



Linux驱动入门

主编 魏清
副主编 梁庚 徐志国

按照初学者的思路来讲述Linux驱动

- ◎ 结合Linux内核源码的分析来进行Linux驱动的开发
- ◎ 立足实践，体现苏嵌教育多年的经验



电子工业出版社
PUBLISHING HOUSE OF ELECTRONICS INDUSTRY
<http://www.phei.com.cn>

嵌入式技术与应用丛书

Linux 驱动入门

主编 魏 清

副主编 梁 庚 徐志国

电子工业出版社
Publishing House of Electronics Industry
北京 · BEIJING

内 容 简 介

本书主要是从 Linux 内核、Linux 总线和 Linux 子系统三个角度对 Linux 驱动进行介绍的，然后对字符设备、块设备和网络设备也分别做了大致介绍。从内容上来讲，本书包括 4 个部分：Linux 内核部分（第 1~6 章），主要包括 Linux 进程调度与进程管理、中断机制、定时机制、并发与同步机制及内存管理，通过对本篇内容的学习，读者可以掌握 Linux 内核的基本概念；Linux 总线部分（第 7~13 章），主要包括 Platfrom 总线、单总线、I2C 总线、串口总线、PCI 总线、SPI 总线和 USB 总线，通过对本篇内容的学习，读者可以掌握设备是如何挂载到 Linux 内核总线上的；Linux 子系统部分（第 14~19 章），主要包括 Keyboard 子系统，LED 子系统、RTC 子系统、Input 子系统、Backlight 子系统、Hwmon 子系统，通过对本篇内容的学习，读者可以掌握如何使用内核中现有的子系统，给设备编写驱动；Linux 驱动部分（第 20~24 章），主要包括看门狗驱动、LCD 驱动、触摸屏驱动、块设备驱动和网络设备驱动，通过对本篇内容的学习，读者可以掌握具体的设备驱动程序的设计方法。

本书适合嵌入式驱动开发的初学者学习使用，也可作为相关专业的教材。

未经许可，不得以任何方式复制或抄袭本书之部分或全部内容。

版权所有，侵权必究。

图书在版编目（CIP）数据

Linux 驱动入门 / 魏清主编. —北京：电子工业出版社，2014.3

（嵌入式技术与应用丛书）

ISBN 978-7-121-22461-4

I. ①L… II. ①魏… III. ①Linux 操作系统 IV. ①TP316.89

中国版本图书馆 CIP 数据核字（2014）第 025904 号

责任编辑：田宏峰 特约编辑：牛雪峰

印 刷：涿州市京南印刷厂

装 订：涿州市京南印刷厂

出版发行：电子工业出版社

北京市海淀区万寿路 173 信箱 邮编 100036

开 本：787×1092 1/16 印张：20 字数：510 千字

印 次：2014 年 3 月第 1 次印刷

印 数：4 000 册 定价：49.00 元



凡所购买电子工业出版社图书有缺损问题，请向购买书店调换。若书店售缺，请与本社发行部联系，联系及邮购电话：(010) 88254888。

质量投诉请发邮件至 zlts@phei.com.cn，盗版侵权举报请发邮件至 dbqq@phei.com.cn。

服务热线：(010) 88258888。

前　　言

目前，国内图书市场上驱动开发书籍虽多，但大多都脱离了 Linux 的内核资源，单一地介绍设备驱动。而作为一个合格的驱动工程师，应该能站在全局的角度，充分利用 Linux 内核中现有的关于总线和子系统的驱动代码，来实现具体设备的驱动。

本书从嵌入式底层驱动开发角度出发，结合 Linux 内核源码分析，将隐藏在嵌入式驱动开发背后的，关于 Linux 内核中的进程管理、内存管理，以及各类驱动等机制和知识娓娓道来。不仅让读者知其然，更要让读者知其所以然，并让这些知识再反作用于实践，从而帮助读者掌握相应设备的驱动。具体说来，全书主要讨论了包括 Linux 内核的基础知识、Linux 内核中进程、内存、中断管理的实现，各类驱动机制的框架实现，字符设备、块设备、网络设备驱动的实现等多个方面的话题。为了读者真正理解这些理论，本书结合每一个总线和子系统相关的驱动代码，使用友善之臂的 Mini2440 开发板，对所讲的总线和子系统代码进行了实际应用，使读者能够真正掌握和使用 Linux 内核中现有的驱动资源。

嵌入式驱动学习一直是所有初学者的高门槛，找到一本合适的参考教材往往非常困难。我在苏嵌的学习期间就已经在网络上分享和交流驱动学习经验，正是在 CSDN 论坛上与无数初学者的沟通和交流，才萌生了给驱动初学者创作本书的念头。在即将走上工作岗位之际，结合自己学成后的项目实践经验，最终成稿。本书的出版也得到了苏嵌教育驱动开发组老师的大力支持，苏嵌教育经过六年的沉淀，嵌入式硬件培训一直在行业内独树一帜，在驱动领域更是总结了很多培训成果，这些成果出于知识产权保护的原因，并未向大众开放。参与本书的作者大多数人都是苏嵌学生和老师中的杰出代表，他们全面总结自身嵌入式驱动学习经验，也第一次面向大众解密了苏嵌驱动开发教学中的许多特色细节。

在多年的项目开发过程中，我发现，要想成为一个嵌入式驱动开发工程师，需要“内外兼修”。内功就是熟悉 Linux 内核源码，对内核中的管理机制一定要很熟悉，并且要有很好的硬件基础。这里的基础不仅是所谓的模电和数电，而且要对 CPU 及其外围设备的时序及工作原理很精通，这是决定你是否能成为合格的驱动开发工程师的根本因素。而外功就是精通 C 语言、数据结构，至少 5 万行代码量，掌握 Linux 上层调用机制，深入理解 Linux 操作系统。对于在校的大学生，在校学习的课程相对独立，缺乏系统性，即使学习 Linux 操作系统，在大学四年都无法接触到 Linux 内核，只是具备少量的“外功”而已，更不要提毕业之后从事 Linux 驱动开发了。

大学生应如何修炼自己“内外功”呢？我们的建议是先从“外功”开始修炼。在大学低年级时先熟悉 C 语言、数据结构以及 Linux 上层的调用机制，熟悉 Linux 操作系统，日常开发在 Linux 平台下进行，并尝试的去看 Linux 内核源码，看不懂没关系，但至少能够对内核中所用到的一些概念及专业名词有所了解，为以后打下基础。大学三四年级就可以专心修炼“内功”了，结合大学所开设的专业课，弥补自己体系知识上的不足。最重要的就是要实践，动手写驱动，借助资料，一步一步地剖析 Linux 内核源码。这样度过大学四年的话，Linux 驱动工程师的梦想就不再是遥不可及了。最后，还要提醒大家在学习的过程中，一定要对自

己学习的东西多做总结，写学习和开发心得，这样能加快您前进的步伐。在苏嵌培训过的不少学员都进入了不错的研发企业，普通二本、三本的学生拿到了年薪 10 万元待遇的人很多。

感谢我的父母、老师和朋友一直以来对我的关心和帮助。参与本书编写的还有张成、李赛、闫坤等。本书汇集了作者的学习心得，对于想学习驱动的同学，无疑是一本高效的入门指南，期待更多如此的佳作问世！

鉴于时间仓促，作者水平有限，书中难免有错误和不足之处，希望广大读者批评指正。
联系 E-mail: training@jestc.com，并已开通 QQ 技术讨论群：1780328730。

作 者

2014 年 1 月于金陵

反侵权盗版声明

电子工业出版社依法对本作品享有专有出版权。任何未经权利人书面许可，复制、销售或通过信息网络传播本作品的行为；歪曲、篡改、剽窃本作品的行为，均违反《中华人民共和国著作权法》，其行为人应承担相应的民事责任和行政责任，构成犯罪的，将被依法追究刑事责任。

为了维护市场秩序，保护权利人的合法权益，我社将依法查处和打击侵权盗版的单位和个人。欢迎社会各界人士积极举报侵权盗版行为，本社将奖励举报有功人员，并保证举报人的信息不被泄露。

举报电话：（010）88254396；（010）88258888

传 真：（010）88254397

E-mail：dbqq@phei.com.cn

通信地址：北京市万寿路 173 信箱

电子工业出版社总编办公室

邮 编：100036

目 录

第 1 章 内核基础	1
1.1 Linux 内核组成	1
1.2 Linux 内核的引导	2
1.3 处理器	3
1.4 存储器	4
第 2 章 进程管理	5
2.1 进程调度	5
2.2 Linux 调度的实现	5
2.3 抢占和上下文切换	6
2.4 进程概念	6
2.5 进程上下文	7
2.6 进程与线程的创建	7
2.7 孤儿进程	8
2.8 系统调用	8
2.9 内核设计系统调用	9
第 3 章 中断处理	11
3.1 中断和中断处理	11
3.2 中断的下半部分	11
3.3 中断下半部分的实现	12
第 4 章 定时计数	14
4.1 定时器基本概念	14
4.2 动态定时器的使用	15
第 5 章 并发同步	16
5.1 内核同步与死锁问题	16
5.2 解决并发同步的方法	17
第 6 章 内存管理	19
6.1 内存管理中基本概念	19
6.2 申请内存的几种方法	19
6.3 内核栈	20
6.4 进程地址空间的基本概念	21
6.5 创建和撤销内存区域	22
6.6 页表	22
6.7 页高速缓存与页回写	23

第 7 章 Platform 总线	25
7.1 Platform 设备驱动概念	25
7.1.1 Platform 总线	25
7.1.2 Platform 设备	26
7.1.3 Platform 驱动	29
7.2 平台设备的资源	29
7.2.1 平台数据和私有数据的区别	29
7.2.2 Platform 设备资源的读取	30
7.3 平台设备驱动测试	30
7.3.1 Platform 设备模块代码	31
7.3.2 Platform 驱动模块代码	32
7.3.3 应用层测试代码	37
第 8 章 单总线	39
8.1 单总线驱动概述	39
8.2 单总线驱动移植	39
8.3 单总线驱动内核代码分析	40
8.3.1 master 驱动分析	40
8.3.2 slave 驱动分析	48
8.4 单总线驱动测试	52
8.5 脱离子系统的 DS18B20 驱动	53
第 9 章 I2C 总线	58
9.1 系统理论	58
9.1.1 I2C 驱动体系概述	58
9.1.2 驱动工程师需要做的事	58
9.2 内核代码	58
9.2.1 内核/drivers/i2c 目录下文件分析	58
9.2.2 I2C 核心	59
9.2.3 I2C 总线驱动	59
9.2.4 I2C 设备驱动	73
9.3 测试代码	80
第 10 章 串口总线	83
10.1 系统理论	83
10.2 串口内核配置	83
10.3 UART 层内核代码	85
10.4 tty 层内核代码	88
10.5 线路规程内核代码	97
10.6 串口测试代码	103
第 11 章 PCI 总线	109
11.1 PCI 总线理论	109

11.1.1	PCI 总线的特点	109
11.1.2	PCI 设备概述	109
11.1.3	查询 PCI 总线和设备的命令	110
11.1.4	PCI 总线架构	110
11.2	PCI 驱动	111
11.2.1	PCI 寻找空间	111
11.2.2	PCI 总线支持的设备	112
11.2.3	PCI 驱动其他 API	112
11.3	PCI 驱动模型	112
11.4	PCI 设备的枚举过程	114
第 12 章	SPI 总线	132
12.1	SPI 理论介绍	132
12.2	SPI 驱动移植	132
12.3	SPI 设备和驱动的注册	135
12.3.1	SPI 主控设备的注册	135
12.3.2	SPI 接口设备的添加	136
12.3.3	SPI 主控设备驱动的注册	137
12.3.4	SPI 接口设备的注册	137
12.3.5	SPI 接口设备驱动的注册	138
12.4	SPI 内核代码分析	139
12.5	SPI 测试代码	159
第 13 章	USB 总线	162
13.1	USB 总线理论	162
13.1.1	USB 概述	162
13.1.2	USB 主机控制器	162
13.1.3	USB 设备与 USB 驱动的匹配	162
13.1.4	USB 设备的逻辑结构和端点的传输方式	163
13.1.5	USB 的 URB 请求块	163
13.1.6	USB 的枚举过程	164
13.2	USB 总线驱动分析	164
13.2.1	USB 驱动框架 usb-skeleton.c	164
13.2.2	USB 鼠标驱动 usbmouse.c	174
13.2.3	USB 键盘驱动 usbkbd.c	178
13.2.4	U 盘驱动分析	183
13.3	U 盘驱动测试	197
第 14 章	Keyboard 子系统	198
14.1	Keyboard 子系统移植与分析	198
14.2	Keyboard 驱动测试	200

第 15 章 LED 子系统	201
15.1 LED 子系统移植与分析	201
15.2 LED 驱动测试	205
第 16 章 RTC 子系统	206
16.1 RTC 子系统的移植与分析	206
16.2 RTC 驱动测试	210
第 17 章 Input 子系统	211
17.1 Input 子系统系统理论	211
17.1.1 Input 子系统概述	211
17.1.2 Input 子系统几个重要数据结构	211
17.1.3 Input 子系统核心层和事件处理层函数概述	214
17.2 内核代码	214
17.2.1 输入子系统设备驱动层	214
17.2.2 输入子系统核心层	224
17.2.3 输入子系统事件处理层	227
17.3 测试代码	229
17.3.1 设备驱动层代码	230
17.3.2 应用层测试代码	232
17.3.3 测试过程和结果	233
第 18 章 Backlight 背光子系统	234
18.1 Backlight 背光子系统概述	234
18.2 PWM 核心驱动	234
18.3 Backlight 核心驱动	239
18.4 基于 PWM&Backlight 的蜂鸣器驱动	242
18.5 驱动测试	246
第 19 章 Hwmon 子系统	247
19.1 Hwmon 子系统概述	247
19.2 ADC 核心驱动	247
19.3 Hwmon 核心驱动	251
19.4 基于 ADC&Hwmon 的 A/D 驱动	252
19.5 驱动测试	258
第 20 章 看门狗驱动	259
20.1 看门狗驱动移植与分析	259
20.2 看门狗驱动测试	260
第 21 章 LCD 驱动	261
21.1 LCD 屏理论	261
21.1.1 LCD 屏基本概念	261
21.1.2 帧缓冲的理解	261

21.2	Mini2440 的 X35 型 LCD 移植	262
21.3	LCD 文件层和驱动层设计思路	264
21.3.1	LCD 驱动中几个重要的数据结构	265
21.3.2	LCD 驱动层	268
21.3.3	LCD 文件层	279
21.4	LCD 驱动测试	284
第 22 章 触摸屏驱动		286
22.1	触摸屏理论概述	286
22.2	触摸屏驱动分析	286
22.3	触摸屏驱动测试	294
第 23 章 Linux 下的块设备驱动		296
23.1	块设备驱动概论	296
23.2	块设备驱动中几个重要的数据结构	296
23.3	使用 I/O 调度的块设备驱动	298
23.4	块设备驱动的测试	302
第 24 章 Linux 下的网络设备驱动		305
24.1	网络设备驱动基础	305
24.1.1	以太网基础理论	305
24.1.2	Linux 网络驱动层次	305
24.2	网络设备驱动移植	307
24.3	网络设备驱动测试	308
参考文献		309



第 1 章

内核基础



1.1 Linux 内核组成

Linux 内核主要是由进程调度、内存管理、虚拟文件系统、网络接口和进程通信五个子系统组成的。

(1) 进程调度控制系统中的多个进程对 CPU 的访问，使得多个进程能在 CPU 中“微观串行，宏观并行”地执行。

(2) 内存管理的主要作用是控制多个进程安全地共享主内存区域，当 CPU 提供内存管理单元时，Linux 内存管理完成为每个进程进行虚拟内存到物理内存的转换。一般而言，Linux 的每一个进程享有 4 GB 的内存空间，0~3 GB 为用户空间，3~4 GB 为内核空间，这 1 GB 的内核空间又被划分为物理内存映射区、虚拟内存分配区、高端页面映射区和系统保留映射区。物理内存映射区最大长度为 896 MB，系统物理内存 0~896 MB 就映射到这个物理内存映射区，系统物理内存中大于 896 MB 的数据属于高端内存，会被映射到高端页面映射区。由此可见，在 3~4 GB 的内核空间中，从低地址到高地址依次为：物理内存映射区、隔离带、虚拟内存分配区、隔离带、高端内存映射区、专用页面映射区和保留区。

为了了解内存管理单元 MMU，我们还需要知道 TLB（块表）和 TTW（转换表漫游，又叫做慢表，当 TLB 中没有缓冲对应的地址转换关系时，需要通过多级页表的访问来获得虚拟地址和物理地址的对应关系，TTW 成功后，结果写入 TLB）。

(3) 虚拟文件系统隐藏各种硬件的具体细节，为所有的设备提供统一的接口。

(4) 网络接口提供了对各种网络标准的存取和各种网络硬件的支持。

(5) 进程通信支持提供进程之间的通信，包括信号量、共享内存、管道等。

Linux 内核五个部分的关系如下所述。

- 进程调度和内存管理之间的关系：相互依赖，程序要运行必须为其创建进程，而创建进程的第一件事就是将程序和数据装入内核。
- 进程通信与内存管理的关系：进程间通信需要依靠内存管理支持共享内存机制。
- 虚拟文件系统和网络接口的关系：虚拟文件系统利用网络接口支持网络文件系统，也利用内存管理支持 RAMDISK 设备。
- 虚拟文件系统与内存管理的关系：内存管理利用虚拟文件系统支持交换，当一个进程存储的内存映射被换出时，内存管理向文件系统发出请求，同时挂起当前正在运行的进程。



1.2 Linux 内核的引导

1. Boot Loader 简介

在 CPU 上电启动时，一般连内存控制器都没有初始化过，根本无法在主存中运行程序，更不可能处在 Linux 内核启动环境中。为了初始化 CPU 及其他外设，使得 Linux 内核可以在系统主存中运行，并让系统符合 Linux 内核启动的必备条件，必须要有一个先于内核运行的程序，即所谓的引导加载程序 Boot Loader，Boot Loader 是在操作系统内核启动之前运行的一段小程序。通过这段程序，系统可以初始化硬件设备，从而将系统的软/硬件环境带到一个合适的状态，以便为最终调用操作系统内核准备好正确的环境，最后从别处（Flash、以太网、UART）载入内核、映像到主存并跳到入口地址。U-Boot 是 Das U-Boot 的简称，其含义是 Universal Boot Loader，是遵循 GPL 条款的开放源码项目。Boot Loader 的操作方式包括启动加载模式和下载模式，我们开发的时候使用下载模式。

2. Boot Loader 的主要任务

依赖于 CPU 体系结构的代码，如设备初始化代码等，通常都放在 stage1 中，而且通常都用汇编语言来实现，以达到短小精悍的目的。而 stage2 则通常用 C 语言来实现，这样可以实现复杂的功能，而且代码会具有更好的可读性和可移植性。

3. Boot Loader 的 stage1 通常包括以下步骤（按执行的先后顺序）

- (1) 硬件设备初始化。
- (2) 为加载 Boot Loader 的 stage2 准备 RAM 空间。
- (3) 拷贝 Boot Loader 的 stage2 到 RAM 空间中。
- (4) 设置好堆栈。
- (5) 跳转到 stage2 的 C 入口点。

4. Boot Loader 的 stage2 通常包括以下步骤（按执行的先后顺序）

- (1) 初始化本阶段要使用到的硬件设备。
- (2) 检测系统内存映射。
- (3) 将 Kernel 映像和根文件系统映像从 Flash 上读到 RAM 空间中。
- (4) 为内核设置启动参数。
- (5) 调用内核。

嵌入式系统在复位后就直接运行 Boot Loader，当 Boot Loader 的控制权被释放后，内核阶段就开始了，内核在进行一些初始化操作之后，就调用 “/init/main.c” 中的 start_kernel 函数，该函数会调用一系列初始化函数来设置中断，执行进一步的内存配置。之后，“/arch/i386/kernel/process.c” 中 kernel_thread 被调用以启动第一个核心线程，该线程执行 init

函数，作为核心线程的 init 函数完成外设及其驱动程序的加载和初始化，挂接根文件系统，搜索 init 程序的顺序是“/sbin/init”、“/etc/init”、“/bin/init”和“/bin/sh”。

5. U-boot 烧写过程

使用 U-boot 将映像文件烧写到板上的 Flash，一般步骤是：

- (1) 通过网络、串口、U 盘、SD 卡等方式将文件传输到 SDRAM。
- (2) 使用 Nand Flash 或 Nor Flash 相关的读写命令将 SDRAM 中的数据烧入 Flash。

注意：如果使用 SD 卡和 U 盘形式更新 U-boot，那么首先 SD 卡和 U 盘中必须有 FAT32 文件系统，并在里面存放了 u-boot.bin 文件。

举例：通过 NFS 服务烧入 Nand Flash。

```
nfs 3000800 192.168.1.100:/home/tekkaman/development/share/u-boot.bin
nand erase 0 0x40000
nand write 0x30008000 0 0x40000
```

6. 内核的引导过程

内核的引导步骤如下。

- (1) 用 U-boot 的 mkimage 工具处理内核映像 zImage。
- (2) 通过网络、串口、U 盘、SD 卡等方式将处理过的内核映像传输到 SDRAM 的一定位置（一般使用 0x30008000）。
- (3) 使用“bootm”等内核引导命令来启动内核。

通过 Nand Flash 引导内核。首先要将处理过的内核映像文件烧入 Nand Flash 的一定位置（由内核分区表决定）。以后每次启动时用 Nand Flash 的读取命令先将这个内核映像文件读到内存的一定位置（由制作内核映像时的“-a”参数决定），再使用 bootm 命令引导内核。

举例：通过 NFS 服务引导内核。

```
nfs 30008000 192.168.1.100:/home/tekkaman/development/share/zImage.img
bootm 30008000
```



1.3 处理器

中央处理器体系架构可以分为两类：冯·诺依曼结构和哈佛结构。冯·诺依曼结构把程序和操作数都放在同一个存储器中，这个存储器通过总线与处理器相连，而哈佛结构是把程序放在程序存储器内，通过程序总线与处理器相连，然后把操作数放在操作数存储器中，通过操作数总线与处理器相连。

中央处理器从指令的角度也可以分为 RISC（精简指令集计算机）和 CISC（复杂指令集计算机）。中央处理器按应用领域可以分为通用处理器（GPP）、数字信号处理器（DSP）和专用处理器及 ASIC。其中 GPP 包括 MCU（微控制器，又叫做单片机）和 MPU（微处理器）；DSP 包括定点 DSP 和浮点 DSP。



1.4 存 储 器

存储器分为非易失性存储器（NVM）和 RAM，其中 NVM 包括 ROM、Flash 和光磁介质存储器；RAM 包括 SRAM、DRAM 和特定应用的 RAM。

NOR Flash: Intel 公司，程序可以直接在 NOR 内运行。

NAND Flash: 东芝公司，NAND 以块方式进行访问，不支持芯片内执行，容量大、价格低，擦写次数和速度，以及编程速度远超 NOR。但是会出错，应用 ECC 检查错误。



第2章

进 程 管 理



2.1 进程调度

多任务系统可以分为非抢占式和抢占式两种。Linux 提供抢占式多任务模式，进程在被抢占之前能够运行的时间叫进程的时间片，Linux 独一无二的公平调度程序本身并没有采用时间片来达到公平调度。

Linux 之前采用 $O(1)$ 调度器，它对大服务器的工作负载很理想，但是对响应时间敏感的程序却有不足。在 Linux 2.6.23 内核版本中用完全公平调度算法（CFS）代替了 $O(1)$ 调度算法。

进程可以被分为 I/O 消耗型和处理器消耗型。I/O 消耗型指进程的大部分时间用来提交 I/O 请求或是等待 I/O 请求；处理器消耗型是指进程把事件大多数用在执行代码上。调度策略通常在两个矛盾中寻找平衡：进程响应迅速和最大系统利用率。Linux 更倾向于优先调度 I/O 消耗型进程。

调度程序总是选择时间片未用尽而且优先级最高的进程运行。

Linux 采用两种不同的优先级范围：第一种是 nice 值，越大的 nice 值意味着更低的优先级；第二种是实时优先级，其值可以配置，越高的实时优先级数值意味着进程优先级越高。任何实时进程的优先级都高于普通进程。

CFS 做法：允许每个进程运行一段时间，循环轮转，选择运行最少的进程作为下一个运行进程，而不再采用分配给每一个进程时间片的做法，CFS 在所有可运行进程总数基础上计算出一个进程应该运行多久，而不是依靠 nice 值来计算时间片。CFS 引入每个进程获得的时间片底线（最小粒度）默认情况为 1 ms，绝对的 nice 值不再影响调度决策，任何进程所获得的处理器时间由它自己和其他所有可运行进程 nice 值的相对差决定。



2.2 Linux 调度的实现

(1) 时间记账。调度器实体结构是 `struct sched_entity`，它嵌入在进程描述符 `struct task_struct` 中。虚拟时间以 ns 为单位，存在 `vruntime` 变量中，它和定时器节拍不再相关，`vruntime` 变量可以准确测定进程的运行时间，而且可以知道谁应该是下一个被运行的进程。

(2) 进程选择。当 CFS 需要选择下一个运行进程时，它会挑一个具有最小 `vruntime` 的进程，这就是 CFS 调度算法的核心：选择具有最小的 `vruntime` 的任务。这里采用红黑树实现的。

(3) 调度器入口。进程调度的主要入口点是 `schedule` 函数，该函数会以优先级为序，从高到低，依次检查每一个调度器，并且从最高优先级的调度器中，选择最高优先级的进程。

(4) 睡眠和唤醒。对于睡眠，内核的操作是：进程把自己标记为休眠状态，从可执行红黑树中移出，放入等待队列，然后调用 `schedule` 函数选择和执行一个其他进程。对于唤醒，正好相反，进程被设置为可执行状态，然后从等待队列中移到可执行红黑树中。

休眠有两种进程状态：`TASK_INTERRUPTIBLE` 和 `TASK_UNINTERRUPTIBLE`。它们唯一的区别在于处在 `TASK_UNINTERRUPTIBLE` 的进程会忽略信号，处于 `TASK_INTERRUPTIBLE` 状态的进程如果接收到一个信号，会被提前唤醒并响应该信号。两种状态的进程位于同一个等待队列上，等待某些事情，不能够运行。

关于休眠还需要注意一点：存在虚假的唤醒，所以有时候需要一个循环处理来保证进程被唤醒的条件真正大达成。等待队列的使用：

```
static DECLARE_WAIT_QUEUE_HEAD(button_waitq);           // 定义等待队列头
wait_event_interruptible(button_waitq, ev_press);      // 休眠
wake_up_interruptible(&button_waitq);                  // 唤醒
```

2.3 抢占和上下文切换

上下文切换就是从一个可执行进程切换到另一个可执行进程。`Schedule` 函数主要完成两个工作：其一，把虚拟内存从上一个进程映射切换到新进程中；其二，从上一个进程的处理器状态切换到新进程的处理器状态。

内核必须知道在什么时候调用 `schedule` 函数，如何仅靠用户程序代码显式地调用 `schedule`，它们可能就会被永远执行下去，所以内核中提供了一个 `need_resched` 标志来表明是否需要重新执行一次调度，该标志对于内核来讲是一个信息，它表示有其他进程应当被运行了，要尽快调用调度程序。

用户抢占：内核即将返回用户空间的时候，如果 `need_resched` 标志被设置，会导致 `schedule` 函数被调用，此时就会发生用户抢占。用户抢占有如下情况时产生：其一，从系统调用返回用户空间时；其二，从中断处理程序返回用户空间时。

内核抢占：在 Linux 2.6 版内核中，内核引入抢占能力，只要重新调度是安全的，即只要没有持有锁，内核就可以在任何时候抢占正在执行的任务。为了支持内核抢占，在每个进程的 `thread_info` 引入 `preempt_count` 计数器，当做一把锁来使用。内核抢占有如下情况时产生。

- 中断处理程序正在执行，且返回用户空间之前。
- 内核代码再一次具有可抢占性的时候。
- 如果内核中的任务显式地调用 `schedule` 函数。
- 如果内核中的任务阻塞（这样会调用 `schedule` 函数）。

2.4 进程概念

进程是正在执行的程序代码的实时结果，是处于执行期的程序以及相关的资源的总称。线程是在进程中活动的对象，内核调度的对象是线程，而不是进程。对于 Linux 系统而言，