下面 185-196 行）。
28  #define TIOCMGET        0x5415
    // 设置单个 modem 状态控制引线的状态(true 或 false)(Individual control line Set)。
29  #define TIOCMBIS        0x5416
    // 复位单个 modem 状态控制引线的状态(Individual control line clear)。
30  #define TIOCMBIC        0x5417
    // 设置 modem 状态引线的状态。如果某一比特位置位，则 modem 对应的状态引线将置为有效。
31  #define TIOCMSET        0x5418
    // 读取软件载波检测标志(1 - 开启；0 - 关闭)。
    // 对于本地连接的终端或其他设备，软件载波标志是开启的，对于使用 modem 线路的终端或设备则
    // 是关闭的。为了能使用这两个 ioctl 调用，tty 线路应该是以 O_NDELAY 方式打开的，这样 open()
    // 就不会等待载波。
32  #define TIOCGSOFTCAR    0x5419
    // 设置软件载波检测标志(1 - 开启；0 - 关闭)。
33  #define TIOCSSOFTCAR    0x541A
    // 返回输入队列中还未取走字符的数目。
34  #define TIOCINQ         0x541B
35
    // 窗口大小(Window size)属性结构。在窗口环境中可用于基于屏幕的应用程序。
    // ioctls 中的 TIOCGWINSZ 和 TIOCSWINSZ 可用来读取或设置这些信息。
36  struct winsize {
37          unsigned short ws_row;      // 窗口字符行数。
38          unsigned short ws_col;      // 窗口字符列数。
39          unsigned short ws_xpixel;   // 窗口宽度，象素值。
40          unsigned short ws_ypixel;   // 窗口高度，象素值。
41  };
42
    // AT&T 系统 V 的 termio 结构。
43  #define NCC 8                       // termio 结构中控制字符数组的长度。
44  struct termio {
45          unsigned short c_iflag;         /* input mode flags */      // 输入模式标志。
46          unsigned short c_oflag;         /* output mode flags */     // 输出模式标志。
47          unsigned short c_cflag;         /* control mode flags */    // 控制模式标志。
48          unsigned short c_lflag;         /* local mode flags */      // 本地模式标志。
49          unsigned char c_line;           /* line discipline */       // 线路规程（速率）。
50          unsigned char c_cc[NCC];        /* control characters */    // 控制字符数组。
51  };
52
    // POSIX 的 termios 结构。
53  #define NCCS 17                     // termios 结构中控制字符数组的长度。
54  struct termios {
55          unsigned long c_iflag;          /* input mode flags */      // 输入模式标志。
56          unsigned long c_oflag;          /* output mode flags */     // 输出模式标志。
57          unsigned long c_cflag;          /* control mode flags */    // 控制模式标志。
58          unsigned long c_lflag;          /* local mode flags */      // 本地模式标志。
59          unsigned char c_line;           /* line discipline */       // 线路规程（速率）。
60          unsigned char c_cc[NCCS];       /* control characters */    // 控制字符数组。
```

```
61 };
62
63 /* c_cc characters */    /* c_cc 数组中的字符 */
   // 以下是 c_cc 数组对应字符的索引值。
64 #define VINTR 0          // c_cc[VINTR]    = INTR    (^C), \003, 中断字符。
65 #define VQUIT 1          // c_cc[VQUIT]    = QUIT    (^\), \034, 退出字符。
66 #define VERASE 2         // c_cc[VERASE]   = ERASE   (^H), \177, 擦出字符。
67 #define VKILL 3          // c_cc[VKILL]    = KILL    (^U), \025, 终止字符。
68 #define VEOF 4           // c_cc[VEOF]     = EOF     (^D), \004, 文件结束字符。
69 #define VTIME 5          // c_cc[VTIME]    = TIME    (\0), \0,   定时器值(参见后面说明)。
70 #define VMIN 6           // c_cc[VMIN]     = MIN     (\1), \1,   定时器值。
71 #define VSWTC 7          // c_cc[VSWTC]    = SWTC    (\0), \0,   交换字符。
72 #define VSTART 8         // c_cc[VSTART]   = START   (^Q), \021, 开始字符。
73 #define VSTOP 9          // c_cc[VSTOP]    = STOP    (^S), \023, 停止字符。
74 #define VSUSP 10         // c_cc[VSUSP]    = SUSP    (^Z), \032, 挂起字符。
75 #define VEOL 11          // c_cc[VEOL]     = EOL     (\0), \0,   行结束字符。
76 #define VREPRINT 12      // c_cc[VREPRINT] = REPRINT (^R), \022, 重显示字符。
77 #define VDISCARD 13      // c_cc[VDISCARD] = DISCARD (^O), \017, 丢弃字符。
78 #define VWERASE 14       // c_cc[VWERASE]  = WERASE  (^W), \027, 单词擦除字符。
79 #define VLNEXT 15        // c_cc[VLNEXT]   = LNEXT   (^V), \026, 下一行字符。
80 #define VEOL2 16         // c_cc[VEOL2]    = EOL2    (\0), \0,   行结束字符 2。
81
82 /* c_iflag bits */       /* c_iflag 比特位 */
   // termios 结构输入模式字段 c_iflag 各种标志的符号常数。
83 #define IGNBRK  0000001          // 输入时忽略 BREAK 条件。
84 #define BRKINT  0000002          // 在 BREAK 时产生 SIGINT 信号。
85 #define IGNPAR  0000004          // 忽略奇偶校验出错的字符。
86 #define PARMRK  0000010          // 标记奇偶校验错。
87 #define INPCK   0000020          // 允许输入奇偶校验。
88 #define ISTRIP  0000040          // 屏蔽字符第 8 位。
89 #define INLCR   0000100          // 输入时将换行符 NL 映射成回车符 CR。
90 #define IGNCR   0000200          // 忽略回车符 CR。
91 #define ICRNL   0000400          // 在输入时将回车符 CR 映射成换行符 NL。
92 #define IUCLC   0001000          // 在输入时将大写字符转换成小写字符。
93 #define IXON    0002000          // 允许开始/停止（XON/XOFF）输出控制。
94 #define IXANY   0004000          // 允许任何字符重启输出。
95 #define IXOFF   0010000          // 允许开始/停止（XON/XOFF）输入控制。
96 #define IMAXBEL 0020000          // 输入队列满时响铃。
97
98 /* c_oflag bits */       /* c_oflag 比特位 */
   // termios 结构中输出模式字段 c_oflag 各种标志的符号常数。
99 #define OPOST   0000001          // 执行输出处理。
100 #define OLCUC   0000002          // 在输出时将小写字符转换成大写字符。
101 #define ONLCR   0000004          // 在输出时将换行符 NL 映射成回车-换行符 CR-NL。
102 #define OCRNL   0000010          // 在输出时将回车符 CR 映射成换行符 NL。
103 #define ONOCR   0000020          // 在 0 列不输出回车符 CR。
104 #define ONLRET  0000040          // 换行符 NL 执行回车符的功能。
105 #define OFILL   0000100          // 延迟时使用填充字符而不使用时间延迟。
106 #define OFDEL   0000200          // 填充字符是 ASCII 码 DEL。如果未设置，则使用 ASCII NULL。
107 #define NLDLY   0000400          // 选择换行延迟。
108 #define   NL0   0000000          // 换行延迟类型 0。
109 #define   NL1   0000400          // 换行延迟类型 1。
110 #define CRDLY   0003000          // 选择回车延迟。
```

```
111 #define   CR0    0000000          // 回车延迟类型 0。
112 #define   CR1    0001000          // 回车延迟类型 1。
113 #define   CR2    0002000          // 回车延迟类型 2。
114 #define   CR3    0003000          // 回车延迟类型 3。
115 #define TABDLY   0014000          // 选择水平制表延迟。
116 #define   TAB0   0000000          // 水平制表延迟类型 0。
117 #define   TAB1   0004000          // 水平制表延迟类型 1。
118 #define   TAB2   0010000          // 水平制表延迟类型 2。
119 #define   TAB3   0014000          // 水平制表延迟类型 3。
120 #define   XTABS  0014000          // 将制表符 TAB 换成空格，该值表示空格数。
121 #define BSDLY    0020000          // 选择退格延迟。
122 #define   BS0    0000000          // 退格延迟类型 0。
123 #define   BS1    0020000          // 退格延迟类型 1。
124 #define VTDLY    0040000          // 纵向制表延迟。
125 #define   VT0    0000000          // 纵向制表延迟类型 0。
126 #define   VT1    0040000          // 纵向制表延迟类型 1。
127 #define FFDLY    0040000          // 选择换页延迟。
128 #define   FF0    0000000          // 换页延迟类型 0。
129 #define   FF1    0040000          // 换页延迟类型 1。
130
131 /* c_cflag bit meaning */     /* c_cflag 比特位的含义 */
    // termios 结构中控制模式标志字段 c_cflag 标志的符号常数（8 进制数）。
132 #define CBAUD    0000017          // 传输速率位屏蔽码。
133 #define  B0      0000000          /* hang up */  /* 挂断线路 */
134 #define  B50     0000001          // 波特率 50。
135 #define  B75     0000002          // 波特率 75。
136 #define  B110    0000003          // 波特率 110。
137 #define  B134    0000004          // 波特率 134。
138 #define  B150    0000005          // 波特率 150。
139 #define  B200    0000006          // 波特率 200。
140 #define  B300    0000007          // 波特率 300。
141 #define  B600    0000010          // 波特率 600。
142 #define  B1200   0000011          // 波特率 1200。
143 #define  B1800   0000012          // 波特率 1800。
144 #define  B2400   0000013          // 波特率 2400。
145 #define  B4800   0000014          // 波特率 4800。
146 #define  B9600   0000015          // 波特率 9600。
147 #define  B19200  0000016          // 波特率 19200。
148 #define  B38400  0000017          // 波特率 38400。
149 #define EXTA B19200               // 扩展波特率 A。
150 #define EXTB B38400               // 扩展波特率 B。

151 #define CSIZE    0000060          // 字符位宽度屏蔽码。
152 #define   CS5    0000000          // 每字符 5 比特位。
153 #define   CS6    0000020          // 每字符 6 比特位。
154 #define   CS7    0000040          // 每字符 7 比特位。
155 #define   CS8    0000060          // 每字符 8 比特位。
156 #define CSTOPB   0000100          // 设置两个停止位，而不是 1 个。
157 #define CREAD    0000200          // 允许接收。
158 #define CPARENB  0000400          // 开启输出时产生奇偶位、输入时进行奇偶校验。
159 #define CPARODD  0001000          // 输入/输入校验是奇校验。
160 #define HUPCL    0002000          // 最后进程关闭后挂断。
161 #define CLOCAL   0004000          // 忽略调制解调器(modem)控制线路。
```

```
162 #define CIBAUD   03600000        /* input baud rate (not used) */  /* 输入波特率(未使用) */
163 #define CRTSCTS  020000000000    /* flow control */  /* 流控制 */
164
165 #define PARENB CPARENB           // 开启输出时产生奇偶位、输入时进行奇偶校验。
166 #define PARODD CPARODD           // 输入/输入校验是奇校验。
167
168 /* c_lflag bits */       /* c_lflag 比特位 */
    // termios 结构中本地模式标志字段 c_lflag 的符号常数。
169 #define ISIG     0000001         // 当收到字符 INTR、QUIT、SUSP 或 DSUSP，产生相应的信号。
170 #define ICANON   0000002         // 开启规范模式（熟模式）。
171 #define XCASE    0000004         // 若设置了 ICANON，则终端是大写字符的。
172 #define ECHO     0000010         // 回显输入字符。
173 #define ECHOE    0000020         // 若设置了 ICANON，则 ERASE/WERASE 将擦除前一字符/单词。
174 #define ECHOK    0000040         // 若设置了 ICANON，则 KILL 字符将擦除当前行。
175 #define ECHONL   0000100         // 如设置了 ICANON，则即使 ECHO 没有开启也回显 NL 字符。
176 #define NOFLSH   0000200         // 当生成 SIGINT 和 SIGQUIT 信号时不刷新输入输出队列，当
                                     // 生成 SIGSUSP 信号时，刷新输入队列。
177 #define TOSTOP   0000400         // 发送 SIGTTOU 信号到后台进程的进程组，该后台进程试图写
                                     // 自己的控制终端。
178 #define ECHOCTL  0001000         // 若设置了 ECHO，则除 TAB、NL、START 和 STOP 以外的 ASCII
                                     // 控制信号将被回显成象^X 式样，X 值是控制符+0x40。
179 #define ECHOPRT  0002000         // 若设置了 ICANON 和 IECHO，则字符在擦除时将显示。
180 #define ECHOKE   0004000         // 若设置了 ICANON，则 KILL 通过擦除行上的所有字符被回显。
181 #define FLUSHO   0010000         // 输出被刷新。通过键入 DISCARD 字符，该标志被翻转。
182 #define PENDIN   0040000         // 当下一个字符是读时，输入队列中的所有字符将被重显。
183 #define IEXTEN   0100000         // 开启实现时定义的输入处理。
184
185 /* modem lines */    /* modem 线路信号符号常数 */
186 #define TIOCM_LE        0x001        // 线路允许(Line Enable)。
187 #define TIOCM_DTR       0x002        // 数据终端就绪(Data Terminal Ready)。
188 #define TIOCM_RTS       0x004        // 请求发送(Request to Send)。
189 #define TIOCM_ST        0x008        // 串行数据发送(Serial Transfer)。[??]
190 #define TIOCM_SR        0x010        // 串行数据接收(Serial Receive)。[??]
191 #define TIOCM_CTS       0x020        // 清除发送(Clear To Send)。
192 #define TIOCM_CAR       0x040        // 载波监测(Carrier Detect)。
193 #define TIOCM_RNG       0x080        // 响铃指示(Ring indicate)。
194 #define TIOCM_DSR       0x100        // 数据设备就绪(Data Set Ready)。
195 #define TIOCM_CD        TIOCM_CAR
196 #define TIOCM_RI        TIOCM_RNG
197
198 /* tcflow() and TCXONC use these */   /* tcflow()和 TCXONC 使用这些符号常数 */
199 #define TCOOFF          0          // 挂起输出。
200 #define TCOON           1          // 重启被挂起的输出。
201 #define TCIOFF          2          // 系统传输一个 STOP 字符，使设备停止向系统传输数据。
202 #define TCION           3          // 系统传输一个 START 字符，使设备开始向系统传输数据。
203
204 /* tcflush() and TCFLSH use these */  /* tcflush()和 TCFLSH 使用这些符号常数 */
205 #define TCIFLUSH        0          // 清接收到的数据但不读。
206 #define TCOFLUSH        1          // 清已写的数据但不传送。
207 #define TCIOFLUSH       2          // 清接收到的数据但不读。清已写的数据但不传送。
208
209 /* tcsetattr uses these */           /* tcsetattr()使用这些符号常数 */
210 #define TCSANOW         0          // 改变立即发生。
```

```
211 #define TCSADRAIN       1           // 改变在所有已写的输出被传输之后发生。
212 #define TCSAFLUSH       2           // 改变在所有已写的输出被传输之后并且在所有接收到但
                                        // 还没有读取的数据被丢弃之后发生。
213
214 typedef int speed_t;                // 波特率数值类型。
215
    // 返回 termios_p 所指 termios 结构中的接收波特率。
216 extern speed_t cfgetispeed(struct termios *termios_p);
    // 返回 termios_p 所指 termios 结构中的发送波特率。
217 extern speed_t cfgetospeed(struct termios *termios_p);
    // 将 termios_p 所指 termios 结构中的接收波特率设置为 speed。
218 extern int cfsetispeed(struct termios *termios_p, speed_t speed);
    // 将 termios_p 所指 termios 结构中的发送波特率设置为 speed。
219 extern int cfsetospeed(struct termios *termios_p, speed_t speed);
    // 等待 fildes 所指对象已写输出数据被传送出去。
220 extern int tcdrain(int fildes);
    // 挂起/重启 fildes 所指对象数据的接收和发送。
221 extern int tcflow(int fildes, int action);
    // 丢弃 fildes 指定对象所有已写但还没传送以及所有已收到但还没有读取的数据。
222 extern int tcflush(int fildes, int queue_selector);
    // 获取与句柄 fildes 对应对象的参数，并将其保存在 termios_p 所指的地方。
223 extern int tcgetattr(int fildes, struct termios *termios_p);
    // 如果终端使用异步串行数据传输，则在一定时间内连续传输一系列 0 值比特位。
224 extern int tcsendbreak(int fildes, int duration);
    // 使用 termios 结构指针 termios_p 所指的数据，设置与终端相关的参数。
225 extern int tcsetattr(int fildes, int optional_actions,
226         struct termios *termios_p);
227
228 #endif
229
```

11.12.3 其他信息

11.12.3.1 控制字符 TIME、MIN

在非规范模式输入处理中，输入字符没有被处理成行，因此擦除和终止处理也就不会发生。MIN 和 TIMEDE 的值即用于确定如何处理接收到的字符。

MIN 表示当满足读操作时（也即，当字符返给用户时）需要读取的最少字符数。TIME 是以 1/10 秒计数的定时值，用于超时定时和短期数据传输。这两个字符的四种组合情况及其相互作用描述如下：

MIN > 0，TIME > 0 的情况：

在这种情况下，TIME 起字符与字符间的定时器作用，并在接收到第 1 个字符后开始起作用。由于它是字符与字符间的定时器，所以在每收到一个字符就会被复位重启。MIN 与 TIME 之间的相互作用如下：一旦收到一个字符，字符间定时器就开始工作。如果在定时器超时（注意定时器每收到一个字符就会重新开始计时）之前收到了 MIN 个字符，则读操作即被满足。如果在 MIN 个字符被收到之前定时器超时了，就将到此时已收到的字符返回给用户。注意，如果 TIME 超时，则起码有一个接收到的字符将被返回，因为定时器只有在接收到了一个字符之后才开始起作用(计时)。在这种情况下(MIN > 0，TIME > 0)，读操作将会睡眠，直到接收到第 1 个字符激活 MIN 与 TIME 机制。如果读到字符数少于已有的字符数，那么定时器将不会被重新激活，因而随后的读操作将被立刻满足。

MIN > 0，TIME = 0 的情况：

在这种情况下，由于 TIME 的值是 0，因此定时器不起作用，只有 MIN 是有意义的。等待的读操作只有当接收到 MIN 个字符时才会被满足(等待着的操作将睡眠直到收到 MIN 个字符)。使用这种情况去读基于记录的终端 IO 的程序将会在读操作中被不确定地（随意地）阻塞。

MIN = 0，TIME > 0 的情况：

在这种情况下，由于 MIN=0，则 TIME 不再起字符间的定时器作用，而是一个读操作定时器，并在读操作一开始就起作用。只要接收到一个字符或者定时器超时就已满足读操作。注意，在这种情况下，如果定时器超时了，将读不到一个字符。如果定时器没有超时，那么只有在读到一个字符之后读操作才会满足。因此在这种情况下，读操作不会无限制地(不确定地)被阻塞，以等待字符。在读操作开始后，如果在 TIME*0.10 秒的时间内没有收到字符，读操作将以收到 0 个字符而返回。

MIN = 0，TIME = 0 的情况：

在这种情况下，读操作会立刻返回。所请求读的字符数或缓冲队列中现有字符数中的最小值将被返回，而不会等待更多的字符被输入缓冲中。

总得来说，在非规范模式下，这两个值是超时定时值和字符计数值。MIN 表示为了满足读操作，需要读取的最少字符数。TIME 是一个十分之一秒计数的计时值。当这两个都设置的话，读操作将等待，直到至少读到一个字符，然后在以读取 MIN 个字符或者时间 TIME 在读取最后一个字符后超时。如果仅设置了 MIN，那么在读取 MIN 个字符之前读操作将不返回。如果仅设置了 TIME，那么在读到至少一个字符或者定时超时后读操作将立刻返回。如果两个都没有设置，则读操作将立刻返回，仅给出目前已读的字节数。

11.13 time.h 文件

11.13.1 功能描述

该头文件用于涉及处理时间的函数。在 MINIX 中有一段对时间的描述很有趣：时间的处理较为复杂，比如什么是 GMT（格林威治标准时间）、本地时间或其他时间等。尽管主教 Ussher(1581-1656 年)曾经计算过，根据圣经，世界开始之日是公元前 4004 年 10 月 12 日上午 9 点，但在 UNIX 世界里，时间是从 GMT 1970 年 1 月 1 日午夜开始的，在这之前，所有均是空无的和(无效的)。

11.13.2 代码注释

程序 11-11 linux/include/time.h

```
1 #ifndef _TIME_H
2 #define _TIME_H
3
4 #ifndef _TIME_T
5 #define _TIME_T
6 typedef long time_t;                    // 从 GMT 1970 年 1 月 1 日开始的以秒计数的时间(日历时间)。
7 #endif
8
9 #ifndef _SIZE_T
```

```
10 #define _SIZE_T
11 typedef unsigned int size_t;
12 #endif
13
14 #define CLOCKS_PER_SEC 100          // 系统时钟滴答频率，100HZ。
15
16 typedef long clock_t;               // 从进程开始系统经过的时钟滴答数。
17
18 struct tm {
19         int tm_sec;                 // 秒数 [0，59]。
20         int tm_min;                 // 分钟数 [ 0，59]。
21         int tm_hour;                // 小时数 [0，59]。
22         int tm_mday;                // 1 个月的天数 [0，31]。
23         int tm_mon;                 // 1 年中月份 [0，11]。
24         int tm_year;                // 从 1900 年开始的年数。
25         int tm_wday;                // 1 星期中的某天 [0，6]（星期天 =0）。
26         int tm_yday;                // 1 年中的某天 [0，365]。
27         int tm_isdst;               // 夏令时标志。
28 };
29
   // 以下是有关时间操作的函数原型。
   // 确定处理器使用时间。返回程序所用处理器时间（滴答数）的近似值。
30 clock_t clock(void);
   // 取时间（秒数）。返回从 1970.1.1:0:0:0 开始的秒数（称为日历时间）。
31 time_t time(time_t * tp);
   // 计算时间差。返回时间 time2 与 time1 之间经过的秒数。
32 double difftime(time_t time2, time_t time1);
   // 将 tm 结构表示的时间转换成日历时间。
33 time_t mktime(struct tm * tp);
34
   // 将 tm 结构表示的时间转换成一个字符串。返回指向该串的指针。
35 char * asctime(const struct tm * tp);
   // 将日历时间转换成一个字符串形式，如“Wed Jun 30 21:49:08:1993\n”。
36 char * ctime(const time_t * tp);
   // 将日历时间转换成 tm 结构表示的 UTC 时间（UTC - 世界时间代码 Universal Time Code）。
37 struct tm * gmtime(const time_t *tp);
   // 将日历时间转换成 tm 结构表示的指定时间区(timezone)的时间。
38 struct tm *localtime(const time_t * tp);
   // 将 tm 结构表示的时间利用格式字符串 fmt 转换成最大长度为 smax 的字符串并将结果存储在 s 中。
39 size_t strftime(char * s, size_t smax, const char * fmt, const struct tm * tp);
   // 初始化时间转换信息，使用环境变量 TZ，对 zname 变量进行初始化。
   // 在与时间区相关的时间转换函数中将自动调用该函数。
40 void tzset(void);
41
42 #endif
43
```

11.14 unistd.h 文件

11.14.1 功能描述

标准符号常数和类型头文件。该文件中定义了很多各种各样的常数和类型，以及一些函数声明。如果在程序中定义了符号__LIBRARY__，则还包括内核系统调用号和内嵌汇编_syscall0()等。

11.14.2 代码注释

程序 11-12 linux/include/unistd.h

```
1  #ifndef _UNISTD_H
2  #define _UNISTD_H
3
4  /* ok, this may be a joke, but I'm working on it */
   /* ok, 这也许是个玩笑，但我正在着手处理 */
   // 下面符号常数指出符合 IEEE 标准 1003.1 实现的版本号，是一个整数值。
5  #define _POSIX_VERSION 198808L
6
   // chown()和 fchown()的使用受限于进程的权限。/* 只有超级用户可以执行 chown（我想..）*/
7  #define _POSIX_CHOWN_RESTRICTED /* only root can do a chown (I think..) */
   // 长于(NAME_MAX)的路径名将产生错误，而不会自动截断。/* 路径名不截断（但是请看内核代码）*/
8  #define _POSIX_NO_TRUNC         /* no pathname truncation (but see in kernel) */
   // 下面这个符号将定义成字符值，该值将禁止终端对其的处理。/* 禁止象^C 这样的字符 */
9  #define _POSIX_VDISABLE '\0'    /* character to disable things like ^C */
   // 每个进程都有一保存的 set-user-ID 和一保存的 set-group-ID。 /* 我们将着手对此进行处理 */
10 /*#define _POSIX_SAVED_IDS */   /* we'll get to this yet */
   // 系统实现支持作业控制。          /* 我们还没有支持这项标准，希望很快就行 */
11 /*#define _POSIX_JOB_CONTROL */ /* we aren't there quite yet. Soon hopefully */
12
13 #define STDIN_FILENO    0           // 标准输入文件句柄（描述符）号。
14 #define STDOUT_FILENO   1           // 标准输出文件句柄号。
15 #define STDERR_FILENO   2           // 标准出错文件句柄号。
16
17 #ifndef NULL
18 #define NULL    ((void *)0)         // 定义空指针。
19 #endif
20
21 /* access */   /* 文件访问 */
   // 以下定义的符号常数用于 access()函数。
22 #define F_OK    0                   // 检测文件是否存在。
23 #define X_OK    1                   // 检测是否可执行（搜索）。
24 #define W_OK    2                   // 检测是否可写。
25 #define R_OK    4                   // 检测是否可读。
26
27 /* lseek */   /* 文件指针重定位 */
   // 以下符号常数用于 lseek()和 fcntl()函数。
28 #define SEEK_SET        0           // 将文件读写指针设置为偏移值。
29 #define SEEK_CUR        1           // 将文件读写指针设置为当前值加上偏移值。
30 #define SEEK_END        2           // 将文件读写指针设置为文件长度加上偏移值。
31
32 /* _SC stands for System Configuration. We don't use them much */
```

```
    /* _SC 表示系统配置。我们很少使用 */
    // 下面的符号常数用于 sysconf()函数。
 33 #define _SC_ARG_MAX             1    // 最大变量数。
 34 #define _SC_CHILD_MAX           2    // 子进程最大数。
 35 #define _SC_CLOCKS_PER_SEC      3    // 每秒滴答数。
 36 #define _SC_NGROUPS_MAX         4    // 最大组数。
 37 #define _SC_OPEN_MAX            5    // 最大打开文件数。
 38 #define _SC_JOB_CONTROL         6    // 作业控制。
 39 #define _SC_SAVED_IDS           7    // 保存的标识符。
 40 #define _SC_VERSION             8    // 版本。
 41
 42 /* more (possibly) configurable things - now pathnames */
    /* 更多的（可能的）可配置参数 - 现在用于路径名 */
    // 下面的符号常数用于 pathconf()函数。
 43 #define _PC_LINK_MAX            1    // 连接最大数。
 44 #define _PC_MAX_CANON           2    // 最大常规文件数。
 45 #define _PC_MAX_INPUT           3    // 最大输入长度。
 46 #define _PC_NAME_MAX            4    // 名称最大长度。
 47 #define _PC_PATH_MAX            5    // 路径最大长度。
 48 #define _PC_PIPE_BUF            6    // 管道缓冲大小。
 49 #define _PC_NO_TRUNC            7    // 文件名不截断。
 50 #define _PC_VDISABLE            8    //
 51 #define _PC_CHOWN_RESTRICTED    9    // 改变宿主受限。
 52
 53 #include <sys/stat.h>     // 文件状态头文件。含有文件或文件系统状态结构 stat{}和常量。
 54 #include <sys/times.h>    // 定义了进程中运行时间结构 tms 以及 times()函数原型。
 55 #include <sys/utsname.h>  // 系统名称结构头文件。
 56 #include <utime.h>        // 用户时间头文件。定义了访问和修改时间结构以及 utime()原型。
 57
 58 #ifdef __LIBRARY__
 59
    // 以下是内核实现的系统调用符号常数，用作系统调用函数表中的索引值。(参见
include/linux/sys.h )
 60 #define __NR_setup      0       /* used only by init, to get system going */
                                    /* __NR_setup 仅用于初始化，以启动系统 */
 61 #define __NR_exit       1
 62 #define __NR_fork       2
 63 #define __NR_read       3
 64 #define __NR_write      4
 65 #define __NR_open       5
 66 #define __NR_close      6
 67 #define __NR_waitpid    7
 68 #define __NR_creat      8
 69 #define __NR_link       9
 70 #define __NR_unlink     10
 71 #define __NR_execve     11
 72 #define __NR_chdir      12
 73 #define __NR_time       13
 74 #define __NR_mknod      14
 75 #define __NR_chmod      15
 76 #define __NR_chown      16
 77 #define __NR_break      17
 78 #define __NR_stat       18
```

```
 79 #define __NR_lseek      19
 80 #define __NR_getpid     20
 81 #define __NR_mount      21
 82 #define __NR_umount     22
 83 #define __NR_setuid     23
 84 #define __NR_getuid     24
 85 #define __NR_stime      25
 86 #define __NR_ptrace     26
 87 #define __NR_alarm      27
 88 #define __NR_fstat      28
 89 #define __NR_pause      29
 90 #define __NR_utime      30
 91 #define __NR_stty       31
 92 #define __NR_gtty       32
 93 #define __NR_access     33
 94 #define __NR_nice       34
 95 #define __NR_ftime      35
 96 #define __NR_sync       36
 97 #define __NR_kill       37
 98 #define __NR_rename     38
 99 #define __NR_mkdir      39
100 #define __NR_rmdir      40
101 #define __NR_dup        41
102 #define __NR_pipe       42
103 #define __NR_times      43
104 #define __NR_prof       44
105 #define __NR_brk        45
106 #define __NR_setgid     46
107 #define __NR_getgid     47
108 #define __NR_signal     48
109 #define __NR_geteuid    49
110 #define __NR_getegid    50
111 #define __NR_acct       51
112 #define __NR_phys       52
113 #define __NR_lock       53
114 #define __NR_ioctl      54
115 #define __NR_fcntl      55
116 #define __NR_mpx        56
117 #define __NR_setpgid    57
118 #define __NR_ulimit     58
119 #define __NR_uname      59
120 #define __NR_umask      60
121 #define __NR_chroot     61
122 #define __NR_ustat      62
123 #define __NR_dup2       63
124 #define __NR_getppid    64
125 #define __NR_getpgrp    65
126 #define __NR_setsid     66
127 #define __NR_sigaction  67
128 #define __NR_sgetmask   68
129 #define __NR_ssetmask   69
130 #define __NR_setreuid   70
131 #define __NR_setregid   71
```

```
132
    // 以下定义系统调用嵌入式汇编宏函数。
    // 不带参数的系统调用宏函数。type name(void)。
    // %0 - eax(__res), %1 - eax(__NR_##name)。其中 name 是系统调用的名称，与 __NR_ 组合形成上面
    // 的系统调用符号常数，从而用来对系统调用表中函数指针寻址。
    // 返回：如果返回值大于等于 0，则返回该值，否则置出错号 errno，并返回-1。
133 #define _syscall0(type,name) \
134 type name(void) \
135 { \
136 long __res; \
137 __asm__ volatile ("int $0x80" \          // 调用系统中断 0x80。
138         : "=a" (__res) \                 // 返回值➔eax(__res)。
139         : "" (__NR_##name)); \           // 输入为系统中断调用号__NR_name。
140 if (__res >= 0) \                        // 如果返回值>=0，则直接返回该值。
141         return (type) __res; \
142 errno = -__res; \                        // 否则置出错号，并返回-1。
143 return -1; \
144 }
145
    // 有 1 个参数的系统调用宏函数。type name(atype a)
    // %0 - eax(__res), %1 - eax(__NR_name), %2 - ebx(a)。
146 #define _syscall1(type,name,atype,a) \
147 type name(atype a) \
148 { \
149 long __res; \
150 __asm__ volatile ("int $0x80" \
151         : "=a" (__res) \
152         : "" (__NR_##name),"b" ((long)(a))); \
153 if (__res >= 0) \
154         return (type) __res; \
155 errno = -__res; \
156 return -1; \
157 }
158
    // 有 2 个参数的系统调用宏函数。type name(atype a, btype b)
    // %0 - eax(__res), %1 - eax(__NR_name), %2 - ebx(a), %3 - ecx(b)。
159 #define _syscall2(type,name,atype,a,btype,b) \
160 type name(atype a,btype b) \
161 { \
162 long __res; \
163 __asm__ volatile ("int $0x80" \
164         : "=a" (__res) \
165         : "" (__NR_##name),"b" ((long)(a)),"c" ((long)(b))); \
166 if (__res >= 0) \
167         return (type) __res; \
168 errno = -__res; \
169 return -1; \
170 }
171
    // 有 3 个参数的系统调用宏函数。type name(atype a, btype b, ctype c)
    // %0 - eax(__res), %1 - eax(__NR_name), %2 - ebx(a), %3 - ecx(b), %4 - edx(c)。
172 #define _syscall3(type,name,atype,a,btype,b,ctype,c) \
173 type name(atype a,btype b,ctype c) \
```

```
174 { \
175 long __res; \
176 __asm__ volatile ("int $0x80" \
177         : "=a" (__res) \
178         : "" (__NR_##name),"b" ((long)(a)),"c" ((long)(b)),"d" ((long)(c))); \
179 if (__res>=0) \
180         return (type) __res; \
181 errno=-__res; \
182 return -1; \
183 }
184
185 #endif /* __LIBRARY__ */
186
187 extern int errno;                       // 出错号，全局变量。
188
    // 对应各系统调用的函数原型定义。(详细说明参见 include/linux/sys.h )
189 int access(const char * filename, mode_t mode);
190 int acct(const char * filename);
191 int alarm(int sec);
192 int brk(void * end_data_segment);
193 void * sbrk(ptrdiff_t increment);
194 int chdir(const char * filename);
195 int chmod(const char * filename, mode_t mode);
196 int chown(const char * filename, uid_t owner, gid_t group);
197 int chroot(const char * filename);
198 int close(int fildes);
199 int creat(const char * filename, mode_t mode);
200 int dup(int fildes);
201 int execve(const char * filename, char ** argv, char ** envp);
202 int execv(const char * pathname, char ** argv);
203 int execvp(const char * file, char ** argv);
204 int execl(const char * pathname, char * arg0, ...);
205 int execlp(const char * file, char * arg0, ...);
206 int execle(const char * pathname, char * arg0, ...);
207 volatile void exit(int status);
208 volatile void _exit(int status);
209 int fcntl(int fildes, int cmd, ...);
210 int fork(void);
211 int getpid(void);
212 int getuid(void);
213 int geteuid(void);
214 int getgid(void);
215 int getegid(void);
216 int ioctl(int fildes, int cmd, ...);
217 int kill(pid_t pid, int signal);
218 int link(const char * filename1, const char * filename2);
219 int lseek(int fildes, off_t offset, int origin);
220 int mknod(const char * filename, mode_t mode, dev_t dev);
221 int mount(const char * specialfile, const char * dir, int rwflag);
222 int nice(int val);
223 int open(const char * filename, int flag, ...);
224 int pause(void);
225 int pipe(int * fildes);
```

```
226 int read(int fildes, char * buf, off_t count);
227 int setpgrp(void);
228 int setpgid(pid_t pid,pid_t pgid);
229 int setuid(uid_t uid);
230 int setgid(gid_t gid);
231 void (*signal(int sig, void (*fn)(int)))(int);
232 int stat(const char * filename, struct stat * stat_buf);
233 int fstat(int fildes, struct stat * stat_buf);
234 int stime(time_t * tptr);
235 int sync(void);
236 time_t time(time_t * tloc);
237 time_t times(struct tms * tbuf);
238 int ulimit(int cmd, long limit);
239 mode_t umask(mode_t mask);
240 int umount(const char * specialfile);
241 int uname(struct utsname * name);
242 int unlink(const char * filename);
243 int ustat(dev_t dev, struct ustat * ubuf);
244 int utime(const char * filename, struct utimbuf * times);
245 pid_t waitpid(pid_t pid,int * wait_stat,int options);
246 pid_t wait(int * wait_stat);
247 int write(int fildes, const char * buf, off_t count);
248 int dup2(int oldfd, int newfd);
249 int getppid(void);
250 pid_t getpgrp(void);
251 pid_t setsid(void);
252
253 #endif
254
```

11.15 utime.h 文件

11.15.1 功能描述

该文件定义了文件访问和修改时间结构 utimbuf{}以及 utime()函数原型。时间以秒计。

11.15.2 代码注释

程序 11-13 linux/include/utime.h

```
 1 #ifndef _UTIME_H
 2 #define _UTIME_H
 3
 4 #include <sys/types.h>  /* I know - shouldn't do this, but .. */
 5                         /* 我知道 - 不应该这样做，但是.. */
 6 struct utimbuf {
 7         time_t actime;          // 文件访问时间。从 1970.1.1:0:0:0 开始的秒数。
 8         time_t modtime;         // 文件修改时间。从 1970.1.1:0:0:0 开始的秒数。
 9 };
```

```
10
   // 设置文件访问和修改时间函数。
11 extern int utime(const char *filename, struct utimbuf *times);
12
13 #endif
14
```

11.16 include/asm/目录下的文件

列表 11-2 linux/include/asm/目录下的文件

	名称	大小	最后修改时间(GMT)	说明
	io.h	477 bytes	1991-08-07 10:17:51	m
	memory.h	507 bytes	1991-06-15 20:54:44	m
	segment.h	1366 bytes	1991-11-25 18:48:24	m
	system.h	1711 bytes	1991-09-17 13:08:31	m

11.17 io.h 文件

11.17.1 功能描述

该文件中定义了对硬件 IO 端口访问的嵌入式汇编宏函数：outb()、inb()以及 outb_p()和 inb_p()。前面两个函数与后面两个的主要区别在于后者代码中使用了 jmp 指令进行了时间延迟。

11.17.2 代码注释

程序 11-14 linux/include/asm/io.h

```
   //// 硬件端口字节输出函数。
   // 参数：value - 欲输出字节；port - 端口。
 1 #define outb(value,port) \
 2 __asm__ ("outb %%al,%%dx"::"a" (value),"d" (port))
 3
 4
   //// 硬件端口字节输入函数。
   // 参数：port - 端口。返回读取的字节。
 5 #define inb(port) ({ \
 6 unsigned char _v; \
 7 __asm__ volatile ("inb %%dx,%%al":"=a" (_v):"d" (port)); \
 8 _v; \
 9 })
10
   //// 带延迟的硬件端口字节输出函数。
   // 参数：value - 欲输出字节；port - 端口。
11 #define outb_p(value,port) \
12 __asm__ ("outb %%al,%%dx\n" \
13                 "\tjmp 1f\n" \
14                 "1:\tjmp 1f\n" \
15                 "1:"::"a" (value),"d" (port))
16
   //// 带延迟的硬件端口字节输入函数。
```

```
   // 参数：port - 端口。返回读取的字节。
17 #define inb_p(port) ({ \
18 unsigned char _v; \
19 __asm__ volatile ("inb %%dx,%%al\n" \
20         "\tjmp 1f\n" \
21         "1:\tjmp 1f\n" \
22         "1:":"=a" (_v):"d" (port)); \
23 _v; \
24 })
25
```

11.18 memory.h 文件

11.18.1 功能描述

该文件含有一个内存复制嵌入式汇编宏 memcpy()。与 string.h 中定义的 memcpy()相同，只是后者采用的是嵌入式汇编 C 函数形式定义的。

11.18.2 代码注释

程序 11-15 linux/include/asm/memory.h

```
 1 /*
 2  * NOTE!!! memcpy(dest,src,n) assumes ds=es=normal data segment. This
 3  * goes for all kernel functions (ds=es=kernel space, fs=local data,
 4  * gs=null), as well as for all well-behaving user programs (ds=es=
 5  * user data space). This is NOT a bug, as any user program that changes
 6  * es deserves to die if it isn't careful.
 7  */
   /*
    * 注意!!!memcpy(dest,src,n)假设段寄存器 ds=es=通常数据段。在内核中使用的
    * 所有函数都基于该假设（ds=es=内核空间，fs=局部数据空间，gs=null），具有良好
    * 行为的应用程序也是这样（ds=es=用户数据空间）。如果任何用户程序随意改动了
    * es 寄存器而出错，则并不是由于系统程序错误造成的。
    */
   //// 内存块复制。从源地址 src 处开始复制 n 个字节到目的地址 dest 处。
   // 参数：dest - 复制的目的地址，src - 复制的源地址，n - 复制字节数。
   // %0 - edi(目的地址 dest)，%1 - esi(源地址 src)，%2 - ecx(字节数 n)，
 8 #define memcpy(dest,src,n) ({ \
 9 void * _res = dest; \
10 __asm__ ("cld;rep;movsb" \                  // 从 ds:[esi]复制到 es:[edi]，并且 esi++，edi++。
                                               // 共复制 ecx(n)字节。
11         ::"D" ((long)(_res)),"S" ((long)(src)),"c" ((long) (n)) \
12         :"di","si","cx"); \
13 _res; \
14 })
15
```

11.19 segment.h 文件

11.19.1 功能描述

该文件中定义了一些访问 Intel CPU 中段寄存器或与段寄存器有关的内存操作函数。在 Linux 系统中，当用户程序通过系统调用开始执行内核代码时，内核程序会首先在段寄存器 ds 和 es 中加载全局描述符表 GDT 中的内核数据段描述符(段值 0x10)，即把 ds 和 es 用于访问内核数据段；而在 fs 中加载了局部描述符表 LDT 中的任务的数据段描述符（段值 0x17），即把 fs 用于访问用户数据段。参见 system_call.s 第 89--93 行。因此在执行内核代码时，若要存取用户程序（任务）中的数据就需要使用特殊的方式。本文件中的 get_fs_byte()和 put_fs_byte()等函数就是专门用来访问用户程序中的数据。

11.19.2 代码注释

程序 11-16 linux/include/asm/segment.h

```
   //// 读取 fs 段中指定地址处的字节。
   // 参数：addr - 指定的内存地址。
   // %0 - (返回的字节_v)；%1 - (内存地址 addr)。
   // 返回：返回内存 fs:[addr]处的字节。
 1 extern inline unsigned char get_fs_byte(const char * addr)
 2 {
 3         unsigned register char _v;
 4
 5         __asm__ ("movb %%fs:%1,%0":"=r" (_v):"m" (*addr));
 6         return _v;
 7 }
 8
   //// 读取 fs 段中指定地址处的字。
   // 参数：addr - 指定的内存地址。
   // %0 - (返回的字_v)；%1 - (内存地址 addr)。
   // 返回：返回内存 fs:[addr]处的字。
 9 extern inline unsigned short get_fs_word(const unsigned short *addr)
10 {
11         unsigned short _v;
12
13         __asm__ ("movw %%fs:%1,%0":"=r" (_v):"m" (*addr));
14         return _v;
15 }
16
   //// 读取 fs 段中指定地址处的长字(4 字节)。
   // 参数：addr - 指定的内存地址。
   // %0 - (返回的长字_v)；%1 - (内存地址 addr)。
   // 返回：返回内存 fs:[addr]处的长字。
17 extern inline unsigned long get_fs_long(const unsigned long *addr)
18 {
19         unsigned long _v;
20
21         __asm__ ("movl %%fs:%1,%0":"=r" (_v):"m" (*addr)); \
22         return _v;
23 }
```

```
24
   //// 将一字节存放在 fs 段中指定内存地址处。
   // 参数：val - 字节值；addr - 内存地址。
   // %0 - 寄存器(字节值 val)；%1 - (内存地址 addr)。
25 extern inline void put_fs_byte(char val,char *addr)
26 {
27 __asm__ ("movb %0,%%fs:%1"::"r" (val),"m" (*addr));
28 }
29
   //// 将一字存放在 fs 段中指定内存地址处。
   // 参数：val - 字值；addr - 内存地址。
   // %0 - 寄存器(字值 val)；%1 - (内存地址 addr)。
30 extern inline void put_fs_word(short val,short * addr)
31 {
32 __asm__ ("movw %0,%%fs:%1"::"r" (val),"m" (*addr));
33 }
34
   //// 将一长字存放在 fs 段中指定内存地址处。
   // 参数：val - 长字值；addr - 内存地址。
   // %0 - 寄存器(长字值 val)；%1 - (内存地址 addr)。
35 extern inline void put_fs_long(unsigned long val,unsigned long * addr)
36 {
37 __asm__ ("movl %0,%%fs:%1"::"r" (val),"m" (*addr));
38 }
39
40 /*
41  * Someone who knows GNU asm better than I should double check the followig.
42  * It seems to work, but I don't know if I'm doing something subtly wrong.
43  * --- TYT, 11/24/91
44  * [ nothing wrong here, Linus ]
45  */
   /*
    * 比我更懂 GNU 汇编的人应该仔细检查下面的代码。这些代码能使用，但我不知道是否
    * 含有一些小错误。
    * --- TYT，1991 年 11 月 24 日
    * [ 这些代码没有错误，Linus ]
    */
46
   //// 取 fs 段寄存器值(选择符)。
   // 返回：fs 段寄存器值。
47 extern inline unsigned long get_fs()
48 {
49         unsigned short _v;
50         __asm__("mov %%fs,%%ax":"=a" (_v):);
51         return _v;
52 }
53
   //// 取 ds 段寄存器值。
   // 返回：ds 段寄存器值。
54 extern inline unsigned long get_ds()
55 {
56         unsigned short _v;
57         __asm__("mov %%ds,%%ax":"=a" (_v):);
```

```
58          return _v;
59  }
60
    //// 设置 fs 段寄存器。
    // 参数：val - 段值（选择符）。
61  extern inline void set_fs(unsigned long val)
62  {
63          __asm__("mov %0,%%fs"::"a" ((unsigned short) val));
64  }
65
66
```

11.20 system.h 文件

11.20.1 功能描述

该文件中定义了设置或修改描述符/中断门等的嵌入式汇编宏。其中，函数 move_to_user_mode()是用于内核在初始化结束时人工切换（移动）到初始进程（任务 0）去执行。所使用的方法是模拟中断调用返回过程，即利用 iret 指令来实现特权级的变更和堆栈的切换，从而把 CPU 执行控制流移动到初始任务 0 的环境中运行。见图 11-2 所示。

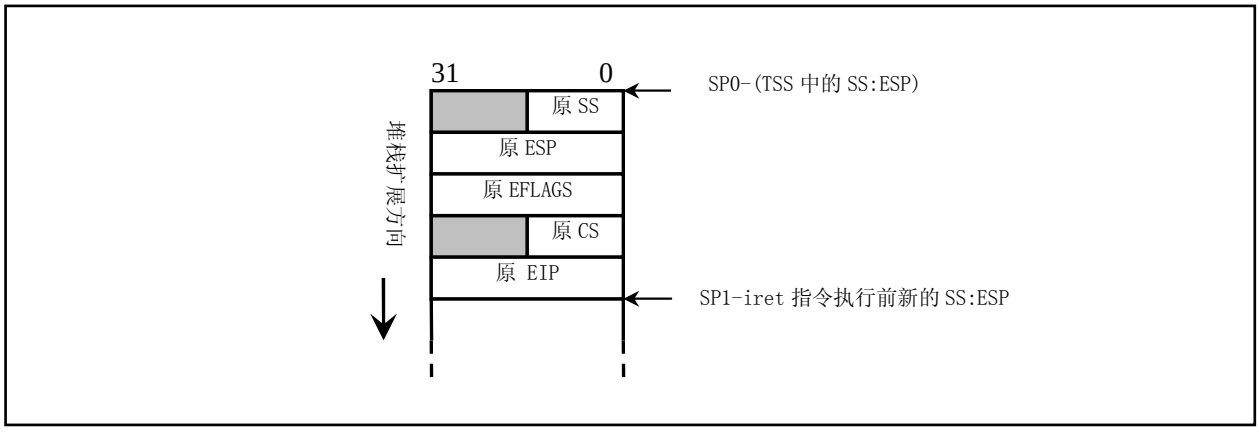

图 11-2 中断调用层间切换时堆栈内容

在去执行任务 0 代码之前，首先设置堆栈，模拟具有特权层切换的刚进入中断调用过程时堆栈的内容布置情况。然后执行 iret 指令，从而引起系统移到任务 0 中去执行。在执行 iret 语句时，堆栈内容如图 11.2 中所示，此时 esp 为 esp1。任务 0 的堆栈就是内核的堆栈。当执行了 iret 之后，就移到了任务 0 中执行了。由于任务 0 描述符特权级是 3，所以堆栈上的 ss:esp 也会被弹出。因此在 iret 之后，esp 又等于 esp0 了。注意，这里的中断返回指令 iret 并不会造成 CPU 去执行任务切换操作，因为在执行这个函数之前，标志位 NT 已经在 sched_init()中被复位。在 NT 复位时执行 iret 指令不会造成 CPU 执行任务切换操作。任务 0 的执行纯粹是人工启动的。

任务 0 是一个特殊进程，它的数据段和代码段直接映射到内核代码和数据空间，即从物理地址 0 开始的 640K 内存空间，其堆栈地址即是内核代码所使用的堆栈。因此图中堆栈中的原 SS 和原 ESP 是将现有内核堆栈指针直接压入堆栈的。

该文件中的另一部份给出了在中断描述符表 IDT 中设置不同类型描述符项的宏。_set_gate()是设置

中断门描述符的宏 set_intr_gate()、set_system_gate()和设置陷阱门描述符的宏 set_trap_gate()所调用的通用宏。IDT 表中的中断门（Interrupt Gate）和陷阱门（Trap Gate）描述符项的格式见图 11-3 所示。

中断门描述符

31	23	15						7			0	
偏移值(OFFSET) 位 31..16		P	DPL	0	1	1	1	0	0	0	（未使用）	4
段选择符（SELECTOR）		偏移值（OFFSET）位 15..0										0

陷阱门描述符

31	23	15						7			0	
偏移值(OFFSET) 位 31..16		P	DPL	0	1	1	1	1	0	0	（未使用）	4
段选择符（SELECTOR）		偏移值（OFFSET）位 15..0										0

图 11-3 中断描述符表 IDT 中的中断门和陷阱门描述符格式

其中，P 是段存在标志；DPL 是描述符的优先级。中断门与陷阱门的区别在于对 EFLAGS 的中断允许标志 IF 的影响。由中断门描述符执行的中断会复位 IF 标志，因此可以避免其它中断干扰当前中断的处理。随后的中断结束指令 IRET 会从堆栈上恢复 IF 标志的原值；而通过陷阱门执行的中断则不会影响 IF 标志。

在设置描述符的通用宏_set_gate(gate_addr,type,dpl,addr)中，参数 gate_addr 指定了描述符所处的物理内存地址。type 指明所需设置的描述符类型，它对应图 11-3 中描述符格式中第 6 字节的低 4 比特位，因此 type=14（0x0E）指明是中断门描述符，type=15（0x0F）指明是陷阱门描述符。参数 dpl 即对应描述符格式中的 DPL。addr 是描述符对应的中断处理过程的 32 位偏移地址。因为中断处理过程属于内核段代码，所以它们的段选择符值均为 0x0008（在 eax 寄存器高字中指定）。

system.h 文件的最后一部份是用于设置一般段描述符内容和在全局描述符表 GDT 中设置任务状态段描述符以及局部表段描述符的宏。这几个宏的参数含义与上述类似。

11.20.2 代码注释

程序 11-17 linux/include/asm/system.h

```
    //// 移动到用户模式运行。
    // 该函数利用 iret 指令实现从内核模式移动到初始任务 0 中去执行。
 1  #define move_to_user_mode() \
 2  __asm__ ("movl %%esp,%%eax\n\t" \          // 保存堆栈指针 esp 到 eax 寄存器中。
 3          "pushl $0x17\n\t" \                // 首先将堆栈段选择符(SS)入栈。
 4          "pushl %%eax\n\t" \                // 然后将保存的堆栈指针值(esp)入栈。
 5          "pushfl\n\t" \                     // 将标志寄存器(eflags)内容入栈。
 6          "pushl $0x0f\n\t" \                // 将 Task0 代码段选择符(cs)入栈。
 7          "pushl $1f\n\t" \                  // 将下面标号 1 的偏移地址(eip)入栈。
 8          "iret\n" \                         // 执行中断返回指令，则会跳转到下面标号 1 处。
 9          "1:\tmovl $0x17,%%eax\n\t" \       // 此时开始执行任务 0，
10          "movw %%ax,%%ds\n\t" \             // 初始化段寄存器指向本局部表的数据段。
11          "movw %%ax,%%es\n\t" \
12          "movw %%ax,%%fs\n\t" \
13          "movw %%ax,%%gs" \
14          :::"ax")
```

```
15
16 #define sti() __asm__ ("sti"::)          // 开中断嵌入汇编宏函数。
17 #define cli() __asm__ ("cli"::)          // 关中断。
18 #define nop() __asm__ ("nop"::)          // 空操作。
19
20 #define iret() __asm__ ("iret"::)        // 中断返回。
21
//// 设置门描述符宏函数。
// 参数：gate_addr -描述符地址；type -描述符中类型域值；dpl -描述符特权层值；addr -偏移地址。
// %0 - (由 dpl,type 组合成的类型标志字)；%1 - (描述符低 4 字节地址)；
// %2 - (描述符高 4 字节地址)；%3 - edx(程序偏移地址 addr)；%4 - eax(高字中含有段选择符)。
22 #define _set_gate(gate_addr,type,dpl,addr) \
23 __asm__ ("movw %%dx,%%ax\n\t" \          // 将偏移地址低字与选择符组合成描述符低 4 字节(eax)。
24         "movw %0,%%dx\n\t" \             // 将类型标志字与偏移高字组合成描述符高 4 字节(edx)。
25         "movl %%eax,%1\n\t" \            // 分别设置门描述符的低 4 字节和高 4 字节。
26         "movl %%edx,%2" \
27         : \
28         : "i" ((short) (0x8000+(dpl<<13)+(type<<8))), \
29         "o" (*((char *) (gate_addr))), \
30         "o" (*(4+(char *) (gate_addr))), \
31         "d" ((char *) (addr)),"a" (0x00080000))
32
//// 设置中断门函数。
// 参数：n - 中断号；addr - 中断程序偏移地址。
// &idt[n]对应中断号在中断描述符表中的偏移值；中断描述符的类型是 14，特权级是 0。
33 #define set_intr_gate(n,addr) \
34         _set_gate(&idt[n],14,0,addr)
35
//// 设置陷阱门函数。
// 参数：n - 中断号；addr - 中断程序偏移地址。
// &idt[n]对应中断号在中断描述符表中的偏移值；中断描述符的类型是 15，特权级是 0。
36 #define set_trap_gate(n,addr) \
37         _set_gate(&idt[n],15,0,addr)
38
//// 设置系统陷阱门函数。
// 上面 set_trap_gate()设置的描述符的特权级为 0，而这里是 3。因此 set_system_gate()设置的
// 中断处理过程能够被所有程序执行。例如单步调试、溢出出错和边界超出出错处理。
// 参数：n - 中断号；addr - 中断程序偏移地址。
// &idt[n]对应中断号在中断描述符表中的偏移值；中断描述符的类型是 15，特权级是 3。
39 #define set_system_gate(n,addr) \
40         _set_gate(&idt[n],15,3,addr)
41
//// 设置段描述符函数（内核中没有用到）。
// 参数：gate_addr -描述符地址；type -描述符中类型域值；dpl -描述符特权层值；
// base - 段的基地址；limit - 段限长。（参见段描述符的格式）
42 #define _set_seg_desc(gate_addr,type,dpl,base,limit) {\
43         *(gate_addr) = ((base) & 0xff000000) | \              // 描述符低 4 字节。
44                 (((base) & 0x00ff0000)>>16) | \
45                 ((limit) & 0xf0000) | \
46                 ((dpl)<<13) | \
47                 (0x00408000) | \
48                 ((type)<<8); \
49         *((gate_addr)+1) = (((base) & 0x0000ffff)<<16) | \    // 描述符高 4 字节。
```

```
50                  ((limit) & 0x0ffff); }
51
    //// 在全局表中设置任务状态段/局部表描述符。状态段和局部表段的长度均被设置成 104 字节。
    // 参数：n - 在全局表中描述符项 n 所对应的地址；addr - 状态段/局部表所在内存的基地址。
    //       type - 描述符中的标志类型字节。
    // %0 - eax(地址 addr)；%1 - (描述符项 n 的地址)；%2 - (描述符项 n 的地址偏移 2 处)；
    // %3 - (描述符项 n 的地址偏移 4 处)；%4 - (描述符项 n 的地址偏移 5 处)；
    // %5 - (描述符项 n 的地址偏移 6 处)；%6 - (描述符项 n 的地址偏移 7 处)；
52  #define _set_tssldt_desc(n,addr,type) \
53  __asm__ ("movw $104,%1\n\t" \                   // 将 TSS（或 LDT）长度放入描述符长度域(第 0-1 字节)。
54          "movw %%ax,%2\n\t" \                    // 将基地址的低字放入描述符第 2-3 字节。
55          "rorl $16,%%eax\n\t" \                  // 将基地址高字右循环移入 ax 中（低字则进入高字处）。
56          "movb %%al,%3\n\t" \                    // 将基地址高字中低字节移入描述符第 4 字节。
57          "movb $" type ",%4\n\t" \               // 将标志类型字节移入描述符的第 5 字节。
58          "movb $0x00,%5\n\t" \                   // 描述符的第 6 字节置 0。
59          "movb %%ah,%6\n\t" \                    // 将基地址高字中高字节移入描述符第 7 字节。
60          "rorl $16,%%eax" \                      // 再右循环 16 比特，eax 恢复原值。
61          ::"a" (addr), "m" (*(n)), "m" (*(n+2)), "m" (*(n+4)), \
62           "m" (*(n+5)), "m" (*(n+6)), "m" (*(n+7)) \
63          )
64
    //// 在全局表中设置任务状态段描述符。
    // n - 是该描述符的指针；addr - 是描述符项中段的基地址值。任务状态段描述符的类型是 0x89。
65  #define set_tss_desc(n,addr) _set_tssldt_desc(((char *) (n)),addr,"0x89")
    //// 在全局表中设置局部表描述符。
    // n - 是该描述符的指针；addr - 是描述符项中段的基地址值。局部表段描述符的类型是 0x82。
66  #define set_ldt_desc(n,addr) _set_tssldt_desc(((char *) (n)),addr,"0x82")
67
```

11.21 include/linux/目录下的文件

列表 11-3 linux/include/linux/目录下的文件

	名称	大小	最后修改时间(GMT)	说明
	config.h	1289 bytes	1991-12-08 18:37:16	m
	fdreg.h	2466 bytes	1991-11-02 10:48:44	m
	fs.h	5474 bytes	1991-12-01 19:48:26	m
	hdreg.h	1968 bytes	1991-10-13 15:32:15	m
	head.h	304 bytes	1991-06-19 19:24:13	m
	kernel.h	734 bytes	1991-12-02 03:19:07	m
	mm.h	219 bytes	1991-07-29 17:51:12	m
	sched.h	5838 bytes	1991-11-20 14:40:46	m
	sys.h	2588 bytes	1991-11-25 20:15:35	m
	tty.h	2173 bytes	1991-09-21 11:58:05	m

11.22 config.h 文件

11.22.1 功能描述

内核配置头文件。定义使用的键盘语言类型和硬盘类型（HD_TYPE）可选项。

11.22.2 代码注释

程序 11-18 linux/include/linux/config.h

```
1  #ifndef _CONFIG_H
2  #define _CONFIG_H
3
4  /*
5   * The root-device is no longer hard-coded. You can change the default
6   * root-device by changing the line ROOT_DEV = XXX in boot/bootsect.s
7   */
   /*
    * 根文件系统设备已不再是硬编码的了。通过修改 boot/bootsect.s 文件中行
    * ROOT_DEV = XXX，你可以改变根设备的默认设置值。
    */
8
9  /*
10  * define your keyboard here -
11  * KBD_FINNISH for Finnish keyboards
```

```
12  * KBD_US for US-type
13  * KBD_GR for German keyboards
14  * KBD_FR for Frech keyboard
15  */
    /*
     * 在这里定义你的键盘类型 -
     * KBD_FINNISH 是芬兰键盘。
     * KBD_US 是美式键盘。
     * KBD_GR 是德式键盘。
     * KBD_FR 是法式键盘。
     */
16 /*#define KBD_US */
17 /*#define KBD_GR */
18 /*#define KBD_FR */
19 #define KBD_FINNISH
20
21 /*
22  * Normally, Linux can get the drive parameters from the BIOS at
23  * startup, but if this for some unfathomable reason fails, you'd
24  * be left stranded. For this case, you can define HD_TYPE, which
25  * contains all necessary info on your harddisk.
26  *
27  * The HD_TYPE macro should look like this:
28  *
29  * #define HD_TYPE { head, sect, cyl, wpcom, lzone, ctl}
30  *
31  * In case of two harddisks, the info should be sepatated by
32  * commas:
33  *
34  * #define HD_TYPE { h,s,c,wpcom,lz,ctl },{ h,s,c,wpcom,lz,ctl }
35  */
    /*
     * 通常，Linux 能够在启动时从 BIOS 中获取驱动器德参数，但是若由于未知原因
     * 而没有得到这些参数时，会使程序束手无策。对于这种情况，你可以定义 HD_TYPE，
     * 其中包括硬盘的所有信息。
     *
     * HD_TYPE 宏应该象下面这样的形式：
     *
     * #define HD_TYPE { head, sect, cyl, wpcom, lzone, ctl}
     *
     * 对于有两个硬盘的情况，参数信息需用逗号分开：
     *
     * #define HD_TYPE { h,s,c,wpcom,lz,ctl }, {h,s,c,wpcom,lz,ctl }
     */
36 /*
37  This is an example, two drives, first is type 2, second is type 3:
38
39 #define HD_TYPE { 4,17,615,300,615,8 }, { 6,17,615,300,615,0 }
40
41  NOTE: ctl is 0 for all drives with heads<=8, and ctl=8 for drives
42  with more than 8 heads.
43
44  If you want the BIOS to tell what kind of drive you have, just
```

```
45  leave HD_TYPE undefined. This is the normal thing to do.
46 */
   /*
    * 下面是一个例子，两个硬盘，第 1 个是类型 2，第 2 个是类型 3：
    *
    * #define HD_TYPE { 4,17,615,300,615,8 }, {6,17,615,300,615,0 }
    *
    * 注意：对应所有硬盘，若其磁头数<=8，则 ctl 等于 0，若磁头数多于 8 个，
    * 则 ctl=8。
    *
    * 如果你想让 BIOS 给出硬盘的类型，那么只需不定义 HD_TYPE。这是默认操作。
    */
47
48 #endif
49
```

11.23 fdreg.h 头文件

11.23.1 功能描述

该头文件用以说明软盘系统常用到的一些参数以及所使用的 I/O 端口。由于软盘驱动器的控制比较烦琐，命令也多，因此在阅读代码之前，最好先参考有关微型计算机控制接口原理的书籍，了解软盘控制器(FDC)的工作原理，然后你就会觉得这里的定义还是比较合理有序的。

在编程时需要访问 4 个端口，分别对应一个或多个寄存器。对于 1.2M 的软盘控制器有表 11–1 中一些端口。

表 11－1 软盘控制器端口

I/O 端口	读写性	寄存器名称
0x3f2	只写	数字输出寄存器(数字控制寄存器)
0x3f4	只读	FDC 主状态寄存器
0x3f5	读/写	FDC 数据寄存器
0x3f7	只读	数字输入寄存器
0x3f7	只写	磁盘控制寄存器(传输率控制)

数字输出端口（数字控制端口）是一个 8 位寄存器，它控制驱动器马达开启、驱动器选择、启动/复位 FDC 以及允许/禁止 DMA 及中断请求。

FDC 的主状态寄存器也是一个 8 位寄存器，用于反映软盘控制器 FDC 和软盘驱动器 FDD 的基本状态。通常，在 CPU 向 FDC 发送命令之前或从 FDC 获取操作结果之前，都要读取主状态寄存器的状态位，以判别当前 FDC 数据寄存器是否就绪，以及确定数据传送的方向。

FDC 的数据端口对应多个寄存器（只写型命令寄存器和参数寄存器、只读型结果寄存器），但任一时刻只能有一个寄存器出现在数据端口 0x3f5。在访问只写型寄存器时，主状态控制的 DIO 方向位必须为 0（CPU → FDC），访问只读型寄存器时则反之。在读取结果时只有在 FDC 不忙之后才算读完结果，通常结果数据最多有 7 个字节。

软盘控制器共可以接受 15 条命令。每个命令均经历三个阶段：命令阶段、执行阶段和结果阶段。

命令阶段是 CPU 向 FDC 发送命令字节和参数字节。每条命令的第一个字节总是命令字节(命令码)。其后跟着 0--8 字节的参数。执行阶段是 FDC 执行命令规定的操作。在执行阶段 CPU 是不加干预的，一般是通过 FDC 发出中断请求获知命令执行的结束。如果 CPU 发出的 FDC 命令是传送数据，则 FDC 可以以中断方式或 DMA 方式进行。中断方式每次传送 1 字节。DMA 方式是在 DMA 控制器管理下，FDC 与内存进行数据的传输直至全部数据传送完。此时 DMA 控制器会将传输字节计数终止信号通知 FDC，最后由 FDC 发出中断请求信号告知 CPU 执行阶段结束。结果阶段是由 CPU 读取 FDC 数据寄存器返回值，从而获得 FDC 命令执行的结果。返回结果数据的长度为 0--7 字节。对于没有返回结果数据的命令，则应向 FDC 发送检测中断状态命令获得操作的状态。

11.23.2 文件注释

程序 11-19 linux/include/linux/fdreg.h

```
1  /*
2   * This file contains some defines for the floppy disk controller.
3   * Various sources. Mostly "IBM Microcomputers: A Programmers
4   * Handbook", Sanches and Canton.
5   */
    /*
     * 该文件中含有一些软盘控制器的一些定义。这些信息有多处来源，大多数取自 Sanches 和 Canton
     * 编著的"IBM 微型计算机：程序员手册"一书。
     */
6  #ifndef _FDREG_H    // 该定义用来排除代码中重复包含此头文件。
7  #define _FDREG_H
8
    // 一些软盘类型函数的原型说明。
9  extern int ticks_to_floppy_on(unsigned int nr);
10 extern void floppy_on(unsigned int nr);
11 extern void floppy_off(unsigned int nr);
12 extern void floppy_select(unsigned int nr);
13 extern void floppy_deselect(unsigned int nr);
14
    // 下面是有关软盘控制器一些端口和符号的定义。
15 /* Fd controller regs. S&C, about page 340 */
    /* 软盘控制器(FDC)寄存器端口。摘自 S&C 书中约 340 页 */
16 #define FD_STATUS       0x3f4           // 主状态寄存器端口。
17 #define FD_DATA         0x3f5           // 数据端口。
18 #define FD_DOR          0x3f2           /* Digital Output Register */
                                           // 数字输出寄存器（也称为数字控制寄存器）。
19 #define FD_DIR          0x3f7           /* Digital Input Register (read) */
                                           // 数字输入寄存器。
20 #define FD_DCR          0x3f7           /* Diskette Control Register (write)*/
                                           // 数据传输率控制寄存器。
21
22 /* Bits of main status register */
    /* 主状态寄存器各比特位的含义 */
23 #define STATUS_BUSYMASK 0x0F            /* drive busy mask */
                                           // 驱动器忙位（每位对应一个驱动器）。
24 #define STATUS_BUSY     0x10            /* FDC busy */
                                           // 软盘控制器忙。
```

```
25 #define STATUS_DMA      0x20            /* 0- DMA mode */
                                           // 0 - 为 DMA 数据传输模式，1 - 为非 DMA 模式。
26 #define STATUS_DIR      0x40            /* 0- cpu->fdc */
                                           // 传输方向：0 - CPU → fdc，1 - 相反。
27 #define STATUS_READY    0x80            /* Data reg ready */
                                           // 数据寄存器就绪位。
28
29 /* Bits of FD_ST0 */
   /*状态字节 0（ST0）各比特位的含义 */
30 #define ST0_DS          0x03            /* drive select mask */
                                           // 驱动器选择号（发生中断时驱动器号）。
31 #define ST0_HA          0x04            /* Head (Address) */
                                           // 磁头号。
32 #define ST0_NR          0x08            /* Not Ready */
                                           // 磁盘驱动器未准备好。
33 #define ST0_ECE         0x10            /* Equipment chech error */
                                           // 设备检测出错（零磁道校准出错）。
34 #define ST0_SE          0x20            /* Seek end */
                                           // 寻道或重新校正操作执行结束。
35 #define ST0_INTR        0xC0            /* Interrupt code mask */
                                           // 中断代码位（中断原因），00 - 命令正常结束；
                                   // 01 - 命令异常结束；10 - 命令无效；11 - FDD 就绪状态改变。
36
37 /* Bits of FD_ST1 */
   /*状态字节 1（ST1）各比特位的含义 */
38 #define ST1_MAM         0x01            /* Missing Address Mark */
                                           // 未找到地址标志(ID AM)。
39 #define ST1_WP          0x02            /* Write Protect */
                                           // 写保护。
40 #define ST1_ND          0x04            /* No Data - unreadable */
                                           // 未找到指定的扇区。
41 #define ST1_OR          0x10            /* OverRun */
                                           // 数据传输超时（DMA 控制器故障）。
42 #define ST1_CRC         0x20            /* CRC error in data or addr */
                                           // CRC 检验出错。
43 #define ST1_EOC         0x80            /* End Of Cylinder */
                                           // 访问超过一个磁道上的最大扇区号。
44
45 /* Bits of FD_ST2 */
   /*状态字节 2（ST2）各比特位的含义 */
46 #define ST2_MAM         0x01            /* Missing Addess Mark (again) */
                                           // 未找到数据地址标志。
47 #define ST2_BC          0x02            /* Bad Cylinder */
                                           // 磁道坏。
48 #define ST2_SNS         0x04            /* Scan Not Satisfied */
                                           // 检索（扫描）条件不满足。
49 #define ST2_SEH         0x08            /* Scan Equal Hit */
                                           // 检索条件满足。
50 #define ST2_WC          0x10            /* Wrong Cylinder */
                                           // 磁道（柱面）号不符。
51 #define ST2_CRC         0x20            /* CRC error in data field */
                                           // 数据场 CRC 校验错。
52 #define ST2_CM          0x40            /* Control Mark = deleted */
```

```
                                        // 读数据遇到删除标志。
53
54 /* Bits of FD_ST3 */
   /*状态字节 3（ST3）各比特位的含义 */
55 #define ST3_HA          0x04        /* Head (Address) */
                                        // 磁头号。
56 #define ST3_TZ          0x10        /* Track Zero signal (1=track 0) */
                                        // 零磁道信号。
57 #define ST3_WP          0x40        /* Write Protect */
                                        // 写保护。
58
59 /* Values for FD_COMMAND */
   /* 软盘命令码 */
60 #define FD_RECALIBRATE  0x07        /* move to track 0 */
                                        // 重新校正(磁头退到零磁道)。
61 #define FD_SEEK         0x0F        /* seek track */
                                        // 磁头寻道。
62 #define FD_READ         0xE6        /* read with MT, MFM, SKip deleted */
                                        // 读数据（MT 多磁道操作，MFM 格式，跳过删除数据）。
63 #define FD_WRITE        0xC5        /* write with MT, MFM */
                                        // 写数据（MT，MFM）。
64 #define FD_SENSEI       0x08        /* Sense Interrupt Status */
                                        // 检测中断状态。
65 #define FD_SPECIFY      0x03        /* specify HUT etc */
                                        // 设定驱动器参数（步进速率、磁头卸载时间等）。
66
67 /* DMA commands */
   /* DMA 命令 */
68 #define DMA_READ        0x46        // DMA 读盘，DMA 方式字（送 DMA 端口 12，11）。
69 #define DMA_WRITE       0x4A        // DMA 写盘，DMA 方式字。
70
71 #endif
72
```

11.24 fs.h 文件

11.24.1 功能描述

fs.h 头文件中定义了有关文件系统的一些常数和结构。主要包含高速缓冲区中缓冲块的数据结构、MINIX 1.0 文件系统中超级块和 i 节点结构以及文件表结构和一些管道操作宏。

11.24.2 代码注释

程序 11-20 linux/include/linux/fs.h

```
1 /*
2  * This file has definitions for some important file table
3  * structures etc.
4  */
  /*
```

```
 * 本文件含有某些重要文件表结构的定义等。
 */

#ifndef _FS_H
#define _FS_H

#include <sys/types.h>    // 类型头文件。定义了基本的系统数据类型。

/* devices are as follows: (same as minix, so we can use the minix
 * file system. These are major numbers.)
 *
 * 0 - unused (nodev)
 * 1 - /dev/mem
 * 2 - /dev/fd
 * 3 - /dev/hd
 * 4 - /dev/ttyx
 * 5 - /dev/tty
 * 6 - /dev/lp
 * 7 - unnamed pipes
 */
/*
 * 系统所含的设备如下：（与 minix 系统的一样，所以我们可以使用 minix 的
 * 文件系统。以下这些是主设备号。）
 *
 * 0 - 没有用到（nodev）
 * 1 - /dev/mem         内存设备。
 * 2 - /dev/fd          软盘设备。
 * 3 - /dev/hd          硬盘设备。
 * 4 - /dev/ttyx        tty 串行终端设备。
 * 5 - /dev/tty         tty 终端设备。
 * 6 - /dev/lp          打印设备。
 * 7 - unnamed pipes    没有命名的管道。
 */

#define IS_SEEKABLE(x) ((x)>=1 && (x)<=3)      // 是否是可以寻找定位的设备。

#define READ 0
#define WRITE 1
#define READA 2         /* read-ahead - don't pause */
#define WRITEA 3        /* "write-ahead" - silly, but somewhat useful */

void buffer_init(long buffer_end);

#define MAJOR(a) (((unsigned)(a))>>8)           // 取高字节（主设备号）。
#define MINOR(a) ((a)&0xff)                     // 取低字节（次设备号）。

#define NAME_LEN 14                             // 名字长度值。
#define ROOT_INO 1                              // 根 i 节点。

#define I_MAP_SLOTS 8                           // i 节点位图槽数。
#define Z_MAP_SLOTS 8                           // 逻辑块（区段块）位图槽数。
#define SUPER_MAGIC 0x137F                      // 文件系统魔数。

```

```
43 #define NR_OPEN 20                              // 打开文件数。
44 #define NR_INODE 32
45 #define NR_FILE 64
46 #define NR_SUPER 8
47 #define NR_HASH 307
48 #define NR_BUFFERS nr_buffers
49 #define BLOCK_SIZE 1024                         // 数据块长度。
50 #define BLOCK_SIZE_BITS 10                      // 数据块长度所占比特位数。
51 #ifndef NULL
52 #define NULL ((void *) 0)
53 #endif
54
   // 每个逻辑块可存放的 i 节点数。
55 #define INODES_PER_BLOCK ((BLOCK_SIZE)/(sizeof (struct d_inode)))
   // 每个逻辑块可存放的目录项数。
56 #define DIR_ENTRIES_PER_BLOCK ((BLOCK_SIZE)/(sizeof (struct dir_entry)))
57
   // 管道头、管道尾、管道大小、管道空？、管道满？、管道头指针递增。
58 #define PIPE_HEAD(inode) ((inode).i_zone[0])
59 #define PIPE_TAIL(inode) ((inode).i_zone[1])
60 #define PIPE_SIZE(inode) ((PIPE_HEAD(inode)-PIPE_TAIL(inode))&(PAGE_SIZE-1))
61 #define PIPE_EMPTY(inode) (PIPE_HEAD(inode)==PIPE_TAIL(inode))
62 #define PIPE_FULL(inode) (PIPE_SIZE(inode)==(PAGE_SIZE-1))
63 #define INC_PIPE(head) \
64 __asm__("incl %0\n\tandl $4095,%0"::"m" (head))
65
66 typedef char buffer_block[BLOCK_SIZE];          // 块缓冲区。
67
   // 缓冲块头数据结构。（极为重要！！！）
   // 在程序中常用 bh 来表示 buffer_head 类型的缩写。
68 struct buffer_head {
69         char * b_data;                  /* pointer to data block (1024 bytes) */ //指针。
70         unsigned long b_blocknr;        /* block number */      // 块号。
71         unsigned short b_dev;           /* device (0 = free) */ // 数据源的设备号。
72         unsigned char b_uptodate;       // 更新标志：表示数据是否已更新。
73         unsigned char b_dirt;           /* 0-clean,1-dirty */ //修改标志:0 未修改,1 已修改.
74         unsigned char b_count;          /* users using this block */  // 使用的用户数。
75         unsigned char b_lock;           /* 0 - ok, 1 -locked */ // 缓冲区是否被锁定。
76         struct task_struct * b_wait;    // 指向等待该缓冲区解锁的任务。
77         struct buffer_head * b_prev;    // hash 队列上前一块（这四个指针用于缓冲区的管理）。
78         struct buffer_head * b_next;    // hash 队列上下一块。
79         struct buffer_head * b_prev_free;   // 空闲表上前一块。
80         struct buffer_head * b_next_free;   // 空闲表上下一块。
81 };
82
   // 磁盘上的索引节点(i 节点)数据结构。
83 struct d_inode {
84         unsigned short i_mode;          // 文件类型和属性(rwx 位)。
85         unsigned short i_uid;           // 用户 id（文件拥有者标识符）。
86         unsigned long i_size;           // 文件大小（字节数）。
87         unsigned long i_time;           // 修改时间（自 1970.1.1:0 算起，秒）。
88         unsigned char i_gid;            // 组 id(文件拥有者所在的组)。
89         unsigned char i_nlinks;         // 链接数（多少个文件目录项指向该 i 节点）。
```

```
90          unsigned short i_zone[9];       // 直接(0-6)、间接(7)或双重间接(8)逻辑块号。
                                            // zone 是区的意思，可译成区段，或逻辑块。
91  };
92
    // 这是在内存中的 i 节点结构。前 7 项与 d_inode 完全一样。
93  struct m_inode {
94          unsigned short i_mode;          // 文件类型和属性(rwx 位)。
95          unsigned short i_uid;           // 用户 id（文件拥有者标识符）。
96          unsigned long i_size;           // 文件大小（字节数）。
97          unsigned long i_mtime;          // 修改时间（自 1970.1.1:0 算起，秒）。
98          unsigned char i_gid;            // 组 id(文件拥有者所在的组)。
99          unsigned char i_nlinks;         // 文件目录项链接数。
100         unsigned short i_zone[9];       // 直接(0-6)、间接(7)或双重间接(8)逻辑块号。
101 /* these are in memory also */
102         struct task_struct * i_wait;    // 等待该 i 节点的进程。
103         unsigned long i_atime;          // 最后访问时间。
104         unsigned long i_ctime;          // i 节点自身修改时间。
105         unsigned short i_dev;           // i 节点所在的设备号。
106         unsigned short i_num;           // i 节点号。
107         unsigned short i_count;         // i 节点被使用的次数，0 表示该 i 节点空闲。
108         unsigned char i_lock;           // 锁定标志。
109         unsigned char i_dirt;           // 已修改(脏)标志。
110         unsigned char i_pipe;           // 管道标志。
111         unsigned char i_mount;          // 安装标志。
112         unsigned char i_seek;           // 搜寻标志(lseek 时)。
113         unsigned char i_update;         // 更新标志。
114 };
115
    // 文件结构（用于在文件句柄与 i 节点之间建立关系）
116 struct file {
117         unsigned short f_mode;          // 文件操作模式（RW 位）
118         unsigned short f_flags;         // 文件打开和控制的标志。
119         unsigned short f_count;         // 对应文件句柄（文件描述符）数。
120         struct m_inode * f_inode;       // 指向对应 i 节点。
121         off_t f_pos;                    // 文件位置（读写偏移值）。
122 };
123
    // 内存中磁盘超级块结构。
124 struct super_block {
125         unsigned short s_ninodes;       // 节点数。
126         unsigned short s_nzones;        // 逻辑块数。
127         unsigned short s_imap_blocks;   // i 节点位图所占用的数据块数。
128         unsigned short s_zmap_blocks;   // 逻辑块位图所占用的数据块数。
129         unsigned short s_firstdatazone; // 第一个数据逻辑块号。
130         unsigned short s_log_zone_size; // log(数据块数/逻辑块)。（以 2 为底）。
131         unsigned long s_max_size;       // 文件最大长度。
132         unsigned short s_magic;         // 文件系统魔数。
133 /* These are only in memory */
134         struct buffer_head * s_imap[8]; // i 节点位图缓冲块指针数组(占用 8 块，可表示 64M)。
135         struct buffer_head * s_zmap[8]; // 逻辑块位图缓冲块指针数组（占用 8 块）。
136         unsigned short s_dev;           // 超级块所在的设备号。
137         struct m_inode * s_isup;        // 被安装的文件系统根目录的 i 节点。(isup-super i)
138         struct m_inode * s_imount;      // 被安装到的 i 节点。
```

```
139         unsigned long s_time;           // 修改时间。
140         struct task_struct * s_wait;    // 等待该超级块的进程。
141         unsigned char s_lock;           // 被锁定标志。
142         unsigned char s_rd_only;        // 只读标志。
143         unsigned char s_dirt;           // 已修改(脏)标志。
144 };
145
    // 磁盘上超级块结构。上面 125-132 行完全一样。
146 struct d_super_block {
147         unsigned short s_ninodes;       // 节点数。
148         unsigned short s_nzones;        // 逻辑块数。
149         unsigned short s_imap_blocks;   // i 节点位图所占用的数据块数。
150         unsigned short s_zmap_blocks;   // 逻辑块位图所占用的数据块数。
151         unsigned short s_firstdatazone; // 第一个数据逻辑块。
152         unsigned short s_log_zone_size; // log(数据块数/逻辑块)。（以 2 为底）。
153         unsigned long s_max_size;       // 文件最大长度。
154         unsigned short s_magic;         // 文件系统魔数。
155 };
156
    // 文件目录项结构。
157 struct dir_entry {
158         unsigned short inode;           // i 节点。
159         char name[NAME_LEN];            // 文件名。
160 };
161
162 extern struct m_inode inode_table[NR_INODE];     // 定义 i 节点表数组（32 项）。
163 extern struct file file_table[NR_FILE];          // 文件表数组（64 项）。
164 extern struct super_block super_block[NR_SUPER]; // 超级块数组（8 项）。
165 extern struct buffer_head * start_buffer;        // 缓冲区起始内存位置。
166 extern int nr_buffers;                           // 缓冲块数。
167
    //// 磁盘操作函数原型。
    // 检测驱动器中软盘是否改变。
168 extern void check_disk_change(int dev);
    // 检测指定软驱中软盘更换情况。如果软盘更换了则返回 1，否则返回 0。
169 extern int floppy_change(unsigned int nr);
    // 设置启动指定驱动器所需等待的时间（设置等待定时器）。
170 extern int ticks_to_floppy_on(unsigned int dev);
    // 启动指定驱动器。
171 extern void floppy_on(unsigned int dev);
    // 关闭指定的软盘驱动器。
172 extern void floppy_off(unsigned int dev);

    //// 以下是文件系统操作管理用的函数原型。
    // 将 i 节点指定的文件截为 0。
173 extern void truncate(struct m_inode * inode);
    // 刷新 i 节点信息。
174 extern void sync_inodes(void);
    // 等待指定的 i 节点。
175 extern void wait_on(struct m_inode * inode);
    // 逻辑块(区段，磁盘块)位图操作。取数据块 block 在设备上对应的逻辑块号。
176 extern int bmap(struct m_inode * inode,int block);
    // 创建数据块 block 在设备上对应的逻辑块，并返回在设备上的逻辑块号。
```

```
177 extern int create_block(struct m_inode * inode,int block);
    // 获取指定路径名的 i 节点号。
178 extern struct m_inode * namei(const char * pathname);
    // 根据路径名为打开文件操作作准备。
179 extern int open_namei(const char * pathname, int flag, int mode,
180         struct m_inode ** res_inode);
    // 释放一个 i 节点(回写入设备)。
181 extern void iput(struct m_inode * inode);
    // 从设备读取指定节点号的一个 i 节点。
182 extern struct m_inode * iget(int dev,int nr);
    // 从 i 节点表(inode_table)中获取一个空闲 i 节点项。
183 extern struct m_inode * get_empty_inode(void);
    // 获取（申请一）管道节点。返回为 i 节点指针（如果是 NULL 则失败）。
184 extern struct m_inode * get_pipe_inode(void);
    // 在哈希表中查找指定的数据块。返回找到块的缓冲头指针。
185 extern struct buffer_head * get_hash_table(int dev, int block);
    // 从设备读取指定块（首先会在 hash 表中查找）。
186 extern struct buffer_head * getblk(int dev, int block);
    // 读/写数据块。
187 extern void ll_rw_block(int rw, struct buffer_head * bh);
    // 释放指定缓冲块。
188 extern void brelse(struct buffer_head * buf);
    // 读取指定的数据块。
189 extern struct buffer_head * bread(int dev,int block);
    // 读 4 块缓冲区到指定地址的内存中。
190 extern void bread_page(unsigned long addr,int dev,int b[4]);
    // 读取头一个指定的数据块，并标记后续将要读的块。
191 extern struct buffer_head * breada(int dev,int block,...);
    // 向设备 dev 申请一个磁盘块（区段，逻辑块）。返回逻辑块号
192 extern int new_block(int dev);
    // 释放设备数据区中的逻辑块(区段，磁盘块)block。复位指定逻辑块 block 的逻辑块位图比特位。
193 extern void free_block(int dev, int block);
    // 为设备 dev 建立一个新 i 节点，返回 i 节点号。
194 extern struct m_inode * new_inode(int dev);
    // 释放一个 i 节点（删除文件时）。
195 extern void free_inode(struct m_inode * inode);
    // 刷新指定设备缓冲区。
196 extern int sync_dev(int dev);
    // 读取指定设备的超级块。
197 extern struct super_block * get_super(int dev);
198 extern int ROOT_DEV;
199
    // 安装根文件系统。
200 extern void mount_root(void);
201
202 #endif
203
```

11.25 hdreg.h 文件

11.25.1 功能描述

该文件中主要定义了对硬盘控制器进行编程的一些命令常量符号。其中包括控制器端口、硬盘状态寄存器各位的状态、控制器命令以及出错状态常量符号。另外还给出了硬盘分区表数据结构。

11.25.2 代码注释

程序 11-21 linux/include/linux/hdreg.h

```
 1 /*
 2  * This file contains some defines for the AT-hd-controller.
 3  * Various sources. Check out some definitions (see comments with
 4  * a ques).
 5  */
   /*
    * 本文件含有一些 AT 硬盘控制器的定义。来自各种资料。请查证某些
    * 定义（带有问号的注释）。
    */
 6 #ifndef _HDREG_H
 7 #define _HDREG_H
 8
 9 /* Hd controller regs. Ref: IBM AT Bios-listing */
   /* 硬盘控制器寄存器端口。参见：IBM AT Bios 程序 */
10 #define HD_DATA         0x1f0   /* _CTL when writing */
11 #define HD_ERROR        0x1f1   /* see err-bits */
12 #define HD_NSECTOR      0x1f2   /* nr of sectors to read/write */
13 #define HD_SECTOR       0x1f3   /* starting sector */
14 #define HD_LCYL         0x1f4   /* starting cylinder */
15 #define HD_HCYL         0x1f5   /* high byte of starting cyl */
16 #define HD_CURRENT      0x1f6   /* 101dhhhh , d=drive, hhhh=head */
17 #define HD_STATUS       0x1f7   /* see status-bits */
18 #define HD_PRECOMP HD_ERROR     /* same io address, read=error, write=precomp */
19 #define HD_COMMAND HD_STATUS    /* same io address, read=status, write=cmd */
20
21 #define HD_CMD          0x3f6   // 控制寄存器端口。
22
23 /* Bits of HD_STATUS */
   /* 硬盘状态寄存器各位的定义(HD_STATUS) */
24 #define ERR_STAT        0x01    // 命令执行错误。
25 #define INDEX_STAT      0x02    // 收到索引。
26 #define ECC_STAT        0x04    /* Corrected error */  // ECC 校验错。
27 #define DRQ_STAT        0x08    // 请求服务。
28 #define SEEK_STAT       0x10    // 寻道结束。
29 #define WRERR_STAT      0x20    // 驱动器故障。
30 #define READY_STAT      0x40    // 驱动器准备好（就绪）。
31 #define BUSY_STAT       0x80    // 控制器忙碌。
32
33 /* Values for HD_COMMAND */
   /* 硬盘命令值（HD_CMD） */
34 #define WIN_RESTORE             0x10    // 驱动器重新校正（驱动器复位）。
```

```
35 #define WIN_READ                0x20    // 读扇区。
36 #define WIN_WRITE               0x30    // 写扇区。
37 #define WIN_VERIFY              0x40    // 扇区检验。
38 #define WIN_FORMAT              0x50    // 格式化磁道。
39 #define WIN_INIT                0x60    // 控制器初始化。
40 #define WIN_SEEK                0x70    // 寻道。
41 #define WIN_DIAGNOSE            0x90    // 控制器诊断。
42 #define WIN_SPECIFY             0x91    // 建立驱动器参数。
43
44 /* Bits for HD_ERROR */
   /* 错误寄存器各比特位的含义（HD_ERROR） */
   // 执行控制器诊断命令时含义与其他命令时的不同。下面分别列出：
   // ================================================
   //              诊断命令时              其他命令时
   // ------------------------------------------------
   // 0x01         无错误                  数据标志丢失
   // 0x02         控制器出错              磁道 0 错
   // 0x03         扇区缓冲区错
   // 0x04         ECC 部件错              命令放弃
   // 0x05         控制处理器错
   // 0x10                                 ID 未找到
   // 0x40                                 ECC 错误
   // 0x80                                 坏扇区
   //-------------------------------------------------
45 #define MARK_ERR        0x01    /* Bad address mark ? */
46 #define TRK0_ERR        0x02    /* couldn't find track 0 */
47 #define ABRT_ERR        0x04    /* ? */
48 #define ID_ERR          0x10    /* ? */
49 #define ECC_ERR         0x40    /* ? */
50 #define BBD_ERR         0x80    /* ? */
51
   // 硬盘分区表结构。参见下面列表后信息。
52 struct partition {
53         unsigned char boot_ind;         /* 0x80 - active (unused) */
54         unsigned char head;             /* ? */
55         unsigned char sector;           /* ? */
56         unsigned char cyl;              /* ? */
57         unsigned char sys_ind;          /* ? */
58         unsigned char end_head;         /* ? */
59         unsigned char end_sector;       /* ? */
60         unsigned char end_cyl;          /* ? */
61         unsigned int start_sect;        /* starting sector counting from 0 */
62         unsigned int nr_sects;          /* nr of sectors in partition */
63 };
64
65 #endif
66
```

11.25.3 其他信息

11.25.3.1 硬盘分区表

为了实现多个操作系统共享硬盘资源，硬盘可以在逻辑上分为 1--4 个分区。每个分区之间的扇区号是邻接的。分区表由 4 个表项组成，每个表项由 16 字节组成，对应一个分区的信息，存放有分区的大小

和起止的柱面号、磁道号和扇区号，见表 11–2 所示。分区表存放在硬盘的 0 柱面 0 头第 1 个扇区的 0x1BE--0x1FD 处。

表 11 - 2 硬盘分区表结构

位置	名称	大小	说明
0x00	boot_ind	字节	引导标志。4 个分区中同时只能有一个分区是可引导的。 0x00-不从该分区引导操作系统；0x80-从该分区引导操作系统。
0x01	head	字节	分区起始磁头号。
0x02	sector	字节	分区起始扇区号(位 0-5)和起始柱面号高 2 位(位 6-7)。
0x03	cyl	字节	分区起始柱面号低 8 位。
0x04	sys_ind	字节	分区类型字节。0x0b-DOS; 0x80-Old Minix; 0x83-Linux …
0x05	end_head	字节	分区的结束磁头号。
0x06	end_sector	字节	结束扇区号(位 0-5)和结束柱面号高 2 位(位 6-7)。
0x07	end_cyl	字节	结束柱面号低 8 位。
0x08--0x0b	start_sect	长字	分区起始物理扇区号。
0x0c--0x0f	nr_sects	长字	分区占用的扇区数。

11.26 head.h 文件

11.26.1 功能描述

head 头文件，定义了 Intel CPU 中描述符的简单结构，和指定描述符的项号。

11.26.2 代码注释

程序 11-22 linux/include/linux/head.h

```
 1 #ifndef _HEAD_H
 2 #define _HEAD_H
 3
 4 typedef struct desc_struct {        // 定义了段描述符的数据结构。该结构仅说明每个描述
 5         unsigned long a,b;          // 符是由 8 个字节构成，每个描述符表共有 256 项。
 6 } desc_table[256];
 7
 8 extern unsigned long pg_dir[1024];  // 内存页目录数组。每个目录项为 4 字节。从物理地址 0 开始。
 9 extern desc_table idt,gdt;          // 中断描述符表，全局描述符表。
10
11 #define GDT_NUL 0                   // 全局描述符表的第 0 项，不用。
12 #define GDT_CODE 1                  // 第 1 项，是内核代码段描述符项。
13 #define GDT_DATA 2                  // 第 2 项，是内核数据段描述符项。
14 #define GDT_TMP 3                   // 第 3 项，系统段描述符，Linux 没有使用。
15
16 #define LDT_NUL 0                   // 每个局部描述符表的第 0 项，不用。
17 #define LDT_CODE 1                  // 第 1 项，是用户程序代码段描述符项。
18 #define LDT_DATA 2                  // 第 2 项，是用户程序数据段描述符项。
19
```

```
20 #endif
21
```

11.27 kernel.h 文件

11.27.1 功能描述

定义了一些内核常用的函数原型等。

11.27.2 代码注释

程序 11-23 linux/include/linux/kernel.h

```
 1 /*
 2  * 'kernel.h' contains some often-used function prototypes etc
 3  */
   /*
    * 'kernel.h'定义了一些常用函数的原型等。
    */
   // 验证给定地址开始的内存块是否超限。若超限则追加内存。( kernel/fork.c, 24 )。
 4 void verify_area(void * addr,int count);
   // 显示内核出错信息，然后进入死循环。( kernel/panic.c, 16 )。
 5 volatile void panic(const char * str);
   // 标准打印（显示）函数。( init/main.c, 151)。
 6 int printf(const char * fmt, ...);
   // 内核专用的打印信息函数，功能与 printf()相同。( kernel/printk.c, 21 )。
 7 int printk(const char * fmt, ...);
   // 往 tty 上写指定长度的字符串。( kernel/chr_drv/tty_io.c, 290 )。
 8 int tty_write(unsigned ch,char * buf,int count);
   // 通用内核内存分配函数。( lib/malloc.c, 117)。
 9 void * malloc(unsigned int size);
   // 释放指定对象占用的内存。( lib/malloc.c, 182)。
10 void free_s(void * obj, int size);
11
12 #define free(x) free_s((x), 0)
13
14 /*
15  * This is defined as a macro, but at some point this might become a
16  * real subroutine that sets a flag if it returns true (to do
17  * BSD-style accounting where the process is flagged if it uses root
18  * privs).  The implication of this is that you should do normal
19  * permissions checks first, and check suser() last.
20  */
   /*
    * 下面函数是以宏的形式定义的，但是在某方面来看它可以成为一个真正的子程序，
    * 如果返回是 true 时它将设置标志（如果使用 root 用户权限的进程设置了标志，则用
    * 于执行 BSD 方式的计帐处理）。这意味着你应该首先执行常规权限检查，最后再
    * 检测 suser()。
    */
21 #define suser() (current->euid == 0)              // 检测是否是超级用户。
```

```
22
23
```

11.28 mm.h 文件

11.28.1 功能描述

mm.h 是内存管理头文件。其中主要定义了内存页面的大小和几个页面释放函数原型。

11.28.2 代码注释

程序 11-24 linux/include/linux/mm.h

```
 1 #ifndef _MM_H
 2 #define _MM_H
 3
 4 #define PAGE_SIZE 4096          // 定义内存页面的大小(字节数)。
 5
   // 取空闲页面函数。返回页面地址。扫描页面映射数组 mem_map[]取空闲页面。
 6 extern unsigned long get_free_page(void);
   // 在指定物理地址处放置一页面。在页目录和页表中放置指定页面信息。
 7 extern unsigned long put_page(unsigned long page,unsigned long address);
   // 释放物理地址 addr 开始的一页面内存。修改页面映射数组 mem_map[]中引用次数信息。
 8 extern void free_page(unsigned long addr);
 9
10 #endif
11
```

11.29 sched.h 文件

11.29.1 功能描述

调度程序头文件，定义了任务结构 task_struct、初始任务 0 的数据，还有一些有关描述符参数设置和获取的嵌入式汇编函数宏语句。

11.29.2 代码注释

程序 11-25 linux/include/linux/sched.h

```
 1 #ifndef _SCHED_H
 2 #define _SCHED_H
 3
 4 #define NR_TASKS 64                 // 系统中同时最多任务（进程）数。
 5 #define HZ 100                      // 定义系统时钟滴答频率(1 百赫兹，每个滴答 10ms)
 6
 7 #define FIRST_TASK task[0]          // 任务 0 比较特殊，所以特意给它单独定义一个符号。
 8 #define LAST_TASK task[NR_TASKS-1]  // 任务数组中的最后一项任务。
 9
10 #include <linux/head.h>    // head 头文件，定义了段描述符的简单结构，和几个选择符常量。
```

```
11 #include <linux/fs.h>      // 文件系统头文件。定义文件表结构（file,buffer_head,m_inode 等）。
12 #include <linux/mm.h>      // 内存管理头文件。含有页面大小定义和一些页面释放函数原型。
13 #include <signal.h>        // 信号头文件。定义信号符号常量，信号结构以及信号操作函数原型。
14
15 #if (NR_OPEN > 32)
16 #error "Currently the close-on-exec-flags are in one word, max 32 files/proc"
17 #endif
18
   // 这里定义了进程运行可能处的状态。
19 #define TASK_RUNNING            0   // 进程正在运行或已准备就绪。
20 #define TASK_INTERRUPTIBLE      1   // 进程处于可中断等待状态。
21 #define TASK_UNINTERRUPTIBLE    2   // 进程处于不可中断等待状态，主要用于 I/O 操作等待。
22 #define TASK_ZOMBIE             3   // 进程处于僵死状态，已经停止运行，但父进程还没发信号。
23 #define TASK_STOPPED            4   // 进程已停止。
24
25 #ifndef NULL
26 #define NULL ((void *) 0)           // 定义 NULL 为空指针。
27 #endif
28
   // 复制进程的页目录页表。Linus 认为这是内核中最复杂的函数之一。( mm/memory.c, 105 )
29 extern int copy_page_tables(unsigned long from, unsigned long to, long size);
   // 释放页表所指定的内存块及页表本身。( mm/memory.c, 150 )
30 extern int free_page_tables(unsigned long from, unsigned long size);
31
   // 调度程序的初始化函数。( kernel/sched.c, 385 )
32 extern void sched_init(void);
   // 进程调度函数。( kernel/sched.c, 104 )
33 extern void schedule(void);
   // 异常(陷阱)中断处理初始化函数，设置中断调用门并允许中断请求信号。( kernel/traps.c, 181 )
34 extern void trap_init(void);
   // 显示内核出错信息，然后进入死循环。( kernel/panic.c, 16 )。
35 extern void panic(const char * str);
   // 往 tty 上写指定长度的字符串。( kernel/chr_drv/tty_io.c, 290 )。
36 extern int tty_write(unsigned minor,char * buf,int count);
37
38 typedef int (*fn_ptr)();                    // 定义函数指针类型。
39
   // 下面是数学协处理器使用的结构，主要用于保存进程切换时 i387 的执行状态信息。
40 struct i387_struct {
41         long    cwd;            // 控制字(Control word)。
42         long    swd;            // 状态字(Status word)。
43         long    twd;            // 标记字(Tag word)。
44         long    fip;            // 协处理器代码指针。
45         long    fcs;            // 协处理器代码段寄存器。
46         long    foo;            // 内存操作数的偏移位置。
47         long    fos;            // 内存操作数的段值。
48         long    st_space[20];   /* 8*10 bytes for each FP-reg = 80 bytes */
49 };                              // 8 个 10 字节的协处理器累加器。
50
   // 任务状态段数据结构（参见列表后的 TSS 信息）。
51 struct tss_struct {
52         long    back_link;      /* 16 high bits zero */
53         long    esp0;
```

```
54          long    ss0;            /* 16 high bits zero */
55          long    esp1;
56          long    ss1;            /* 16 high bits zero */
57          long    esp2;
58          long    ss2;            /* 16 high bits zero */
59          long    cr3;
60          long    eip;
61          long    eflags;
62          long    eax,ecx,edx,ebx;
63          long    esp;
64          long    ebp;
65          long    esi;
66          long    edi;
67          long    es;             /* 16 high bits zero */
68          long    cs;             /* 16 high bits zero */
69          long    ss;             /* 16 high bits zero */
70          long    ds;             /* 16 high bits zero */
71          long    fs;             /* 16 high bits zero */
72          long    gs;             /* 16 high bits zero */
73          long    ldt;            /* 16 high bits zero */
74          long    trace_bitmap;   /* bits: trace 0, bitmap 16-31 */
75          struct i387_struct i387;
76 };
77
    // 这里是任务（进程）数据结构，或称为进程描述符。
    // ============================
    // long state                   任务的运行状态（-1 不可运行，0 可运行(就绪)，>0 已停止）。
    // long counter                 任务运行时间计数(递减)（滴答数），运行时间片。
    // long priority                运行优先数。任务开始运行时 counter = priority，越大运行越长。
    // long signal                  信号。是位图，每个比特位代表一种信号，信号值=位偏移值+1。
    // struct sigaction sigaction[32] 信号执行属性结构，对应信号将要执行的操作和标志信息。
    // long blocked                 进程信号屏蔽码（对应信号位图）。
    // ----------------------------
    // int exit_code                任务执行停止的退出码，其父进程会取。
    // unsigned long start_code     代码段地址。
    // unsigned long end_code       代码长度（字节数）。
    // unsigned long end_data       代码长度 + 数据长度（字节数）。
    // unsigned long brk            总长度（字节数）。
    // unsigned long start_stack    堆栈段地址。
    // long pid                     进程标识号(进程号)。
    // long father                  父进程号。
    // long pgrp                    父进程组号。
    // long session                 会话号。
    // long leader                  会话首领。
    // unsigned short uid           用户标识号（用户 id）。
    // unsigned short euid          有效用户 id。
    // unsigned short suid          保存的用户 id。
    // unsigned short gid           组标识号（组 id）。
    // unsigned short egid          有效组 id。
    // unsigned short sgid          保存的组 id。
    // long alarm                   报警定时值（滴答数）。
    // long utime                   用户态运行时间（滴答数）。
    // long stime                   系统态运行时间（滴答数）。
```

```
    // long cutime                子进程用户态运行时间。
    // long cstime                子进程系统态运行时间。
    // long start_time            进程开始运行时刻。
    // unsigned short used_math   标志：是否使用了协处理器。
    // ---------------------------
    // int tty                    进程使用 tty 的子设备号。-1 表示没有使用。
    // unsigned short umask       文件创建属性屏蔽位。
    // struct m_inode * pwd       当前工作目录 i 节点结构。
    // struct m_inode * root      根目录 i 节点结构。
    // struct m_inode * executable 执行文件 i 节点结构。
    // unsigned long close_on_exec 执行时关闭文件句柄位图标志。（参见 include/fcntl.h）
    // struct file * filp[NR_OPEN] 进程使用的文件表结构。
    // ---------------------------
    // struct desc_struct ldt[3] 本任务的局部表描述符。0-空，1-代码段 cs，2-数据和堆栈段 ds&ss。
    // ---------------------------
    // struct tss_struct tss      本进程的任务状态段信息结构。
    // ===========================
 78 struct task_struct {
 79 /* these are hardcoded - don't touch */
 80         long state;     /* -1 unrunnable, 0 runnable, >0 stopped */
 81         long counter;
 82         long priority;
 83         long signal;
 84         struct sigaction sigaction[32];
 85         long blocked;   /* bitmap of masked signals */
 86 /* various fields */
 87         int exit_code;
 88         unsigned long start_code,end_code,end_data,brk,start_stack;
 89         long pid,father,pgrp,session,leader;
 90         unsigned short uid,euid,suid;
 91         unsigned short gid,egid,sgid;
 92         long alarm;
 93         long utime,stime,cutime,cstime,start_time;
 94         unsigned short used_math;
 95 /* file system info */
 96         int tty;                /* -1 if no tty, so it must be signed */
 97         unsigned short umask;
 98         struct m_inode * pwd;
 99         struct m_inode * root;
100         struct m_inode * executable;
101         unsigned long close_on_exec;
102         struct file * filp[NR_OPEN];
103 /* ldt for this task 0 - zero 1 - cs 2 - ds&ss */
104         struct desc_struct ldt[3];
105 /* tss for this task */
106         struct tss_struct tss;
107 };
108
109 /*
110  *  INIT_TASK is used to set up the first task table, touch at
111  * your own risk!. Base=0, limit=0x9ffff (=640kB)
112  */
    /*
```

```
 * INIT_TASK 用于设置第 1 个任务表，若想修改，责任自负☺!
 * 基址 Base = 0，段长 limit = 0x9ffff (=640kB)。
 */
// 对应上面任务结构的第 1 个任务的信息。
#define INIT_TASK \
/* state etc */ { 0,15,15, \      // state, counter, priority
/* signals */   0,{{},},0, \      // signal, sigaction[32], blocked
/* ec,brk... */ 0,0,0,0,0,0, \    // exit_code,start_code,end_code,end_data,brk,start_stack
/* pid etc.. */ 0,-1,0,0,0, \     // pid, father, pgrp, session, leader
/* uid etc */   0,0,0,0,0,0, \    // uid, euid, suid, gid, egid, sgid
/* alarm */     0,0,0,0,0,0, \    // alarm, utime, stime, cutime, cstime, start_time
/* math */      0, \              // used_math
/* fs info */   -1,0022,NULL,NULL,NULL,0, \ // tty,umask,pwd,root,executable,close_on_exec
/* filp */      {NULL,}, \          // filp[20]
        { \                       // ldt[3]
                {0,0}, \
/* ldt */       {0x9f,0xc0fa00}, \  // 代码长 640K，基址 0x0，G=1，D=1，DPL=3，P=1 TYPE=0x0a
                {0x9f,0xc0f200}, \  // 数据长 640K，基址 0x0，G=1，D=1，DPL=3，P=1 TYPE=0x02
        }, \
/*tss*/ {0,PAGE_SIZE+(long)&init_task,0x10,0,0,0,0,(long)&pg_dir,\    // tss
         0,0,0,0,0,0,0,0, \
         0,0,0x17,0x17,0x17,0x17,0x17,0x17, \
         _LDT(0),0x80000000, \
                {} \
        }, \
}

extern struct task_struct *task[NR_TASKS];      // 任务数组。
extern struct task_struct *last_task_used_math; // 上一个使用过协处理器的进程。
extern struct task_struct *current;             // 当前进程结构指针变量。
extern long volatile jiffies;                   // 从开机开始算起的滴答数（10ms/滴答）。
extern long startup_time;                       // 开机时间。从 1970:0:0:0 开始计时的秒数。

#define CURRENT_TIME (startup_time+jiffies/HZ)  // 当前时间（秒数）。

// 添加定时器函数（定时时间 jiffies 滴答数，定时到时调用函数*fn()）。( kernel/sched.c,272)
extern void add_timer(long jiffies, void (*fn)(void));
// 不可中断的等待睡眠。( kernel/sched.c, 151 )
extern void sleep_on(struct task_struct ** p);
// 可中断的等待睡眠。( kernel/sched.c, 167 )
extern void interruptible_sleep_on(struct task_struct ** p);
// 明确唤醒睡眠的进程。( kernel/sched.c, 188 )
extern void wake_up(struct task_struct ** p);

/*
 * Entry into gdt where to find first TSS. 0-nul, 1-cs, 2-ds, 3-syscall
 * 4-TSS0, 5-LDT0, 6-TSS1 etc ...
 */
/*
 * 寻找第 1 个 TSS 在全局表中的入口。0-没有用 nul，1-代码段 cs，2-数据段 ds，3-系统段 syscall
 * 4-任务状态段 TSS0，5-局部表 LTD0，6-任务状态段 TSS1，等。
 */
// 全局表中第 1 个任务状态段(TSS)描述符的选择符索引号。
```

```
153 #define FIRST_TSS_ENTRY 4
    // 全局表中第 1 个局部描述符表(LDT)描述符的选择符索引号。
154 #define FIRST_LDT_ENTRY (FIRST_TSS_ENTRY+1)
    // 宏定义，计算在全局表中第 n 个任务的 TSS 描述符的索引号（选择符）。
155 #define _TSS(n) ((((unsigned long) n)<<4)+(FIRST_TSS_ENTRY<<3))
    // 宏定义，计算在全局表中第 n 个任务的 LDT 描述符的索引号。
156 #define _LDT(n) ((((unsigned long) n)<<4)+(FIRST_LDT_ENTRY<<3))
    // 宏定义，加载第 n 个任务的任务寄存器 tr。
157 #define ltr(n) __asm__("ltr %%ax"::"a" (_TSS(n)))
    // 宏定义，加载第 n 个任务的局部描述符表寄存器 ldtr。
158 #define lldt(n) __asm__("lldt %%ax"::"a" (_LDT(n)))
    // 取当前运行任务的任务号（是任务数组中的索引值，与进程号 pid 不同）。
    // 返回：n - 当前任务号。用于( kernel/traps.c, 79)。
159 #define str(n) \
160 __asm__("str %%ax\n\t" \                    // 将任务寄存器中 TSS 段的有效地址➔ax
161         "subl %2,%%eax\n\t" \               // (eax - FIRST_TSS_ENTRY*8)➔eax
162         "shrl $4,%%eax" \                   // (eax/16)➔eax = 当任务号。
163         :"=a" (n) \
164         :"a" (0),"i" (FIRST_TSS_ENTRY<<3))
165 /*
166  *      switch_to(n) should switch tasks to task nr n, first
167  * checking that n isn't the current task, in which case it does nothing.
168  * This also clears the TS-flag if the task we switched to has used
169  * tha math co-processor latest.
170  */
    /*
     * switch_to(n)将切换当前任务到任务 nr，即 n。首先检测任务 n 不是当前任务，
     * 如果是则什么也不做退出。如果我们切换到的任务最近（上次运行）使用过数学
     * 协处理器的话，则还需复位控制寄存器 cr0 中的 TS 标志。
     */
    // 跳转到一个任务的 TSS 段选择符组成的地址处会造成 CPU 进行任务切换操作。
    // 输入：%0 - 偏移地址(*&__tmp.a);      %1 - 存放新 TSS 的选择符；
    //       dx - 新任务 n 的 TSS 段选择符；ecx - 新任务指针 task[n]。
    // 其中临时数据结构__tmp 用于组建 177 行远跳转（far jump）指令的操作数。该操作数由 4 字节偏移
    // 地址和 2 字节的段选择符组成。因此__tmp 中 a 的值是 32 位偏移值，而 b 的低 2 字节是新 TSS 段的
    // 选择符（高 2 字节不用）。跳转到 TSS 段选择符会造成任务切换到该 TSS 对应的进程。对于造成任务
    // 切换的长跳转，a 值无用。177 行上的内存间接跳转指令使用 6 字节操作数作为跳转目的地的长指针，
    // 其格式为：jmp 16 位段选择符：32 位偏移值。但在内存中操作数的表示顺序与这里正好相反。
    // 在判断新任务上次执行是否使用过协处理器时，是通过将新任务状态段地址与保存在
    // last_task_used_math 变量中的使用过协处理器的任务状态段地址进行比较而作出的，
    // 参见 kernel/sched.c 中函数 math_state_restore()。
171 #define switch_to(n) {\
172 struct {long a,b;} __tmp; \
173 __asm__("cmpl %%ecx,_current\n\t" \         // 任务 n 是当前任务吗?(current ==task[n]?)
174         "je 1f\n\t" \                       // 是，则什么都不做，退出。
175         "movw %%dx,%1\n\t" \                // 将新任务 16 位选择符存入__tmp.b 中。
176         "xchgl %%ecx,_current\n\t" \        // current = task[n]; ecx = 被切换出的任务。
177         "ljmp %0\n\t" \                     // 执行长跳转至*&__tmp，造成任务切换。
                                                // 在任务切换回来后才会继续执行下面的语句。
178         "cmpl %%ecx,_last_task_used_math\n\t" \ // 原任务上次使用过协处理器吗？
179         "jne 1f\n\t" \                      // 没有则跳转，退出。
180         "clts\n" \                          // 原任务上次使用过协处理器，则清 cr0 的 TS 标志。
181         "1:" \
```

```
182         ::"m" (*&__tmp.a), "m" (*&__tmp.b), \
183         "d" (_TSS(n)), "c" ((long) task[n])); \
184 }
185
    // 页面地址对准。（在内核代码中没有任何地方引用!!）
186 #define PAGE_ALIGN(n) (((n)+0xfff)&0xfffff000)
187
    // 设置位于地址 addr 处描述符中的各基地址字段(基地址是 base)，参见列表后说明。
    // %0 - 地址 addr 偏移 2；%1 - 地址 addr 偏移 4；%2 - 地址 addr 偏移 7；edx - 基地址 base。
188 #define _set_base(addr,base) \
189 __asm__("movw %%dx,%0|n|t" \                    // 基址 base 低 16 位(位 15-0)➔[addr+2]。
190         "rorl $16,%%edx|n|t" \                  // edx 中基址高 16 位(位 31-16)➔dx。
191         "movb %%dl,%1|n|t" \                    // 基址高 16 位中的低 8 位(位 23-16)➔[addr+4]。
192         "movb %%dh,%2" \                        // 基址高 16 位中的高 8 位(位 31-24)➔[addr+7]。
193         ::"m" (*((addr)+2)), \
194           "m" (*((addr)+4)), \
195           "m" (*((addr)+7)), \
196           "d" (base) \
197         :"dx")
198
    // 设置位于地址 addr 处描述符中的段限长字段(段长是 limit)。
    // %0 - 地址 addr；%1 - 地址 addr 偏移 6 处；edx - 段长值 limit。
199 #define _set_limit(addr,limit) \
200 __asm__("movw %%dx,%0|n|t" \                    // 段长 limit 低 16 位(位 15-0)➔[addr]。
201         "rorl $16,%%edx|n|t" \                  // edx 中的段长高 4 位(位 19-16)➔dl。
202         "movb %1,%%dh|n|t" \                    // 取原[addr+6]字节➔dh，其中高 4 位是些标志。
203         "andb $0xf0,%%dh|n|t" \                 // 清 dh 的低 4 位(将存放段长的位 19-16)。
204         "orb %%dh,%%dl|n|t" \                   // 将原高 4 位标志和段长的高 4 位(位 19-16)合成 1 字节，
205         "movb %%dl,%1" \                        // 并放会[addr+6]处。
206         ::"m" (*(addr)), \
207           "m" (*((addr)+6)), \
208           "d" (limit) \
209         :"dx")
210
    // 设置局部描述符表中 ldt 描述符的基地址字段。
211 #define set_base(ldt,base) _set_base( ((char *)&(ldt)) , base )
    // 设置局部描述符表中 ldt 描述符的段长字段。
212 #define set_limit(ldt,limit) _set_limit( ((char *)&(ldt)) , (limit-1)>>12 )
213
    // 从地址 addr 处描述符中取段基地址。功能与_set_base()正好相反。
    // edx - 存放基地址(__base)；%1 - 地址 addr 偏移 2；%2 - 地址 addr 偏移 4；%3 - addr 偏移 7。
214 #define _get_base(addr) ({\
215 unsigned long __base; \
216 __asm__("movb %3,%%dh|n|t" \                    // 取[addr+7]处基址高 16 位的高 8 位(位 31-24)➔dh。
217         "movb %2,%%dl|n|t" \                    // 取[addr+4]处基址高 16 位的低 8 位(位 23-16)➔dl。
218         "shll $16,%%edx|n|t" \                  // 基地址高 16 位移到 edx 中高 16 位处。
219         "movw %1,%%dx" \                        // 取[addr+2]处基址低 16 位(位 15-0)➔dx。
220         :"=d" (__base) \                        // 从而 edx 中含有 32 位的段基地址。
221         :"m" (*((addr)+2)), \
222          "m" (*((addr)+4)), \
223          "m" (*((addr)+7))); \
224 __base;})
225
```

```
    // 取局部描述符表中 ldt 所指段描述符中的基地址。
226 #define get_base(ldt)  _get_base( ((char *)&(ldt)) )
227
    // 取段选择符 segment 指定的描述符中的段限长值。
    // 指令 lsl 是 Load Segment Limit 缩写。它从指定段描述符中取出分散的限长比特位拼成完整的
    // 段限长值放入指定寄存器中。所得的段限长是实际字节数减 1，因此这里还需要加 1 后才返回。
    // %0 - 存放段长值(字节数)；%1 - 段选择符 segment。
228 #define get_limit(segment) ({ \
229 unsigned long __limit; \
230 __asm__("lsll %1,%0\n\tincl %0":"=r" (__limit):"r" (segment)); \
231 __limit;})
232
233 #endif
234
```

11.29.3 其他信息

11.29.3.1 任务状态段信息

31	23	15	7	0	
I/O 映射图基地址(MAP BASE)		0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0			64
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		局部描述符表(LDT)的选择符			60
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		GS			5C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		FS			58
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		DS			54
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		SS			50
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		CS			4C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		ES			48
EDI					44
ESI					40
EBP					3C
ESP					38
EBX					34
EDX					30
ECX					2C
EAX					28
EFLAGS					24
指令指针(EIP)					20
页目录基地址寄存器 CR3（PDBR）					1C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		SS2			18
ESP2					14
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		SS1			10
ESP1					0C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0		SS0			08
ESP0					04

0000000000000000	前一执行任务 TSS 的描述符	00

图 11-4 任务状态段的结构

任务状态段的详细说明请参考附录。这里对其进行简单描述。

CPU 管理任务需要的所有信息被存储于一个特殊类型的段中，任务状态段(task state segment - TSS)。图中显示出执行 80386 任务的 TSS 格式。

TSS 中的字段可以分为两类：

1. CPU 在进行任务切换时更新的动态信息集。这些字段有：
   - o 通用寄存器（EAX，ECX，EDX，EBX，ESP，EBP，ESI，EDI）；
   - o 段寄存器（ES, CS, SS, DS, FS, GS）；
   - o 标志寄存器（EFLAGS）；
   - o 指令指针（EIP）；
   - 前一个执行任务的 TSS 的选择符（仅当返回时才更新）。
2. CPU 读取但不会更改的静态信息集。这些字段有：
   - o 任务的 LDT 的选择符；
   - o 含有任务页目录基地址的寄存器（PDBR）；
   - o 特权级 0-2 的堆栈指针；
   - o 当任务进行切换时导致 CPU 产生一个调试(debug)异常的 T-比特位（调试跟踪位）；
   - o I/O 比特位图基地址（其长度上限就是 TSS 的长度上限，在 TSS 描述符中说明）。

任务状态段可以存放在线形空间的任何地方。与其他各类段相似，任务状态段也是由描述符来定义的。当前正在执行任务的 TSS 是由任务寄存器（TR）来指示的。指令 LTR 和 STR 用来修改和读取任务寄存器中的选择符（任务寄存器的可见部分）。

I/O 比特位图中的每 1 比特对应 1 个 I/O 端口。比如端口 41 的比特位就是 I/O 位图基地址+5，位偏移 1 处。在保护模式中，当遇到 1 个 I/O 指令时(IN, INS, OUT, OUTS)，CPU 首先就会检查当前特权级是否小于标志寄存器的 IOPL，如果这个条件满足，就执行该 I/O 操作。如果不满足，那么 CPU 就会检查 TSS 中的 I/O 比特位图。如果相应比特位是置位的，就会产生一般保护性异常，否则就会执行该 I/O 操作。

11.30 sys.h 文件

11.30.1 功能描述

sys.h 头文件列出了内核中所有系统调用函数的原型，以及系统调用函数指针表。

11.30.2 代码注释

程序 11-26 linux/include/linux/sys.h

```
1 extern int sys_setup();       // 系统启动初始化设置函数。      (kernel/blk_drv/hd.c,71)
2 extern int sys_exit();        // 程序退出。                    (kernel/exit.c, 137)
3 extern int sys_fork();        // 创建进程。                    (kernel/system_call.s, 208)
4 extern int sys_read();        // 读文件。                      (fs/read_write.c, 55)
5 extern int sys_write();       // 写文件。                      (fs/read_write.c, 83)
6 extern int sys_open();        // 打开文件。                    (fs/open.c, 138)
7 extern int sys_close();       // 关闭文件。                    (fs/open.c, 192)
8 extern int sys_waitpid();     // 等待进程终止。                (kernel/exit.c, 142)
9 extern int sys_creat();       // 创建文件。                    (fs/open.c, 187)
```

```
10 extern int sys_link();          // 创建一个文件的硬连接。          (fs/namei.c, 721)
11 extern int sys_unlink();        // 删除一个文件名(或删除文件)。    (fs/namei.c, 663)
12 extern int sys_execve();        // 执行程序。                      (kernel/system_call.s, 200)
13 extern int sys_chdir();         // 更改当前目录。                  (fs/open.c, 75)
14 extern int sys_time();          // 取当前时间。                    (kernel/sys.c, 102)
15 extern int sys_mknod();         // 建立块/字符特殊文件。           (fs/namei.c, 412)
16 extern int sys_chmod();         // 修改文件属性。                  (fs/open.c, 105)
17 extern int sys_chown();         // 修改文件宿主和所属组。          (fs/open.c, 121)
18 extern int sys_break();         //                                 (-kernel/sys.c, 21)
19 extern int sys_stat();          // 使用路径名取文件的状态信息。    (fs/stat.c, 36)
20 extern int sys_lseek();         // 重新定位读/写文件偏移。         (fs/read_write.c, 25)
21 extern int sys_getpid();        // 取进程 id。                     (kernel/sched.c, 348)
22 extern int sys_mount();         // 安装文件系统。                  (fs/super.c, 200)
23 extern int sys_umount();        // 卸载文件系统。                  (fs/super.c, 167)
24 extern int sys_setuid();        // 设置进程用户 id。               (kernel/sys.c, 143)
25 extern int sys_getuid();        // 取进程用户 id。                 (kernel/sched.c, 358)
26 extern int sys_stime();         // 设置系统时间日期。              (-kernel/sys.c, 148)
27 extern int sys_ptrace();        // 程序调试。                      (-kernel/sys.c, 26)
28 extern int sys_alarm();         // 设置报警。                      (kernel/sched.c, 338)
29 extern int sys_fstat();         // 使用文件句柄取文件的状态信息。  (fs/stat.c, 47)
30 extern int sys_pause();         // 暂停进程运行。                  (kernel/sched.c, 144)
31 extern int sys_utime();         // 改变文件的访问和修改时间。      (fs/open.c, 24)
32 extern int sys_stty();          // 修改终端行设置。                (-kernel/sys.c, 31)
33 extern int sys_gtty();          // 取终端行设置信息。              (-kernel/sys.c, 36)
34 extern int sys_access();        // 检查用户对一个文件的访问权限。  (fs/open.c, 47)
35 extern int sys_nice();          // 设置进程执行优先权。            (kernel/sched.c, 378)
36 extern int sys_ftime();         // 取日期和时间。                  (-kernel/sys.c,16)
37 extern int sys_sync();          // 同步高速缓冲与设备中数据。      (fs/buffer.c, 44)
38 extern int sys_kill();          // 终止一个进程。                  (kernel/exit.c, 60)
39 extern int sys_rename();        // 更改文件名。                    (-kernel/sys.c, 41)
40 extern int sys_mkdir();         // 创建目录。                      (fs/namei.c, 463)
41 extern int sys_rmdir();         // 删除目录。                      (fs/namei.c, 587)
42 extern int sys_dup();           // 复制文件句柄。                  (fs/fcntl.c, 42)
43 extern int sys_pipe();          // 创建管道。                      (fs/pipe.c, 71)
44 extern int sys_times();         // 取运行时间。                    (kernel/sys.c, 156)
45 extern int sys_prof();          // 程序执行时间区域。              (-kernel/sys.c, 46)
46 extern int sys_brk();           // 修改数据段长度。                (kernel/sys.c, 168)
47 extern int sys_setgid();        // 设置进程组 id。                 (kernel/sys.c, 72)
48 extern int sys_getgid();        // 取进程组 id。                   (kernel/sched.c, 368)
49 extern int sys_signal();        // 信号处理。                      (kernel/signal.c, 48)
50 extern int sys_geteuid();       // 取进程有效用户 id。             (kenrl/sched.c, 363)
51 extern int sys_getegid();       // 取进程有效组 id。               (kenrl/sched.c, 373)
52 extern int sys_acct();          // 进程记帐。                      (-kernel/sys.c, 77)
53 extern int sys_phys();          //                                 (-kernel/sys.c, 82)
54 extern int sys_lock();          //                                 (-kernel/sys.c, 87)
55 extern int sys_ioctl();         // 设备控制。                      (fs/ioctl.c, 30)
56 extern int sys_fcntl();         // 文件句柄操作。                  (fs/fcntl.c, 47)
57 extern int sys_mpx();           //                                 (-kernel/sys.c, 92)
58 extern int sys_setpgid();       // 设置进程组 id。                 (kernel/sys.c, 181)
59 extern int sys_ulimit();        //                                 (-kernel/sys.c, 97)
60 extern int sys_uname();         // 显示系统信息。                  (kernel/sys.c, 216)
61 extern int sys_umask();         // 取默认文件创建属性码。          (kernel/sys.c, 230)
62 extern int sys_chroot();        // 改变根系统。                    (fs/open.c, 90)
```

```
63 extern int sys_ustat();          // 取文件系统信息。                (fs/open.c, 19)
64 extern int sys_dup2();           // 复制文件句柄。                  (fs/fcntl.c, 36)
65 extern int sys_getppid();        // 取父进程 id。                   (kernel/sched.c, 353)
66 extern int sys_getpgrp();        // 取进程组 id，等于 getpgid(0)。  (kernel/sys.c, 201)
67 extern int sys_setsid();         // 在新会话中运行程序。            (kernel/sys.c, 206)
68 extern int sys_sigaction();      // 改变信号处理过程。              (kernel/signal.c, 63)
69 extern int sys_sgetmask();       // 取信号屏蔽码。                  (kernel/signal.c, 15)
70 extern int sys_ssetmask();       // 设置信号屏蔽码。                (kernel/signal.c, 20)
71 extern int sys_setreuid();       // 设置真实与/或有效用户 id。      (kernel/sys.c,118)
72 extern int sys_setregid();       // 设置真实与/或有效组 id。        (kernel/sys.c, 51)
73
   // 系统调用函数指针表。用于系统调用中断处理程序(int 0x80)，作为跳转表。
74 fn_ptr sys_call_table[] = { sys_setup, sys_exit, sys_fork, sys_read,
75 sys_write, sys_open, sys_close, sys_waitpid, sys_creat, sys_link,
76 sys_unlink, sys_execve, sys_chdir, sys_time, sys_mknod, sys_chmod,
77 sys_chown, sys_break, sys_stat, sys_lseek, sys_getpid, sys_mount,
78 sys_umount, sys_setuid, sys_getuid, sys_stime, sys_ptrace, sys_alarm,
79 sys_fstat, sys_pause, sys_utime, sys_stty, sys_gtty, sys_access,
80 sys_nice, sys_ftime, sys_sync, sys_kill, sys_rename, sys_mkdir,
81 sys_rmdir, sys_dup, sys_pipe, sys_times, sys_prof, sys_brk, sys_setgid,
82 sys_getgid, sys_signal, sys_geteuid, sys_getegid, sys_acct, sys_phys,
83 sys_lock, sys_ioctl, sys_fcntl, sys_mpx, sys_setpgid, sys_ulimit,
84 sys_uname, sys_umask, sys_chroot, sys_ustat, sys_dup2, sys_getppid,
85 sys_getpgrp, sys_setsid, sys_sigaction, sys_sgetmask, sys_ssetmask,
86 sys_setreuid,sys_setregid };
87
```

11.31 tty.h 文件

11.31.1 功能描述

终端数据结构和常量定义。

11.31.2 代码注释

程序 11-27 linux/include/linux/tty.h

```
1 /*
2  * 'tty.h' defines some structures used by tty_io.c and some defines.
3  *
4  * NOTE! Don't touch this without checking that nothing in rs_io.s or
5  * con_io.s breaks. Some constants are hardwired into the system (mainly
6  * offsets into 'tty_queue'
7  */
8
   /*
    * 'tty.h'中定义了 tty_io.c 程序使用的某些结构和其他一些定义。
    *
    * 注意！在修改这里的定义时，一定要检查 rs_io.s 或 con_io.s 程序中不会出现问题。
    * 在系统中有些常量是直接写在程序中的（主要是一些 tty_queue 中的偏移值）。
    */
9 #ifndef _TTY_H
```

```
10 #define _TTY_H
11
12 #include <termios.h>        // 终端输入输出函数头文件。主要定义控制异步通信口的终端接口。
13
14 #define TTY_BUF_SIZE 1024        // tty 缓冲区（缓冲队列）大小。
15
   // tty 等待队列数据结构。用于 tty_struc 结构中的读、写和辅助（规范）缓冲队列。
16 struct tty_queue {
17         unsigned long data;              // 队列缓冲区中含有字符行数值（不是当前字符数）。
                                            // 对于串口终端，则存放串行端口地址。
18         unsigned long head;              // 缓冲区中数据头指针。
19         unsigned long tail;              // 缓冲区中数据尾指针。
20         struct task_struct * proc_list;  // 等待进程列表。
21         char buf[TTY_BUF_SIZE];          // 队列的缓冲区。
22 };
23
   // 以下定义了 tty 等待队列中缓冲区操作宏函数。（tail 在前，head 在后，参见 tty_io.c 的图）。
   // a 缓冲区指针前移 1 字节，若已超出缓冲区右侧，则指针循环。
24 #define INC(a) ((a) = ((a)+1) & (TTY_BUF_SIZE-1))
   // a 缓冲区指针后退 1 字节，并循环。
25 #define DEC(a) ((a) = ((a)-1) & (TTY_BUF_SIZE-1))
   // 清空指定队列的缓冲区。
26 #define EMPTY(a) ((a).head == (a).tail)
   // 缓冲区还可存放字符的长度（空闲区长度）。
27 #define LEFT(a) (((a).tail-(a).head-1)&(TTY_BUF_SIZE-1))
   // 缓冲区中最后一个位置。
28 #define LAST(a) ((a).buf[(TTY_BUF_SIZE-1)&((a).head-1)])
   // 缓冲区满（如果为 1 的话）。
29 #define FULL(a) (!LEFT(a))
   // 缓冲区中已存放字符的长度。
30 #define CHARS(a) (((a).head-(a).tail)&(TTY_BUF_SIZE-1))
   // 从 queue 队列项缓冲区中取一字符(从 tail 处，并且 tail+=1)。
31 #define GETCH(queue,c) \
32 (void)({c=(queue).buf[(queue).tail];INC((queue).tail);})
   // 往 queue 队列项缓冲区中放置一字符（在 head 处，并且 head+=1）。
33 #define PUTCH(c,queue) \
34 (void)({(queue).buf[(queue).head]=(c);INC((queue).head);})
35
   // 判断终端键盘字符类型。
36 #define INTR_CHAR(tty) ((tty)->termios.c_cc[VINTR])     // 中断符。
37 #define QUIT_CHAR(tty) ((tty)->termios.c_cc[VQUIT])     // 退出符。
38 #define ERASE_CHAR(tty) ((tty)->termios.c_cc[VERASE])   // 削除符。
39 #define KILL_CHAR(tty) ((tty)->termios.c_cc[VKILL])     // 终止符。
40 #define EOF_CHAR(tty) ((tty)->termios.c_cc[VEOF])       // 文件结束符。
41 #define START_CHAR(tty) ((tty)->termios.c_cc[VSTART])   // 开始符。
42 #define STOP_CHAR(tty) ((tty)->termios.c_cc[VSTOP])     // 停止符。
43 #define SUSPEND_CHAR(tty) ((tty)->termios.c_cc[VSUSP])  // 挂起符。
44
   // tty 数据结构。
45 struct tty_struct {
46         struct termios termios;                 // 终端 io 属性和控制字符数据结构。
47         int pgrp;                               // 所属进程组。
48         int stopped;                            // 停止标志。
```

```
49          void (*write)(struct tty_struct * tty);    // tty 写函数指针。
50          struct tty_queue read_q;                   // tty 读队列。
51          struct tty_queue write_q;                  // tty 写队列。
52          struct tty_queue secondary;                // tty 辅助队列(存放规范模式字符序列),
53          };                                         // 可称为规范(熟)模式队列。
54
55  extern struct tty_struct tty_table[];              // tty 结构数组。
56
57  /*      intr=^C         quit=^|         erase=del        kill=^U
58          eof=^D          vtime=\0        vmin=\1         sxtc=\0
59          start=^Q        stop=^S         susp=^Z         eol=\0
60          reprint=^R      discard=^U      werase=^W       lnext=^V
61          eol2=\0
62  */
    /* 中断 intr=^C      退出 quit=^|      删除 erase=del      终止 kill=^U
     * 文件结束 eof=^D   vtime=\0          vmin=\1           sxtc=\0
     * 开始 start=^Q     停止 stop=^S      挂起 susp=^Z      行结束 eol=\0
     * 重显 reprint=^R   丢弃 discard=^U   werase=^W         lnext=^V
     * 行结束 eol2=\0
     */
    // 控制字符对应的 ASCII 码值。[8 进制]
63  #define INIT_C_CC "\003\034\177\025\004\0\1\0\021\023\032\0\022\017\027\026\0"
64
65  void rs_init(void);         // 异步串行通信初始化。(kernel/chr_drv/serial.c, 37)
66  void con_init(void);        // 控制终端初始化。     (kernel/chr_drv/console.c, 617)
67  void tty_init(void);        // tty 初始化。         (kernel/chr_drv/tty_io.c, 105)
68
69  int tty_read(unsigned c, char * buf, int n);   // (kernel/chr_drv/tty_io.c, 230)
70  int tty_write(unsigned c, char * buf, int n);  // (kernel/chr_drv/tty_io.c, 290)
71
72  void rs_write(struct tty_struct * tty);        // (kernel/chr_drv/serial.c, 53)
73  void con_write(struct tty_struct * tty);       // (kernel/chr_drv/console.c, 445)
74
75  void copy_to_cooked(struct tty_struct * tty);  // (kernel/chr_drv/tty_io.c, 145)
76
77  #endif
78
```

11.32 include/sys/目录中的文件

列表 11-4 linux/include/sys/目录下的文件

	名称	大小	最后修改时间(GMT)	说明
	stat.h	1304 bytes	1991-09-17 15:02:48	m
	times.h	200 bytes	1991-09-17 15:03:06	m
	types.h	805 bytes	1991-09-17 15:02:55	m
	utsname.h	234 bytes	1991-09-17 15:03:23	m
	wait.h	560 bytes	1991-09-17 15:06:07	m

11.33 stat.h 文件

11.33.1 功能描述

该头文件说明了函数 stat()返回的数据及其结构类型，以及一些属性操作测试宏、函数原型。

11.33.2 代码注释

程序 11-28 linux/include/sys/stat.h

```
 1 #ifndef _SYS_STAT_H
 2 #define _SYS_STAT_H
 3
 4 #include <sys/types.h>
 5
 6 struct stat {
 7         dev_t   st_dev;     // 含有文件的设备号。
 8         ino_t   st_ino;     // 文件 i 节点号。
 9         umode_t st_mode;    // 文件类型和属性（见下面）。
10         nlink_t st_nlink;   // 指定文件的连接数。
11         uid_t   st_uid;     // 文件的用户(标识)号。
12         gid_t   st_gid;     // 文件的组号。
13         dev_t   st_rdev;    // 设备号(如果文件是特殊的字符文件或块文件)。
14         off_t   st_size;    // 文件大小（字节数）（如果文件是常规文件）。
15         time_t  st_atime;   // 上次（最后）访问时间。
16         time_t  st_mtime;   // 最后修改时间。
17         time_t  st_ctime;   // 最后节点修改时间。
18 };
19
   // st_mode 值的符号名称。
   // 文件类型：
20 #define S_IFMT  00170000    // 文件类型（8 进制表示）。
21 #define S_IFREG  0100000    // 常规文件。
22 #define S_IFBLK  0060000    // 块特殊（设备）文件，如磁盘 dev/fd0。
```

```
23 #define S_IFDIR  0040000    // 目录文件。
24 #define S_IFCHR  0020000    // 字符设备文件。
25 #define S_IFIFO  0010000    // FIFO 特殊文件。
   // 文件属性位：
   // S_ISUID 用于测试文件的 set-user-ID 标志是否置位。若该标志置位，则当执行该文件时，进程的
   // 有效用户 ID 将被设置为该文件宿主的用户 ID。S_ISGID 则是针对组 ID 进行相同处理。
26 #define S_ISUID  0004000    // 执行时设置用户 ID（set-user-ID）。
27 #define S_ISGID  0002000    // 执行时设置组 ID（set-group-ID）。
28 #define S_ISVTX  0001000    // 对于目录，受限删除标志。
29
30 #define S_ISREG(m)      (((m) & S_IFMT) == S_IFREG)   // 测试是否常规文件。
31 #define S_ISDIR(m)      (((m) & S_IFMT) == S_IFDIR)   // 是否目录文件。
32 #define S_ISCHR(m)      (((m) & S_IFMT) == S_IFCHR)   // 是否字符设备文件。
33 #define S_ISBLK(m)      (((m) & S_IFMT) == S_IFBLK)   // 是否块设备文件。
34 #define S_ISFIFO(m)     (((m) & S_IFMT) == S_IFIFO)   // 是否 FIFO 特殊文件。
35
   // 文件访问权限：
36 #define S_IRWXU 00700       // 宿主可以读、写、执行/搜索。
37 #define S_IRUSR 00400       // 宿主读许可。
38 #define S_IWUSR 00200       // 宿主写许可。
39 #define S_IXUSR 00100       // 宿主执行/搜索许可。
40
41 #define S_IRWXG 00070       // 组成员可以读、写、执行/搜索。
42 #define S_IRGRP 00040       // 组成员读许可。
43 #define S_IWGRP 00020       // 组成员写许可。
44 #define S_IXGRP 00010       // 组成员执行/搜索许可。
45
46 #define S_IRWXO 00007       // 其他人读、写、执行/搜索许可。
47 #define S_IROTH 00004       // 其他人读许可。
48 #define S_IWOTH 00002       // 其他人写许可。
49 #define S_IXOTH 00001       // 其他人执行/搜索许可。
50
51 extern int chmod(const char *_path, mode_t mode);     // 修改文件属性。
52 extern int fstat(int fildes, struct stat *stat_buf);  // 取指定文件句柄的文件状态信息。
53 extern int mkdir(const char *_path, mode_t mode);     // 创建目录。
54 extern int mkfifo(const char *_path, mode_t mode);    // 创建管道文件。
55 extern int stat(const char *filename, struct stat *stat_buf); // 取指定文件名的文件状态信息。
56 extern mode_t umask(mode_t mask);  // 设置属性屏蔽码。
57
58 #endif
59
```

11.34 times.h 文件

11.34.1 功能描述

该头文件中主要定义了文件访问与修改时间结构 tms。它将由 times()函数返回。其中 time_t 是在 sys/types.h 中定义的。还定义了一个函数原型 times()。

11.34.2 代码注释

程序 11-29 linux/include/sys/times.h

```
 1 #ifndef _TIMES_H
 2 #define _TIMES_H
 3
 4 #include <sys/types.h>     // 类型头文件。定义了基本的系统数据类型。
 5
 6 struct tms {
 7         time_t tms_utime;  // 用户使用的 CPU 时间。
 8         time_t tms_stime;  // 系统（内核）CPU 时间。
 9         time_t tms_cutime; // 已终止的子进程使用的用户 CPU 时间。
10         time_t tms_cstime; // 已终止的子进程使用的系统 CPU 时间。
11 };
12
13 extern time_t times(struct tms * tp);
14
15 #endif
16
```

11.35 types.h 文件

11.35.1 功能描述

types.h 头文件中定义了基本的数据类型。所有的类型定义为适当的数学类型长度。另外，size_t 是无符号整数类型，off_t 是扩展的符号整数类型，pid_t 是符号整数类型。

11.35.2 代码注释

程序 11-30 linux/include/sys/types.h

```
 1 #ifndef _SYS_TYPES_H
 2 #define _SYS_TYPES_H
 3
 4 #ifndef _SIZE_T
 5 #define _SIZE_T
 6 typedef unsigned int size_t;        // 用于对象的大小（长度）。
 7 #endif
 8
 9 #ifndef _TIME_T
10 #define _TIME_T
11 typedef long time_t;                // 用于时间（以秒计）。
12 #endif
13
14 #ifndef _PTRDIFF_T
15 #define _PTRDIFF_T
16 typedef long ptrdiff_t;
17 #endif
```

```
18
19 #ifndef NULL
20 #define NULL ((void *) 0)
21 #endif
22
23 typedef int pid_t;                // 用于进程号和进程组号。
24 typedef unsigned short uid_t;     // 用于用户号（用户标识号）。
25 typedef unsigned char gid_t;      // 用于组号。
26 typedef unsigned short dev_t;     // 用于设备号。
27 typedef unsigned short ino_t;     // 用于文件序列号。
28 typedef unsigned short mode_t;    // 用于某些文件属性。
29 typedef unsigned short umode_t;   //
30 typedef unsigned char nlink_t;    // 用于连接计数。
31 typedef int daddr_t;
32 typedef long off_t;               // 用于文件长度（大小）。
33 typedef unsigned char u_char;     // 无符号字符类型。
34 typedef unsigned short ushort;    // 无符号短整数类型。
35
36 typedef struct { int quot,rem; } div_t;    // 用于 DIV 操作。
37 typedef struct { long quot,rem; } ldiv_t;  // 用于长 DIV 操作。
38
   // 文件系统参数结构，用于 ustat()函数。最后两个字段未使用，总是返回 NULL 指针。
39 struct ustat {
40         daddr_t f_tfree;              // 系统总空闲块数。
41         ino_t f_tinode;               // 总空闲 i 节点数。
42         char f_fname[6];              // 文件系统名称。
43         char f_fpack[6];              // 文件系统压缩名称。
44 };
45
46 #endif
47
```

11.36 utsname.h 文件

11.36.1 功能描述

utsname.h 是系统名称结构头文件。其中定义了结构 utsname 以及函数原型 uname()。POSIX 要求字符数组长度应该是不指定的，但是其中存储的数据需以 null 终止。因此该版内核的 utsname 结构定义不符要求（数组长度都被定义为 9）。

11.36.2 代码注释

程序 11-31 linux/include/sys/utsname.h

```
1 #ifndef _SYS_UTSNAME_H
2 #define _SYS_UTSNAME_H
3
4 #include <sys/types.h>     // 类型头文件。定义了基本的系统数据类型。
5
6 struct utsname {
```

```
 7          char sysname[9];   // 本版本操作系统的名称。
 8          char nodename[9];  // 与实现相关的网络中节点名称。
 9          char release[9];   // 本实现的当前发行级别。
10          char version[9];   // 本次发行的版本级别。
11          char machine[9];   // 系统运行的硬件类型名称。
12 };
13
14 extern int uname(struct utsname * utsbuf);
15
16 #endif
17
```

11.37 wait.h 文件

11.37.1 功能描述

该头文件描述了进程等待时信息。包括一些符号常数和 wait()、waitpid()函数原型声明。

11.37.2 代码注释

程序 11-32 linux/include/sys/wait.h

```
 1 #ifndef _SYS_WAIT_H
 2 #define _SYS_WAIT_H
 3
 4 #include <sys/types.h>
 5
 6 #define _LOW(v)         ( (v) & 0377)           // 取低字节（8 进制表示）。
 7 #define _HIGH(v)        ( ((v) >> 8) & 0377)    // 取高字节。
 8
 9 /* options for waitpid, WUNTRACED not supported */
   /* waitpid 的选项，其中 WUNTRACED 未被支持 */
   // [ 注：其实 0.11 内核已经支持 WUNTRACED 选项。上面这条注释应该是以前内核版本遗留下来的。 ]
   // 以下常数符号是函数 waitpid(pid_t pid, long *stat_addr, int options)中 options 使用的选项。
10 #define WNOHANG         1       // 如果没有状态也不要挂起，并立刻返回。
11 #define WUNTRACED       2       // 报告停止执行的子进程状态。
12
   // 以下宏定义用于判断 waitpid()函数返回的状态字含义。
13 #define WIFEXITED(s)    (!((s)&0xFF)        // 如果子进程正常退出，则为真。
14 #define WIFSTOPPED(s)   (((s)&0xFF)==0x7F) // 如果子进程正停止着，则为 true。
15 #define WEXITSTATUS(s)  (((s)>>8)&0xFF)     // 返回退出状态。
16 #define WTERMSIG(s)     ((s)&0x7F)          // 返回导致进程终止的信号值（信号量）。
17 #define WSTOPSIG(s)     (((s)>>8)&0xFF)     // 返回导致进程停止的信号值。
18 #define WIFSIGNALED(s)  (((unsigned int)(s)-1 & 0xFFFF) < 0xFF) // 如果由于未捕捉到信号
                                                                   // 而导致子进程退出则为真。
19
   // wait()和 waitpit()函数允许进程获取与其子进程之一的状态信息。各种选项允许获取已经终止或
   // 停止的子进程状态信息。如果存在两个或两个以上子进程的状态信息，则报告的顺序是不指定的。
   // wait()将挂起当前进程，直到其子进程之一退出（终止），或者收到要求终止该进程的信号，
```

```
    // 或者是需要调用一个信号句柄（信号处理程序）。
    // waitpid()挂起当前进程，直到 pid 指定的子进程退出（终止）或者收到要求终止该进程的信号，
    // 或者是需要调用一个信号句柄（信号处理程序）。
    // 如果 pid=-1，options=0，则 waitpid()的作用与 wait()函数一样。否则其行为将随 pid 和 options
    // 参数的不同而不同。（参见 kernel/exit.c,142）
20  pid_t wait(int *stat_loc);
21  pid_t waitpid(pid_t pid, int *stat_loc, int options);
22
23  #endif
24
```

第12章 库文件(lib)

12.1 概述

c 语言的函数库（library）文件是一些可重用程序模块集合，而 Linux 内核库文件则是编译时专门供内核使用的一些内核常用函数的组合。下面列表中的 c 文件就是构成内核库文件中模块的程序，主要包括退出函数_exit()、关闭文件函数 close()、复制文件描述符函数 dup()、文件打开函数 open()、写文件函数 write()、执行程序函数 execve()、内存分配函数 malloc()、等待子进程状态函数 wait()、创建会话系统调用 setsid()以及在 include/string.h 中实现的所有字符串操作函数。

除了一个由 Tytso 编制的 malloc.c 程序较长以外，其他程序都什么短小，有的只有一二行代码。基本都是直接调用系统中断调用实现其功能。

列表 12-1 /linux/lib/目录中的文件

	文件名	文件长度	最后修改时间 (GMT)	说明
	Makefile	2602 bytes	1991-12-02 03:16:05	
	_exit.c	198 bytes	1991-10-02 14:16:29	
	close.c	131 bytes	1991-10-02 14:16:29	
	ctype.c	1202 bytes	1991-10-02 14:16:29	
	dup.c	127 bytes	1991-10-02 14:16:29	
	errno.c	73 bytes	1991-10-02 14:16:29	
	execve.c	170 bytes	1991-10-02 14:16:29	
	malloc.c	7469 bytes	1991-12-02 03:15:20	
	open.c	389 bytes	1991-10-02 14:16:29	
	setsid.c	128 bytes	1991-10-02 14:16:29	
	string.c	177 bytes	1991-10-02 14:16:29	
	wait.c	253 bytes	1991-10-02 14:16:29	
	write.c	160 bytes	1991-10-02 14:16:29	

在编译内核阶段，Makefile 中的相关指令会把以上这些程序编译成.o 模块，然后组建成 lib.a 库文件形式并链接到内核模块中。与通常编译环境提供的各种库文件不同（例如 libc.a、libufc.a 等），这个库中的函数主要用于内核初始化阶段的 init/main.c 程序，为其在用户态执行的 init()函数提供支持。因此所包含的函数很少，也特别简单。但它与一般库文件的实现方式完全相同。

创建函数库通常使用命令 ar（archive – 归档缩写）。例如要创建一个含有 3 个模块 a.o、b.o 和 c.o 的函数库 libmine.a，则需要执行如下命令：

ar -rc libmine.a a.o b.o c.o d.o

若要往这个库文件中添加函数模块 dup.o，则可执行以下命令

ar -rs dup.o

12.2 Makefile 文件

12.2.1 功能描述

组建内核函数库的 Makefile 文件。

12.2.2 代码注释

程序 12-1 linux/lib/Makefile

```
 1 #
 2 # Makefile for some libs needed in the kernel.
 3 #
 4 # Note! Dependencies are done automagically by 'make dep', which also
 5 # removes any old dependencies. DON'T put your own dependencies here
 6 # unless it's something special (ie not a .c file).
 7 #
   # 内核需要用到的 libs 库文件程序的 Makefile。
   #
   # 注意！依赖关系是由'make dep'自动进行的，它也会自动去除原来的依赖信息。不要把你自己的
   # 依赖关系信息放在这里，除非是特别文件的（也即不是一个.c 文件的信息）。
 8
 9 AR       =gar    # GNU 的二进制文件处理程序，用于创建、修改以及从归档文件中抽取文件。
10 AS       =gas    # GNU 的汇编程序。
11 LD       =gld    # GNU 的连接程序。
12 LDFLAGS =-s -x  # 连接程序所有的参数，-s 输出文件中省略所有符号信息。-x 删除所有局部符号。
13 CC       =gcc    # GNU C 语言编译器。
14 CFLAGS  =-Wall -O -fstrength-reduce -fomit-frame-pointer -fcombine-regs \
15         -finline-functions -mstring-insns -nostdinc -I../include
   # C 编译程序选项。-Wall 显示所有的警告信息；-O 优化选项，优化代码长度和执行时间；
   # -fstrength-reduce 优化循环执行代码，排除重复变量；-fomit-frame-pointer 省略保存不必要
   # 的框架指针；-fcombine-regs 合并寄存器，减少寄存器类的使用；-finline-functions 将所有简
   # 单短小的函数代码嵌入调用程序中；-mstring-insns Linus 自己填加的优化选项，以后不再使用；
   # -nostdinc -I../include 不使用默认路径中的包含文件，而使用这里指定目录中的(../include)。

16 CPP      =gcc -E -nostdinc -I../include
   # C 前处理选项。-E 只运行 C 前处理，对所有指定的 C 程序进行预处理并将处理结果输出到标准输
   # 出设备或指定的输出文件中；-nostdinc -I../include 同前。
17
   # 下面的规则指示 make 利用下面的命令将所有的.c 文件编译生成.s 汇编程序。该规则的命令
   # 指使 gcc 采用 CFLAGS 所指定的选项对 C 代码编译后不进行汇编就停止（-S），从而产生与
   # 输入的各个 C 文件对应的汇编代码文件。默认情况下所产生的汇编程序文件名是原 C 文件名
   # 去掉.c 而加上.s 后缀。-o 表示其后是输出文件的名称。其中$*.s（或$@）是自动目标变量，
   # $<代表第一个先决条件，这里即是符合条件*.c 的文件。
18 .c.s:
19         $(CC) $(CFLAGS) \
20         -S -o $*.s $<
  # 下面规则表示将所有.s 汇编程序文件编译成.o 目标文件。22 行是实现该操作的具体命令。
21 .s.o:
22         $(AS) -c -o $*.o $<
23 .c.o:                      # 类似上面，*.c 文件-→*.o 目标文件。不进行连接。
24         $(CC) $(CFLAGS) \
```

```
25          -c -o $*.o $<
26
    # 下面定义目标文件变量 OBJS。
27  OBJS  = ctype.o _exit.o open.o close.o errno.o write.o dup.o setsid.o \
28          execve.o wait.o string.o malloc.o
29
    # 在有了先决条件 OBJS 后使用下面的命令连接成目标 lib.a 库文件。
30  lib.a: $(OBJS)
31          $(AR) rcs lib.a $(OBJS)
32          sync
33
     # 下面的规则用于清理工作。当执行'make clean'时，就会执行下面的命令，去除所有编译
     # 连接生成的文件。'rm'是文件删除命令，选项-f 含义是忽略不存在的文件，并且不显示删除信息。
34  clean:
35          rm -f core *.o *.a tmp_make
36          for i in *.c;do rm -f `basename $$i .c`.s;done
37
     # 下面得目标或规则用于检查各文件之间的依赖关系。方法如下：
     # 使用字符串编辑程序 sed 对 Makefile 文件（即是本文件）进行处理，输出为删除 Makefile
     # 文件中'### Dependencies'行后面的所有行（下面从 45 开始的行），并生成 tmp_make
     # 临时文件（39 行的作用）。然后对 kernel/blk_drv/目录下的每个 C 文件执行 gcc 预处理操作.
     # -M 标志告诉预处理程序输出描述每个目标文件相关性的规则，并且这些规则符合 make 语法。
     # 对于每一个源文件，预处理程序输出一个 make 规则，其结果形式是相应源程序文件的目标
     # 文件名加上其依赖关系--该源文件中包含的所有头文件列表。把预处理结果都添加到临时
     # 文件 tmp_make 中，然后将该临时文件复制成新的 Makefile 文件。
38  dep:
39          sed '/\#\#\# Dependencies/q' < Makefile > tmp_make
40          (for i in *.c;do echo -n `echo $$i | sed 's,\.c,\.s,'`" "; \
41                  $(CPP) -M $$i;done) >> tmp_make
42          cp tmp_make Makefile
43
44  ### Dependencies:
45  _exit.s _exit.o : _exit.c ../include/unistd.h ../include/sys/stat.h \
46    ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
47    ../include/utime.h
48  close.s close.o : close.c ../include/unistd.h ../include/sys/stat.h \
49    ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
50    ../include/utime.h
51  ctype.s ctype.o : ctype.c ../include/ctype.h
52  dup.s dup.o : dup.c ../include/unistd.h ../include/sys/stat.h \
53    ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
54    ../include/utime.h
55  errno.s errno.o : errno.c
56  execve.s execve.o : execve.c ../include/unistd.h ../include/sys/stat.h \
57    ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
58    ../include/utime.h
59  malloc.s malloc.o : malloc.c ../include/linux/kernel.h ../include/linux/mm.h \
60    ../include/asm/system.h
61  open.s open.o : open.c ../include/unistd.h ../include/sys/stat.h \
62    ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
63    ../include/utime.h ../include/stdarg.h
64  setsid.s setsid.o : setsid.c ../include/unistd.h ../include/sys/stat.h \
65    ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
```

```
66   ../include/utime.h
67 string.s string.o : string.c ../include/string.h
68 wait.s wait.o : wait.c ../include/unistd.h ../include/sys/stat.h \
69   ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
70   ../include/utime.h ../include/sys/wait.h
71 write.s write.o : write.c ../include/unistd.h ../include/sys/stat.h \
72   ../include/sys/types.h ../include/sys/times.h ../include/sys/utsname.h \
73   ../include/utime.h
```

12.3 _exit.c 程序

12.3.1 功能描述

程序调用内核的退出系统调用函数。

12.3.2 代码注释

程序 12-2 linux/lib/_exit.c

```
1 /*
2  *  linux/lib/_exit.c
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
7 #define __LIBRARY__         // 定义一个符号常量，见下行说明。
8 #include <unistd.h>         // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                              // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编 syscall0()等。
9
  //// 内核使用的程序(退出)终止函数。
  // 直接调用系统中断 int 0x80，功能号__NR_exit。
  // 参数：exit_code - 退出码。
10 volatile void _exit(int exit_code)
11 {
  // %0 - eax(系统调用号__NR_exit)；%1 - ebx(退出码 exit_code)。
12         __asm__("int $0x80"::"a" (__NR_exit),"b" (exit_code));
13 }
14
```

12.3.3 相关信息

参见 include/unistd.h 中的说明。

12.4 close.c 程序

12.4.1 功能描述

12.4.2 代码注释

程序 12-3 linux/lib/close.c

```
 1 /*
 2  *  linux/lib/close.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #define __LIBRARY__
 8 #include <unistd.h>        // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                              // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编 syscall0()等。
 9
   // 关闭文件函数。
   // 下面该调用宏函数对应：int close(int fd)。直接调用了系统中断 int 0x80，参数是__NR_close。
   // 其中 fd 是文件描述符。
10 _syscall1(int,close,int,fd)
11
```

12.5 ctype.c 程序

12.5.1 功能描述

该程序用于为 ctype.h 提供辅助的数组结构数据，用于对字符进行类型判断。

12.5.2 代码注释

程序 12-4 linux/lib/ctype.c

```
 1 /*
 2  *  linux/lib/ctype.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #include <ctype.h>         // 字符类型头文件。定义了一些有关字符类型判断和转换的宏。
 8
 9 char _ctmp;                // 一个临时字符变量，供 ctype.h 文件中转换字符宏函数使用。
   // 字符特性数组(表)，定义了各个字符对应的属性，这些属性类型(如_C 等)在 ctype.h 中定义。
   // 用于判断字符是控制字符(_C)、大写字符(_U)、小写字符(_L)等所属类型。
10 unsigned char _ctype[] = {0x00,                    /* EOF */
11 _C, _C, _C, _C, _C, _C, _C, _C,                   /* 0-7 */
12 _C, _C|_S, _C|_S, _C|_S, _C|_S, _C|_S, _C, _C,    /* 8-15 */
13 _C, _C, _C, _C, _C, _C, _C, _C,                   /* 16-23 */
14 _C, _C, _C, _C, _C, _C, _C, _C,                   /* 24-31 */
15 _S|_SP, _P, _P, _P, _P, _P, _P, _P,               /* 32-39 */
16 _P, _P, _P, _P, _P, _P, _P, _P,                   /* 40-47 */
17 _D, _D, _D, _D, _D, _D, _D, _D,                   /* 48-55 */
18 _D, _D, _P, _P, _P, _P, _P, _P,                   /* 56-63 */
```

```
 _P, _U| _X, _U| _X, _U| _X, _U| _X, _U| _X, _U| _X, _U,      /* 64-71 */
 _U, _U, _U, _U, _U, _U, _U, _U,                             /* 72-79 */
 _U, _U, _U, _U, _U, _U, _U, _U,                             /* 80-87 */
 _U, _U, _U, _P, _P, _P, _P, _P,                             /* 88-95 */
 _P, _L| _X, _L| _X, _L| _X, _L| _X, _L| _X, _L| _X, _L,     /* 96-103 */
 _L, _L, _L, _L, _L, _L, _L, _L,                             /* 104-111 */
 _L, _L, _L, _L, _L, _L, _L, _L,                             /* 112-119 */
 _L, _L, _L, _P, _P, _P, _P, _C,                             /* 120-127 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,             /* 128-143 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,             /* 144-159 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,             /* 160-175 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,             /* 176-191 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,             /* 192-207 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,             /* 208-223 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,             /* 224-239 */
 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0};            /* 240-255 */

```

12.6 dup.c 程序

12.6.1 功能描述

该程序包括一个创建文件描述符拷贝的函数 dup()。在成功返回之后，新的和原来的描述符可以交替使用。它们共享锁定、文件读写指针以及文件标志。例如，如果文件读写位置指针被其中一个描述符使用 lseek()修改过之后，则对于另一个描述符来讲，文件读写指针也被改变。该函数使用数值最小的未使用描述符来建立新描述符。但是这两个描述符并不共享执行时关闭标志(close-on-exec)。

12.6.2 代码注释

程序 12-5 linux/lib/dup.c

```
/*
 *  linux/lib/dup.c
 *
 *  (C) 1991  Linus Torvalds
 */

#define __LIBRARY__
#include <unistd.h>        // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                           // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编_syscall0()等。

//// 复制文件描述符函数。
// 下面该调用宏函数对应：int dup(int fd)。直接调用了系统中断 int 0x80，参数是__NR_dup。
// 其中 fd 是文件描述符。
_syscall1(int,dup,int,fd)

```

12.7 errno.c 程序

12.7.1 功能描述

该程序仅定义了一个出错号变量 errno。用于在函数调用失败时存放出错号。请参考 include/errno.h 文件。

12.7.2 代码注释

程序 12-6 linux/lib/errno.c

```
1 /*
2  *  linux/lib/errno.c
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
7 int errno;
8
```

12.8 execve.c 程序

12.8.1 功能描述

运行执行程序的系统调用函数。

12.8.2 代码注释

程序 12-7 linux/lib/execve.c

```
1 /*
2  *  linux/lib/execve.c
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
7 #define __LIBRARY__
8 #include <unistd.h>        // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                             // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编_syscall0()等。
9
  //// 加载并执行子进程(其他程序)函数。
  // 下面该调用宏函数对应：int execve(const char * file, char ** argv, char ** envp)。
  // 参数：file - 被执行程序文件名；argv - 命令行参数指针数组；envp - 环境变量指针数组。
  // 直接调用了系统中断 int 0x80，参数是__NR_execve。参见 include/unistd.h 和 fs/exec.c 程序。
10 _syscall3(int,execve,const char *,file,char **,argv,char **,envp)
11
```

12.9 malloc.c 程序

12.9.1 功能描述

该程序中主要包括内存分配函数 malloc()。为了不与用户程序使用的 malloc()函数相混淆，从内核 0.98 版以后就该名为 kmalloc()，而 free_s()函数改名为 kfree_s()。

malloc()函数使用了存储桶(bucket)的原理对分配的内存进行管理。基本思想是对不同请求的内存块大小(长度)，使用存储桶目录(下面简称目录)分别进行处理。比如对于请求内存块的长度在 32 字节或 32 字节以下但大于 16 字节时，就使用存储桶目录第二项对应的存储桶描述符链表分配内存块。其基本结构示意图见图 12-1 所示。该函数目前一次所能分配的最大内存长度是一个内存页面，即 4096 字节。

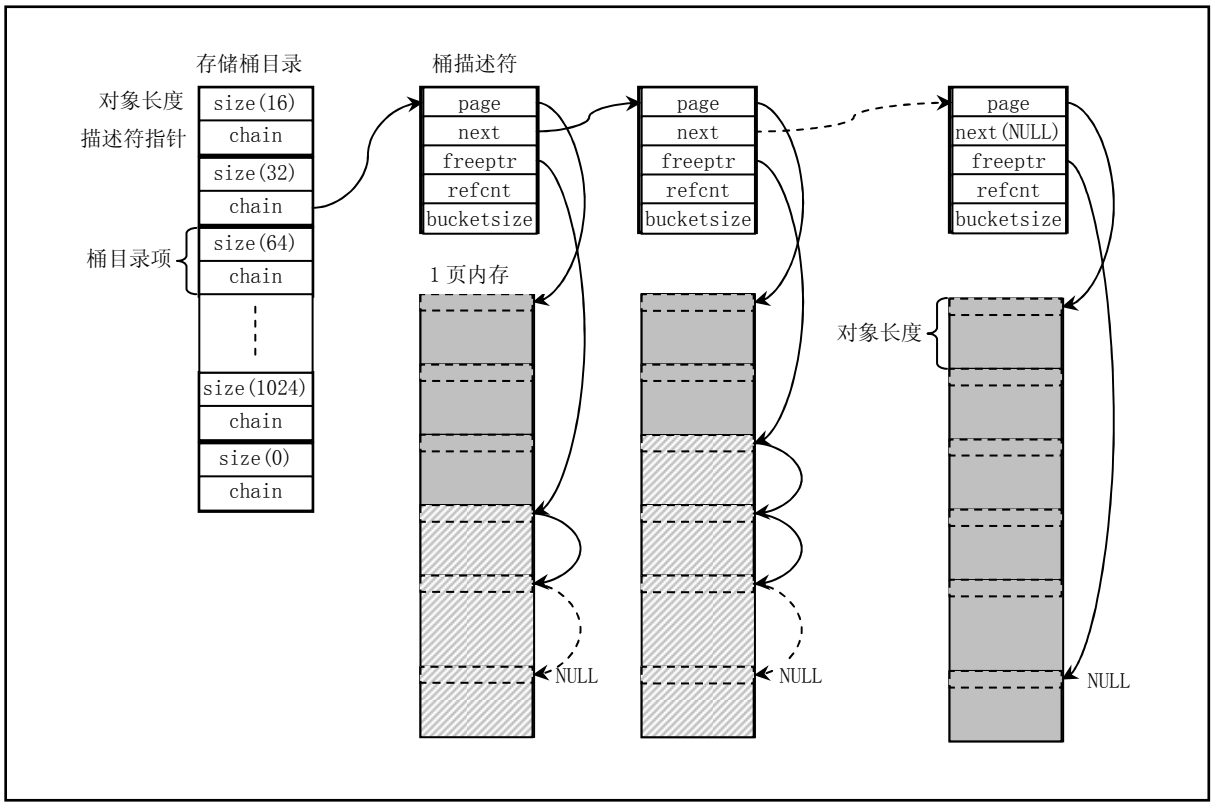

图 12-1 使用存储桶原理进行内存分配管理的结构示意图

在第一次调用 malloc()函数时，首先要建立一个页面的空闲存储桶描述符(下面简称描述符)链表，其中存放着还未使用或已经使用完毕而收回的描述符。该链表结构示意图见图 12-2 所示。其中 free_bucket_desc 是链表头指针。从链表中取出或放入一个描述符都是从链表头开始操作。当取出一个描述符时，就将链表头指针所指向的头一个描述符取出；当释放一个空闲描述符时也是将其放在链表头处。

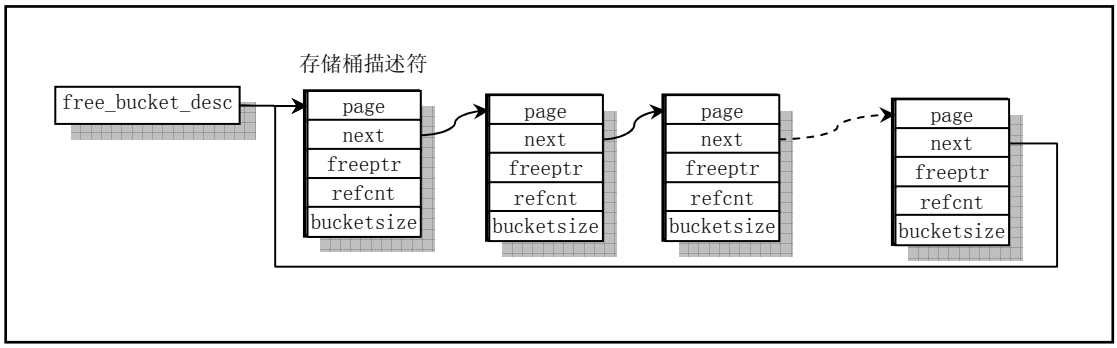

图 12-2 空闲存储桶描述符链表结构示意图

malloc()函数执行的基本步骤如下：

1. 首先搜索目录，寻找适合请求内存块大小的目录项对应的描述符链表。当目录项的对象字节长度大于请求的字节长度，就算找到了相应的目录项。如果搜索完整个目录都没有找到合适的目录项，则说明用户请求的内存块太大。
2. 在目录项对应的描述符链表中查找具有空闲空间的描述符。如果某个描述符的空闲内存指针 freeptr 不为 NULL，则表示找到了相应的描述符。如果没有找到具有空闲空间的描述符，那么我们就需要新建一个描述符。新建描述符的过程如下：
   a. 如果空闲描述符链表头指针还是 NULL 的话，说明是第一次调用 malloc()函数，此时需要 init_bucket_desc()来创建空闲描述符链表。
   b. 然后从空闲描述符链表头处取一个描述符，初始化该描述符，令其对象引用计数为 0，对象大小等于对应目录项指定对象的长度值，并申请一内存页面，让描述符的页面指针 page 指向该内存页，描述符的空闲内存指针 freeptr 也指向页开始位置。
   c. 对该内存页面根据本目录项所用对象长度进行页面初始化，建立所有对象的一个链表。也即每个对象的头部都存放一个指向下一个对象的指针，最后一个对象的开始处存放一个 NULL 指针值。
   d. 然后将该描述符插入到对应目录项的描述符链表开始处。
3. 将该描述符的空闲内存指针 freeptr 复制为返回给用户的内存指针，然后调整该 freeptr 指向描述符对应内存页面中下一个空闲对象位置，并使该描述符引用计数值增 1。

free_s()函数用于回收用户释放的内存块。基本原理是首先根据该内存块的地址换算出该内存块对应页面的地址(用页面长度进行模运算)，然后搜索目录中的所有描述符，找到对应该页面的描述符。将该释放的内存块链入 freeptr 所指向的空闲对象链表中，并将描述符的对象引用计数值减 1。如果引用计数值此时等于零，则表示该描述符对应的页面已经完全空出，可以释放该内存页面并将该描述符收回到空闲描述符链表中。

12.9.2 代码注释

程序 12-8 linux/lib/malloc.c

```
1  /*
2   * malloc.c --- a general purpose kernel memory allocator for Linux.
3   *
4   * Written by Theodore Ts'o (tytso@mit.edu), 11/29/91
5   *
6   * This routine is written to be as fast as possible, so that it
7   * can be called from the interrupt level.
8   *
9   * Limitations: maximum size of memory we can allocate using this routine
10  *      is 4k, the size of a page in Linux.
```

```
 *
 * The general game plan is that each page (called a bucket) will only hold
 * objects of a given size.  When all of the object on a page are released,
 * the page can be returned to the general free pool.  When malloc() is
 * called, it looks for the smallest bucket size which will fulfill its
 * request, and allocate a piece of memory from that bucket pool.
 *
 * Each bucket has as its control block a bucket descriptor which keeps
 * track of how many objects are in use on that page, and the free list
 * for that page.  Like the buckets themselves, bucket descriptors are
 * stored on pages requested from get_free_page().  However, unlike buckets,
 * pages devoted to bucket descriptor pages are never released back to the
 * system.  Fortunately, a system should probably only need 1 or 2 bucket
 * descriptor pages, since a page can hold 256 bucket descriptors (which
 * corresponds to 1 megabyte worth of bucket pages.)  If the kernel is using
 * that much allocated memory, it's probably doing something wrong.  :-)
 *
 * Note: malloc() and free() both call get_free_page() and free_page()
 *      in sections of code where interrupts are turned off, to allow
 *      malloc() and free() to be safely called from an interrupt routine.
 *      (We will probably need this functionality when networking code,
 *      particularily things like NFS, is added to Linux.)  However, this
 *      presumes that get_free_page() and free_page() are interrupt-level
 *      safe, which they may not be once paging is added.  If this is the
 *      case, we will need to modify malloc() to keep a few unused pages
 *      "pre-allocated" so that it can safely draw upon those pages if
 *      it is called from an interrupt routine.
 *
 *      Another concern is that get_free_page() should not sleep; if it
 *      does, the code is carefully ordered so as to avoid any race
 *      conditions.  The catch is that if malloc() is called re-entrantly,
 *      there is a chance that unecessary pages will be grabbed from the
 *      system.  Except for the pages for the bucket descriptor page, the
 *      extra pages will eventually get released back to the system, though,
 *      so it isn't all that bad.
 */

/*
 *     malloc.c - Linux 的通用内核内存分配函数。
 *
 * 由 Theodore Ts'o 编制 (tytso@mit.edu), 11/29/91
 *
 * 该函数被编写成尽可能地快，从而可以从中断层调用此函数。
 *
 * 限制：使用该函数一次所能分配的最大内存是 4k，也即 Linux 中内存页面的大小。
 *
 * 编写该函数所遵循的一般规则是每页(被称为一个存储桶)仅分配所要容纳对象的大小。
 * 当一页上的所有对象都释放后，该页就可以返回通用空闲内存池。当 malloc()被调用
 * 时，它会寻找满足要求的最小的存储桶，并从该存储桶中分配一块内存。
 *
 * 每个存储桶都有一个作为其控制用的存储桶描述符，其中记录了页面上有多少对象正被
 * 使用以及该页上空闲内存的列表。就象存储桶自身一样，存储桶描述符也是存储在使用
 * get_free_page()申请到的页面上的，但是与存储桶不同的是，桶描述符所占用的页面
```

```
 * 将不再会释放给系统。幸运的是一个系统大约只需要 1 到 2 页的桶描述符页面，因为一
 * 个页面可以存放 256 个桶描述符(对应 1MB 内存的存储桶页面)。如果系统为桶描述符分
 * 配了许多内存，那么肯定系统什么地方出了问题☺。
 *
 * 注意！ malloc()和 free()两者关闭了中断的代码部分都调用了 get_free_page()和
 *       free_page()函数，以使 malloc()和 free()可以安全地被从中断程序中调用
 *       (当网络代码，尤其是 NFS 等被加入到 Linux 中时就可能需要这种功能)。但前
 *       提是假设 get_free_page()和 free_page()是可以安全地在中断级程序中使用的，
 *       这在一旦加入了分页处理之后就可能不是安全的。如果真是这种情况，那么我们
 *       就需要修改 malloc()来“预先分配”几页不用的内存，如果 malloc()和 free()
 *       被从中断程序中调用时就可以安全地使用这些页面。
 *
 *       另外需要考虑到的是 get_free_page()不应该睡眠；如果会睡眠的话，则为了防止
 *       任何竞争条件，代码需要仔细地安排顺序。 关键在于如果 malloc()是可以重入地
 *       被调用的话，那么就会存在不必要的页面被从系统中取走的机会。除了用于桶描述
 *       符的页面，这些额外的页面最终会释放给系统，所以并不是象想象的那样不好。
 */

#include <linux/kernel.h> // 内核头文件。含有一些内核常用函数的原形定义。
#include <linux/mm.h>     // 内存管理头文件。含有页面大小定义和一些页面释放函数原型。
#include <asm/system.h>   // 系统头文件。定义了设置或修改描述符/中断门等的嵌入式汇编宏。

// 存储桶描述符结构。
struct bucket_desc {    /* 16 bytes */
        void                    *page;          // 该桶描述符对应的内存页面指针。
        struct bucket_desc      *next;          // 下一个描述符指针。
        void                    *freeptr;       // 指向本桶中空闲内存位置的指针。
        unsigned short          refcnt;         // 引用计数。
        unsigned short          bucket_size;    // 本描述符对应存储桶的大小。
};

// 存储桶描述符目录结构。
struct _bucket_dir {    /* 8 bytes */
        int                     size;       // 该存储桶的大小(字节数)。
        struct bucket_desc      *chain;     // 该存储桶目录项的桶描述符链表指针。
};

/*
 * The following is the where we store a pointer to the first bucket
 * descriptor for a given size.
 *
 * If it turns out that the Linux kernel allocates a lot of objects of a
 * specific size, then we may want to add that specific size to this list,
 * since that will allow the memory to be allocated more efficiently.
 * However, since an entire page must be dedicated to each specific size
 * on this list, some amount of temperance must be exercised here.
 *
 * Note that this list *must* be kept in order.
 */
/*
 * 下面是我们存放第一个给定大小存储桶描述符指针的地方。
 *
 * 如果 Linux 内核分配了许多指定大小的对象，那么我们就希望将该指定的大小加到
```

```
 * 该列表(链表)中，因为这样可以使内存的分配更有效。但是，因为一页完整内存页面
 * 必须用于列表中指定大小的所有对象，所以需要做总数方面的测试操作。
 */
// 存储桶目录列表(数组)。
struct _bucket_dir bucket_dir[] = {
        { 16,   (struct bucket_desc *) 0},    // 16 字节长度的内存块。
        { 32,   (struct bucket_desc *) 0},    // 32 字节长度的内存块。
        { 64,   (struct bucket_desc *) 0},    // 64 字节长度的内存块。
        { 128,  (struct bucket_desc *) 0},    // 128 字节长度的内存块。
        { 256,  (struct bucket_desc *) 0},    // 256 字节长度的内存块。
        { 512,  (struct bucket_desc *) 0},    // 512 字节长度的内存块。
        { 1024, (struct bucket_desc *) 0},    // 1024 字节长度的内存块。
        { 2048, (struct bucket_desc *) 0},    // 2048 字节长度的内存块。
        { 4096, (struct bucket_desc *) 0},    // 4096 字节(1 页)内存。
        { 0,    (struct bucket_desc *) 0}};   /* End of list marker */

/*
 * This contains a linked list of free bucket descriptor blocks
 */
/*
 * 下面是含有空闲桶描述符内存块的链表。
 */
struct bucket_desc *free_bucket_desc = (struct bucket_desc *) 0;

/*
 * This routine initializes a bucket description page.
 */
/*
 * 下面的子程序用于初始化一页桶描述符页面。
 */
//// 初始化桶描述符。
// 建立空闲桶描述符链表，并让 free_bucket_desc 指向第一个空闲桶描述符。
static inline void init_bucket_desc()
{
        struct bucket_desc *bdesc, *first;
        int     i;

// 申请一页内存，用于存放桶描述符。如果失败，则显示初始化桶描述符时内存不够出错信息，死机。
        first = bdesc = (struct bucket_desc *) get_free_page();
        if (!bdesc)
                panic("Out of memory in init_bucket_desc()");
// 首先计算一页内存中可存放的桶描述符数量，然后对其建立单向连接指针。
        for (i = PAGE_SIZE/sizeof(struct bucket_desc); i > 1; i--) {
                bdesc->next = bdesc+1;
                bdesc++;
        }
        /*
         * This is done last, to avoid race conditions in case
         * get_free_page() sleeps and this routine gets called again....
         */
        /*
         * 这是在最后处理的，目的是为了避免在 get_free_page()睡眠时该子程序又被
         * 调用而引起的竞争条件。
```

```
 */
    // 将空闲桶描述符指针 free_bucket_desc 加入链表中。
113         bdesc->next = free_bucket_desc;
114         free_bucket_desc = first;
115 }
116
    //// 分配动态内存函数。
    // 参数：len - 请求的内存块长度。
    // 返回：指向被分配内存的指针。如果失败则返回 NULL。
117 void *malloc(unsigned int len)
118 {
119         struct _bucket_dir      *bdir;
120         struct bucket_desc      *bdesc;
121         void                    *retval;
122
123         /*
124          * First we search the bucket_dir to find the right bucket change
125          * for this request.
126          */
            /*
             * 首先我们搜索存储桶目录 bucket_dir 来寻找适合请求的桶大小。
             */
    // 搜索存储桶目录，寻找适合申请内存块大小的桶描述符链表。如果目录项的桶字节数大于请求的字节
    // 数，就找到了对应的桶目录项。
127         for (bdir = bucket_dir; bdir->size; bdir++)
128                 if (bdir->size >= len)
129                         break;
    // 如果搜索完整个目录都没有找到合适大小的目录项，则表明所请求的内存块大小太大，超出了该
    // 程序的分配限制(最长为 1 个页面)。于是显示出错信息，死机。
130         if (!bdir->size) {
131                 printk("malloc called with impossibly large argument (%d)\n",
132                         len);
133                 panic("malloc: bad arg");
134         }
135         /*
136          * Now we search for a bucket descriptor which has free space
137          */
            /*
             * 现在我们来搜索具有空闲空间的桶描述符。
             */
138         cli();  /* Avoid race conditions */  /* 为了避免出现竞争条件，首先关中断 */
    // 搜索对应桶目录项中描述符链表，查找具有空闲空间的桶描述符。如果桶描述符的空闲内存指针
    // freeptr 不为空，则表示找到了相应的桶描述符。
139         for (bdesc = bdir->chain; bdesc; bdesc = bdesc->next)
140                 if (bdesc->freeptr)
141                         break;
142         /*
143          * If we didn't find a bucket with free space, then we'll
144          * allocate a new one.
145          */
            /*
             * 如果没有找到具有空闲空间的桶描述符，那么我们就要新建立一个该目录项的描述符。
             */
```

```
146         if (!bdesc) {
147                 char            *cp;
148                 int             i;
149
    // 若 free_bucket_desc 还为空时，表示第一次调用该程序，则对描述符链表进行初始化。
    // free_bucket_desc 指向第一个空闲桶描述符。
150                 if (!free_bucket_desc)
151                         init_bucket_desc();
    // 取 free_bucket_desc 指向的空闲桶描述符，并让 free_bucket_desc 指向下一个空闲桶描述符。
152                 bdesc = free_bucket_desc;
153                 free_bucket_desc = bdesc->next;
    // 初始化该新的桶描述符。令其引用数量等于 0；桶的大小等于对应桶目录的大小；申请一内存页面，
    // 让描述符的页面指针 page 指向该页面；空闲内存指针也指向该页开头，因为此时全为空闲。
154                 bdesc->refcnt = 0;
155                 bdesc->bucket_size = bdir->size;
156                 bdesc->page = bdesc->freeptr = (void *) cp = get_free_page();
    // 如果申请内存页面操作失败，则显示出错信息，死机。
157                 if (!cp)
158                         panic("Out of memory in kernel malloc()");
159                 /* Set up the chain of free objects */
                    /* 在该页空闲内存中建立空闲对象链表 */
    // 以该桶目录项指定的桶大小为对象长度，对该页内存进行划分，并使每个对象的开始 4 字节设置
    // 成指向下一对象的指针。
160                 for (i=PAGE_SIZE/bdir->size; i > 1; i--) {
161                         *((char **) cp) = cp + bdir->size;
162                         cp += bdir->size;
163                 }
    // 最后一个对象开始处的指针设置为 0(NULL)。
    // 然后让该桶描述符的下一描述符指针字段指向对应桶目录项指针 chain 所指的描述符，而桶目录的
    // chain 指向该桶描述符，也即将该描述符插入到描述符链链头处。
164                 *((char **) cp) = 0;
165                 bdesc->next = bdir->chain; /* OK, link it in! */   /* OK，将其链入！*/
166                 bdir->chain = bdesc;
167         }
    // 返回指针即等于该描述符对应页面的当前空闲指针。然后调整该空闲空间指针指向下一个空闲对象，
    // 并使描述符中对应页面中对象引用计数增 1。
168         retval = (void *) bdesc->freeptr;
169         bdesc->freeptr = *((void **) retval);
170         bdesc->refcnt++;
    // 最后开放中断，并返回指向空闲内存对象的指针。
171         sti();  /* OK, we're safe again */   /* OK，现在我们又安全了*/
172         return(retval);
173 }
174
175 /*
176  * Here is the free routine.  If you know the size of the object that you
177  * are freeing, then free_s() will use that information to speed up the
178  * search for the bucket descriptor.
179  *
180  * We will #define a macro so that "free(x)" is becomes "free_s(x, 0)"
181  */
    /*
     * 下面是释放子程序。如果你知道释放对象的大小，则 free_s()将使用该信息加速
```

```
 * 搜寻对应桶描述符的速度。
 *
 * 我们将定义一个宏，使得"free(x)"成为"free_s(x, 0)"。
 */
//// 释放存储桶对象。
// 参数：obj - 对应对象指针；size - 大小。
182 void free_s(void *obj, int size)
183 {
184         void            *page;
185         struct _bucket_dir      *bdir;
186         struct bucket_desc      *bdesc, *prev;
187
188         /* Calculate what page this object lives in */
            /* 计算该对象所在的页面 */
189         page = (void *)  ((unsigned long) obj & 0xfffff000);
190         /* Now search the buckets looking for that page */
            /* 现在搜索存储桶目录项所链接的桶描述符，寻找该页面 */
//
191         for (bdir = bucket_dir; bdir->size; bdir++) {
192                 prev = 0;
193                 /* If size is zero then this conditional is always false */
                    /* 如果参数 size 是 0，则下面条件肯定是 false */
194                 if (bdir->size < size)
195                         continue;
// 搜索对应目录项中链接的所有描述符，查找对应页面。如果某描述符页面指针等于 page 则表示找到
// 了相应的描述符，跳转到 found。如果描述符不含有对应 page，则让描述符指针 prev 指向该描述符。
196                 for (bdesc = bdir->chain; bdesc; bdesc = bdesc->next) {
197                         if (bdesc->page == page)
198                                 goto found;
199                         prev = bdesc;
200                 }
201         }
// 若搜索了对应目录项的所有描述符都没有找到指定的页面，则显示出错信息，死机。
202         panic("Bad address passed to kernel free_s()");
203 found:
// 找到对应的桶描述符后，首先关中断。然后将该对象内存块链入空闲块对象链表中，并使该描述符
// 的对象引用计数减 1。
204         cli(); /* To avoid race conditions */   /* 为了避免竞争条件 */
205         *((void **)obj) = bdesc->freeptr;
206         bdesc->freeptr = obj;
207         bdesc->refcnt--;
// 如果引用计数已等于 0，则我们就可以释放对应的内存页面和该桶描述符。
208         if (bdesc->refcnt == 0) {
209                 /*
210                  * We need to make sure that prev is still accurate.  It
211                  * may not be, if someone rudely interrupted us....
212                  */
                /*
                 * 我们需要确信 prev 仍然是正确的，若某程序粗鲁地中断了我们
                 * 就有可能不是了。
                 */
// 如果 prev 已经不是搜索到的描述符的前一个描述符，则重新搜索当前描述符的前一个描述符。
213                 if ((prev && (prev->next != bdesc)) ||
```

```
214                     (!prev && (bdir->chain != bdesc)))
215                         for (prev = bdir->chain; prev; prev = prev->next)
216                                 if (prev->next == bdesc)
217                                         break;
    // 如果找到该前一个描述符，则从描述符链中删除当前描述符。
218                 if (prev)
219                         prev->next = bdesc->next;
    // 如果 prev==NULL，则说明当前一个描述符是该目录项首个描述符，也即目录项中 chain 应该直接
    // 指向当前描述符 bdesc，否则表示链表有问题，则显示出错信息，死机。因此，为了将当前描述符
    // 从链表中删除，应该让 chain 指向下一个描述符。
220                 else {
221                         if (bdir->chain != bdesc)
222                                 panic("malloc bucket chains corrupted");
223                         bdir->chain = bdesc->next;
224                 }
    // 释放当前描述符所操作的内存页面，并将该描述符插入空闲描述符链表开始处。
225                 free_page((unsigned long) bdesc->page);
226                 bdesc->next = free_bucket_desc;
227                 free_bucket_desc = bdesc;
228         }
    // 开中断，返回。
229         sti();
230         return;
231 }
232
233
```

12.10 open.c 程序

12.10.1 功能描述

open()系统调用用于将一个文件名转换成一个文件描述符。当调用成功时，返回的文件描述符将是进程没有打开的最小数值的描述符。该调用创建一个新的打开文件，并不与任何其他进程共享。在执行 exec 函数时，该新的文件描述符将始终保持着打开状态。文件的读写指针被设置在文件开始位置。

参数 flag 是 0_RDONLY、O_WRONLY、O_RDWR 之一，分别代表文件只读打开、只写打开和读写打开方式，可以与其他一些标志一起使用。(参见 fs/open.c，138 行)

12.10.2 代码注释

程序 12-9 linux/lib/open.c

```
1 /*
2  *  linux/lib/open.c
3  *
4  *  (C) 1991  Linus Torvalds
5  */
6
```

```
 7 #define __LIBRARY__
 8 #include <unistd.h>        // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                              // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编_syscall0()等。
 9 #include <stdarg.h>        // 标准参数头文件。以宏的形式定义变量参数列表。主要说明了-个
                              // 类型(va_list)和三个宏(va_start, va_arg 和 va_end)，用于
                              // vsprintf、vprintf、vfprintf 函数。
10
   //// 打开文件函数。
   // 打开并有可能创建一个文件。
   // 参数：filename - 文件名；flag - 文件打开标志；...
   // 返回：文件描述符，若出错则置出错码，并返回-1。
11 int open(const char * filename, int flag, ...)
12 {
13         register int res;
14         va_list arg;
15
   // 利用 va_start()宏函数，取得 flag 后面参数的指针，然后调用系统中断 int 0x80，功能 open 进行
   // 文件打开操作。
   // %0 - eax(返回的描述符或出错码)；%1 - eax(系统中断调用功能号__NR_open)；
   // %2 - ebx(文件名 filename)；%3 - ecx(打开文件标志 flag)；%4 - edx(后随参数文件属性 mode)。
16         va_start(arg,flag);
17         __asm__("int $0x80"
18                 :"=a" (res)
19                 :"" (__NR_open),"b" (filename),"c" (flag),
20                 "d" (va_arg(arg,int)));
   // 系统中断调用返回值大于或等于 0，表示是一个文件描述符，则直接返回之。
21         if (res>=0)
22                 return res;
   // 否则说明返回值小于 0，则代表一个出错码。设置该出错码并返回-1。
23         errno = -res;
24         return -1;
25 }
26
```

12.11 setsid.c 程序

12.11.1 功能描述

该程序包括一个 setsid()系统调用函数。如果调用的进程不是一个组的领导时，该函数用于创建一个新会话。则调用进程将成为该新会话的领导、新进程组的组领导，并且没有控制终端。调用进程的组 id 和会话 id 被设置成进程的 PID(进程标识符)。调用进程将成为新进程组和新会话中的唯一进程。

12.11.2 代码注释

程序 12-10 linux/lib/setsid.c

```
1 /*
2  *  linux/lib/setsid.c
3  *
```

```
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #define __LIBRARY__
 8 #include <unistd.h>        // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                              // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编_syscall0()等。
 9
   //// 创建一个会话并设置进程组号。
   // 下面系统调用宏对应于函数：pid_t setsid()。
   // 返回：调用进程的会话标识符(session ID)。
10 _syscall0(pid_t,setsid)
11
```

12.12 string.c 程序

12.12.1 功能描述

所有字符串操作函数已经存在于 string.h 中，这里通过首先声明'extern'和'inline'前缀为空，然后再包含 string.h 头文件，实现了 string.c 中仅包含字符串函数的实现代码。参见 include/string.h 头文件前的说明。

12.12.2 代码注释

程序 12-11 linux/lib/string.c

```
 1 /*
 2  *  linux/lib/string.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #ifndef __GNUC__              // 需要 GNU 的 C 编译器编译。
 8 #error I want gcc!
 9 #endif
10
11 #define extern
12 #define inline
13 #define __LIBRARY__
14 #include <string.h>
15
```

12.13 wait.c 程序

12.13.1 功能描述

该程序包括函数 waitpid()和 wait()。这两个函数允许进程获取与其子进程之一的状态信息。各种选

项允许获取已经终止或停止的子进程状态信息。如果存在两个或两个以上子进程的状态信息，则报告的顺序是不指定的。

wait()将挂起当前进程，直到其子进程之一退出（终止），或者收到要求终止该进程的信号，或者是需要调用一个信号句柄（信号处理程序）。

waitpid()挂起当前进程，直到 pid 指定的子进程退出（终止）或者收到要求终止该进程的信号，或者是需要调用一个信号句柄（信号处理程序）。

如果 pid= -1，options=0，则 waitpid()的作用与 wait()函数一样。否则其行为将随 pid 和 options 参数的不同而不同。（参见 kernel/exit.c,142）

12.13.2 代码注释

程序 12-12 linux/lib/wait.c

```
 1 /*
 2  *  linux/lib/wait.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #define __LIBRARY__
 8 #include <unistd.h>        // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                              // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编_syscall0()等。
 9 #include <sys/wait.h>      // 等待调用头文件。定义系统调用 wait()和 waitpid()及相关常数符号。
10
   //// 等待进程终止系统调用函数。
   // 该下面宏结构对应于函数：pid_t waitpid(pid_t pid, int * wait_stat, int options)
   //
   // 参数：pid - 等待被终止进程的进程 id，或者是用于指定特殊情况的其他特定数值；
   //       wait_stat - 用于存放状态信息；options - WNOHANG 或 WUNTRACED 或是 0。
11 _syscall3(pid_t,waitpid,pid_t,pid,int *,wait_stat,int,options)
12
   //// wait()系统调用。直接调用 waitpid()函数。
13 pid_t wait(int * wait_stat)
14 {
15         return waitpid(-1,wait_stat,0);
16 }
17
```

12.14 write.c 程序

12.14.1 功能描述

该程序中包括一个向文件描述符写操作函数 write()。该函数向文件描述符指定的文件写入 count 字节的数据到缓冲区 buf 中。

12.14.2 代码注释

程序 12-13 linux/lib/write.c

```
 1 /*
 2  *  linux/lib/write.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 #define __LIBRARY__
 8 #include <unistd.h>        // Linux 标准头文件。定义了各种符号常数和类型，并声明了各种函数。
                              // 如定义了__LIBRARY__，则还含系统调用号和内嵌汇编_syscall0()等。
 9
   //// 写文件系统调用函数。
   // 该宏结构对应于函数：int write(int fd, const char * buf, off_t count)
   // 参数：fd - 文件描述符；buf - 写缓冲区指针；count - 写字节数。
   // 返回：成功时返回写入的字节数(0 表示写入 0 字节)；出错时将返回-1，并且设置了出错号。
10 _syscall3(int,write,int,fd,const char *,buf,off_t,count)
11
```

第13章 建造工具(tools)

13.1 概述

Linux 内核源代码中的 tools 目录中包含一个生成内核磁盘映像文件的工具程序 build.c，该程序将单独编译成可执行文件，在 linux/目录下的 Makefile 文件中被调用运行，用于将所有内核编译代码连接和合并成一个可运行的内核映像文件 image。具体方法是对 boot/中的 bootsect.s、setup.s 使用 8086 汇编器进行编译，分别生成各自的执行模块。再对源代码中的其他所有程序使用 GNU 的编译器 gcc/gas 进行编译，并连接成模块 system。然后使用 build 工具将这三块组合成一个内核映像文件 image。基本编译连接/组合结构如图 13-1 所示。

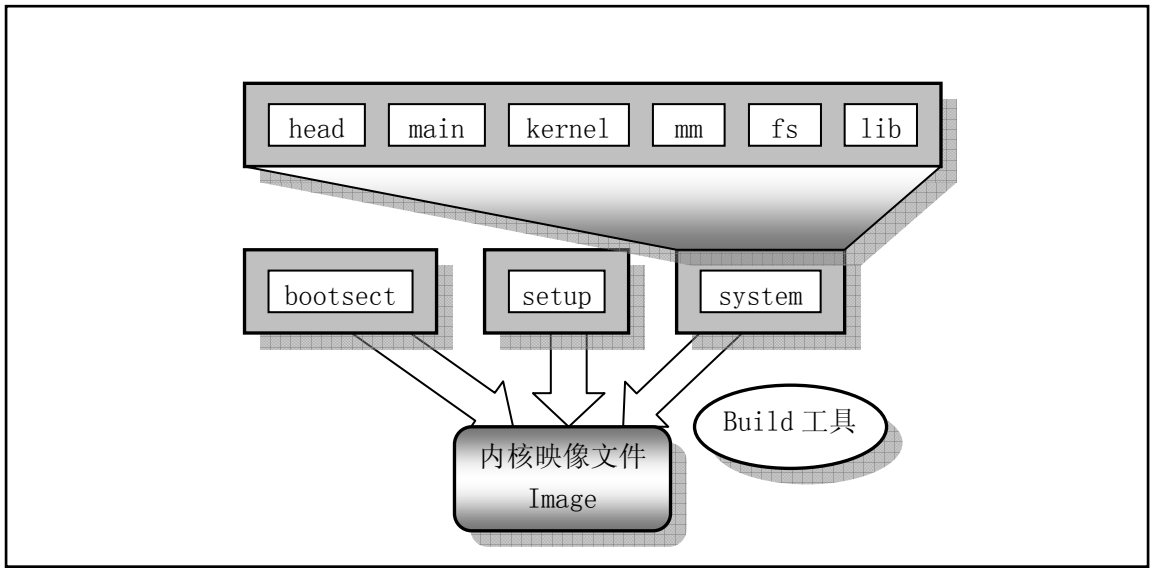

图 13-1 内核编译连接/组合结构

13.2 build.c 程序

13.2.1 功能概述

build 程序使用 4 个参数，分别是 bootsect 文件名、setup 文件名、system 文件名和可选的根文件系统设备文件名。

程序首先检查命令行上最后一个根设备文件名可选参数，若其存在，则读取该设备文件的状态信息结构（stat），取出设备号。若命令行上不带该参数，则使用默认值。

然后对 bootsect 文件进行处理，读取该文件的 minix 执行头部信息，判断其有效性，然后读取随后 512 字节的引导代码数据，判断其是否具有可引导标志 0xAA55，并将前面获取的根设备号写入到 508,509

位移处，最后将该 512 字节代码数据写到 stdout 标准输出，由 Make 文件重定向到 Image 文件。

接下来以类似的方法处理 setup 文件。若该文件长度小于 4 个扇区，则用 0 将其填满为 4 个扇区的长度，并写到标准输出 stdout 中。

最后处理 system 文件。该文件是使用 GCC 编译器产生，所以其执行头部格式是 GCC 类型的，与 linux 定义的 a.out 格式一样。在判断执行入口点是 0 后，就将数据写到标准输出 stdout 中。若其代码数据长度超过 128KB，则显示出错信息。最终形成的内核 Image 文件格式是：

- 第 1 个扇区上存放的是 bootsect 代码，长度正好 512 字节；
- 从第 2 个扇区开始的 4 个扇区（2 - 5 扇区）存放着 setup 代码，长度不超过 4 个扇区大小；
- 从第 6 个扇区开始存放 system 模块的代码，其长度不超过 build.c 第 35 行上定义的大小。

13.2.2 代码注释

程序 13-1 linux/tools/build.c

```
 1 /*
 2  *  linux/tools/build.c
 3  *
 4  *  (C) 1991  Linus Torvalds
 5  */
 6
 7 /*
 8  * This file builds a disk-image from three different files:
 9  *
10  * - bootsect: max 510 bytes of 8086 machine code, loads the rest
11  * - setup: max 4 sectors of 8086 machine code, sets up system parm
12  * - system: 80386 code for actual system
13  *
14  * It does some checking that all files are of the correct type, and
15  * just writes the result to stdout, removing headers and padding to
16  * the right amount. It also writes some system data to stderr.
17  */
    /*
     * 该程序从三个不同的程序中创建磁盘映像文件：
     *
     * - bootsect：该文件的 8086 机器码最长为 510 字节，用于加载其他程序。
     * - setup：该文件的 8086 机器码最长为 4 个磁盘扇区，用于设置系统参数。
     * - system：实际系统的 80386 代码。
     *
     * 该程序首先检查所有程序模块的类型是否正确，并将检查结果在终端上显示出来，
     * 然后删除模块头部并扩充大正确的长度。该程序也会将一些系统数据写到 stderr。
     */
18
19 /*
20  * Changes by tytso to allow root device specification
21  */
    /*
     * tytso 对该程序作了修改，以允许指定根文件设备。
     */
22
23 #include <stdio.h>      /* fprintf */              /* 使用其中的 fprintf() */
24 #include <string.h>                                /* 字符串操作 */
```

```
25 #include <stdlib.h>     /* contains exit */       /* 含有 exit() */
26 #include <sys/types.h>  /* unistd.h needs this */ /* 供 unistd.h 使用 */
27 #include <sys/stat.h>                             /* 文件状态信息结构 */
28 #include <linux/fs.h>                             /* 文件系统 */
29 #include <unistd.h>     /* contains read/write */ /* 含有 read()/write() */
30 #include <fcntl.h>                                /* 文件操作模式符号常数 */
31
32 #define MINIX_HEADER 32             // minix 二进制模块头部长度为 32 字节。
33 #define GCC_HEADER 1024             // GCC 头部信息长度为 1024 字节。
34
35 #define SYS_SIZE 0x2000             // system 文件最长节数(字节数为 SYS_SIZE*16=128KB)。
36
37 #define DEFAULT_MAJOR_ROOT 3        // 默认根设备主设备号 - 3（硬盘）。
38 #define DEFAULT_MINOR_ROOT 6        // 默认根设备次设备号 - 6（第 2 个硬盘的第 1 分区）。
39
40 /* max nr of sectors of setup: don't change unless you also change
41  * bootsect etc */
   /* 下面指定 setup 模块占的最大扇区数：不要改变该值，除非也改变 bootsect 等相应文件。
42 #define SETUP_SECTS 4               // setup 最大长度为 4 个扇区（4*512 字节）。
43
44 #define STRINGIFY(x) #x             // 用于出错时显示语句中表示扇区数。
45
   //// 显示出错信息，并终止程序。
46 void die(char * str)
47 {
48         fprintf(stderr,"%s\n",str);
49         exit(1);
50 }
51
   // 显示程序使用方法，并退出。
52 void usage(void)
53 {
54         die("Usage: build bootsect setup system [rootdev] [> image]");
55 }
56
57 int main(int argc, char ** argv)
58 {
59         int i,c,id;
60         char buf[1024];
61         char major_root, minor_root;
62         struct stat sb;
63
   // 如果程序命令行参数不是 4 或 5 个，则显示程序用法并退出。
64         if ((argc != 4) && (argc != 5))
65                 usage();
   // 如果参数是 5 个，则说明带有根设备名。
66         if (argc == 5) {
   // 如果根设备名是软盘("FLOPPY")，则取该设备文件的状态信息，若出错则显示信息，退出。
67                 if (strcmp(argv[4], "FLOPPY")) {
68                         if (stat(argv[4], &sb)) {
69                                 perror(argv[4]);
70                                 die("Couldn't stat root device.");
71                         }
```

```
    // 若成功则取该设备名状态结构中的主设备号和次设备号。
 72                         major_root = MAJOR(sb.st_rdev);
 73                         minor_root = MINOR(sb.st_rdev);
 74                 } else {
    // 否则让主设备号和次设备号取 0。
 75                         major_root = 0;
 76                         minor_root = 0;
 77                 }
    // 若参数只有 4 个，则让主设备号和次设备号等于系统默认的根设备。
 78         } else {
 79                 major_root = DEFAULT_MAJOR_ROOT;
 80                 minor_root = DEFAULT_MINOR_ROOT;
 81         }
    // 在标准错误终端上显示所选择的根设备主、次设备号。
 82         fprintf(stderr, "Root device is (%d, %d)\n", major_root, minor_root);
    // 如果主设备号不等于 2(软盘)或 3(硬盘)，也不等于 0(取系统默认根设备)，则显示出错信息，退出。
 83         if ((major_root != 2) && (major_root != 3) &&
 84             (major_root != 0)) {
 85                 fprintf(stderr, "Illegal root device (major = %d)\n",
 86                         major_root);
 87                 die("Bad root device --- major #");
 88         }
    // 初始化 buf 缓冲区，全置 0。
 89         for (i=0;i<sizeof buf; i++) buf[i]=0;
    // 以只读方式打开参数 1 指定的文件(bootsect)，若出错则显示出错信息，退出。
 90         if ((id=open(argv[1],O_RDONLY,0))<0)
 91                 die("Unable to open 'boot'");
    // 读取文件中的 minix 执行头部信息(参见列表后说明)，若出错则显示出错信息，退出。
 92         if (read(id,buf,MINIX_HEADER) != MINIX_HEADER)
 93                 die("Unable to read header of 'boot'");
    // 0x0301 - minix 头部 a_magic 魔数；0x10 - a_flag 可执行；0x04 - a_cpu, Intel 8086 机器码。
 94         if (((long *) buf)[0]!=0x04100301)
 95                 die("Non-Minix header of 'boot'");
    // 判断头部长度字段 a_hdrlen（字节）是否正确。（后三字节正好没有用，是 0）
 96         if (((long *) buf)[1]!=MINIX_HEADER)
 97                 die("Non-Minix header of 'boot'");
    // 判断数据段长 a_data 字段(long)内容是否为 0。
 98         if (((long *) buf)[3]!=0)
 99                 die("Illegal data segment in 'boot'");
    // 判断堆 a_bss 字段(long)内容是否为 0。
100         if (((long *) buf)[4]!=0)
101                 die("Illegal bss in 'boot'");
    // 判断执行点 a_entry 字段(long)内容是否为 0。
102         if (((long *) buf)[5] != 0)
103                 die("Non-Minix header of 'boot'");
    // 判断符号表长字段 a_sym 的内容是否为 0。
104         if (((long *) buf)[7] != 0)
105                 die("Illegal symbol table in 'boot'");
    // 读取实际代码数据，应该返回读取字节数为 512 字节。
106         i=read(id,buf,sizeof buf);
107         fprintf(stderr,"Boot sector %d bytes.\n",i);
108         if (i != 512)
109                 die("Boot block must be exactly 512 bytes");
```

```
    // 判断 boot 块 0x510 处是否有可引导标志 0xAA55。
110         if ((*(unsigned short *)(buf+510)) != 0xAA55)
111                 die("Boot block hasn't got boot flag (0xAA55)");
    // 引导块的 508，509 偏移处存放的是根设备号。
112         buf[508] = (char) minor_root;
113         buf[509] = (char) major_root;
    // 将该 boot 块 512 字节的数据写到标准输出 stdout，若写出字节数不对，则显示出错信息，退出。
114         i=write(1,buf,512);
115         if (i!=512)
116                 die("Write call failed");
    // 最后关闭 bootsect 模块文件。
117         close (id);
118
    // 现在开始处理 setup 模块。首先以只读方式打开该模块，若出错则显示出错信息，退出。
119         if ((id=open(argv[2],O_RDONLY,0))<0)
120                 die("Unable to open 'setup'");
    // 读取该文件中的 minix 执行头部信息(32 字节)，若出错则显示出错信息，退出。
121         if (read(id,buf,MINIX_HEADER) != MINIX_HEADER)
122                 die("Unable to read header of 'setup'");
    // 0x0301 - minix 头部 a_magic 魔数；0x10 - a_flag 可执行；0x04 - a_cpu, Intel 8086 机器码。
123         if (((long *) buf)[0]!=0x04100301)
124                 die("Non-Minix header of 'setup'");
    // 判断头部长度字段 a_hdrlen（字节）是否正确。（后三字节正好没有用，是 0）
125         if (((long *) buf)[1]!=MINIX_HEADER)
126                 die("Non-Minix header of 'setup'");
    // 判断数据段长 a_data 字段(long)内容是否为 0。
127         if (((long *) buf)[3]!=0)
128                 die("Illegal data segment in 'setup'");
    // 判断堆 a_bss 字段(long)内容是否为 0。
129         if (((long *) buf)[4]!=0)
130                 die("Illegal bss in 'setup'");
    // 判断执行点 a_entry 字段(long)内容是否为 0。
131         if (((long *) buf)[5] != 0)
132                 die("Non-Minix header of 'setup'");
    // 判断符号表长字段 a_sym 的内容是否为 0。
133         if (((long *) buf)[7] != 0)
134                 die("Illegal symbol table in 'setup'");
    // 读取随后的执行代码数据，并写到标准输出 stdout。
135         for (i=0 ; (c=read(id,buf,sizeof buf))>0 ; i+=c )
136                 if (write(1,buf,c)!=c)
137                         die("Write call failed");
    //关闭 setup 模块文件。
138         close (id);
    // 若 setup 模块长度大于 4 个扇区，则算出错，显示出错信息，退出。
139         if (i > SETUP_SECTS*512)
140                 die("Setup exceeds " STRINGIFY(SETUP_SECTS)
141                         " sectors - rewrite build/boot/setup");
    // 在标准错误 stderr 显示 setup 文件的长度值。
142         fprintf(stderr,"Setup is %d bytes.\n",i);
    // 将缓冲区 buf 清零。
143         for (c=0 ; c<sizeof(buf) ; c++)
144                 buf[c] = '\0';
    // 若 setup 长度小于 4*512 字节，则用\0 将 setup 填足为 4*512 字节。
```

```
145         while (i<SETUP_SECTS*512) {
146                 c = SETUP_SECTS*512-i;
147                 if (c > sizeof(buf))
148                         c = sizeof(buf);
149                 if (write(1,buf,c) != c)
150                         die("Write call failed");
151                 i += c;
152         }
153
    // 下面处理 system 模块。首先以只读方式打开该文件。
154         if ((id=open(argv[3],O_RDONLY,0))<0)
155                 die("Unable to open 'system'");
    // system 模块是 GCC 格式的文件，先读取 GCC 格式的头部结构信息(linux 的执行文件也采用该格式)。
156         if (read(id,buf,GCC_HEADER) != GCC_HEADER)
157                 die("Unable to read header of 'system'");
    // 该结构中的执行代码入口点字段 a_entry 值应为 0。
158         if (((long *) buf)[5] != 0)
159                 die("Non-GCC header of 'system'");
    // 读取随后的执行代码数据，并写到标准输出 stdout。
160         for (i=0 ; (c=read(id,buf,sizeof buf))>0 ; i+=c )
161                 if (write(1,buf,c)!=c)
162                         die("Write call failed");
    // 关闭 system 文件，并向 stderr 上打印 system 的字节数。
163         close(id);
164         fprintf(stderr,"System is %d bytes.\n",i);
    // 若 system 代码数据长度超过 SYS_SIZE 节（或 128KB 字节），则显示出错信息，退出。
165         if (i > SYS_SIZE*16)
166                 die("System is too big");
167         return(0);
168 }
169
```

13.2.3 相关信息

13.2.3.1 可执行文件头部数据结构

Minix 可执行文件 a.out 的头部结构如下所示（参见 minix 2.0 源代码 01400 行开始）：

```
struct  exec {
  unsigned char a_magic[2];     // 执行文件魔数。
  unsigned char a_flags;        // 标志（参见后面说明）。
  unsigned char a_cpu;          // cpu 标识号。
  unsigned char a_hdrlen;       // 头部长度。
  unsigned char a_unused;       // 保留给将来使用。
  unsigned short a_version;     // 版本信息（目前未用）。
  long          a_text;         // 代码段长度，字节数。
  long          a_data;         // 数据段长度，字节数。
  long          a_bss;          // 堆长度，字节数。
  long          a_entry;        // 执行入口点地址。
  long          a_total;        // 分配的内存总量。
  long          a_syms;         // 符号表大小。
  ...
```

```
};
```

其中标志字段定义为：

```
A_UZP    0x01          // 未映射的 0 页（页数）。
A_PAL    0x02          // 以页边界调整的可执行文件。
A_NSYM   0x04          // 新型符号表。
A_EXEC   0x10          // 可执行文件。
A_SEP    0x20          // 代码和数据是分开的。
```

CPU 标识号为：

```
A_NONE   0x00          // 未知。
A_I8086  0x04          // Intel i8086/8088。
A_M68K   0x0B          // Motorola m68000。
A_NS16K  0x0C          // 国家半导体公司 16032。
A_I80386 0x10         // Intel i80386。
A_SPARC  0x17          // Sun 公司 SPARC。
```

GCC 执行文件头部结构信息参见 linux/include/a.out.h 文件。

第14章 实验环境设置与使用方法

14.1 概述

为了配合 Linux 0.11 内核工作原理的学习，本章介绍了利用 PC 机仿真软件和在实际计算机上运行 Linux 0.11 系统的方法。其中包括内核的编译过程、PC 仿真环境下文件的访问和复制、引导盘和根文件系统的制作方法以及 Linux 0.11 系统的使用方法等。最后还说明了如何对内核代码作少量语法修改，使其在现有的 RedHat 9 系统（gcc 3.x）下能顺利通过编译。

在开始进行实验之前，首先准备好一些有用的工具软件。在 Windows 平台上，可以准备以下几个软件：

- Bochs 2.1x 开放源代码的 PC 机仿真软件包。
- UltraEdit 超级编辑器。可用来编辑二进制文件。
- WinImage DOS 格式软盘映像文件读写软件。

运行 Linux 0.11 系统的最佳方法是使用 PC 仿真软件。目前世面上流行的 PC 仿真软件系统主要有 3 种：VMware 公司的 VMware Workstation、Connectix 公司的 Virtual PC（现在该软件已被微软收购）和开放源代码的 Bochs（发音与'box'相同）。这 3 种软件都虚拟或仿真了 Intel x86 硬件环境，可以让我们在运行这些软件的系统平台上运行多种其他的“客户”操作系统。

就使用范围和运行性能来说，这 3 个仿真软件还是有一定的区别。Bochs 仿真了 x86 的硬件环境及其外围设备，因此很容易被移植到很多操作系统上或者不同体系结构的平台上。由于主要使用了仿真技术，其运行性能和速度都要比其他两个软件要慢很多。Virtual PC 的性能则界于 Bochs 和 VMware Workstation 之间。它仿真了 x86 的大部分，而其他部分则采用虚拟技术来实现。VMware Workstation 仅仿真了一些 I/O 功能，而所有其他部分则是在 x86 实时硬件上直接执行。也就是说当客户操作系统在要求执行一条指令时，VMware 不是用仿真方法来模拟这条指令，而是把这条指令“传递”给实际系统的硬件来完成。因此 VMware 是 3 种软件中运行速度和性能最高的一种。有关这 3 种软件之间的具体区别和性能差异，请参考网上的一篇评论文章（http://www.osnews.com/story.php?news_id=1054）。

从应用方面来看，如果仿真环境主要是用于应用程序开发，那么 VMware Workstation 和 Virtual PC 可能是比较好的选择。但是如果需要开发一些低层系统软件（比如进行操作系统开发和调试、编译系统开发等），那么 Bochs 就是一个很好的选择。使用 Bochs，你可以知道被执行程序在仿真硬件环境中的具体状态和精确时序，而非实际硬件系统执行的结果。这也是为什么很多操作系统开发者更倾向于使用 Bochs 的原因。因此本章主要介绍利用 Bochs 仿真环境运行 Linux 0.11 的方法。目前，Bochs 网站名是 http://sourceforge.net/projects/bochs/。你可以从上面下载到最新发布的 Bochs 软件系统以及很多已经制作好的可运行磁盘映像文件。

14.2 Bochs 仿真系统

Bochs 是一个能完全仿真 Intel x86 计算机的程序。它可以被配置成仿真 386、486、Pentium 或以上的新型 CPU。在执行的整个过程，Bochs 仿真了所有的指令，并且含有标准 PC 机外设所有的设备模块。

由于 Bochs 仿真了整个 PC 环境，因此在其中执行的软件会“认为”它是在一个真实的机器上运行。这种完全仿真的方法使得我们能在 Bochs 下不加修改地运行大量的软件系统。

Bochs 是 Kevin Lawton 于 1994 年开始采用 C++语言开发的软件系统，被设计成能够在 Intel x86、PPC、Alpha、Sun 和 MIPS 硬件上运行。不管运行的主机采用的是何硬件平台，Bochs 仍然仿真 x86 的软件。这是其他两种仿真软件所不能做到的。为了在被模拟的机器上执行执行任何活动，Bochs 需要与主机操作系统进行交互。当在 Bochs 显示窗口中按下一键时，一个击键事件就会发送到键盘的设备处理模块中。当被模拟的机器需要从模拟的硬盘上执行读操作时，Bochs 就会从主机上的硬盘映像文件中执行读操作。

Bochs 软件的安装非常方便。你可以直接从 bochs.sourceforge.net 网站上下载到 Bochs 安装软件包。如果你所使用的计算机操作系统是 Windows，则其安装过程与普通软件完全一样。安装好后会在 C 盘上生成一个目录：'C:\Program Files\Bochs-2.1.1\'（其中版本号随不同的版本而不同）。如果你的系统是 RedHat 9 或其他 Linux 系统，你可以下载 Bochs 的 RPM 软件包并按如下方法来安装：

```
user$ su
Password:
root# rpm -i bochs-1.2.1.i386.rpm
root# exit
user$ _
```

安装时需要有 root 权限，否则你就得在自己的目录下重新编译 Bochs 系统。另外，Bochs 需要在 X11 环境下运行，因此系统中必须已经安装了 X Windows 系统才能使用 Bochs。在安装好后，可以先使用 Bochs 中自带的 Linux dlx 程序包来测试和熟悉一下系统。另外，也可以从 Bochs 网站上下载一些已经制作好的 Linux 磁盘映像文件。建议下载 Bochs 网站上的一个 SLS Linux 模拟系统：sls-0.99pl.tar.bz2 作为创建 Linux 0.11 模拟系统的辅助平台。在制作新的硬盘映像文件时需要借助这些系统对硬盘映像文件进行分区和格式化操作。

有关重新编译 Bochs 系统或把 Bochs 安装到其他硬件平台上的操作方法，请参考 Bochs 用户手册中的相关说明。

14.2.1 设置 Bochs 系统

为了在 Bochs 中运行一个操作系统，最少需要以下一些资源或信息：

- bochs 执行文件；
- bios 映像文件（通常称为'BIOS-bochs-latest'）；
- vga bios 映像文件（例如，'VGABIOS-lgpl-latest'）；
- 至少一个引导启动磁盘映像文件（软盘、硬盘或 CDROM 的映像文件）。

但是我们在使用过程中往往需要为运行系统预先设置一些参数。这些参数可以在命令行上传递给 Bochs 执行程序，但通常我们都使用一个配置文件（例如 Sample.bxrc）为专门的一个应用来设置。下面说明在 Windows 环境下配置文件的设置方法。

14.2.2 配置文件 bochsrc

Bochs 使用配置文件中的信息来寻找所使用的磁盘映像文件、运行环境外围设备的配置以及其他一些模拟机器的设置信息。每个被仿真的系统都需要设置一个相应的配置文件。若所安装的 Bochs 系统是 2.1 或以后版本，那么 Bochs 系统会自动识别后缀是'.bxrc'的配置文件，并且在双击该文件图标时就会自动启动 Bochs 系统运行。例如，我们可以把配置文件名取为'bochsrc-0.11.bxrc'。在 Bochs 安装的主目录下有一个名称为'bochsrc-sample.txt'的样板配置文件，其中列出了所有可用的的参数设置，并带有详细的

说明。下面简单介绍几个在实验中经常要修改的参数。

1. megs

用于设置模拟系统所含内存容量。默认值是 32MB。例如，如果要把模拟机器设置为含有 128MB 的系统，则需要在配置文件中含有如下一行信息：

```
megs: 128
```

2. floppya（floppyb）

floppya 表示第一个软驱，floppyb 代表第二个软驱。如果需要从一个软盘上来引导系统，那么 floppya 就需要指向一个可引导的磁盘。若想使用磁盘映像文件，就在后面写上磁盘映像文件的名称。在许多操作系统中，Bochs 可以直接读写主机系统的软盘驱动器。若要访问这些实际驱动器中的磁盘，就使用设备名称（Linux 系统）或驱动器号（Windows 系统）。还可以使用 status 来表明磁盘的插入状态。ejected 表示未插入，inserted 表示磁盘已插入。下面是几个例子，其中所有盘均为已插入状态。

```
floppya: 1_44=/dev/fd0, status=inserted                 # Linux 系统下直接访问 1.44MB A 盘。
floppya: 1_44=b:, status=inserted                       # win32 系统下直接访问 1.44MB B 盘。
floppya: 1_44=bootimage.img, status=inserted            # 指向磁盘映像文件 bootimage.img。
floppyb: 1_44=..\Linux\rootimage.img, status=inserted   # 指向上级目录 Linux/下 rootimage.img。
```

在配置文件中，若同时存在几行相同名称的参数，那么只有最后一行的参数起作用。

3. ata0、ata1、ata2、ata3

这 4 个参数名用来启动模拟系统中最多 4 个 ATA 通道。对于每个启用的通道，必须指明两个 IO 基地址和一个中断请求号。默认情况下只有 ata0 是启用的，并且参数默认为下面所示的值：

```
ata0: enabled=1, ioaddr1=0x1f0, ioaddr2=0x3f0, irq=14
ata1: enabled=1, ioaddr1=0x170, ioaddr2=0x370, irq=15
ata2: enabled=1, ioaddr1=0x1e8, ioaddr2=0x3e0, irq=11
ata3: enabled=1, ioaddr1=0x168, ioaddr2=0x360, irq=9
```

4. ata0-master（ata0-slave）

ata0-master 用来指明模拟系统中第 1 个 ATA 通道(0 通道)上连接的第 1 个 ATA 设备(硬盘或 CDROM 等)；ata0-slave 指明第 1 个通道上连接的第 2 个 ATA 设备。例子如下所示，其中，设备配置的选项含义如表 14–1 所示。

```
ata0-master: type=disk, path=hd.img, mode=flat, cylinders=306, heads=4, spt=17, translation=none
ata1-master: type=disk, path=2G.cow, mode=vmware3, cylinders=5242, heads=16, spt=50, translation=echs
ata1-slave:  type=disk, path=3G.img, mode=sparse, cylinders=6541, heads=16, spt=63, translation=auto
ata2-master: type=disk, path=7G.img, mode=undoable, cylinders=14563, heads=16, spt=63, translation=lba
ata2-slave:  type=cdrom, path=iso.sample, status=inserted
ata0-master: type=disk, path="hdc-large.img", mode=flat, cylinders=487, heads=16, spt=63
ata0-slave:  type=disk, path="..\hdc-0.11.img", mode=flat, cylinders=121, heads=16, spt=63
```

表 14－1 设备配置的选项

选项	说明	可取的值

type	连接的设备类型	[disk | cdrom]
path	映像文件路径名	
mode	映像文件类型，仅对 disk 有效	[flat | concat | external | dll | sparse | vmware3 | undoable | growing | volatile]
cylinders	仅对 disk 有效	
heads	仅对 disk 有效	
spt	仅对 disk 有效	
status	仅对 cdrom 有效	[inserted | ejected]
biosdetect	bios 检测类型	[none | auto],仅对 ata0 上 disk 有效 [cmos]
translation	bios 进行变换的类型(int13),仅对 disk 有效	[none | lba | large | rechs | auto]
model	确认设备 ATA 命令返回的字符串	

在配置 ATA 设备时，必须指明连接设备的类型 type，可以是 disk 或 cdrom。还必须指明设备的“路径名”path。“路径名”可以是一个硬盘映像文件、CDROM 的 iso 文件或者直接指向系统的 CDROM 驱动器。在 Linux 系统中，可以使用系统设备作为 Bochs 的硬盘，但由于安全原因，在 windows 下不赞成直接使用系统上的物理硬盘。

对于类型是 disk 的设备，选项 path、cylinders、heads 和 spt 是必须的。对于类型是 cdrom 的设备，选项 path 是必须的。

磁盘变换方案（在传统 int13 bios 功能中实现，并且用于象 DOS 这样的老式操作系统）可以定义为：

- none：无需变换，适用于容量小于 528MB（1032192 个扇区）的硬盘；
- large：标准比特移位算法，用于容量小于 4.2GB（8257536 个扇区）的硬盘；
- rechs：修正移位算法，使用 15 磁头的伪物理硬盘参数，适用于容量小于 7.9GB（15482880 个扇区）的硬盘；
- lba：标准 lba-辅助算法。适用于容量小于 8.4GB（16450560 个扇区）的硬盘；
- auto：自动选择最佳变换方案。（如果模拟系统启动不了就应该改变）。

mode 选项用于说明如何使用硬盘映像文件。它可以是以下模式之一：

- flat：一个平坦顺序文件；
- concat：多个文件；
- external：由开发者专用，通过 C++类来指定；
- dll：开发者专用，通过 DLL 来使用；
- sparse：可堆砌的、可确认的、可退回的；
- vmware3：支持 vmware3 的硬盘格式；
- undoable：具有确认重做的平坦文件；
- growing：容量可扩展的映像文件；
- volatile：具有易变重做的平坦文件。

以上选项的默认值是：

mode=flag, biosdetect=auto, translation=auto, model=”Generic 1234”

5. boot

boot 用来定义模拟机器中用于引导启动的驱动器。可以指定是软盘、硬盘或者 CDROM。也可以使用驱动器号'c'和'a'。例子如下：

```
boot: a
```

```
boot: c
boot: floppy
boot: disk
boot: cdrom
```

6. ips

ips（Instructions Per Second）指定每秒钟仿真的指令条数。这是 Bochs 在主机系统中运行的 IPS 数值。这个值会影响模拟系统中与时间有关的很多事件。例如改变 IPS 值会影响到 VGA 更新的速率以及其他一些模拟系统评估值。因此需要根据所使用的主机性能来设定该值。可参考表 14–2 进行设置。

表 14－2 每秒种仿真指令数

速度	机器配置	IPS 典型值
650Mhz	Athlon K-7 with Linux 2.4.x	2 to 2.5 million
400Mhz	Pentium II with Linux 2.0.x	1 to 1.8 million
166Mhz	64bit Sparc with Solaris 2.x	0.75 million
200Mhz	Pentium with Linux 2.x	0.5 million

例如：

```
ips: 1000000
```

7. log

指定 log 的路径名可以让 Bochs 记录执行的一些日志信息。如果在 Bochs 中运行的系统发生不能正常运行的情况就可以参考其中的信息来找出基本原由。log 通常设置为：

```
log: bochsout.txt
```

14.2.3 调试功能

参见 bochs Debugger

14.3 创建磁盘映像文件

磁盘映像文件（Disk Image File）是软盘或硬盘上信息的一个完整映像，并以文件的形式保存。磁盘映像文件中存储信息的格式与对应磁盘上保存信息的格式完全一样。空磁盘映像文件是容量与我们创建的磁盘相同但内容全为 0 的一个文件。这些空映像文件就象刚买来的新软盘或硬盘，还需要经过分区或/以及格式化才能使用。

在制作磁盘映像文件之前，我们首先需要确定所创建映像文件的容量。对于软盘映像文件，各种规格（1.2MB 或 1.44MB）的容量都是固定的。因此这里主要说明如何确定自己需要的硬盘映像文件的容量。普通硬盘的结构由堆积的金属圆盘组成。每个圆盘的上下两面用于保存数据，并且以同心圆的方式把整个表面划分成一个个磁道，或称为柱面（Cylinder）。因此一个圆盘需要一个磁头（Head）来读写上面的数据。在圆盘旋转时磁头只需要作径向移动就可以在任何磁道上方移动，从而能够访问圆盘表面所有有效的位置。每个磁道被划分成若干个扇区，扇区长度一般由 256 -- 1024 字节组成。对于大多数系统来说，通常扇区长度均为 512 字节。一个典型的硬盘结构见图 14-1 所示。

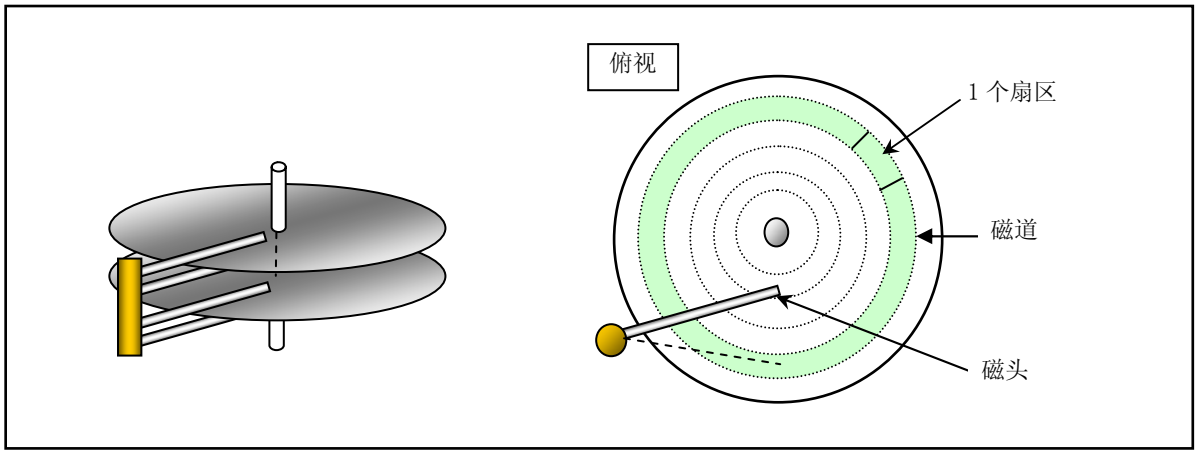

图 14-1 典型硬盘内部结构

图中示出了具有两个金属圆盘的硬盘结构。因此该硬盘有 4 个物理磁头。所含的最大柱面数在生产时已确定。当对硬盘进行分区和格式化时，圆盘表面的磁介质就被初始化成指定格式的数据，从而每个磁道（或柱面）被划分成指定数量的扇区。因此这个硬盘的总扇区数为：

硬盘总扇区数 = 物理磁道数 X 物理磁头数 X 每磁道扇区数

硬盘中以上这些实际的物理参数与一个操作系统中所使用的参数会有区别，称为逻辑参数。但这些参数所计算出的总扇区数与硬盘物理参数计算出的肯定是相同的。由于在设计 PC 机系统时没有考虑到硬件设备性能和容量发展得如此之快，ROM BIOS 某些表示硬盘参数所使用的比特位太少而不能符合实际硬盘物理参数的要求。因此目前操作系统或机器 BIOS 中普遍采用的措施就是在保证硬盘总扇区数相等的情况下适当调整磁道数、词头数和每磁道扇区数，以符合兼容性和参数表示限制的要求。在 Bochs 配置文件有关硬盘设备参数中的变换（Translation）选项也是为此目的而设置的。

在我们为 Linux 0.11 系统制作硬盘 Image 文件时，考虑到其本身代码量很少，而且所使用的 MINIX 1.5 文件系统最大容量为 64MB 的限制，因此每个硬盘分区大小最大也只能是 64MB。另外，Linux 0.11 系统尚未支持扩展分区，因此对于一个硬盘 Image 文件来说，最多有 4 个分区。因此，Linux 0.11 系统可使用的硬盘 Image 文件最大容量是 64 x 4 = 256MB。在下面的说明中，我们将以创建一个具有 4 个分区、每个分区为 60MB 的硬盘 Image 文件为例子进行说明。

对于软盘来说，我们可以把它看作是一种具有固定磁道数（柱面数）、磁头数和每磁道扇区数（spt - Sectors Per Track）的超小型硬盘。例如容量是 1.44MB 的软盘参数是 80 个磁道、2 个磁头和每磁道有 18 个扇区、每个扇区有 512 字节。其扇区总数是 2880，总容量是 80 x 2 x 18 x 512 = 1474560 字节。因此下面介绍的所有针对硬盘映像文件的制作方式都可以用来制作软盘映像文件。为了叙述上的方便，在没有特别指出时，我们把所有磁盘映像文件统称为 Image 文件。

14.3.1 利用 Bochs 软件自带的 Image 生成工具

Bochs 系统带有一个 Image 生成工具“Disk Image Creation Tool”（bximage.exe）。用它可以制作软盘和硬盘的空 Image 文件。在运行并出现了 Image 创建界面时，程序首先会提示选择需要创建的 Image 类型（硬盘 hd 还是软盘 fd）。若是创建硬盘，还会提示输入硬盘 Image 的 mode 类型。通常只需要选择其默认值 flat 即可。然后输入你需要创建的 Image 容量。程序会显示对应的硬盘参数值：柱面数（磁道数、磁头数和每磁道扇区数，并要求输入 Image 文件的名称。程序在生成了 Image 文件之后，会显示一条用于 Bochs 配置文件中设置硬盘参数的配置信息。记下这条信息并编辑到配置文件中。下面是创建一个

256MB 硬盘 Image 文件的过程。

```
========================================================================
                                bximage
                  Disk Image Creation Tool for Bochs
        $Id: bximage.c,v 1.19 2003/08/01 01:20:00 cbothamy Exp $
========================================================================
Do you want to create a floppy disk image or a hard disk image?
Please type hd or fd. [hd]

What kind of image should I create?
Please type flat, sparse or growing. [flat]

Enter the hard disk size in megabytes, between 1 and 32255
[10] 256

I will create a 'flat' hard disk image with
  cyl=520
  heads=16
  sectors per track=63
  total sectors=524160
  total size=255.94 megabytes

What should I name the image?
[c.img] hdc.img

Writing: [] Done.

I wrote 268369920 bytes to (null).

The following line should appear in your bochsrc:
  ata0-master: type=disk, path="hdc.img", mode=flat, cylinders=520, heads=16, spt=63

Press any key to continue
```

如果已经有了一个容量满足要求的硬盘 Image 文件，那么可以直接复制该文件就能产生另一个 Image 文件。然后可以按照自己的要求对该文件进行处理。对于创建软盘 Image 文件其过程与上述类似，只是还会提示你选择软盘种类的提示。同样，如果已经有其他软盘 Image 文件，那么采用直接复制方法即可。

14.3.2 在 Linux 系统下使用 dd 命令创建 Image 文件。

前面已经说明，刚创建的 Image 文件是一个内容全为 0 的空文件，只是其容量与要求的一致。因此我们可以首先计算出要求容量的 Image 文件的扇区数，然后使用 dd 命令来产生相应的 Image 文件。

例如我们想要建立柱面数是 520、磁头数是 16、每磁道扇区数是 63 的硬盘 Image 文件，其扇区总数为：520 * 16 * 63 = 524160，则命令为：

```
dd if=/dev/zero of=hdc.img bs=512 count=524160
```

对于 1.44MB 的软盘 Image 文件，其扇区数是 2880，因此命令为：

```
dd if=/dev/zero of=diska.img bs=512 count=2880
```

14.3.3 利用 WinImage 创建 DOS 格式的软盘 Image 文件

WinImage 是一个 DOS 格式 Image 文件访问和创建工具。双击 DOS 软盘 Image 文件的图标就可以浏览、删除或往里添加文件。除此之外，它还能用于浏览 CDROM 的 iso 文件。使用 WinImage 创建软盘 Image 时可以生成一个带有 DOS 格式的 Image 文件。方法如下：

a) 运行 WinImage。选择“Options->Settings”菜单，选择其中的 Image 设置页。设置 Compression 为“None”（也即把指示标拉到最左边）。
b) 创建 Image 文件。选择菜单 File->New，此时会弹出一个软盘格式选择框。请选择容量是 1.44MB 的格式。
c) 再选择引导扇区属性菜单项 Image->Boot Sector properties，单击对话框中的 MS-DOS 按钮。
d) 保存文件。

注意，在保存文件对话框中“保存类型”一定要选择“All files (*.*)”，否则创建的 Image 文件中会包含一些 WinImage 自己的信息，从而会造成 Image 文件在 Bochs 下不能正常使用。可以通过查看文件长度来确定新创建 Image 是否符合要求。标准 1.44MB 软盘的容量应该是 1474560 字节。如果新的 Image 文件长度大于该值，那么请严格按照所述方法重新制作或者使用 UltraEdit 等二进制编辑器删除多余的字节。删除操作的方法如下：

- 使用 UltraEdit 以二进制模式打开 Image 文件。根据磁盘映像文件第 511，512 字节是 55,AA 两个十六进制数，我们倒推 512 字节，删除这之前的所有字节。此时对于使用 MSDOS5.0 作为引导的磁盘来讲，文件头几个字节应该类似于“EB 3C 90 4D ...”。
- 然后下拉右边滚动条，移动到 img 文件末尾处。删除“...F6 F6 F6”后面的所有数据。通常来讲就是删除从 0x168000 开始的所有数据。操作完成时最后一行应该是完整的一行“F6 F6 F6...”。存盘退出即可使用该 Image 文件了。

14.4 访问磁盘映像文件中的信息

Bochs 使用磁盘映像文件来仿真被模拟系统中外部存储设备，被模拟操作系统中的所有文件均以软盘或硬盘设备中的格式保存在映像文件中。由此就带来了主机操作系统与 Bochs 中被模拟系统之间交换信息的问题。虽然 Bochs 系统能被配置成直接使用主机的软盘驱动器、CDROM 驱动器等物理设备来运行，但是利用这种信息交换方法比较烦琐。因此最好能够直接读写 Image 文件中的信息。如果需要往被模拟的操作系统中添加文件，就把文件存入 Image 文件中。如果要取出其中的文件就从 Image 文件中读出。但由于保存在 Image 文件中的信息不仅是按照相应的软盘或硬盘格式存放，而且还以一定的文件系统格式存放。因此访问 Image 文件中信息的程序必须能够识别其中的文件系统才能操作。对于本章应用来说，我们需要一些工具来识别 Image 文件中的 MINIX 和（或）DOS 文件系统格式。

总体来说，如果与模拟系统交换的文件长度比较小，我们可以采用软盘 Image 文件作为交换媒介。如果有大批量文件需要从模拟系统中取出或放入模拟系统，那么我们可以利用现有 Linux 系统来操作。下面就从这两个方面讨论可采用的几种方法。

利用磁盘映像读写工具访问软盘映像文件中的信息（小文件或分割的文件）
在 Linux 主环境中利用 loop 设备访问硬盘映像文件中的信息。（大批量信息交换）
利用 iso 格式文件进行信息交换（大批量信息交换）

14.4.1 使用 WinImage 工具软件

使用软盘 Image 文件，我们可以与模拟系统进行少量文件的交换。前提条件是被模拟系统支持对 DOS

格式软盘进行读写（例如通过 mtools 命令）。下面以实例来说明具体的操作方法。

在读写文件之前，首先需要根据前面描述的方法准备一个 1.44MB Image 文件（文件名假设是 diskb.img）。并修改 Linux 0.11 的 bochs.bxrc 配置文件，在 floppya 参数下增加以下一行信息：

```
floppyb: 1_44="diskb.img", status=inserted
```

也即给模拟系统增加第 2 个 1.44MB 软盘设备，并且该设备对应的 Image 文件名是 diskb.img。

如果想把 Linux 0.11 系统中的某个文件取出来，那么现在可以双击配置文件图标开始运行 Linux 0.11 系统。在进入 Linux 0.11 系统后，使用 DOS 软盘读写工具 mtools 把 hello.c 文件写到第 2 个软盘 Image 中。如果软盘 Image 是使用 Bochs 创建的或还没有格式化过，可以使用 mformat b:命令首先进行格式化。

```
[/usr/root]# mcopy hello.c b:
Copying HELLO.C
[/usr/root]# mdir b:
 Volume in drive B has no label
 Directory for B:/

HELLO    C            74    4-30-104   4:47p
       1 File(s)     1457152 bytes free
[/usr/root]# _
```

现在退出 Bochs 系统，并使用 WinImage 打开 diskb.img 文件，在 WinImage 的主窗口中会有一个 hello.c 文件存在。用鼠标选中该文件并拖到桌面上即完成了取文件的整个操作过程。　　如果需要把某个文件输入到模拟系统中，那么操作步骤正好与上述相反。

14.4.2 利用现有 Linux 系统

现有 Linux 系统（例如 RedHat 9）能够访问多种文件系统，包括利用 loop 设备访问存储在文件中的文件系统。对于软盘 Image 文件，我们可以直接使用 mount 命令来加载 Image 中的文件系统进行读写访问。例如我们需要访问 rootimage-0.11 中的文件，那么只要执行以下命令。

```
[root@plinux images]# mount -t minix rootimage-0.11 /mnt -o loop
[root@plinux images]# cd /mnt
[root@plinux mnt]# ls
bin  dev  etc  root  tmp  usr
[root@plinux mnt]# _
```

其中 mount 命令的-t minix 选项指明所读文件系统类型是 MINIX，-o loop 选项说明通过 loop 设备来加载文件系统。若需要访问 DOS 格式软盘 Image 文件，只需把 mount 命令中的文件类型选项 minix 换成 msdos 即可。

如果想访问硬盘 Image 文件，那么操作过程与上述不同。由于软盘 Image 文件一般包含一个完整文件系统的映像，因此可以直接使用 mount 命令加载软盘 Image 中的文件系统，但是硬盘 Image 文件中通常含有分区信息，并且文件系统是在各个分区中建立的。也即我们可以把硬盘中的每个分区看成是一个完整的“大”软盘。

因此，为了访问一个硬盘 Image 文件某个分区中的信息，我们需要首先了解这个硬盘 Image 文件中分区信息，以确定需要访问的分区在 Image 文件中的起始偏移位置。关于硬盘 Image 文件中分区信息，我们可以在模拟系统运行时使用 fdisk 命令查看，也可以在这里查看。这里以下面软件包中包括的硬盘

Image 文件 hdc-0.11.img 为例来说明访问其中第 1 个分区中文件系统的方法。

http://oldlinux.org/Linux.old/bochs/linux-0.11-devel-040329.zip

这里需要用到 loop 设备设置与控制命令 losetup。该命令主要用于把一个普通文件或一个块设备与 loop 设备相关联，或用于释放一个 loop 设备、查询一个 loop 设备的状态。该命令的详细说明请参照在线手册页。

首先执行下面命令把 hdc-0.11.img 文件与 loop1 相关联，并利用 fdisk 命令查看其中的分区信息。

```
[root@plinux devel]# losetup /dev/loop1 hdc-0.11.img
[root@plinux devel]# fdisk /dev/loop1
Command (m for help): x                                    # 进入扩展功能菜单
Expert command (m for help): p                             # 显示分区表
Disk /dev/loop1: 16 heads, 63 sectors, 121 cylinders

Nr AF  Hd Sec  Cyl  Hd Sec  Cyl    Start     Size ID
 1 80   1   1    0  15  63  119        1   120959 81
 2 00   0   0    0   0   0    0        0        0 00
 3 00   0   0    0   0   0    0        0        0 00
 4 00   0   0    0   0   0    0        0        0 00
Expert command (m for help): q
[root@plinux devel]# _
```

从上面 fdisk 给出的分区信息可以看出，该 Image 文件仅含有 1 个分区。记下该分区的起始扇区号(也即分区表中 Start 一栏的内容)。如果你需要访问具有多个分区的硬盘 Image，那么你就需要记住相关分区的起始扇区号。

接下来，我们先使用 losetup 的-d 选项把 hdc-0.11.img 文件与 loop1 的关联解除，重新把它关联到 hdc-0.11.img 文件第 1 个分区的起始位置处。这需要使用 losetup 的-o 选项，该选项指明关联的起始字节偏移位置。由上面分区信息可知，这里第 1 个分区的起始偏移位置是 1 * 512 字节。在把第 1 个分区与 loop1 重新关联后，我们就可以使用 mount 命令来访问其中的文件了。

```
[root@plinux devel]# losetup -d /dev/loop1
[root@plinux devel]# losetup -o 512 /dev/loop1 hdc-0.11.img
[root@plinux devel]# mount -t minix /dev/loop1 /mnt
[root@plinux devel]# cd /mnt
[root@plinux mnt]# ls
bin  dev  etc  image  mnt  tmp  usr  var
[root@plinux mnt]# _
```

在对分区中文件系统访问结束后，最后请卸载和解除关联。

```
[root@plinux mnt]# cd
[root@plinux root]# umount /dev/loop1
[root@plinux root]# losetup -d /dev/loop1
[root@plinux root]# _
```

14.5 制作根文件系统

本节的目标是在硬盘上建立一个根文件系统。虽然在 oldlinux.org 上可以下载到已经制作好的软盘和硬盘根文件系统 Image 文件，但这里还是把制作过程详细描述一遍，以供大家学习参考。在制作过程中还可以参考 Linus 的文章：INSTALL-0.11。在制作根文件系统盘之前，我们首先下载 rootimage-0.11 和 bootimage-0.11 映像文件（请下载日期最新的相关文件）：

http://oldlinux.org/Linux.old/images/bootimage-0.11-20040305
http://oldlinux.org/Linux.old/images/rootimage-0.11-20040305

将这两个文件修改成便于记忆的 bootimage-0.11 和 rootimage-0.11，并专门建立一个名为 Linux-0.11 的子目录。在制作过程中，我们需要复制 rootimage-0.11 软盘中的一些执行程序并使用 bootimage-0.11 引导盘来启动模拟系统。因此在开始着手制作根文件系统之前，首先需要确认已经能够运行这两个软盘 Image 文件组成的最小 Linux 系统。

14.5.1 根文件系统和根文件设备

Linux 引导启动时，默认使用的文件系统是根文件系统。其中一般都包括以下一些子目录和文件：

- etc/ 目录主要含有一些系统配置文件；
- dev/ 含有设备特殊文件，用于使用文件操作语句操作设备；
- bin/ 存放系统执行程序。例如 sh、mkfs、fdisk 等；
- usr/ 存放库函数、手册和其他一些文件；
- usr/bin 存放用户常用的普通命令；
- var/ 用于存放系统运行时可变的数据或者是日志等信息。

存放文件系统的设备就是文件系统设备。比如，对于一般使用的 Windows2000 操作系统，硬盘 C 盘就是文件系统设备，而硬盘上按一定规则存放的文件就组成文件系统，Windows2000 有 NTFS 或 FAT32 等文件系统。而 Linux 0.11 内核所支持的文件系统是 MINIX 1.0 文件系统。

14.5.2 创建文件系统

对于上面创建的硬盘 Image 文件，在能使用之前还必须对其进行分区和创建文件系统。通常的做法是把需要处理的硬盘 Image 文件挂接到 Bochs 下已有的模拟系统中（例如上面提到的 SLS Linux），然后使用模拟系统中的命令对新的 Image 文件进行处理。下面假设你已经安装了 SLS Linux 模拟系统，并且该系统存放在名称为 SLS-Linux 的子目录中。我们利用它对上面创建的 256MB 硬盘 Image 文件 hdc.img 进行分区并创建 MINIX 文件系统。我们将在这个 Image 文件中创建 1 个分区，并且建立成 MINIX 文件系统。我们执行的步骤如下：

1. 在 SLS-Linux 同级目录下建立一个名称为 Linux-0.11 的子目录，把 hdc.img 文件移动到该目录下。
2. 进入 SLS-Linux 目录，编辑 SLS Linux 系统的 Bochs 配置文件 bochsrc.bxrc。在 ata0-master 一行下加入我们的硬盘 Image 文件的配置参数行：

   ata0-slave:type=disk, path=..\Linux-0.11\hdc.img, cylinders=520, heads=16, spt=63

3. 退出编辑器。双击 bochsrc.bxrc 的图标，运行 SLS Linux 模拟系统。在出现 Login 提示符时键入'root'

并按回车键。如果此时 Bochs 不能正常运行，一般是由于配置文件信息有误，请重新编辑该配置文件。

4. 利用 fdisk 命令在 hdc.img 文件中建立 1 个分区。下面是建立第 1 个分区的命令序列。建立另外 3 个分区的过程与此相仿。由于 SLS Linux 默认建立的分区类型是支持 MINIX2.0 文件系统的 81 类型（Linux/MINIX），因此需要使用 fdisk 的 t 命令把类型修改成 80（Old MINIX）类型。这里请注意，我们已经把 hdc.img 挂接成 SLS Linux 系统下的第 2 个硬盘。按照 Linux 0.11 对硬盘的命名规则，该硬盘整体的设备名应为/dev/hd5（参见表 14–3）。但是从 Linux 0.95 版开始硬盘的命名规则已经修改成目前使用的规则，因此在 SLS Linux 下第 2 个硬盘整体的设备名称是/dev/hdb。

```
[/]# fdisk /dev/hdb
Command (m for help): n
Command action
   e   extended
   p   primary partition (1-4)
p
Partition number (1-4): 1
First cylinder (1-520): 1
Last cylinder or +size or +sizeM or +sizeK (1-520): +63M

Command (m for help): t
Partition number (1-4): 1
Hex code (type L to list codes): L
 0  Empty           8  AIX             75  PC/IX           b8  BSDI swap
 1  DOS 12-bit FAT  9  AIX bootable    80  Old MINIX       c7  Syrinx
 2  XENIX root      a  OPUS            81  Linux/MINIX     db  CP/M
 3  XENIX user     40  Venix           82  Linux swap      e1  DOS access
 4  DOS 16-bit <32M 51  Novell?        83  Linux extfs     e3  DOS R/O
 5  Extended       52  Microport       93  Amoeba          f2  DOS secondary
 6  DOS 16-bit >=32 63  GNU HURD       94  Amoeba BBT      ff  BBT
 7  OS/2 HPFS      64  Novell          b7  BSDI fs
Hex code (type L to list codes): 80

Command (m for help): p
Disk /dev/hdb: 16 heads, 63 sectors, 520 cylinders
Units = cylinders of 1008 * 512 bytes
   Device Boot  Begin   Start     End  Blocks   Id  System
/dev/hdb1           1       1     129   65015+  80  Old MINIX

Command (m for help):w
The partition table has been altered.
Please reboot before doing anything else.
[/]#
```

表 14－3 硬盘逻辑设备号

逻辑设备号	对应设备文件	说明
0x300	/dev/hd0	代表整个第 1 个硬盘
0x301	/dev/hd1	表示第 1 个硬盘的第 1 个分区
0x302	/dev/hd2	表示第 1 个硬盘的第 2 个分区
0x303	/dev/hd3	表示第 1 个硬盘的第 3 个分区

0x304	/dev/hd4	表示第 1 个硬盘的第 4 个分区
0x305	/dev/hd5	代表整个第 2 个硬盘
0x306	/dev/hd6	表示第 2 个硬盘的第 1 个分区
0x307	/dev/hd7	表示第 2 个硬盘的第 2 个分区
0x308	/dev/hd8	表示第 2 个硬盘的第 3 个分区
0x309	/dev/hd9	表示第 2 个硬盘的第 4 个分区

5. 请记住该分区中数据块数大小（这里是 65015），在创建文件系统时会使用到这个值。当分区建立好后，按照通常的做法需要重新启动一次系统，以让 SLS Linux 系统内核能正确识别这个新加的分区。
6. 再次进入 SLS Linux 模拟系统后，我们使用 mkfs 命令在刚建立的第 1 个分区上创建 MINIX 文件系统。命令与信息如下所示。这里创建了具有 64000 个数据块的分区（一个数据块为 1KB 字节）。

```
[/]# mkfs /dev/hdb1 64000
21333 inodes
64000 blocks
Firstdatazone=680 (680)
Zonesize=1024
Maxsize=268966912
[/]#
```

至此，我们完成了在 hdc.img 文件的第 1 个分区中创建文件系统的工作。当然，建立创建文件系统也可以在运行 Linux 0.11 软盘上的根文件系统时建立。的现在我们可以把这个分区中建立成一个根文件系统。

14.5.3 Linux-0.11 的 Bochs 配置文件

在 Bochs 中运行 Linux 0.11 模拟系统时，其配置文件 bochsrc.bxrc 中通常需要以下这些内容。

```
romimage: file=$BXSHARE\BIOS-bochs-latest, address=0xf0000
megs: 16
vgaromimage: $BXSHARE\VGABIOS-elpin-2.40
floppya: 1_44="bootimage-0.11", status=inserted
ata0-master: type=disk, path="hdc.img", mode=flat, cylinders=520, heads=16, spt=63
boot: a
log: bochsout.txt
panic: action=ask
#error: action=report
#info: action=report
#debug: action=ignore
ips: 1000000
mouse: enabled=0
```

我们可以把 SLS Linux 的 Bochs 配置文件 bochsrc.bxrc 复制到 Linux-0.11 目录中，然后修改成与上面相同的内容。需要特别注意 floppya、ata0-master 和 boot，这 3 个参数一定要与上面一致。

现在我们用鼠标双击这个配置文件。首先 Bochs 显示窗口应该出现图 14-2 中画面。

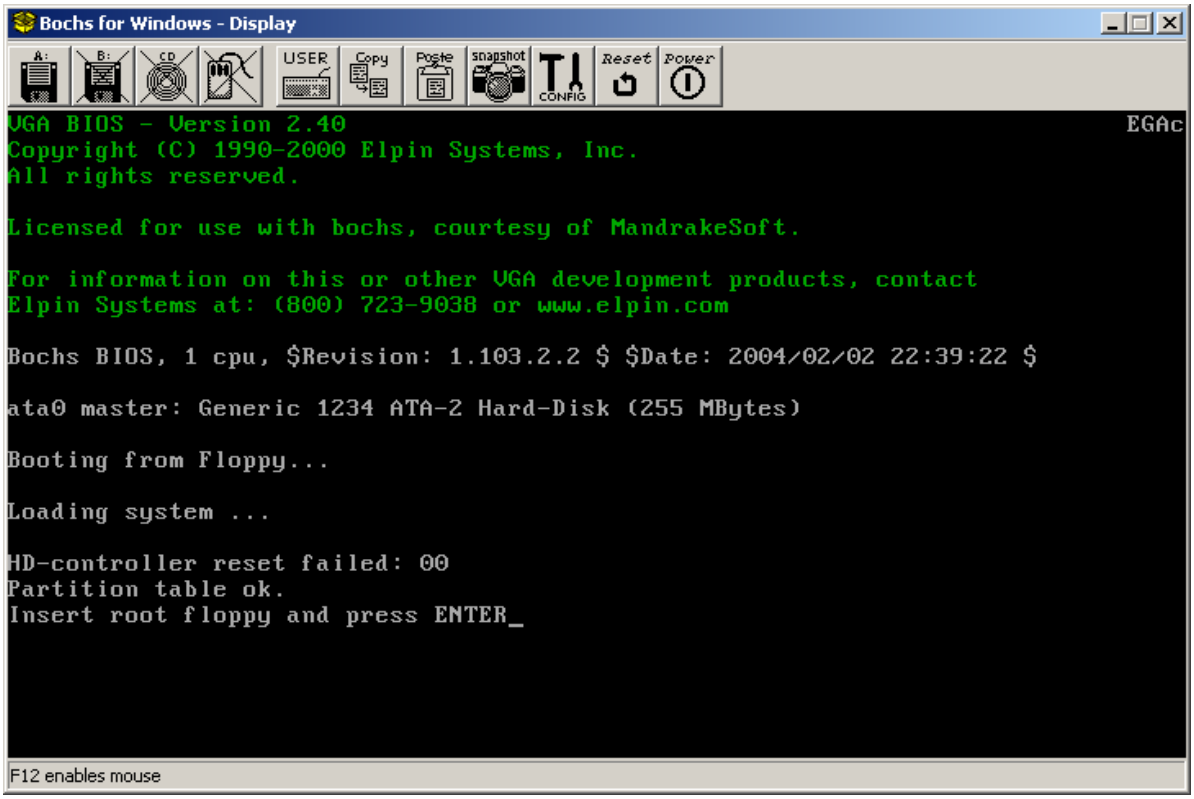

图 14-2 Bochs 系统运行窗口

此时应该单击菜单条上的'CONFIG'图标进入 Bochs 设置窗口（需要用鼠标点击才能把该窗口提到最前面）。设置窗口显示的内容见图 14-3 所示。

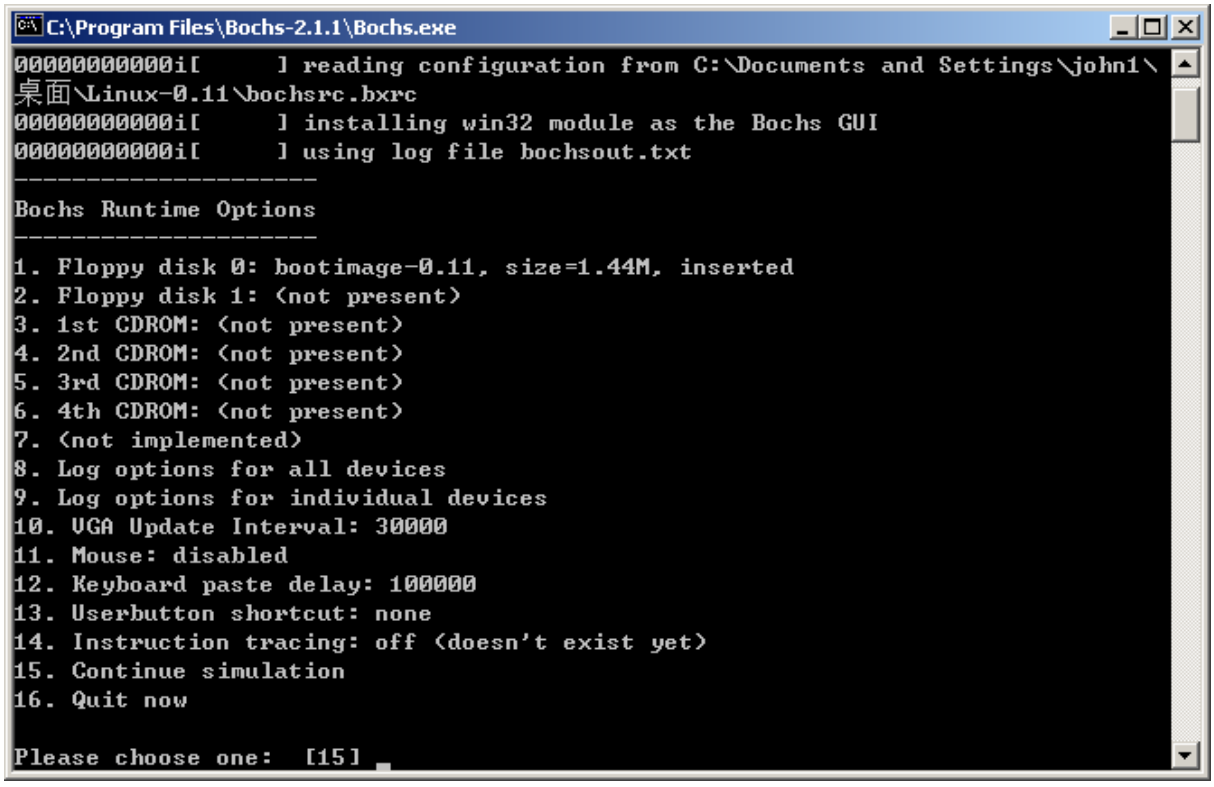

图 14-3 Bochs 系统配置窗口

修改第 1 项的软盘设置，让其指向 rootimage-0.11 盘。然后连续按回车键，直到设置窗口最后一行信息显示'Continuing simulation'为止。此时再切换到 Bochs 运行窗口。单击回车键后就正式进入了 Linux 0.11 系统。见图 14-4 所示。

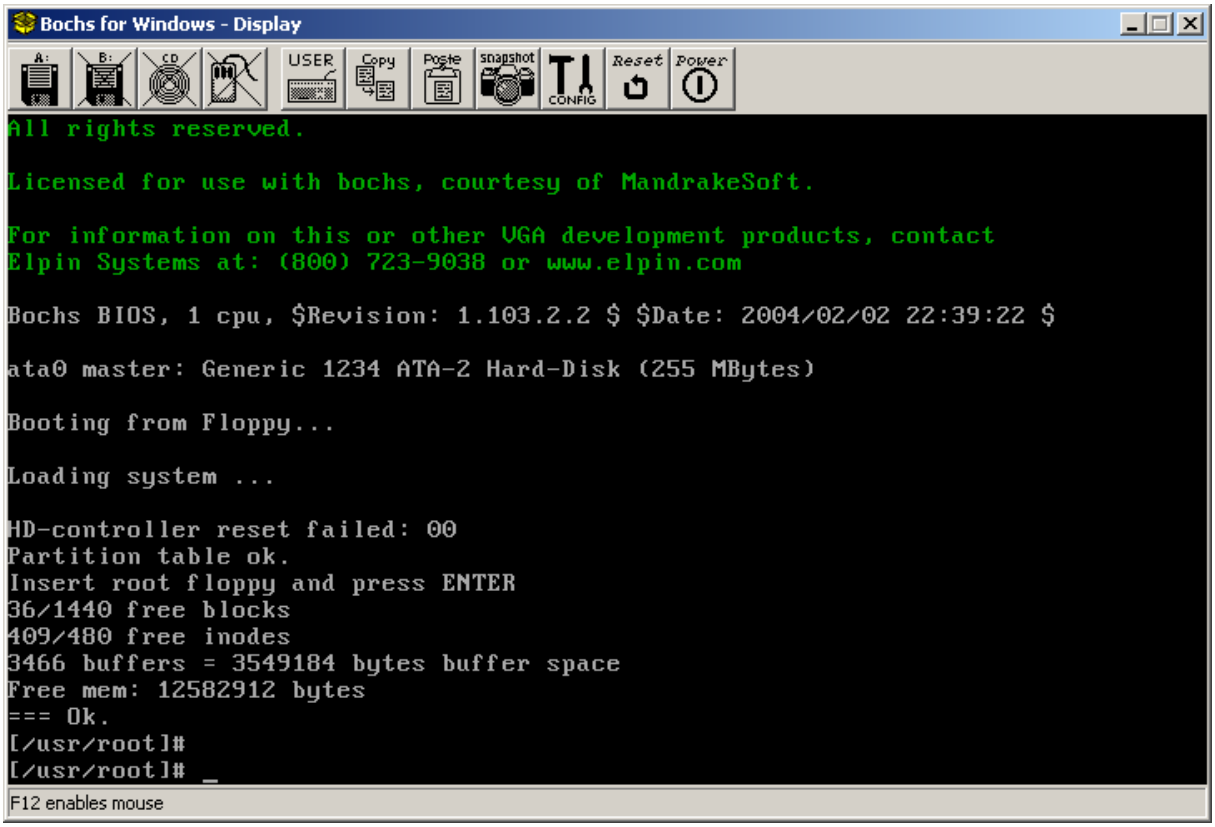

图 14-4 Bochs 中运行的 Linux 0.11 系统

14.5.4 在 hdc.img 上建立根文件系统

由于软盘容量太小，若要让 Linux 0.11 系统真正能做点什么的话，就需要在硬盘（这里是指硬盘 Image 文件）上建立根文件系统。在前面我们已经建立一个 256MB 的硬盘 Image 文件 hdc.img，并且此时已经连接到了运行着的 Bochs 环境中，因此上图中出现一条有关硬盘的信息：

“ata0 master: Generic 1234 ATA-2 Hard-Disk (255 Mbytes)”

如果没有看到这条信息，说明你的 Linux 0.11 配置文件没有设置正确。请重新编辑 bochsrc.bxrc 文件，并重新运行 Bochs 系统，直到出现上述相同画面。

我们在前面已经在 hdc.img 第 1 个分区上建立了 MINIX 文件系统。若还没建好或者想再试一边的话，那么就请键入一下命令来建立一个 64MB 的文件系统：

```
[/usr/root]# mkfs /dev/hd1 64000
```

现在可以开始加载硬盘上的文件系统了。执行下列命令，把新的文件系统加载到/mnt 目录上。

```
[/usr/root]# cd /
[/]# mount /dev/hd1 /mnt
[/]#
```

在加载了硬盘分区上的文件系统之后，我们就可以把软盘上的根文件系统复制到硬盘上去了。请执行以下命令：

```
[/]# cd /mnt
[/mnt]# for i in bin dev etc usr tmp
> do
> cp +recursive +verbose /$i $i
done
```

此时软盘根文件系统上的所有文件就会被复制到硬盘上的文件系统中。在复制过程中会出现很多类似下面的信息。

```
/usr/bin/mv -> usr/bin/mv
/usr/bin/rm -> usr/bin/rm
/usr/bin/rmdir -> usr/bin/rmdir
/usr/bin/tail -> usr/bin/tail
/usr/bin/more -> usr/bin/more
/usr/local -> usr/local
/usr/root -> usr/root
/usr/root/.bash_history -> usr/root/.bash_history
/usr/root/a.out -> usr/root/a.out
/usr/root/hello.c -> usr/root/hello.c
/tmp -> tmp
[/mnt]# _
```

现在说明你已经在硬盘上建立好了一个基本的根文件系统。你可以在新文件系统中随处查看一下。然后卸载硬盘文件系统，并键入'logout'或'exit'退出 Linux 0.11 系统。此时会显示如下信息：

```
[/mnt]# cd /
[/]# umount /dev/hd1
[/]# logout

child 4 died with code 0000
[/usr/root]# _
```

14.5.5 使用硬盘 Image 上的根文件系统

一旦你在硬盘 Image 文件上建立好文件系统，就可以让 Linux 0.11 以它作为根文件系统启动。这通过修改引导盘 bootimage-0.11 文件的第 509、510 字节的内容就可以实现。请按照以下步骤来进行。

1. 首先复制 bootimage-0.11 和 bochsrc.bxrc 两个文件，产生 bootimage-0.11-hd 和 bochsrc-hd.bxrc 文件。
2. 编辑 bochsrc-hd.bxrc 配置文件。把其中的'floppya:'上的文件名修改成'bootimage-0.11-hd'，并存盘。

3. 用 UltraEdit 或任何其他可修改二进制文件的编辑器（winhex 等）编辑 bootimage-0.11-hd 二进制文件。修改第 509、510 字节（原值应该是 00、00）为 01、03，表示根文件系统设备在硬盘 Image 的第 1 个分区上。然后存盘退出。如果把文件系统安装在了别的分区上，那么需要修改前 1 个字节以对应到你的分区上。

000001f0h: 00 00 00 00 00 00 00 00 00 00 00 00 **01 03** 55 AA ; ....U?

现在可以双击 bochsrc-hd.bxrc 配置文件的图标，Bochs 系统应该会快速进入 Linux 0.11 系统并显示出图 14-5 中图形来。

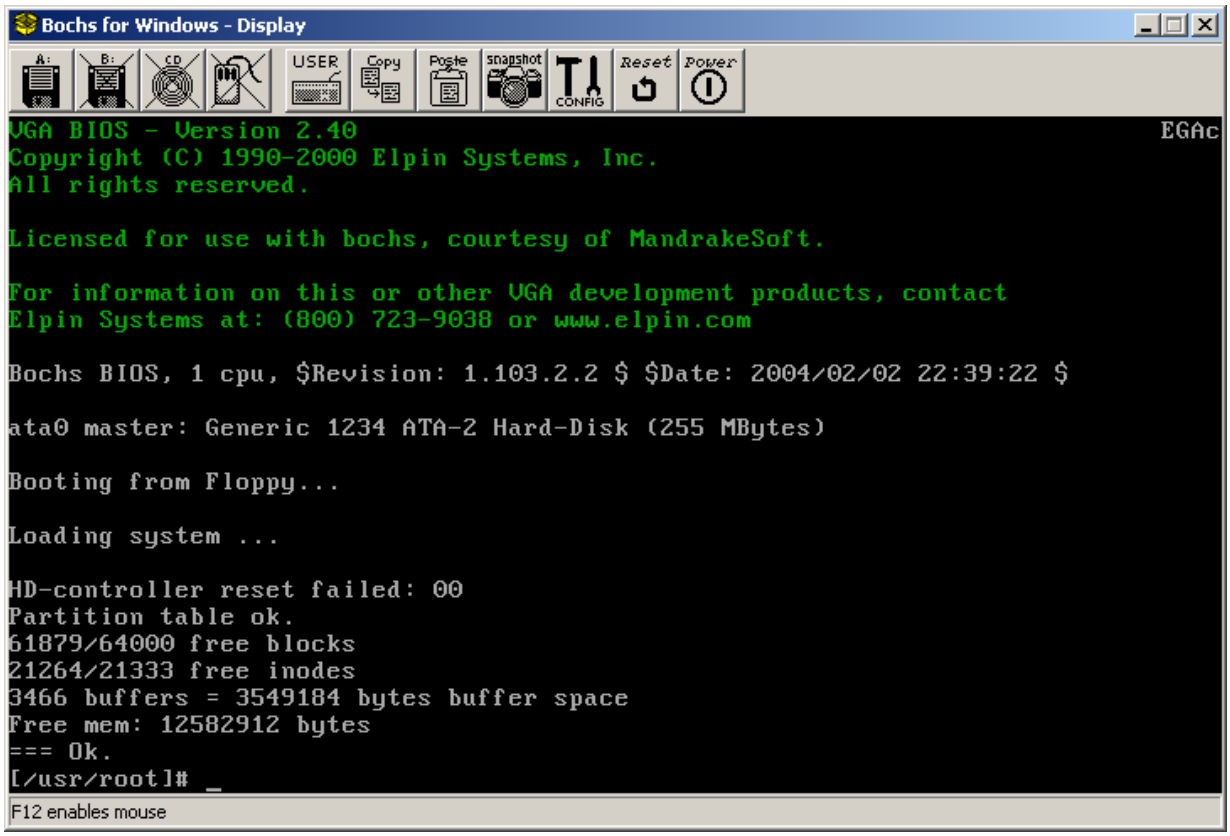

图 14-5 使用硬盘 Image 文件上的文件系统

14.6 在 Linux 0.11 系统上编译 0.11 内核

目前作者已经重新组建了一个带有 gcc 1.40 编译环境的 Linux 0.11 系统软件包。该系统设置成在 Bochs 仿真系统下运行，并且已经配置好相应的 bochs 配置文件。该软件包可从下面地址得到。

http://oldlinux.org/Linux.old/bochs/linux-0.11-devel-040817.zip 或
http://oldlinux.org/Linux.old/bochs/linux-0.11-devel-040923.zip

该软件包中含有一个 README 文件，其中说明了软件包中所有文件的作用和使用方法。若你的系统中已经安装了 bochs 系统，那么只需双击配置文件 bochs-hd.bxrc 的图标即可运行硬盘 Image 文件作为根文件系统的 Linux 0.11。在/usr/src/linux 目录下键入'make'命令即可编译 Linux 0.11 内核源代码，并生

成引导启动映像文件 Image。若需要输出这个 Image 文件，可以首先备份 bootimage-0.11-hd 文件，然后使用下面命令就会把 bootimage-0.11-hd 替换成新的引导启动文件。直接重新启动 Bochs 即可使用该新编译生成的 bootimage-0.11-hd 来引导系统。

```
[/usr/src/linux]# make
[/usr/src/linux]# dd bs=8192 if=Image of=/dev/fd0
[/usr/src/linux]# _
```

也可以使用 mtools 命令把新生成的 Image 文件写到第 2 个软盘映像文件 diskb.img 中，然后使用工具软件 WinImage 将 diskb.img 中的'Image'文件取出。

```
[/usr/src/linux]# mcopy Image b:
Copying IMAGE
[/usr/src/linux]# mcopy System.map b:
Copying SYSTEM.MAP
[/usr/src/linux]# mdir b:
 Volume in drive B is B.
 Directory for B:/
GCCLIB-1 TAZ      934577    3-29-104   7:49p
IMAGE             121344    4-29-104  11:46p
SYSTEM   MAP       17162    4-29-104  11:47p
README               764    3-29-104   8:03p
       4 File(s)     382976 bytes free
[/usr/src/linux]# _
```

如果想把新的引导启动 Image 文件与软盘上的根文件系统 rootimage-0.11 一起使用，那么在编译之前首先编辑 Makefile 文件，使用#注释掉'ROOT_DEV='一行内容即可。

在编译内核时通常可以很顺利地完成。可能出现的问题是编译器 gcc 不能识别选项'-mstring-ins'，这个选项是 Linus 对自己编译的 gcc 1.40 编译器做的扩展实验参数，用于对 gcc 生成字符串指令时进行优化处理。为了解决这个问题，可以直接删除所有 Makefile 中的这个参数再重新编译内核。另一个可能出现的问题是找不到 gar 命令，此时可以把/usr/local/bin/下的 ar 直接链接或复制/改名成 gar 即可。

14.7 在 Redhat 9 系统下编译 Linux 0.11 内核

最初的 Linux 操作系统内核是在 Minix 1.5.10 操作系统的扩展版本 Minix-i386 上交叉编译开发的。Minix 1.5.10 该版本的操作系统是随 A.S. Tanenbaum 的《Minix 设计与实现》一书第 1 版一起由 Prentice Hall 发售的。该版本的 Minix 虽然可以运行在 80386 及其兼容微机上，但并没有利用 80386 的 32 位机制。为了能在该系统上进行 32 位操作系统的开发，Linus 使用了 Bruce Evans 的补丁程序将其升级为 MINIX-386，并把 GNU 的系列开发工具 gcc、gld、emacs、bash 等移植到 Minix-386 上。在这个平台上，Linus 进行交叉编译，开发出 Linux 0.01、0.03、0.11 等版本的内核。作者曾根据 Linux 邮件列表中的文章介绍，建立起了类似 Linus 当时的开发平台，并顺利地编译出 Linux 的早期版本内核（见 http://oldlinux.org 论坛中的介绍）。

但由于 Minix 1.5.10 早已过时，而且该开发平台的建立非常烦琐，因此这里只简单介绍一下如何修改 Linux 0.11 版内核源代码，使其能在目前常用的 RedHat 9 操作系统标准的编译环境下进行编译，生成可运行的启动映像文件 bootimage。读者可以在普通 PC 机上或 Bochs 等虚拟机软件中运行它。这里仅给

出主要的修改方面，所有的修改之处可使用工具 diff 来比较修改后和未修改前的代码，找出其中的区别。假如，未修改过的代码在 linux 目录中，修改过的代码在 linux-mdf 中，则需要执行下面的命令：

diff -r linux linux-mdf > dif.out

其中文件 dif.out 中即包含代码中所有修改过的地方。已经修改好并能在 RedHat 9 下编译的 Linux 0.11 内核源代码可以从下面地址处下载：

http://oldlinux.org/Linux.old/kernel/linux-0.11-040327-rh9.tar.gz
http://oldlinux.org/Linux.old/kernel/linux-0.11-040327-rh9.diff.gz

用编译好的启动映像文件软盘启动时，屏幕上应该会显示以下信息：

```
Booting from Floppy...
Loading system ...

Insert root floppy and press ENTER
```

如果在显示出“Loding system...”后就没有反应了，这说明内核不能识别计算机中的硬盘控制器子系统。可以找一台老式的 PC 机再试试，或者使用 vmware、bochs 等虚拟机软件试验。在要求插入根文件系统盘时，如果直接按回车键，则会显示以下不能加载根文件系统的信息，并且死机。若要完整地运行 linux 0.11 操作系统，则还需要与之相配的根文件系统，可以到 oldlinux.org 网站上下载一个使用。

http://oldlinux.org/Linux.old/images/rootimage-0.11-for-orig

14.7.1 修改 makefile 文件

在 Linux 0.11 内核代码文件中，几乎每个子目录中都包括一个 makefile 文件，需要对它们都进行以下修改：

a. 将 gas =>as, gld=>ld。现在 gas 和 gld 已经直接改名称为 as 和 ld 了。
b. as(原 gas)已经不用-c 选项，所以要将 Makefile, 因此需要去掉其-c 编译选项。在内核主目录 Linux 下 makefile 文件中，是在 34 行上。
c. 去掉 gcc 的编译标志选项：-fcombine-regs、-mstring-insns 以及所有子目录中 Makefile 中的这两个选项。在 94 年的 gcc 手册中就已找不到-fcombine-regs 选项，而-mstring-insns 是 Linus 自己对 gcc 的修改增加的选项，所以你我的 gcc 中肯定不包括这个优化选项。
d. 在 gcc 的编译标志选项中，增加-m386 选项。这样在 RedHat 9 下编译出的内核映像文件中就不含有 80486 及以上 CPU 的指令，因此该内核就可以运行在 80386 机器上。

14.7.2 修改汇编程序中的注释

as86 编译程序不能识别 c 语言的注释语句，因此需要使用!注释掉 boot/bootsect.s 文件中的 C 注释语句。

14.7.3 内存位置对齐语句 align 值的修改

在 boot 目录下的三个汇编程序中，align 语句使用的方法目前已经改变。原来 align 后面带的数值是

指对起内存位置的幂次值，而现在则需要直接给出对起的整数地址值。因此，原来的语句：
.align 3
需要修改成(2 的 3 次幂值 2^3=8)：
.align 8

14.7.4 修改嵌入宏汇编程序

由于对 as 的不断改进，目前其自动化程度越来越高，因此已经不需要人工指定一个变量需使用的 CPU 寄存器。因此内核代码中的__asm__("ax")需要全部去掉。例如 fs/bitmap.c 文件的第 20 行、26 行上，fs/namei.c 文件的第 65 行上等。

在嵌入汇编代码中，另外还需要去掉所有对寄存器内容无效的声明。例如 include/string.h 中第 84 行：
:"si","di","ax","cx");
需要修改成如下的样子：
:);

14.7.5 c 程序变量在汇编语句中的引用表示

在开发 Linux 0.11 时所用的汇编器，在引用 C 程序中的变量时需要在变量名前加一下划线字符'_'，而目前的 gcc 编译器可以直接识别使用这些汇编中引用的 c 变量，因此需要将汇编程序（包括嵌入汇编语句）中所有 c 变量之前的下划线去掉。例如 boot/head.s 程序中第 15 行语句：
.globl _idt,_gdt,_pg_dir,_tmp_floppy_area
需要改成：
.globl idt,gdt,pg_dir,tmp_floppy_area
第 31 行语句：
lss _stack_start,%esp
需要改成：
lss stack_start,%esp

14.7.6 保护模式下调试显示函数

在进入保护模式之前,可以用 ROM BIOS 中的 int 0x10 调用在屏幕上显示信息,但进入了保护模式后，这些中断调用就不能使用了。为了能在保护模式运行环境中了解内核的内部数据结构和状态，我们可以使用下面这个数据显示函数 check_data32()[10]。内核中虽然有 printk()显示函数,但是它需要调用 tty_write(),在内核没有完全运转起来该函数是不能使用的。这个 check_data32()函数可以在进入保护模式后,在屏幕上打印你感兴趣的东西。起用页功能与否，不影响效果，因为虚拟内存在 4M 之内，正好使用了第一个页表目录项，而页表目录从物理地址 0 开始，再加上内核数据段基地址为 0，所以 4M 范围内，虚拟内存与线性内存以及物理内存的地址相同。linus 当初可能也这样斟酌过的，觉得这样设置使用起来比较方便☺。

嵌入式汇编语句的使用方法参见 5.4.3.1 节中的说明。

```
/*
* 作用：在屏幕上用 16 进制显示一个 32 位整数。
* 参数：value -- 要显示的整数。
*       pos   -- 屏幕位置,以 16 个字符宽度为单位,例如为 2,即表示从左上角 32 字符宽度处开始显示。
* 返回：无。
* 如果要在汇编程序中用，要保证该函数被编译链接进了内核.gcc 汇编中的用法如下:
```

[10] 该函数由 oldlinux.org 论坛上的朋友 notrump 提供。

```
* pushl  pos      //pos 要用你实际的数据代替,例如 pushl $4
* pushl  value    //pos 和 value 可以是任何合法的寻址方式
* call   check_data32
*/
inline void check_data32(int value, int pos)
{
__asm__ __volatile__(                          // %0 - 含有欲显示的值 value; ebx - 屏幕位置。
"shl    $4, %%ebx\n\t"              // 将 pos 值乘 16，在加上 VGA 显示内存起始地址，
"addl   $0xb8000, %%ebx\n\t"        // ebx 中得到在屏幕左上角开始的显示字符位置。
"movl   $0xf0000000, %%eax\n\t"     // 设置 4 比特屏蔽码。
"movb   $28, %%cl\n"                // 设置初始右移比特数值。
"1:\n\t"
"movl   %0, %%edx\n\t"              // 取欲显示的值 value➔edx
"andl   %%eax, %%edx\n\t"           // 取 edx 中有 eax 指定的 4 个比特。
"shr    %%cl, %%edx\n\t"            // 右移 28 位，edx 中即为所取 4 比特的值。
"add    $0x30, %%dx\n\t"            // 将该值转换成 ASCII 码。
"cmp    $0x3a, %%dx\n\t"            // 若该 4 比特数值小于 10，则向前跳转到标号 2 处。
"jb2f\n\t"
"add    $0x07, %%dx\n"              // 否则再加上 7，将值转换成对应字符 A—F。
"2:\n\t"
"add    $0x0c00, %%dx\n\t"          // 设置显示属性。
"movw   %%dx, (%%ebx)\n\t"          // 将该值放到显示内存中。
"sub    $0x04, %%cl\n\t"            // 准备显示下一个 16 进制数，右移比特位数减 4。
"shr    $0x04, %%eax\n\t"           // 比特位屏蔽码右移 4 位。
"add    $0x02, %%ebx\n\t"           // 更新显示内存位置。
"cmpl   $0x0, %%eax\n\t"            // 屏蔽码值已经移出右端（已经显示完 8 个 16 进制数）？
"jnz1b\n"                           // 还有数值需要显示，则向后跳转到标号 1 处。
::"m"(value), "b"(pos));
}
```

14.8 利用 bochs 调试内核

Bochs 具有非常强大的操作系统内核调试功能。这也是本文选择 Bochs 作为首选实验环境的主要原因之一。有关 Bochs 调试功能的说明参见前面 14.2 节，这里基于 Linux 0.11 内核来说明 Windows 环境下 Bochs 系统调试操作的基本方法。

14.8.1 运行 Bochs 调试程序

我们假设 Bochs 系统已被安装在目录“C:\Program Files\Bochs-2.1.1\”中，并且 Linux 0.11 系统的 Bochs 配置文件名称是 bochsrc-hd.bxrc。现在在包含内核 Image 文件的目录下建立一个简单的批处理文件 run.bat，其内容如下：

```
"C:\Program Files\Bochs-2.1.1\bochsdbg" -q -f bochsrc-hd.bxrc
```

其中 bochsdbg 是 Bochs 系统的调试执行程序。运行该批处理命令即可进入调试环境。此时 Bochs 的主显示窗口空白，而控制窗口将显示以下类似内容：

```
C:\Documents and Settings\john1\桌面\Linux-0.11>"C:\Program Files\Bochs-2.1.1\bo
chsdbg" -q -f bochsrc-hd.bxrc
========================================================================
                       Bochs x86 Emulator 2.1.1
                           February 08, 2004
========================================================================
00000000000i[     ] reading configuration from bochsrc-hd.bxrc
00000000000i[     ] installing win32 module as the Bochs GUI
00000000000i[     ] Warning: no rc file specified.
00000000000i[     ] using log file bochsout.txt
Next at t=0
(0) context not implemented because BX_HAVE_HASH_MAP=0
[0x000ffff0] f000:fff0 (unk. ctxt): jmp f000:e05b             ; ea5be000f0
<bochs:1>
```

此时 Bochs 调试系统已经准备好开始运行，CPU 执行指针已指向 ROM BIOS 中地址 0x000fffff0 处的指令处。其中'<bochs:1>'是命令输入提示符，其中的数字表示当前的命令序列号。在命令提示符'<bochs:1>'后面键入'help'命令，可以列出调试系统的基本命令。若要了解某个命令的具体使用方法，可以键入'help'命令并且后面跟随一个用单引号括住的具体命令，例如：“help 'vbreak'”，如下面所示。

```
<bochs:1> help
help - show list of debugger commands
help 'command'- show short command description
-*- Debugger control -*-
    help, q|quit|exit, set, instrument, show, trace-on, trace-off,
    record, playback, load-symbols, slist
-*- Execution control -*-
    c|cont, s|step|stepi, p|n|next, modebp
-*- Breakpoint management -*-
    v|vbreak, lb|lbreak, pb|pbreak|b|break, sb, sba, blist,
    bpe, bpd, d|del|delete
-*- CPU and memory contents -*-
    x, xp, u|disas|disassemble, r|reg|registers, setpmem, crc, info, dump_cpu,
    set_cpu, ptime, print-stack, watch, unwatch, ?|calc
<bochs:2> help 'vbreak'
help vbreak
vbreak seg:off - set a virtual address instruction breakpoint
<bochs:3>
```

为了让 Bochs 直接模拟执行到 Linux 的引导启动程序开始处，我们可以先使用断点命令在 0x7c00 处设置一个断点，然后让系统连续运行到 0x7c00 处停下来。执行的命令序列如下：

```
<bochs:3> vbreak 0x0000:0x7c00
<bochs:4> c
(0) Breakpoint 1, 0x7c00 (0x0:0x7c00)
Next at t=4409138
(0) [0x00007c00] 0000:7c00 (unk. ctxt): mov ax, 0x7c0             ; b8c007
<bochs:5>
```

此时，CPU 执行到 boot.s 程序开始处的第 1 条指令处，Bochs 主窗口将显示出“Boot From floppy...”

等一些信息。现在，我们可以利用单步执行命令's'或'n'（不跟踪进入子程序）来跟踪调试程序了。在调试时可以使用 Bochs 的断点设置命令、反汇编命令、信息显示命令等来辅助我们的调试操作。下面是一些常用命令的示例：

```
<bochs:8> u /10                                 # 反汇编从当前地址开始的 10 条指令。
00007c00: (                   ): mov ax, 0x7c0          ; b8c007
00007c03: (                   ): mov ds, ax             ; 8ed8
00007c05: (                   ): mov ax, 0x9000         ; b80090
00007c08: (                   ): mov es, ax             ; 8ec0
00007c0a: (                   ): mov cx, 0x100          ; b90001
00007c0d: (                   ): sub si, si             ; 29f6
00007c0f: (                   ): sub di, di             ; 29ff
00007c11: (                   ): rep movs word ptr [di], word ptr [si] ; f3a5
00007c13: (                   ): jmp 9000:0018          ; ea18000090
00007c18: (                   ): mov ax, cs             ; 8cc8
<bochs:9> info r                                # 查看当前 CPU 寄存器的内容
eax            0xaa55           43605
ecx            0x110001         1114113
edx            0x0              0
ebx            0x0              0
esp            0xfffe           0xfffe
ebp            0x0              0x0
esi            0x0              0
edi            0xffe4           65508
eip            0x7c00           0x7c00
eflags         0x282            642
cs             0x0              0
ss             0x0              0
ds             0x0              0
es             0x0              0
fs             0x0              0
gs             0x0              0
<bochs:10> print-stack                          # 显示当前堆栈的内容
   0000fffe [0000fffe]  0000
   00010000 [00010000]  0000
   00010002 [00010002]  0000
   00010004 [00010004]  0000
   00010006 [00010006]  0000
   00010008 [00010008]  0000
   0001000a [0001000a]  0000
...
<bochs:11> dump_cpu                             # 显示 CPU 中的所有寄存器和状态值。
eax:0xaa55
ebx:0x0
ecx:0x110001
edx:0x0
ebp:0x0
esi:0x0
edi:0xffe4
esp:0xfffe
eflags:0x282
eip:0x7c00
```

```
cs:s=0x0, dl=0xffff, dh=0x9b00, valid=1
ss:s=0x0, dl=0xffff, dh=0x9300, valid=7
ds:s=0x0, dl=0xffff, dh=0x9300, valid=1
es:s=0x0, dl=0xffff, dh=0x9300, valid=1
fs:s=0x0, dl=0xffff, dh=0x9300, valid=1
gs:s=0x0, dl=0xffff, dh=0x9300, valid=1
ldtr:s=0x0, dl=0x0, dh=0x0, valid=0
tr:s=0x0, dl=0x0, dh=0x0, valid=0
gdtr:base=0x0, limit=0x0
idtr:base=0x0, limit=0x3ff
dr0:0x0
dr1:0x0
dr2:0x0
dr3:0x0
dr6:0xffff0ff0
dr7:0x400
tr3:0x0
tr4:0x0
tr5:0x0
tr6:0x0
tr7:0x0
cr0:0x60000010
cr1:0x0
cr2:0x0
cr3:0x0
cr4:0x0
inhibit_mask:0
done
<bochs:12>
```

由于 Linux 0.11 内核的 32 位代码是从绝对物理地址 0 处开始存放的，因此若想直接执行到 32 位代码开始处，即 head.s 程序开始处，我们可以在线性地址 0x0000 处设置一个断点并运行命令'c'执行到那个位置处。

另外，当直接在命令提示符下打回车键时会重复执行上一个命令；按向上方向键会显示上一命令。其他命令的使用方法请参考'help'命令。

14.8.2 定位内核中的变量或数据结构

在编译内核时会产生一个 system.map 文件。该文件列出了内核 Image (bootimage)文件中全局变量和各个模块中的局部变量的偏移地址位置。在内核编译完成后可以使用前面介绍的文件导出方法把 system.map 文件抽取到主机环境（windows）中。有关 system.map 文件的详细功能和作用请参见 2.10.3 节。system.map 样例文件中的部分内容见如下所示。利用这个文件，我们可以在 Bochs 调试系统中快速地定位某个变量或跳转到指定的函数代码处。

```
...
Global symbols:

  _dup: 0x16e2c
  _nmi: 0x8e08
  _bmap: 0xc364
```

```
  _iput: 0xc3b4
  _blk_dev_init: 0x10ed0
  _open: 0x16dbc
  _do_execve: 0xe3d4
  _con_init: 0x15ccc
  _put_super: 0xd394
  _sys_setgid: 0x9b54
  _sys_umask: 0x9f54
  _con_write: 0x14f64
  _show_task: 0x6a54
  _buffer_init: 0xd1ec
  _sys_settimeofday: 0x9f4c
  _sys_getgroups: 0x9edc
...
```

同样，由于 Linux 0.11 内核的 32 位代码是从绝对物理地址 0 处开始存放的，system.map 中全局变量的偏移位置值就是 CPU 中线性地址位置，因此我们可以直接在感兴趣的变量或函数名位置处设置断点，并让程序连续执行到指定的位置处。例如若我们想调试函数 buffer_init()，那么从 system.map 文件中可以知道它位于 0xd1ec 处。此时我们可以在该处设置一个线性地址断点，并执行命令'c'让 CPU 执行到这个指定的函数开始处，见如下所示。

```
<bochs:12> lb 0xd1ec                                    # 设置线性地址断点。
<bochs:13> c                                            # 连续执行。
(0) Breakpoint 2, 0xd1ec in ?? ()
Next at t=16689666
(0) [0x0000d1ec] 0008:0000d1ec (unk. ctxt): push ebx                    ; 53
<bochs:14> n                                            # 执行下一指令。
Next at t=16689667
(0) [0x0000d1ed] 0008:0000d1ed (unk. ctxt): mov eax, dword ptr ss:[esp+0x8] ; 8b442408
<bochs:15> n                                            # 执行下一指令。
Next at t=16689668
(0) [0x0000d1f1] 0008:0000d1f1 (unk. ctxt): mov edx, dword ptr [ds:0x19958] ; 8b1558990100
<bochs:16>
```

程序调试是一种技能，需要多练习才能熟能生巧。上面介绍的一些基本命令需要组合在一起使用才能灵活地观察到内核代码执行的整体环境情况。

14.9 内核引导启动+根文件系统组成的集成盘

本节内容主要说明制作由内核引导启动映像文件和根文件系统组合成的集成盘映像文件的制作原理和方法。主要目的是了解 Linux 0.11 内核内存虚拟盘工作原理，并进一步理解引导盘和根文件系统盘的概念。加深对 kernel/blk_drv/ramdisk.c 程序运行方式的理解。在制作这个集成盘之前，我们需要首先下载或准备好以下实验软件：

http://oldlinux.org/Linux.old/bochs/linux-0.11-devel-040923.zip
http://oldlinux.org/Linux.old/images/rootimage-0.11-for-orig

linux-0.11-devel 是运行在 Bochs 下的带开发环境的 Linux 0.11 系统，rootimage-0.11 是 1.44MB 软盘映像文件中的 Linux 0.11 根文件系统。后缀'for-orig'是指该根文件系统适用于未经修改的 Linux 0.11 内核源代码编译出的内核引导启动映像文件。当然这里所说的“未经修改”是指没有对内核作过什么大的改动，因为我们还是要修改编译配置文件 Makefile，以编译生成含有内存虚拟盘的内核代码来。

14.9.1 集成盘制作原理

通常我们使用软盘启动 Linux 0.11 系统时需要两张盘（这里“盘”均指对应软盘的 Image 文件）：一张是内核引导启动盘，一张是基本的根文件系统盘。这样必须使用两张盘才能引导启动系统来正常运行一个基本的 Linux 系统，并且在运行过程中根文件系统盘必须一直保持在软盘驱动器中。而我们这里描述的集成盘是指把内核引导启动盘和一个基本的根文件系统盘的内容合成制作在一张盘上。这样我们使用一张集成盘就能引导启动 Linux 0.11 系统到命令提示符状态。集成盘实际上就是一张含有根文件系统的内核引导盘。

为了能运行集成盘系统，该盘上的内核代码中需要开启内存虚拟盘（RAMDISK）的功能。这样集成盘上的根文件系统就能被加载到内存中的虚拟盘中，从而系统上的两个软盘驱动器就能腾出来用于加载（mount）其他文件系统盘或派其他用途。下面我们再详细介绍一下在一张 1.44MB 盘上制作成集成盘的原理和步骤。

14.9.1.1 引导过程原理

Linux 0.11 的内核在初始化时会根据编译时设置的 RAMDISK 选项判断在系统物理内存是否要开辟虚拟盘区域。如果没有设置 RAMDISK（即其长度为 0）则内核会根据 ROOT_DEV 所设置的根文件系统所在设备号，从软盘或硬盘上加载根文件系统，执行无虚拟盘时的一般启动过程。

如果在编译 Linux 0.11 内核源代码时，在其 linux/Makefile 配置文件中定义了 RAMDISK 的大小，则内核代码在引导并初始化 RAMDISK 区域后就会首先尝试检测启动盘上的第 256 磁盘块（每个磁盘块为 1KB，即 2 个扇区）开始处是否存在一个根文件系统。检测方法是判断第 257 磁盘块中是否存在一个有效的文件系统超级块信息。如果有，则将该文件系统加载到 RAMDISK 区域中，并将其作为根文件系统使用。从而我们就可以使用一张集成了根文件系统的启动盘来引导系统到 shell 命令提示符状态。若启动盘上指定磁盘块位置（第 256 磁盘块）上没有存放一个有效的根文件系统，那么内核就会提示插入根文件系统盘。在用户按下回车键确认后，内核就把处于独立盘上的根文件系统整个地读入到内存的虚拟盘区域中去执行。这个检测和加载过程见图 14-6 所示。

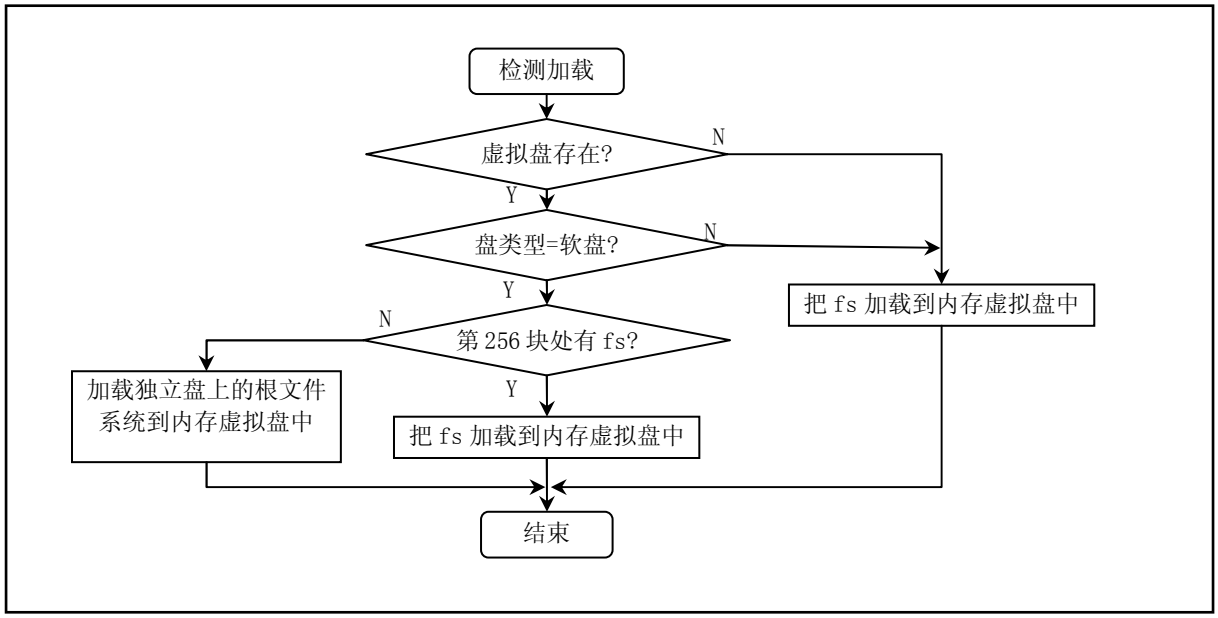

图 14-6 加载根文件系统到内存虚拟盘区域的流程图

14.9.1.2 集成盘的结构

对于 Linux 0.1x 内核，其代码加数据段的长度很小，大约在 120KB 左右。在开发 Linux 系统初始阶段，即使考虑到内核的扩展，Linus 还是认为内核的长度不会超过 256KB，因此在 1.44MB 的盘上可以把一个基本的根文件系统放在启动盘的第 256 个磁盘块开始的地方，组合形成一个集成盘片。一个添加了基本根文件系统的引导盘（即集成盘）的结构示意图见图 14-7 所示。其中文件系统的详细结构请参见文件系统一章中的说明。

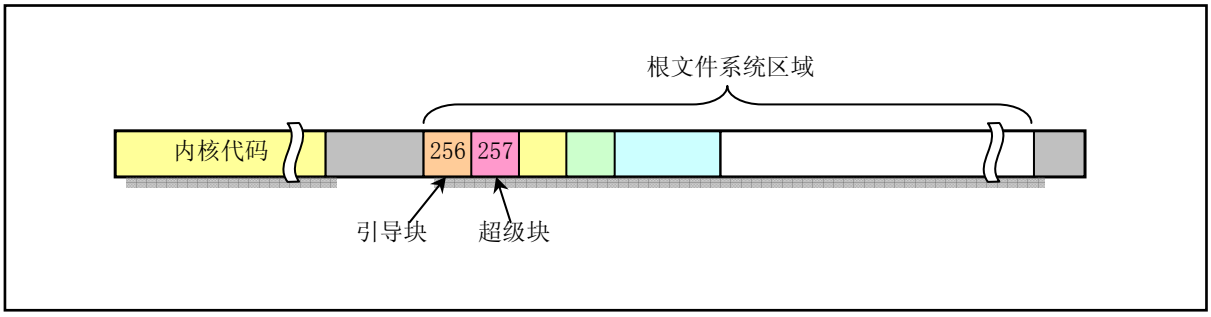

图 14-7 集成盘上代码结构

如上所述，集成盘上根文件系统放置的位置和大小主要与内核的长度和定义的 RAMDISK 区域的大小有关。Linus 在 ramdisk.c 程序中默认地定义了这个根文件系统的开始放置位置为第 256 磁盘块开始的地方。对于 Linux 0.11 内核来讲，编译产生的内核 Image 文件（即引导启动盘 Image 文件）的长度在 120KB 左右，因此把根文件系统放在盘的第 256 磁盘块开始的地方肯定没有问题，只是稍许浪费了一点磁盘空间。还剩下共有 1440 - 256 = 1184 KB 空间可用来存放根文件系统。当然我们也可以根据具体编译出的内核大小来调整存放根文件系统的开始磁盘块位置。例如我们可以修改 ramdisk.c 第 75 行 block 的值为 130 把存放根文件系统的开始位置往前挪动一些以腾出更多的磁盘空间供盘上的根文件系统使用。

14.9.2 集成盘的制作过程

在不改动内核程序 ramdisk.c 中默认定义的根文件系统开始存放磁盘块位置的情况下，我们假设需要

制作集成盘上的根文件系统的容量为 1024KB（最大不超过 1184KB）。制作集成盘的主要思路是首先建立一个 1.44MB 的空的 Image 盘文件，然后将新编译出的开启了 RAMDISK 功能的内核 Image 文件复制到该盘的开始处。再把定制的大小不超过 1024KB 的文件系统复制到该盘的第 256 磁盘块开始处。具体制作步骤如下所示。

14.9.2.1 重新编译内核

重新编译带有 RAMDISK 定义的内核 Image 文件，假定 RAMDISK 区域设置为 2048KB。方法如下：在 Bochs 系统中运行 linux-0.11-devel 系统。编辑其中的/usr/src/linux/Makefile 文件，修改以下设置行：

```
RAMDISK = -DRAMDISK = 2048
ROOT_DEV = FLOPPY
```

然后重新编译内核源代码生成新的内核 Image 文件。

```
make clean; make
```

14.9.2.2 制作临时根文件系统

制作大小为 1024KB 的根文件系统 Image 文件，假定其文件名为 rootram.img。制作方法如下：

(1) 利用本章前面介绍的方法制作一张大小为 1024KB 的空 Image 文件。假定该文件的名称是 rootram.img。可使用在现在的 Linux 系统下执行下面命令生成：

```
    dd bs=1024 if=/dev/zero of=rootram.img count=1024
```

(2) 在 Bochs 系统中运行 linux-0.11-devel 系统。然后在 Bochs 主窗口上把驱动盘分别配置成：A 盘为 rootimage-0.11-orign；B 盘为 rootram.img。

(3) 使用下面命令在 rootram-0.11 盘上创建大小为 1024KB 的空文件系统。然后使用下列命令分别把 A 盘和 B 盘加载到/mnt 和/mnt1 目录上。若目录/mnt1 不存在，可以建立一个。

```
mkfs /dev/fd1 1024
mkdir /mnt1
mount /dev/fd0 /mnt
mount /dev/fd1 /mnt1
```

(4) 使用 cp 命令有选择性地复制/mnt 上 rootimage-0.11-orign 中的文件到/mnt1 目录中，在/mnt1 中制作出一个根文件系统。若遇到出错信息，那么通常是容量已经超过了 1024KB 了。利用下面的命令或使用本章前面介绍的方法来建立根文件系统。

首先精简/mnt/中的文件，以满足容量不要超过 1024KB 的要求。我们可以删除一些/bin 和/usr/bin 下的文件来达到这个要求。关于容量可以使用 df 命令来查看。例如我选择保留的文件是以下一些：

```
[/bin]# ll
total 495
-rwx--x--x   1 root     root        29700 Apr 29 20:15 mkfs
-rwx--x--x   1 root     root        21508 Apr 29 20:15 mknod
-rwx--x--x   1 root     root        25564 Apr 29 20:07 mount
-rwxr-xr-x   1 root     root       283652 Sep 28 10:11 sh
-rwx--x--x   1 root     root        25646 Apr 29 20:08 umount
-rwxr-xr-x   1 root     4096       116479 Mar  3  2004 vi
```

```
[/bin]#[/bin]# cd /usr/bin
[/usr/bin]# ll
total 364
-rwxr-xr-x   1 root     root        29700 Jan 15  1992 cat
-rwxr-xr-x   1 root     root        29700 Mar  4  2004 chmod
-rwxr-xr-x   1 root     root        33796 Mar  4  2004 chown
-rwxr-xr-x   1 root     root        37892 Mar  4  2004 cp
-rwxr-xr-x   1 root     root        29700 Mar  4  2004 dd
-rwx--x--x   1 root     4096        36125 Mar  4  2004 df
-rwx--x--x   1 root     root        46084 Sep 28 10:39 ls
-rwxr-xr-x   1 root     root        29700 Jan 15  1992 mkdir
-rwxr-xr-x   1 root     root        33796 Jan 15  1992 mv
-rwxr-xr-x   1 root     root        29700 Jan 15  1992 rm
-rwxr-xr-x   1 root     root        25604 Jan 15  1992 rmdir
[/usr/bin]#
```

然后利用下列命令复制文件。另外，可以按照自己的需要修改一下/etc/fstab 和/etc/rc 文件中的内容。

```
cd /user
for i in bin dev etc usr tmp
do
cp +recursive +verbose /$i $i
done
sync
```

(5) 使用 umount 命令卸载/dev/fd0 和/dev/fd1 上的文件系统，然后使用 dd 命令把/dev/fd1 中的文件系统复制到 Linux-0.11-devel 系统中，建立一个名称为 rootram-0.11 的根文件系统 Image 文件：

```
dd bs=1024 if=/dev/fd1 of=rootram-0.11 count=1024
```

此时在 Linux-0.11-devel 系统中我们已经有了新编译出的内核 Image 文件/usr/src/linux/Image 和一个简单的容量不超过 1024KB 的根文件系统映像文件 rootram-0.11。

14.9.2.3 建立集成盘

组合上述两个映像文件，建立集成盘。修改 Bochs 主窗口 A 盘配置，将其设置为前面准备好的 1.44MB 名称为 bootroot-0.11 的映像文件。然后执行命令：

```
dd bs=8192 if=/usr/src/linux/Image of=/dev/fd0
dd bs=1024 if=rootram-0.11 of=/dev/fd0 seek=256
sync;sync;sync;
```

其中选项 bs=1024 表示定义缓冲的大小为 1KB。seek=256 表示写输出文件时跳过前面的 256 个磁盘块。然后退出 Bochs 系统。此时我们在主机的当前目录下就得到了一张可以运行的集成盘映像文件 bootroot-0.11

14.9.3 运行集成盘系统

先为集成盘制作一个简单的 Bochs 配置文件 bootroot-0.11.bxrc。其中主要设置是：

```
floppya: 1_44=bootroot-0.11
```

然后用鼠标双击该配置文件运行 Bochs 系统。此时应有如图 14-8 所示显示结果。

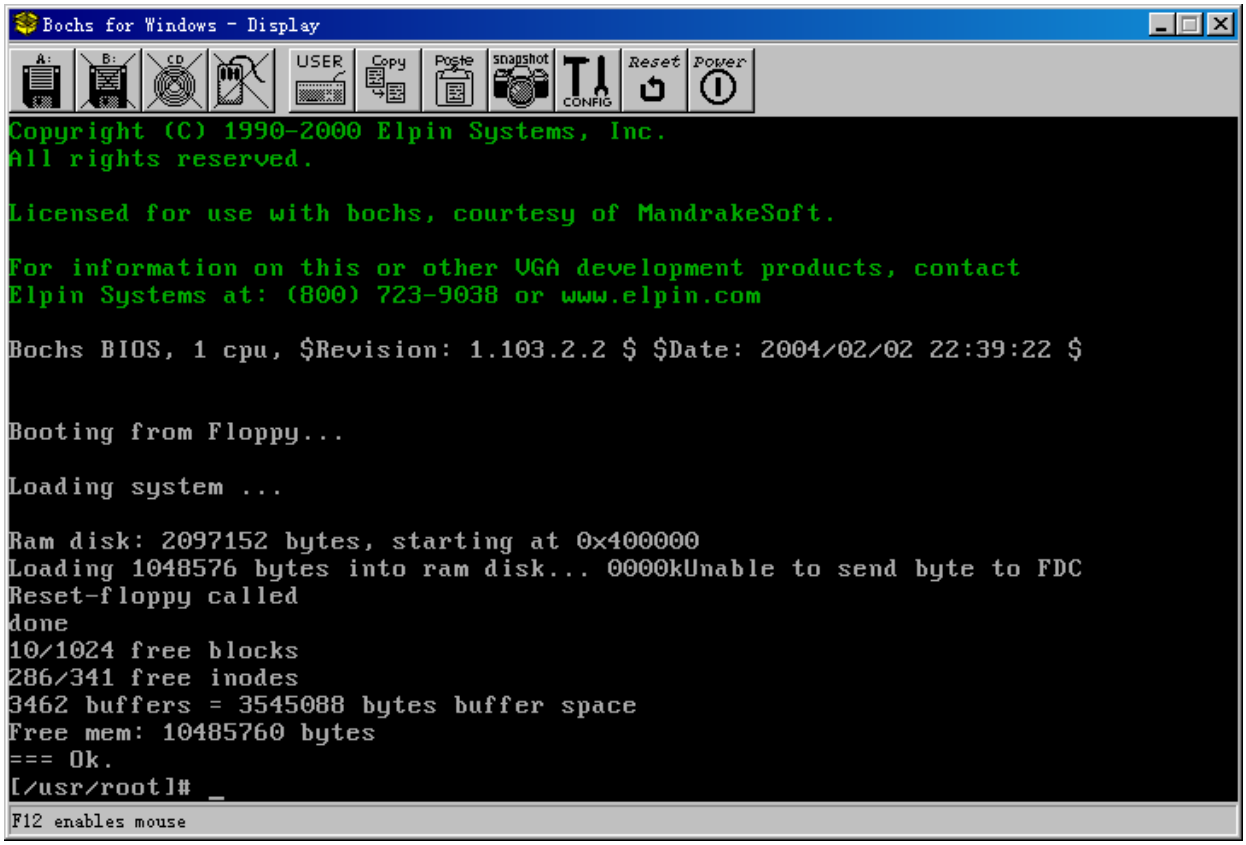

图 14-8 集成盘运行界面

为了方便大家做实验，也可以从下面网址下载已经做好并能立刻运行的集成盘软件：

http://oldlinux.org/Linux.old/bochs/bootroot-0.11-040928.zip

参考文献

[1] Intel Co. INTEL 80386 Programmer's Reference Manual 1986, INTEL CORPORATION,1987.

[2] James L. Turley. Advanced 80386 Programming Technigues. Osborne McGraw-Hill,1988.

[3] Brian W. Kernighan, Dennis M. Ritchie. The C programming Language. Prentice-Hall 1988.

[4] Leland L. Beck. System Software: An Introduction to Systems Programming,3nd. Addison-Wesley,1997.

[5] Richard M. Stallman, Using and Porting the GNU Compiler Collection,the Free Software Foundation, 1998.

[6] The Open Group Base Specifications Issue 6 IEEE Std 1003.1-2001, The IEEE and The Open Group.

[7] David A Rusling, The Linux Kernel, 1999. http://www.tldp.org/

[8] Linux Kernel Source Code，http://www.kernel.org/

[9] Digital co.ltd. VT100 User Guide, http://www.vt100.net/

[10] Clark L. Coleman. Using Inline Assembly with gcc. http://oldlinux.org/Linux.old/

[11] John H. Crawford, Patrick P. Gelsinger. Programming the 80386. Sybex, 1988.

[12] FreeBSD Online Manual, http://www.freebsd.org/cgi/man.cgi

[13] Andrew S.Tanenbaum 著 陆佑珊、施振川译，操作系统教程 MINIX 设计与实现. 世界图书出版公司，1990.4

[14] Maurice J. Bach 著，陈葆珏，王旭，柳纯录，冯雪山译，UNIX 操作系统设计. 机械工业出版社，2000.4

[15] John Lions 著，尤晋元译，莱昂氏 UNIX 源代码分析，机械工业出版社，2000.7

[16] Andrew S. Tanenbaum 著 王鹏，尤晋元等译，操作系统：设计与实现（第 2 版），电子工业出版社，1998.8

[17] Alessandro Rubini，Jonathan 著，魏永明，骆刚，姜君译，Linux 设备驱动程序，中国电力出版社，2002.11

[18] Daniel P. Bovet, Marco Cesati 著, 陈莉君，冯锐，牛欣源 译，深入理解 LINUX 内核, 中国电力出版社 2001.

[19] 张载鸿. 微型机(PC 系列)接口控制教程, 清华大学出版社，1992.

[20] 李凤华，周利华，赵丽松. MS-DOS 5.0 内核剖析. 西安电子科技大学出版社，1992.

[21] RedHat 7.3 操作系统在线手册. http://www.plinux.org/cgi-bin/man.cgi

[22] W.Richard Stevens 著 尤晋元等译，UNIX 环境高级编程. 机械工业出版社，2000.2

[23] Linux Weekly Edition News. http://lwn.net/

[24] P.J. Plauger. The Standard C Library. Prentice Hall, 1992

[25] Free Software Foundation. The GNU C Library. http://www.gnu.org/ 2001

[26] Chuck Allison. The Standard C Library. C/C++ Users Journal CD-ROM, Release 6. 2003

[27] Bochs simulation system. http://bochs.sourceforge.net/

[28] Brennan "Bas" Underwood. Brennan's Guide to Inline Assembly. http://www.rt66.com/~brennan/

附录

附录1 内核主要常数

1. 系统最大进程数

系统最大进程（任务）数为 64。

2. 定时器链表数

```
#define TIME_REQUESTS 64                // 最多可有 64 个定时器链表（64 个任务）。
```

3. 进程的运行状态

```
#define TASK_RUNNING            0   // 进程正在运行或已准备就绪。
#define TASK_INTERRUPTIBLE      1   // 进程处于可中断等待状态。
#define TASK_UNINTERRUPTIBLE    2   // 进程处于不可中断等待状态，主要用于 I/O 操作等待。
#define TASK_ZOMBIE             3   // 进程处于僵死状态，已停止运行，但父进程还没发信号。
#define TASK_STOPPED            4   // 进程已停止。
```

4. 内存页长度

PAGE_SIZE = 4096 字节

5. 数据块长度

BLOCK_SIZE = 1024 字节

6. 系统同时打开文件数

NR_FILE = 64

7. 进程同时打开文件数

NR_OPEN = 20

8. 系统主设备编号

与 Minix 系统的设备编号一样，因此可以使用 minix 的文件系统。

```
0 - 没有用到（nodev）
1 - /dev/mem        内存设备。
2 - /dev/fd         软盘设备。
3 - /dev/hd         硬盘设备。
4 - /dev/ttyx       tty 串行终端设备。
5 - /dev/tty        tty 终端设备。
6 - /dev/lp         打印设备。
7 - unnamed pipes   没有命名的管道。
```

9. 硬盘逻辑设备编号方法

由于 1 个硬盘中可以存在 1--4 个分区，因此硬盘还依据分区的不同用次设备号进行指定分区。因此硬盘的逻辑设备号由以下方式构成：

设备号=主设备号*256 + 次设备号
也即 dev_no = (major<<8) + minor
两个硬盘的所有逻辑设备号见下表所示。

附表 1 硬盘逻辑设备号

逻辑设备号	对应设备文件	说明
0x300	/dev/hd0	代表整个第 1 个硬盘

0x301	/dev/hd1	表示第 1 个硬盘的第 1 个分区
0x302	/dev/hd2	表示第 1 个硬盘的第 2 个分区
0x303	/dev/hd3	表示第 1 个硬盘的第 3 个分区
0x304	/dev/hd4	表示第 1 个硬盘的第 4 个分区
0x305	/dev/hd5	代表整个第 2 个硬盘
0x306	/dev/hd6	表示第 2 个硬盘的第 1 个分区
0x307	/dev/hd7	表示第 2 个硬盘的第 2 个分区
0x308	/dev/hd8	表示第 2 个硬盘的第 3 个分区
0x309	/dev/hd9	表示第 2 个硬盘的第 4 个分区

其中 0x300 和 0x305 并不与哪个分区对应，而是代表整个硬盘。
从 linux 内核 0.95 版后已经不使用这种烦琐的命名方式，而是使用与现在相同的命名方法了。

附录2 内核数据结构

这里集中列出了内核中的主要数据结构，并给予简单说明，注明了每个结构所在的文件和具体位置。作为阅读时参考。

1. 执行文件结构 a.out（include/a.out.h，第 6 行）

a.out（Assembly out）执行文件头格式结构。

```
struct exec {
        unsigned long a_magic       // 执行文件魔数。使用 N_MAGIC 等宏访问。
        unsigned a_text             // 代码长度，字节数。
        unsigned a_data             // 数据长度，字节数。
        unsigned a_bss              // 文件中的未初始化数据区长度，字节数。
        unsigned a_syms             // 文件中的符号表长度，字节数。
        unsigned a_entry            // 执行开始地址。
        unsigned a_trsize           // 代码重定位信息长度，字节数。
        unsigned a_drsize           // 数据重定位信息长度，字节数。
};
```

2. 文件锁定操作结构 flock（include/fcntl.h，43 行）

文件锁定操作数据结构。

```
struct flock {
        short l_type;               // 锁定类型（F_RDLCK，F_WRLCK，F_UNLCK）。
        short l_whence;             // 开始偏移(SEEK_SET，SEEK_CUR 或 SEEK_END)。
        off_t l_start;              // 阻塞锁定的开始处。相对偏移（字节数）。
        off_t l_len;                // 阻塞锁定的大小；如果是 0 则为到文件末尾。
        pid_t l_pid;                // 加锁的进程 id。
};
```

3. sigaction 的数据结构（include/signal.h，48 行）

sigaction 的数据结构。

```
struct sigaction {
        void (*sa_handler)(int);
        sigset_t sa_mask;
        int sa_flags;
        void (*sa_restorer)(void);
};
```

sa_handler 是对应某信号指定要采取的行动。可以是上面的 SIG_DFL，或者是 SIG_IGN 来忽略该信号，也可以是指向处理该信号函数的一个指针。

sa_mask 给出了对信号的屏蔽码，在信号程序执行时将阻塞对这些信号的处理。另外，引起触发信号处理的信号也将被阻塞，除非使用了 SA_NOMASK 标志。

sa_flags 指定改变信号处理过程的信号集。

sa_restorer 恢复函数指针，由函数库 Libc 提供，用于清理用户态堆栈。

4. 终端窗口大小属性结构（include/termios.h，36 行）

窗口大小(Window size)属性结构。在窗口环境中可用于基于屏幕的应用程序。ioctls 中的 TIOCGWINSZ 和 TIOCSWINSZ 可用来读取或设置这些信息。

```
struct winsize {
```

```
        unsigned short ws_row;      // 窗口字符行数。
        unsigned short ws_col;      // 窗口字符列数。
        unsigned short ws_xpixel;   // 窗口宽度，象素值。
        unsigned short ws_ypixel;   // 窗口高度，象素值。
};
```

5. termio(s)结构（include/termios.h，44 行）

AT&T 系统 V 的 termio 结构。其中控制字符数据长度 NCC = 8。

```
struct termio {
        unsigned short c_iflag;         // 输入模式标志。
        unsigned short c_oflag;         // 输出模式标志。
        unsigned short c_cflag;         // 控制模式标志。
        unsigned short c_lflag;         // 本地模式标志。
        unsigned char c_line;           // 线路规程（速率）。
        unsigned char c_cc[NCC];        // 控制字符数组。
};
```

POSIX 的 termios 结构（第 54 行）。其中控制字符数据长度 NCC = 17。

```
struct termios {
        unsigned long c_iflag;          // 输入模式标志。
        unsigned long c_oflag;          // 输出模式标志。
        unsigned long c_cflag;          // 控制模式标志。
        unsigned long c_lflag;          // 本地模式标志。
        unsigned char c_line;           // 线路规程（速率）。
        unsigned char c_cc[NCCS];       // 控制字符数组。
};
```

以上定义的两个终端数据结构 termio 和 termios 是分别属于两类 UNIX 系列(或刻隆)，termio 是在 AT&T 系统 V 中定义的，而 termios 是 POSIX 标准指定的。两个结构基本一样，只是 termio 使用短整数类型定义模式标志集，而 termios 使用长整数定义模式标志集。由于目前这两种结构都在使用，因此为了兼容性，大多数系统都同时支持它们。另外，以前使用的是一类似的 sgtty 结构，目前已基本不用。

6. 时间结构（include/time.h，第 18 行）

```
struct tm {
        int tm_sec;             // 秒数 [0，59]。
        int tm_min;             // 分钟数 [ 0，59]。
        int tm_hour;            // 小时数 [0，59]。
        int tm_mday;            // 1 个月的天数 [0，31]。
        int tm_mon;             // 1 年中月份 [0，11]。
        int tm_year;            // 从 1900 年开始的年数。
        int tm_wday;            // 1 星期中的某天 [0，6]（星期天 =0）。
        int tm_yday;            // 1 年中的某天 [0，365]。
        int tm_isdst;           // 夏令时标志。
};
```

7. 文件访问/修改结构（include/utime.h，第 6 行）

```
struct utimbuf {
        time_t actime;          // 文件访问时间。从 1970.1.1:0:0:0 开始的秒数。
        time_t modtime;         // 文件修改时间。从 1970.1.1:0:0:0 开始的秒数。
```

```
};
```

8. 缓冲区头结构 buffer_head（include/linux/fs.h，第 68 行）

缓冲区头数据结构。在程序中常用 bh 来表示 buffer_head 类型变量的缩写。

```
struct buffer_head {
        char * b_data;                  // 指向数据块的指针（数据块为 1024 字节）。
        unsigned long b_blocknr;        // 块号。
        unsigned short b_dev;           // 数据源的设备号（0 表示未用）。
        unsigned char b_uptodate;       // 更新标志：表示数据是否已更新。
        unsigned char b_dirt;           // 修改标志：0-未修改，1-已修改。
        unsigned char b_count;          // 使用该数据块的用户数。
        unsigned char b_lock;           // 缓冲区是否被锁定，0-未锁；1-已锁定。
        struct task_struct * b_wait;    // 指向等待该缓冲区解锁的任务。
        struct buffer_head * b_prev;    // 前一块（这四个指针用于缓冲区的管理）。
        struct buffer_head * b_next;    // 下一块。
        struct buffer_head * b_prev_free;   // 前一空闲块。
        struct buffer_head * b_next_free;   // 下一空闲块。
};
```

9. 内存中磁盘索引节点结构（include/linux/fs.h，第 93 行）

这是在内存中的 i 节点结构。磁盘上的索引节点结构 d_inode 只包括前 7 项。

```
struct m_inode {
        unsigned short i_mode;          // 文件类型和属性(rwx 位)。
        unsigned short i_uid;           // 用户 id（文件拥有者标识符）。
        unsigned long i_size;           // 文件大小（字节数）。
        unsigned long i_mtime;          // 文件修改时间（自 1970.1.1:0 算起，秒）。
        unsigned char i_gid;            // 组 id(文件拥有者所在的组)。
        unsigned char i_nlinks;         // 文件目录项链接数。
        unsigned short i_zone[9];       // 直接(0-6)、间接(7)或双重间接(8)逻辑块号。
                                        // zone 是区的意思，可译成区段，或逻辑块。
// 以下字段在内存中。
        struct task_struct * i_wait;    // 等待该 i 节点的进程。
        unsigned long i_atime;          // 最后访问时间。
        unsigned long i_ctime;          // i 节点自身修改时间。
        unsigned short i_dev;           // i 节点所在的设备号。
        unsigned short i_num;           // i 节点号。
        unsigned short i_count;         // i 节点被使用的次数，0 表示该 i 节点空闲。
        unsigned char i_lock;           // 锁定标志。
        unsigned char i_dirt;           // 已修改(脏)标志。
        unsigned char i_pipe;           // 管道标志。
        unsigned char i_mount;          // 安装标志。
        unsigned char i_seek;           // 搜寻标志(lseek 时)。
        unsigned char i_update;         // 更新标志。
};
```

10. 文件结构（include/linux/fs.h，第 116 行）

文件结构，用于在文件句柄与 i 节点之间建立关系。

```
struct file {
        unsigned short f_mode;          // 文件操作模式（RW 位）
```

```
        unsigned short f_flags;         // 文件打开和控制的标志。
        unsigned short f_count;         // 对应文件句柄（文件描述符）数。
        struct m_inode * f_inode;       // 指向对应 i 节点。
        off_t f_pos;                    // 文件位置（读写偏移值）。
};
```

11. 磁盘超级块结构（include/linux/fs.h，第 124 行）

内存中磁盘超级块结构。磁盘上的超级块结构 d_super_block 只包括前 8 项。

```
struct super_block {
        unsigned short s_ninodes;       // 节点数。
        unsigned short s_nzones;        // 逻辑块数。
        unsigned short s_imap_blocks;   // i 节点位图所占用的数据块数。
        unsigned short s_zmap_blocks;   // 逻辑块位图所占用的数据块数。
        unsigned short s_firstdatazone; // 第一个数据逻辑块号。
        unsigned short s_log_zone_size; // log(数据块数/逻辑块)。（以 2 为底）。
        unsigned long s_max_size;       // 文件最大长度。
        unsigned short s_magic;         // 文件系统魔数。
// 以下字段仅在内存中。
        struct buffer_head * s_imap[8]; // i 节点位图缓冲块指针数组(占用 8 块，可表示 64M)。
        struct buffer_head * s_zmap[8]; // 逻辑块位图缓冲块指针数组（占用 8 块）。
        unsigned short s_dev;           // 超级块所在的设备号。
        struct m_inode * s_isup;        // 被安装的文件系统根目录的 i 节点。(isup-super i)
        struct m_inode * s_imount;      // 被安装到的 i 节点。
        unsigned long s_time;           // 修改时间。
        struct task_struct * s_wait;    // 等待该超级块的进程。
        unsigned char s_lock;           // 被锁定标志。
        unsigned char s_rd_only;        // 只读标志。
        unsigned char s_dirt;           // 已修改(脏)标志。
};
```

12. 目录项结构（include/linux/fs.h，第 157 行）

文件目录项结构。

```
struct dir_entry {
        unsigned short inode;           // i 节点。
        char name[NAME_LEN];            // 文件名。
};
```

13. 硬盘分区表结构（include/linux/hdreg.h，第 52 行）

硬盘分区表结构。参见下面列表后信息。

```
struct partition {
        unsigned char boot_ind;     // 引导标志。0x80-该分区可引导操作系统。
        unsigned char head;         // 分区起始磁头号。
        unsigned char sector;       // 分区起始扇区号(位 0-5)和起始柱面号高 2 位(位 6-7)。
        unsigned char cyl;          // 分区起始柱面号低 8 位。
        unsigned char sys_ind;      // 分区类型字节。0x0b-DOS; 0x80-Old Minix; 0x83-Linux
        unsigned char end_head;     // 分区的结束磁头号。
        unsigned char end_sector;   // 结束扇区号(位 0-5)和结束柱面号高 2 位(位 6-7)。
        unsigned char end_cyl;      // 结束柱面号低 8 位。
        unsigned int start_sect;    // 分区起始物理扇区号（从 0 开始计）。
```

```
        unsigned int nr_sects;      // 分区占用的扇区数。
};
```

为了实现多个操作系统共享硬盘资源，硬盘可以在逻辑上分为 1--4 个分区。每个分区之间的扇区号是邻接的。分区表由 4 个表项组成，每个表项由 16 字节组成，对应一个分区的信息，存放有分区的大小和起止的柱面号、磁道号、扇区号和引导标志。分区表存放在硬盘的 0 柱面 0 头第 1 个扇区的 0x1BE--0x1FD 处。4 个分区中同时只能有一个分区是可引导的。

14. 段描述符结构（include/linux/head.h，第 4 行）

CPU 中描述符的简单格式。

```
struct desc_struct {                // 定义了段描述符的数据结构。该结构仅说明每个描述
        unsigned long a,b;          // 符是由 8 个字节构成，每个描述符表共有 256 项。
} desc_table[256];
```

15. i387 使用的结构（include/linux/sched.h，第 40 行）

这是数学协处理器使用的结构，主要用于保存进程切换时 i387 的执行状态信息。

```
struct i387_struct {
        long    cwd;                // 控制字(Control word)。
        long    swd;                // 状态字(Status word)。
        long    twd;                // 标记字(Tag word)。
        long    fip;                // 协处理器代码指针。
        long    fcs;                // 协处理器代码段寄存器。
        long    foo;                // 内存操作数的偏移位置。
        long    fos;                // 内存操作数的段值。
        long    st_space[20];       // 8 个 10 字节的协处理器累加器。
};
```

16. 任务状态段结构（include/linux/sched.h，第 51 行）

任务状态段数据结构（参见附录）。

```
struct tss_struct {
        long    back_link;      /* 16 high bits zero */
        long    esp0;
        long    ss0;            /* 16 high bits zero */
        long    esp1;
        long    ss1;            /* 16 high bits zero */
        long    esp2;
        long    ss2;            /* 16 high bits zero */
        long    cr3;
        long    eip;
        long    eflags;
        long    eax,ecx,edx,ebx;
        long    esp;
        long    ebp;
        long    esi;
        long    edi;
        long    es;             /* 16 high bits zero */
        long    cs;             /* 16 high bits zero */
        long    ss;             /* 16 high bits zero */
        long    ds;             /* 16 high bits zero */
        long    fs;             /* 16 high bits zero */
```

```
        long    gs;             /* 16 high bits zero */
        long    ldt;            /* 16 high bits zero */
        long    trace_bitmap;   /* bits: trace 0, bitmap 16-31 */
        struct i387_struct i387;
};
```

17. 进程（任务）数据结构 task（include/linux/sched.h，第 78 行）

这是任务（进程）数据结构，或称为进程描述符。

```
struct task_struct {
        long state                      //任务的运行状态（-1 不可运行，0 可运行(就绪)，>0 已停止）。
        long counter                    // 任务运行时间计数(递减)（滴答数），运行时间片。
        long priority                   // 运行优先数。任务开始运行时 counter=priority，越大运行越长。
        long signal                     // 信号。是位图，每个比特位代表一种信号，信号值=位偏移值+1。
        struct sigaction sigaction[32]  // 信号执行属性结构，对应信号将要执行的操作和标志信息。
        long blocked                    // 进程信号屏蔽码（对应信号位图）。
        int exit_code                   // 任务执行停止的退出码，其父进程会取。
        unsigned long start_code        // 代码段地址。
        unsigned long end_code          // 代码长度（字节数）。
        unsigned long end_data          // 代码长度 + 数据长度（字节数）。
        unsigned long brk               // 总长度（字节数）。
        unsigned long start_stack       // 堆栈段地址。
        long pid                        // 进程标识号(进程号)。
        long father                     // 父进程号。
        long pgrp                       // 父进程组号。
        long session                    // 会话号。
        long leader                     // 会话首领。
        unsigned short uid              // 用户标识号（用户 id）。
        unsigned short euid             // 有效用户 id。
        unsigned short suid             // 保存的用户 id。
        unsigned short gid              // 组标识号（组 id）。
        unsigned short egid             // 有效组 id。
        unsigned short sgid             // 保存的组 id。
        long alarm                      // 报警定时值（滴答数）。
        long utime                      // 用户态运行时间（滴答数）。
        long stime                      // 系统态运行时间（滴答数）。
        long cutime                     // 子进程用户态运行时间。
        long cstime                     // 子进程系统态运行时间。
        long start_time                 // 进程开始运行时刻。
        unsigned short used_math        // 标志：是否使用了协处理器。
        int tty                         // 进程使用 tty 的子设备号。-1 表示没有使用。
        unsigned short umask            // 文件创建属性屏蔽位。
        struct m_inode * pwd            // 当前工作目录 i 节点结构。
        struct m_inode * root           // 根目录 i 节点结构。
        struct m_inode * executable     // 执行文件 i 节点结构。
        unsigned long close_on_exec     // 执行时关闭文件句柄位图标志。（参见 include/fcntl.h）
        struct file * filp[NR_OPEN]     // 文件结构指针表，最多 32 项。表项号即是文件描述符的值。
        struct desc_struct ldt[3]       // 任务局部描述符表。0-空，1-代码段 cs，2-数据和堆栈段 ds&ss。
        struct tss_struct tss           // 进程的任务状态段信息结构。
};
```

18. tty 等待队列结构（include/linux/tty.h，第 16 行）

tty 等待队列数据结构。

```
struct tty_queue {
        unsigned long data;             // 等待队列缓冲区中当前数据指针（字符数[??]）。
                                        // 对于串口终端，则存放串口端口地址。
        unsigned long head;             // 缓冲区中数据头指针。
        unsigned long tail;             // 缓冲区中数据尾指针。
        struct task_struct * proc_list; // 等待进程列表。
        char buf[TTY_BUF_SIZE];         // 队列的缓冲区。
};
```

19. tty 结构（include/linux/tty.h，第 45 行）

tty 数据结构。

```
struct tty_struct {
        struct termios termios;                 // 终端 io 属性和控制字符数据结构。
        int pgrp;                               // 所属进程组。
        int stopped;                            // 停止标志。
        void (*write)(struct tty_struct * tty); // tty 写函数指针。
        struct tty_queue read_q;                // tty 读队列。
        struct tty_queue write_q;               // tty 写队列。
        struct tty_queue secondary;             // tty 辅助队列(存放规范模式字符序列)，
};
extern struct tty_struct tty_table[];           // tty 结构数组。
```

20. 文件状态结构（include/sys/stat.h，第 6 行）

```
struct stat {
        dev_t   st_dev;         // 含有文件的设备号。
        ino_t   st_ino;         // 文件 i 节点号。
        umode_t st_mode;        // 文件属性（见下面）。
        nlink_t st_nlink;       // 指定文件的连接数。
        uid_t   st_uid;         // 文件的用户(标识)号。
        gid_t   st_gid;         // 文件的组号。
        dev_t   st_rdev;        // 设备号(如果文件是特殊的字符文件或块文件)。
        off_t   st_size;        // 文件大小（字节数）（如果文件是常规文件）。
        time_t  st_atime;       // 上次（最后）访问时间。
        time_t  st_mtime;       // 最后修改时间。
        time_t  st_ctime;       // 最后节点修改时间。
};
```

21. 文件访问与修改时间结构（include/sys/times.h，第 6 行）

```
struct tms {
        time_t tms_utime;       // 用户使用的 CPU 时间。
        time_t tms_stime;       // 系统（内核）CPU 时间。
        time_t tms_cutime;      // 已终止的子进程使用的用户 CPU 时间。
        time_t tms_cstime;      // 已终止的子进程使用的系统 CPU 时间。
};
```

22. ustat 结构（include/sys/types.h，第 39 行）

文件系统参数结构，用于函数 ustat()。

```
struct ustat {
        daddr_t f_tfree;            // 系统总空闲块数。
        ino_t f_tinode;             // 总空闲 i 节点数。
        char f_fname[6];            // 文件系统名称。
        char f_fpack[6];            // 文件系统压缩名称。
};
```

最后两个字段未使用，总是返回 NULL 指针。

23. 系统名称头文件（include/sys/utsname.h，第 6 行）

```
struct utsname {
        char sysname[9];            // 本版本操作系统的名称。
        char nodename[9];           // 与实现相关的网络中节点名称。
        char release[9];            // 本实现的当前发行级别。
        char version[9];            // 本次发行的版本级别。
        char machine[9];            // 系统运行的硬件类型名称。
};
```

24. 块设备请求项结构（kernel/blk_drv/blk.h，第 23 行）

下面是请求队列中项的结构。其中如果 dev=-1，则表示没有使用该项。

```
struct request {
        int dev;                    // 使用的设备号，未用时为-1。
        int cmd;                    // 命令(READ 或 WRITE)。
        int errors;                 // 作时产生的错误次数。
        unsigned long sector;       // 起始扇区。(1 块=2 扇区)
        unsigned long nr_sectors;   // 读/写扇区数。
        char * buffer;              // 数据缓冲区。
        struct task_struct * waiting;   // 任务等待操作执行完成的地方。
        struct buffer_head * bh;    // 缓冲区头指针(include/linux/fs.h,68)。
        struct request * next;      // 指向下一请求项。
};
```

附录3 80x86 保护运行模式

1. 80386 概述

80386 是一个高级的 32 位微处理器，专门用于多任务的操作系统，并为需要高性能的应用所设计。32 位的寄存器和数据通道支持 32 位的寻址方式和数据类型，处理器可以寻址最高可达 4GB 的物理内存以及 64TB（2^{46} 字节）的虚拟内存。芯片上的内存管理包括地址转换寄存器、高级多任务硬件、保护机制以及分页虚拟内存机制。下面针对系统编程，概要说明使用 80386 的这些基本原理。

1.1 系统寄存器

设计用于系统编程的系统寄存器主要包括以下几类：

- 标志寄存器 EFALGS；
- 内存管理寄存器；
- 控制寄存器；
- 调试寄存器；
- 测试寄存器。

系统标志寄存器 EFLAGS 控制着 I/O、可屏蔽中断、调试、任务切换以及保护模式和多任务环境下虚拟 8086 程序的执行。其中主要标志见附图 1 所示。

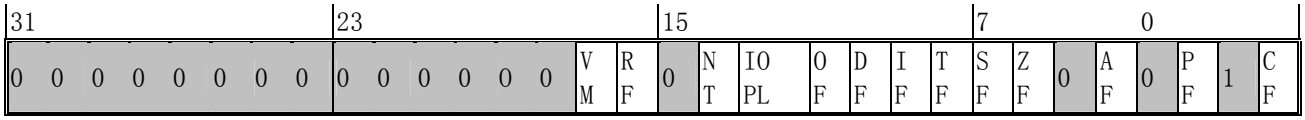

附图 1 系统标志寄存器

其中系统标志：VM – 虚拟 8086 模式；RF – 恢复标志；NT – 嵌套任务标志；IO PL – I/O 特权级标志；IF – 中断允许标志。

内存管理寄存器有 4 个，用于分段内存管理：

- GDTR – 全局描述符表寄存器(Global Descriptor Table Register)；
- LDTR – 局部描述符表寄存器(Local Descriptor Table Register)；
- IDTR – 中断描述符表寄存器(Interrupt Descriptor Table Register)；
- TR – 任务寄存器。

其中前两个寄存器(GDTR,LDTR)分别指向段描述符表 GDT 和 LDT。IDTR 寄存器指向中断向量表。TR 寄存器指向处理器所需的当前任务的信息。

80386 共有 4 个控制寄存器，分别是 CR0、CR1、CR2 和 CR3。格式见附图 2 所示。

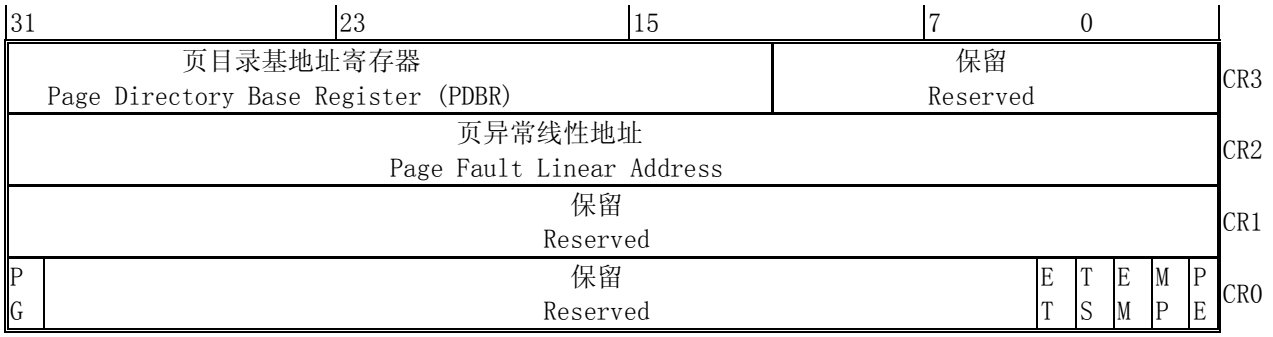

附图 2 系统控制寄存器

控制寄存器 CR0 含有系统整体的控制标志。其中：

- PE – 保护模式开启位（Protection Enable，比特位 0）。如果设置了该比特位，就会使处理器开始在保护模式下运行。
- MP – 协处理器存在标志（Math Present，比特位 1）。用于控制 WAIT 指令的功能，以配合协处理的运行。
- EM – 仿真控制（Emulation，比特位 2）。指示是否需要仿真协处理器的功能。
- TS – 任务切换（Task Switch，比特位 3）。每当任务切换时处理器就会设置该比特位，并且在解释协处理器指令之前测试该位。
- ET – 扩展类型（Extention Type，比特位 4）。该位指出了系统中所含有的协处理器类型（是 80287 还是 80387）。
- PG – 分页操作（Paging，比特位 31）。该位指示出是否使用页表将线性地址变换成物理地址。

1.2 内存管理

内存管理主要涉及处理器的内存寻址机制。80x86 使用两步将一个分段形式的逻辑地址转换为实际物理内存地址。

- 段变换，将一个由段选择符和段内偏移构成的逻辑地址转换为一个线性地址；
- 页变换，将线性地址转换为对应的物理地址。该步是可选的。

在分页机制开启时，通过将前面所述的段转换和页转换组合在一起，即实现了从逻辑地址到物理地址的两个转换阶段。

1.3 段变换

附图 3 示出了处理器是如何将一个逻辑地址转换为线性地址的。在转换过程中 CPU 使用了以下一些数据结构：

- 段描述符（Segment Descriptors）；
- 描述符表（Descriptor tables）；
- 选择符（Selectors）；
- 段寄存器（Segment Registers）。

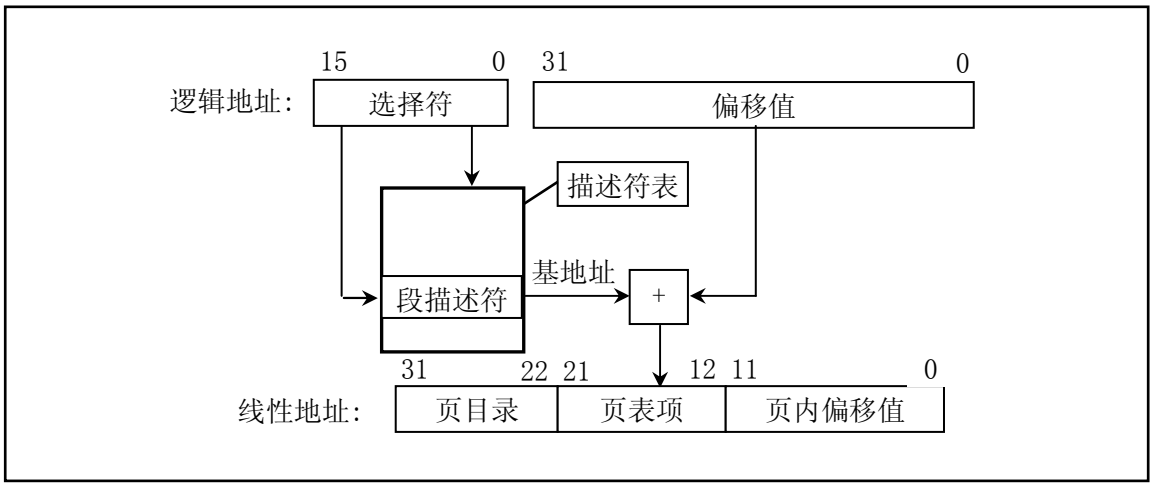

附图 3 段变换示意图

1.4 段描述符

段描述符向 CPU 提供了将逻辑地址映射为线性地址所必要的信息。描述符是由程序编译器、链接器、加载器或操作系统创建的。下图示出了描述符的两种一般格式。所有种类的描述符都具有这两种格式之一。段描述符的各个字段的含义见附图 4 所示。

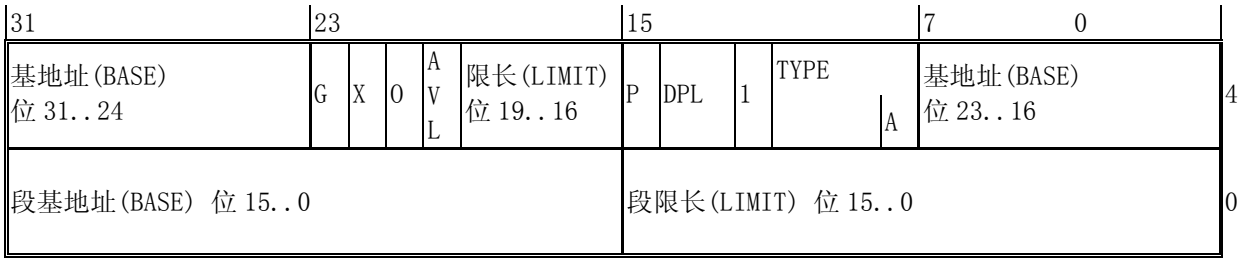

a.用于程序代码段和数据段的描述符

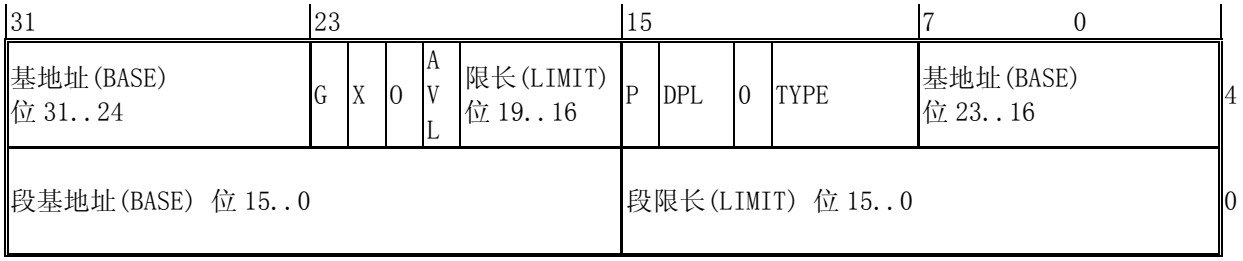

b.用于特殊系统段的描述符

附图 4 描述符的一般格式

- 基地址（BASE）：定义段在 4GB 线性空间中的位置。处理器会将基地址的三个部分组合成一个 32 位的值。
- 段限长（LIMIT）：定义了段的最大长度。处理器将组合段限长的两个部分形成一个 20 位的值。处理器会依据颗粒度（Granularity）位字段的值来解释段限长域的实际含义：
  - ♦ 当以 1 字节为单元时，则定义了最高可为 1MB 字节的长度；
  - ♦ 当以 4KB 字节为单元时，则定义了最高可为 4GB 字节的长度。在加载时限长值将左移 12 位。
- 颗粒度（Granularity）：指定了限长字段值代表的单元含义。当为 0 时，限长单元值为 1 字节；当该位为 1 时，限长的单元值为 4KB 字节。
- 类型（TYPE）：4 比特（位 11-位 8），用于区分各种不同类型的描述符。对于代码段选择符，其最高比特位为 1。对于数据段选择符，其最高比特位是 0。
- 描述符特权级（Descriptor Privilege Level – DPL）：用于保护机制。共有 4 级：0–3。0 级是最高特权级，3 级是最低特权级。
- 段存在位（Segment-Present bit – P）：如果该位为零，则该描述符无效，不能用于地址变换过程。当指向该描述符的选择符被加载到段寄存器中时，处理器就会发出一个异常信号。
- 访问位（Accessed bit – A）：当处理器访问过该段时就会设置该比特位。

1.5 描述符表

段描述符是保存在描述符表中的，有两类描述符表：

- 全局描述符表（Global descriptor table – GDT）；
- 局部描述符表（Local descriptor table – LDT）。

描述符表是由 8 字节构成的描述符项的内存中的一个数组，见附图 5 所示。描述符表的长度是可变

的，最多可以含有 8192（2^{13}）个描述符。但是对于 GDT 表，其第一个描述符（索引 0）是不用的。

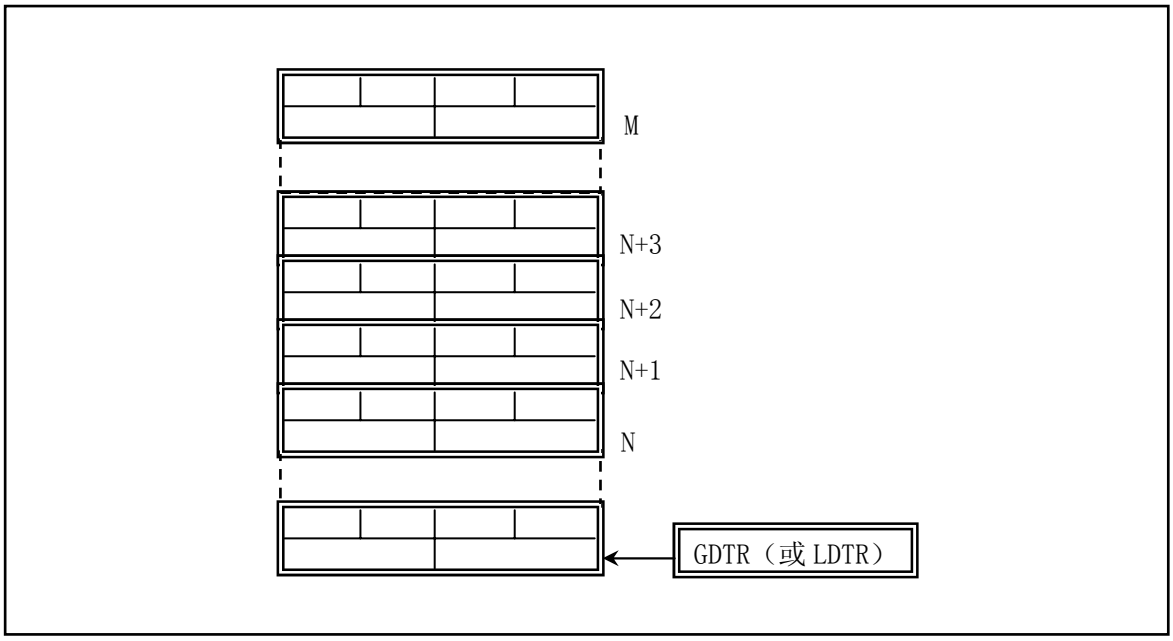

附图 5 描述符表示意图

处理器是通过使用 GDTR 和 LDTR 寄存器来定位 GDT 表和当前的 LDT 表。这两个寄存器以线性地址的方式保存了描述符表的基地址和表的长度。指令 lgdt 和 sgdt 用于访问 GDTR 寄存器；指令 lldt 和 sldt 用于访问 LDTR 寄存器。lgdt 使用内存中一个 6 字节操作数来加载 GDTR 寄存器。头两个字节代表描述符表的长度，后 4 个字节是描述符表的基地址。然而请注意，访问 LDTR 寄存器的指令 lldt 所使用的操作数却是一个 2 字节的操作数，表示全局描述符表 GDT 中一个描述符项的选择符。该选择符所对应的 GDT 表中的描述符项应该对应一个局部描述符表。选择符的含义见附图 7 中说明。

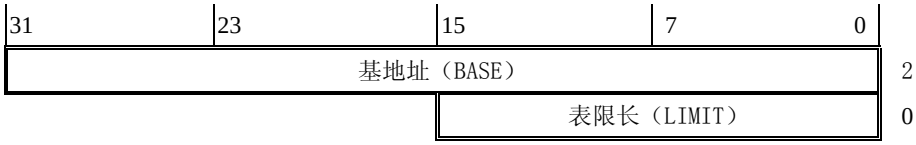

附图 6 GDTR 中的内容

1.6 选择符(Selectors)

逻辑地址的选择符部分是用于指定一描述符的，它是通过指定一描述符表并且索引其中的一个描述符项完成的。示出了选择符的格式。各字段的含义为：

索引值(Index)：用于选择指定描述符表中 8192 个描述符中的一个。处理器将该索引值乘上 8(描述符的字节长度)，并加上描述符表的基地址即可访问表中指定的段描述符。

表指示器(Table Indicator - TI)：指定选择符所引用的描述符表。值为 0 表示指定 GDT 表，值为 1 表示指定当前的 LDT 表。

请求者的特权级(Requestor's Privalege Level - RPL)：用于保护机制。

附图 7 选择符格式

由于 GDT 表的第一项(索引值为 0)没有被使用，因此一个具有索引值 0 和表指示器值也为 0 的选择符（也即指向 GDT 的第一项的选择符）可以用作为一个空(null)选择符。当一个段寄存器（不能是 CS 或 SS）加载了一个空选择符时，处理器并不会产生一个异常。但是若使用这个段寄存器访问内存时就会产生一个异常。对于初始化还未使用的段寄存器以陷入意外的引用来说，这个特性是很有用的。

1.7 段寄存器

处理器将描述符中的信息保存在段寄存器中，因而可以避免在每次访问内存时查询描述符表。

每个段寄存器都有一个“可见”部分和一个“不可见”部分，见附图 8 所示。这些段地址寄存器的可见部分是由程序来操作的，就好象它们只是简单的 16 位寄存器。不可见部分则是由处理器来处理的。

对这些寄存器的加载操作使用的是普通程序指令，这些指令可以分为两类：

1. 直接加载指令；例如，MOV，POP，LDS，LSS，LGS，LFS。这些指令显式地引用了指定的段寄存器。
2. 隐式加载指令；例如，远调用 CALL 和远跳转 JMP。这些指令隐式地引用了 CS 段寄存器，并用新值加载到 CS 中。

程序使用这些指令会把 16 位的选择符加载到段寄存器的可见部分，而处理器则会自动地从描述符表中将一个描述符的基地址、段限长、类型以及其它信息加载到段寄存器中的不可见部分中去。

	16 位可见部分	隐藏部分
CS		
SS		
DS		
ES		
FS		
GS		

附图 8 段寄存器

2. 页变换

在地址变换的第二阶段，CPU 将线性地址转换为物理地址。地址变换的这个阶段实现了基于分页的虚拟内存系统和分页级保护的基本功能。页变化这一步是可选的，页变换仅在设置了 CR0 的 PG 比特位后才起作用,该比特位是在软件初始化时由操作系统设置的。如果操作系统需要实现多个虚拟 8086 任务、基于分页的保护机制或基于分页的虚拟内存，那么就一定要设置该位。

2.1 页框（帧）(Page Frame)

页框是一个物理内存地址连续的 4K 字节单元。它以字节为边界，大小固定。

2.2 线性地址(Linear Address)

线性地址通过指定一个页表、页表中的某一页以及该页中的偏移值，从而间接地指向对应的物理地址。附图 9 示出了线性地址的格式。

31 22	21 12	11 0
页目录 (DIR)	页 (PAGE)	偏移值 (OFFSET)

附图 9 线性地址

附图 10 示出了处理器将一个线性地址转换成物理地址的方法。通过使用两级页表，处理器将一个线性地址的页目录字段(DIR)、页字段(PAGE)和偏移字段(OFFSET)翻译成对应的物理地址。寻址机制使用线性地址的页目录字段作为页目录中的索引值、使用页表字段作为页目录所指定页表中的索引值、使用偏移字段作为页表所确定的内存页中的字节偏移值。

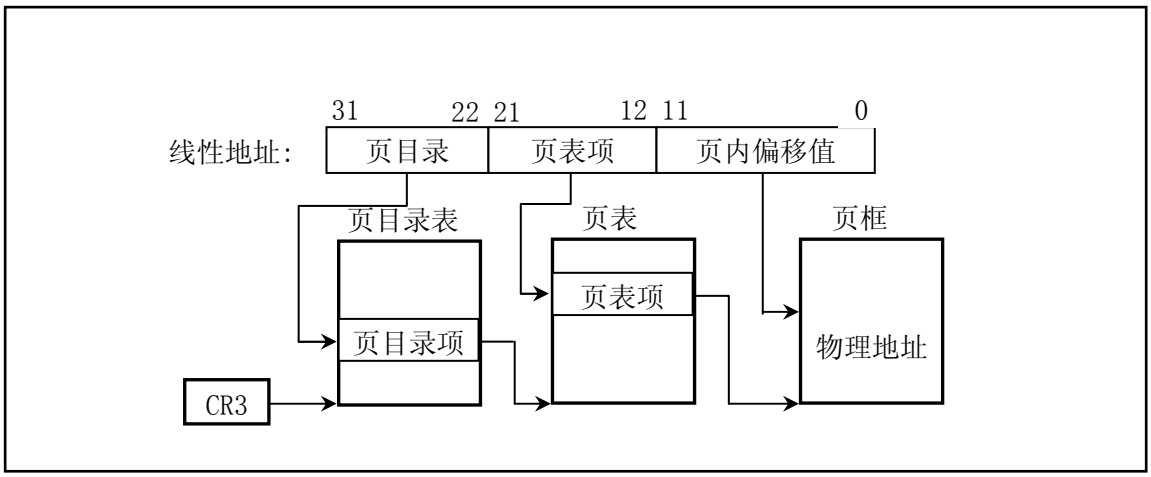

附图 10 线性地址转换成物理地址

2.3 页表(Page Table)

页表只是一个简单的 32 位页指示器的数组。页表本身也是一页内存，因此它含有 4K 字节的内存，可容纳 1K 个 32 位的项。

这里使用了两级页表来定位一页内存页。最高层是页目录，页目录可定位最多 1K 个第二级页表，而每个二级页表可以定位最多 1K 内存页。因此，一个页目录定位的所有页表可以寻址 1M 内存页（2^{20}）。由于每一页内存含有 4K 字节（2^{12}），最终一个页目录所指定的页表可以寻址 80386 的整个物理地址空间（$2^{20} * 2^{12} = 2^{32}$）。

当前页目录的物理地址是存储在 CPU 控制寄存器 CR3 中的，因此该寄存器也被称为页目录基地址寄存器（page directory base register – PDBR）。内存管理软件可以选择对所有的任务只使用一个页目录，或每个任务使用一个页目录，也可以组合两个任务使用一个页目录。

2.4 页表项(Page-Table Entries)

各级页表所使用的页表项是相同的，其格式见附图 11 所示。

31 12	11								0
页框地址 位 31..12 (PAGE FRAME ADDRESS)	可用 (AVAIL)	0	0	D	A	0	0	U/S	R/W	P

附图 11 页表项结构

其中，页框地址(PAGE FRAME ADDRESS)指定了一页内存的物理起始地址。因为内存页是位于 4K 边界上的，所以其低 12 比特总是 0。在一个页目录中，页表项的页框地址是一个页表的起始地址；在第二级页表中，页表项的页框地址是包含期望内存操作的页框的地址。

存在位（PRESENT – P）确定了一个页表项是否可以用于地址转换过程。P=1 表示该项可用。当目

录表项或第二级表项的 P=0 时，则该表项是无效的，不能用于地址转换过程。此时该表项的其它所有比特位都可供程序使用；处理器不对这些位进行测试。

当 CPU 试图使用一个页表项进行地址转换时，如果此时任意一级页表项的 P=0，则处理器就会发出页异常信号。对于支持分页虚拟内存的软件系统中，页不存在(page-not-present)异常处理程序就可以把所请求的页加入到物理内存中。此时导致异常的指令就可以被重新执行。

已访问（Accessed – A）和已修改（Dirty – D）比特位提供了有关页使用的信息。除了页目录项中的已修改位，这些比特位将由硬件置位，但不复位。

在对一页内存进行读或写操作之前，处理器将设置相关的目录和二级页表项的已访问位。在向一个二级页表项所涵盖的地址进行写操作之前，处理器将设置该二级页表项的已修改位，而页目录项中的已修改位是不用的。当需求的内存超出实际物理内存量时，支持分页虚拟内存的操作系统可以使用这些位来确定哪些页可以从内存中取走。操作系统必须负责检测和复位这些比特位。

读/写位（Read/Write – R/W）和用户/超级用户位（User/Supervisor – U/S）并不用于地址转换，但用于分页级的保护机制，是由处理器在地址转换过程中同时操作的。

2.5 页转换高速缓冲

为了最大地提高地址转换的效率，处理器将最近所使用的页表数据存放在芯片上的高速缓冲中。操作系统设计人员必须在当前页表改变时刷新高速缓冲，可使用以下两种方式之一：

1. 通过使用 MOV 指令重新加载 CR3 页目录基址寄存器；
2. 通过执行一个任务切换。

3. 多任务（Multitasking）

为了提供有效的、受保护的多任务机制，80x86 使用了一些特殊的数据结构。支持多任务运行的寄存器和数据结构主要有任务状态段（Task State Segment）和任务寄存器（Task register）。使用这些数据结构，CPU 可以快速地从一个任务的执行切换到另一个任务，并保存原有任务的内容。

3.1 任务状态段（Task State Segment – TSS）

处理器管理任务的所有信息存储在一个特殊类型的段中，即任务状态段 TSS，见附图 12 所示。给出了 TSS 的格式。其中的字段可分为两类：

- 处理器只读其中信息的静态字段集（图中灰色部分）；
- 每次任务切换时处理器将会更新的动态字段集。

图中 SS0:ESP0 用于存放任务在内核态运行时的堆栈指针。SS1:ESP1 和 SS2:ESP2 分别对应运行于特权级 1 和 2 时使用的堆栈指针，这两个特权级在 Linux 中没有使用。而任务工作于用户态时堆栈指针则保存在 SS:ESP 寄存器中。

31 – 23	15 – 7 – 0	
I/O 映射图基地址(MAP BASE)	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	64
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	局部描述符表(LDT)的选择符	60
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	GS	5C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	FS	58
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	DS	54
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	SS	50
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	CS	4C
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	ES	48
EDI		44

ESI		40
EBP		3C
ESP		38
EBX		34
EDX		30
ECX		2C
EAX		28
EFLAGS		24
指令指针(EIP)		20
页目录基地址寄存器 CR3（PDBR）		1C
0000000000000000	SS2	18
ESP2		14
0000000000000000	SS1	10
ESP1		0C
0000000000000000	SS0	08
ESP0		04
0000000000000000	前一执行任务 TSS 的描述符	00

附图 12 任务状态段 TSS

任务状态段 TSS 可以处于线性空间的任何位置。TSS 与其它段一样，也是使用段描述符来定义的。访问 TSS 的描述符会导致任务切换。因此，在大多数系统中都将描述符的 DPL（描述符特权级）字段设置为最高特权级 0，这样就可以只允许可信任的软件执行任务的切换。TSS 的描述符只能放在全局描述符表 GDT 中。

3.2 任务寄存器

任务寄存器（Task Register – TR）的作用与一般段寄存器的类似，它通过指向 TSS 来确定当前执行的任务。它也有 16 位的可见部分和不可见部分。可见部分中的选择符用于在 GDT 表中选择一个 TSS 描述符，处理器使用不可见部分来存放描述符中的基地址和段限长值。指令 LTR 和 STR 用于修改和读取任务寄存器中的可见部分，指令所使用的操作数是一 16 位的选择符。

另外，还有一种提供对 TSS 间接、受保护引用的任务门描述符（Task Gete Descriptor）。这种描述符是在一般段描述符格式的基地址位 15..0 字段(第 3、4 字节)中存放的是一个 TSS 描述符的选择符，并利用其中的特权级字段(DPL)来控制使用描述符执行任务切换的权限。见下面有关中断描述符表 IDT 描述符中的说明。

在以下 4 种情况下，CPU 会切换执行的任务：

1. 当前任务执行了一条引用 TSS 描述符的 JMP 或 CALL 指令；
2. 当前任务执行了一条引用任务门的 JMP 或 CALL 指令；
3. 引用了中断描述符表（IDT）中任务门的中断或异常；
4. 当嵌套任务标志 NT 置位时，当前任务执行了一个 IRET 指令。

4. 中断和异常

中断和异常是一种特殊类型的控制转换。它们改变了正常程序流而去处理其它的事件（例如外部事

件、出错报告或异常条件）。中断与异常的主要区别在于中断常用于处理 CPU 外部的异步事件，而异常则是处理 CPU 在执行过程中本身检测到的问题。

外部中断源有两种：由 CPU 的 INTR 引脚输入的可屏蔽中断和 NMI 引脚输入的不可屏蔽中断。同样，异常也有两类：由 CPU 检测到的出错、陷阱或放弃事件以及编程设置的“软中断”（如 INT 3 指令等）。

处理器使用标识号（中断号）来识别每种类型的中断或异常。处理器所能识别的不可屏蔽中断 NMI 和异常的标识号是预先确定的，范围是 0 到 31（0x00-0x1f）。目前这些号码并没有全都使用，未确定的号码由 Intel 公司留作今后使用。

可屏蔽中断的标识号由外部中断控制器（如 8259A 可编程中断控制器）确定，并在 CPU 的中断识别阶段通知 CPU。8259A 所分配的中断号可以通过编程指定，可使用的标识号范围是 32 到 255（0x20-0xff）。Linux 系统将 32-47 分配给了可屏蔽中断，余下的 48-255 用来标识其它软中断。而 Linux 只使用了号码 128（0x80）作为系统调用的中断向量号。

4.1 中断描述符表

中断描述符表（Interrupt Descriptor Table – IDT）将每个中断或异常标识号与处理相应事件程序指令的一个描述符相关联。与 GDT 和 LDT 相似，IDT 是一个 8 字节描述符数组，但其第 1 项可以含有一个描述符。处理器通过将中断号异常号乘上 8 即可索引 IDT 中对应的描述符。IDT 可以位于物理内存的任何地方。处理器是使用 IDT 寄存器（IDTR）来定位 IDT 的。修改和复制 IDT 的指令是 LIDT 和 SIDT。与 GDT 表的操作一样，IDT 也是使用 6 字节数据的内存地址作为操作数的。前两个字节表示表的限长，后 4 个字节是表的线性基地址。

4.2 IDT 描述符

在中断描述符表 IDT 中可以含有三类描述符中的任意一种：

- 任务门（Task gates）；
- 中断门（Interrupt gates）；
- 陷阱门（Trap gates）；

附图 13 给出了任务门、中断门和陷阱门描述符的格式。

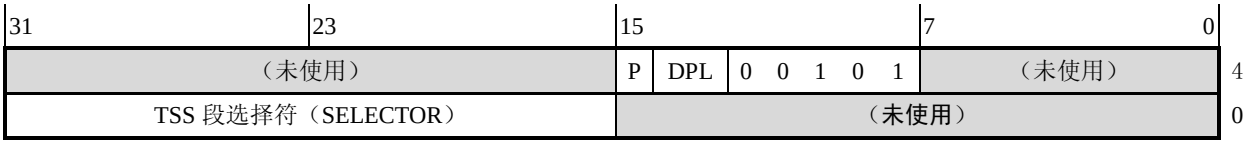

80X86 任务门描述符

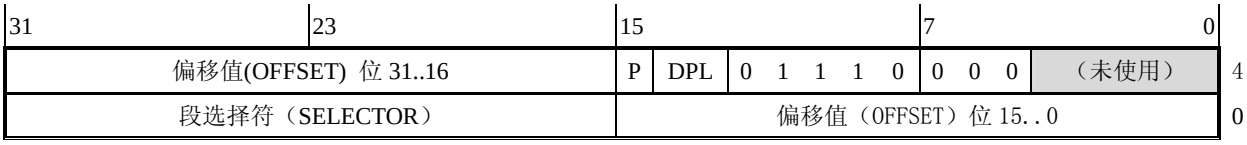

80X86 中断门描述符

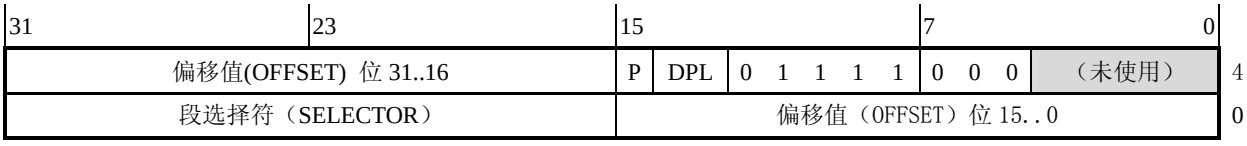

80X86 陷阱门描述符

附图 13 任务门、中断门和陷阱门描述符

4.3 中断任务和中断过程

正如 CALL 指令能调用一个过程或任务一样，一个中断或异常也能“调用”中断处理程序，该程序是一个过程或一个任务。当响应一个中断或异常时，CPU 使用中断或异常的标识号来索引 IDT 表中的描述符。如果 CPU 索引到一个中断门或陷阱门时，它就调用处理过程；如果是一个任务门，它就引起任务切换。

中断门或陷阱门间接地指向一个过程，该过程将在当前执行任务上下文中执行。门描述符中的段选择符指向 GDT 或当前 LDT 中的一个可执行段的描述符。门描述符中的偏移字段值指向中断或异常处理过程的开始处。

80X86 执行一个中断或异常处理过程的方式与 CALL 指令调用一个过程的方式非常相似，只是两者在使用堆栈上略有不同。中断会在把原指令指针压入堆栈之前，把原标志寄存器 EFLAGS 的内容也推入堆栈中。对于与段有关的异常，CPU 还会将一个错误码压入异常处理程序的堆栈上。

对于中断过程处理结束的返回操作，中断返回指令 IRET 与 RET 相似，但是 IRET 为了去除压入堆栈的 EFLAGS 值，ESP 会多递增 4 个字节。

中断门与陷阱门的区别在于对中断允许标志 IF 的影响。由中断门向量引起的中断会复位 IF，因此可以避免其它中断干扰当前中断的处理。随后的 IRET 指令会从堆栈上恢复 IF 的原值；而通过陷阱门产生的中断则不会影响 IF 标志。

IDT 表中的任务门描述符间接地指向一个任务状态段 TSS。任务门描述符中的段选择符指向 GDT 表中的一个 TSS 描述符。当产生的中断或异常指向 IDT 中的一个任务门描述符，就会导致任务切换，从而会在独立的任务中处理中断。Linux 系统中并没有使用任务门描述符。

附录4 ASCII 码表

DEC	HEX	CHR	DEC	HEX	CHR	DEC	HEX	CHR
0	00	NUL	43	2B	+	86	56	V
1	01	SOH	44	2C	,	87	57	W
2	02	STX	45	2D	-	88	58	X
3	03	ETX	46	2E	.	89	59	Y
4	04	EOT	47	2F	/	90	5A	Z
5	05	ENQ	48	30	0	91	5B	[
6	06	ACK	49	31	1	92	5C	\
7	07	BEL	50	32	2	93	5D	]
8	08	BS	51	33	3	94	5E	^
9	09	TAB	52	34	4	95	5F	_
10	0A	LF	53	35	5	96	60	`
11	0B	VT	54	36	6	97	61	a
12	0C	FF	55	37	7	98	62	b
13	0D	CR	56	38	8	99	63	c
14	0E	SO	57	39	9	100	64	d
15	0F	SI	58	3A	:	101	65	e
16	10	DLE	59	3B	;	102	66	f
17	11	DC1	60	3C	<	103	67	g
18	12	DC2	61	3D	=	104	68	h
19	13	DC3	62	3E	>	105	69	i
20	14	DC4	63	3F	?	106	6A	j
21	15	NAK	64	40	@	107	6B	k
22	16	SYN	65	41	A	108	6C	l
23	17	ETB	66	42	B	109	6D	m
24	18	CAN	67	43	C	110	6E	n
25	19	EM	68	44	D	111	6F	o
26	1A	SUB	69	45	E	112	70	p
27	1B	ESC	70	46	F	113	71	q
28	1C	FS	71	47	G	114	72	r
29	1D	GS	72	48	H	115	73	s
30	1E	RS	73	49	I	116	74	t
31	1F	US	74	4A	J	117	75	u
32	20	(space)	75	4B	K	118	76	v
33	21	!	76	4C	L	119	77	w
34	22	"	77	4D	M	120	78	x
35	23	#	78	4E	N	121	79	y
36	24	$	79	4F	O	122	7A	z
37	25	%	80	50	P	123	7B	{
38	26	&	81	51	Q	124	7C	|
39	27	'	82	52	R	125	7D	}
40	28	(	83	53	S	126	7E	~
41	29	)	84	54	T	127	7F	DEL
42	2A	*	85	55	U			

索引

由于内核代码相对比较庞大，很多变量/函数在源代码的很多程序中被使用/调用，因此对其进行索引比较困难。本索引主要根据变量或函数名称给出定义它的程序文件名、行号和所在页码。