LINUX 内核精髓

精通LINUX内核必会的75个绝技

LINUX KERNEL HACKS™

高桥 浩和 主编

池田 宗广、大岩 尚宏、岛本 裕志
竹部 晶雄、平松 雅巳 著

杨婷 译

刘波 审校

O'REILLY®
机械工业出版社
China Machine Press
华章科技

O’Reilly 精品图书系列

Linux内核精髓

——精通Linux内核必会的75个绝技

Linux Kernel Hacks

[日]高桥 浩和　著

杨婷　译

ISBN：978-7-111-41049-2

本书纸版由机械工业出版社于2013年出版，电子版由华章分社（北京华章图文信息有限公司）全球范围内制作与发行。

客服热线：+ 86-10-68995265

客服信箱：service@bbbvip.com

官方网址：www.hzmedia.com.cn

新浪微博 @研发书局

腾讯微博 @yanfabook

目　录

O’Reilly Media, Inc.介绍

O'Reilly Media通过图书、杂志、在线服务、调查研究和会议等方式传播创新知识。自1978年开始，O’Reilly一直都是前沿发展的见证者和推动者。超级极客们正在开创着未来，而我们关注真正重要的技术趋势—通过放大那些“细微的信号”来刺激社会对新科技的应用。作为技术社区中活跃的参与者，O’Reilly的发展充满了对创新的倡导、创造和发扬光大。

O'Reilly为软件开发人员带来革命性的“动物书”；创建第一个商业网站（GNN）；组织了影响深远的开放源码峰会，以至于开源软件运动以此命名；创立了Make杂志，从而成为DIY革命的主要先锋；公司一如既往地通过多种形式缔结信息与人的纽带。O’Reilly的会议和峰会集聚了众多超级极客和高瞻远瞩的商业领袖，共同描绘出开创新产业的革命性思想。作为技术人士获取信息的选择，O’Reilly现在还将先锋专家的知识传递给普通的计算机用户。无论是通过书籍出版，在线服务或者面授课程，每一项O’Reilly的产品都反映了公司不可动摇的理念—信息是激发创新的力量。

业界评论

“O'Reilly Radar博客有口皆碑。”

——Wired

“O'Reilly凭借一系列（真希望当初我也想到了）非凡想法建立了数百万美元的业务。”

——Business 2.0

“O'Reilly Conference是聚集关键思想领袖的绝对典范。”

——CRN

“一本O’Reilly的书就代表一个有用、有前途、需要学习的主题。”

——Irish Times

“Tim是位特立独行的商人，他不光放眼于最长远、最广阔的视野并且切实地按照Yogi Berra的建议去做了：‘如果你在路上遇到岔路口，走小路（岔路）。’回顾过去Tim似乎每一次都选择了小路，而且有几次都是一闪即逝的机会，尽管大路也不错。”

——Linux Journal

编者与作者介绍

主编简介

高桥浩和（Hirokazu Takahashi）

毕业于北海道大学电子工学系。从VAX全盛时代开始致力于各种UNIX系列操作系统的功能强化和内核调整，以及大规模系统的实时操作系统的设计等。以ISP的服务器构建为契机，开始正式研究Linux。

作者简介

池田宗广（Munehiro IKEDA）

大学时代，亲眼看到X68000的gcc生成比主流编译器还要快好几倍的代码，因此开始确信免费软件/开源软件的可能性。此后，在历经咖啡店店员、生产技术人员、硬件工程师后，终于开始从事Linux内核开发。这个行业最吸引人的就是能够跨公司甚至跨国界与世界最优秀的技术人员进行交流。现居住在美国，爱好音乐演奏，当过鼓手，也当过主唱，最近几年一直在弹贝斯。不管是作为技术人员还是贝斯手都喜欢做幕后工作，只不过天生就不喜欢半途而废。

大岩尚宏（Naohiro Ooiwa）

任职于Miracle Linux株式会社的软件工程师。大学时研究的是类似手机这样使用天线接收无线高频信号的模拟线路。从事Linux开发工作的时候开始深入研究软件。他是《Debug Hacks》的作者，本书是O’REILLY JAPAN的第二本Hacks系列图书。

岛本裕志（Hiroshi Shimamoto）

软件工程师。负责问题分析和调试。主要工作就是在出现故障时，根据日志和核心转储找出问题所在。因此在工作中会经常用到二进制和CPU运行的知识。同时也在论坛中从事过一些关于x86架构和调度程序的活动。目前关注虚拟化方面的活动。

竹部晶雄（Akio Takebe）

在Xen、KVM等与虚拟化相关的开源论坛参与开发活动。主要负责IA64架构、RAS系列和PCI pass through的开发。在开源论坛认识了专门研究省电技术的工程师，从而开始对省电方面产生兴趣。现在正使用Ruby on Rails开发云计算相关软件。

平松雅巳（Masami Hiramatsu）

Linux内核追踪的相关维护人员。主要工作是对perf和ftrace的动态事件进行维护。也参与了SystemTap的开发，最近热衷于将系统SystemTap的用途从专门用于追踪扩展到游戏编程等。主要使用的是bash和vim，但是因为bash不能用hjkl移动光标，总的来说属于vim用户。喜欢使用Ubuntu和Fedora。现在的研究方向是ARM Linux、Btrfs等。

撰稿人简介

畑山大辅（HATAYAMA Daisuke）

crash gcore扩展模块的维护人员。对调试和故障分析感兴趣。最喜欢做的事情就是从元数据对系统进行研究。正在努力练习马拉松长跑，争取在搞技术的同时锻炼出健康的体魄。近期目标是四小时内跑完马拉松。

藤田朗（Akira Fujita）

任职于NEC软件东北株式会社。担任软件工程师。大学毕业之后开始转向软件行业。喜欢Linux文件系统（ext3/ext4）。喜欢defrag，爱好五人足球。

技术审校者简介

刘波，资深Linux内核开发工程师、应用开发工程师和嵌入式开发工程师，现在重庆工商大学计算机科学与信息工程学院担任教师，从事Linux程序开发和Oracle管理方面的教学工作，在读博士。此外，他还专注于大规模机器学习、数值分析与计算、最优化理论（凸优化）的研究。

致谢

本书的编著工作受到了多方的大力支持。计划还未确定时，O’REILLY JAPAN就对此表示了很大的兴趣，并给予我们参与写作的机会，对此我们要向O’REILLY JAPAN的各位表示衷心的感谢。特别是受到担任编辑的赤池凉子女士的很多照顾。写作进度滞后时，赤池女士依旧迅速地安排了后面的多次修改，非常感谢她。

对作为作者参与写作的池田宗广、平松雅巳先生，以及非常爽快地同意作为撰稿人紧急参与写作的藤田朗、畑山大辅先生也要表示衷心的感谢。在各位的辛勤努力下，本书才能够具有如此丰富和引人入胜的内容。

对百忙之中抽出时间负责主编的高桥浩和先生也表示衷心的感激。对写作过程中的技术趋势以及所有章节都进行了详细的指导。也非常感谢三好和人、永野武先生为我们免费提供很多原稿。

此外，非常感谢《Debug Hacks》的作者安部东洋，为本书进行指导，使得本书质量大幅提高。

在从一开始就共同执笔的岛本裕志、竹部晶雄先生的努力下，本书才得以顺利出版。感谢你们。最后，借此机会向本书写作过程中为我们提供协助的各方人士表示衷心的感谢。

大岩尚宏

主编致辞

从1991年Linux内核诞生，到现在已经过去了20多年，现在Linux 3.0也即将发布。在这20多年间，Linux内核已经进化成可以在便携式计算机到大型服务器的各种硬件上运行的操作系统。至今仍有众多开发人员在不断地对Linux内核进行开发。

虽然网络上有很多关于Linux的信息，但是关于熟练使用Linux内核或者参与Linux内核开发所需的信息并不多。因此我们决定从这些信息中筛选出Linux技术人员可能感兴趣的内容，汇编成一本书。关于省电和虚拟化的介绍是非常符合当前市场需求的。高级内核的概要分析功能也是内核开发人员的必需工具。

在有限的篇幅内能够介绍的内容并不是很多，我们只是希望能够以此为契机，激发更多人对Linux内核的兴趣，并实际参与内核开发。

高桥浩和

前言

内核是操作系统的核心，操作系统的基本功能都是由内核提供的。文件生成和数据包传输等也是通过内核的功能实现的。但这些都不是简单的任务。平时可能意识不到，但这其中确实包含了很多先进技术。例如，在文件系统方面，配置文件时尽量减少磁盘扫描，在网络方面，由于路由表的入口数量庞大，因此设计时尽量保证对系统整体影响较小的设计。在内存管理、进程管理方面也作出了很多努力。解读这种先进技术也是内核构建的魅力之一。

然而，最近的Linux所提供的并不只有基本功能。随着功能的不断发展，现在已经出现了很多特定领域的便捷功能和独特功能。即使是内核黑客也很少有人能够完全掌握。

本书从Linux内核的众多先进功能中选取了一些必备并且有趣的内容进行介绍，同时也对内部的运行机制和结构进行了阐述。此外，本书还介绍了熟练使用这些功能所需的工具、设置方法以及调整方法等。

省电就是其中一项内容。除了使用方法以外，本书还介绍了省电的理念、与硬件的关系等。此外，还提到了当前广受关注的虚拟化、资源管理、标准文件系统中所采用的ext4等已有功能和新功能。对于已有功能，本书结合最新的源码，介绍它的更改内容和新增功能。其中也包括文档中没有记载，且必须对内核内部有一定理解才能得知的信息，因此，即使是比较了解这个功能的人也可能会有新的发现。另外，本书还介绍了内核的相关工具，其中gcore在重要的系统中就是非常可靠的工具。

最新的Linux内核中安装了强大的追踪、概要分析功能，具备很多方便实用的功能。这些功能不仅能够很方便地达到预期的目的，而且对于分析内核功能也非常有用。甚至对于内核构建的高手也有一定帮助。

全书列举了非常多的实例，让读者更快地学会如何使用。对于想要熟练使用内核的读者来说，本书也是非常好的参考书。

本书还为想要了解Linux内核的读者以及读过本书后开始对Linux内核开发产生兴趣的读者，介绍了获取内核源码的方法和内核开发方法等内核构建入门所需的信息。我们希望读者能够通过本书更加了解Linux的世界。

在电脑刚刚诞生的时候，有一段时期人们认为“如果想要提高编程水平就查看UNIX代码”。因为最快的方式就是参考天才所编写的最先进的代码并进行模仿。而在阅读Linux内核的代码时，相信大家也会深有同感。

Linux内核是开源软件，无论是谁都可以参与开发。Linux内核的代码花费了大量的时间和精力来编写。各领域都由具有专业知识的维护人员进行长期的管理，从而得到不断的改进。基于电子邮件的开发也在不断进行，因此可以看到各种讨论，并了解到当前代码的发展历程。每次看到Linux内核的代码，都会让人感叹其中凝聚的智慧和努力，也感受到当时的辛苦。希望读者能够从本书开始接触Linux这个不一般的世界，诞生更多的内核高手。

本书主要内容

本书介绍的是Linux内核所提供的功能。不仅有比较基础的功能，还有一些功能需要具有一定的知识才能使用。

此外，还介绍了使用功能时需要用到的信息和命令。除了内核以外，本书还将介绍相关的应用程序。基本上是基于TUI进行说明的，但也有一部分关于GUI的介绍。

涉及的主要版本为Linux内核2.6.18到写作时最新的Linux内核3.0[1]。其中一部分还介绍了Red Hat Enterprise Linux 4（RHEL4：基于Linux内核2.6.9）的功能。示例代码已经在工作中经常使用的RHEL和任何用户都可以使用的Fedora、CentOS等中进行过严格测试。

本书不涉及Linux内核的实际安装和以算法等为主体的内容。

[1]写作本书时已经发布了3.0-rc版本。

本书使用方法

本书可以按顺序依次阅读，另外由于每一节之间都是独立的，因此也可以从感兴趣的章节开始阅读。第1章介绍了内核的基础知识，如果是第一次接触内核，建议先学习第1章。本书在介绍已有功能时也加入了一些新的信息。相信即使是经验丰富的人也可以在本书中有新的发现，因此希望各位读者能够将本书从头到尾完整读一遍。本书还收录了一些作者珍藏的信息。详细内容请参见参考文献。

本书约定

等宽字体（sample）

表示文件名、文件的内容、控制台的输出、变量名称、命令、命令选项、数据包名称、模块名称、驱动程序名称、键、内核配置、样本代码、其他代码等。

等宽粗体（sample）

表示应替换为用户输入的命令或文本等。

斜体（sample）

表示根据环境决定的值等。

小贴士：表示提示、建议、补充事项等。

注意事项：表示注意、警告等。

每一节标题左侧的温度计图标表示该节的相对难易度。

意见与提问

关于本书的内容，我们尽最大的努力进行了验证和确认，但可能还是会存在错误或不正确的地方，或者是会引起误解或混淆的表述、输入错误等。如果在阅读本书的过程中发现了这些问题，请告知我们，以便进行改善。

株式会社O’REILLY（奥莱利）JAPAN

邮编160-0002东京都新宿区坂町26番地27 Intelligent大厦1层

电话03-3356-5227

FAX 03-3356-5261

电子邮件japan@oreilly.co.jp

关于本书的技术性问题和意见请发送到下列邮件地址。

japan@oreilly. co.jp

本书的网站上可以找到示例代码[1]、勘误表和附加信息。

http://www. oreilly.co.jp/books/9784873115016/

关于O’REILLY的其他信息请参考下列网站。

http://www. oreilly.co.jp/（日语）

http://www. oreilly.com/（英语）

[1]这些示例代码是笔者写作时使用的程序，并不保证在各种环境下都可以运行。另外，有时会不经过提示进行修改。示例代码不一定都能对应，敬请谅解。

第1章　内核入门

一提起内核包，总会让人感觉似乎困难至极、如临深渊一般。但其基本的操作与其他开放源代码软件包并没有什么不一样，都是首先获取源代码，进行解读，然后修改或者添加新功能对应的代码，并编译、测试。本章将介绍这些内核包操作中最基础的知识，以及Linux内核特有的方法。

HACK#1如何获取Linux内核

本节介绍获取Linux内核源代码的各种方法。

“获取内核”这个说法看似简单，其实Linux内核有很多种衍生版本。要找出自己想要的源代码到底是哪一个，必须首先理解各种衍生版本的意义。

接下来将简单介绍Linux内核的开发模式，并分析各种衍生版本在其中所处的地位，然后介绍获取这些衍生版本的源代码的方法。

内核的种类

想要获取正确的Linux内核源代码，首先必须了解Linux内核的开发模式。

Linux内核是由多个开发者以分散型的模式进行开发的。这里出现的“分散型”，是指多个衍生源码树同时存在。下面将简单介绍一些具有代表性的源码树及其地位。

Linus树

最具有代表性的源码树，应属Linux内核的最初创始人——Linus Torvalds所管理的Linus树。新版本Linux内核的发布，就意味着Linus树的源代码被贴上了新发布版本的标签。到2011年为止，Linux内核的版本号一直是用2.6.x这样的三个数字来表示的[1]。Linus树一直被认为是Linux内核源代码的“根源”，因此一旦其发布了新版本，其他的开发树就会将自己独特的开发成果移植到这个版本上，在此基础上再次进行开发。Linus树由于其“根源”的地位而称为主线（mainline）。

一旦发布新版本Linus树，就会立刻打开一个“合并窗口”（merge window），接受下一版本需要作出的改变。合并窗口将开启约两周时间。合并窗口关闭后，就会发布下一版本的候选版，即所谓的“rc内核”[2]。从rc内核发布后到下一版本发布的期间为测试期，这一期间基本只接受关于bugfix的修改。rc版内核每隔约一周时间会依次推出rc1、rc2……当Linus判断其质量已经达到可以发布的水平时，就会作为新版本发布。按照最近的实际情况来看，基本上在rc6～rc9左右就会发布新版本，也就是说Linux内核每隔2～3个月就会发布新版本。新版本发布后，又会打开下一版本的合并窗口，然后对rc版进行测试。Linux内核就是按照这样的周期来开发的。

小贴士：Linus树的内核由于完全没有任何华而不实的东西，因此称为“香草”（vanilla）内核或“库存”（stock）内核。

linux-next树

这是一个为发布将来的版本而积累新代码并进行测试的源码树，主要由Stephen Rothwell等人进行管理和运营。原则上要添加新功能或者进行安装配置时，首先要在linux-next树中进行测试，在确认各自之间可以兼容之后再添加到Linus树内。

stable树

这是一个主要只针对过去发布的内核版本进行bug修改，使其更加稳定的树，由Greg Kroah-Hartman、Chris Wright进行维护管理。这个树的版本号是在Linus树的版本号后面加一位数字，以2.6.x.y这样的4个数字来表示。针对某个Linus树版本的稳定（stable）版维护一般持续6个月左右，但也有持续更久的。

开发树

Linux内核可以说是各种功能的集合体。例如内存管理、文件系统、网络、各种设备驱动程序、CPU架构固有部分等。这些功能部分称为“子系统”，各子系统分别在不同的源码树中进行开发。在开发、修改过程中也有一些不属于特定子系统的内容，这些内容首先会被发送到Andrew Morton管理的mm树（准确地说是mmotm：mm on the moment，补丁包的缩写）。这样的源码树统称为“开发树”。

在各开发树中开发出的源代码在经过linux-next中的测试后再植入Linus树。

开发树的数量多如繁星。如果哪天你因为想要开发某个功能而在手边的源代码上进行了修改，这也可以说是一个“开发树”。

Linus树、开发树等作为所有树的根源，也称为“upstream”，即“上游”。但这是广义上的叫法，有时也仅指最上游的Linus树。

发布版内核

最后要介绍的是发布版内核（distribution kernel）。应该有很多人使用的都是作为Linux发布版的一部分发布的内核。这些来源于发布版的内核几乎都是在Linus树或stable树内核的基础上进行发布版特有的扩展和bug修改而得到的。像这样添加了发布版特有的修改，并作为发布版的一部分发布的内核，就称为“发布版内核”。

[1]Linux 2.6.39的下一版本将是Linux 3.0。

[2]rc是release candidate（发布候选）的缩写。

如何获取上游内核

在了解Linux内核的各种衍生版本后，我们首先尝试一下获取上游内核（upstream kernel）。Linus树、linux-next树，以及绝大部分的开发树都可以从http：//www.kernel.org/获取（见图1-1）。

Linux内核的开发都是在最新版上游内核的基础上进行的。其中最重要的就是作为所有树的根源的Linus树。下面介绍获取Linus树的两种方法。

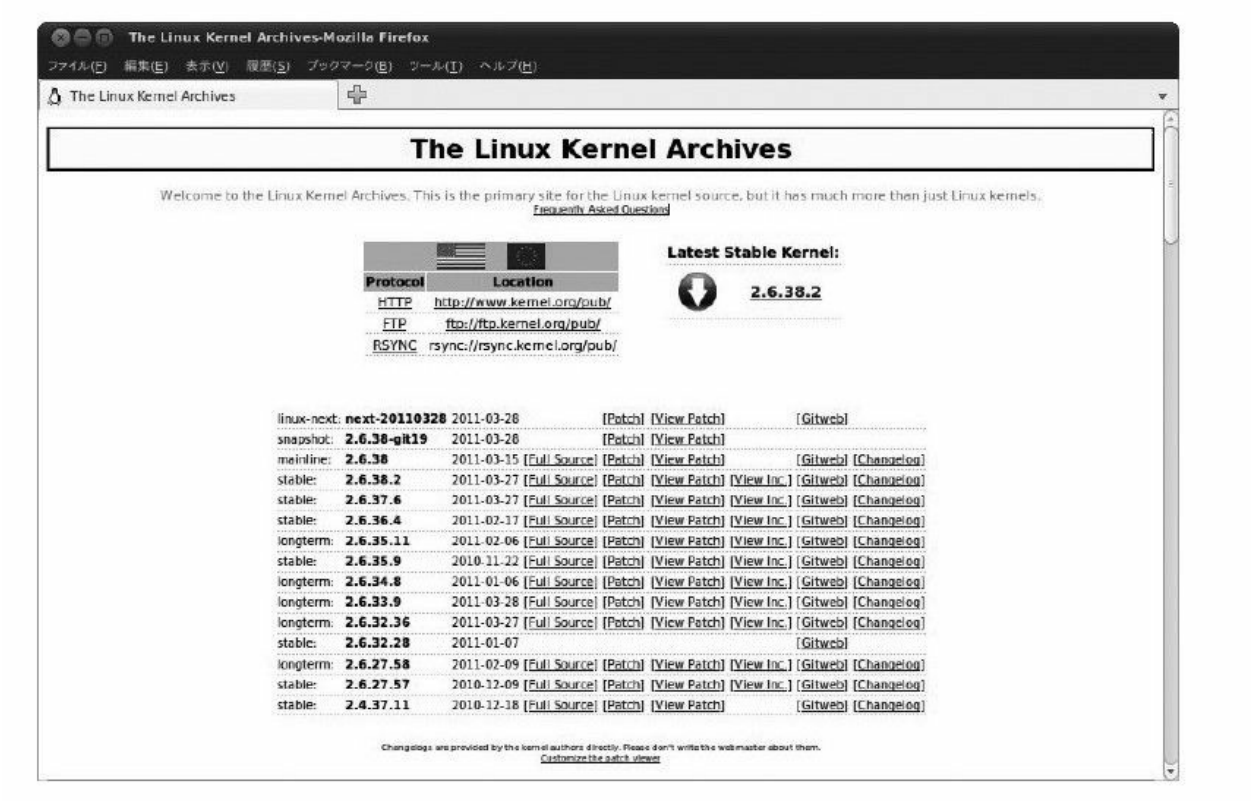

图　1-1　http：//www.kernel.org

下载tar文件

获取Linus树最简单的方法就是从kernel.org下载tar文件。2.6内核所有发布版本的tar文件都能够从http：//www.kernel.org/pub/linux/kernel/v2.6/获取。

这里有很多种类的文件。例如，表1-1所示的是与2.6.38对应的文件，可以从中随意选择一个下载。无论下载的是哪个，解压缩后或打补丁后的tar文件都是一样的。

表 1-1　Linux-2.6.38 的各种源文件

文　件　名	内　　容
linux-2.6.38.tar.bz2	完整的源码树。使用 tar+bzip2 压缩
linux-2.6.38.tar.gz	完整的源码树。使用 tar+gzip 压缩
patch-2.6.38.bz2	2.6.37 升级到 2.6.38 的补丁。使用 bzip2 压缩
patch-2.6.38.gz	2.6.37 升级到 2.6.38 的补丁。使用 gzip 压缩

除这些以外，还有一些文件名后缀为“.sign”的文件。这些文件都是用来确保各个文件兼容性的GnuPG签名。可以在验证下载是否正常时使用这些文件。

小贴士：使用GnuPG来检测兼容性时可以执行下列命令。

```
$gpg--keyserver wwwkeys.pgp.net--recv-keys 0x517DoFoE
$gpg-verify＜签名文件＞＜下载的文件＞
```

详细内容请参考http：//www.kernel.org/signature.html。

rc版或者更新更为频繁的快照tar文件存放在子目录下。主要的子目录如表1-2所示。

表 1-2　http://www.kernel.org/pub/linux/kernel/v2.6/ 的子目录

目　录　名	内　　容
next	rc 版升级到 linux-next 的补丁
testing	rc 版源码树的 tar 文件与补丁。目录下的文件仅针对下一发布版本。针对以前版本的文件存放在下一层的子目录下
snapshots	每天更新 1 ～ 2 次的快照文件补丁

使用Git

Linus树和开发树通过修复各种补丁而不断更新。在最新的树中进行开发是最基本的原则，因此为了保持最新，必须每天多次下载tar文件修复补丁。这项工作是非常花费精

力的，但是也不需要担心，因为可以用Git来解决。

Git是Linux内核所采用的SCM（Source Code Management system），具备分散开发所需的多个功能。Git命令更为详细的使用方法将在Hack#4中介绍，这里就先了解一下怎样使用Git命令来获取最新的Linus树。要在适当的目录下执行下列命令，但是在此之前必须注意的是，因为这条命令会将包括修改记录在内的所有仓库数据复制到本地磁盘中，所以必须要有1GB以上的磁盘容量。在操作时请注意磁盘和网络的容量。

```
$git clone git：//git.kernel.org/pub/scm/linux/kernel/git/torvalds/linux-2.6
```

命令执行完成后，应该就会生成一个标题为linux-2.6的目录。这就是包括修改记录在内的Linus树的最新、最完整的副本。

为了让手头的源码树时刻保持最新，需要在源码树的根目录（linux-2.6）下执行下列命令。

```
$git pull
```

如果没有对手头的源码树代码作出任何修改，该命令会使得手头的源码树与Linus树的最新状态保持一致。当使用git clone进行复制时，git命令会记住复制源目录的URL，因此执行git pull时不需要指定URL。

使用git命令还可以获取除Linus树以外的开发树的最新版本。在http：//git.kernel.org/上能看到放置在kernel.org下的其他开发树一览表。如果希望开发或者追踪各领域最新开发情况，也可以从这里找到开发树的URL。

如何获取发布版内核

在多数情况下，发布版内核的源代码都是按照各发布版所采用的方法进行打包的。因此要获取发布版内核的源代码，只需要下载源代码包，进行安装或解压缩就可以了。

下面选取具有代表性的发布版Fedora和Ubuntu为例，讲解如何获取这两种发布版内核源代码。这里选取的发布版的版本分别为Fedora 14和Ubuntu 10.10。

Fedora

在Fedora中，内核源码是作为源码RPM（SRPM）提供的。使用yum-units包里所带的yumdownloader下载SRPM。此后要使用的yum-builddep也是yum-units包中所带的，所以如果事先没有安装，首先请安装这个工具包。

可以执行下列命令来下载内核的SRPM。

```
$yumdownloader--source kernel
```

在笔者的环境下，下载的是kernel-2.6.35.11-83.fc14.src.rpm。

如前文所述，发布版内核都带有自身特有的补丁。SRPM是将vanilla内核的源代码和补丁分开放置的，补丁在创建过程中被分配给vanilla内核的源代码。所以要获取发布版内核的源代码，就要完全执行RPM的创建过程，但并不完全执行。虽然每个SRPM在创建RPM时都需要用到不同的源码包，但只要执行下列命令，就能够安装创建Linux内核所需的所有源码包。这条命令请在root权限下执行。

```
#yum-builddep kernel-2.6.35.11-83.fc14.src.rpm
```

安装SRPM需要执行下列命令。安装SRPM，就是指将所包含的文件解压缩。SRPM包含的文件将解压缩到在主目录下生成的rpmbuild的几个子目录下。

小贴士：生成rpmbuild目录的位置，是通过%_topdir这个rpm的宏变量来设置的。在以前的发布版中是在/usr/src/redhat下的生成，近来的版本是在/usr/lib/rpm/macros下创建：

```
%_topdir%{getenv：HOME}/rpmbuild
```

直接在用户目录下生成。

```
$rpm-i kernel-2.6.35.11-83.fc14.src.rpm
```

RPM包的创建是通过rpmbuild命令进行的。本次操作的目的是获取内核的源代码，所以为了让命令结束前能给源代码修复补丁，应在rpmbuild命令中加上-bp选项。命令中的参数会赋予一个用来创建源码包的设置文件，即SPEC文件。

```
$cd～/rpmbuild/SPEC
$rpmbuild-bp kernel.spec
```

这时就会生成一个标题为～/rpmbuild/BUILD/kernel-2.6.35.fc14/linux-2.6.35.x86_64的目录，在这个目录下会生成发布版内核的源代码。

使用源代码来创建内核二进制文件的方法，请参考Hack#2。

Ubuntu

在Ubuntu或基于Ubuntu的Debian下，内核源代码是作为deb包提供的。首先，与其他的源码包一样用apt-get来执行安装。标题为Linux-source的源码包就是最新的内核源码包的元包。

```
#apt-get install linux-source
```

在笔者的环境下，到这一步就完成了linux-source-2.6.35的安装。

在安装内核源代码的deb包后，会在/usr/src下生成tar文件，只要将这个文件复制到适当的目录下并解压缩，就能够获取内核源代码。

```
$cp/usr/src/linux-source-2.6.35.tar.bz2～
$cd
$tar xjf linux-source-2.6.35.tar.bz2
```

关于创建内核二进制码的方法，同样请参考Hack#2。

小结

本节介绍了在上游内核与发布版内核这两种情形下获取内核源代码的方法。首先要获取源代码，然后才能够读取源代码、修改bug以及开发新功能。Linux内核中有很多信息是必须读取源代码后才能理解的。通过读取源代码，能够从真正意义上理解一直以来“以为理解”的内容。因此一定要努力学习源代码。

参考文献

·内核文档Documentation/development-process/*

Linux内核版本3.0

2011年5月，Linus Torvalds宣布，Linux内核版本由2.6升级到3.0。据Linus Torvalds称，2.6系列由于经过39次发布后，更新号（第三个数字）过大，因此本次版本升级最大的目的就是进行一次改头换面。由2.6.39到3.0的版本升级与2.6系列内的版本升级并没有什么不同，也是由2.6系列延续下来的。目前预计在版本3系列中，将第二个数字作为Linus树的更新号，第三个数字作为stable树的更新号使用。也就是说，Linus树3.0的下一个发布版本将是3.1，基于版本3.0的stable树内核将是3.0.1、3.0.2。Linus树内核的tar文件在版本3系列中放在以下位置：

http://www. kernel.org/pub/linux/kernel/v3.0/

Git仓库也同样可以通过前面提到的URL（git：//git.kernel.org/pub/scm/linux/kernel/git/torvalds/linux-2.6）来获取。

—Munehiro IKEDA

HACK#2　如何编译Linux内核

本节介绍编译Linux内核的方法。

当发现bug而修改源代码或者添加新功能时，就需要对内核进行重新编译，生成二进制映像文件。另外，如果想要使用发布版内核中无效的功能或者驱动程序时，或者相反地，想要删除不需要的功能从而使内核更精简、更快时，或者想使用最新版的上游内核时，也需要对内核进行编译。

下面主要介绍对上游内核进行设置、编译以及安装的方法。当使用发布版内核的源码包管理系统来管理内核映像文件时，需要将内核映像文件打包。接下来以两个具有代表性的发布版Fedora和Ubuntu为例来讲解具体的方法。最后将简单地介绍在源码树外对驱动程序等进行编译的方法，以及在不同平台的编译环境编译内核的方法，即所谓的交叉编译。

内核编译的过程

对内核进行编译的步骤如下：

1.获取源代码，如有需要则进行修改。

2.设置。

3.编译。

4.根据发布版生成相应的源码包。

5.安装内核映像和模块。

使用上游内核安装内核映像时，若不使用发布版的源码包管理系统，则不需要进行步骤4。想要使用源码包管理系统来安装时，可以使用各发布版的源码包创建系统。在这种

情况下步骤3和步骤4的操作是合并进行的。

下面首先讲解不使用源码包管理系统来生成、安装内核映像文件的情形。然后介绍将内核映像文件打包和安装的方法。

需要的源码包

对内核进行设置和编译时可以使用各种工具。如果没有明确指示，就不会安装表1-3和表1-4所示的源码包，但是它们是必不可少的。这些需要事先安装好。

表 1-3　必要的源码包一览表（Fedora 14）

源 码 包 名	备　　注
ncurses-devel	基于控制台（文字界面）设置时需要
qt-devel	基于窗口（图形界面）设置时需要
qt3-devel	基于窗口（图形界面）设置时需要
gcc-c++	基于窗口（图形界面）设置时需要
rpm-build	生成 rpm 包时需要

表 1-4　必要的源码包一览表（Ubuntu 10.10）

源 码 包 名	备　　注
libncurses5-dev	基于控制台（文字界面）设置时需要
qt3-dev-tools	基于窗口（图形界面）设置时需要
g++	基于窗口（图形界面）设置时需要
kernel-package	生成 deb 包时需要
fakeroot	生成 deb 包时需要
dpkg-dev	生成 deb 包时需要

编译、安装上游内核

获取源代码

关于获取内核源代码的方法，请参考Hack#1。

这里以源代码在～/linux-2.6下的情况为例。

进行设置

Linux内核自身的源代码树中就具备进行编译设置的结构，不仅可以设置编译或不编译某个功能，在进行编译时，还能非常细致地设置是将功能静态添加到Linux内核的二进制码中，还是作为模块进行编译。虽然能够进行细致的设置，但同时也造成设置项目数量过多。因此源代码树中还带有帮助进行设置的工具。这个工具包称为kconfig，应先启动这个工具再进行设置。

小贴士：2.6.38中的设置项目数量超过12 000个。

设置工具虽然准备了基于控制台（文字界面）和基于窗口（图形界面）的两种类型，但其实用户要执行的操作不管用哪一个界面都没有太大的区别。这里主要以基于控制台的工具为例展开介绍，基于窗口的工具仅在后面简单介绍。

要启动基于控制台的设置工具，需在源码树的根下执行下列命令。

```
$make menuconfg
```

之后控制台就会显示如图1-2所示的项目。设置是按层次进行的，现在看到的是最上面一层。

在这里，先不执行任何操作，按一下【TAB】键，选择Exit后，再按下【Enter】键。就会出现询问“是否保存新设置”的选项，然后选择Yes按钮关闭设置工具。

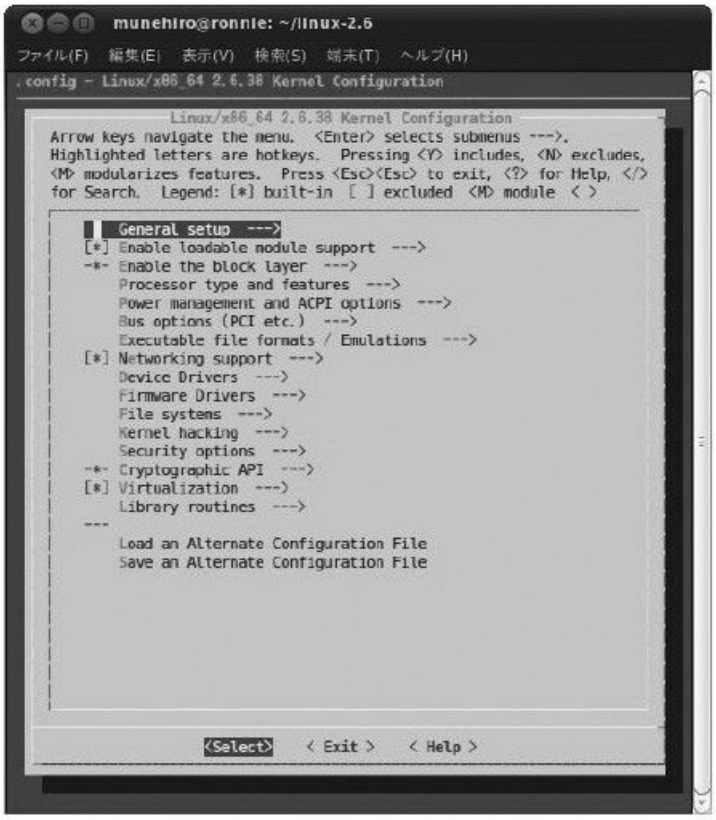

图　1-2　make menuconfig生成的设置画面

编译设置保存在源码树的根下标题为.config的文件里。因为这次是在.config文件不存在的状态下启动的设置工具，所以会生成一个默认设置内容的.config文件。

.config的内容如下所示（细节部分会因为执行环境的不同而有所差异）。

```
#
#Automatically generated make config：don't edit
#Linux/x86_64 2.6.38 Kernel Configuration
#Sun Mar 27 03：17：57 2011
#
CONFIG_64BIT=y
#CONFIG_X86_32 is not set
CONFIG_X86_64=y
CONFIG_X86=y
……
```

以#开头的行是注释行。

CONFIG_*是设置项目。这些设置项目与Linux内核的各功能相对应，编译时受这个

值的控制。设置项目取表1-5所示三个值中的一个。

表 1-5　设置项目（CONFIG_*）所取的值

值	说　明
=y	该项目所对应的功能将静态添加到内核中
=m	该项目所对应的功能将编译为模块。当内核在执行时，模块会在需要时加载并添加到内核中。有一些功能无法作为模块进行编译。在这种情况下对应的设置项目不取该值
# CONFIG_* is not set	该项目所对应的功能不编译。这些项目的行全部被注释掉

注意事项：.config文件不能手动编辑。有时某个功能会依赖于其他功能。在这种情况下，如果设置不能正确反映依赖关系，就会出现编译错误或者最终变成无法执行的内核。kconfig可以掌控依赖关系，并保证设置的兼容性。

小贴士：在没有.config文件的情况下启动并执行make menuconfig命令后生成的.config文件，是根据kconfig的设置文件—Kconfig*中的默认值生成的。

另外，在源码树中分别为每个架构准备了默认的.config文件。不按照Kconfig的默认设置，而是想根据各架构的默认设置生成.config文件时，需执行下列命令。

```
$make defconfg
```

各架构的默认.config文件位于以下路径。

```
arch/＜arch＞/configs/*_defconfig
```

现在就可以尝试进行设置了。再次执行make menuconfig命令打开设置菜单。设置菜单中经常使用到的按键如表1-6所示，以供参考。

表 1-6　设置菜单的按键一览

按　键	操　作
↑	将选择项目的光标向上移动
↓	将选择项目的光标向下移动
<TAB>、←、→	切换操作菜单（Select/Exit/Help）

（续）

按　键	操　作
<Enter>	按照所选择的操作菜单进行操作
Y	将项目设为 <*>（有效：静态添加）
N	将项目设为 <>（无效）
M	将项目设为 <M>（有效：作为模块进行编译）
<SPACE>	将项目在 <M>/<*>/<> 间切换
<ESC><ESC>	回到上一层（与操作菜单的 <Exit> 相同）
?	显示关于所选项目的帮助（与操作菜单的 <Help> 相同）
/	搜索设置项目。根据设置项目的符号名来搜索在菜单上的位置时十分方便

这里以软盘驱动器为例，尝试启用它。这个设置项目在2.6.38中定义为CONFIG_BLK_DEV_FD，位于菜单层的如下位置。

```
Device Drivers--->
Block devices--->
Normal floppy disk support
```

图1-3所示就是在菜单上选择这个项目的界面。

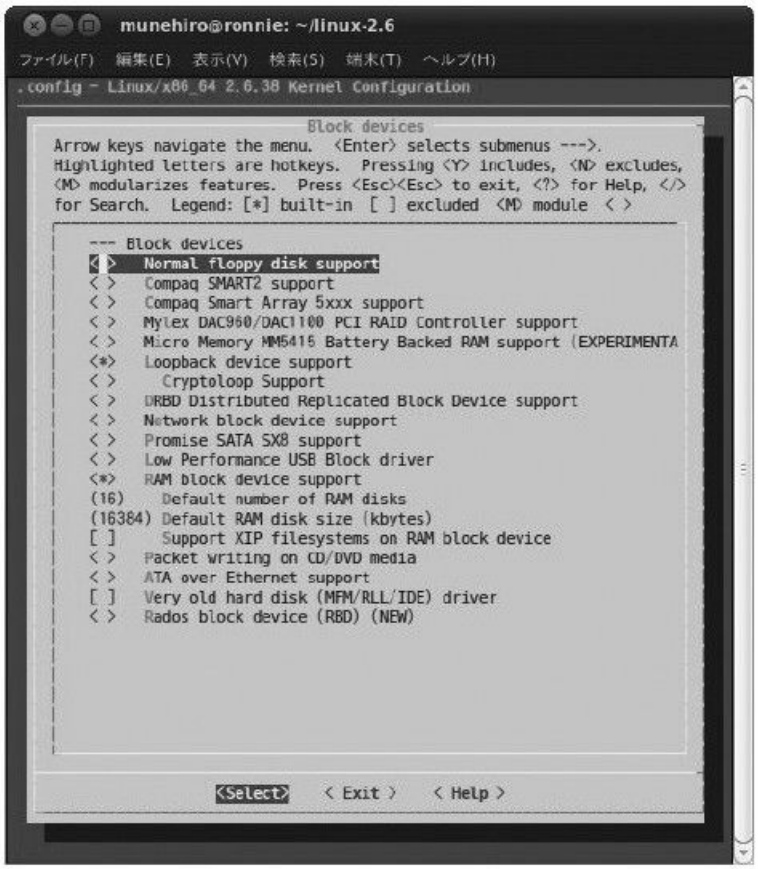

图　1-3　Normal floppy disk支持的设置

这时按【y】键，左侧的选择显示就会变成＜*＞。这就表示该项目已编译并静态添加到内核中。按【m】键，显示则变成＜M＞。这时，该项目将作为模块编译。当使用该功能时，模块会根据需要动态添加到内核中。如果按【n】键，则会变成＜＞，该功能不编译。

内核的编译设置就是这样指定一个个的项目来进行的。

此外，还有一些项目需要设置数值和字符串。例如，在当前打开的界面中，“Default number of RAM disks”等就是这种项目。选择这样的项目后按回车键，就会出现对话框，可以在其中输入数值或字符串。

大致完成自己想要的设置后，可以在菜单最上层的画面上选择操作菜单的＜Exit＞，

或者连按两次【Esc】键完成设置，在出现的“是否保存新设置？”对话框中选择Yes按钮，将设置保存到.config文件中。

到这里，内核的编译设置就完成了。

小贴士：经常有人因为手头有在旧版本中生成的.config文件，而想要在此基础上进行一些修改，以编译新的内核。在这种情况下，可以将原来的.config文件复制到源码树的根下，然后执行下列命令。

```
$make oldconfg
```

执行该命令后，就会出现一个个的对话框，询问新增加的设定项目要如何设置。如果版本之间的差别较大，就需要回答较多的项目设置问题，所以可以先针对所有的询问都按回车键，以便使用默认设置，然后再用make menuconfig等进行设置。

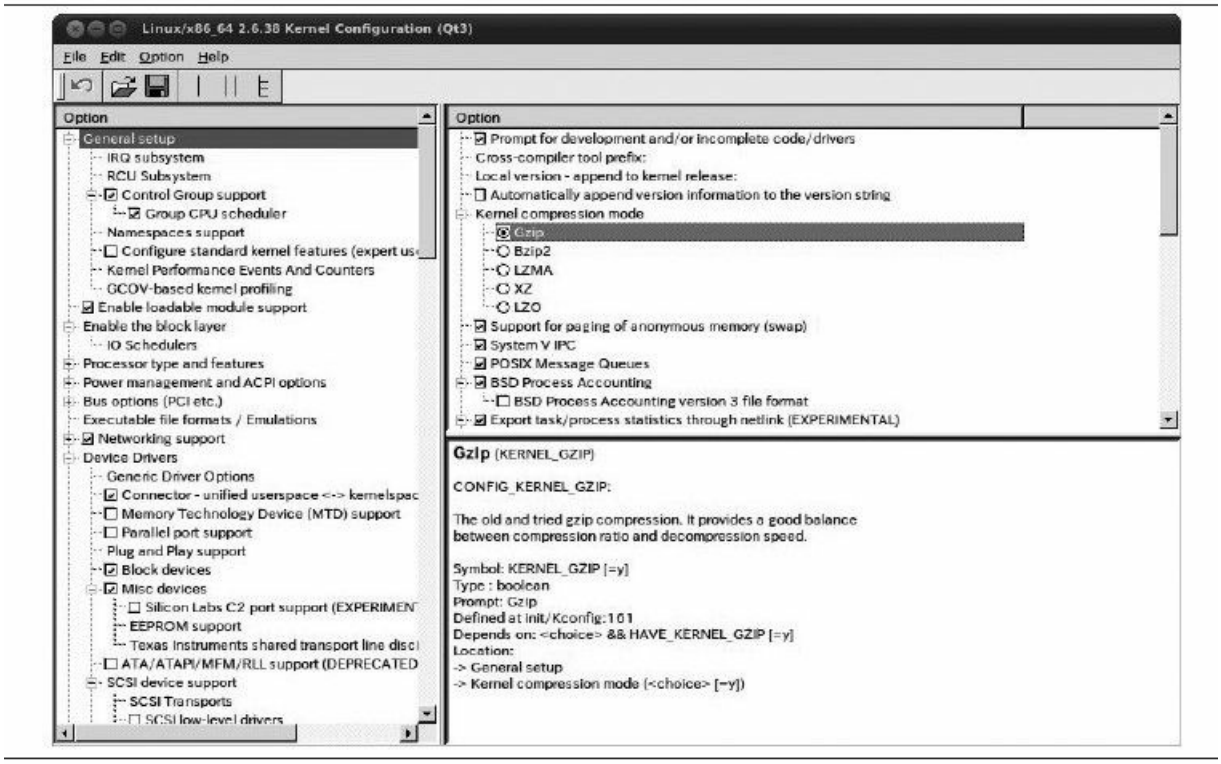

图　1-4　make xconfig生成的设置界面

基于窗口（图形界面）的设置工具通过下列命令来启动。

```
$make xconfg
```

启动后就会打开如图1-4所示的窗口，就在这里进行设置。

如果掌握了基于控制台的设置工具，那么基于窗口的工具也就很容易掌握了。可以根据个人喜好来选择使用哪一个。

进行编译

要对已完成设置的上游内核进行编译，需在源码树的根目录下执行下列命令。

```
$make
```

编译需要花费的时间与机器的性能和设置有较大的关系，快的时候只需要几分钟，有时也可能需要花费几个小时。请耐心等待。

如何节约编译时间

下面列出了几个缩短编译时间的小提示。

在内核的设置上下工夫

编译的代码越少，编译就能越快完成。一般为了使发布版内核在多样的环境中能够顺利运行，都会带有多个驱动程序。将其中在自己的环境中不需要的驱动程序设置为无效，仅将必要的作为编译对象，就能大幅缩短编译时间。关于设置的技巧请参考Hack#6。

使用Make的-j选项

-j选项是用来指定make的并发性的选项。并发性是用数值来指定的，例如“-j 4”。当机器为多处理器时，可以按照处理器的数量来指定数值，这样就有可能实现快速编译。

购买高性能的机器

速度是永远的追求。

将内核安装到系统中

编译完成后，就可以将生成的内核安装到系统中。安装时必须有root权限。

安装分为两个阶段进行。第一阶段是模块的安装。在编译完成的源码树的根目录下执行下列命令。

```
#make modules_install
```

这时，编译后的模块就安装到/lib/modules下。

第二阶段是安装内核二进制映像文件，生成并安装boot初始化文件系统映像文件。同样也是在源码树的根目录下执行下列命令。

```
#make install
```

这时，内核映像文件就安装到/boot下。如果使用的是Fedora系列的发布版，就会同时生成boot初始化文件系统映像，并同样安装到/boot下。而Ubuntu等Debian系列的发布版则需要执行下列命令，另行生成和安装boot初始化文件系统映像。在＜内核版本＞的部分请输入表示当前生成的内核版本的文字。

```
#update-initramfs-c-k＜内核版本＞
```

表1-7所示为通过安装生成的文件以及目录的一览表。在＜内核版本＞的部分中同样输入表示当前生成的内核版本的文字。

表 1-7　通过安装内核而生成的文件和目录

文件名或目录名	内　　容
/lib/modules/<内核版本>	安装模块的目录
/boot/vmlinuz-<内核版本>	内核映像文件
/boot/initramfs-<内核版本>或 /boot/initrd.img-<内核版本>	boot 初始化文件系统映像
/boot/Systemmap-<内核版本>	地址信息文件

在一些系统设置下可能需要手动进行GRUB设置才能从当前安装的内核启动。在这种情况下，请适当地编辑/boot/grub/menu.lst或者执行update-grub命令。

到这里内核的安装就完成了。这时请重启机器，确认新的内核是否能够正常运行。

注意事项：在确认新内核能够正常运行之前，绝对不要删除现在所使用的内核以及相应的GRUB的记录。新内核经常会出现无法启动的情况。这时如果没有启动的内核，系统就无法进行操作。

小贴士：内核二进制映像的文件名和模块目录名是根据内核的版本来命名的。因此，当对已安装版本的内核进行再次编译并安装时，原来安装的内核以及模块会被覆盖。

为了防止这种情况的发生，可以在设置项目CONFIG_LOCALVERSION中设置文字。在这个设置项目中指定的文字会作为内核版本的一部分，因此可以防止被覆盖。

其他的make对象或变量

在进行内核的设置或编译时，有一些可用的make目标，如表1-8所示。

表 1-8　其他的 make 对象

对　　象	说　　明
clean	将源码树恢复到编译前的状态。obj 文件等被删除，.config 或编译过程中自动生成的部分文件不会被删除

（续）

对　象	说　明
mrproper	将源码树完全恢复到发布时的状态。发布时源码树中不存在的文件全部被删除，包括 .config 文件
help	显示可以使用的 make 对象
tags	生成标签文件。有了标签文件，就能使用 Emacs 等编辑器的 tag jump 功能跳到函数定义处，可以高效进行源码浏览
cscope	生成用于 cscope 的索引文件。cscope 是基于控制台（文字界面）的源码浏览器
allyesconfig	生成将所有设置项目设置为有效并静态添加到内核中的 .config 文件
allnoconfig	生成将允许范围内的设置项目设置为无效的 .config 文件
allmodconfig	生成将所有能设置为模块的项目设置为有效并设置为模块的 .config 文件
<dir>/<file>.o	仅进行生成指定的目标文件所必需的编译。当仅指定 <dir> 时，由 .config 文件生成该目录内所有目标文件
<dir>/<file>.ko	仅生成指定的模块

表1-9展示了为控制make的输出而设置的make变量。这些变量需在对象前指定，如：

```
$make V=1 clean
```

表 1-9　控制 make 输出的变量

变　量	说　明
V=0|1|2	设置编译时控制台显示的详细程度。默认为仅显示概要，设置为 0。当设置为 1 时，显示更加详细的信息。当设置为 2 时，除了概要以外，还会显示要进行编译的原因（原因大多数都是“由于没有对象”）
O=<dir>	将编译最终生成的文件全部输出到 <dir>。在源码树禁止写入等情况下非常实用

卸载内核

按照前面介绍的安装方法安装的内核不在发布版源码包管理系统的管理范围内。因此

不能用rpm或dpkg这样的命令来卸载。

但是也不需要担心，内核的文件配置如表1-5所示，相对来说比较简单。想要卸载时，只需要删除这些文件就可以了。

注意事项：卸载内核时请慎重考虑。另外，请一定要做好更改GRUB设置等工作。

生成内核包

Fedora

Fedora的源码包管理系统是RPM。要将内核纳入RPM的管理范围内，就需要生成RPM源码包。

其实Linux内核在创建时就具备生成RPM源码包的功能。编译时需要将rpm-pkg作为对象执行make命令。

```
$make rpm-pkg
```

通过这条命令，编译内核后就会创建源码包（SRPM）和二进制码包（RPM），二进制码包存放在～/rpmbuild/rpms下，源码包存放在～/rpmbuild/SRPMS下。

如果拥有将SRPM解压缩后的发布版内核的源码，则使用rpmbuild创建源码包。如果内核的SRPM是解压缩到～/rpmbuild下的，则执行下列命令创建源码包。

```
$rpmbuild-ba～/rpmbuild/SPECS/kernel.spec
```

所创建的源码包存放的目录与上面相同。这些源码包和普通源码包一样，可以使用rpm命令来安装、卸载。

小贴士：在上游内核中创建源码包时也是用make来调出rpmbuild的。

Ubuntu

Ubuntu的源码包管理系统是dpkg。源码包为deb格式。

上游内核的创建与RPM同样，也能生成deb源码包。这一make操作的对象为deb-pkg。通过执行下列make命令，就能够创建deb源码包。

```
$make deb-pkg
```

所创建的源码包存放在源码树的根目录下。会生成数个源码包，其中包含内核映像和模块的是linux-image-＜内核版本＞.deb文件。这些源码包的操作和普通的deb源码包文件一样，可以用dpkg来进行。

此外，Ubuntu还在kernel-package包里收录了用来协助内核包创建的工具—make-kpkg命令。这个工具可以通过命令选项对创建操作进行设置，根据需要也可以使用这个工具。这里就不介绍详细的使用方法了。

在源码树外编译模块

有时可能想要对还未导入上游内核的驱动程序等与内核源码树分开提供的源代码进行编译，并将其作为模块安装。

在这种情况下，只要驱动程序源代码的Makefile编写正确，就可以按照下列方法进行编译、安装。

```
$make-C/lib/modules/$（uname-r）/build M=$PWD
#make-C/lib/modules/$（uname-r）/build M=$PWD modules_install
```

当为make指定-C选项时，make首先会读取指定目录下的Makefile。这里指定为-C选项的变量，是指向当前正在运行的内核源目录的符号链接。也就是说，这个驱动程序与当前运行的内核是在完全相同的环境下创建，具体来说，就是使用头文件或.config文件来创建的。

指定M=$PWD是为了告知Linux内核的创建操作正在源码树外执行创建操作。

交叉编译内核

交叉编译是指针对与正在执行编译的平台不同的其他平台生成二进制数据。例如，在x86_64环境下生成针对ARM的二进制数据的情形。这种编译器又称为“交叉编译器”。只要拥有交叉编译器，对Linux内核进行交叉编译就变得非常简单。这时还需要为make赋予两个变量，如表1-10所示。

表 1-10　交叉编译所需的变量

变　量	说　明
ARCH	对象架构
CROSS_COMPILE	指定交叉编译器的前缀

举一个使用交叉编译器armv5tel-linux-gcc来交叉编译ARM内核的例子。在这种情况下，make命令变成如下所示的内容。

ARM内核的二进制映像较多使用的是uImage格式。第一行创建这个格式的二进制映像，第二行创建模块。

```
$make ARCH=arm CROSS_COMPILE=armv5tel-linux-uImage
$make ARCH=arm CROSS_COMPILE=armv5tel-linux-modules
```

创建的内核二进制映像作为源码树内的arch/arm/boot/uImage文件。

创建的内核和模块必须转移到对象机器上。如果在对象机器上可以使用源码包管理系统，则最简单的方法就是生成源码包并在对象机器上安装。然而，如果不能使用源码包管理系统，虽然内核映像转移起来很简单，但是模块就有一些问题。模块分散在源码树的各个目录下，想要手动查找这些模块并在/lib/modules下构建目录树，是不太现实的。

其实，通过modules_install安装模块的位置可以用变量INSTALL_MOD_PATH来指定。可以利用这一点，例如，当安装在主目录下时，可以用tar对每个目录进行整合，再

转移到对象机器上。这一操作可以用下列命令来实现。

```
$make ARCH=arm CROSS_COMPILE=armv5tel-linux-INSTALL_MOD_PATH=～/armroot-2.6.38 modules_install
```

这样就会在主目录下生成一个标题为～/armroot-2.6.38/lib/modules的目录，模块就安装在这个目录下。

模块的目录下有标题为build和source的符号链接，这些都是指向编译过内核的源码树。如果在对象机器上完全不进行编译，就不需要进行修改，如有必要可以在对象机器上适当修改。

小结

本节主要以上游内核为中心，讲解了对内核进行编译设置、编译、安装的方法。一方面，内核是系统的根源，如果设置或者安装错误，系统就有可能陷入无法启动的危险中。另一方面，由于基本不依赖于其他的软件，并且可以安装多个内核，因此笔者认为可以比较放心地尝试修改或改造。

为了保证系统的流畅性，也为了尽快使用最新的内核，不仅内核开发人员，而且Linux系统的普通用户也非常需要掌握内核的编译、安装方法。你也可以挑战一下。

参考文献

·Documentation/kbuild/*（内核源文档）

—Munehiro IKEDA

HACK#3　如何编写内核模块

本节将介绍向Linux内核中动态添加功能的结构—内核模块的编写方法。

内核模块

Linux内核是单内核（monolithic kernel），也就是所有的内核功能都集成在一个内核空间内。但是内核具有模块功能，可以将磁盘驱动程序、文件系统等独立的内核功能制作成模块，并动态添加到内核空间或者删除。

内核模块是可以动态添加到Linux内核空间的二进制文件，文件扩展名为ko。

内核模块的编写方法大致有两种。一种是将内核源码树带有的功能编写为模块的方法（参考Hack#2），另一种是将内核源码树中所没有的特有功能编写为模块的方法。

通过内核配置编写模块

把内核源代码文件中CONFIG_*=m的项目所对应的驱动程序编写为模块。编写生成的模块一般安装在/lib/modules/内核版本/kernel下。

以RHEL6为例

```
#ls/lib/modules/2.6.32-71.29.1.el6.x86_64/kernel/
arch crypto drivers fs kernel lib mm net sound
```

编写特有的内核模块

下面将介绍如何编写内核源码树中所没有的特有内核模块。

以mymod模块为例说明，请将下面的代码以mymod.c为文件名保存。

```
#include＜linux/module.h＞
#include＜linux/timer.h＞
#include＜linux/errno.h＞
static int sec=5；
module_param（sec, int, S_IRUGO|S_IWUSR）；
MODULE_PARM_DESC（sec，"Set the interval."）；
static void mymod_timer（unsigned long data）；
static DEFINE_TIMER（timer, mymod_timer，0，0）；
static void mymod_timer（unsigned long data）
{
printk（KERN_INFO"mymod：timer\n"）；
mod_timer（＆timer, jiffies+sec*HZ）；
}
static int mymod_init（void）
{
printk（KERN_INFO"mymod：init\n"）；
if（sec＜=0）{
printk（KERN_INFO"Invalid interval sec=%d\n"，sec）；
return-EINVAL；
}
mod_timer（＆timer, jiffies+sec*HZ）；
return 0；
}
static void mymod_exit（void）
{
del_timer（＆timer）；
printk（KERN_INFO"mymod：exit\n"）；
}
module_init（mymod_init）；
module_exit（mymod_exit）；
MODULE_AUTHOR（"Hiroshi Shimamoto"）；
MODULE_LICENSE（"GPL"）；
MODULE_DESCRIPTION（"My module"）；
```

在模块的源代码中包含（include）头文件linux/module.h。

名为module_int（）和module_exit（）的宏，可以调用回调（callback）函数来进行初始化和终止模块的处理。在模块的源文件中进行如下描述，就可以在添加模块时调用初始化函数，在删除模块时调用终止函数。

```
module_init（初始化函数名）；
module_exit（终止函数名）；
```

在这个例子模块的情形下调用的分别是mymod_init（）和mymod_exit（）。

初始化函数为了表示初始化已正常完成，需要返回0。按照Linux内核中的写法，发生错误（error）时将返回一个值为负数的错误代码。在这个例子中，如果设定值出错，则处理为-EINVAL（非法值）。

下面先用 3 个宏对模块进行定义，但在模块编写中并不是必需的。

MODULE_AUTHOR()	表示模块的作者
MODULE_LICENSE()	表示模块的许可证
MODULE_DESCRIPTION()	模块的说明

这个例子模块还用到了模块参数。模块参数可以使用module_param（）宏来生成。

```
module_param（参数名，参数类型，权限（permission））；
```

在例子模块中，sec定义为int类型的模块参数。

另外，还可以使用MODULE_PARM_DESC（）宏来对模块参数进行说明。

先简单介绍一下这个例子的运行过程。当添加模块时，会调用指定为初始化函数的mymod_init（）。在mymod_init（）中首先通过printk（）输出：

```
mymod：init
```

然后确认模块参数sec是否正常。在模块参数sec的值为0以下的异常情形时，会返回EINVAL错误代码并终止程序。在判断模块参数sec正常后，将内核计时器设置为sec秒后启动超时（timeout）函数mymod_timer（）。在每隔sec秒启动的mymod_timer（）中，首先使用printk（）输出：

```
mymod：timer
```

再次设置sec秒的内核计时器，然后终止。当删除模块时，会调用mymod_exit（）函数，删除内核计时器，通过printk（）输出：

```
mymod：exit
```

于是模块终止。

接下来需要准备编写模块所需的Makefile。由于是使用内核的创建框架来生成，因此Makefile的内容非常简单。

```
obj-m：=mymod.o
```

最后执行下列make命令，通过当前目录（current directory）的源代码和Makefile生成模块mymod.ko。

#make-C/lib/modules/'uname-r'/build M='pwd'

通过使用modinfo命令，可以看到所生成模块mymod.ko的信息。从这里可以看到使用MODULE_*宏所指定的内容。

```
#modinfo mymod.ko
filename：mymod.ko
description：My module
license：GPL
author：Hiroshi Shimamoto
srcversion：61A3BB7CFC0C89B8344F5A5
depends：
vermagic：2.6.32-71.29.1.el6.x86_64 SMP mod_unload modversions
parm：sec：Set the interval.（int）
```

添加内核模块

添加内核模块需要用到insmod命令或modprobe命令。

通过执行insmod命令把生成的mymod.ko模块添加进来。

```
#insmod mymod.ko
```

使用dmesg命令，可以看到例子模块mymod.ko的输出内容。

```
#dmesg|tail
:
mymod：init
```

作为模块初始化函数mymod_init（）所调用的printk（）的输出内容会在最后一行显示。使用lsmod可以显示目前添加到内核中的模块列表。

```
#lsmod
Module Size Used by
mymod 1482 0
:
```

可以看到，mymod行存在，模块已添加。

要将已添加的模块从内核空间删除时，可以使用rmmod命令。

```
#rmmod mymod
```

执行rmmod命令后，模块将从内核空间内删除，使用lsmod命令就不会再输出mymod行。

此外，使用dmesg命令还可以看到终止模块的处理中printk（）输出的信息mymod：exit。

```
#dmesg|tail
：
mymod：exit
```

下面针对模块参数作一些介绍。在添加模块后，就会在/sys/module下生成对应的目录和文件。

```
#ls/sys/module/mymod/
holders initstate notes parameters refcnt sections srcversion
```

可以确认在parameters下生成的模块mymod中所定义的参数sec。

```
#ls-l/sys/module/mymod/parameters/sec
-rw-r--r--.1 root root 4096 May 15 06：34/sys/module/mymod/parameters/sec
```

其内容应当是初始值5。

```
#cat/sys/module/mymod/parameters/sec
5
```

模块参数可以在使用insmod添加模块时对值进行指定。

```
#insmod mymod.ko sec=10
```

进行上述操作后，添加mymod.ko时模块参数sec就为10，默认间隔5秒的超时变成间隔10秒。

小结

本节介绍了内核模块的编写方法。编写特有内核模块是Kernel构建的入门级操作，你也可以尝试一下。

参考文献

·Documentation/kbuild/modules. txt

—Hiroshi Shimamoto

HACK#4　如何使用Git

本节介绍Git的使用方法。

Git是Linux内核等众多OSS（Open Source Software，开源软件）开发中所使用的SCM（Source Code Management，源码管理）系统。在2005年以前，在Linux内核开发中一直使用一个叫做BitKeeper的SCM。但是由于后来BitKeeper的许可证被更改，可能会对开发造成障碍，因此Linux不得不改用新的SCM进行开发。在这种情况下，Linux内核的创始人Linus Torvalds就开发了Git，将Linus树的仓库转移到了Git中。直到2011年的今天，Linus树仍然使用Git进行管理，其他大部分的开发树使用的也是Git。目前Git由维护人员滨野纯（Junio C Hamano）等人持续进行开发。

Git的设计使其能够支持Linux或者OSS的开发模式。Git具有这些特征：分布式仓库；与互联网具有亲和性；版本更新记录管理不以单个文件为对象，而是将整个源码树作为一个对象；处理速度快等。

Git具有非常多的功能，如果一一进行说明的话能写成一本书。这里主要针对第一次使用Git的读者，通过使用指南的形式介绍日常使用较多的基本功能，同时对相关基本概念进行解说。

笔者使用的是1.7.1版本的Git。

分布式仓库型SCM

仓库是指保存SCM中源代码等信息及历史记录的原始数据的地方。CVS是以往使用较多的SCM，而在CVS中一直是将源代码从仓库签出（checkout）到本地工作区，进行修改后将代码提交到仓库中。像这样，仓库和工作区明确分开，多个开发者针对单一仓库进行提交的SCM称为“单一式仓库型”。

而Git采用的是与之相反的“分布式仓库型”结构。在Git中，工作区本身就是仓库。也就是说，开发者拥有各自的仓库，它们之间不存在结构层面的上下关系，所有仓库都是并行存在的。在Linux内核中一般认为linus树的仓库是“中央”仓库，其实这只是大家一致认可的叫法，从Git的结构上看，完全没有任何设置是以linus树作为中央的。

如上所述，Git直到完结时都是将本地磁盘的工作区作为仓库的。要能够熟练使用Git，首先必须掌握如何在本地仓库进行操作。下面将首先讲述在本地仓库进行操作的流程，然后介绍与其他仓库进行协作的方法。

在本地仓库进行操作

创建新的仓库

使用Git管理源代码的第一步是创建新的仓库。创建仓库需要创建普通的目录，并将该目录作为Git的仓库使用。操作过程如下。

```
$mkdir-p～/hello
$cd～/hello
$git init
```

这时，～/hello就可以作为Git的仓库使用了。下面就使用这个仓库来了解一下Git的基本功能。

小贴士：Git的命令以git＜command＞的形式启动。每条命令都有man page（帮助页面），当想要阅读帮助页面时，请用连字符将man git-＜command＞和子命令连接起来。

例如，当想要阅读init子命令的帮助页面时，应写为：

```
$man git-init
```

如果写成：

```
$man git init
```

显示出来的就是git（1）和init（8）的页面。

Git设置

在进行实际的文件操作前，首先要进行最低限度的必要设置。笔者一般进行的最低设置是提交者（committer）的姓名与邮件地址。在仓库目录下可以执行下列操作来进行这些设置。在这里设置的是笔者的信息。

```
$git confg--add user.email"m_ikeda@hogeraccho.com"
$git confg--add user.name"Munehiro\"Muuhh\"Ikeda"
```

把这个设置写入仓库目录的.git/config文件中。执行上面的git config命令后，这个文件中就应当写入了下列信息。

```
[user]
email=m_ikeda@hogeraccho.com
name=Munehiro\"Muuhh\"Ikeda
```

除此以外，还可以进行很多种设置，这里就先点到为止。

小贴士：写入.git/config的设置项目仅能适用于该仓库。

如果为git config指定--global选项，还可以参照要在用户已启动的所有仓库上共同使用的设置。与之对应的设置文件为～/.gitconfig。

当想要参照或添加整个系统的共同设置时，可以使用--system选项。与之对应的设置文件是/etc/gitconfig。

将文件添加到仓库中

现在，尝试创建文件并将其添加到Git的仓库中。首先，创建一个hello.c文件，其内容如下。

```
/*hello.c*/
#include＜stdio.h＞
int main（void）
{
printf（"Herro world！\n"）；
return 0；
}
```

在Git中向仓库增加或修改文件的过程称为“提交”。提交分为两阶段进行，首先指定要提交的对象文件，然后进行实际的提交。

```
$git add hello.c
```

```
$git commit
```

执行git commit后，会启动一个用来输入提交信息的编辑器。由于这是第一次提交，因此在第一行中输入Initial commit，并保存文件。

小贴士：这里为git add明确指定了文件名hello.c，如果有多个文件，可以使用：

```
$git add
```

将当前目录下的所有文件作为提交对象。

小贴士：在编辑提交信息时，如果没有保存文件就关闭了编辑器，就不会提交文件。

这样，hello.c就提交到了仓库中，以后就可以使用Git来管理和修改记录等。

修改并提交文件

仔细看一看刚才提交的文件，突然发现Hello居然写成了Herro了！下面就学习如何进行修改。

将hello.c的printf（"Herro world！\n"）；行修改成printf（"Hello world！\n"）；保存后提交。对文件进行修改时，也像新增加时一样需要对文件执行git add命令，将其作为提交对象。但是，当对多个文件进行修改时，一般会希望先把修改后的文件全部提交。在这种情况下，如果使用git commit的-a选项，就不需要执行git add命令。

```
$git commit-a
```

这时会像新增加时一样启动编辑器，要求输入提交信息，在输入Correct misspelling后保存文件并关闭编辑器。

这样修改内容就提交到了仓库中。

小贴士：git commit-a原本是用来提交Git所管理的所有文件的。一次也没有执行git

add命令的文件不会提交，例如，新创建的文件等。

确认工作区的状态

如果进行了很多修改，就需要确认已经提交工作区的仓库处于什么状态。我们试着稍微改变源代码来进行确认。

首先将hello.c的return 0；改为return 1；。然后创建新文件goodbye.c。

```
/*goodbye.c*/
#include＜stdio.h＞
int main（void）
{
printf（"Goodbye world！\n"）；
return 0；
}
```

用来确认状态的第一个命令是git status，尝试执行以下命令。

```
$git status
#On branch master
#Changed but not updated：
#（use"git add＜file＞……"to update what will be committed）
#（use"git checkout--＜file＞……"to discard changes in working directory）
#
#modified：hello.c
#
#Untracked files：
#（use"git add＜file＞……"to include in what will be committed）
#
#goodbye.c
no changes added to commit（use"git add"and/or"git commit-a"）
```

输出的内容显示hello.c的修改还没有提交，goodbye.c不在Git的管理范围内。

要确认哪个文件在Git的管理范围内，可以使用下列命令。

```
$git ls-fles
hello.c
```

如果想要看到修改hello.c的历史记录，可以执行下列命令。差别就会分段显示出来。

```
$git diff
diff--git a/hello.c b/hello.c
index aa28db5..7ef0a54 100644
---a/hello.c
+++b/hello.c
@@-4，6+4，6@@
int main（void）
{
printf（"Hello world！\n"）；
-return 0；
+return 1；
}
```

显示出差别的只有Git管理范围内的文件。由于goodbye.c还不在Git的管理范围内，因此没有任何显示。

下面，对goodbye.c执行git add命令，确认前者是否在Git的管理范围内。

```
$git add goodbye.c
$git ls-fles
goobye.c
hello.c
```

可以看到多出了goodbye.c。

这时可以再次使用git diff来显示差别。但奇怪的是，刚才明明对goodbye.c使用了git add命令，为什么没有显示呢？这时，再执行下列命令。

```
$git add hello.c
$git diff
```

而这次竟然什么也不显示了。这是怎么回事？

事实上，git diff显示的并不是最新提交与工作区之间的差别，而是“缓存区”（staging area，也称为分段存储区）与工作区之间的差别。缓存区是用来暂时存放下一次要提交到仓库的信息的区域。也就是说，git add的作用是将当前工作区的内容存放到缓存区。执行git commit后，最新提交和缓存区的内容是一致的。在工作区进行修改后再次执行git add，最新提交与缓存区的内容就变得不同，而缓存区与工作区的内容一致。在上例中，在执行git add hello.c后工作区与缓存区的内容是完全一致的。因此git diff就不会再显示任

何内容。

当想看到的不是缓存区与当前工作区的差别，而是最新提交与当前工作区的差别时，可以为git diff指定表示最新提交的HEAD。

```
$git diff HEAD
diff--git a/goodbye.c b/goodbye.c
new file mode 100644
index 0000000..13f79ea
---/dev/null
+++b/goodbye.c
@@-0，0+1，9@@
+/*goodbye.c*/
+#include＜stdio.h＞
+
+int main（void）
+{
+printf（"Goodbye world！\n"）；
+return 0；
+}
+
diff--git a/hello.c b/hello.c
index aa28db5..7ef0a54 100644
---a/hello.c
+++b/hello.c
@@-4，6+4，6@@
int main（void）
{
printf（"Hello world！\n"）；
-return 0；
+return 1；
}
```

如果想要知道最新提交与缓存区的差别，可以使用git diff--cached。由于当前缓存区与工作区是完全一致的，因此输入的内容与上述内容相同。

然后，使用git commit-a提交所作的修改，提交信息为Add goodbye.c。

参照提交记录

当想要参照提交记录时，可以使用git log命令。如果在当前仓库执行这条命令，就会显示关于之前进行的3次提交的下列相关信息（日期等信息因环境不同而各异）。

```
$git log
commit 9b670c34bd7bd772648a99738017802f2b24f859
```

```
Author：Munehiro"Muuhh"Ikeda＜m_ikeda@hogeraccho.com＞
Date：Sat Apr 2 14：09：39 2011-0700
Add goodbye.c
commit c47feeef44a652bda15dbb580d48213dc1294664
Author：Munehiro"Muuhh"Ikeda＜m_ikeda@hogeraccho.com＞
Date：Sat Apr 2 13：20：10 2011-0700
Correct misspelling
commit 83d9b3f95cdb43e76953c77f03d2700e978dde8d
Author：Munehiro"Muuhh"Ikeda＜m_ikeda@hogeraccho.com＞
Date：Sat Apr 2 13：18：07 2011-0700
Initial commit
```

紧接着commit后面显示的，是仅指示该提交的散列（hash）值。Author描述的是提交者的信息。事先使用git config设置提交者的信息，就是为了将这些作为提交信息记录下来。可以发现，每次提交的最后一行显示的都是提交时输入的提交信息。

git log默认输出所有的提交记录，但也可以用如表1-11所示的命令行参数来指定提交的散列值，限制输出范围。

表 1-11　指定 git log 的提交范围（绝对散列值）

命　令	显 示 范 围
git log <hash>	到提交散列值 <hash> 为止
git log <hash>..	从 <hash> 之后到最新的提交为止
git log <hash1>..<hash2>	从 <hash1> 之后到提交 <hash2> 为止

散列值不需要完整输入，只需输入一定长度使其仅指示这次提交（但最少要输入4个字）。

最新提交可以用HEAD这一别名进行参照。另外还可以将从HEAD开始的相对位置指定为HEAD～2等。使用这一方法还可以进行如表1-12所示的指定。

表 1-12　指定 git log 的提交范围（相对于 HEAD）

命　令	显示范围
git log、git log HEAD	到最新提交为止，即所有提交
git log HEAD~、git log HEAD~1	到倒数第二次提交为止
git log HEAD~~、git log HEAD~2	到倒数第三次提交为止
git log HEAD~2.. HEAD~1	从倒数第三次提交到倒数第二次提交为止，即仅倒数第二次提交

在Git的其他子命令下指定提交范围的方法也是相同的。使用git diff等也可以输出指定范围的差别。

如果为git log指定文件，则仅输出与该文件有关的提交。还可以使用-p选项将提交后的变更内容以段落形式显示出来。当前仓库显示的内容如下。

```
$git log-p goodbye.c
commit 9b670c34bd7bd772648a99738017802f2b24f859
Author：Munehiro"Muuhh"Ikeda＜m_ikeda@hogeraccho.com＞
Date：Sat Apr 2 14：09：39 2011-0700
Add goodbye.c
diff--git a/goodbye.c b/goodbye.c
new file mode 100644
index 0000000..13f79ea
---/dev/null
+++b/goodbye.c
@@-0，0+1，9@@
+/*goodbye.c*/
+#include＜stdio.h＞
+
+int main（void）
+{
+printf（"Goodbye world！\n"）；
+return 0；
+}
+
```

修改提交

在进行提交后，有时也会想要对已经提交的内容进行修改。修改方法大致可以分为两种。

第一种方法是进行新的提交来取消某个提交。在这种情况下，原先的提交和后来为了

取消它而进行的提交都会保留记录。要取消当前仓库的最新提交时，进行如下操作。

$git revert HEAD

提交信息可以根据个人喜好进行修改，这里就不作修改，直接以默认内容保存，并关闭编辑器。goodbye.c从工作区被删除，hello.c的内容也回到前一次提交的状态（返回值为0）。使用git log-p来确认提交的内容，可以发现使用git revert进行的最新提交（提交信息Revert"Add goodbye.c"）与前一次提交（提交信息Add goodbye.c）的变更是完全相反的。

第二种方法是直接对提交进行修改。直接修改提交也有三种作法，得出的结果在细节上有一些不同。

直接修改提交的第一种作法，适用于对最新提交进行较小修改的情况。假设在刚才的git revert中，想保留hello.c的返回值1，不作修改，并在提交信息中记录下来。在这种情况下需要进行如下操作。

```
$vi hello.c
（将return 0；重新修改为return 1；）
$git add hello.c
$git commit--amend
将提交信息修改为Revert"Add goodbye.c"except for return value，保存
```

并关闭编辑器。

再用git log-p来确认提交信息与变更内容，可以发现返回值的更改从最新提交中被删除，提交信息也发生了改变。

直接修改提交的第二种作法，就是取消提交。假设想要取消最新提交，也就是将记录恢复到最新提交前一次的提交（HEAD～1），但是希望工作区的源代码维持原状。这时应执行下列命令。

```
$git reset--soft HEAD～1
```

然后用git log查看记录，可以发现Revert……的提交已经消失了。但是由于并没有对工作区作出修改，因此原本通过当前最新提交的Add goodbye.c应当添加的文件goodbye.c不存在。

最后一种作法，是在恢复记录的同时，将工作区也恢复到相应的状态。可以执行下列命令：

```
$git reset--hard HEAD
```

由于工作区也已经回到了当前的HEAD（即Add goodbye.c），因此goodbye.c恢复。目前记录、工作区都已经完全恢复到提交Add goodbye.c后的状态。

小贴士：对提交记录进行修改时请慎重。特别需要注意的是，这个方法如果用在被其他仓库参照的仓库中，会出现相互之间记录不兼容的问题，因此不能在此情况下使用。

为提交加标签

可以为每次提交加上“标签”。为发布版本等关键的提交加上标签，以后就可以使用标签名称来参照本次提交，十分方便。

假设将HEAD～1的提交Correct misspelling发布为版本1，然后尝试为ver1加上标签。

```
$git tag ver1 HEAD～1
```

可以使用下列命令来显示仓库内的标签列表。

```
$git tag-1
```

创建分支

想要在保留当前开发系统的同时进行其他系统的开发，就需要创建“分支”。下面以刚才加了标签ver1的提交为起点，创建名为ver1x的分支。ver1x是针对下一版本的开发分

支。

```
$git branch ver1x ver1
```

仓库的分支列表可以用下列命令来显示。

```
$git branch
*master
ver1x
```

如图1-5所示，从输出的内容可以看到，新的分支ver1x已经创建。前面有*的是当前工作区需要的分支（当前分支）。然后，将当前分支更改为ver1x。

```
$git checkout ver1x
Switched to branch'ver1x'
$git branch
master
*ver1x
```

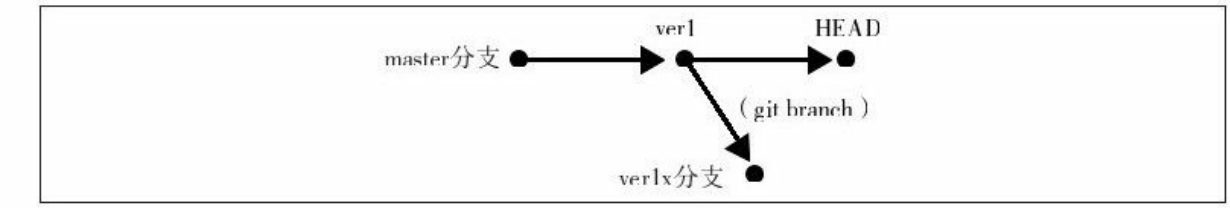

图　1-5　分支的创建

在ver1x分支中创建新的文件thanks.c，并提交。

```
/*thanks.c*/
#include＜stdio.h＞
int main（void）
{
printf（"Thank you guys！\n"）；
return 0；
}
$git add thanks.c
$git commit
```

将ver1x：Add thanks.c作为提交信息。

使用git log查看记录，可以发现，master分支里的Add goodbye.c在分支ver1x内是无效的，提交Add thanks.c的祖先是分支ver1x的起点，即提交Correct misspelling。像这样创建分支，就可以在同一仓库内独立地进行其他系统的开发。

rebase命令

开发版必须一直在最新发行版的基础上进行开发。例如，当发行版安装新功能时，必须将其也安装到开发版中。在当前的仓库中，goodbye.c就相当于新安装的功能。这时就需要将开发分支ver1x的起点移动到发行版的最新提交中。这种分支起点的移动称为复位基底（rebase），如图1-6所示。想要将当前分支复位基底到分支master的最新提交，需要执行下列命令。由于现在的当前分支为ver1x，因此这条命令复位基底的是ver1x。

```
$git rebase master
```

小贴士：上例中是rebase到master的最新提交，但可以使用--onto选项来指定要rebase到的任意提交。默认为所指定分支（上例中为master）的最新提交。

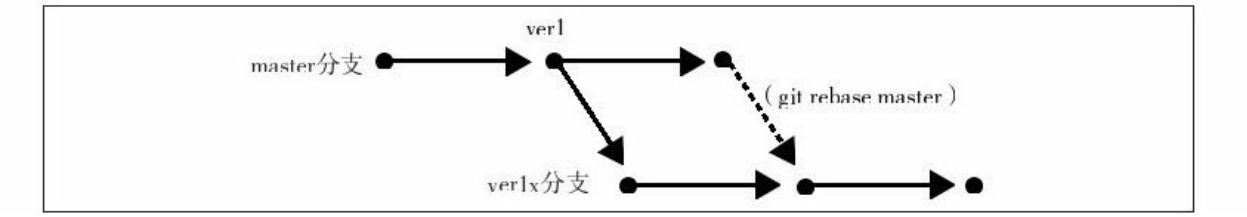

图　1-6　分支的rebase

合并分支

为了合并发行版master分支与开发版分支ver1x中各自进行修改与开发的情况，就需要对文件进行修改。

首先在目前需要的ver1x分支中进行修改。通过下列命令来修改goodbye.c的注释。

```
$git branch
master
```

```
*ver1x
$vi goodbye.c
（将/*goodbye.c*/修改为/*goodbye.c：needed?*/）
$git commit-a
```

将提交信息写为ver1x：Modify comment in goodbye.c。然后移动到master分支，在这边也对goodbye.c进行修改。

```
$git checkout master
$vi goodbye.c
（将/*goodbye.c*/修改为/*goodbye.c：yes, needed！*/
将return 0；修改为return 1；）
$git commit-a
```

将提交信息写为Modify comment and return value of goodbye.c。

到此为止，ver1x分支下的开发就基本完成了，假设即将将其作为版本2进行发布。在这种情况下，需要将分支ver1x合并到分支master中，将ver1x下的开发成果整合到发行版中（见图1-7）。将当前分支作为master执行下列命令。

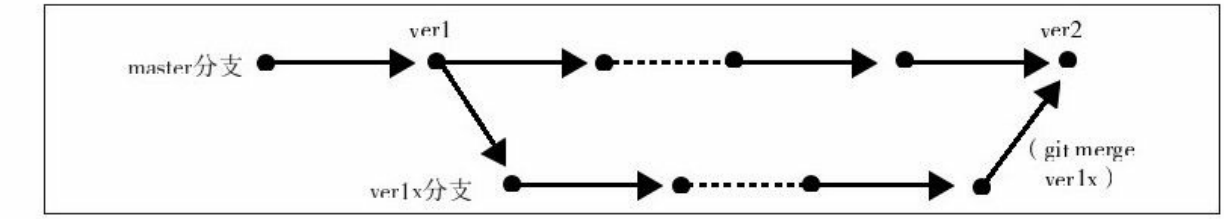

图　1-7　分支的合并

```
$git merge ver1x
Auto-merging goodbye.c
CONFLICT（content）：Merge conflict in goodbye.c
Automatic merge failed；fix conflicts and then commit the result.
```

这时提示由于goodbye.c中发生了冲突而无法合并。这是由于在两个分支下都对goodbye.c进行了修改。发生冲突的文件可以使用git status命令，显示为unmerged。

```
$git status
goodbye.c：needs merge
#On branch master
#Changes to be committed：
#（use"git reset HEAD＜file＞……"to unstage）
#
```

```
#new file：thanks.c
#
#Changed but not updated：
#（use"git add＜file＞……"to update what will be committed）
#（use"git checkout--＜file＞……"to discard changes in working directory）
#
#unmerged：goodbye.c
#
```

再查看一下goodbye.c的内容。

```
＜＜＜＜＜＜＜HEAD：goodbye.c
/*goodbye.c：yes, needed！*/
=======
/*goodbye.c：needed?*/
＞＞＞＞＞＞＞ver1x：goodbye.c
#include＜stdio.h＞
int main（void）
{
printf（"Goodbye world！\n"）；
return 1；
}
```

发生冲突的部分是用冲突标记＜＜＜＜＜＜＜和＞＞＞＞＞＞＞显示的。必须人工决定选择其中的哪一个。这里选择采用master分支下的修改，即yes, needed！。

将goodbye.c修改为下列内容。

```
/*goodbye.c：yes, needed！*/
#include＜stdio.h＞
int main（void）
{
printf（"Goodbye world！\n"）；
return 1；
}
```

使用git add通知Git修改已结束，并进行提交。

```
$git add goodbye.c
$git commit
```

到这一步，两个分支的合并就结束了。使用git log确认记录，可以发现进行合并后，在ver1x分支中进行的ver1x：Add thanks.c等修改在master分支中也体现出来。冲突的解决

也作为一个提交记录下来。

然后加上标签，以便将这个状态作为版本2进行参照。

```
$git tag ver2
```

小贴士：即使在两个分支下对相同文件进行了修改，如果是针对不同行进行的修改，Git也会自动将这些修改合并。上例就在master分支下修改了goodbye.c的返回值，这个部分也由Git自动进行了合并。

参照图形记录

对分支进行合并后，提交之间的从属关系变得复杂，比较难把握。这时可以使用git log--graph命令，在文字界面上将从属关系以图形显示出来。

除此以外，也可以使用gitk数据包里所含的基于图形界面的工具gitk。图1-8所示为gitk的界面。

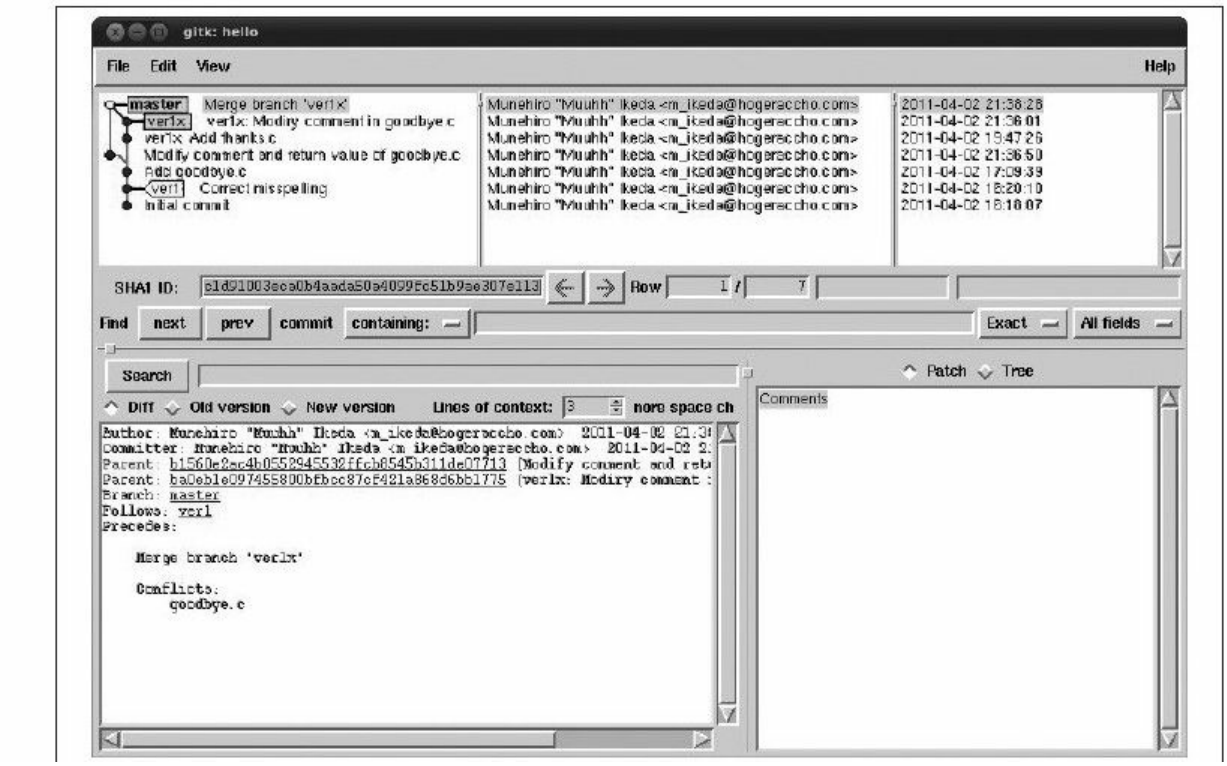

图　1-8　gitk

提取补丁

想要根据从版本1到版本2的各次提交的差别提取补丁文件，可以执行下列命令。

```
$git format-patch ver1..ver2
```

当前目录下就会生成0001-Add-goodbye.c.patch等补丁文件。

在这里使用标签名称指定了补丁的起点和终点，除此以外，还可以指定提交的散列值与分支名。

提取源码树

执行下列命令，可以将版本2的源代码作为tar文件提取出来。

```
$git archive--format=tar--prefx="hello-v2/"ver2＞../hello-v2.tar
```

根目录下就会生成名为hello-v2.tar的tar文件。

小贴士：当各文件包含到tar文件中时，文件名前面会加上使用--prefix选项指定的文字。这只是单纯地添加了文字，因此，当指定tar文件内的根目录名时，要记得如上例中的“hello-v2/”这样在文字的最后加上“/”。

小贴士：.git目录不会包含到tar文件中，因此即使将这里生成的tar文件解压缩，也不能发挥Git仓库的功能。

相反的，如果将Git仓库的目录连同.git目录在内全部复制，就能够发挥与原来的仓库完全相同的功能。从这一点也可以看出Git完全是分布式仓库。

与远程仓库进行共同作业

本地仓库的操作已经基本掌握，下面就将介绍与远程仓库进行共同作业的方法。

这里将按照一般开发者进行Linux内核上游开发时的流程来说明。大致流程如下。

·将上游的仓库复制到本地。

·不断追踪上游仓库的最新状态，同时在本地仓库进行开发。

·以补丁的形式将开发成果提交维护人员及开发邮件列表。

复制仓库

当进行上游开发时，首先要复制各维护人员所管理的开发仓库（远程仓库），建立本地仓库。在Git中将这一步称为“复制”。复制是通过git clone命令来进行的。例如，复制Linus树的仓库的命令为：

```
$git clone git：//git.kernel.org/pub/scm/linux/kernel/git/torvalds/linux-2.6
```

复制Linus树时要下载1GB以上的数据，因此需要花费很长时间，仅在必要时再进行这个操作。这里将之前生成的hello仓库当做远程仓库，将其复制到其他位置。

```
$cd
$git clone hello local
```

生成local目录后，里面包含的文件就与hello目录完全相同。进入local目录，使用git log确认记录，就可以发现至今为止的记录已完全复制过来。

建立本地分支

请在本地仓库执行git branch命令。在这一阶段只有master分支。这个master分支是在

远程仓库（即hello仓库）的master分支关联的基础上，在本地仓库生成的分支。关联，就是指此后与远程仓库进行同步时，hello仓库在master分支下所作的改动会合并到这个分支。因此，如果在master分支中进行开发，进行同步时两个仓库所作的更改就有可能发生冲突。为了避免发生这种情况，就要事先从master分支中分出一个用于在本地进行开发的分支work。

```
$git checkout-b work
```

git checkout-b命令将在创建分支的同时进行检查（针对当前分支的最新修改）。

追踪分支

为了便于说明，上文的描述比较简单，可能会让人认为本地仓库的master分支是hello仓库master分支的副本，而其实并不是这样。hello仓库的master分支，在本地仓库是以origin/master的标题出现的。这个分支才完全是hello仓库master分支的副本，这种分支称为“追踪分支”。在使用git pull对仓库进行同步时，首先同步的就是这个追踪分支。然后，把追踪分支的提交合并到追踪分支所关联的本地分支中。

通过执行git branch-r命令，可以显示追踪分支的列表。下方显示的就是在本地仓库中执行这一命令的输出结果（见图1-9）。

```
$git branch-r
origin/HEAD-＞origin/master
origin/master
origin/ver1x
```

远程仓库的相关信息可以使用git remote show命令来确认。虽然可以设置多个远程仓库，但仅设置一个时其默认名称为origin，因此执行该命令时可以指定origin。

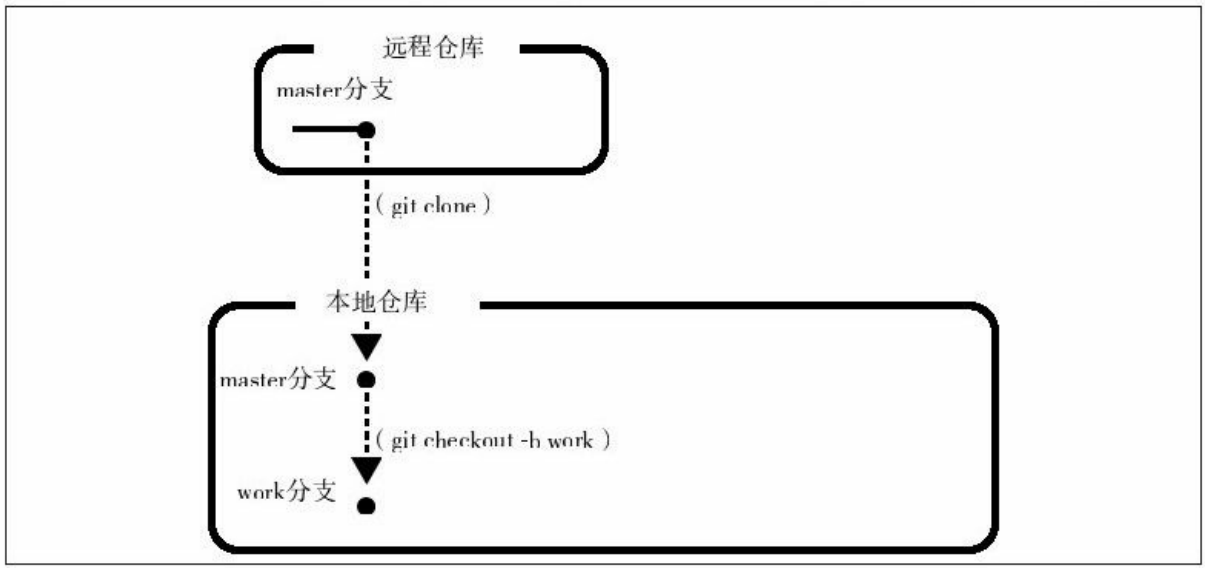

图　1-9　本地分支的建立

```
$git remote show origin
*remote origin
URL：/home/munehiro/hello
Remote branch merged with'git pull'while on branch master
master
Tracked remote branches
master
ver1x
```

这里的输出具有下列含义。

·远程仓库origin的URL：/home/munehiro/hello

·在本地分支master上执行git pull时合并的远程分支：master

·追踪分支：master, ver1x

这些信息是通过.git/config文件设置的。相关各部分的内容（section）如下所示。[remote"origin"]部分规定了远程仓库的URL、远程仓库上的分支、追踪分支之间的关系。[branch"master"]部分规定了合并到本地分支master的远程分支为origin仓库（即hello仓库）的master分支。

```
$cat.git/confg
……
[remote"origin"]
```

```
fetch=+refs/heads/*：refs/remotes/origin/*
url=/home/munehiro/hello
[branch"master"]
remote=origin
merge=refs/heads/master
……
```

追踪分支是为了追踪远程仓库而存在的，因此不能在这个分支上进行本地修改（从技术上是可以的，但并不推荐）。

以追踪分支为起点建立本地分支后，本地分支就被追踪分支关联。例如，可以通过下列命令，建立与master分支的追踪分支相关联的本地分支master2。

```
$git branch master2 origin/master
```

本地分支master及master2虽然被关联，但二者完全是本地分支。因此也可以直接在上面进行本地开发。但是，由于需要通过git pull进行合并，因此如果发生了冲突，就必须在这时候解决。

与远程仓库同步

想要看到在远程仓库上不断进行的开发，可以在hello仓库的master分支下对thanks.c进行如下修改并提交（将负（-）的行改为正（+）的行）。

```
-return 0；
+return 2；
$git commit-a
```

将Modify return value of thanks.c into 2作为提交信息。

使用git pull命令可以让本地仓库与远程仓库的最新状态保持同步。在本地仓库执行下列命令后，在hello仓库的master分支下进行的修改就会全部整合到本地仓库的master分支。

```
$git checkout master
$git pull
```

这时使用git log查看记录，可以发现hello仓库的提交Modify return value of thanks.c into 2已经整合并完成同步。

将开发分支rebase到最新状态

在本地仓库的work分支下不断进行本地开发。将当前分支设置为work后，对thanks.c进行如下的修改并提交。

```
$git checkout work
-printf（"Thank you guys！\n"）；
-return 0；
+printf（"Thank you so much guys！\n"）；
+return 1；
$git commit-a
```

在此以前，提交信息都只有1行，而这次需要输入多行，如下所示。第2行只需另起一空行。

```
Modify message thanks.c
I really appreciate your efforts.
```

另外，本地开发成果必须基于最新版的远程仓库（上游仓库）。当前的work分支是以版本2为起点的，而这已经不是最新版。处于最新状态的是刚才进行了同步的本地仓库的master分支。因此，如图1-10所示，只需要将work分支复位基底到master分支的HEAD。

thanks. c内发生了冲突，可以按照与上文所述“合并分支”同样的方法来消除冲突。为了保留上游的修改，并加入自己的开发成果，需要对thanks.c进行如下修改。

```
$git rebase master
First, rewinding head to replay your work on top of it……
Applying：Modify thanks.c
Using index info to reconstruct a base tree……
Falling back to patching base and 3-way merge……
Auto-merging thanks.c
CONFLICT（content）：Merge conflict in thanks.c
Failed to merge in the changes.
Patch failed at 0001 Modify thanks.c
When you have resolved this problem run"git rebase--continue".
If you would prefer to skip this patch, instead run"git rebase--skip".
To restore the original branch and stop rebasing run"git rebase--abort".
```

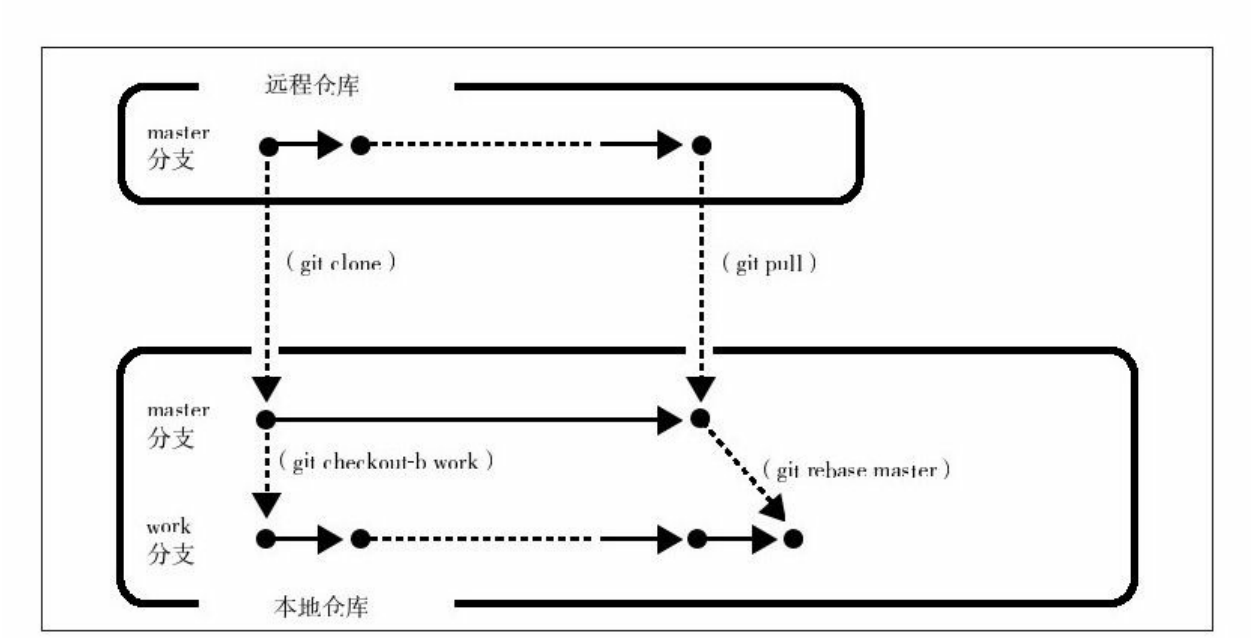

图　1-10　本地开发分支的复位基底

例1-1　thanks.c的冲突标记

```
<<<<<<<HEAD
printf（"Thank you guys！\n"）；
return 2；
=======
printf（"Thank you so much guys！\n"）；
return 1；
>>>>>>>Modify thanks.c
```

例1-2　thanks.c的修改结果

```
printf（"Thank you so much guys！\n"）；
return 2；
```

因为发生冲突而中断的复位基底，在消除冲突并对文件执行git add命令后，再执行git rebase--continue就会继续。

```
$git add thanks.c
$git rebase--continue
```

这样就成功地复位基底到最新版了。这时也可以使用git log确认记录。

用邮件将补丁发送给维护人员

现在，本地仓库的开发终于完成了。Linux内核开发的流程是先以补丁的形式将开发成果发送到邮件列表，经过评估与讨论后再整合到上游的仓库内。可以使用git format-patch将补丁输出为文件，粘贴到平时使用的电子邮件的正文并发送，而Git也备有直接发送邮件的功能—git send-email命令。这里使用这条命令来发送邮件。

另外，在笔者所使用的环境（Ubuntu 10.04、Fedora14）中，git send-mail命令原来是放在与Git不同的git-email数据包里的，因此需要事先下载。

小贴士：通过Git直接发送邮件，就可以避免电子邮件软件出现的换行符等问题。

要将本地仓库的开发成果，即以master分支为起点的work分支的各次提交（目前只有一个），作为补丁以邮件发送，可以执行下列命令。另外，如果事先在配置文件中设置各种选项，就不需要每次都在命令行进行输入。表1-13所示为与选项对应的配置文件的段落名。

```
$git send-email--to=hello_maintainer@hogeraccho.com--cc=hello-ml@hogeraccho.com--smtp-server=smtp.googlemail.com--smtp-encryption=ssl--smtp-server-port=465--smtp-user=youruser@gmail.com--smtp-pass=yourpw master..work
```

表 1-13 git send-email 的选项

选　项	说　明	设置文件段落
--to	邮件的 To 地址	sendmail.to
--cc	邮件的 Cc 地址	sendmail.cc
--smtp-server	SMTP 服务器名称	sendmail.smtp-server
--smtp-encription	连接的保护方式（ssl 或 tls）	sendmail.smtpencryption
--smtp-server-port	SMTP 的端口号	sendmail.smtp-server-port
--smtp-user	SMTP 的用户名	sendmail.smtpuser
--smtp-pass	SMTP 的密码	sendmail.smtp-pass

将--to、--cc等改成自己的地址，并尝试发送邮件，应当会收到如下列内容的邮件。

```
From：Munehiro Muuhh Ikeda＜m_ikeda@hogeraccho.com＞
To：you@your.domain.co.jp
Cc：Munehiro Muuhh Ikeda＜m_ikeda@hogeraccho.com＞
Subject：[PATCH]Modify message thanks.c
I really appreciate your efforts.
---
thanks.c|2+-
1 files changed，1 insertions（+），1 deletions（-）
diff--git a/thanks.c b/thanks.c
index c28de46..806371d 100644
---a/thanks.c
+++b/thanks.c
@@-3，7+3，7@@
int main（void）
{
-
printf（"Thank you guys！\n"）；
+printf（"Thank you so much guys！\n"）；
return 2；
}
--
1.7.1
```

提交信息的第1行是邮件标题，从空行之后（即第3行开始）是邮件的正文。

git send-email有非常多的选项，可以进行各种设置。建议浏览帮助页面（man page），进行各种尝试，最后生成最佳的配置文件。

其他有用的命令

除上面介绍的以外，还有很多其他有用的命令。表1-14简单整理了其中的一部分，详细内容请参考git的帮助页面。

表 1-14　其他命令

命　令	操　作
git push	将本地修改直接传递到远程仓库。仅在拥有对远程仓库进行修改的权限时有效
git fetch	从远程仓库将修改抓取到追踪分支。与 git pull 不同的是不进行与本地分支的合并。git pull 是在内部调出 git fetch 和 git merge 操作的
git stash	要将工作区中还未提交的修改保存并移动到其他分支时使用。保存后的状态可以用 git stash pop 来调出
git cherry-pick	要将其他分支下的 1 个提交到使用当前分支时使用。由于提交会复制，因此会变成其他的散列值
git gc	删除未使用的对象或文件，优化仓库
git am	从 mbox 格式的文件导入补丁并提交
git bisect	用来指定导入了 bug 的提交

小结

当进行Linux内核的上游开发时，Git可以说是必需的工具。Git具有优秀的功能与速度，在多个开发人员参与的项目中可以成为非常有效的工具，并且不仅限于Linux内核的开发。一直以来使用单一仓库型SCM的人可以体验分布式仓库型SCM的高度可扩展性。当然，对于初次使用SCM的人来说也一定会是很好用的工具。

HACK#5　使用checkpatch.pl检查补丁的格式

本节介绍发布前检查补丁格式的方法。

Linux内核是由多个开发者进行开发的。因此，为了保持补丁评估与源代码的可读性，按照统一的规则进行编写是非常重要的。编写规则写在Linux内核源代码的Documentation/CodingStyle中。所有开发者必须先阅读规则内容，遵照这些规则进行编写后再将补丁发布到论坛上。

话虽如此，但要从一开始就将这些规则完全记住也是不太可能的。因此Linux内核的源码树内准备了用来检查补丁格式的脚本scripts/patchcheck.pl。下面将介绍使用这个脚本来检查补丁格式的方法。

检查格式的示例

首先，看一个对源代码进行一些简单修改并生成补丁的例子。在fs/namei.c内的符号链接系统调用（symbolic link system call）的入口函数中添加printk（）。这个补丁wrong-patch-example.patch的内容如下所示。

```
From 6064092a8a276fa6e09755872193cfe1e4a16f42 Mon Sep 17 00：00：00 2001
From：Munehiro"Muuhh"Ikeda＜m_ikeda@hogeraccho.com＞
Date：Sun，22 May 2011 14：54：58-0700
Subject：[PATCH]wrong patch example
Added printk（）on sys_symlink（）.
---
fs/namei.c|1+
1 files changed，1 insertions（+），0 deletions（-）
diff--git a/fs/namei.c b/fs/namei.c
index e3c4f11..d40214a 100644
---a/fs/namei.c
+++b/fs/namei.c
@@-2912，6+2912，7@@out_putname：
SYSCALL_DEFINE2（symlink, const char__user*，oldname, const char__user*，
newname）
{
+printk（KERN_DEBUG"[TRIAL]trying symlink：%s--＞%s￥n"，oldname, newname）；
return sys_symlinkat（oldname, AT_FDCWD, newname）；
}
```

```
--
1.7.4
```

当检查补丁的格式时，需在内核源码树的根下，以补丁文件名为变量执行scripts/checkpatch.pl。当不指定任何选项时，含有格式错误的行的内容也会输出。在这里如果指定--terse选项，就可以将各错误或警告的概要分别在1行中输出。

```
$scripts/checkpatch.pl--terse wrong-patch-example.patch
wrong-patch-example.patch：19：WARNING：line over 80 characters
wrong-patch-example.patch：19：ERROR：space prohibited after that open
parenthesis'（'
wrong-patch-example.patch：19：ERROR：space prohibited before that close
parenthesis'）'
wrong-patch-example.patch：25：ERROR：Missing Signed-off-by：line（s）
total：3 errors，1 warnings，7 lines checked
```

短短1行的补丁，竟然输出了这么多的内容。这些内容依次分别是针对下列内容的错误或警告。

·[警告]1行的字数超过80字。

·[错误]前括号“（”后面有多余的空格。

·[错误]后括号“）”前面有多余的空格。

·[错误]没有Signed-off-by（补丁发布人的署名）。

前3个是关于编写规则的错误或警告，最后1个是编写规则之外的补丁格式的错误。

对这些错误进行修改，将较长的行分成两行，删除不需要的空格并添加在Signed-off-by后，补丁的内容就如下所示。

```
From cb24866e8c989f55abebc3e6bf879cf3d17d3e87 Mon Sep 17 00：00：00 2001
From：Munehiro"Muuhh"Ikeda＜m_ikeda@hogeraccho.com＞
Date：Sun，22 May 2011 14：54：58-0700
Subject：[PATCH]correct patch example
Added printk（）on sys_symlink（）.
Signed-off-by：Munehiro"Muuhh"Ikeda＜m_ikeda@hogeraccho.com＞
---
fs/namei.c|2++
1 files changed，2 insertions（+），0 deletions（-）
```

```
diff--git a/fs/namei.c b/fs/namei.c
index e3c4f11..1c47443c 100644
---a/fs/namei.c
+++b/fs/namei.c
@@-2912，6+2912，8@@out_putname：
SYSCALL_DEFINE2（symlink, const char__user*，oldname, const char__user*，
newname）
{
+printk（KERN_DEBUG"[TRIAL]trying symlink：%s--＞%s￥n"，
+oldname, newname）；
return sys_symlinkat（oldname, AT_FDCWD, newname）；
}
--
1.7.4
```

使用checkpatch.pl输出的主要错误或警告

scripts/checkpatch. pl输出的错误或警告有很多种，其中有一些比较具有代表性的，如下所示。在编写的阶段就应当充分注意它们。

错误

·换行符为DOS格式（CR+LF）。

·行首、行尾有多余的空格。

·不是用制表符，而是用空格缩进。

·switch语句和case语句的缩进不一致。

·函数定义块（block）以外的“{”写在独立的行中。

·注释符使用的是“//”。

·全局变量或静态变量是明确指定以0初始化的。

·前括号“（”或“[”后面有多余的空格。

·后括号“）”或“]”前面有多余的空格。

·逗号“，”后面没有空格。

·if、for、while的前括号“（”前面没有空格。

·else未与if块结尾的“}”写在同一行。

·使用了将来要废弃的头文件或函数。

·补丁内没有Signed-off-by行。

警告

·补丁内含有的路径起点不是内核源码树的根目录。

·1行的长度超过80字。

·制表符前面有空格。

·const关键词的使用方法有问题。

·printk（）没有指定输出级别（KERN_*）。

·goto的分支终点的标签label缩进。

·用“{}”括住了只有1行的代码块。

·使用了volatile修饰符。

·kmalloc（）的返回值已经转换。

小结

使用scripts/checkpatch.pl可以在投稿前检查补丁的格式。将补丁列入邮件列表时，经常可以看到“未按照规则编写，请修改”的提示。一定要在发布前检查补丁的格式，才能集中对补丁内容进行讨论。

参考文献

·Documentation/CodingStyle（内核源文档）

—Munehiro IKEDA

HACK#6　使用localmodconfig缩短编译时间

本节介绍使用make localmodconfig生成精简的.config文件，缩短内核编译时间的方法。

为了能够应对各种各样的环境，发布版的内核包含很多内核模块。但是在某个特定机器，例如，大家自己平时使用的PC上实际用到的模块只是其中的极小一部分。重新构建内核时，对不使用的模块进行编译就会浪费时间。编译后的模块存放在磁盘里，因此也会造成磁盘空间的浪费。

将localmodconfig作为make的目标，就可以生成仅以正在使用的内核模块为对象的.config文件，可以在Linux内核2.6.32以后的版本中使用它。使用这条命令，可以生成仅启用必要模块的.config文件，从而缩短内核的编译时间。

localmodconfig的使用方法

将运行中的内核源代码解压缩，并在源码树的根下执行下列命令。

#make localmodconfg

如果是一般的发布版，只需进行这一操作就可以生成.config文件，将要编译的内核模块缩减到最少。此后只需执行下列命令，照常进行内核的编译、安装。

```
#make
#make modules_install
#make install
```

localmodconfig的效果

使用两种.config文件对上游内核（Linux 2.6.34）进行了编译，并记录分别花费的时间。

第一次是使用Fedora13的默认内核.config文件对Linux 2.6.34进行了编译，将其记为“2.6.34-fc13”。第二次使用的是在2.6.34-fc13的.config文件的基础上使用localmodconfig生成的.config文件，编译后的文件记为“2.6.34-localmod”。两次花费的编译时间如下所示。

·2. 6.34-fc13：26分13秒

·2. 6.34-localmod：8分20秒

通过使用localmodconfig生成的.config文件，将编译时间缩短到了1/3以内。

另外，还对内核模块的数量以及它们所在目录的总容量进行了比较。

```
#du-sh/lib/modules/2.6.34-fc13/kernel/
75M/lib/modules/2.6.34-fc13/kernel
#fnd/lib/modules/2.6.34-fc13/kernel-name'*.ko'|wc-l
2046
#du-sh/lib/modules/2.6.34-localmod/kernel/
9.2M/lib/modules/2.6.34-localmod/kernel/
#fnd/lib/modules/2.6.34-fc13-localmod1/kernel-name'*.ko'|wc-l
138
```

localmodconfig使内核模块的数量减少到约1/15，占用的磁盘空间也减少到约1/8。

localmodconfig的结构

localmodconfig是通过内核源码树的下列脚本执行的。

---

scripts/kconfig/streamline_config.pl

---

localmodconfig首先会尝试提取一套配置选项作为模型。使用的模型为源码树的.config文件或者/boot下正在运行的内核的.config文件（/boot/config-＜内核版本＞）。当这些不存在时，将从正在运行的内核映像（/boot/vmlinuz-＜内核版本＞）、保存了设置信息的内核模块（configs.ko）等提取信息。

另外，要从内核映像或configs.ko提取出配置选项的信息，内核必须是在指定CONFIG_IKCONFIG选项的情况下编译的。当无法提取用做模型的配置选项时，即，找不到.config文件，且正在运行的内核是在未指定CONFIG_IKCONFIG选项的情况下编译的，就会导致localmodconfig失败。

然后，localmodconfig通过lsmod获取当前安装到内核中的内核模块列表，找出对它们进行编译所需的配置选项并记录下来。

最后，localmodconfig将模型的配置选项中指定要作为内核模块进行编译的部分（CONFIG_*=m）进行如下修改，并输出为.config文件。

·当前安装到内核的内核模块所需要的选项：不修改

·此外：改为禁用

模型中指定要静态安装到内核的选项（CONFIG_*=y）、设置为禁用的选项（#CONFIG_*is not set）不进行修改，直接输出。

小贴士：通过把作为模型的配置选项指定到模块中，却未安装到内核的内核模块中，

导致其配置选项失效，无法编译。因此，在执行localmodconfig命令之前，可以将需要编译的内核模块手动安装到内核中。例如，可以使用下列命令，将用来虚拟化的模块kvm.ko安装到内核中。

```
#modprobe kvm
```

当然，localmodconfig生成了.config文件后，也可以使用make menuconfig等手动对.config文件进行修改。

localyesconfig

localyesconfig是与localmodconfig相似的make目标。使用这条命令，通过localmodconfig设置为内核模块的配置选项，将设置为在无提示的情况下安装到内核中。

在编写不使用initramfs启动的内核时localyesconfig非常方便。

小结

对于不是很清楚的配置选项，应当先启用，以避免出现内核无法启动的情况。相信凡是自己构建（make）过内核的人对这一点都深有体会。如果使用localmodconfig就不再需要担心这个问题。localmodconfig既能够节约详细检查config选项的时间，又能缩短编译所花费的时间，为我们提供了强有力的支持。

—Munehiro IKEDA

第2章　资源管理

Linux内核的主要工作是资源管理。资源管理这一叫法看似简单，其实管理的资源是非常多样的，包括对CPU时间进行分配的进程调度、物理内存的分配与虚拟空间的控制、磁盘I/O等。本章将介绍Linux内核中的几个资源管理功能。其中Linux内核特有的Cgroup资源控制，就是能够进行虚拟化资源控制的重要功能。

HACK#7　Cgroup、Namespace、Linux容器

本节将介绍Cgroup与Namespace以及通过这两个功能实现的容器功能。

Cgroup

Cgroup（control group）是将任意进程进行分组化管理的Linux内核功能。Cgroup本身是提供将进程进行分组化管理的功能和接口的基础结构，I/O或内存的分配控制等具体的资源管理功能是通过这个功能来实现的。这些具体的资源管理功能称为Cgroup子系统或控制器。

Cgroup子系统有控制内存的Memory控制器、控制进程调度的CPU控制器等。运行中的内核可以使用的Cgroup子系统由/proc/cgroup来确认。

Cgroup提供了一个cgroup虚拟文件系统，作为进行分组管理和各子系统设置的用户接口。要使用Cgroup，必须挂载cgroup文件系统。这时通过挂载选项指定使用哪个子系统。这里指定debug这个没有实质功能的调试用子系统来挂载。

```
#mount-t cgroup-o debug cgroup/cgroup
```

注意事项：这里所说的“虚拟文件系统”，是指procfs和sysfs这种不具有物理设备的文件系统。并不是用来接纳文件系统差异的内核内部层layerVFS。

小贴士：关于cgroup文件系统的标准化挂载要点，是由开发论坛进行讨论的，但目前尚未得出结论。这里是挂载到/cgroup。

挂载后，在挂载位置下应该可以看到下列几个文件。这些是Cgroup呈现出来的特殊文件。

```
#ls/cgroup
```

```
cgroup.event_control debug.current_css_set debug.taskcount
cgroup.procs debug.current_css_set_cg_links notify_on_release
debug.cgroup_css_links debug.current_css_set_refcount release_agent
debug.cgroup_refcount debug.releasable tasks
```

文件名前缀为cgroup的以及没有前缀的文件是由Cgroup的基础结构提供的特殊文件。而前缀为debug的文件是由debug子系统提供的特殊文件。Cgroup的子系统提供的特殊文件都会像这样加上子系统的前缀。因此，根据挂载时指定的选项，即所使用的子系统不同，存在的特殊文件也不同。但是Cgroup的基础结构所提供的特殊文件则是无论指定哪种子系统都一直存在的。特殊文件分为只读文件和可读写文件。只读文件是为用户提供信息的文件。可读写的特殊文件通过写入值来更改Cgroup以及Cgroup子系统设置的文件。设置的值可以通过读入特殊文件来确认。在这些特殊文件中，最重要的是tasks特殊文件。其内容可以显示如下。＜/p＞

```
#cat/cgroup/tasks
1
2
3
4
……
```

虽然看上去只是一些数字的排列，但其实这些是属于这个分组的线程的线程ID（TID）。在这时，系统上运行的所有线程的TID都包含在/cgroup/tasks中。这就表示全部线程都属于这个分组。那么这里出现的“分组”又是什么呢？分组，就是体现为cgroup文件系统目录的线程的集合。由于/cgroup也是目录，因此它也表示一个分组。像这样位于挂载点最上层的目录是自动生成的分组，称为根分组。在这个阶段，只有/cgroup（即根分组）是系统上存在的唯一分组。

小贴士：英语中将通过Cgroup创建的分组称做cgroup，容易与表示结构的“Cgroup”混淆，所以这里仅称为“分组”。

下面尝试创建一个分组，也就是在/cgroup下创建子目录。其内容如下所示。

```
#mkdir/cgroup/test
#ls/cgroup/test
```

```
cgroup.event_control debug.current_css_set debug.taskcount
cgroup.procs debug.current_css_set_cg_links notify_on_release
debug.cgroup_css_links debug.current_css_set_refcount tasks
debug.cgroup_refcount debug.releasable
```

虽然是新生成的目录，但是已经有文件存在。cgroup文件系统在目录生成的同时就会在其中配置特殊文件。

/cgroup/test也和/cgroup一样有tasks。其内容如下。

```
#cat/cgroup/test/tasks
```

tasks的内容似乎是空的，这表示这个分组内一个线程也没有。可以将适当的线程添加到这个分组中。要将线程添加到分组中，可以在tasks中写入该线程的TID。这里以添加shell本身为例。

```
#echo$$
2474
#echo$$＞/cgroup/test/tasks
#cat/cgroup/test/tasks
2474
3821
```

tasks的内容中包含shell的TID（也是PID，即进程ID）—2474，可以看出这个shell已经属于test分组。除此以外，这个分组内还有另一个TID为3821的线程，这是什么呢？我们再来看一下tasks的内容。

```
#cat/cgroup/test/tasks
2474
3822
```

结果居然发生了变化。事实上这个改变的部分，是显示了tasks内容的cat进程的TID。最初的cat（3821）和第二次的cat（3822）是不同的进程，TID也不同，所以结果发生了变化。但是似乎并没有将cat进程添加到test分组中。其实，属于分组的进程一旦生成子进程，其子进程就会自动属于母进程。由于cat是shell的子进程，因此前者自动属于test分组。大家应该还记得，在挂载cgroup文件系统后，系统上的所有线程是属于根分组的。也

就是说，除了将明确指定为新生成分组内的进程为祖先进程以外，生成的进程都属于根分组。

这时，再显示/cgroup/tasks的内容的话，应该不会显示shell的TID（2474）。这是因为shell不属于根分组，而是属于test分组。然后，再将这个shell返回到根分组。

```
#echo 2474＞/cgroup/tasks
```

这样，shell的TID（2474）就再次属于/cgroup/tasks，而/cgroup/test/tasks就变空。如果分组中一个线程也没有，可以进行撤销。删除目录就可以撤销分组。

```
#rmdir/cgroup/test
```

表2-1是每个子系统中Cgroup都会提供的特殊文件列表。

表 2-1　Cgroup 提供的文件种类

文　件　名	R/W	用　　途
release_agent	RW	删除分组时执行的命令。这个文件只存在于根分组
notify_on_release	RW	设置是否执行 release_agent。为 1 时执行
tasks	RW	属于分组的线程 TID 列表
cgroup.procs	R	属于分组的进程 PID 列表。仅包括多线程进程的线程 leader 的 TID，这点与 tasks 不同
cgroup.event_control	RW	监视状态变化和分组删除事件的配置文件

这里仅介绍了最基本的Cgroup使用方法，也就是分组的创建、撤销和将线程添加到分组的方法。实际使用Cgroup时，应在将线程添加到分组后，在分组内的特殊文件中设置值，来控制系统的运行。

Namespace

使用Namespace（命名空间），可以让每个进程组具有独立的PID、IPC和网络空间。

可以向clone系统调用的第3个参数flags设置划分命名空间的标志，通过执行clone系统调用可以划分命名空间。

例如，划分PID命名空间后，在新生成的PID命名空间内进程的PID是从1开始的。从新PID为1的进程fork（）分叉得到的进程，被封闭到这个新的PID命名空间，与其他PID命名空间分隔开。在新创建的PID命名空间中生成的进程，其PID有可能与存在于原PID命名空间中的进程相同，但由于二者的PID命名空间划分开，就不存在相互影响。同样，也可以用PID、网络、文件系统的挂载空间、UTS（Universal Time sharing System）为对象进行资源划分。可以在clone系统调用的第3个参数中设置资源划分的种类，如表2-2所示。

表 2-2　资源划分

名　　称	说　　明
CLONE_NEWIPC	划分 IPC（进程间通信）命名空间。信号量（semaphore）、共享内存、消息队列等进程间通信用的资源
CLONE_NEWNET	划分网络命名空间。分配网络接口
CLONE_NEWNS	划分挂载的命名空间。与 chroot 同样分配新的根文件系统
CLONE_NEWPID	划分 PID 命名空间。分配新的进程 ID 空间
CLONE_NEWUTS	划分 UTS 命名空间。分配新的 UTS 空间

Linux容器

使用Cgroup和Namespace就可以实现容器。容器这个技术也称为操作系统虚拟化，是将一个内核所管理的资源划分成多个分组。

在容器中，CPU和内存资源是使用Cgroup来划分的。PID、IPC、网络等资源使用Namespace来划分。

LXC

Linux中实际安装的容器有LXC（Linux Container）。本节将以Fedora 14为例介绍LXC的使用方法。

```
#yum install lxc
```

要使用网络，还需要安装bridge-utils。

```
#yum install bridge-utils
```

在使用LXC之前，必须启用cgroup文件系统。使用下列命令挂载cgroup文件系统。

```
#mount-t cgroup cgroup/cgroup
```

另外，向/etc/fstab添加下列语句，就可以在系统启动时自动挂载cgroup文件系统。

```
cgroup/cgroup cgroup defaults 0 0
```

首先，将bash shell进程放进容器。

这里要为容器中使用的文件系统准备一个/lxc目录。

```
#mkdir/lxc
```

```
#cd/lxc
```

然后准备作为容器内的根文件系统的目录。

```
#mkdir rootfs
#cd rootfs
```

还需要准备其他必要的目录（这些目录主要使用bind mount）。

```
#mkdir bin dev etc lib lib64 proc sbin sys usr var
```

然后还要生成LXC的配置文件lxc.conf以及引用的fstab。

```
#vi/lxc/lxc.conf
lxc.utsname=lxc
lxc.rootfs=/lxc/rootfs
lxc.mount=/lxc/fstab
#vi/lxc/fstab
/bin/lxc/rootfs/bin none ro, bind 0 0
/sbin/lxc/rootfs/sbin none ro, bind 0 0
/lib/lxc/rootfs/lib none ro, bind 0 0
/lib64/lxc/rootfs/lib64 none ro, bind 0 0
/etc/lxc/rootfs/etc none ro, bind 0 0
/usr/lxc/rootfs/usr none ro, bind 0 0
/dev/lxc/rootfs/dev none rw, bind 0 0
/dev/pts/lxc/rootfs/dev/pts none rw, bind 0 0
/proc/lxc/rootfs/proc proc defaults 0 0
/sys/lxc/rootfs/sys sysfs defaults 0 0
```

准备工作完成后，使用lxc-create命令生成名为lxc的容器。

```
#lxc-create-n lxc-f/lxc/lxc.conf
```

使用lxc-ls命令可以确认容器列表。

```
#lxc-ls
lxc
```

使用lxc-create命令在lxc容器内执行bash。

```
#lxc-execute-n lxc bash
```

小贴士：在笔者的环境下，出现了终端的按键输入不显示的情况。发生这种情况时可以执行reset命令，终端的操作就会恢复。

```
bash 4.1#reset（不显示在画面上）
```

执行ps命令，就可以发现PID是从1开始的，除lxc容器以外看不到其他进程。

```
bash-4.1#ps aux
USER PID%CPU%MEM VSZ RSS TTY STAT START TIME COMMAND
root 1 0.1 0.1 14688 664 pts/0 S 21：34 0：00/usr/lib64/
lxc/lxc-init--bash
root 2 0.3 0.3 108440 1760 pts/0 S 21：34 0：00 bash
root 6 0.0 0.2 108120 1104 pts/0 R+21：34 0：00 ps aux
```

另外，生成的容器可以使用lxc-destroy命令来撤销。

```
#lxc-destroy-n lxc
```

接下来尝试启用网络，并启动sshd进程。然后，创建用来连接分配到容器的网络接口的网桥（关于网桥请参考Hack#24）。

在这个例子中将IP地址设置为192.168.20.254。

```
#brctl addbr br0
#ifconfg br0 192.168.20.254
```

然后，修改lxc.conf，添加网络设置。

```
#vi/lxc/lxc.conf
lxc.utsname=lxc
lxc.rootfs=/lxc/rootfs
lxc.mount=/lxc/fstab
lxc.network.type=veth
lxc.network.flags=up
lxc.network.link=br0
lxc.network.name=eth0
lxc.network.ipv4=192.168.20.1/24
```

启动sshd时需要下列目录，要事先创建。当该目录不存在时，从lxc-execute启动sshd

时就会失败。

```
#mkdir-p rootfs/var/empty/sshd
```

接下来生成容器。

```
#lxc-execute-n lxc/usr/sbin/sshd
```

这时打开其他终端，确认SSH服务器是否正在运行。

首先，使用ping命令确认网络是否已连接。

```
#ping 192.168.20.1
PING 192.168.20.1（192.168.20.1）56（84）bytes of data.
64 bytes from 192.168.20.1：icmp_req=1 ttl=64 time=0.899 ms
64 bytes from 192.168.20.1：icmp_req=2 ttl=64 time=0.174 ms
^C
```

使用ssh命令，连接分配到容器的IP地址192.168.20.1。

```
#ssh 192.168.20.1
root@192.168.20.1's password：
```

SSH连接已建立，输入密码后就成功登录。

通过ps命令所显示的进程来确认资源是否已被容器隔离。

```
-bash-4.1#ps auxw
USER PID%CPU%MEM VSZ RSS TTY STAT START TIME COMMAND
root 1 0.0 0.1 14688 660 pts/0 S+21：43 0：00/usr/lib64/lxc/
lxc-init--/usr/sbin/sshd
root 3 0.0 0.2 75104 1116?Ss 21：43 0：00/usr/sbin/sshd
root 4 1.4 0.8 108816 4068?Ss 21：47 0：00 sshd：root@pts/3
root 6 1.6 0.3 108440 1904 pts/3 Ss 21：47 0：00-bash
root 19 0.0 0.2 108124 1104 pts/3 R+21：47 0：00 ps auxw
-bash-4.1#ifconfg eth0
eth0 Link encap：Ethernet HWaddr 3A：A1：C2：A0：6F：1B
inet addr：192.168.20.1 Bcast：192.168.20.0 Mask：255.255.255.0
inet6 addr：fe80：38a1：c2ff：fea0：6f1b/64 Scope：Link
UP BROADCAST RUNNING MULTICAST MTU：1500 Metric：1
RX packets：280 errors：0 dropped：0 overruns：0 frame：0
TX packets：259 errors：0 dropped：0 overruns：0 carrier：0
collisions：0 txqueuelen：1000
```

```
RX bytes：31389（30.6 KiB）TX bytes：31373（30.6 KiB）
-bash-4.1#exit
logout
```

可以在其他终端执行lxc-stop，来关闭装有sshd的容器。

```
#lxc-stop-n lxc
```

然后运行debian。

使用debootstrap创建用来启动debian的根文件系统。deboot strap使用yum来安装。

```
#yum install debootstrap
```

创建debian的根文件系统，需要准备/debian。

```
#mkdir/debian
#cd/debian
```

现在执行debootstrap，生成debian lenny的文件系统。

```
#debootstrap--arch=amd64 lenny lenny
```

然后，准备LXC用的设置。

```
#vi/debian/lenny.conf
```

lxc. utsname=lenny

lxc. network.type=veth

lxc. network.flags=up

```
lxc.network.link=br0
lxc.network.name=eth0
lxc.network.ipv4=192.168.20.2/24
lxc.rootfs=/debian/lenny
lxc.mount=/debian/lenny.fstab
```

```
#vi/debian/lenny.fstab
devpts/debian/lenny/dev/pts devpts defaults 0 0
proc/debian/lenny/proc proc defaults 0 0
sysfs/debian/lenny/sys sysfs defaults 0 0
```

创建名称为lenny的容器。

```
#lxc-create-n lenny-f lenny.conf
```

所创建的容器可以通过lxc-start来启动。只到这一步的话，init虽然启动，但不能进行任何操作。这是因为刚执行debootstrap后，安装的仅是最低限度需要的数据包。这里为了让外部能够连接到容器，需要安装sshd。

```
#lxc-start-n lenny bash
```

debian环境的shell就会在容器内启动。然后使用apt-get安装openssh-server。

```
lenny：～#apt-get install openssh-server
```

另外，为了在SSH上进行登录，还需要设置root的密码。

```
lenny：～#passwd
```

在容器内启动lenny。

```
#lxc-start-n lenny
INIT：version 2.86 booting
Setting the system clock.
Cannot access the Hardware Clock via any known method.
Use the--debug option to see the details of our search for an access method.
Unable to set System Clock to：Fri Dec 10 22：59：45 UTC 2010（warning）.
Activating swap……done.
Setting the system clock.
Cannot access the Hardware Clock via any known method.
Use the--debug option to see the details of our search for an access method.
Unable to set System Clock to：Fri Dec 10 22：59：46 UTC 2010（warning）.
Cleaning up ifupdown……
Loading kernel modules……FATAL：Could not load/lib/modules/2.6.35.9-64.fc14.
x86_64/modules.dep：No such file or directory
Checking file systems……fsck 1.41.3（12-Oct-2008）
done.
Setting kernel variables（/etc/sysctl.conf）……done.
```

```
Mounting local filesystems……done.
Activating swapfile swap……done.
Setting up networking……
Configuring network interfaces……done.
INIT：Entering runlevel：2
Starting enhanced syslogd：rsyslogd.
Starting OpenBSD Secure Shell server：sshd.
Starting periodic command scheduler：crond.
```

我们尝试从其他终端使用SSH来连接。

```
#ssh 192.168.20.2
root@192.168.20.2's password：
lenny：～#
```

在debian环境下实施关闭（shutdown）的话，容器结束。

```
lenny：～#shutdown-h now
```

按照前面所述方法使用LXC就可以简单地创建容器。

小结

本节介绍了Linux内核的资源划分功能：划分CPU、内存空间、I/O等的Cgroup，以及划分PID、IPC、网络、mount命名空间的Namespace。另外，还介绍了实际安装上述资源划分功能的容器LXC。

参考文献

·man 2 clone

·man 2 unshare

·LXC

http://lxc. sourceforge.net/

http://www. ibm.com/developerworks/jp/linux/library/l-lxc-containers/

·debootstrap

http://www. debian.org/releases/stable/i386/apds03.html.ja

—Munehiro IKEDA, Hiroshi Shimamoto

HACK#8　调度策略

本节介绍Linux的调度策略（scheduling policy）。

Linux调度策略的类别大致可以分为TSS（Time Sharing System，分时系统）和实时系统这两种。

一方面，一般的进程是通过分时运行的。也就是说，使用CPU的时间达到分配给进程的时间（时间片）时，就会切换到其他进程。这种分时运行的调度策略称为TSS。

另一方面，在实时制约较严格且要求保证实时的处理中，就需要指定静态的执行优先级，并严格按照执行优先级进行调度。对这种对应答性有要求的进程，可以使用实时调度策略。另外，与TSS调度策略的进程相比，CPU将优先分配给使用实时调度策略的进程。

在Linux中，进程的静态优先级为0～99。TSS调度策略的优先级为0，实时调度策略的优先级可以指定的范围为1～99。

Linux 2. 6.23以前一直采用的O（1）调度程序，还会在TSS调度策略中添加动态优先级。长时间持续使用CPU的进程，其调度的动态优先级会渐渐降低。Linux的进程调度程序是按照优先级来分配CPU的，因此长时间占用CPU的进程优先级与其他进程相比就相对较低。与之相对的是，频繁与用户进行交流的shell等对话进程由于CPU使用时间短，其调度的优先级变高，更容易分配到CPU。因此，为等待用户输入而立刻腾出CPU的shell进程的优先级变得比其他进程高，用户的应答性就得到提高。

在Linux 2.6.23导入的CFS（Completely Fair Scheduler）调度程序中，没有之前的O（1）调度程序所进行的经验性优先级变化。CFS通过称为公平的CPU时间分配的结构来运行。

调度策略

RHEL6（Linux 2. 6.32）中定义了下列调度策略。

SCHED_OTHER
SCHED_FIFO
SCHED_RR
SCHED_BATCH
SCHED_IDLE

下面将分别对各调度策略进行介绍。

SCHED_OTHER

这是Linux的标准调度策略，也是所谓TSS调度策略。

在RHEL5等Linux 2.6.23之前的内核所使用的以优先级为基础的O（1）调度程序中，还加入了经验性的判断，优先为会话进程赋予执行权。TSS的时间片由优先级决定。

在RHEL6等Linux 2.6.23之后的CFS中，会公平地为所有TSS策略的进程分配CPU时间。其时间片是动态决定的。

SCHED_FIFO

这是实时调度策略，即具有静态优先级的调度策略。Linux内核中能够为实时调度策略的进程指定的优先级为1～99。使用了SCHED_FIFO调度策略的进程，除了等待I/O完成时休眠、自发休眠或优先级更高的实时进程获得优先权以外，不会释放执行权。

使用SCHED_FIFO的实时调度策略时，需要注意的是，它的进程不会自动释放CPU，也就是说执行权不会转移到其他进程。例如，实时调度策略的进程陷入无限循环时，其他所有优先级较低的进程永远不会被赋予执行权，此时系统就会死机。

小贴士：另外，要对进程使用实时调度策略，必须有root权限。

SCHED_RR

这也是实时调度策略。RR是round robin（轮询）的缩写，与SCHED_FIFO不同的是，

它具有时间片。时间片使用完时，执行权将转移到其他进程。

在2.6.23以前导入的O（1）调度程序中，时间片是由优先级决定的。

引入CFS时SCHED_RR的调度策略也进行了修改，时间片变为固定值（100毫秒）。

SCHED_BATCH

指定这个调度策略的进程不是会话型，不会根据休眠时间更改优先级。

例如，备份处理等需要进行较大文件或大量文件存取的进程，是通过磁盘I/O来中止的。在TSS调度策略中，因为这个休眠，正在进行备份处理的进程优先级提高，需要应答性的shell等的优先级相对降低。这就会导致系统的应答性降低。

在RHEL5的O（1）调度程序中，使用了这个调度策略的进程被识别为休眠时间为0的CPU bound进程。因此，优先级必然会变成比会话型shell进程低。

对非会话型的进程（即所谓的补丁处理）使用这个调度策略，就可以使会话型进程的优先级保持相对较高，并确保应答性。

在Linux 2.6.23导入的CFS中，对进行补丁处理的进程改变了处理的方法，优先级不会因休眠时间而发生变化。在导入CFS的RHEL6中，SCHED_BATCH和SCHED_OTHER几乎没有区别，因此可以不使用。

SCHED_IDLE

这是由CFS导入的新等级。CPU空闲时，即SCHED_IDLE等级以外处于可执行状态的进程消失时，将被赋予执行权。也就是它将成为优先级最低的进程。

特殊标志：SCHED_RESET_ON_FORK

为了限制实时调度策略的进程运行，而为调度策略添加了标志flag。设置了标志flag的实时调度策略进程，在执行fork（）时，新生成的子进程就成为SCHED_OTHER策略的

进程。

如下例所示，通过向实时调度策略添加标志flag来设置。

```
sched_setscheduler（pid, SCHED_FIFO|SCHED_RESET_ON_FORK，＆param）；
```

关于调度策略的系统调用

关于调度策略的系统调用如下所示。

sched_setscheduler（）

更改调度策略和进程优先级。

sched_getscheduler（）

获取当前调度策略与进程优先级。

sched_setparam（）

更改调度参数（即进程优先级）。

sched_getparam（）

获取当前调度参数。

sched_get_priority_max（） sched_get_priority_min（）

获取调度策略的进程的静态优先级范围。

sched_rr_get_interval（）

获取当前时间片。

chrt命令

用户使用chrt命令可以很简单地更改调度策略。RHEL5版本的chrt命令中不存在指定SCHED_IDLE的-i选项。

在CentOS5（RHEL5）中chrt的使用方法如下所示。

```
$chrt--help
chrt（util-linux 2.13-pre7）
usage：chrt[options][prio][pid|cmd[args……]]
manipulate real-time attributes of a process
-b，--batch set policy to SCHED_BATCH
-f，--fifo set policy to SCHED_FF
-p，--pid operate on existing given pid
-m，--max show min and max valid priorities
-o，--other set policy to SCHED_OTHER
-r，--rr set policy to SCHED_RR（default）
-h，--help display this help
-v，--verbose display status information
-V，--version output version information
```

下面是Fedora 12（RHEL6）中chrt的使用方法。

```
$chrt--help
chrt-manipulate real-time attributes of a process.
Set policy：
chrt[options]＜policy＞＜priority＞{＜pid＞|＜command＞[＜arg＞……]}
Get policy：
chrt[options]{＜pid＞|＜command＞[＜arg＞……]}
Scheduling policies：
-b|--batch set policy to SCHED_BATCH
-f|--fifo set policy to SCHED_FIFO
-i|--idle set policy to SCHED_IDLE
-o|--other set policy to SCHED_OTHER
-r|--rr set policy to SCHED_RR（default）
Options：
-h|--help display this help
-p|--pid operate on existing given pid
-m|--max show min and max valid priorities
-v|--verbose display status information
-V|--version output version information
```

使用chrt命令，可以更改进程的调度策略和优先级。例如，使用SCHED_IDLE解压缩内核源代码存档时的命令行如下所示。

```
$chrt-i o tar jxf linux-2.6.33.tar.bz2
```

正在运行的进程的调度策略也可以通过指定目的进程的PID来更改。

```
#chrt-p-r 99＜pid＞
```

另外，使用实时调度策略，必须具有root权限。

小结

本节介绍了可以使用Linux进程调度程序指定的调度策略。可以尝试修改对备份处理和要求实时性的进程的调度策略。

参考文献

·CFS

http://www. ibm.com/developerworks/jp/linux/library/l-cfs/?ca=dnj-0208

·man sched_setscheduler他

http://www. linux.or.jp/JM/html/LDP_man-pages/man2/sched_setscheduler.2.html

—Hiroshi Shimamoto

HACK#9　RT Group Scheduling与RT Throttling

本节介绍对实时进程所使用的CPU时间进行限制的功能RT Group Scheduling和RT Throttling。

RT Group Scheduling和RT Throttling功能是用来限制使用实时调度策略的进程的CPU时间。内核2.6.25以后的版本都可以使用这个功能。

本节将介绍如何使用RT Scheduling和RT Throttling来限制实时进程的CPU时间。

为了让Linux系统能够应用到需要实时性的领域，Linux的进程调度程序采用的是实时调度策略（参考Hack#8）。

实时调度策略具有静态优先级，调度的优先级比其他一般进程高，需要执行时一定会分配CPU时间。如果实时进程陷入无限循环，就会占用CPU，其他处理完全无法运行。

该功能通过限制实时进程的CPU时间，使执行权即使在这种情况下也能切换到其他进程，可以避免产生系统死机的问题。

实时

实时功能的目的是实现满足实时限制的处理，即，在有限时间内得到处理结果。也就是将对特定事件进行处理的延迟控制在一定时间以内，在有意义的时间内一定作出应答的功能。因此，即使在内核运行过程中，也能迅速切换到要处理事件的进程。因此内核内部设置了优先权点（preemption point），可以根据事件立刻切换到实时进程。

要求实时性的处理，如图形处理。在实时图形处理中，画面更新的处理应当配合显示器上显示的刷新来进行。这个实时处理中重要的是要在一定时间（刷新率）内完成图形处理。

分配CPU时间提高吞吐量的目的和实时的目的是不同的，这点经常容易混淆。

RT Throttling

RT Throttling是对分配给实时进程的CPU时间进行限制的功能。使用实时调度策略的进程由于bug等出现不可控错误时，完全不调度其他进程，系统就会无响应。通过限制分配给实时进程的每个单位时间的CPU时间，就可以防止使用实时调度策略的进程出现bug。

还可以指定单位时间内分配多少CPU时间给实时进程。标准设置的单位时间是1秒，CPU分配时间是0.95秒，非实时进程每1秒也可以使用CPU 0.05秒。

可是对分配给实时进程的CPU时间进行限制，会不会对实时处理造成影响呢？答案是不会。正如在关于实时性的介绍中提到的，对某个处理使用实时策略，是为了满足实时限制，即在一定时间内完成处理。如果对实时性有要求的进程占用CPU时间，就不能实现实时性。

为使用实时调度策略的进程的处理分配所必需的或实时限制量的CPU时间，就可以防止系统的实时进程出现不可控错误等意外情况。

系统的整体设置

整个系统的CPU时间设置可以使用sysctl来获取、设置。最近的内核都可以通过sysctl来限制实时进程能够使用的CPU时间。

下列为获取当前值的例子。这个例子中使用的是标准设置，单位时间为1秒，CPU分配时间为0.95秒。

```
$sysctl-n kernel.sched_rt_period_us
1000000
$sysctl-n kernel.sched_rt_runtime_us
950000
```

设置示例

要将CPU分配时间改为0.9秒，可以执行下列操作。

```
#sysctl-w kernel.sched_rt_runtimes_us=900000
```

另外，将CPU分配时间指定为-1，对实时进程的CPU时间限制就会消失。这与内核导入该功能之前的行为是一样的。

```
#sysctl-w kernel.sched_rt_runtime_us=-1
```

当然，也可以从proc文件系统存取。

```
/proc/sys/kernel/sched_rt_period_us
/proc/sys/kernel/sched_rt_runtime_us
```

当CONFIG_RT_GROUP_SCHED有效时，受到Cgroup设置值的限制，不能进行与Cgroup中的有效值相矛盾的设置。但是在这里，将sched_rt_runtime_us设置为-1，是用来使RT Throttling失效的设置。

一般来说，sysctl中的设置仅用于有效（启用）与无效（关闭）的切换，单个设置需要使用Cgroup来进行。

Cgroup中的设置

RT Group Scheduling是Cgroup的子系统。要使用RT Group Scheduling，必须启用CONFIG_RT_GROUP_SCHED。可以与其他Cgroup一样通过cgroup文件系统进行设置（参考Hack#7）。

```
#mount-t cgroup cgroup/cgroup
```

与RT Group Scheduling相关的项目有下面两个。可以对每个分组分别设置RT throttling的单位时间与CPU分配时间。

```
cpu.rt_period_us
```

cpu.rt_runtime_us

小结

在需要实时性的领域，必须向进程赋予实时调度策略，将延迟控制在一定数量以下。但是，实时进程因bug等发生不可控错误时，就可能出现系统自身无法应答的情况。

使用RT Group Scheduling功能，可以仅分配实时进程真正需要的CPU时间，从而防止系统进程发生不可控错误等。

参考文献

·Documentation/scheduler/sched-rt-group. txt

—Hiroshi Shimamoto

HACK#10　Fair Group Scheduling

本节介绍Cgroup之一、管理CPU资源的Fair Group Scheduling。

Fair Group Scheduling

Fair Group Scheduling是Cgroup的资源管理之一，用来控制Linux内核的进程调度程序进行的CPU时间分配。与其他Cgroup进行的资源管理一样，可以对每个特定进程组进行资源（CPU分配时间）管理。使用这个功能，就可以在分组间对CPU分配时间进行调整。

另外，Fair Group Scheduling使用的是Linux 2.6.23以后引入的CFS（Completely Fair Scheduler）的CPU分配时间控制功能，因此在没有安装CFS的Linux 2.6.23之前版本的内核中不能使用。因此，本节介绍怎样通过CFS对非实时调度策略进程的CPU分配进行控制。

Fair Group Scheduling的使用方法

下面通过实例来讲解Fair Group Scheduling的使用方法。

使用前，需要挂载和安装Cgroup文件系统。由于使用了Cgroup进行资源控制，因此挂载时需要启用CPU资源控制。

```
#mount-t cgroup-o cpu cgroup/cgroup
```

在本示例中将创建两个控制CPU资源的分组，分别为GroupA、GroupB。

```
#mkdir/cgroup/GroupA
#mkdir/cgroup/GroupB
```

为GroupA、GroupB这两个分组分配进程，从而在各分组间公平分享CPU时间。也就是说，GroupA和GroupB的CPU使用率都是50%。

然后，确认一下实际的CPU时间分配是否公平。打开一个新的终端，将shell进程分配给GroupA。

```
#echo$$＞/cgroup/GroupA/tasks
```

然后，在这个shell上形成死循环，使CPU利用率达到100%。

```
#while：；do true；done
```

接着，向GroupB分配新的shell进程，在shell上形成死循环，使GroupB中的CPU使用率也达到100%。

```
#echo$$＞/cgroup/GroupB/tasks
#while：；do true；done
```

在这个状态下使用top命令确认CPU使用率，可以发现各分组中shell（bash）的CPU使用率基本都是50%，GroupA和GroupB分别使用一半的CPU资源。

```
top-03：53：13 up 1 day，19：07，4 users, load average：1.35，0.42，0.14
Tasks：115 total，3 running，112 sleeping，0 stopped，0 zombie
Cpu（s）：100.0%us，0.0%sy，0.0%ni，0.0%id，0.0%wa，0.0%hi，0.0%si，
0.0%st
Mem：1021532k total，497896k used，523636k free，80220k buffers
Swap：2064376k total，0k used，2064376k free，204004k cached
PID USER PR NI VIRT RES SHR S%CPU%MEM TIME+COMMAND
8333 root 20 0 105m 1856 1444 R 50.2 0.2 0：37.83 bash
8342 root 20 0 105m 1820 1424 R 49.9 0.2 0：32.43 bash
```

然后，向其中一个分组添加进程，并确认分组间（GroupA和GroupB）的CPU资源分配为各50%。

打开一个新的终端，向GroupB添加shell进程。同样，在这个shell上形成死循环，使CPU使用率达到100%。

```
#echo$$＞/cgroup/GroupB/tasks
#while：；do true；done
```

这时使用top命令将显示下列结果。

```
top-03：54：07 up 1 day，19：08，4 users, load average：1.89，0.71，0.25
Tasks：115 total，4 running，111 sleeping，0 stopped，0 zombie
Cpu（s）：100.0%us，0.0%sy，0.0%ni，0.0%id，0.0%wa，0.0%hi，0.0%si，0.0%st
Mem：1021532k total，497896k used，523636k free，80228k buffers
Swap：2064376k total，0k used，2064376k free，204008k cached
PID USER PR NI VIRT RES SHR S%CPU%MEM TIME+COMMAND
8333 root 20 0 105m 1856 1444 R 49.9 0.2 1：04.86 bash
8342 root 20 0 105m 1820 1424 R 24.9 0.2 0：57.64 bash
8354 root 20 0 105m 1852 1448 R 24.9 0.2 0：01.82 bash
```

可以看出GroupA和GroupB都为50%，并且GroupB中的两个shell进程也各占25%。再确认一下，是否即使再向GroupB添加其他进程，也不会对分配给GroupA的CPU时间产生影响。

同样，添加终端，将shell分配给GroupB，并形成死循环。

```
#echo$$＞/cgroup/GroupB/tasks
#while：；do true；done
```

从top命令的结果可以看出，向GroupA分配了50%，剩下的50%被GroupB的3个进程均分。

```
top-03：57：11 up 1 day，19：11，5 users, load average：3.22，1.88，0.79
Tasks：116 total，5 running，111 sleeping，0 stopped，0 zombie
Cpu（s）：99.7%us，0.3%sy，0.0%ni，0.0%id，0.0%wa，0.0%hi，0.0%si，0.0%st
Mem：1021532k total，498648k used，522884k free，80260k buffers
Swap：2064376k total，0k used，2064376k free，204008k cached
PID USER PR NI VIRT RES SHR S%CPU%MEM TIME+COMMAND
8333 root 20 0 105m 1856 1444 R 49.9 0.2 2：38.69 bash
8342 root 20 0 105m 1824 1424 R 16.9 0.2 1：36.27 bash
8354 root 20 0 105m 1856 1448 R 16.6 0.2 0：39.11 bash
8368 root 20 0 105m 1824 1424 R 16.6 0.2 0：14.23 bash
```

以上就是在分组间平分CPU资源的方法。

cpu. shares

下面介绍cpu.shares特殊文件。在启用CPU资源控制的Cgroup文件系统中，为Fair Group Scheduling准备了cpu.shares文件。

```
#ls/cgroup/GroupA
cgroup.procs cpu.rt_runtime_us notify_on_release
cpu.rt_period_us cpu.shares tasks
```

在cpu.shares文件中，可以对进程调度程序所处理的进程组设置CPU时间分配的比重。通过修改这个值，就可以在分组间调整CPU时间的比例。默认值为1024。

```
#cat/cgroup/GroupA/cpu.shares
1024
```

这里将GroupB的cpu.shares设置为GroupA的一半，即512。

```
#echo 512＞/cgroup/GroupB/cpu.shares
```

在CPU资源分配中，GroupA的比重变为1024，GroupB的比重变为512。因此，分配给

GroupA的时间就是GroupB的2倍。使用top命令，确认分配给刚才启动的shell进程的CPU资源。

```
top-04：07：40 up 1 day，19：22，5 users, load average：4.00，3.73，2.34
Tasks：116 total，5 running，111 sleeping，0 stopped，0 zombie
Cpu（s）：100.0%us，0.0%sy，0.0%ni，0.0%id，0.0%wa，0.0%hi，0.0%si，0.0%st
Mem：1021532k total，481024k used，540508k free，80348k buffers
Swap：2064376k total，0k used，2064376k free，204012k cached
PID USER PR NI VIRT RES SHR S%CPU%MEM TIME+COMMAND
8333 root 20 0 105m 1856 1444 R 66.5 0.2 7：54.18 bash
8342 root 20 0 105m 1824 1424 R 11.3 0.2 3：20.07 bash
8354 root 20 0 105m 1856 1448 R 11.0 0.2 2：22.90 bash
8368 root 20 0 105m 1824 1424 R 11.0 0.2 1：58.02 bash
```

可以发现，GroupA变成66%，GroupB变成33%，并且在GroupB中，3个shell进程分别占用11%。

小结

本节介绍了Fair Group Scheduling。它能以进程组为单位控制CPU资源分配，将CPU时间平分给多个用户，使特定处理不会对其他处理造成一定程度上的影响。

—Hiroshi Shimamoto

HACK#11 cpuset

本节介绍控制物理CPU分配的cpuset。

cpuset是Linux控制组（Cgroup）之一，其功能是指定特定进程或线程所使用的CPU组。另外，除CPU以外，同样还能指定内存节点的分配。

以前的内核具有CPU affinity功能，该功能将线程分配给特定CPU。现在的内核中虽然也有affinity（taskset命令），但推荐使用cpuset。

用法

使用cpuset前，必须通过内核config启用cpuset功能。

```
CONFIG_CPUSETS=y
```

最近的发布版在标准中就已启用。cpuset就是作为Cgroup提供的一个功能。因此，使用cpuset时，就需要挂载Cgroup文件系统。使用下列方法启用cpuset选项，挂载Cgroup后，就可以使用cpuset（参考Hack#7）。

```
#mount-o cpuset-t cgroup cgroup/cgroup
```

在这里创建一个新的CPU分配组GroupA。与其他Cgroup同样在挂载的Cgroup下创建新目录GroupA，作为分组GroupA。

```
#mkdir/cgroup/GroupA
```

编辑新创建分组GroupA的cpuset，修改CPU分配情况。这里以仅将CPU0分配给分组GroupA的情况为例进行说明。在分组GroupA下的特殊文件cpuset.cpus内写入要分配的CPU编号，使用下列命令，来控制分组的cpuset。

```
#echo 0＞/cgroup/GroupA/cpuset.cpus
```

到这一步，就完成了仅使用CPU0作为GroupA的CPU分配的设置。

接下来，在这个分组GroupA中添加进程。这里将当前shell添加到GroupA中。使用下列命令，将PID（$$表示shell本身的PID）写入GroupA下的task文件。

```
#echo$$＞/cgroup/GroupA/task
```

此后由当前shell启动的进程全部在这个GroupA下，使用的CPU仅限于0号CPU。

现在确认所使用的CPU数量是否受限，以及产生的效果如何。本节显示的是以Fedora 12为例的情况。

本示例中使用的Fedora 12内核如下。

#uname-a

```
Linux fedora12 2.6.31.12-174.2.22.fc12.x86_64#1 SMP Fri Feb 19 18：55：03 UTC 2010
x86_64 x86_64 x86_64 GNU/Linux
```

如果使用cpuset改变所使用的CPU数量会怎么样？比较内核的编译时间。

首先准备好要进行比较的编译。为了避免磁盘性能的影响，首先创建内存文件系统tmpfs，并在其中配置源文件。创建目录/tmp/build，挂载tmpfs，命令如下所示。

```
#mkdir/tmp/build
#mount-t tmpfs none/tmp/build
```

本次测量的是内核源代码每次在创建的tmpfs下解压缩tarball时，使用默认config所花费的内核编译时间。使用的一系列命令行如下。

```
#cd/tmp/build/
#tar jxf/ext4data/kernel/linux-2.6.33.tar.bz2
#cd linux-2.6.33/
```

```
#make defconfg
#time make-j 2
```

首先测量Linux 2.6.33的编译时间。

将Cgroup挂载到/cgroup，创建分组GroupA。

```
#mount-o cpuset-t cgroup cgroup/cgroup
#mkdir/cgroup/GroupA
```

接下来看一下向分组GroupA分配两个CPU时的结果。

```
#echo"0-1"＞/cgroup/GroupA/cpuset.cpus
#echo 0＞/cgroup/GroupA/cpuset.mems mems默认为空，因此需要填入值
#echo$$＞/cgroup/GroupA/tasks
```

编译时间如下。

```
#time make-j 2
real 4m55.568s
user 2m42.066s
sys 5m4.575s
```

然后将CPU缩减到只有0号CPU。

```
#echo 0＞/cgroup/GroupA/cpuset.cpus
#echo 0＞/cgroup/GroupA/cpuset.mems
#echo$$＞/cgroup/GroupA/tasks
#mount-t tmpfs none/tmp/build
#cd/tmp/build/
#tar jxf/ext4data/kernel/linux-2.6.33.tar.bz2
#cd linux-2.6.33/
#make defconfg
#time make-j 2
real 7m44.491s
user 2m47.319s
sys 4m56.737s
```

可以看到，CPU数量变为1，实际花费的时间（real）增加。

下面以对虚拟化（KVM）进程所使用的CPU进行限制的情况为例，看一下将分配给KVM进程的CPU固定，并确保主机操作系统能够一直使用CPU后，是否能够减少虚拟化

的影响。

这个示例同样使用Fedora 12。

首先使用KVM，启动两个客户端操作系统。然后，在客户端操作系统中循环进行内核编译，加大CPU负载。

在解压缩Linux 2.6.33源代码的目录下，无限循环执行make clean和make命令，增加客户端操作系统的CPU负载。

```
hshimamoto@ubuntu：～/kernel/linux-2.6.33$while：；do make clean；time make；done
hshimamoto@opensuse：～/kernel/linux-2.6.33＞while：；do make clean；time make；done
```

在这种情况下计算主机操作系统上的内核编译时间。同前例一样，需要创建tmpfs，消除磁盘性能的影响后再进行测量。计算结果如下。

```
#time make-j 2
real 8m20.468s
user 2m45.890s
sys 4m51.091s
```

然后，将KVM的qemu-kvm进程可以使用的CPU设置为只有0号CPU。

```
#mount-o cpuset-t cgroup cgroup/cgroup
#mkdir/cgroup/kvm
#echo 0＞/cgroup/kvm/cpuset.meme将kvm分组的cpuset设为只有0
#echo 0＞/cgroup/kvm/cpuset.cpus
```

将启动中的qemu-kvm移动到kvm分组。

```
#ps x|grep qemu
2495 pts/2 Sl+238：37 qemu-kvm
2628 pts/3 Sl+255：33 qemu-kvm
#for i in'\ls/proc/2495/task/'；do echo$i＞/cgroup/kvm/tasks；done
#for i in'\ls/proc/2628/task/'；do echo$i＞/cgroup/kvm/tasks；done
```

另外，ksmd（参考Hack#36）也使用CPU，因此这里也将其加入kvm分组。

```
#ps ux|grep ksmd
root 35 2.2 0.0 0 0?SN Mar23 119：42[ksmd]
#echo 35＞/cgroup/kvm/tasks
```

现在，主机操作系统的内核编译时间就变成如下所示。

```
#time make-j 2
real 7m55.081s
user 2m43.303s
sys 5m12.039s
```

可以发现，内核编译所花费的实际时间减少了接近30秒。

这是因为虚拟化的KVM进程只在CPU0上运行，在主机操作系统上就可以使用100%的CPU。

小结

本节介绍了使用Linux中的Cgroup的cpuset。通过使用这个功能，就可以限制特定进程所使用的CPU。从另一个角度来看，通过固定使用的CPU，还可以提高缓存的利用效率和性能。

—Hiroshi Shimamoto

HACK#12　使用Memory Cgroup限制内存使用量

Memory Cgroup是Cgroup的资源限制功能之一，可以控制特定进程可以使用的内存量。

Memory Cgroup

Memory Cgroup是Cgroup（参考Hack#7）之一，用来控制进程所使用的内存（LRU管理的缓存）数量。

其用法有很多种，例如，可以用来避免因一时处理较大文件或大量文件，而导致无用的页面缓存增大，内存资源紧张的情况。另外，还可以在多用户环境中限制各用户可以使用的内存量。

用法

Memory Cgroup是Cgroup的一种，因此使用前必须挂载cgroup文件系统。启用Memory Cgroup时，可以为挂载命令指定memory选项，也可以不指定选项以启用Cgroup的所有功能。

本节使用下列方式挂载到/cgroup。

```
#mount-t cgroup-o memory memcg/cgroup
```

挂载cgroup后，通过在/cgroup下创建新目录来创建新的分组。Memory Cgroup可以通过对该目录下的文件设置参数，来控制内存使用量。

另外，能否通过Cgroup文件系统控制以及特殊文件的种类多少，会根据内核版本和内核config的不同有所差异。

Cgroup文件系统中关于Memory Cgroup配置的主要特殊文件如表2-3所示。

表2-3　关于Memory Cgroup的主要文件

表 2-3　关于 Memory Cgroup 的主要文件

文 件 名	说　明
memory.usage_in_bytes	显示当前内存（进程内存＋页面缓存）的使用量
memory.memsw.usage_in_bytes	显示当前内存（进程内存＋页面缓存）＋交换区使用量
memory.limit_in_bytes	设置、显示内存（进程内存＋页面缓存）使用量的限制值
memory.memsw.limit_in_bytes	设置、显示内存（进程内存＋页面缓存）＋交换区使用量的限制值
memory.falicnt	显示内存（进程内存＋页面缓存）达到限制值的次数
memory.memsw.failcnt	显示内存（进程内存＋页面缓存）＋交换区到达限制值的次数
memory.max_usage_in_bytes	显示记录的内存（进程内存＋页面缓存）使用量的最大值
memory.memsw.max_usage_in_bytes	显示记录的内存（进程内存＋页面缓存）＋交换区使用量的最大值
memory.stat	输出统计信息，详细内容后面叙述
memory.force_empty	强制释放分配给分组的内存
memory.use_hierarchy	设置、显示层次结构的使用
memory.swappiness	设置、显示针对分组的 swappiness（相当于 sysctl 的 vm.swappiness）

限制内存使用量

内存使用量可以使用memory.limit_in_bytes进行限制。这里创建一个名称为GroupA的分组，尝试将内存使用量限制为10MB。可以通过如下命令行实现。

```
#mkdir/cgroup/GroupA
#echo 10M＞/cgroup/GroupA/memory.limit_in_bytes
#echo$$＞/cgroup/GroupA/tasks
```

下面看一下Memory Cgroup限制内存使用量的效果。

1.获取较大的文件

首先，看一下不对内存使用量进行限制时的结果。

```
# free
             total       used       free     shared    buffers     cached
Mem:       1021532     415728     605804          0      24260     141764
-/+ buffers/cache:     249704     771828
Swap:      2064376          0    2064376

# wget http://ftp.yz.yamagata-u.ac.jp/pub/linux/centos/5.6/isos/x86_64/CentOS-
5.6-x86_64-LiveCD.iso
--2011-04-19 00:35:27--  http://ftp.yz.yamagata-u.ac.jp/pub/linux/centos/5.6/
isos/x86_64/CentOS-5.6-x86_64-LiveCD.iso
Resolving ftp.yz.yamagata-u.ac.jp... 133.24.255.153, 133.24.255.161
Connecting to ftp.yz.yamagata-u.ac.jp|133.24.255.153|:80... connected.
HTTP request sent, awaiting response... 200 OK
Length: 733669376 (700M) [application/x-iso9660-image]
Saving to: "CentOS-5.6-x86_64-LiveCD.iso"

100%[======================================>] 733,669,376  496K/s   in 22m 44s

2011-04-19 00:58:11 (525 KB/s) - "CentOS-5.6-x86_64-LiveCD.iso" saved
[733669376/733669376]

# free
             total       used       free     shared    buffers     cached
Mem:       1021532     957288      64244          0      12944     676844
-/+ buffers/cache:     267500     754032
Swap:      2064376          0    2064376
```

从free来看，原本有约600MB的空闲内存减少到约60MB。而cached的值大幅增加，可

以看出对wget命令获取的约700MB的文件进行缓存时使用了空闲内存。

下面看一下将内存使用量限制为10MB时的结果。

```
# free
             total       used       free     shared    buffers     cached
Mem:       1021532     419988     601544          0      23280     154960
-/+ buffers/cache:     241748     779784
Swap:      2064376          0    2064376

# wget http://ftp.yz.yamagata-u.ac.jp/pub/linux/centos/5.6/isos/x86_64/CentOS-
5.6-x86_64-LiveCD.iso
--2011-04-19 23:04:47--  http://ftp.yz.yamagata-u.ac.jp/pub/linux/centos/5.6/
isos/x86_64/CentOS-5.6-x86_64-LiveCD.iso
Resolving ftp.yz.yamagata-u.ac.jp... 133.24.255.153, 133.24.255.161
Connecting to ftp.yz.yamagata-u.ac.jp|133.24.255.153|:80... connected.
HTTP request sent, awaiting response... 200 OK
Length: 733669376 (700M) [application/x-iso9660-image]
Saving to: "CentOS-5.6-x86_64-LiveCD.iso"

100%[======================================>] 733,669,376  579K/s   in 24m 4s

2011-04-19 23:28:51 (496 KB/s) - "CentOS-5.6-x86_64-LiveCD.iso" saved

# free
             total       used       free     shared    buffers     cached
Mem:       1021532     432732     588800          0      25744     164656
-/+ buffers/cache:     242332     779200
Swap:      2064376          0    2064376
```

从free命令中cached的差别可以看出内存使用量限制在约10MB。

2.备份处理

在通过tar命令创建数据库时也可以使用。以Linux内核源代码数据库为例进行说明。

不限制内存使用量时：

```
# free; tar cf linux.tar linux; free
             total       used       free     shared    buffers     cached
Mem:       1021532     286136     735396          0      20144     110392
-/+ buffers/cache:     155600     865932
Swap:      2064376          0    2064376
             total       used       free     shared    buffers     cached
Mem:       1021532     949472      72060          0      20644     718776
-/+ buffers/cache:     210052     811480
Swap:      2064376          0    2064376
```

内存使用量限制为10MB时：

```
# free; tar cf linux.tar linux; free
             total       used       free     shared    buffers     cached
Mem:       1021532     288760     732772          0      20204     110372
-/+ buffers/cache:     158184     863348
Swap:      2064376          0    2064376
             total       used       free     shared    buffers     cached
Mem:       1021532     340476     681056          0      21732     118752
-/+ buffers/cache:     199992     821540
Swap:      2064376          0    2064376
```

可以发现内存同样限制为10MB。

层次结构

通过Memory Cgroup控制的分组可以采用层次结构。可以在memory.use_hierarchy中写入1，启用分组的层次结构。

```
#echo 1＞/cgroup/memory.use_hierarchy
```

例如，通过执行下列命令审校者注1，可以创建如图2-1所示的分组结构。

```
#mkdir/cgroup/A
#echo 100M＞/cgroup/A/memory.limit_in_bytes
#mkdir/cgroup/A/{B1，B2}
#echo 70M＞/cgroup/A/B1/memory.limit_in_bytes
#echo 30M＞/cgroup/A/B2/memory.limit_in_bytes
#mkdir/cgroup/A/B1/{C11，C12}
```

审校者注1：下面的第1、3、6、9行命令原书有误，应该加上“-p”参数。

```
#echo 40M＞/cgroup/A/B1/C11/memory.limit_in_bytes
#echo 30M＞/cgroup/A/B1/C12/memory.limit_in_bytes
#mkdir/cgroup/A/B2/{C21，C22}
#echo 20M＞/cgroup/A/B2/C21/memory.limit_in_bytes
#echo 10M＞/cgroup/A/B2/C22/memory.limit_in_bytes
```

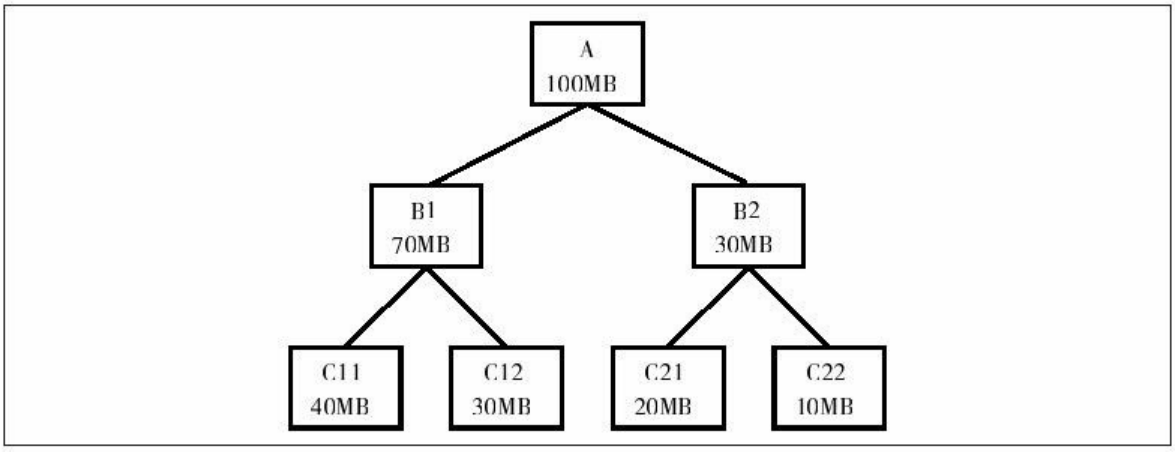

图　2-1　创建的分组结构

显示统计信息

关于各分组内存使用量的统计信息可以从memory.stat文件中读取（见表2-4）。

表2-4　内存使用量的统计信息

表 2-4　内存使用量的统计信息

名　称	说　明
cache	页面缓存量（字节数）
rss	匿名页面与交换区缓存的内存量（字节数）
mapped_file	指向进程空间的文件映射所使用的内存量（字节数）
pgpgin	页面换入次数
pgpgout	页面换出次数
swap	交换区使用量（字节数）
inactive_anon	LRU 列表中无效的匿名页面（字节数）
active_anon	LRU 列表中有效的匿名页面（字节数）
inactive_file	LRU 列表中无效的文件缓存（字节数）
active_file	LRU 列表中有效的文件缓存（字节数）
unevictable	不能用 mlock 等回收的内存量（字节数）

下列内容在使用层次结构时有效，将显示层次结构中处于上层的分组所限制的值（见表2-5）。

表2-5　使用层次结构时的分组限制值

表 2-5　使用层次结构时的分组限制值

名　称	说　明
hierarchical_memory_limit	上层分组对内存（进程内存＋页面缓存）的限制值
hierarchical_memsw_limit	上层分组对内存（进程内存＋页面缓存）＋交换区的限制值

表2-6所示为层次结构中分组的合计，在本分组下创建的所有分组的合计值。

表2-6　层次结构中分组下的合计值

表 2-6　层次结构中分组下的合计值

名　称	说　明
total_cache	本分组下所有页面缓存量（字节数）的合计值
total_rss	本分组下所有匿名页面与交换区缓存内存量（字节数）的合计值
total_mapped_files	本分组下所有指向进程空间的文件映射所使用的内存量（字节数）的合计值
total_pgpgin	本分组下所有页面换入次数的合计值
total_pgpgout	本分组下所有页面换出次数的合计值
total_swap	本分组下所有交换区使用量（字节数）的合计值
total_inactive_anon	本分组下所有 LRU 列表中无效的匿名页面（字节数）的合计值
total_active_anon	本分组下所有 LRU 列表中有效的匿名页面（字节数）的合计值
total_inactive_file	本分组下所有 LRU 列表中无效的文件缓存（字节数）的合计值
total_active_file	本分组下所有 LRU 列表中有效的文件缓存（字节数）的合计值
total_unevictable	本分组下所有不能用 molock 等回收的内存量（字节数）的合计值

小结

本节介绍了Memory Cgroup。使用Memory Cgroup设置内存使用量的上限，就可以避免产生多余的页面缓存，减少对其他处理的影响。

参考文献

·Documentation/cgroup/memory. txt

—Hiroshi Shimamoto

HACK#13　使用Block I/O控制器设置I/O优先级

本节介绍使用Block I/O控制器的功能设置I/O优先级的方法。

Block I/O控制器可以将任意进程分组，并对该分组设置I/O的优先级。这个功能是在Linux 2.6.33时添加到Linux内核中的。例如，在前台进行一般处理的同时，在后台磁盘备份处理的情况下，如果备份处理频繁地向磁盘进行I/O操作，前台的处理即使有I/O请求，也不能立刻进行I/O处理，结果导致前台处理的性能下降。

Block I/O控制器在这种情况下就非常有效。创建I/O优先级较高的分组和较低的分组，并将前台处理的进程和后台处理的进程分别分配到这些分组中。这样可以使前台处理的I/O优先于后台处理，防止性能下降。

本节将介绍Block I/O控制器的使用方法。使用的Linux内核版本为2.6.35。

使用Block I/O控制器的前提条件

Block I/O控制器是Cgroup的子系统之一，是作为I/O调度程序之一的CFQ的一部分安装的。因此，使用Block I/O控制器时，必须使用启用了下列config选项编译的内核。

```
CONFIG_BLK_CGROUP
CONFIG_CFQ_GROUP_IOSCHED
```

确认Cgroup支持

首先确认运行中的内核是否支持Cgroup和Cgroup子系统Block I/O控制器。如果有/proc/cgroups，运行中的内核就可以支持Cgroup。/proc/cgroups的内容如下。

```
$ cat /proc/cgroups
    subsys_name        hierarchy      num_cgroups    enabled
    blkio                             1              1              1
```

只要subsys_name列显示了blkio，且enabled为1就没问题。如果看不到blkio，就需要重新编译内核。如果enabled为0，则启动时的内核命令行应当如下所示。

```
cgroup_disabled=blkio
```

这时需要修改/boot/grub/grub.conf等，将上述指定从内核命令行中删除，并重新启动。

确认CFQ支持

接下来确认是否能够将CFQ作为I/O调度程序使用。例如，想要查看块设备sdb中可以使用的I/O调度程序时，需要执行下列命令。

```
$cat/sys/class/block/sdb/queue/scheduler
noop deadline[cfq]
```

可以使用的I/O调度程序会显示出来，其中当前选择的调度程序已加上了方括号。如果显示cfq则没问题；如果不显示就需要启用CFQ，重新编译内核。

注意事项：设备种类不同，scheduler文件的内容也不同。I/O调度程序是对一般的块设备使用的，因此，例如在loopback设备loop0等中不会显示cfq。请对sda、sdb等一般的块设备进行确认。

尝试使用Block I/O控制器

Block I/O控制器的设置通过cgroup文件系统进行。关于Cgroup和cgroup文件系统的基本情况请参考Hack#7。

首先挂载cgroup文件。将blkio作为挂载选项，指定将Block I/O控制器作为子系统使用。

```
#mount-t cgroup-o blkio cgroup/cgroup
```

然后，在CFQ中为想要控制I/O优先级的块设备设置I/O调度程序。这里使用的块设备是sdb。

```
#echo cfq＞/sys/class/block/sdb/queue/scheduler
$cat/sys/class/block/sdb/queue/scheduler
noop deadline[cfq]
```

这时，使用Block I/O控制器前的准备工作就完成了。为了方便讲解，在这里创建优先级较高的分组“high”和优先级较低的分组“low”，并分别向各分组分配1个进程来观察I/O的情况。首先创建分组。

```
#mkdir/cgroup/high
#mkdir/cgroup/low
```

对各分组设置I/O的优先级。设置优先级时，在blkio.weight中写入100～1000的“weight值”。初始值为500，值越大表示优先级越高。

```
#echo 1000＞/cgroup/high/blkio.weight
#echo 100＞/cgroup/low/blkio.weight
```

小贴士：仅根分组的weight初始值为1000。

为了进行测试，制作一个简单的脚本。这个脚本将进程添加到所指定的两个分组low和high，分别计算出读文件所需的时间。创建如下的“blkio_test.sh”脚本，并为其赋予执行权限。

```
#！/bin/sh
#blkio_test.sh
#Test script for Block IO Controller
#read/mnt/sdb/low.dat（$flow）as cgroup$cg_low
#and read/mnt/sdb/high.dat（$fhigh）as cgroup$cg_high simultaneously.
#
#$1：cgroup path for lower priority（-->$cg_low）
#$2：cgroup path for higher priority（-->$cg_high）
function print_usage（）
{
echo"usage：$0＜cgroup_low＞＜cgroup_high＞"
exit 1
}
##############################
#params and variables
flow=/mnt/sdb/low.dat
fhigh=/mnt/sdb/high.dat
#cgroups to which processes will be asigned
if[$#！=2]；then
print_usage
fi
cg_low=$1
cg_high=$2
for cg in$cg_low$cg_high；do
if[！-d$cg]；then
echo"$cg does not exists"
print_usage
fi
done
#temporary files
out_low=$（mktemp）
out_high=$（mktemp）
##############################
#sync, drop caches and read files
echo-n"sync and drop all caches……"
sync
echo 3＞/proc/sys/vm/drop_caches
echo"done"
echo-n"reading files……"
echo$$＞$cg_low/tasks
（time dd if=$flow of=/dev/null）＞$out_low 2＞＆1＆
echo$$＞$cg_high/tasks
（time dd if=$fhigh of=/dev/null）＞$out_high 2＞＆1＆
wait
echo"done"
##############################
#print the results
echo"--------------------"
echo"dd in$cg_low："
cat$out_low
echo"--------------------"
```

```
echo"dd in$cg_high："
cat$out_high
rm-f$out_low$out_high
```

首先，在不分组的情况下进行测试。使用同属于根分组的两个进程，同时读入文件。由于脚本读入的是/mnt/sdb/low.dat、/mnt/sdb/high.dat文件，因此需要先创建两个大小适当的文件，再运行脚本。这里创建了约400MB的文件并执行相关代码。

```
#dd if=/dev/zero of=/mnt/sdb/low.dat bs=1M count=400
#dd if=/dev/zero of=/mnt/sdb/high.dat bs=1M count=400
#./blkio_test.sh/cgroup/cgroup
--------------------
dd in/mnt/cgroups：
819200+0 records in
819200+0 records out
419430400 bytes（419 MB）copied，14.0493 s，29.9 MB/s
real 0m14.156s
user 0m0.261s
sys 0m1.183s
--------------------
dd in/mnt/cgroups：
819200+0 records in
819200+0 records out
419430400 bytes（419 MB）copied，14.2007 s，29.5 MB/s
real 0m14.292s
user 0m0.281s
sys 0m1.186s
```

两个进程同样使用约14秒的时间完成读入。接下来，在分组的情况下进行测试。将两个进程分别添加到low、high分组中，同时读入文件。

```
#./blkio_test.sh/cgroup/low/cgroup/high
--------------------
dd in/cgroup/low：
819200+0 records in
819200+0 records out
419430400 bytes（419 MB）copied，13.0829 s，32.1 MB/s
real 0m13.388s
user 0m0.250s
sys 0m1.208s
--------------------
dd in/cgroup/high：
819200+0 records in
819200+0 records out
419430400 bytes（419 MB）copied，7.43459 s，56.4 MB/s
real 0m7.818s
user 0m0.256s
sys 0m1.209s
```

属于/cgroup/low的进程完成文件读入耗费约13秒，而属于/cgroup/high的进程完成读入耗费约8秒。与优先级较低，即weight设置值较小的分组相比，优先级较高，即属于weight设置值较大的分组（/cgroup/high）的进程可以优先执行I/O操作。

Block I/O控制器提供的特殊文件

除了blkio.weight以外，Block I/O控制器还提供了一些其他的特殊文件。文件列表如表2-7所示。只读属性的特殊文件是用来获取统计信息的文件，多数是根据各设备、I/O的类型（read/write、sync/async）另起一行的。

表 2-7　Block I/O 控制器的设置用特殊文件

文　件　名	R/W	用　　途
blkio.weight	RW	设置分组 weight 值的文件。weight 值可以设置为 100~1000。weight 值越大，优先级越高
blkio.weight_device	RW	按照＜设备主号码＞:＜设备副号码＞<weight 值＞的格式写入，就可以为各设备设置 weight 值。将＜weight 值＞设置为 0 时，该设备的设置被清除。这里没有进行设置的设备使用 blkio.weight 的 weight 值
blkio.io_merged	R	合并的 I/O 数
blkio.io_queued	R	当前保留的 I/O 数
blkio.io_service_bytes	R	I/O 请求总字节数
blkio.io_serviced	R	I/O 请求数
blkio.io_service_time	R	从 I/O 请求设备到完成所花费的总时间。单位为纳秒
blkio.io_wait_time	R	I/O 请求到达设备之前保留在等待队列的总时间。单位为纳秒
blkio.reset_stats	W	写入后，统计信息被清除
blkio.sectors	R	I/O 请求的总扇区数
blkio.time	R	目前为止分配给分组的时间片的长度。单位为纳秒

小贴士：I/O的合并，是指将应用程序发出的多个I/O请求合并为1个。把相邻扇区的I/O整理到一起后，仅需一次DMA就可以完成I/O，因此可以提高I/O处理的效率。

另外，在启用内核选项CONFIG_DEBUG_BLK_CGROUP进行编译的内核中，还有为用户提供调试用信息的文件，这里不作说明。

关于Block I/O控制器的CFQ设置用虚拟文件

/sys/block/＜dev＞/queue/iosched中有CFQ的设置用虚拟文件，表2-8所示文件会对Block I/O控制器的运行产生影响。

表 2-8　关于 Block I/O 控制器的 sysfs 的 CFQ 设置文件

文 件 名	R/W	用　途
group_isolation	RW	用来设置在 I/O 性能和分组间优先级控制二者中优先切换到哪一个。为 0 时，为了实现 I/O 性能最大化，会适度降低一些分组优先级的兼容性

限制事项

由于Block I/O控制器仍是比较新的功能，因此在使用上还有一些限制。接下来列出了到Linux内核版本2.6.35为止存在的限制事项。

不支持非同步I/O

需要各分组进行优先级控制的，当前仅为同步I/O，即初次读入和Direct I/O的读写。普通的写入是经过页面缓存的非同步I/O，因此不属于优先级控制的对象，都被看做根分组发出的I/O。

不支持分组层次化

把分组的层次限制为仅一层，因此无法创建从根分组开始有两层次以上的分组。用cgroup文件系统的目录层次可以显示如下。

```
/cgroup#根分组
/cgroup/gr1#第一层：可以创建
/cgroup/gr1/gr2#第二层：不可以创建
```

根分组与子分组作同等处理

根分组不作为其他子分组的上级分组，而是作为同等分组进行处理。当根分组内存在拥有实时I/O优先权的进程时，这个影响比较明显。根分组会被其他子分组抢占，因此即使是实时进程，也不能占用I/O带宽。

Block I/O控制器的结构与注意事项

为了更准确地理解Block I/O控制器的运行，下面介绍其内部结构及其使用上的注意事项。

Block I/O控制器对各分组的I/O请求分配时间片。仅许可各分组在这个时间片内执行

I/O操作。分组的weight值越大，时间片的长度越长；weight值越小，时间片的长度越短。通过这种方式来指定分组间的I/O操作的优先级。

这里需要注意的是，优先级不是通过I/O带宽（字节/秒，bps），而是通过时间片的长度来指定的。因此，两个分组在I/O完成所需时间差距极大的模式下执行I/O时，具体来说，就是一个依次读入，另一个随机读入的情况下，各分组的I/O带宽就会与weight值的设置迥然不同。

另外，还需要注意的是，Block I/O控制器只有在针对设备的I/O发生竞争时，才会根据优先级对I/O进行控制。在I/O不发生竞争的情况下，即使是优先级较低的分组，Block I/O控制器也不会禁止I/O的执行。也就是说，如果优先级较高的分组没有对某个设备发出I/O请求，那么即使是优先级较低的分组，也可以使用该设备的全部带宽。这里所说的设备是指实际的物理块设备。dm（device-mapper）等可以为应用程序提供逻辑性块设备，但是Block I/O控制器与逻辑块设备完全无关，只在向物理设备执行I/O时进行控制。当多个分组同时对同一逻辑设备发出I/O请求时，根据这些I/O请求所针对的物理设备不同，实际的I/O有可能竞争，有可能不竞争。这时，想要预测出哪个I/O会优先进行，就必须正确把握逻辑设备和物理设备的对应关系。

小结

Block I/O控制器是正在开发的新功能。还存在前面所述的一些限制，因此更需要大家通过实际体验来发现存在问题或尚有不足的功能，反馈给开发者或者自己大胆地制作出来，才能够将其不断地完善。

参考文献

·关于Cgroup请参考Hack#7。

·Documentation/cgroups/blkio-controller. txt（内核源文档）

——Munehiro IKEDA

HACK#14　虚拟存储子系统的调整

本节介绍如何使用/proc进行虚拟存储子系统的调整。

虚拟空间存储方式

在Linux上向应用程序分配内存时，是通过以页面为单位的虚拟存储方式进行的。采用虚拟存储方式，在实际操作中具有不需要确保连续的物理内存（不用担心内存碎片）的优点。最近的处理器大部分都具备用于虚拟存储的处理器嵌入式TLB（Translation ；lookaside buffer，旁路转换缓冲区，或称为页表缓冲区）和处理不存在的页面访问的结构。除了部分嵌入式应用外，大多数Linux应用中都可以使用虚拟存储方式的内存管理。使用虚拟存储方式的内存管理，具有下列特点。

·程序使用的页面是在应用程序最初访问时由内核分配的。

·如果分配的页面为程序文本、有初始值的数据（.data）区域或（被mmap的）数据文件区域，则在页面分配的同时从对应的文件读取数据，页面通过这些数据初始化。

·如果对于不存在拥有初始值的数据的区域，则只进行页面分配处理。该页面作为匿名（anonymous）页面处理。

应用程序通过malloc（）等分配可用的存储区时，不会立刻向该区域（空间）分配实际的页面。而是在必要时仅分配需要用到的页面。

多数应用程序一般都不会使用分配到的所有存储区。有时分配与最大数据量大小相等的缓冲区，有时也会需要为散列表（hash table）等分配没有实体的空间。这种情况下，使用虚拟存储方式延迟内存分配，就不需要向未使用的空间分配内存。

由于根据需要分配页面，因此应用程序启动时不能事先得知该应用程序最终使用的最

大页面数，这是虚拟存储方式的缺点。进程在逻辑上的虚拟内存空间与实际分配给该空间（已使用）的实际内存空间之间不再有直接的关系，最大使用内存量会根据环境（处理的数据等）的变化而变化。

应用程序使用的内存量对系统稳定性有很大的影响，因此不能无限度地使用内存。

虚拟空间超额使用量的调整

只存在一个进程时，即使不知道该进程的最大内存使用量，也可以使用已有的进程单位的资源限制功能对内存使用量进行充分限制。实际安装的内存为10GB时，可以使用ulimiti命令将该进程的最大虚拟空间大小设置为10GB。考虑到应用程序与虚拟空间大小相比要使用多少物理内存，也可以设置比10GB更大的虚拟空间大小（在Linux中未安装进程的物理内存驻留大小限制功能，因此无法使用。）

但是，考虑到多个进程互相争夺内存的情况，就需要限制整个系统的虚拟空间量。如上所述，即使无限度地向进程分配虚拟空间，只要不实际使用也就没问题。分配给进程的虚拟空间的大小与本质上实际安装的物理量无关。但是，从系统的稳定性来看，分配的虚拟空间大小应该保证达到物理内存的量。将没有物理内存保证的虚拟空间进行大量分配，并实际访问时，如果同时分配大量的物理页面，系统就会崩溃。

在Linux中有规定“允许超过物理内存量分配多少虚拟空间”的参数，通过下列两个/proc入口来进行控制。

·/proc/sys/vm/overcommit_memory
·/proc/sys/vm/overcommit_ratio

/proc/sys/vm/overcommit_memory是控制虚拟空间分配的策略的参数，可以设置下列3种值。

·OVERCOMMIT_GUESS（0）
·OVERCOMMIT_ALWAYS（1）
·OVERCOMMIT_NEVER（2）

默认为OVERCOMMIT_GUESS。

#cat/proc/sys/vm/overcommit_memory
0

设置为OVERCOMMIT_NEVER时，执行下列命令。

```
#echo 2＞/proc/sys/vm/overcommit_memory
```

可以在/proc/sys/vm/overcommit_ratio中指定允许过量使用的虚拟空间所占物理内存总量的百分比。默认为50%。可以分配的最大虚拟空间为总物理内存量的150%。下面介绍overcommit_memory的不同取值对应的不同虚拟空间分配。

OVERCOMMIT_GUESS

overcommit_memory的默认值为OVERCOMMIT_GUESS。指定这个参数时，预测将空闲内存、页面缓存量、空闲交换区量、可回收slab（长字节）量等回收的页面数，虚拟空间要求分配的量比这个数小时，分配成功。

（请注意，在多个进程同时要求大量的虚拟空间时是无法正确预测的。下面所述的OVERCOMMIT_NEVER中就没有这种问题。）

在OVERCOMMIT_GUESS的情况下，可分配的虚拟空间大小基本就是物理内存大小和交换区大小的合计值。物理内存为2GB，交换区为2GB，当前消耗1GB时，还可以分配约3GB的虚拟空间。

OVERCOMMIT_ALWAYS

在OVERCOMMIT_ALWAYS的情况下，虚拟空间分配总是成功。即使对于过大的虚拟空间要求，也会分配虚拟空间。可以在与实际安装的物理内存量完全无关的形态下使用虚拟空间，如前面所述的散列表等。

OVERCOMMIT_NEVER

在OVERCOMMIT_NEVER的情况下，对可分配虚拟空间量的管理更加严格。

首先，记录下整个系统内已分配的虚拟空间量。这个值严格由系统进行集中管理，在

分配或释放虚拟空间时重新计算。这个值为/proc/meminfo的Committed_AS。

对于虚拟空间大小的计算也比其他参数严格。例如，在OVERCOMMIT_GUESS的情况下，对mmap系统调用设置了MAP_NORESERVE的虚拟空间量不添加到Committed_AS中。但是，在OVERCOMMIT_NEVER的情况下会添加到Committed_AS中。指定了MAP_NORESERVE的区域也作为可能分配物理内存的虚拟空间处理。

将“所有物理内存量+总交换区量”加上通过/proc/sys/vm/overcommit_ratio指定的比例得到的值，作为可分配的虚拟空间总量。这个值可以使用/proc/meminfo的CommitLimit查看。CommitLimit的值仅在利用OVERCOMMIT_NEVER时有效。在OVERCOMMIT_GUESS、OVERCOMMIT_ALWAYS的情况下，这个项目没有意义。

要求分配虚拟空间时，如果“整个系统中已经分配（Committed_AS）”的虚拟空间量超过“可分配虚拟空间量（CommitLimit）”，则分配失败。

小结

本节介绍了虚拟空间的过量使用。根据系统的不同，需要对虚拟空间分配策略进行调整，管理要确保的内存量。

——Naohiro Ooiwa

关于进程的虚拟内存分配

在 Hack #13 中已经介绍过，用 malloc() 等预留内存后，就会分配虚拟内存。但使用 mmap() 时分配虚拟内存有一些限制条件。

例如，启动进程后，动态链接器就会进行动态库（library）的安装。由动态库的执行文件信息决定 mmap 的大小。接着，链接器会配置文本段和数据段，如果是 64 位操作系统，就会设置 alignment，当文本段和数据段较小时，它们之间有约 2MB 的空间。

以适当的访问权限对代码段和数据段执行 mmap 命令，使用 mprotect(PROT_NONE) 让此外未使用的段无法访问。

下面是在 CentOS 5.4 64 位操作系统下启动 apache 时 ps 命令的结果。

```
# ps aux
USER       PID %CPU %MEM    VSZ   RSS TTY      STAT START   TIME COMMAND
...
root      4469  8.5  0.5 238244 11136 ?        Ss   10:27   0:00 /usr/sbin/httpd
apache    4471  0.0  0.3 238244  6516 ?        S    10:27   0:00 /usr/sbin/httpd
apache    4472  0.0  0.3 238244  6512 ?        S    10:27   0:00 /usr/sbin/httpd
apache    4473  0.0  0.3 238244  6512 ?        S    10:27   0:00 /usr/sbin/httpd
...
```

每一个进程确保了 200MB 以上的虚拟内存（VSZ）。使用 pmap 命令查看详细内容。pmap 命令显示的是进程的内存映射。

```
# pmap -d 4469
4469:   /usr/sbin/httpd
Address           Kbytes Mode  Offset           Device    Mapping
...
00002aff7a62e000      20 r-x-- 0000000000000000 008:00005 mod_cgi.so 文本段
```

```
00002aff7a633000    2048 ----- 0000000000005000 008:00005 mod_cgi.so 剩余区域
00002aff7a833000       8 rw--- 0000000000005000 008:00005 mod_cgi.so 数据段
00002aff7a835000       8 r-x-- 0000000000000000 008:00005 mod_version.so
00002aff7a837000    2044 ----- 0000000000002000 008:00005 mod_version.so
00002aff7aa36000       8 rw--- 0000000000001000 008:00005 mod_version.so
00002aff7aa38000     216 r-x-- 0000000000000000 008:00005 mod_perl.so
00002aff7aa6e000    2044 ----- 0000000000036000 008:00005 mod_perl.so
00002aff7ac6d000      16 rw--- 0000000000035000 008:00005 mod_perl.so
00002aff7ac71000    1200 r-x-- 0000000000000000 008:00005 libperl.so
00002aff7ad9d000    2044 ----- 000000000012c000 008:00005 libperl.so
00002aff7af9c000      36 rw--- 000000000012b000 008:00005 libperl.so
...
00002aff85b6e000    3844 rw--- 00002aff85b6e000 000:00000   [ anon ]
00007fff79a9c000      84 rw--- 00007ffffffea000 000:00000   [ stack ]
ffffffffff600000    8192 ----- 0000000000000000 000:00000   [ anon ]
mapped: 246436K    writeable/private: 6580K    shared: 692K
```

在 32 位的 CentOS 下的情况如下所示。

```
# ps aux
...
root      2715  6.6  7.6  23168  9488 ?        S    10:58   0:00 /usr/sbin/httpd
apache    2718  0.0  3.8  23168  4796 ?        S     10:58   0:00 /usr/sbin/httpd
apache    2719  0.0  3.8  23168  4796 ?        S     10:58   0:00 /usr/sbin/httpd
apache    2720  0.0  3.8  23168  4796 ?        S     10:58   0:00 /usr/sbin/httpd
...
```

每一个进程的虚拟内存（VSZ）为约 23MB。使用 pmap 命令查看内存映射，内容如下。

```
# pmap -d 2715
...
00508000      28 r-x-- 0000000000000000 008:00002 mod_proxy_ftp.so
0050f000       8 rwx-- 0000000000006000 008:00002 mod_proxy_ftp.so
00511000       4 r-x-- 0000000000000000 008:00002 mod_suexec.so
00512000       8 rwx-- 0000000000000000 008:00002 mod_suexec.so
00514000      16 r-x-- 0000000000000000 008:00002 mod_disk_cache.so
00518000       8 rwx-- 0000000000004000 008:00002 mod_disk_cache.so
0051a000       8 r-x-- 0000000000000000 008:00002 mod_file_cache.so
0051c000       8 rwx-- 0000000000001000 008:00002 mod_file_cache.so
0051e000      20 r-x-- 0000000000000000 008:00002 mod_cgi.so
00523000       8 rwx-- 0000000000004000 008:00002 mod_cgi.so
00525000       8 r-x-- 0000000000000000 008:00002 libutil-2.5.so
00527000       4 r-x-- 0000000000001000 008:00002 libutil-2.5.so
00528000       4 rwx-- 0000000000002000 008:00002 libutil-2.5.so
...
mapped: 23168K    writeable/private: 4916K    shared: 684K
```

在 32 位操作系统的情况下不存在访问权限为 -----（PROT_NONE）的区域。这是因为 32 位操作系统、64 位操作系统中链接器执行共享库映射的策略不同。将上述 pmap 命令的结果进行比较，看起来像是 64 位操作系统浪费了虚拟内存，但不用担心。

映射的区域中没有访问权限（PROT_NONE）的区域、写入权限（PROT_WRITE）或不是共享（MAP_SHARED）的区域不添加到 Committed_AS 中。因此在 64 位操作系统的情况下，即使消耗虚拟内存地址空间，也不会消耗实际的虚拟内存。

HACK#15　ramzswap

本节介绍将一部分内存作为交换设备使用的ramzswap。

ramzswap是将一部分内存空间作为交换设备使用的基于RAM的块设备。对要换出（swapout）的页面进行压缩后，不是写入磁盘，而是写入内存。可以使用的内存仅为完成压缩的部分。压缩处理使用的是LZO[1]。

ramzswap是从Linux 2.6.33合并到Staging驱动程序的。Staging驱动程序是指尚未达到某种程度的质量的试验性驱动程序。

通过使用ramzswap，运转速度可以比换出到一般磁盘设备时更高。这是因为内存的I/O较快，且经过压缩后I/O变小。只有用于嵌入式系统的内存等的机器中，可以避免内存不足时由于内存回收处理导致性能极端下降，或抑制OOM Killer的运行。

ramzswap的项目在如下环境中，即使减去压缩/解压缩的CPU系统开销，也可以提高性能。

·上网本或瘦客户机（thin client）这种配备了内存容量小但CPU性能较高的的PC。·在组装机器上，不想在外部闪存存储器（flash memory storage）中生成交换区时。使用ramzswap时，可以使用已经整合到上游内核的，也可以从论坛中下载并使用。

整合到上游内核的ramzswap实际安装了论坛的部分成果。本节将针对上游内核和论坛版内核进行介绍。Linux内核以2.6.35为例，论坛数据包以版本0.6.2为例。操作系统使用Fedora 12。

使用论坛版ramzswap

使用论坛版的数据包时，首先需要下载数据包进行编译。由于要对内核模块进行编

译，因此必须事先安装kernel-devel。

```
$wget http：//compcache.googlecode.com/fles/compcache-0.6.2.tar.gz
$tar zxvf compcache-0.6.2.tar.gz
$cd compcache-0.6.2/
$make
```

make命令结束后，将生成内核模块ramzswap.ko和ramzswap设备的控制工具—rzscontrol命令和rzscontrol命令的manual文件。

小贴士：ramswap版本0.6.2的运行已经在Linux 2.6.32中确认。使用RHEL6编译时，需要在ramzswap_drv.c的最前面加上#include＜linux/slab.h＞。

rzscontrol命令创建的路径为compcache-0.6.2/sub-projects/rzscontrol/rzscontrol, manual文件创建的路径为compcache-0.6.2/sub-projects/rzscontrol/man/rzscontrol.1。ramzswap版本0.6.2不会通过make命令自动安装。可以直接使用这些文件。

ramzswap的使用方法有两种。一种是在内存中创建虚拟交换区磁盘的ramzswap disk，另一种是在使用内存的同时使用交换文件或交换块设备的backing swap。一般系统与使用ramzswap disk、backing swap系统的内存和交换区的关系如图2-2所示。

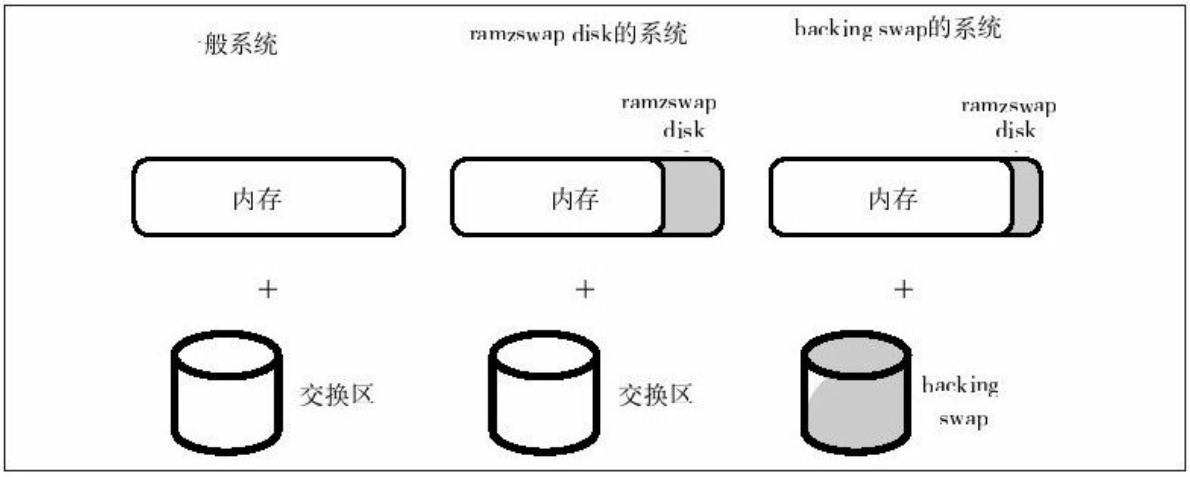

图2-2　一般系统与使用ramzswap disk、backing swap的系统的内存和交换区的关系

首先介绍第一个ramzswap disk。

[1]关于LZO请见参考文献。

ramzswap disk的使用方法

使用ramzswap disk，首先需要将用来压缩/解压缩数据的LZO模块安装到内核中。

```
#modprobe lzo_compress
#modprobe lzo_decompress
```

注意事项：在部分发布版（Fedora14等）中，把lzo_decompress模块静态安装到内核中，有时会因为没有模块而导致modprobe失败。

```
#modprobe lzo_decompress
FATAL：Module lzo_decompress not found.
```

没有模块，也没有静态安装到内核时，对ramzswap.ko执行insmod命令，就会出现如下错误。

```
#insmod ramzswap.ko
insmod：error inserting'ramzswap.ko'：-1 Unknown symbol in module
```

自己构建内核时，请将CONFIG_LZO_DECOMPRESS设置为y或m。把像Fedora 14这样lzo_decompress静态安装到内核的情况下，ramzswap.ko的insmod会成功。

接下来安装ramzswap模块。这里将设置num_devices=4，以生成4个设备文件。

```
#insmod./ramzswap.ko num_devices=4
#ls/dev/ramzswap*
/dev/ramzswap0/dev/ramzswap1/dev/ramzswap2/dev/ramzswap3
#lsmod
Module Size Used by
ramzswap 21108 0
lzo_decompress 2768 1 ramzswap
lzo_compress 2480 1 ramzswap
……
```

将ramzswap模块安装到内核的同时，还可以设置各参数。下面是设置作为ramzswap disk使用的内存大小的例子。

```
#insmod ramzswap.ko num_devices=4 disksize_kb=20480
```

只有/dev/ramzswap0的初始化（后面介绍--init选项）和disksize_kb参数设置是自动进行的。/dev/ramzswap1～3的初始化和disksize_kb参数需要另行设置。后面也可以在rzscontol命令中设置相同参数。但是num_devices只能在安装模块时进行设置。表2-9所示为可设置的参数列表。其内容将在后面详细说明。

表2-9 ramzswap的模块参数与rzscontrol命令的选项

上游内核中含有的ramzswap模块参数	论坛版的ramzswap模块参数	ramzswap命令选项
num_devices	num_devices	无
	disksize_kb	-d、--disksize_kb
	memlimit_kb	-m、--memlimit_kb
	backing_swap	-b、--backing_swap

安装ramzswap模块后，为了作为交换区使用对ramzswap设备进行初始化，并启用交换功能。

```
#sub-projects/rzscontrol/rzscontrol/dev/ramzswap0--init
#swapon/dev/ramzswap0
```

这时也可以使用-p选项指定优先级，与已有的交换设备同时使用。这个值较大表示优先级较高，因此应当指定比一般的交换设备更大的值。

```
# swapon -p 100 /dev/ramzswap0
# swapon -s
Filename                                Type            Size        Used    Priority
/dev/ramzswap0                          partition       511992      0       100
/dev/sda2                               partition       2047992     0       -1
```

这时，ramzswap设备的交换功能就已启用。使用一定数量的内存后，就会发生换出。

可以使用rzscontrol命令的--stats选项来确认ramzswap的统计信息和状态。

```
#sub-projects/rzscontrol/rzscontrol/dev/ramzswap--stats
```

表2-10为此时的输出结果和各项目的说明。

表 2-10 执行 ramzswap disk 命令时 rzscontrol --stats 的输出结果

输　出	说　明
DiskSize: 255 852KB	ramzswap disk 的大小。默认设置为物理内存的 25%
NumReads: 91 576	从 ramzswap 设备读出的页面总数（解压缩页面的次数）
NumWrites: 224 893	写入 ramzswap 设备的页面总数（压缩页面的次数）
FailedReads: 0	因解压缩失败等导致 swap 区域的数据读取失败的页面数
FailedWrites: 0	因压缩失败等导致无法写入 swap 区域的页面数
InvalidIO: 0	因某些原因（内存不足等）导致无法处理的 I/O 请求数。这些 I/O 请求会撤销
NotifyFree: 220 016	释放的页面总数
ZeroPages: 163	在换出的页面中，数据全部为 0（零页面）的页面数。为零页面时仅记录其为零页面，压缩处理或实际的 I/O 会省略
GoodCompress: 96%	成功将大小压缩到页面大小 50% 以下的比例
NoCompress: 0%	未能将页面压缩到 75% 以下的比例。此时，压缩会放弃，换出压缩前的原始页面
PagesStored: 4871	正在换出的页面数。包括未能压缩（已计入 NoCompress）的页面。不包括零页面
PagesUsed: 1255	ramzswap 实际使用的页面数。这是 ramzswap 保留的内存量
OrigDataSize: 19 484KB	有换出要求的数据的合计大小。PagesStored× 页面大小（一般为 4096 字节）。该值对应压缩前的大小
ComprDataSize: 4801KB	换出后数据的合计大小。PagesUsed× 页面大小（一般为 4096 字节）。该值对应压缩后的大小
MemUsedTotal: 5020KB	ramzswap 实际使用的总内存量

由于ramzswap不会立刻释放保留的内存，因此OrigDataSize和free命令的数值不一定一致。

rzscontrol命令也可以对各个ramzswap设备进行设置。使用--disksize_kb选项可以设置ramzswap设备的大小（单位为千字节）。执行下列命令就可以设置ramzswap设备的容量。

#sub-projects/rzscontrol/rzscontrol/dev/ramzswap0--init--disksize_kb=10240要将ramzswap设备排除在交换对象之外，可以使用swapoff命令。

```
#swapoff/dev/ramzswap0
```

要关闭ramzswap，需要在swapoff之后使用rzscontrol命令的--reset选项释放残留在ramzswap磁盘中的内存。最后将模块从内核中移除。

```
#sub-projects/rzscontrol/rzscontrol/dev/ramzswap0--reset
#rmmod ramzswap
```

backing swap的使用方法

ramzswap还有另一种使用方法，就是将部分内存作为ramzswap disk使用，再将交换文件或交换块设备作为backing swap使用。

ramswap为内存和磁盘的两层。如果内存稍有不足，则仅使用内存的ramzswap disk进行处理，但如果缺少更多内存，则页面的内容存放到backing swap中。

下面介绍backing swap的使用方法。

首先与ramzswap disk同样进行设置。

```
#modprobe lzo_compress
#modprobe lzo_decompress
#insmod./ramzswap.ko num_devices=4
```

然后使用rzscontrol命令指定backing swap。

```
#sub-projects/rzscontrol/rzscontrol/dev/ramzswap0--init--backing_swap=/dev/sda2--memlimit_kb=10240
```

使用--backing_swap选项指定交换文件或交换块设备。这里指定的是块设备/dev/sda2。--memlimit_kb选项指定的是作为ramzswap disk使用的内存大小。使用内存的方式基本与ramzswap disk相同。没有指定时设置为所有内存大小的15%。这里设置为10240KB。

最后启用已生成设备的交换功能。

```
#swapon/dev/ramzswap0
```

内存使用量一旦增加，首先压缩的页面会写入ramzswap disk的区域中。这时未压缩到50%以下的页面则写入backing swap中，而非ramzswap disk中。另外，超过--memlimit_kb

选项指定的内存大小时也会写入backing swap中。

表2-11所示为执行rzscontrol--stats的结果。说明中仅记载与ramzswap disk的不同之处。

表 2-11　执行 ramzswap --stats 的结果

输　出	说　明
BackingSwap: /dev/sda2	使用 --backing_swap 指定的文件
DiskSize: 2 048 000KB	backing swap 的大小
MemLimit: 10 240KB	使用 --memlimit_kb 指定的大小

（续）

输　出	说　明
NumReads: 21 542	
NumWrites: 986 033	
FailedReads: 0	
FailedWrites: 0	
InvalidIO: 0	
NotifyFree: 0	
ZeroPages: 644	
GoodCompress: 99%	
NoCompress: 0%	未能将页面压缩到 50% 以下的情况
PagesStored: 16 961	
PagesUsed: 2592	
OrigDataSize: 67 844KB	
ComprDataSize:10 236KB	换出后的数据的合计大小。PagesUsed× 页面大小（通常为 4096 字节）。为压缩后的大小。在这个示例中如果进行更多的写入，就会超过 MemLimit，超过的部分会转移到 BackingSwap 中
MemUsedTotal: 10 368KB	
BDevNumReads: 110 861	从 BackingSwap 读入的次数
BDevNumWrites: 944 417	写入 BackingSwap 的次数

使用上游内核的ramzswap

要使用安装在上游内核的ramzswap，需要首先启用内核config（CONFIG_RAMZSWAP=y），编译内核。使用make menuconfig命令启用下列项目。

```
Device Drivers
->Staging drivers
->Compressed in-memory swap device（ramzswap）
```

启动编译后的内核。

使用方法

使用方法与论坛版相同，但需要另外编译用于上游内核的rzscontrol命令。由于上游内核驱动程序内没有安装backing swap，因此必须修改rzscontrol命令的代码。

上游内核中还没有安装backing swap和memlimit，因此将这部分代码从这个补丁中删除。下面使用这个补丁来编译rzscontrol命令。

```
#wget http：//compcache.googlecode.com/fles/compcache-0.6.2.tar.gz
#tar zxvf compcache-0.6.2.tar.gz
#cd compcache-0.6.2/sub-projects/rzscontrol
#patch-p1＜ramzswap-for-2.6.35.patch
```

按照下列方式指定上游内核的include文件进行编译。

```
#gcc-g-Wall-D_GNU_SOURCE rzscontrol.c-o rzscontrol-I/linux-2.6.35/drivers/
staging/ramzswap/-I../include
```

使用方法与论坛版相同。

小结

本节介绍了ramzswap。是否能够通过压缩页面数据受益，是与内存数据的内容相关的。但是即使多少有一些压缩/解压缩的系统开销，也比内存耗尽好得多。这在没有交换区的无磁盘（diskless）组装机器中尤其有效。

参考文献

·compcache Compressed Caching for Linux

http://code. google.com/p/compcache/

·LZO1X Compressor from MiniLZO

http://www. oberhumer.com/opensource/lzo/

·Compcache：in-memory compressed swapping

http://lwn. net/Articles/334649/

——Naohiro Ooiwa

HACK#16　OOM Killer的运行与结构

本节介绍OOM Killer的运行与结构。

Linux中的Out Of Memory（OOM）Killer功能作为确保内存的最终手段，可以在耗尽系统内存或交换区后，向进程发送信号，强制终止该进程。

这个功能即使在无法释放内存的情况下，也能够重复进行确保内存的处理过程，防止系统停滞。还可以找出过度消耗内存的进程。本节将介绍2.6内核的OOM Killer。

确认运行、日志

进行系统验证或负载试验时，有时会出现正在运行中的进程终止或者SSH连接突然断开、尝试重新登录也无法连接的情况。

这时需要查看日志。有时会输出如下内核信息。

Pid：4629，comm：stress Not tainted 2.6.26#3
Call Trace：
[＜ffffffff80265a2c＞]oom_kill_process+0x57/0x1dc
[＜ffffffff80238855＞]__capable+0x9/0x1c
[＜ffffffff80265d39＞]badness+0x16a/0x1a9
[＜ffffffff80265f59＞]out_of_memory+0x1e1/0x24b
[＜ffffffff80268967＞]__alloc_pages_internal+0x320/0x3c2
[＜ffffffff802726cb＞]handle_mm_fault+0x225/0x708
[＜ffffffff8047514b＞]do_page_fault+0x3b4/0x76f
[＜ffffffff80473259＞]error_exit+0x0/0x51
Node 0 DMA per-cpu：
CPU 0：hi：0，btch：1 usd：0
CPU 1：hi：0，btch：1 usd：0
……
Active：250206 inactive：251609 dirty：0 writeback：0 unstable：0
free：3397 slab：2889 mapped：1 pagetables：2544 bounce：0
Node 0 DMA free：8024kB min：20kB low：24kB high：28kB active：8kB inactive：180kB
present：7448kB pa
ges_scanned：308 all_unreclaimable?yes
lowmem_reserve[]：0 2003 2003 2003
……
Node 0 DMA：6*4kB 4*8kB 2*16kB 2*32kB 5*64kB 1*128kB 3*256kB 1*512kB 2*1024kB
2*2048kB 0*4096k
B=8024kB
Node 0 DMA32：1*4kB 13*8kB 1*16kB 6*32kB 2*64kB 2*128kB 1*256kB 1*512kB

0*1024kB 0*2048kB 1*40
96kB=5564kB
29 total pagecache pages
Swap cache：add 1630129，delete 1630129，find 2279/2761
Free swap=0kB
Total swap=2048248kB
Out of memory：kill process 2875（sshd）score 94830592 or a child
Killed process 3082（sshd）

最后出现了Out of memory（内存不足）。这就表示OOM Killer已经运行。无法重新连接的情况就是因为sshd被OOM Killer终止。如果不重新启动sshd就无法登录。

OOM Killer通过终止进程来确保空闲内存，接下来将介绍如何选定这个进程。

进程的选定方法

OOM Killer在内存耗尽时，会查看所有进程，并分别为每个进程计算分数。将信号发送给分数最高的进程。

计算分数的方法

在OOM Killer计算分数时要考虑很多方面。首先要针对每个进程确认下列1～9个事项再计算分数。

1.首先，计算分数时是以进程的虚拟内存大小为基准的。虚拟内存大小可以使用ps命令的VSZ或/proc/＜PID＞/status的VmSize[1]。来确认。对于正在消耗虚拟内存的进程，其最初的得分较高。单位是将1KB作为1个得分。消耗1GB内存的进程，得分约为1 000 000。

2.如果进程正在执行swapoff系统调用，则得分设置为最大值（unsigned long的最大值）。这是因为禁用swap的行为与消除内存不足是相反的，会立刻将其作为OOM Killer的对象进程。

3.如果是母进程，则将所有子进程内存大小的一半作为分数。

4.根据进程的CPU使用时间和进程启动时间调整得分。这是因为在这里认为越是长时间运行或从事越多工作的进程越重要，需保持得分较低。

首先，用得分除以CPU使用时间（以10秒为单位）的平方根。如果CPU使用时间为90秒，由于以10秒为单位，因此就是用得分除以9的平方根“3”。另外，根据进程启动开始的时间也可以调整得分。用得分除以启动时间（以1000秒为单位）的平方根的平方根。如果是持续运行16 000秒的进程，则用得分除以16的平方根“4”的平方根“2”。越是长时间运行的进程就越重要。

小贴士：虽然源代码的备注中写有以10秒为单位、以1000秒为单位，但是实际上在位运算中是以8和1024为单位来计算。

5.对于通过nice命令等将优先级设置得较低的进程，要将得分翻倍。nice-n中设置为1

～19的命令的得分翻倍。

6.特权进程普遍较为重要，因此将其得分设置为1/4。

7.通过capset（3）等设置了功能（capability）CAP_SYS_RAWIO[2]的进程，其得分为1/4。将直接对硬件进行操作的进程判断为重要进程。

8.关于Cgroup，如果进程只允许与促使OOM Killer运行的进程所允许的内存节点完全不同的内存节点，则其得分为1/8。

9.最后通过proc文件系统oom_adj的值调整得分。

依据以上规则，为所有进程打分，向得分最高的进程发送信号SIGKILL（到Linux 2.6.10为止，在设置了功能CAP_SYS_RAWIO的情况下，发送SIGTERM，在没有设置的情况下，发送SIGKILL）。

各进程的得分可以使用/proc/＜PID＞/oom_score来确认。

但是init（PID为1的）进程不能成为OOM Killer的对象。当成为对象的进程包含子进程时，先向其子进程发送信号。

向成为对象的进程发送信号后，对于引用系统的全线程，即使线程组（TGID）不同，如果存在与对象进程共享相同内存空间的进程，则也向这些进程发送信号。

[1]有时/proc/＜PID＞status的VmSize与计算出的分值多少有些差异。
[2]默认为已设置。

关于OOM Killer的proc文件系统

下面开始介绍与OOM Killer相关的proc文件系统。

/proc/＜PID＞/oom_adj

为/proc/＜PID＞/oom_adj设置值就可以调整得分。调整值的范围为-16～15。正的值容易被OOM Killer选定。负值可能性较低。例如，当指定3时，得分就变为2^3倍；当指定-5时，得分就变为$1/2^5$。

“-17”是一个特殊的值。如果设置为-17，就会禁止OOM Killer发出的信号（从Linux 2.6.12开始支持设置-17）。

在OOM Killer运行的情况下，为了实现远程登录而想要将sshd排除在对象外时，可以执行下列命令。

```
#cat/proc/'cat/var/run/sshd.pid'/oom_score
15
#echo-17＞/proc/'cat/var/run/sshd.pid'/oom_adj
#tail/proc/'cat/var/run/sshd.pid'/oom_*
==＞/proc/2278/oom_adj＜==
-17
==＞/proc/2278/oom_score＜==
0/*得分变成0*/
```

从Linux 2.6.18开始可以使用/proc/＜PID＞/oom_adj。内容记载在Documentation/filesystems/proc.txt中。

/proc/sys/vm/panic_on_oom

将/proc/sys/vm/panic_on_oom设置为1时，在OOM Killer运行时可以不发送进程信号，而是使内核产生重大故障。

#echo 1＞/proc/sys/vm/panic_on_oom

/proc/sys/vm/oom_kill_allocating_task

从Linux 2.6.24开始proc文件系统就有oom_kill_allocating_task。如果对此设置除0以外的值，则促使OOM Killer运行的进程自身将接收信号。此处省略对所有进程的得分计算过程。

```
#echo 1＞/proc/sys/vm/oom_kill_allocating_task
```

这样就不需要参照所有进程，但是也不会考虑进程的优先级和root权限等，只发送信号。

/proc/sys/vm/oom_dump_tasks

从Linux 2.6.25开始，将oom_dump_tasks设置为除0以外的值时，在OOM Killer运行时的输出中会增加进程的列表信息。

下面为设置示例。

```
#echo 1＞/proc/sys/vm/oom_dump_tasks
```

列表信息显示如下，可以使用dmesg或syslog来确认。

```
[ pid ]   uid  tgid total_vm      rss cpu oom_adj name
[    1]     0     1     2580        1   0       0 init
[  500]     0   500     3231        0   1     -17 udevd
[ 2736]     0  2736     1470        1   0       0 syslogd
[ 2741]     0  2741      944        0   0       0 klogd
[ 2765]    81  2765     5307        0   0       0 dbus-daemon
[ 2861]     0  2861      944        0   0       0 acpid
...
[ 3320]     0  3320   525842   241215   1       0 stress
```

/proc/＜PID＞/oom_score_adj

从Linux 2.6.36开始都安装了/proc/＜PID＞/oom_score_adj，此后将替换为/proc/＜PID＞/oom_adj。详细内容请参考Documentation/feature-removal-schedules.txt。即使当前是

对/proc/＜PID＞/oom_adj进行的设置，在内核内部进行变换后的值也是针对/proc/＜PID＞/oom_score_adj设置的。

/proc/＜PID＞/oom_score_adj可以设置-1000～1000之间的值。设置为-1000时，该进程就被排除在OOM Killer强制终止的对象外。

在内核2.6.36以后的版本中写入oom_adj，只会输出一次如下的信息。

```
#dmesg
……
udevd（60）：/proc/60/oom_adj is deprecated, please use/proc/60/oom_score_adj
instead.
……
```

RHEL5的特征

在RHEL5中运行OOM Killer时要比在上游内核中更加慎重。OOM Killer会计算调用的次数，仅在一定时间段内超出调用一定次数的情况下运行。

1.OOM Killer从上次调出到下一次调出之间超过5秒时，调用次数重新开始计算。这是为了避免仅因为产生突发性的内存负载就终止进程。

2.在计数变成0后的1秒以内调出时，不计入调用的次数。

3.OOM Killer的调用次数不足10次时，实际不会运行。OOM Killer调用10次时才开始认为内存不足。

4.最后OOM Killer运行不到5秒的话，OOM Killer不会再次运行。因此运行频率最高也有5秒一次。这是为了防止不必要地连续终止多个进程。也有等待接收到OOM Killer发出信号的进程终止（释放内存）的意思。

5.OOM Killer一旦运行，调用的次数就重新回到0。

也就是说，只有在OOM Killer在5秒以内调出的状态连续出现10次以上时才会运行。这些限制原本是到Linux 2.6.10为止都有的。因此在基于Linux 2.6.9的RHEL4中也需要实施这些限制。当前的上游内核中已经取消了这些限制。

RHEL4的运行

查看OOM Killer在RHEL4（Linux 2.6.9）中的运行情况。在下例中，是内存、交换区都为2GB的环境下，使用负载测试工具stress刻意消耗内存。

stress是给内存、CPU、磁盘I/O施加负载的工具。既可以为其中一项增加负载，也可以同时为这三项中的几项增加负载。stress在运行中如果接收到信号，就会输出信息并终止。

```
# wget -t0 -c http://weather.ou.edu/~apw/projects/stress/stress-1.0.0.tar.g
# tar zxvf stress-1.0.0.tar.gz
# cd stress-1.0.0
# ./configure ; make ; make install
# stress --vm 2 --vm-bytes 2G --vm-keep     /* 两个进程分别消耗2GB内存 */
stress: info: [17327] dispatching hogs: 0 cpu, 0 io, 2 vm, 0 hdd
stress: FAIL: [17327] (416) <-- worker 17328 got signal 15       /* 接收SIGTERM信号
stress: WARN: [17327] (418) now reaping child worker processes
stress: FAIL: [17327] (452) failed run completed in 70s
```

此时的控制台画面显示如下。

```
oom-killer: gfp_mask=0xd0
Mem-info:
...
Swap cache: add 524452, delete 524200, find 60/102, race 0+0
Free swap:            0kB                        /* 交换区剩余为0 */
524224 pages of RAM                              /* 1页4KB，因此内存大小为2GB */
10227 reserved pages                             /* 在内核内部预约的内存 */
19212 pages shared
253 pages swap cached
Out of Memory: Killed process 17328 (stress).    /* 根据信号终止的进程 */
```

在上游内核中无法禁用OOM Killer，而在RHEL4中则通过/proc/sys/vm/oom-kill可以禁用OOM Killer。

#echo 0＞/proc/sys/vm/oom-kill
或者
#/sbin/sysctl-w vm.oom-kill=0

禁用后OOM Killer就不会发送信号，但是会输出如上内存信息。

RHEL5的运行

在RHEL5（Linux 2.6.18）中对OOM Killer的运行进行确认的方法与RHEL4中相同。

```
#stress--vm 2--vm-bytes 2G--vm-keep
stress：info：[11779]dispatching hogs：0 cpu，0 io，2 vm，0 hdd
stress：FAIL：[11779]（416）＜--worker 11780 got signal 9/*SIGKILL*/
stress：WARN：[11779]（418）now reaping child worker processes
stress：FAIL：[11779]（452）failed run completed in 46s
```

此时的控制台画面如下所示。添加了运行OOM Killer时的回溯输出，便于调试。

```
Call Trace：
[＜ffffffff800bf551＞]out_of_memory+0x8e/0x321
[＜ffffffff8000f08c＞]__alloc_pages+0x22b/0x2b4
……
[＜ffffffff800087fd＞]__handle_mm_fault+0x208/0xe04
[＜ffffffff80065a6a＞]do_page_fault+0x4b8/0x81d
[＜ffffffff800894ad＞]default_wake_function+0x0/0xe
[＜ffffffff80039dda＞]tty_ldisc_deref+0x68/0x7b
[＜ffffffff8005cde9＞]error_exit+0x0/0x84
Mem-info：
……
Swap cache：add 512503，delete 512504，find 90/129，race 0+0
Free swap=0kB
Total swap=2048276kB
Free swap：0kB
524224 pages of RAM
42102 reserved pages
78 pages shared
0 pages swap cached
Out of memory：Killed process 11780（stress）.
```

RHEL6的运行

RHEL6. 0中OOM Killer计算得分的方式基本和RHEL5中没有不同。RHEL6系不会如“RHEL5的特征”中所述慎重地运行。其运行基本与上游内核相同。

小结

本节介绍了OOM Killer的结构和各种设置。当系统运行异常时确认syslog等，如果有OOM Killer的输出，就可以得知曾出现内存不足。

参考文献

·stress

http://weather. ou.edu/～apw/projects/stress/

——Naohiro Ooiwa

第3章　文件系统

本章将介绍RHEL6等用做标准文件系统的ext4的使用和调整方法，以及从ext2/ext3转换的方法。另外，还将介绍进行I/O基准测试（benchmark）的fio以及用户空间的文件系统FUSE。

HACK#17　如何使用ext4

本节介绍ext4的编写和挂载方法、开发版ext4的使用方法。

ext4是ext3的后续文件系统，从Linux 2.6.19开始使用。现在主要的发布版中多数都是采用ext4作为标准文件系统。

除了间接参照块管理以外，ext4还以扩展形式支持块的管理，使其能够处理更大的文件、文件系统。另外，还增加了确保多块（multiblock）[1]、确保延迟块、提高fsck速度、碎片整理等新的功能。在ext3中，时间戳（time stamp）的单位为毫秒，而ext4中变成了纳秒，可管理的时间日期上限也从2038年为止扩展到2514年为止。时间戳的种类也在以往的mtime、atime、ctime基础上增加了保存文件生成时间的crtime[2]。

表3-1所示为ext3和ext4主要功能的差异。

表 3-1　ext3 和 ext4 的性能、功能比较

性能、功能	ext3	ext4
最大文件大小	约 2TB	约 16TB
最大文件系统大小	约 16TB	约 1EB
块管理方式	间接参照块方式	区间方式（标准）、间接参照块方式
日志（journaling）功能	○	○
日志校验和（journal check sum）	—	○
延迟分配	—	○

（续）

性能、功能	ext3	ext4
多块分配	—	○
持久预分配	—	○（在区间形式的情况下）
条带（stripe）方式	—	○
时间戳单位	毫秒	纳秒
在线碎片整理	—	○

ext4的生成与挂载

下面介绍ext4的生成方法。生成文件系统时可以使用e2fsprogs中的mke2fs命令。mke2fs有很多种选项。表3-2介绍其中的一部分。

表 3-2　mke2fs 的选项

选　项	说　明
b	指定块的大小
F	强制执行 mke2fs
I	指定索引节点大小（字节单位）
O	文件系统功能的启用 / 禁用
T	指定文件系统的种类
v	显示详细内容

选项的详细情况请参考mke2fs命令的操作指南。

生成ext4时，需要将文件系统的种类指定为ext4，执行mke2fs命令。在该例子中使用的是Fedora 14的e2fsprogs-1.41.12-5，在/dev/sdb1上生成ext4。

#mke2fs-t ext4/dev/sdb1或mkfs-t ext4/dev/sdb1

挂载ext4时可以执行mount命令。需要向变量指定设备和挂载点。在该例子中是挂载到/mnt。

```
#mount-t ext4/dev/sdb1/mnt
```

[1]关于确保多块的内容请参考HACK#19。

[2]ext4的索引节点大小为256字节的情况。

关于mount选项

ext4中增加了很多功能。这些功能多数都可以在生成文件系统时或挂载时选择启用/禁用。这里介绍可以在挂载中设置的一部分选项（见表3-3）。

mount选项的详细内容请参考mount命令的操作指南或内核文档（Documentation/filesystems/ext4.txt）。

表 3-3　ext4 的挂载选项

选　项	说　明	默　认	ext4 特有
data=writeback	将日志模式设置为 writeback	—	—
data=ordered	将日志模式设置为 ordered	○	—
data=journal	将日志模式设置为 journal	—	—
journal_checksum	为要写入日志的事务添加校验和	—	○
journal_async_commit	非同步地将记录写入日志	—	○
barrier=1	启用写入屏障（barrier）	○	—
barrier=0	禁用写入屏障	—	—
discard	向下级块设备通知块已释放	—	—
nodiscard	不向下级块设备通知块已释放	○	—
delalloc	写入时使用延迟分配	○	○
nodelalloc	写入时不使用延迟分配。在出现写入请求的当时确保块	—	○
auto_da_alloc	通过 rename 进行文件替换、通过 truncate 后的写入进行文件替换时，不使用延迟分配功能，而是在当时立刻确保块	○	○
noauto_da_alloc	rename 和 truncate 处理时也使用延迟分配	—	○

开发版ext4的获取方法

现在论坛也在对ext4进行积极开发。开发版的ext4包含新的功能和bug的修改等。利用开发版时，需要从ext4的维护人员所管理的Git树中获取。这里将介绍获取开发版内核、命令的方法。获取时可以使用git命令。

ext4 patch queue的获取

正在开发的ext4的补丁包括在ext4 patch queue中。可以使用下列方法来获取。

```
#git clone http：//repo.or.cz/r/ext4-patch-queue.git
```

获取成功后，就会生成ext4-patch-queue目录。其中就有适用于ext4的补丁。对应的内核版本、适用的补丁的顺序记载在series文件中。

```
#cat ext4-patch-queue/series
#BASE v3.0-rc1
#
correct-comments-for-ext4_free_blocks
fix-max-file-size
use-FIEMAP_EXTENT_LAST-flag-for-last-extent
fixed-tracepoints-cleanup
#potential problems?
fix-oops-in-jbd2_journal_remove_journal_head
##########################################
#unstable patches
##################################################
stable-boundary
……
```

将这些补丁适用于内核的源代码后，生成的内核就具有ext4的最新功能。

开发版的e2fsprogs的获取

e2fsprogs的Git树可以执行下列命令来获取。

```
#git clone http：//git.kernel.org/pub/scm/fs/ext2/e2fsprogs.git
```

这时获取的是最新的稳定版e2fsprogs，因此需要切换到开发版的“next”分支。

```
#git checkout next
```

这样就切换到了开发版的e2fsprogs。可以通过执行configure, make来使用各种命令。由于内核、命令都是开发版，因此在使用过程中可能会发现bug。这时请向linux-ext4@vger.kernel.org报告。

小结

本节介绍了ext4的生成与挂载、获取开发版ext4的内核补丁和命令的方法。ext4具有比ext3更多的功能，作为更加便捷的文件系统，能够吸引更多的用户。

参考文献

·Ext4（and Ext2/Ext3）Wiki

https：//ext4. wiki.kernel.org/index.php/Main_Page

·Mailing list ARChives

http://marc. info/?l=linux-ext4＆r=1＆w=2

——Akira Fujita

HACK#18　向ext4转换

ext4可以与ext2/ext3在后台进行互换。这里将介绍从ext2/ext3转换的方法以及转换时的注意事项。

转换

有两种方法可以将ext2/ext3的磁盘映像作为ext4来使用。

1.直接作为ext4挂接

执行下列命令，就可以将ext2/ext3的磁盘映像/dev/sdb1作为ext4挂载到/mnt。

```
#mount-t ext4/dev/DEV MOUNTPOINT
```

通过上述方法，ext4的多块分配、延迟分配等功能也可以使用，因此性能比ext2/ext3更高。但是，如果只是将ext2/ext3的磁盘映像直接作为ext4挂载，ext4的很多功能仍然是无效的。例如，由于用间接块管理文件块，因此最大文件大小、最大文件系统大小都与作为ext2/ext3使用时相同。

2.启用并挂载ext4的功能标志

要启用/禁用功能标志，可以使用e2fsprogs工具包的tune2fs命令或debugfs命令。在下例中使用tune2fs命令，启用extent标志。

```
#tune2fs-0 extent/dev/sdb1
```

当前设置的功能标志可以同样使用e2fsprogs工具包的debugs命令或dumpe2fs命令。在下例中使用的是debugfs命令，输出结果的“Filesystem features”中有“extent”，可以确认extent的功能标志已经设置。

```
#debugfs-R stats/dev/sdbl
debugfs 1.41.12（17-May-2010）
Filesystem volume name：＜none＞
Last mounted on：＜not available＞
Filesystem UUID：03487be4-ed6e-4621-a3e6-326d443305f7
Filesystem magic number：0xEF53
Filesystem revision#：1（dynamic）
Filesystem features：has_journal ext_attr resize_inode dir_index filetype
extent sparse_super large_file
……
```

tune2fs命令中可以设置多个功能标志，但不能设置flex_bg等。flex_bg是将块组虚拟整合，将元数据所在位置局部化，从而提高文件系统检测（fsck）速度。这个功能与块组的布局有关，块组的布局是在文件系统生成时由mke2fs命令决定的，因此不能通过文件系统生成后的tune2fs命令等来更改。

如果使用tune2fs命令取消已设置的功能标志，就可以从ext4磁盘映像返回ext2/ext3磁盘映像。但是，extent标志一旦设置，就不能使用tune2fs命令来禁用，因此一旦设置这个标志，就无法返回ext2/ext3。ext4上以extent形式生成的文件在ext2/ext3文件系统中是无法读写的，因此必须事先知晓。

通过允许未初始化的块组，设置提高fsck检测速度的uninit_bg标志时，需要执行下列e2fsck命令。这样就可以对未使用的块组作标记，提高此后的fsck速度。

```
#e2fsck-pD/dev/sdb1
```

在本书写作时，ext文件系统之间的互换性中仍然存在一些bug。如果磁盘有空间，个人推荐不要将ext2/ext3的磁盘映像转换为ext4，而是直接创建为ext4。

关于功能标志

我们已经了解ext4的各种功能是由功能标志来管理的，那么文件系统生成时设置的功能标志应当如何决定呢？/etc/mke2fs.conf是管理mke2fs命令的标准设置的文件，除了功能标志之外，还可以设置块的大小或索引节点大小等的默认值。下列为Fedora 14的/etc/mke2fs.conf的内容。

```
[root@linux akira]#cat/etc/mke2fs.conf
[defaults]
base_features=sparse_super, filetype, resize_inode, dir_index, ext_attr
blocksize=4096
inode_size=256
inode_ratio=16384
[fs_types]
ext3={
features=has_journal
}
ext4={
features=has_journal, extent, huge_file, flex_bg, uninit_bg, dir_
nlink, extra_isize
inode_size=256
}
……
```

在没有/etc/mke2fs.conf的情形或者执行mke2fs命令时指定的不是-T而是-t的情形下，mke2fs命令将根据指定的文件系统种类和使用的磁盘大小来设置参数。

功能标志中有一些是ext2/ext3/ext4中共通的功能标志，也有一些是ext4特有的。表3-4、表3-5所示为与ext4相关的主要功能标志列表。

表 3-4　ext2/ext3/ext4 共通的主要功能标志列表

标　志　名	说　　明
sparse_super	不在所有块组内生成备份用的超级块。空的块作为数据块使用
filetype	文件格式信息保存在目录中
resize_inode	为了使块组描述表可以扩展而预分配空间
dir_index	使用散列值的 B 树，提高目录检索速度
ext_attr	使文件的扩展属性可以使用
large_file	使其可以处理 2GB 以上的文件

表 3-5　ext4 标准功能标准列

标　志　名	说　　明	ext4 特有
has_journal	支持日志	
extent	使其能够处理 extent 形式的文件	○
huge_file	使其能够处理 2TB 以上的文件	
flex_bg	将数个块组的元数据分别集中在一起布局	○
uninit_bg	具有提高允许未初始化块组的文件系统检测（fsck）速度	○
dir_nlink	可以在 1 个目录下生成 65 000 个以上的目录	○
extra_isize	扩大索引节点的大小[注3]	-
auto_64-bit_support[注4]	支持 64 位的块编号	○

[1]ext4为了支持纳秒或更长的时间戳，使用的是扩展的inode区域。

[2]块数超过32位可处理的情形下自动设置。

小结

本节介绍了从ext2/ext3转换到ext4的方法以及ext4的功能标志。ext4在继承ext2/ext3的文件系统结构的同时，还新增了很多功能，使性能得到提高。用户在使用时也不会明显感觉到与一直使用的ext3有什么变化，这也是ext4的魅力之一。

参考文献

·Ext4（and Ext2/Ext3）Wiki

https：//ext4. wiki.kernel.org/index.php/Main_Page

·Mailing list ARChives

http://marc. info/?l=linux-ext4＆r=1＆w=2

——Akira Fujita

HACK#19　ext4的调整

本节介绍可以从用户空间执行的ext4调整。

ext4在sysfs中有一些关于调整的特殊文件（见表3-6）。使用这些特殊文件，就不用进行内核编译、重启，直接从用户空间确认、更改内核空间的设置参数。

表 3-6　sysfs 中的 ext4 文件

文　件　名	说　　明	默认值
delayed_allocation_blocks	等待延迟分配的块数	

（续）

文　件　名	说　　明	默认值
mb_max_to_scan	分配多块时为找出最佳 extent 而搜索的最大 extent 数	200
mb_min_to_scan	分配多块时为找出最佳 extent 而搜索的最小 extent 数	10
inode_goal	下一个要分配的 inode 编号（调试用）	0（禁用）
inode_readahead_blks	先行读入缓冲器缓存（buffer cache）的 inode 表块 (table block) 数的最大值	32
mb_order2_req	对于大于该值（2 的幂次方）的块，要求使用 Buddy 检索	2
lifetime_write_kbytes	文件系统生成后写入的数据量（KB）	
mb_stats	指定收集 (1) 或不收集 (0) 多块分配的相关统计信息。统计信息在卸载时显示	0（禁用）
max_writeback_mb_bump	进行下一次 inode 处理前尝试写入磁盘的数据量的最大值（MB）	128
mb_stream_req	块数小于该值的文件群被集中写入到磁盘上相近的区域	16
mb_group_prealloc	未指定挂载选项的 stripe 参数时，以该值的倍数为单位确保块的分配	512
session_write_kbytes	挂载后写入文件系统的数据量（KB）	

/sys/fs/ext4/＜设备名＞下有与文件系统相关的各种文件。表3-6所示为这些文件的说

明和默认值的列表。

这里将具体介绍上述文件中最为有效的部分文件。

1.lifetime_write_kbytes与session_write_kbytes

lifetime_write_kbytes虽然不是可调整的入口，但是在SSD上生成ext4的情况下有时非常有用。SSD对写入次数有限制。通过磨损平衡（wear leveling）将写入分散化，从而延长了寿命，但掌握目前为止写入文件系统的数据量对于预测SSD寿命也是非常有用的信息。

lifetime_write_kbytes以千字节为单位记录写入文件系统的数据量，session_write_kbytes以千字节为单位记录文件系统挂载后写入的数据量。

下例中展现的就是lifetime_write_kbytes和session_write_kbytes的值。

即使在刚生成ext4后，lifetime_write_kbytes也会显示已有数据写入。这表示执行mkfs时写入的元数据量。而sesson_write_kbytes中记录的是挂载文件系统的处理中产生的数据被写入的信息。

```
#cat/sys/fs/ext4/sda5/lifetime_write_kbytes
10637
#cat/sys/fs/ext4/sda5/session_write_kbytes
1
```

在这个ext4上生成100MB的文件。可以看到值分别增加了约100MB。由于元数据的写出也会计数，因此是约100MB。

```
#dd if=/dev/urandom of=/mnt/mp1/fle bs=1M count=100
100+0 records in
100+0 records out
104857600 bytes（105 MB）copied，18.322 s，5.7 MB/s
#cat/sys/fs/ext4/sda5/lifetime_write_kbytes
113099
#cat/sys/fs/ext4/sda5/session_write_kbytes
102463
```

再次挂载文件系统后，lifetime_write_kbytes的值会有一些增加。这是因为文件系统的挂载处理中有更新的数据（例如，内存上的超级块信息等）写入磁盘。而session_write_kbyte重置为0。

```
#umount/mnt/mp1
#mount-t ext4/dev/sda5/mnt/mp1
#cat/sys/fs/ext4/sda5/lifetime_write_kbytes
113105
#cat/sys/fs/ext4/sda5/session_write_kbytes
1
```

2.mb_stream_req

ext4中安装了多块分配处理功能，可以降低块分配处理中的CPU成本。可以将多个块分配到物理上连续的区域，提高I/O的效率。

另外，ext4可以使用fallocate系统调用进行块的持久预分配，而多块分配处理中安装的则是内核内部使用的group预分配（下称group PA）和inode预分配（下称inode PA）。group PA由各CPU分别管理，用来将对象文件块（满足某条件的块）排列到物理上较近的区域，inode PA用来将某一个文件的块排列到物理上连续的区域。

这些预分配算法的切换是如何进行的呢？ext4.h里的下列定义就是其阈值。

```
#defne MB_DEFAULT_STREAM_THRESHOLD 16/*64k*/
```

由于是以块数为单位，因此块的大小4KB时阈值为64KB，块的大小为1KB时阈值为16KB。

默认设置表示对于16块以下的块分配处理使用group PA，对于16块以上则使用inode PA。这个值可以使用mb_stream_req来更改。

默认值设置为16块，是因为设置文件等多数文件都在16块（块的大小4KB时阈值为64KB）以内。因此，这些文件通过group PA实现物理上的局部化。在系统启动时等数据

读入处理操作中，通过将文件数据局部化，可以缩短磁盘的寻道时间（seek time）。实际操作mb_stream_req，来验证一下group PA和inode PA的运行和效果。为了便于测定预分配的效果，这次操作中将延迟分配禁用。

```
#mount-t ext4-o nodelalloc/dev/sdb5/mnt/mp1
#cat/proc/mounts|grep sdb5
/dev/sdb5/mnt/mp1 ext4
rw, relatime, user_xattr, barrier=1，nodelalloc, data=ordered 0 0
```

为了使用group PA，将mb_stream_req设置为64，并向文件分配小于这个值的32块。

```
#echo 64＞/sys/fs/ext4/sdb5/mb_stream_req
#for i in 1 2 3；do dd if=/dev/urandom of=/mnt/mp1/fle$i bs=4K count=32＞
/dev/null 2＞＆1；done
#ls-l/mnt/mp1/fle*
-rw-r--r--1 root root 135168 2011-05-17 01：10/mnt/mp1/file1
-rw-r--r--1 root root 135168 2011-05-17 01：10/mnt/mp1/file2
-rw-r--r--1 root root 135168 2011-05-17 01：10/mnt/mp1/file3
```

可以使用e2fsprogsa工具包的fileflag命令来确认分配给磁盘的数据块。根据physical和length显示的值，可以看出通过group PA，把各个文件的数据块排列在物理上相近的位置。

```
#for i in 1 2 3；do flefrag-v/mnt/mp1/fle$i；done
Filesystem type is：ef53
File size of/mnt/mp1/file1 is 131072（32 blocks, blocksize 4096）
ext logical physical expected length flags
0 0 33280 32 eof
/mnt/mp1/file1：1 extent found
Filesystem type is：ef53
File size of/mnt/mp1/file2 is 131072（32 blocks, blocksize 4096）
ext logical physical expected length flags
0 0 33792 32 eof
/mnt/mp1/file2：1 extent found
Filesystem type is：ef53
File size of/mnt/mp1/file3 is 131072（32 blocks, blocksize 4096）
ext logical physical expected length flags
0 0 33312 32 eof
```

然后，为了确认inode PA的运行，再将mb_stream_req设置为16，并向文件分配大于这个值的32块。

```
#rm-rf/mnt/mp1/fle*
#umount/mnt/mp1
#mount-t ext4-o nodelalloc/dev/sdb5/mnt/mp1
```

#echo 16＞/sys/fs/ext4/sdb5/mb_stream_req
#for i in 1 2 3；do dd if=/dev/urandom of=/mnt/mp1/fle$i bs=4K count=32＞/dev/null 2＞＆1；done

```
# for i in 1 2 3; do filefrag -v /mnt/mp1/file$i; done

Filesystem type is: ef53
File size of /mnt/mp1/file1 is 131072 (32 blocks, blocksize 4096)
 ext logical physical expected length flags
   0       0    33280              16
   1      16    33072    33295     16 eof
/mnt/mp1/file1: 2 extents found
Filesystem type is: ef53
File size of /mnt/mp1/file2 is 131072 (32 blocks, blocksize 4096)
 ext logical physical expected length flags
   0       0    33296              16
   1      16    33088    33311     16 eof
/mnt/mp1/file2: 2 extents found
Filesystem type is: ef53
File size of /mnt/mp1/file3 is 131072 (32 blocks, blocksize 4096)
 ext logical physical expected length flags
   0       0    33792              16
   1      16    33104    33807     16 eof
/mnt/mp1/file3: 2 extents found
```

在多于mb_stream_request的块分配处理中，将使用inode PA。inode PA只在引用对象文件期间保留有效的预分配块。从而在按顺序向对象文件写入时，把块分配到物理上连续的区域，抑制碎片的产生。要注意的是，inode PA在块分配中并不是每次都会生成，而是只在多块分配处理中获取的连续空闲块与要求的块数之间有差异时使用。例如，对于16块的分配要求，当多块分配处理检索到连续空闲块有16个时，就不会生成inode PA。

在上述块分配中不生成inode PA, file1的第一个范围（extent）是从物理偏移量33 280分配16块，而从其后的物理偏移量33 296分配的是file2的第一个范围的块。这样就会产生碎片[1]。

为了避免产生碎片，文件系统上就必须有足够的连续空闲块。使用e2fsprogs工具包中包含的e2freefrag命令来确认有多少连续的空闲块。在下例中，Extent Size Range越大，在整体中所占的比例越大，可见这个文件系统上有充足的连续空闲块。

#e2freefrag/dev/sdb5
Device：/dev/sdb5
Blocksize：4096 bytes

Total blocks：1220703

```
Free blocks: 1166377 (95.5%)

Min. free extent: 40 KB
Max. free extent: 917504 KB
Avg. free extent: 358884 KB
Num. free extent: 13

HISTOGRAM OF FREE EXTENT SIZES:
Extent Size Range :  Free extents   Free Blocks  Percent
   32K...    64K-  :             2           20    0.00%
   64M...   128M-  :             2        49102    4.21%
  128M...   256M-  :             5       326180   27.97%
  512M...  1024M-  :             4       791075   67.82%
```

产生的碎片可以使用e4defrag命令来消除。发布版（例如Fedora 14）的e2fsprogs工具包中还未收入e4defrag命令。在使用时就需要获取由Git管理的e2fsprogs工具包。使用git命令获取e2fsprogs的方法请参考HACK#17[2]

下面是执行e4defrag命令的示例。可以看出原来有17个的文件碎片已消除。

```
#e4defrag-v/mnt/mp1/fle1
ext4 defragmentation for/mnt/mp1/file1
[1/1]/mnt/mp3/file1：100%extents：17-＞1[OK]
Success：[1/1]
```

上文介绍了更改mb_stream_request的值时块的分配的差异。通过切换group PA、inode PA，就可以在文件系统上对文件进行布局。有时还可以提高顺序读入中的I/O性能。

3.inode_readahead_blks

使用inode_readahead_blks可以控制进行预读的inode表的数量。inode表是指磁盘上储存inode结构的区域，被分配给各块组。与下列flex_bg标志同时使用，就可以提高运行效率。

下例输出的是启用/禁用功能标志flex_bg时inode表的位置。

·启用flex_bg

```
#mke2fs-t ext4/dev/sda4；dumpe2fs/dev/sda4|egrep"Group|Inode table"
dumpe2fs 1.41.14（22-Dec-2010）
Group 0：（Blocks 0-32767）[ITABLE_ZEROED]
Primary superblock at 0，Group descriptors at 1-1
Inode table at 332-833（+332）
Group 1：（Blocks 32768-65535）[INODE_UNINIT, ITABLE_ZEROED]
Backup superblock at 32768，Group descriptors at 32769-32769
Inode table at 834-1335（bg#0+834）
Group 2：（Blocks 65536-98303）[INODE_UNINIT, BLOCK_UNINIT, ITABLE_ZEROED]
Inode table at 1336-1837（bg#0+1336）
Group 3：（Blocks 98304-131071）[INODE_UNINIT, ITABLE_ZEROED]
Backup superblock at 98304，Group descriptors at 98305-98305
Inode table at 1838-2339（bg#0+1838）
……
```

·禁用flex_bg

```
#mke2fs-t ext4-O^fex_bg/dev/sda4；dumpe2fs/dev/sda4|egrep"Group|Inode table"
dumpe2fs 1.41.14（22-Dec-2010）
Group 0：（Blocks 0-32767）[ITABLE_ZEROED]
Primary superblock at 0，Group descriptors at 1-1
Inode table at 302-803（+302）
Group 1：（Blocks 32768-65535）[INODE_UNINIT, ITABLE_ZEROED]
Backup superblock at 32768，Group descriptors at 32769-32769
Inode table at 33070-33571（+302）
Group 2：（Blocks 65536-98303）[INODE_UNINIT, BLOCK_UNINIT, ITABLE_ZEROED]
Inode table at 65538-66039（+2）
Group 3：（Blocks 98304-131071）[INODE_UNINIT, ITABLE_ZEROED]
Backup superblock at 98304，Group descriptors at 98305-98305
Inode table at 98606-99107（+302）
……
```

启用flex_bg时，“Inode table at”显示的物理块编号连续，可以看出各块组的inode表排列在物理上连续的区域。

flex_bg在标准设置中是将每16块组的元数据集中在一处。因此，各块组的inode表按照0～15、16～31的单位集中在一处。

因此不启用flex_bg时，有时即使为inode_readahead_blks设置较大的值，inode表的区域也并不连续，因此没有什么意义。

在连续访问多个文件的处理中，可以将inode_readahead_blks设置较大的值，一次读入大量inode表，这样效率更高。

在下面这个极端的例子中，将inode_readahead_blks分别设置为1和4096时的内核源代码读入时间进行了比较。启用ext4的flex_bg。

·当inode_readahead_blks为1时

```
#time fnd/mnt/mp1/linux-2.6.39-rc1-type f-exec cat＞/dev/null{}\;
real 3m36.599s
user 0m5.092s
sys 0m43.510s
```

·当inode_readahead_blks为4096时

```
#time fnd/mnt/mp1/linux-2.6.39-rc1-type f-exec cat＞/dev/null{}\;
real 3m23.613s
user 0m5.080s
sys 0m43.341s
```

执行时间的差异为约6%。根据运用环境的不同也会有一些差异，在经常需要连续读取多个文件的环境下，就可以通过更改inode_readahead_blks来提高读入性能。

小结

本章介绍了使用sysfs的ext4调整。可以从用户空间对内核参数进行操作，非常方便。如果在ext4的源代码中发现了其他可以从用户空间进行调整的项目，请尝试向邮件地址列表投稿。对于新的结构或功能会有积极的参考作用，这时如果有补丁的话一定会得到很多反馈。

[1]本次为了便于测定而禁用了延迟分配，因此结果非常明显。ext4默认是启用延迟分配的，因此在实际的块分配中能够尽量减少碎片的产生。

[2]e2fsprogs的master分支内包含e4defrag命令，因此不需要切换分支。

参考文献

·Ext4（and Ext2/Ext3）Wiki

https：//ext4. wiki.kernel.org/index.php/Main_Page

·Mailing list ARChives

http://marc. info/?l=linux-ext4＆r=1＆w=2

——Akira Fujita

HACK#20　使用fio进行I/O的基准测试

本节介绍使用fio进行模拟各种情况的I/O基准测试的操作方法。

I/O的基准测试中有无数需要考虑的因素。是I/O依次访问还是随机访问？是通过read/write的I/O？还是通过访问mmap的空间的I/O？是单一进程发出的I/O？还是多个进程同时发出的I/O？进程是受I/O限制还是受CPU限制？等等。

如果使用fio，就不需要每次都根据不同情况来编写用于性能评估的程序，就可以模拟这些情况的I/O。

安装fio

Fedora、Ubuntu等主流发布版中都备有fio的二进制文件包。请使用yum、apt等安装fio工具包。

这里按照Fedora 13中包含的fio版本1.36来进行说明。

想要使用最新版时，请先从下列网页下载fio的源代码，再进行安装。

程序页

http://freshmeat. net/projects/fio

Git仓库

git：//git. kernel.org/pub/scm/linux/kernel/git/axboe/fio.git

基本执行方法

指定记载了I/O操作模式的设置文件，然后启动fio命令，这就是fio最基本的执行方法。大多数的项目可以不使用配置文件而通过命令行选项来指定。首先举出两种分别使用命令行选项的方法和配置文件的方法的简单例子，了解基本执行方法和命令行/设置文件的对应情况。

第一个示例执行的是下列操作。

·进行10MB的顺序读入。

·同时，其他进程随机进行5MB的写入。

·使用read（2）和write（2）进行读写。

·使用Direct I/O。

在fio命令行进行这些设置时的操作如下。在当前目录下会生成读写用的文件，因此要在可以写入的目录下执行。

```
$fo--name=global--direct=1--name=read--rw=read--size=10m--name=write
--rw=randwrite--size=5m
```

与上述命令行选项具有相同意义的配置文件如下所示。

```
#cat fo_exam.fo
[global]
direct=1
[readjob]
size=10m
rw=read
[writejob]
size=5m
rw=randwrite
```

使用这个配置文件执行fio命令如下。

```
$fo simple_read.fo
```

命令行选项与配置文件的各项之间的关系非常明显。这里简单介绍配置文件的各项的意义。

以#开头的是注释（comment）。内容直到行尾都被忽略。

方括号表示[]作业（job）定义选项的开始。方括号内是作业的名称。作业可以任意命名。但是global这个名称是内部使用的。作业global是用来定义所有作业共同的设置项。

fio按照每个作业生成进程，生成的进程根据设置进行实际的I/O操作。因此，fio的配置文件中除了global选项以外，必须要定义多个作业。

global选项中设置了direct=1。将direct设置为1时，使用的就Direct I/O。未指定时，就等同于direct=0（经由一般页面缓存进行I/O）。

接下来定义名为readjob的作业。

readjob作业中使用size设置I/O操作的大小（字节数）。后缀m表示兆字节。后缀可以使用k、m、g、t、p。readjob作业的进程在进行了size所设置的大小的I/O后就会结束。

rw用来设置I/O模式。readjob作业中指定的是表示顺序读出的read。其他的将在下一节中介绍。

最后再定义一个名称为writejob的作业。

writejob作业将进行I/O的大小设置为5MB, I/O模式设置为随机写入（randwrite）。

按照这个设置执行fio时，首先会在当前目录下生成用于I/O的文件，进行同步处理，取消页面缓存。然后，生成与readjob作业相对应的进程和与writejob作业相对应的进程，

进行各自设置的I/O操作。各作业在完成size所设置的字节数的I/O后，就会结束。所有作业结束后，结果就会显示在控制台上。

输出结果包括很多信息。这些内容将在下一节中详细介绍。

模拟实验的例子和输出的意义

现在已经掌握了基本执行方法，就可以尝试生成并执行模拟某种情况的配置文件，然后对输出进行分析。

先生成符合下列情况的配置文件。

·在文件数据的基础上执行查询（query）并返回发出请求的进程有两个正在执行。每隔10毫秒接受查询的请求并执行，从接受请求到返回结果的演算过程花费5毫秒。

·1个正在运行的进程，它用来将访问记录写入磁盘。记录每1秒通过direct I/O写入。通过AIO实现I/O复用（multiplexing）。

·与此同时，执行文件系统备份处理。

模拟这种情况的配置文件以及其中使用的各种配置项的意义如表3-7所示。另外，模拟时间设置为执行30秒后结束。

```
#server_sim. fo
[global]
directory=/mnt/sdb
runtime=30
time_based
[query]
size=100m
rw=randread
ioengine=mmap
thinktime=10k
thinktime_spin=5k
filename=query. dat
numjobs=2
[log]
size=10m
rw=randrw
ioengine=libaio
iodepth=32
thinktime=1m
thinktime_blocks=2
blocksize=1k，4k
direct=1
[backup]
size=100m
```

rw=randrw
thinktime=1k

表 3-7 fio 的配置项

配 置 项	说 明
blocksize	1 次的 I/O 大小。单位为字节。使用逗号隔开，可以分别指定 read、write。默认值为 4KB
direct	指定 1 时使用 Direct I/O。未指定时等同于指定为 0。使用经由页面缓存的 I/O
directory	存放 I/O 对象文件的目录。未指定时为当前目录
filename	I/O 对象文件名。默认由 fio 自动决定每个作业及进程的名称。在 filename 中可以指定设备文件。这时不经由文件系统，而是从设备直接读写数据。在上述设置中要让 query 作业的两个进程读取相同的文件，因此明确指定了 query.dat 这一文件名
ioengine	指定进程的 I/O 发出方法。可以指定下列内容。（具有代表性的）
	• sync 使用 read(2)、write(2) 的一般 I/O
	• libaio Linux AIO
	• posixaio 使用 glibc 的 aio_read(3) 和 aio_write(3) 的 POSIX AIO
	• mmap 使用 mmap(2) 及 memcpy(3) 的读写
	• cpuio 不进行 I/O。用于定义模拟执行 CPU 限制进程和 CPU 有负载的作业
iodepth	使用 AIO 时，同时发出 I/O 数的上限值。用于模拟用户进程为了防止大量并发 I/O 发生竞争而对 I/O 复用度设限的情况。默认值为 1
numjobs	通过这个作业定义执行的进程数。未指定时进程数为 1
runtime	执行时间。单位为秒。执行作业的进程在 I/O 的数据量达到 size 指定的值，或经过 runtime 指定的时间后就会结束。（参照 time_based）

（续）

配 置 项	说 明
rw	指定 I/O 模式。可以指定下列内容。 • read 顺序读 • write 顺序写 • randread 随机读 • randwrite 随机写 • rw 顺序读 / 写混合 • randrw 随机读 / 写混合
size	指定到作业结束为止进行 I/O 的数据量。单位为字节
thinktime	从发出 I/O 到下一次发出 I/O 的等待时间。单位为微秒。等待时进程通过 nanosleep(2) 休眠。（参照 thinktime_spin）
thinktime_blocks	设置在发出几次 I/O 后进入 thinktime 设置的等待。默认值为 1
thinktime_spin	设置 thinktime 指定的等待时间中不休眠而是实际消耗 CPU 等待的时间。单位为微秒
time_based	指定到达 runtime 所指定的时间为止反复作业。未指定 time_based 时，size 指定的数量的 I/O 完成后，作业的进程结束。指定 time_based 时，在 runtime 设置的时间内持续发出 I/O

然后实际执行，并详细查看输出结果。

```
$fo server_sim.fo
query：（g=0）：rw=randread, bs=4K-4K/4K-4K, ioengine=mmap, iodepth=1
query：（g=0）：rw=randread, bs=4K-4K/4K-4K, ioengine=mmap, iodepth=1
log：（g=0）：rw=randrw, bs=1K-1K/4K-4K, ioengine=libaio, iodepth=32
backup：（g=0）：rw=randrw, bs=4K-4K/4K-4K, ioengine=sync, iodepth=1
Starting 4 processes
query：Laying out IO file（s）（1 file（s）/100MB）
log：Laying out IO file（s）（1 file（s）/10MB）
backup：Laying out IO file（s）（1 file（s）/100MB）
query：（groupid=0，jobs=1）：err=0：pid=3158
read：io=6，740KB, bw=225KB/s, iops=56，runt=30006msec
clat（usec）：min=6，max=124K, avg=7553.49，stdev=5995.06
bw（KB/s）：min=162，max=254，per=25.31%，avg=225.24，stdev=15.52
cpu：usr=28.83%，sys=0.24%，ctx=3544，majf=1639，minf=75
IO depths：1=100.0%，2=0.0%，4=0.0%，8=0.0%，16=0.0%，32=0.0%，>=64=0.0%
submit：0=0.0%，4=100.0%，8=0.0%，16=0.0%，32=0.0%，64=0.0%，>=64=0.0%
complete：0=0.0%，4=100.0%，8=0.0%，16=0.0%，32=0.0%，64=0.0%，>=64=0.0%
issued r/w：total=1685/0，short=0/0
lat（usec）：10=2.67%，20=0.06%，500=0.18%，750=0.65%，1000=0.36%
```

lat（msec）：2=1.54%，4=15.73%，10=58.16%，20=17.69%，50=2.79%
lat（msec）：100=0.12%，250=0.06%
query：（groupid=0，jobs=1）：err=0：pid=3159
read：io=6，772KB, bw=226KB/s, iops=56，runt=30008msec
clat（usec）：min=6，max=128K, avg=7470.76，stdev=6163.17
bw（KB/s）：min=181，max=260，per=25.45%，avg=226.47，stdev=14.27
cpu：usr=28.99%，sys=0.20%，ctx=3622，majf=1630，minf=88
IO depths：1=100.0%，2=0.0%，4=0.0%，8=0.0%，16=0.0%，32=0.0%，＞=64=0.0%
submit：0=0.0%，4=100.0%，8=0.0%，16=0.0%，32=0.0%，64=0.0%，＞=64=0.0%
complete：0=0.0%，4=100.0%，8=0.0%，16=0.0%，32=0.0%，64=0.0%，＞=64=0.0%
issued r/w：total=1693/0，short=0/0
lat（usec）：10=3.66%，20=0.06%，500=0.35%，750=0.77%，1000=0.06%
lat（msec）：2=1.24%，4=16.42%，10=55.64%，20=19.31%，50=2.30%
lat（msec）：100=0.12%，250=0.06%
log：（groupid=0，jobs=1）：err=0：pid=3160
read：io=39，936B, bw=1，311B/s, iops=1，runt=30449msec
slat（usec）：min=8，max=63，avg=27.92，stdev=19.38
clat（msec）：min=36，max=16，815，avg=10042.82，stdev=5584.03
bw（KB/s）：min=0，max=1，per=0.01%，avg=0.06，stdev=0.24
write：io=197KB, bw=6，625B/s, iops=1，runt=30449msec
slat（usec）：min=10，max=89，avg=33.40，stdev=22.97
clat（msec）：min=33，max=16，778，avg=11045.30，stdev=5371.05
bw（KB/s）：min=0，max=7，per=0.56%，avg=2.62，stdev=2.59
cpu：usr=0.00%，sys=0.01%，ctx=31，majf=0，minf=21
IO depths：1=1.1%，2=2.2%，4=4.5%，8=9.0%，16=18.0%，32=65.2%，＞=64=0.0%
submit：0=0.0%，4=100.0%，8=0.0%，16=0.0%，32=0.0%，64=0.0%，＞=64=0.0%
complete：0=0.0%，4=98.3%，8=0.0%，16=0.0%，32=1.7%，64=0.0%，＞=64=0.0%
issued r/w：total=39/50，short=0/0
lat（msec）：50=2.25%，2000=4.49%，＞=2000=93.26%
backup：（groupid=0，jobs=1）：err=0：pid=3161
read：io=13，556KB, bw=452KB/s, iops=112，runt=30005msec
clat（usec）：min=419，max=104K, avg=6669.29，stdev=4584.93
bw（KB/s）：min=341，max=525，per=50.82%，avg=452.29，stdev=40.41
write：io=14，072KB, bw=469KB/s, iops=117，runt=30005msec
clat（usec）：min=10，max=98，704，avg=79.48，stdev=2190.03
bw（KB/s）：min=321，max=632，per=100.32%，avg=469.52，stdev=72.87
cpu：usr=0.38%，sys=0.74%，ctx=10302，majf=0，minf=28
IO depths：1=100.0%，2=0.0%，4=0.0%，8=0.0%，16=0.0%，32=0.0%，＞=64=0.0%
submit：0=0.0%，4=100.0%，8=0.0%，16=0.0%，32=0.0%，64=0.0%，＞=64=0.0%
complete：0=0.0%，4=100.0%，8=0.0%，16=0.0%，32=0.0%，64=0.0%，＞=64=0.0%
issued r/w：total=3389/3518，short=0/0
lat（usec）：20=38.63%，50=12.25%，500=0.51%，750=0.61%，1000=0.04%
lat（msec）：2=1.61%，4=9.64%，10=28.99%，20=7.37%，50=0.25%
lat（msec）：100=0.10%，250=0.01%
Run status group 0（all jobs）：
READ：io=27，107KB, aggrb=890KB/s, minb=1KB/s, maxb=462KB/s, mint=30005msec，
maxt=30449msec
WRITE：io=14，269KB, aggrb=468KB/s, minb=6KB/s, maxb=480KB/s, mint=30005msec，
maxt=30449msec
Disk stats（read/write）：
sdb：ios=6698/2302，merge=0/26478，ticks=48982/1143531，in_queue=1207586，util=93.27%

第一部分输出的是已执行进程的信息，分别输出了名称、I/O模式、块的大小等设置。有两个query是因为指定为numjob=2，所以要执行两个进程。

接下来第一行为query的两个段落是query作业两个进程的结果，其后显示的分别是log作业和backup作业的结果。下面对比各部分的内容，看一下各输出表示的意义。

从read：和write：开始的3行或4行表示的是关于读入和写入的数据量、平均带宽、延迟。平均带宽是将总数据量除以作业执行时间得出的值，因此在thinktime较长的作业中值较低。clat（completion latency）的行为延迟，是作业进程开始向内核发出I/O请要到完成为止的时间，即从调出read（2）等直到返回的时间。log作业由于使用的是AIO，因此多输出一个slat（submitting latency）延迟。这表示I/O发出要求滞留在作业进程内部的queue时间。

从query作业的延迟来看，平均花费7.5毫秒左右，最多花费130毫秒左右。10毫秒的查询间隔中大部分时间都耗费在等待I/O上。log作业中出现了最长16秒的延迟。这时应当重新设计系统，分散I/O负载。

小贴士：clat在read（2）或Direct I/O的write（2）中I/O实际花费的时间，而在常用的经由页面缓存的write（2）中只是将数据存放到页面缓存所需的时间。上例中backup作业的write就相当于这种情况，因此其值平均为79微秒，比其他情况短得多。

I/O depths的行表示通过AIO实现复用的I/O数与时间之间的关系。例如，log作业的IO depths中的“8=9.0%，16=18.0%”，就表示9～16个I/O同时执行的时间相当于所有执行时间的18.0%。由于I/O复用只存在于AIO的情况下，因此在log以外的作业都是“1=100%”。

从log作业的IO depths可以看出，65.2%的时间都达到复用上限值附近的19～32。这也显示I/O负载仍然过高。

最后两个段落是关于所有进程总共的统计值。输出所有I/O的数据量的合计结果等。

小结

本节使用fio进行实际使用情况的I/O模拟实验，介绍了输出的结果。fio有非常多的选项，可以进行更加精确和详细的设置，由于数量庞大，这里无法一一列举。源代码包含的文档和man中有详细的记载，但都是英文。参考这些内容并熟练使用I/O操作，I/O基准测试就能成为强有力的工具。

——Munehiro IKEDA

HACK#21 FUSE

本节将介绍使用用户进程的文件系统框架—FUSE。

FUSE概要

FUSE（Filesystem in Userspace，用户空间文件系统），是用来生成用户空间的一般进程的框架。使用FUSE，就可以以一般应用程序进程的形式生成独特的文件系统，与已有的文件系统同样进行挂载。从Linux 2.6.14开始实际安装FUSE。

例如，在最近的Linux发布版中，有一些标准配置用于挂载Windows的文件系统NTFS的ntfs-3g（Ubuntu等）。当连接到存在NTFS格式文件系统的分区表所在的磁盘时，经由gvfs挂载。此时，使用FUSE安装到用户空间的ntfs-3g开始将NTFS文件系统挂载到用户的目录树。

此外还有ZFS on FUSE。ZFS适用的是CDDL这个与GPL没有互换性的许可证。因此它不能整合到拥有GPL许可证的Linux内核中。在这种情况下，使用FUSE安装ZFS，从而能够使用ZFS文件系统，就是ZFS on FUSE。一旦启动zfs-fuse守护进程（demon），就可以使用zfs或zpool命令进行ZFS的操作。

安装FUSE文件系统

libfuse就是用于简单安装使用FUSE的独特文件系统的标准库。例如，安装并读入专用的文件系统时，只需要生成下列4个功能。

getattr　获取文件属性

readdir　获取目录条目

open　打开文件

read　读入文件

卸载

使用FUSE挂载的文件系统，可以使用fusermount命令来卸载。

```
$fusermount-u挂载点
```

使用FUSE的文件系统

这里将介绍使用从普通发布版中可以获取的FUSE的文件系统。

---

sshfs

将可以把SSH远程登录的机器的目录挂载到本地机器上，在与远程服务器频繁进行文件交换时非常便利。例如，将remote主机的admin用户的foo目录挂载到本地的～/remote-foo时，命令行如下。类似一般的SSH，同样要求输入密码。

$sshfs hshimamoto@remote：foo～/remote-foo

在此之后，对本地机器的～/remote的foo目录进行的处理就是对远程机器remote的foo目录的处理。

fuseiso

挂载ISO映像文件。一般挂载ISO映像时是使用loopback设备进行挂载的，但有时普通用户权限是无法操作loopback设备的。另外loopback设备还存在可利用次数的限制。使用fuseiso，就可以很简单地将ISO映像挂载到自己的文件系统，并参照其内容。

#fuseiso foo.iso～/iso

---

encfs

加密文件系统。用户将特定目录加密，然后挂载将该目录解密后的文件系统。

已加密的文件（目录）名和内容通过文件系统生成时指定的算法加密，但需要注意的是，目录中的文件数或文件大小、属性等不会因为加密而修改。

命令示例如下。创建目录enc-foo，并挂载为dec-foo。

```
$mkdir～/enc-foo
$mkdir～/dec-foo
$encfs～/enc-foo～/dec-foo
```

首次挂载加密目录时，将进行加密的初始设置。将显示如下信息，输出用来进行加密设置的提示符。

生成新的加密卷标。

```
Please choose from one of the following options：
enter"x"for expert configuration mode，
enter"p"for pre-configured paranoia mode，
anything else, or an empty line will select standard mode.?＞
```

针对详细的设置这里不作介绍。直接按【Enter】键，使用默认设置。

```
Standard configuration selected.
```

设置已完成。生成下列属性的文件系统：

```
文件系统加密算法："ssl/aes"，版本3：0：2
Filename encoding："nameio/block"，version 3：0：1
键大小：192位
Block Size：1024 bytes
Each file contains 8 byte header with unique IV data.
Filenames encoded using IV chaining mode.
File holes passed through to ciphertext.
Now you will need to enter a password for your filesystem.
You will need to remember this password, as there is absolutely
no recovery mechanism.However, the password can be changed
later using encfsctl.
新的Encfs密码：
确认Encfs密码：
```

再设置用来加密、解密的密码就完成了。尝试在dec-foo目录下创建文件。

```
$vi～/dec-foo/bar.txt
$cat～/dec-foo/bar.txt
Hello Encfs!
```

卸载dec-foo后，就难以用普通的方法来参照这个加密目录。

```
$fusermount-u～/dec-foo
```

看一下enc-foo目录，可以发现由于已经加密，因此内容不是文本，而是二进制数据。

```
$ls enc-foo/
QQJqAaAW-hx1QiWGH8fRHplZ
$fle enc-foo/QQJqAaAW-hx1QiWGH8fRHplZ
enc-foo/QQJqAaAW-hx1QiWGH8fRHplZ：data
```

再次使用encfs命令进行挂载时，这次只要求输入密码。

```
$encfs～/enc-foo～/dec-foo
EncFS密码：
$ls dec-foo/
bar.txt
$cat dec-foo/bar.txt
Hello Encfs!
```

小结

本节介绍了FUSE，还介绍了一些使用FUSE的便捷文件系统。此外可能还有其他使用FUSE的文件系统。

参考文献

·Documentation/filesystems/fuse. txt

·FUSE（http：//fuse. sourceforge.net/）

——Hiroshi Shimamoto

第4章　网络

本章将介绍与网络相关的内核功能。内容包括TUN/TAP设备、网桥设备、VLAN设备、bonding设备和网络调度、dropwatch。

HACK#22　如何控制网络的带宽

本节介绍控制网络带宽的功能。

Linux内核中安装有称为网络调度或分组调度的带宽控制。这个功能可以控制每个网络设备传输的吞吐量。通过控制带宽，就可以优先进行重要的通信，或者优先其他服务的性能。

本节将以CentOS 5.4所提供的CBQ（Class Based Queueing）的设置为例进行说明。需要安装iproute数据包。

设置带宽控制

CBQ是指以具有优先级的类为单位分配传输带宽。为每个类准备配置文件并介绍控制带宽的方法。

iproute工具包中具有样本/etc/sysconfig/cbq/cbq-0000.example。

```
#cat/etc/sysconfg/cbq/cbq-0000.example
DEVICE=eth0，10Mbit，1Mbit
RATE=128Kbit
WEIGHT=10Kbit
PRIO=5
RULE=192.168.1.0/24
```

下面以这个样本为基础，对各个项进行说明。

DEVICE

DEVICE选项的是作为带宽控制对象的网络设备。

格式如下。

DEVICE=＜iframe＞，＜bandwidth＞[，＜weight＞]

ifname网络接口。在上例中为eth0。bandwidth指定的是网络设备的物理带宽。如果是千兆以太网（Gigabit Ethernet）则为1000Mbit。weight是根类的比重。值越大，表示根类一次处理的数据比例越大。根类是针对每个设备分别生成的。推荐将weight指定为bandwidth的1/10。

RATE

RATE指定的是分配到该类的带宽。单位为bit或bps。

bit对应bits/秒，bps对应bytes/秒。设置为100Mbytes/秒时，需指定RATE=100Mbps。WEIGHT WEIGHT用来设置该类的比重。值越大，表示该类一次处理的数据比例越大。推荐将WEIGHT指定为RATE的1/10。

PRIO

PRIO为该类的优先级。可设定为1～8。默认值为5。数字越大，表示优先级越低。PRIO为8时WEIGHT自动变为1。

RULE

RULE指定的是带宽控制对象。可以使用通信对象的IP地址或端口号来限定，因此也可以只控制HTTP或FTP的带宽。格式如下。

RULE=[[saddr[/prefix]][：port[/mask]]，][daddr[/prefix]][：port[/mask]]

仅对192.168.0.100进行带宽控制时设置如下。

RULE=192. 168.0.100

仅对HTTP（端口号80）进行控制时设置如下。

```
RULE=192.168.0.100：80，
```

其他参数或配置的详细内容将在下一节中介绍。

TIME

TIME参数在上例中并没有出现。格式可以按照下列方式通过时间或星期来修改带宽RATE和WEIGHT的配置。

```
TIME=[＜dow＞，＜dow＞，……，＜dow＞/]＜from＞-＜till＞；＜rate＞/＜weight＞[/＜peak＞]
```

描述如下。

```
TIME=18：00-06：00；256Kbit/25Kbit
```

启动脚本

CBQ的设置使用tc（traffic control）命令来进行。但是tc命令的选项很多，非常复杂。iproute工具包中含有读入配置文件并自动执行tc命令的启动脚本，这里就使用这个脚本。

这个启动脚本默认读入/etc/sysconfig/cbq/中的cbq-*文件。由于这里已经存在示例文件，因此可以尝试运行脚本。

```
#chmod 777/usr/share/doc/iproute-2.6.18/examples/cbq.init-v0.7.3
#/usr/share/doc/iproute-2.6.18/examples/cbq.init-v0.7.3 start
**CBQ：failed to compile CBQ configuration!
```

小贴士：RHEL6中有/etc/sysconfig/cbq/，但是没有cbq.init文件。RHEL6中的/sbin/cbq就相当于cbq.init。

在这个示例中进行CBQ的设置，就会出错。脚本已运行的命令记录在/var/cache/cbq.init中。

```
#cat/var/cache/cbq.init
/sbin/tc qdisc del dev eth0 root
/sbin/tc qdisc add dev eth0 root handle 1 cbq bandwidth 10Mbit avpkt 3000 cell 8
/sbin/tc class change dev eth0 root cbq weight 1Mbit allot 1514
**CBQ：class ID of cbq-0000.example must be in range＜0002-FFFF＞!
```

最后显示的是错误的详细信息。cbq的配置文件名为/etc/sysconfig/cbq/cbq-＜类ID＞，类ID必须设置2以上的数值。

在上例中，对于配置文件由于类ID为0，因此启动失败。根据环境将文件名改为cbq-2.eth3再次运行。在eth3中将发往IP地址192.168.0.100的分组通信设置为100Mbit/sec。

```
#cat/etc/sysconfg/cbq/cbq-2.eth3
DEVICE=eth3，1000Mbit，100Mbit
RATE=100Mbit
WEIGHT=10Mbit
```

```
RULE=192.168.0.100
#mv/etc/sysconfg/cbq/cbq-0000.example/etc/sysconfg/cbq/_cbq-0000.example
#/usr/share/doc/iproute-2.6.22/examples/cbq.init-v0.7.3 start
```

设置内容可以使用tc命令来确认。

#tc-s-d class show dev eth3

或者也可以通过/var/cache/cbq.init的内容来确认。

```
#cat/var/cache/cbq.init
/sbin/tc qdisc del dev eth3 root
/sbin/tc qdisc add dev eth3 root handle 1 cbq bandwidth 1000Mbit avpkt 3000
cell 8
/sbin/tc class change dev eth3 root cbq weight 100Mbit allot 1514
/sbin/tc class add dev eth3 parent 1：classid 1：2 cbq bandwidth 1000Mbit rate
100Mbit weight 10Mbit
prio 5 allot 1514
cell 8 maxburst 20 avpkt 3000 bounded
/sbin/tc qdisc add dev eth3 parent 1：2 handle 2 tbf rate 100Mbit buffer 10Kb/8 limit 15Kb mtu 1500
/sbin/tc filter add dev eth3 parent 1：0 protocol ip prio 100 u32 match ip dst 192.168.0.100 classid 1：2
```

使用下列命令也可以确认。

```
#/usr/share/doc/iproute-2.6.22/examples/cbq.init-v0.7.3 list
```

确认带宽控制

本节使用nuttcp来确认吞吐量。

```
#wget-t0-c http：//www.lcp.nrl.navy.mil/nuttcp/nuttcp-5.5.5.tar.bz2
#tar jxvf nuttcp-5.5.5.tar.bz2
#cd nuttcp-5.5.5
#gcc-O2-o nuttcp nuttcp-5.5.5.c
```

首先，在IP地址192.168.0.100（receiver）一方作为服务器启动nuttcp。

```
[receiver]#./nuttcp-S
```

发送（sender）方按照下列方式执行nuttcp。默认为发送数据10秒钟，计算吞吐量。

```
[sender]#./nuttcp 192.168.0.100
0.1685 MB/10.00 sec=0.1413 Mbps 0%TX 0%RX
```

结果为141kbps，非常缓慢。停止CBQ，再次计算，就会得到如下所示的接近以太网物理带宽上限的速度。

```
[sender]#/usr/share/doc/iproute-2.6.22/examples/cbq.init-v0.7.3 stop
[sender]#./nuttcp 192.168.0.100
```

1125.2779 MB/10.03 sec=941.4133 Mbps 5%TX 13%RX

使用数据包捕获进行确认时，每隔约200毫秒传输一次数据。这是因为TSO（TCP Segmentation Offload）与CBQ的组合使其成为了无意图的动作。

因此这时需要禁用TSO。使用ethtool命令来确认TSO的设置。

```
[sender]#ethtool-k eth3
Offload parameters for eth3：
Cannot get device udp large send offload settings：Operation not supported
rx-checksumming：on
tx-checksumming：on
```

```
scatter-gather：on
tcp segmentation offload：on TSO启用
udp fragmentation offload：off
generic segmentation offload：off
```

本次使用的NIC具有TSO功能，默认是启用的。因此需要使用ethtool工具将TSO功能禁用，再次使用nuttcp命令来计算吞吐量。

```
[sender]#ethtool-K eth3 tso off
[sender]#ethtool-k eth3
Offload parameters for eth3：
Cannot get device udp large send offload settings：Operation not supported
rx-checksumming：on
tx-checksumming：on
scatter-gather：on
tcp segmentation offload：off
udp fragmentation offload：off
generic segmentation offload：off
[sender]#./nuttcp 192.168.0.100
92.3214 MB/10.00 sec=77.4083 Mbps 0%TX 3%RX
```

结果为77Mbps，与刚才的数值相比，虽然性能得到了改善，但77Mbps与设置值100Mbps相比，吞吐量明显降低。

这是因为对于千兆以太网的NIC来说，TBF的缓冲区不够大。TBF（Token Bucket Filter）是Qdisc（queueing discipline）之一，用来把通信数据包放入队列，这里不作具体介绍。在10Mbps的情况下推荐将缓冲区大小设置为10kb/8。可以在CBQ配置文件的BUFFER项目中进行设置。本次为Gbit，因此设置为1000kb/8。

```
[sender]#cat/etc/sysconfg/cbq/cbq-2.eth3
DEVICE=eth3，1000Mbit，100Mbit
RATE=100Mbit
WEIGHT=10Mbit
RULE=192.168.0.100
BUFFER=1000kb/8
[sender]#/usr/share/doc/iproute-2.6.22/examples/cbq.init-v0.7.3 restart
[sender]#./nuttcp 192.168.0.100
116.0705 MB/10.01 sec=97.3100 Mbps 0%TX 3%RX
```

这样就可以使用CBQ进行正确的带宽控制。

小结

本节介绍了使用CBQ进行网络带宽控制的方法。通过限制优先级较低的通信的带宽，可以有效地优先执行重要的通信。在Web浏览器上设置CBQ的WebCBQ工具现在已经公开。将文件解压缩，对Apache的设置进行一些编辑，就可以从远程设置网络带宽。关于使用SR-IOV的带宽控制，请参考HACK#35。

参考文献

·CBQ. init traffic management script

http://sourceforge. net/projects/cbqinit/files/cbqinit/

·WebCBQ Bandwidth Manager

http://sourceforge. net/projects/webcbq/

·Linux Advanced Routing＆Traffic Control HOWTO[第9章队列规则与带宽管理]

http://linuxjf. sourceforge.jp/JFdocs/Adv-Routing-HOWTO/lartc.qdisc.classful.html

——Naohiro Ooiwa

HACK#23　TUN/TAP设备

本节介绍在Linux中实现网络通道的TUN/TAP设备。

TUN/TAP设备

TUN/TAP设备是TUN（Tunnel）设备和TAP设备的总称。Linux的内核源代码中加入了Universal TUN/TAP设备。因此可以很方便地生成TUN/TAP设备，实现网络隧道。

这里将简单介绍TUN设备和TAP设备。用一句话来说，TUN设备用来实现三层隧道，TAP设备用来实现二层隧道。

TUN设备

这是虚拟的点对点设备，在一般的TCP/IP网络中处理的是三层IP数据包。在Linux中一般体现为用tunX表示的点对点的网络设备。

对TUN设备tun0进行ifconfig的输出如下所示。

```
#ifconfg tun0
tun0 Link encap：UNSPEC HWaddr 00-00-00-00-00-00-00-00-00-00-00-00-00-00-00-00
inet addr：192.168.1.1 P-t-P：192.168.1.2 Mask：255.255.255.255
UP POINTOPOINT RUNNING NOARP MULTICAST MTU：1500 Metric：1
RX packets：0 errors：0 dropped：0 overruns：0 frame：0
TX packets：0 errors：0 dropped：0 overruns：0 carrier：0
collisions：0 txqueuelen：500
RX bytes：0（0.0 b）TX bytes：0（0.0 b）
```

TAP设备

这是虚拟的以太网设备，在TCP/IP网络中处理二层的以太网帧。在Linux中一般体现为用tapX表示的以太网络设备。

对TAP设备tap0进行ifconfig的输出如下所示。

```
#ifconfg tap0
tap0 Link encap：Ethernet HWaddr D2：76：E4：DD：E0：F8
BROADCAST MULTICAST MTU：1500 Metric：1
RX packets：0 errors：0 dropped：0 overruns：0 frame：0
TX packets：0 errors：0 dropped：0 overruns：0 carrier：0
collisions：0 txqueuelen：500
RX bytes：0（0.0 b）TX bytes：0（0.0 b）
```

以太网帧从用户空间的应用程序发送到用于网络隧道的设备—TAP设备，对操作系统来说就是以太网帧从外部到达这个TAP设备。从外部接收的以太网帧经由操作系统的网络栈发送到TAP设备，然后由用户空间的应用程序接收。

应用程序示例

VPN（Virtual Private Network）

在使用TUN/TAP设备的应用程序中，VPN是最常见的。例如，实际安装的VPN之一Vtun，就是本章介绍的Universal TUN/TAP驱动程序的母程序。此外还有OpenVPN等。TUN/TAP设备对于VPN可以说是必需的。

虚拟机的网络连接

在Linux的虚拟结构KVM中所使用的qemu，在生成虚拟网络时使用TAP。如果没有TAP设备，将虚拟机的NIC桥接到物理NIC的结构是无法实现的。

使用TUN/TAP设备的程序设计示例

这里简单编写使用TUN/TAP设备的样本程序，并确认其运行结果。

生成点对点连接的TUN设备，对ICMP的ECHO进行处理，来确认TUN设备运行的情况。示例程序为tunpong.c，是在只有ICMP的ECHO REQUEST进入的前提下生成的。这个程序只是为了查看TUN设备的使用方法，不包括错误处理等。

例4-1　tunpong.c

```
#include＜fcntl.h＞
#include＜sys/ioctl.h＞
#include＜sys/socket.h＞
#include＜linux/if.h＞
#include＜linux/if_tun.h＞
#include＜unistd.h＞
#include＜stdlib.h＞
#include＜stdio.h＞
#include＜string.h＞
int tun_open（void）
{
struct ifreq ifr；
int fd；
char dev[IFNAMSIZ]；
char buf[512]；
/*打开用来操作TUN/TAP设备的文件*/
fd=open（"/dev/net/tun"，O_RDWR）；
/*生成TUN设备（tun0）*/
memset（＆ifr，0，sizeof（ifr））；
ifr.ifr_flags=IFF_TUN|IFF_NO_PI；
strncpy（ifr.ifr_name，"tun%d"，IFNAMSIZ）；
ioctl（fd, TUNSETIFF，＆ifr）；
strncpy（dev, ifr.ifr_name, IFNAMSIZ）；
/*使用ifconfig命令添加IP地址*/
sprintf（buf，"ifconfig%s 192.168.1.1 pointopoint 192.168.1.2"，dev）；system（buf）；
return fd；
}
void dump_pkt（unsigned char*pkt, int len）
{
int i；
for（i=0；i＜len；i++）
printf（"%02x"，pkt[i]）；
printf（"￥n"）；
}
void pingpong（int fd）
{
fd_set fds；
int len；
```

```
unsigned char pkt[512];
FD_ZERO（＆fds）；
FD_SET（fd，＆fds）；
select（fd+1，＆fds, NULL, NULL, NULL）；
if（FD_ISSET（fd，＆fds））{
len=read（fd, pkt，512）；
dump_pkt（pkt, len）；
/*ICMP头部分为0x08（echo request）*/
if（pkt[20]！=0x08）
return；
/*将IP头的src设为192.168.1.2，dst设为192.168.1.1*/
pkt[15]=0x02；
pkt[19]=0x01；
pkt[20]=0x00；/*echo reply*/
write（fd, pkt, len）；
}
}
int main（int argc, char**argv）
{
int fd；
fd=tun_open（）；
for（；）
pingpong（fd）；
return 0；
}
```

使用下列命令行来进行示例程序的编译。

```
#gcc-g-02-o tunpong tunpong.c
```

对TUN设备进行操作需要有root权限。请首先成为root用户再尝试运行示例程序tunpong。

#./tunpong

在运行后打开另一个终端，使用ifconfig命令来确认。通过示例程序内部运行的ifconfig，可以得知IP地址192.168.1.1和点对点的192.168.1.2被分配到TUN设备（tun0）。

```
#ifconfg tun0
tun0 Link encap：UNSPEC HWaddr 00-00-00-00-00-00-00-00-00-00-00-00-00-00-
00-00
inet addr：192.168.1.1 P-t-P：192.168.1.2 Mask：255.255.255.255
UP POINTOPOINT RUNNING NOARP MULTICAST MTU：1500 Metric：1
RX packets：0 errors：0 dropped：0 overruns：0 frame：0
TX packets：0 errors：0 dropped：0 overruns：0 carrier：0
collisions：0 txqueuelen：500
RX bytes：0（0.0 b）TX bytes：0（0.0 b）
```

接下来，执行ping命令，尝试将ICMP ECHO REQUEST发送到192.168.1.2。可以确认，ping命令返回如下REPLY。

```
$ping 192.168.1.2
PING 192.168.1.2（192.168.1.2）56（84）bytes of data.
64 bytes from 192.168.1.2：icmp_req=1 ttl=64 time=0.100 ms
64 bytes from 192.168.1.2：icmp_req=2 ttl=64 time=0.248 ms
64 bytes from 192.168.1.2：icmp_req=3 ttl=64 time=0.207 ms
```

另外，还可以看到在tunpong的标准输出中输出了发送到192.168.1.2的数据包（ICMP ECHO REQUEST）的转储结果，程序tunpong通过TUN设备接收数据包。

```
#./tunpong
45 00 00 54 00 00 40 00 40 01 b7 55 c0 a8 01 01 c0 a8 01 02 08 00 e6 31 1a 48 00 01 82 8f 06 4e 00 00 00 00 a2 d4 0d 00 00 00 00 00 10 11 12 13 14 15 16 17 18 19 1a 1b 1c 1d 1e 1f 20 21 22 23 24 25 26 27 28 29 2a 2b 2c 2d 2e 2f 30 31 32 33 34 35 36 37
45 00 00 54 00 00 40 00 40 01 b7 55 c0 a8 01 01 c0 a8 01 02 08 00 9a 30 1a 48 00 02 83 8f 06 4e 00 00 00 00 ed d4 0d 00 00 00 00 00 10 11 12 13 14 15 16 17 18 19 1a 1b 1c 1d 1e 1f 20 21 22 23 24 25 26 27 28 29 2a 2b 2c 2d 2e 2f 30 31 32 33 34 35 36 37
45 00 00 54 00 00 40 00 40 01 b7 55 c0 a8 01 01 c0 a8 01 02 08 00 68 30 1a 48 00 03 84 8f 06 4e 00 00 00 00 1e d4 0d 00 00 00 00 00 10 11 12 13 14 15 16 17 18 19 1a 1b 1c 1d 1e 1f 20 21 22 23 24 25 26 27 28 29 2a 2b 2c 2d 2e 2f 30 31 32 33 34 35 36 37
```

最后使用ifconfig命令确认统计信息。RX和TX的packets和bytes同时增加，可以看出成功进行了发送和接收。

```
#ifconfg tun0
tun0 Link encap：UNSPEC HWaddr 00-00-00-00-00-00-00-00-00-00-00-00-00-00-00-00
inet addr：192.168.1.1 P-t-P：192.168.1.2 Mask：255.255.255.255
UP POINTOPOINT RUNNING NOARP MULTICAST MTU：1500 Metric：1 RX packets：3 errors：0 dropped：0 overruns：0 frame：0
TX packets：3 errors：0 dropped：0 overruns：0 carrier：0 collisions：0 txqueuelen：500
RX bytes：252（252.0 b）TX bytes：252（252.0 b）
```

小结

本节介绍了TUN/TAP设备。实现Linux网络隧道的TUN/TAP设备，除了用于需要VPN等网络隧道的应用程序以外，最近也多用于实现虚拟环境中的虚拟网络，是非常重要的设备。

——Hiroshi Shimamoto

HACK#24　网桥设备

介绍Linux内核中网桥设备的生成和网桥连接。

Linux内核中安装有网桥功能。使用网桥功能，就可以将多个网络接口连接到一个网段上。如图4-1所示将多个网络接口连接到Linux机器的网桥接口上，就可以将各网段整理为一个网段。例如，图4-1中是将4个网络接口连接到一个网桥上。这个Linux机器拥有4个网络接口（eth0～eth3），eth0连接到路由器，eth1～eth3分别连接到不同的客户端。

物理上分为4个网段，而通过使用Linux内核的网桥功能，就可以整合为一个网段。也就是说，启用了网桥功能的Linux机器等同于交换式集线器（switching hub）。

Linux内核将IP地址分配到网桥接口br0。不会向连接到网桥的网络接口（图4-1中的eth0～eth4）分配IP地址。

最近开始越来越多地将网桥功能运用在虚拟环境中。在虚拟环境中是将TAP设备和物理NIC进行网桥连接。

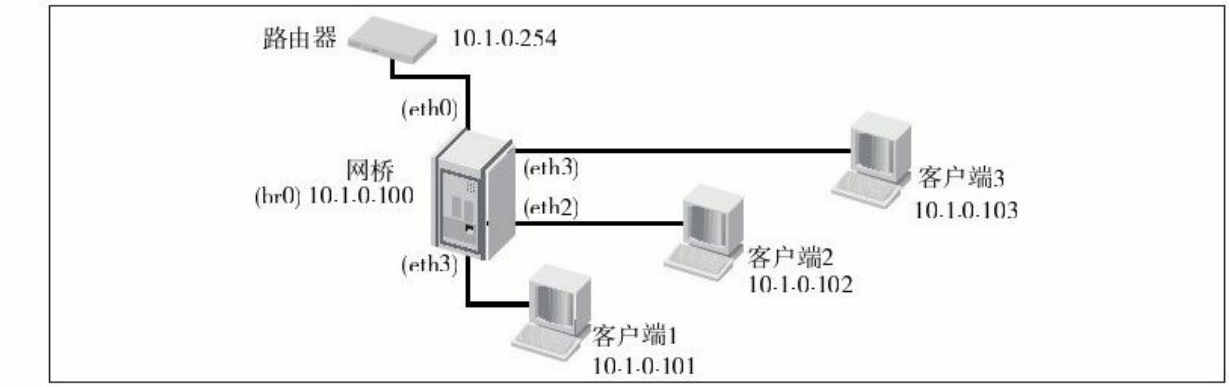

图　4-1　网桥连接

brctl命令

bridge-utils工具包中包含对网桥进行操作的命令brctl。可以按下列方式安装。RedHat系列

```
#yum install bridge-utils
```

Debian系列

```
#apt-get install bridge-utils
```

在已经安装虚拟功能的情况下，对网桥进行操作的命令也应该同时安装了。常用的命令如表4-1所示。

表 4-1　网桥中经常使用的命令

名　称	功　能
brctl show[网桥名]	显示网桥列表与状态
brctl addbr 网桥名	生成网桥

（续）

名　称	功　能
brctl addif 网桥名 接口名	将接口连接到网桥网络
brctl delif 网桥名 接口名	拆除连接到网桥的网络接口
brctl delbr 网桥名	删除网桥

使用网桥功能的示例

进行图4-1的网桥连接时的操作如下。如果在经由作为设置对象的网络接口之一连接（ssh等）的状态下实施这个作业，需要注意有时会由于网络接口IP地址更换的时机等而无法进行网络断开的操作。

1.生成网桥设备br0。

```
#brctl addbr br0
```

2.向网桥设备分配IP地址。

```
#ifconfg br0 10.1.0.100 netmask 255.255.255.0 broadcast 10.1.0.255 up
```

3.将eth0连接到网桥br0。

```
#brctl addif br0 eth0
```

4.将eth0激活。

```
#ifconfg eth0 up
```

5.同样对eth1～eth3进行操作3、4。

```
#brctl addif br0 eth1
#ifconfg eth1 up
#brctl addif br0 eth2
#ifconfg eth2 up
#brctl addif br0 eth3
#ifconfg eth3 up
```

通过以上操作，网络接口的网桥连接就完成了。brctl show显示的网桥状态如下所示。

#brctl show
bridge name bridge id STP enabled interfaces
br0 8000.545200006400 no eth0
eth1
eth2
eth3

网桥的设置

可以设置为操作系统启动时自动生成网桥。每个发布版中的设置方法都有所不同，这里将介绍Debian系列和RedHat系列。

Debian系列的情况在/etc/network/interfaces中描述。设置static address 0.0.0.0，使得不会对连接到网桥的接口本身设置IP地址。

例4-2/etc/network/interfaces

```
uto eth0
iface eth0 inet static
address 0.0.0.0
auto eth1
iface eth1 inet static
address 0.0.0.0
auto eth2
iface eth2 inet static
address 0.0.0.0
auto eth3
iface eth3 inet static
address 0.0.0.0
auto br0
iface br0 inet dhcp
bridge_ports eth0 eth1 eth2 eth3
bridge_stp off
```

RedHat系列的情况

在目录/etc/sysconfig/network-scripts下配置ifcfg-（网桥名）。

例4-3　ifcfg-br0

```
DEVICE=br0
TYPE=Bridge
BOOTPROTO=dhcp
ONBOOT=yes
STP=off
```

对与连接到网桥的网络接口相对应的ifcfg-（接口名）进行编辑，设置为使用网桥。另外设置为NM_CONTROLLED=no，就可以将其排除在NetworkManager的管理范围之外。

例4-4　ifcfg-eth0

```
DEVICE=eth0
HWADDR=**：**：**：**：**：**
NM_CONTROLLED=no
ONBOOT=yes
BRIDGE=br0
```

虚拟机的网桥连接

在启动qemu的情况下，使用-net选项指定tap启动，TAP设备生成和删除时就会执行脚本。执行的脚本默认为qemu-ifup.sh，但可以使用选项来修改。通过这个脚本来向TAP设备的网桥进行连接。具体来说，就是在生成TAP设备的同时，会以这个TAP设备名为变量调出脚本。

#qemu-ifup. sh tap设备名

qemu-ifup. sh的内容如下。

```
#！/bin/sh
TAP=$1
brctl addbr br0$TAP
ifconifg$TAP up
```

使用虚拟管理库的libvirt，就可以在虚拟机启动时自动进行网桥连接。

小结

Linux内核中安装有网桥功能，通过使用网桥功能，可以将多个网段整合为一个网段。Linux机器通过这个功能，就能够像交换式集线器一样运行。此外，网桥功能还可以在KVM等虚拟环境中，将虚拟机的网络连接到物理网络。

——Hiroshi Shimamoto

HACK#25　VLAN

本节介绍VLAN（Virtual LAN）的设置方法。

在Linux中安装了802.1Q标签VLAN功能。VLAN是虚拟分配以太网的功能。使用VLAN ID从物理上将一个以太网分割开。在VLAN环境下，具有相同VLAN ID就可以相互通信，但是即使将LAN线连接到相同集线器或交换机上，VLAN ID不同也不能相互通信。

本节将介绍VLAN的设置方法，包括准备配置文件的方法和使用命令行设置的方法。

使用命令进行设置

使用vconfig命令和ip命令可以进行VLAN环境的设置。

使用vconfig命令生成VLAN接口时的操作如下。把VLAN ID设置为100。

```
#vconfg add eth0 100
Added VLAN with VID==100 to IF-：eth0：-
```

使用ip命令也可以进行同样的设置。

```
#ip link add link eht0 name eth0.100 type vlan id 100
```

NIC eth0中将生成VLAN ID100的VLAN接口。与一般的网络接口同样可以设置IP地址等。

```
#ifconfg eth0.100 192.168.1.100
#ifconfg eth0.100
eth0.100 Link encap：Ethernet HWaddr 00：1B：21：0F：91：8F
inet addr：192.168.1.100 Bcast：192.168.1.255 Mask：255.255.255.0
UP BROADCAST RUNNING SLAVE MULTICAST MTU：1500 Metric：1
……
```

生成的VLAN接口的状态可以使用/proc/net/vlan来确认。

```
#ls/proc/net/vlan/
config eth0.100
#head/proc/net/vlan/*
==>/proc/net/vlan/config<==
VLAN Dev name|VLAN ID
Name-Type：VLAN_NAME_TYPE_RAW_PLUS_VID_NO_PAD
eth0.100|100|eth0
==>/proc/net/vlan/eth0.100<==
eth0.100 VID：100 REORDER_HDR：1 dev->priv_flags：1
total frames received 0
total bytes received 0
Broadcast/Multicast Rcvd 0
total frames transmitted 0
total bytes transmitted 0
total headroom inc 0
total encap on xmit 0
Device：eth0
```

要删除VLAN接口时，可以执行下列命令。

```
#vconfg rem eth0.100
```

或者

```
#ip link delete eth0.100
```

在这个示例中，生成的VLAN接口的名称是物理网络接口+点+VLAN ID（即eth0.<VLAN ID>），但VLAN的接口名有4种，如表4-2所示。

表 4-2　VLAN 接口名的种类

种　类	VLAN 接口名的示例	每个种类的命名规则
VLAN_PLUS_VID	vlan0005	字符串 vlan+0 padding（多个 0 叠加）+VLAN ID
VLAN_PLUS_VID_NO_PAD	vlan5	字符串 vlan+VLAN ID
DEV_PLUS_VID	eth0.0005	物理网络接口名 + 点 +0 padding+VLAN ID
DEV_PLUS_VID_NO_PAD	eth0.5	物理网络接口名 + 点 +VLAN ID

使用vconfig add增加VLAN接口时，需要事先使用vconfig set_name_type＜种类＞来设置种类。设置了种类后，内核就会按照种类从VLAN接口名来识别ID。

但是在已有配置文件中使用ifup命令的情况，是通过ifup脚本来识别VLAN ID的，因

此无须在意VLAN设备名的种类。

使用设置文件进行设置

在etc/sysconfig/network-scripts/下准备好eth0.100用的配置文件，系统启动时就可以自动生成VLAN接口。请设置DEVICE=VLAN接口名，并设置为VLAN=yes。

```
#cat ifcfg-eth0.100
DEVICE=eth0.100
TYPE=Ethernet
BOOTPROTO=static
IPADDR=192.168.1.100
ONBOOT=yes
VLAN=yes
```

VLAN_PLUS_VID、VLAN_PLUS_VID_NO_PAD的VLAN接口需要设置为VLAN=yes，并在PHYSDEV=后面写入物理网络接口名。

```
#cat ifcfg-vlan002
DEVICE=vlan002
TYPE=Ethernet
BOOTPROTO=static
IPADDR=192.168.1.102
ONBOOT=yes
VLAN=yes
PHYSDEV=eth0
```

准备eth0.001用和vlan3用的配置文件，然后执行ifup命令，内核中就能够正常识别这些VLAN接口。

```
#cat ifcfg-eth0.001
DEVICE=eth0.001
……
VLAN=yes
#cat ifcfg-vlan3
DEVICE=vlan3
……
VLAN=yes
PHYSDEV=eth0
#ifup eth0.001
#ifup vlan002
#ifup vlan3
#cat/proc/net/vlan/confg
VLAN Dev name|VLAN ID
Name-Type：VLAN_NAME_TYPE_RAW_PLUS_VID_NO_PAD
```

eth0.001|1|eth0
vlan002|2|eth0
vlan3|3|eth0
#ifconfg
eth0 Link encap：Ethernet HWaddr 00：1B：21：0F：91：8F
inet addr：192.168.3.100 Bcast：192.168.3.255 Mask：255.255.255.0 UP BROADCAST RUNNING SLAVE MULTICAST MTU：1500 Metric：1
……
eth0.001 Link encap：Ethernet HWaddr 00：1B：21：0F：91：8F
inet addr：192.168.1.101 Bcast：192.168.1.255 Mask：255.255.255.0 UP BROADCAST RUNNING SLAVE MULTICAST MTU：1500 Metric：1
……
vlan002 Link encap：Ethernet HWaddr 00：1B：21：0F：91：8F
inet addr：192.168.1.102 Bcast：192.168.1.255 Mask：255.255.255.0 UP BROADCAST RUNNING SLAVE MULTICAST MTU：1500 Metric：1
……
vlan3 Link encap：Ethernet HWaddr 00：1B：21：0F：91：8F
inet addr：192.168.1.103 Bcast：192.168.1.255 Mask：255.255.255.0 UP BROADCAST RUNNING SLAVE MULTICAST MTU：1500 Metric：1
……

MAC-VLAN

从2.6.23版本开始就具有了MAC-VLAN。在2.6.38版本中还是试验性（EXPERIMENTAL）的驱动程序。使用时需要启用内核config文件CONFIG_MACVLAN。在RHEL6中默认是编译为模块的。要生成MAC-VLAN接口，可以使用下列ip命令（对每个MAC地址指定分配的VLAN接口）。MAC-VLAN驱动程序macvlan自动安装到内核中，因此可以省略modprobe命令。

#modprobe macvlan
#lsmod|grep macvlan
macvlan 9727 0
#ip link add link eth0 name eth0.100 address 00：aa：bb：cc：dd：ee type macvlan
#ifconfg eth0.100
eth0.100 Link encap：Ethernet HWaddr 00：AA：BB：CC：DD：EE
BROADCAST MULTICAST MTU：1500 Metric：1
……

参考文献

·initscripts数据包文档

/usr/share/doc/initscripts-*/sysconfig. txt

·802. 1Q VLAN implementation for Linux

http://www. candelatech.com/-greear/vlan.html

——Naohiro Ooiwa

HACK#26　bonding驱动程序

本节介绍使用bonding驱动程序将多个物理网络设备绑定方法。

bonding是将多个物理网络设备绑定的驱动程序。绑定bonding说法来自于黏合剂bond。绑定的运行根据模式不同而有所差异。Linux的bonding有7种模式，本节将介绍的是普遍较常使用的激活备份模式。

本节中所举的示例是将物理网络设备eth0和eth1绑定，构成bonding设备bond0的环境（见图4-2）。

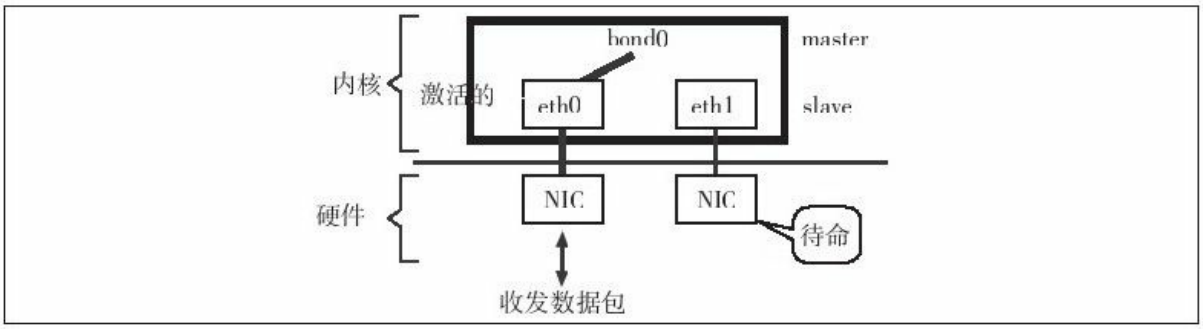

图　4-2　本节的bonding构成（激活备份模式）

构成bond0的eth0/eth1称为从设备（slave）。bond0称为主设备（master）。激活备份模式时，激活的slave eth0进行通信。eth1为备份，处于待命状态。

使用方法

Linux的bonding有7种模式。下面先简单地介绍各种模式。模式的名称就是直接指定到模块参数的字符串。也可以使用（）中的数字来指定模式。

balance-rr（0）

通过轮询（round robin）来分散负载。发送数据时，第一个数据从eth0发送，第二个数据从eth1发送。依次由eth0/eth1发送。

active-backup（1）

多个从设备中的一个运行。这个从设备称为激活的从设备。如果激活从设备出现故障，断开链接（link down）时，则切换为其他从设备。这个模式称为激活备份模式。

balance-xor（2）

通过MAC地址的异或结果（XOR）来决定从设备。从设备由散列队列（hashlist）进行管理，根据使用某计算公式求得的散列值来决定从设备。计算出散列值的方法称为散列策略（hash policy）。balance-xor模式的计算公式为（（发送方MAC地址xor接收方MAC地址）/从设备数）。将得到的余数作为散列值。由于使用Ether头的MAC地址，因此将这个策略称为layer2。可以在xmit_hash_policy模块选项中更改散列策略。除layer2以外，还有layer2+3和layer3+4。layer2+3是通过MAC地址和IP地址的组合来计算出散列值。layer3+4是通过MAC地址、IP地址和TCP、UDP的端口号的组合来算出散列值。在这个模式下，只要上述条件不改变，就会使用相同从设备。

broadcast（4）

已连接的所有从设备发送相同数据。即使某个从设备发送失败也不会中断，而是从其他从设备发送数据。

此外还有802.3ad（4）、balance-tlb（5）、balance-alb（6）。详细情况请看参考文献。默认为轮询。使用激活备份模式时需要按下列方法将模块安装到内核中。

```
#modprobe bonding mode=active-backup
```

或者执行下列命令。

```
#modprobe bonding mode=1
```

一般在准备其他模块参数时同时准备接口的配置文件。这样在启动时bonding接口就会启用。RHEL6中不是在modprobe.conf中而是在/etc/modprobe.d/*.conf中设置bonding模块的别名（alias）。这里的文件名设置为bond.conf。

```
#cat/etc/modprobe.d/bond.conf
alias bond0 bonding
alias bond1 bonding
```

接口的配置文件如下。

```
#cat/etc/sysconfg/network-scripts/ifcfg-eth0
DEVICE="eth0"
NM_CONTROLLED="no"
ONBOOT=no
HWADDR=AA：AA：AA：AA：AA：AA
TYPE=Ethernet
BOOTPROTO=none
MASTER=bond0
SLAVE=yes
#cat/etc/sysconfg/network-scripts/ifcfg-eth1
DEVICE="eth1"
NM_CONTROLLED="no"
ONBOOT=no
HWADDR=BB：BB：BB：BB：BB：BB
TYPE=Ethernet
BOOTPROTO=none
MASTER=bond0
SLAVE=yes
#cat/etc/sysconfg/network-scripts/ifcfg-bond0
DEVICE=bond0
ONBOOT=yes
BOOTPROTO=static
IPADDR=192.168.0.10
NETMASK=255.255.255.0
NETWORK=192.168.0.0
BROADCAST=192.168.0.255
BONDING_OPTS="mode=1 miimon=100 primary=eth0"
```

上例是在ifcfg-bond0中记载的BONDING_OPT。这是用来设置模块选项的。通过写入ifcfg-bond0文件，对每个bonding接口设置选项。因此在RHEL6并不推荐在/etc/modprobe.d/bond.conf下使用option来记载bonding模块的选项。在配置文件里记载后，就可以使用ifup bond0来启动bonding设备。成为从设备的接口可以使用ifconfig命令确

认。

```
#ifconfg eth0
eth0 Link encap：Ethernet HWaddr 00：1B：21：0F：91：8F
UP BROADCAST SLAVE MULTICAST MTU：1500 Metric：1有SLAVE
RX packets：0 errors：0 dropped：0 overruns：0 frame：0
TX packets：0 errors：0 dropped：0 overruns：0 carrier：0
collisions：0 txqueuelen：1000
RX bytes：0（0.0 b）TX bytes：0（0.0 b）
Interrupt：16 Memory：efbc0000-efbe0000
```

bonding接口的设置内容可以在下列proc文件系统中确认。

```
#cat/proc/net/bonding/bond0
Ethernet Channel Bonding Driver：v3.7.0（June 2，2010）
Bonding Mode：fault-tolerance（active-backup）
Primary Slave：eth2（primary_reselect always）
Currently Active Slave：eth0激活slave
MII Status：down
MII Polling Interval（ms）：100
Up Delay（ms）：0
Down Delay（ms）：0
Slave Interface：eth0
MII Status：down
Speed：100 Mbps
Duplex：full
Link Failure Count：0
Permanent HW addr：aa：aa：aa：aa：aa：aa原始的MAC地址
Slave queue ID：0
Slave Interface：eth1
MII Status：down
Speed：100 Mbps
Duplex：full
Link Failure Count：0
Permanent HW addr：bb：bb：bb：bb：bb：bb
Slave queue ID：0
```

关于激活备份模式

激活备份模式在激活从设备发生连接障碍时，就会切换到其他从设备。切换到的从设备就会作为激活从设备运行。障碍是指线缆或NIC发生问题，连接中断。

拔掉激活从设备的LAN线缆，或执行ifdown命令，就可以确认切换的运行。

当前激活的从设备可以在/proc/net/bonding/bond0中确认。eth0第一次成为激活从设备时，bond0的MAC地址设置为eth0的MAC地址。即使切换为eth1，bond0的MAC地址也不会变化。由于这样的构造，使得从外部看起来bond0是一个端口。

小贴士：从Linux2.6.24开始安装了fail_over_mac选项，可以更改决定bonding接口的MAC地址的策略。

使用ifconfig命令可以确认当前的bonding接口和从设备的MAC地址。接口的原始MAC地址可以在/proc/net/bonding/bond0中确认。

下面将介绍在激活备份模式下使用的主要模块选项。

miimon

激活备份模式的连接障碍可以通过定期监控检查出来。miimon设置的是通过MII（Media Independent Interface）监控时的周期。单位为毫秒，初始设置值为100毫秒。使用MII监视时NIC必须和MII相对应。

NIC是否对应可以使用mii-tool命令来确认。如果与MII相对应，则会输出如下结果。

#mii-tool

---

eth0：negotiated 100baseTx-FD flow-control, link ok
eth1：negotiated 100baseTx-FD flow-control, link ok

在不与MII对应的NIC下使用bonding的激活备份模式时，使用ARP监控。在模块选项中设置arp_interval、arp_ip_target等。这种情况下必须设置使用arp_ip_target监控的IP地址，监控过程中一直传输的是ARP数据包。

updelay

updelay选项在检测出从设备的连接后，不会立刻连接，而是会等待updelay所指定的时间。这个选项以毫秒为单位来设置。

这个选项在MII连接监控中有效。推荐设置为miimon数值的倍数。

updelay=100（单位为毫秒）

从Linux 2.6.31开始，即使指定updelay，最先输入的从设备也无视updelay。

操作系统启动后，bond0被ifup，并按照eth0、eth1的顺序注册为slave。eth0是最先注册的从设备，因此无视updelay，立刻被ifup。由于slave（eth0）已经注册，接下来的eth1就需要等待updelay的时间后再ifup。

primary

这个选项用来设置要作为激活从设备的接口。如果设primary=eth0，eth0就设置为激活从设备。例如，假设为了产生连接问题而执行ifdown eth0。连接会断开，因此激活从设备会切换到eth1。接下来执行ifup eth0命令，使eth0恢复。未设置primary模块选项时，激活从设备仍然是eth1。设置primary=eth0时，在ifup的时候激活slave切换为eth0。

参考文献

·Linux Ethernet Bonding Driver HOWTO

Documentation/networking/bonding. txt

——Naohiro Ooiwa

HACK#27　Network Drop Monitor

本节介绍dropwatch的使用方法，并以UDP为例介绍网络的调整方法。

从Linux 2.6.30开始具有Network Drop Monitor（dropwatch）功能。

dropwatch是监控内核的网络栈丢弃的数据包。

接收数据包后，数据从网络驱动程序传输到内核的网络层。在这里进行校验和或IP地址的确认等数据包验证处理。在这个过程中，如果是非法数据包，则依据RFC丢弃，即使是合法的数据包，在超过接收缓冲区大小等情况也会有意识地丢弃。

由于上述这些理由，接收数据包在内核内丢弃。这些不会在日志等中输出，因此一般难以发现。

如果是非法数据包，那么丢弃也没问题，但如果内存有空闲却因接收缓冲区较小而在网络负载较高时丢弃大量数据包，就需要通过调整来进行改善。

本节以UDP的网络负载为例，使用dropwatch来确认丢弃数据包的情况。使用proc文件系统调整接收缓冲区的大小，并使用dropwatch来确认调整结果。使用的操作系统为RHEL6。

dropwatch的使用方法

使用上游内核时，需要启用Network packet drop alerting service（NET_DROP_MONITOR=y）并编译内核。

dropwatch是使用Kernel Tracepoint API安装的。具体来说，就是各协议释放socket缓冲区时（kfree_skb函数）收集信息。可以应对IP、ARP、ICMP、IGMP、UDP协议的数据包等。

因此，即使不使用proc文件系统或工具针对各个协议收集信息，也可以通过dropwatch将数据集中到一起进行确认。

dropwatch是作为内核功能使用，因此不需要为了调查潜在的网络性能而改变已有的应用程序。便于使用也是其优点之一。

下面开始实际使用dropwatch。无须进行特别的设置。执行dropwatch命令，显示出dropwatch和提示符后，输入start。

```
#dropwatch
Initalizing null lookup method
dropwatch＞start＜---输入start
Enabling monitoring……
Kernel monitoring activated.
Issue Ctrl-C to stop monitoring
1 drops at location 0xffffffff81433719
16 drops at location 0xffffffff81440849
4 drops at location 0xffffffff81440849
4 drops at location 0xffffffff81440849
4 drops at location 0xffffffff81440849
1 drops at location 0xffffffff8149a8ed
1 drops at location 0xffffffff8149a8ed
……
```

使用Ctrl+C返回提示符。输入stop或exit就可以结束。最左边的数值就是废弃的数据包数。location后面的数值是内核内的地址。在-l选项中使用/proc/kallsyms，将地址转换成函数名输出。按照下列方法执行-l命令。kas为kernel all symbols的缩写。

```
#dropwatch-l kas
Initalizing kallsyms db
dropwatch＞start
Enabling monitoring……
Kernel monitoring activated.
Issue Ctrl-C to stop monitoring
12 drops at ip_rcv_finish+199---①
2 drops at ip_forward+288
1 drops at ip_forward+288
5 drops at netlink_broadcast+180
4 drops at ip_rcv_finish+199
1 drops at igmp_rcv+cb
8 drops at ip_rcv_finish+199
1 drops at__brk_limit+1e8a3284
……
```

①表示在ip_rcvz-finish函数的偏移量0×199中检测出废弃了12个数据包。这个信息为每隔1秒输出一次，或者在废弃的数据包数达到64时输出。在当前已安装的版本中，这些最小值是不能改变的。

ip_rcv_finish函数的偏移量0×194是下列代码中的①，实际检测出的内容为上一行的ip_rcv_finishi+0×194＜kfree_skb＞。

例4-5＜内核2.6.32-71.el6.×86_64＞

```
0xffffffff8144082d＜ip_rcv_finish+0x17d＞：mov 0xe0（%rax），%rax；
0xffffffff8144083４＜ip_rcv_finish+0x184＞：add
-0x7e767c40（，%rdx，8），%rax
0xffffffff8144083c＜ip_rcv_finish+0x18c＞：addq$0x1，0x40（%rax）
0xffffffff81440841＜ip_rcv_finish+0x191＞：mov%rbx，%rdi
0xffffffff81440844＜ip_rcv_finish+0x194＞：callq 0xffffffff81405560
＜kfree_skb＞
0xffffffff81440849＜ip_rcv_finish+0x199＞：mov$0x1，%eax---①
0xffffffff8144084e＜ip_rcv_finish+0x19e＞：jmp 0xffffffff814407dd＜ip_
rcv_finish+0x12d＞
0xffffffff81440850＜ip_rcv_finish+0x1a0＞：mov 0xcc（%rbx），%ecx
```

具体调整的例

在大量发送UDP数据包的测试程序udp-stress.c中进行具体的验证。

例4-6＜udp-stress.c＞

```
#include＜stdio.h＞
#include＜string.h＞
#include＜arpa/inet.h＞
#include＜unistd.h＞
#define DADDR"192.168.0.112"
#define PORT 5000
int
main（int argc, char**argv）
{
int sock=0；
struct sockaddr_in dest；
char tmpbuf[]={"stress"}；
sock=socket（PF_INET, SOCK_DGRAM，0）；
if（！sock）{
perror（"socket"）；
return 1；
}
```

```
dest.sin_family=AF_INET;
dest.sin_port=htons（PORT）;
dest.sin_addr.s_addr=inet_addr（DADDR）;
if（connect（sock，（struct sockaddr*）&dest, sizeof（dest））==-1）{
perror（"connect"）;
return 1;
}
while（1）
sendto（sock, tmpbuf, strlen（tmpbuf）+1，0，
（struct sockaddr*）&dest, sizeof（dest））;
close（sock）;
return 0;
}
```

编译udp-stress.c。

```
#gcc-Wall udp-stress.c-o udp-stress
```

在接收UDP数据包的机器（RHEL6）上执行nc命令。nc命令只是接收UDP的数据包并显示数据的程序。

```
#nc-u-l 192.168.0.112 5000
```

对执行nc命令的服务器机器执行udp-stress，并发送UDP数据包。在服务器机器上执行dropwatch，在笔者的环境下首先会输出如下内容，并未能进行UDP通信。

```
64 drops at nf_hook_slow+e0
14 drops at ip_rcv_finish+176
64 drops at nf_hook_slow+e0
2 drops at ip_rcv_finish+176
64 drops at nf_hook_slow+e0
64 drops at nf_hook_slow+e0
8 drops at ip_rcv_finish+176
64 drops at nf_hook_slow+e0
64 drops at nf_hook_slow+e0
1 drops at unix_stream_recvmsg+2f3
6 drops at ip_rcv_finish+176
64 drops at nf_hook_slow+e0
```

nf_hook_slow是netfilter的函数。这表示根据DROP的规则已废弃。

下面暂时删除所有iptables的规则。

```
#iptables-F
```

这样就不会输出nf_hook_slow+e0。也就是说，由于删除了netfilter的规则，因此nf_hook_slow+e0不存在数据包丢失。

这样就可以进行UDP通信，因此再次执行dropwatch。

```
2 drops at ip_forward+288
6 drops at ip_rcv_finish+199
2 drops at ip_rcv_finish+199
1 drops at ip_forward+288
1 drops at unix_stream_recvmsg+30d
1 drops at unix_stream_recvmsg+30d
4 drops at ip_rcv_finish+199
6 drops at ip_rcv_finish+199
2 drops at unix_stream_recvmsg+30d
14 drops at ip_rcv_finish+199
64 drops at__udp_queue_rcv_skb+79＜---执行udp-stress的时刻
1 drops at unix_stream_recvmsg+30d
64 drops at__udp_queue_rcv_skb+79
4 drops at ip_rcv_finish+199
64 drops at__udp_queue_rcv_skb+79
64 drops at__udp_queue_rcv_skb+79
64 drops at__udp_queue_rcv_skb+79
64 drops at__udp_queue_rcv_skb+79
64 drops at__udp_queue_rcv_skb+79
64 drops at__udp_queue_rcv_skb+79
64 drops at__udp_queue_rcv_skb+79
1 drops at igmp_rcv+cb
64 drops at__udp_queue_rcv_skb+79
```

从执行udp-stressd的时刻开始，输出变成64 drops at__udp_queue_rcv_skb+79。这就是下列代码中的**。

```
0xffffffff81467691＜__udp_queue_rcv_skb+0x61＞：movslq%edx，%rdx
0xffffffff81467694＜__udp_queue_rcv_skb+0x64＞：mov%r12，%rdi
0xffffffff81467697＜__udp_queue_rcv_skb+0x67＞：add-0x7e767c40（，%rdx，8），%rax
0xffffffff8146769f＜__udp_queue_rcv_skb+0x6f＞：addq$0x1，0x18（%rax）
0xffffffff814676a4＜__udp_queue_rcv_skb+0x74＞：callq 0xffffffff81405560＜kfree_skb＞
0xffffffff814676a9＜__udp_queue_rcv_skb+0x79＞：mov$0xffffffff，%eax---**
0xffffffff814676ae＜__udp_queue_rcv_skb+0x7e＞：jmp 0xffffffff81467662＜__udp_queue_rcv_skb+0x32＞
```

通过__udp_queue_rcv_skb（）调出kfree_skb（）的只有一处（②）。要让②通过编译，③处的sock_queue_rcv_skb（）必须是个错误。

例4-7＜net/ipv4/udp.c＞

```
static int__udp_queue_rcv_skb（struct sock*sk, struct sk_buff*skb）
{
int is_udplite=IS_UDPLITE（sk）；
int rc；
if（（rc=sock_queue_rcv_skb（sk, skb））＜0）{---③
/*Note that an ENOMEM error is charged twice*/
if（rc==-ENOMEM）{
UDP_INC_STATS_BH（sock_net（sk），UDP_MIB_RCVBUFERRORS，
```

is_udplite）；

```
atomic_inc（＆sk-＞sk_drops）；
}
goto drop；
}
return 0；
drop：
UDP_INC_STATS_BH（sock_net（sk），UDP_MIB_INERRORS, is_udplite）；
kfree_skb（skb）；---②
return-1；
}
```

使用SystemTap确认sock_queue_rcv_skb（）返回的地方，结果为③。＜net/core/sock.c＞

```
281 int sock_queue_rcv_skb（struct sock*sk, struct sk_buff*skb）
282{
283 int err=0；
284 int skb_len；
285 unsigned long flags；
```

```
286         struct sk_buff_head *list = &sk->sk_receive_queue;
287
288         /* Cast sk->rcvbuf to unsigned... It's pointless, but reduces
289            number of warnings when compiling with -W --ANK
290          */
291         if (atomic_read(&sk->sk_rmem_alloc) + skb->truesize >=
292             (unsigned)sk->sk_rcvbuf) {
293                 err = -ENOMEM;
294                 goto out;           ---❸
295         }
......
```

sk_rcvbuf就是/proc/sys/net/core/rmem_default，在这里不作详细说明。初始值为124

928。

```
#cat/proc/sys/net/core/rmem_default
124928
```

如果增大这个值，废弃的数据包就会减少，因此可以尝试进行下列设置。

```
#echo 4194304＞/proc/sys/net/core/rmem_default
```

这时如果执行udp-stress，就不会输出__udp_queue_rcv_skb+79。

小结

本节介绍了dropwatch。可以确认系统中是否产生了过多的数据包废弃，以及在哪里发生废弃。在这个过程中可能找出需要进行调整的地方。

参考文献

·Welcome to dropwatch

https：//fedorahosted. org/dropwatch/

·Kernel Tracepoint API.

Documentation/trace/tracepoints. txt

——Naohiro Ooiwa

第5章　虚拟化

本章将介绍使用KVM或Xen的虚拟化技术。在计算机的历史上，对各种设备进行虚拟化。使用调度程序的CPU资源虚拟化、使用内存管理的虚拟内存等都属于虚拟化。这里介绍的虚拟机技术是将包括CPU、内存、I/O设备在内的整个系统虚拟化的技术。除了以省电等为目的整合系统资源以外，还可以用来使用遗留（legacy）操作系统和生成动态资源。这里介绍的就是最大限度使用虚拟机的技术。

HACK#28　如何使用Xen

本节介绍管理程序（hypervisor）Xen的使用方法。

Xen是众多Linux发布版中所采用的管理程序。管理程序（又称虚拟机监视器）是为虚拟机提供运行环境的基础软件。Xen是在CPU中还没有称为Intel TV或AMD-V的虚拟化支持功能的时代开发出的管理程序，可以通过半虚拟化（paravirtualization）方式运行虚拟机。在Intel VT或AMD-V出现后，也可以支持使用这些功能的全虚拟化（full virtualization）方式。半虚拟化方式与全虚拟化方式的框架如图5-1所示。

半虚拟化方式

客户端操作系统在已虚拟化的情况下，修改内核或设备驱动程序的方法。半虚拟化方式的客户端操作系统称为半虚拟化客户端（PV客户端）。半虚拟化方式的驱动程序称为半虚拟化驱动程序（PV驱动程序）。

全虚拟化方式

使用支持虚拟化功能的Intel VT或AMD-V等CPU的方法。将PC硬件上运行的操作系统直接在虚拟机环境上运行的方法。全虚拟化方式的客户端操作系统称为全虚拟化客户端（HVM客户端）。

在RHEL5等使用Xen时，一般是使用virt-manager等来安装客户端操作系统。如果使用virt-manager，就算没有虚拟化知识也可以很简单地生成客户端操作系统。Xen作为Linux的虚拟机功能已经为大家所熟悉，因此这里仅介绍Xen的概要和不使用virt-manager时Xen的使用方法。

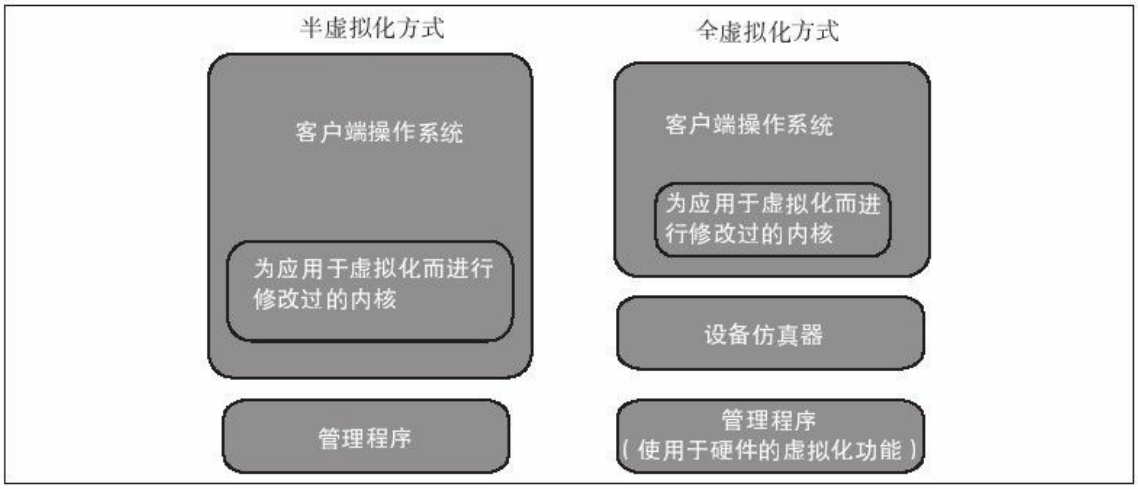

图　5-1　半虚拟化与全虚拟化

Xen的概要

构成Xen的主要要素有管理程序、主机操作系统（Dom0）、客户端操作系统（DomU），如图5-2所示。

管理程序用来生成、删除、管理虚拟机的CPU或内存等。例如，进行虚拟CPU的调度或者向虚拟机分配内存等。从管理程序来看，主机操作系统看起来与客户端操作系统是一样的。主机操作系统与一般的客户端操作系统不同，具有向管理程序请求虚拟机环境控制处理的权限。主机操作系统中存在叫做xend的守护进程或者设备仿真器qemu-dm进程。xend是接受生成客户端操作系统请求的守护进程，从xm命令接受处理要求，经由主机操作系统向管理程序请求生成虚拟机等。qemu-dm虽然也称为设备模型，实际上是仿真虚拟机设备的进程，用来仿真VGA或IDE等设备。

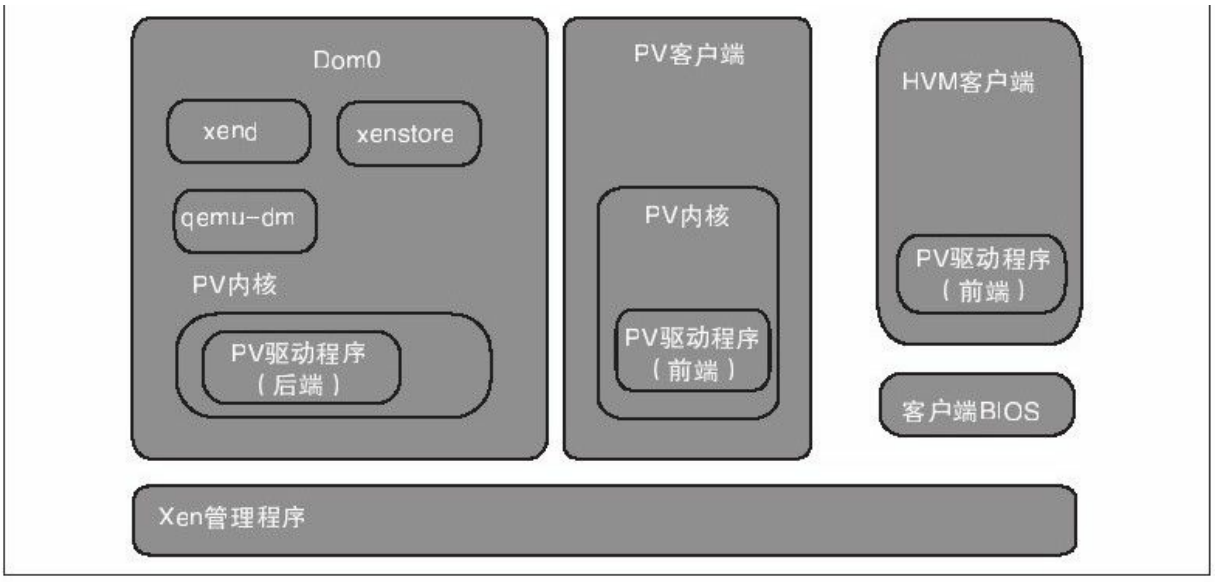
Dom0
xend
xenstore
qemu-dm
PV内核
PV驱动程序
（后端）
PV客户端
PV内核
PV驱动程序
（前端）
HVM客户端
PV驱动程序
（前端）
客户端BIOS
Xen管理程序

图　5-2　Xen的概要

Xen的半虚拟化客户端的使用方法

为了能够看到生成的Xen，这里不使用virt-manager生成半虚拟化客户端操作系统。下面以安装了RHEL5-Xen等Xen环境为前提。

1.生成客户端操作系统的磁盘映像。

```
#dd if=/dev/zero of=/root/rhel5.img bs=1M seek=4096 count=0
#mke2fs-F-j/root/rhel5.img
```

2.将当前运行中的Linux文件系统上的文件复制到步骤1中准备的磁盘映像中。

```
#mount-o loop/root/rhel5.img/mnt/
#cp-ax/{dev, etc, usr, bin, sbin, lib, lib64，var}/mnt/
#mkdir-p/mnt/{root, proc, sys, home, tmp}
```

3.将磁盘映像上的fstab重新设置为用于客户端操作系统。

将/dev/xvda1设置为块设备。/dev/xvda1是为客户端操作系统而准备的块设备名称。设置方法将在后面介绍。

```
# vim /mnt/etc/fstab
  /dev/xvda1              /               ext3       defaults             1 1
  tmpfs                   /dev/shm        tmpfs      defaults             0 0
  devpts                  /dev/pts        devpts     gid=5,mode=620       0 0
  sysfs                   /sys            sysfs      defaults             0 0
  proc                    /proc           proc       defaults             0 0
```

4.在磁盘映像的modprobe.conf中指定PV驱动程序模块。

在这里指定的是PV驱动程序的前端驱动程序—xennet、xenblk。

```
#vim/mnt/etc/modprobe.conf
alias eth0 xennet
alias scsi_hostadapter xenblk
```

5.将runlevel设置为3。

将/mnt/etc/inittab的initdefault行进行如下更改。

```
/mnt/etc/inittab initdefault
id：3：initdefault：
```

6.向securetty添加tty0。

为了可以从控制台登录，需要向securetty添加tty0。

```
#echo tty0＞＞/etc/securetty
```

7.生成initrd（在Dom0上的/boot下生成）。

指定客户端操作系统的fstab，生成initrd。指定时要使PV驱动程序模块xennet、xenblk也加入initrd中。

```
#mkinitrd-f/boot/initrd-2.6.18-164.el5xenU.img 2.6.18-164.el5xen--fstab/mnt/etc/fstab--with xennet--with xenblk
```

#umount/mnt/

8.启动客户端操作系统的启动配置文件。

客户端内核和initrd放在Dom0上。

```
#vim/etc/xen/rhel5
kernel="/boot/vmlinuz-2.6.18-164.el5xen"
ramdisk="/boot/initrd-2.6.18-164.el5xenU.img"
memory=1024
name="rhel5"
disk=['file：/root/rhel5.img, xvda1，w']
root="/dev/xvda1 ro"
extra="3"
```

9.启动客户端操作系统。

使用xm create命令启动客户端操作系统。通过-c选项来连接到启动的客户端操作系统的控制台。

```
#xm create-c rhel5
```

Xen的全虚拟化客户端的使用方法

1.生成客户端操作系统的磁盘映像。

```
#dd if=/dev/zero of=/root/rhel5hvm.img bs=1M seek=4096 count=0
```

2.生成客户端操作系统的配置文件。

指定步骤1中生成的磁盘映像和安装媒体的ISO。启动顺序依次为CD-ROM驱动器（d）和HDD（c）。

```
#vim/etc/xen/rhel5hvm
memory=1024
builder="hvm"
kernel="/usr/lib/xen/boot/hvmloader"
pae=1
acpi=1
apic=1
device_model='/usr/lib64/xen/bin/qemu-dm'[1]
sdl=0
vnc=1
vncdisplay=7
vncpasswd=''
vnclisten="0.0.0.0"
keymap="ja"
boot="dc"
disk=["file：/root/rhel5hvm.img, hda, w"，"file：/root/rhel-server-5.6-x86_64-dvd.iso, hdc：cdrom, r"]
vif=['']
serial="pty"
on_poweroff="destroy"
on_reboot="restart"
on_crash="restart"
```

3.使用xm create启动客户端操作系统，安装操作系统。

```
#xm create rhel5hvm
```

为了获取客户端操作系统的VGA控制台，在主机操作系统上按照下列方式启动vcnviewer。

```
#vncviewer 127.0.0.1：7
```

安装完成后，如果重新启动客户端操作系统，安装程序就会再次启动，因此安装完成后应使用xm destroy停止客户端操作系统。

```
#xm destroy rhel5hvm
```

4.编辑客户端操作系统的设置文件，卸载安装媒体的ISO。

```
#vim/etc/xen/rhel5hvm
name="rhel5hvm"
memory=1024
builder="hvm"
kernel="/usr/lib/xen/boot/hvmloader"
pae=1
acpi=1
apic=1
device_model='/usr/lib64/xen/bin/qemu-dm'[2]
sdl=0
vnc=1
vncdisplay=7
vncpasswd=''
vnclisten="0.0.0.0"
keymap="ja"
boot="dc"
disk=["file：/root/rhel5hvm.img, hda, w"，"，hdc：cdrom, r"]
vif=["]
serial="pty"
on_poweroff="destroy"
on_reboot="restart"
on_crash="restart"
```

5.启动客户端操作系统。

```
#xm create rhel5hvm
```

[1]主机操作系统为x86_64的情况。在x86_32的情况下指定device='/usr/lib/sen/bin/qemu-dm'。

[2]主机操作系统为x86_64的情况。在x86_32的情况下指定device_model='/usr/lib/xen/bin/qemu-dm'。

小结

这里介绍了使用低层次API的客户端操作系统生成方法。virt-manager在内部的功能也应该有所了解了。Xen的客户端操作系统中还有其他一些可以设置的项目（见表5-1），大家可以尝试一下。

表 5-1　客户端操作系统的设置

项　目	说　明
kernel	主要指定半虚拟化客户端时启动的 kernel
ramdisk	主要指定半虚拟化客户端时启动的 initrd
builder	指定全虚拟化客户端（hvm）、半虚拟化客户端（linux）
memory	指定内存大小。单位为 MB
uuid	用于客户端操作系统识别的 UUID。也指定到 SMBI 操作系统 type1 System information
name	客户端操作系统名称
cpus	指定客户端操作系统可以使用的物理 CPU
vcpus	虚拟 CPU 数
vif	设置虚拟 NIC（MAC 地址、以太网模型、连接的网桥、设备类型）
disk	设置虚拟磁盘（磁盘类型、路径、客户端操作系统上的设备名称、读写模式）
vtpm	设置 TPM
dhcp	启用传递到内核启动参数的 dhcp
netmask	指定传递到内核启动参数的子网掩码
gateway	指定传递到内核启动参数的网关
Hostname	指定传递到内核启动参数的主机名称
root	指定传递到内核启动参数的 root 设备
nfs_server	指定传递到内核启动参数的 NFS 服务器
nfs_root	指定传递到内核启动参数的 NFS 的 root 设备
extra	指定其他传递到内核启动参数的选项
on_poweroff	电源切断时的操作（destroy、restart、preserve、rename-restart）
on_reboot	重启时的操作（destroy、restart、preserve、rename-restart）
on_crash	内核 panic 时的操作（destroy、restart、preserve、rename-restart）
device_model:	设备仿真器（qemu-dm）的路径
boot	启动顺序（c:HDD、d:CD-ROM 驱动器、a:FDD）
snapshot	磁盘映像的写时复制（copy on write）
sdl	在 VGA 中使用 SDL 库
vnc	在 VGA 中使用 VNC 显示器

（续）

项　目	说　明
vnclisten	VNC 的连接许可地址
vncdisplay	VNC 的显示器编号
vncunused	自动分配 VNC 中未使用的显示器编号
vncpasswd	VNC 连接时使用的密码
stdvga	将 VGA 中使用的设备模型设置为 stdvga
serial	将串行控制台重定向到 pty 设备
soundhw	声卡的模型
localtime	启用 localtime
full-screen	全屏启动
usb	启用 USB
usbdevice	启用 USB 鼠标或 USB 图形输入板
keymap	指定键盘的布局

HACK#29　如何使用KVM

本节介绍KVM的使用方法。

KVM是Linux 2.6.20中采用的Linux内核的管理程序功能。管理程序是指将多个操作系统在1台物理机器上运行的软件，KVM在RHEL6等中采用。KVM采用的是全虚拟化方式，必须在系统能够使用CPU的Inter VT或AMD-V功能的状态下才能使用。使用KVM时，请在BIOS的设置界面上确认虚拟化功能是否可用。

KVM的概要

如图5-3所示，KVM是由管理程序—kvm启动程序和设备仿真器—qemu-kvm构成的。qemu-kvm是在PC仿真器qemu上进行了一些针对KVM的修改后得到的。KVM的特征是kvm驱动程序作为Linux内核的一部分运行，因此可以使用Linux内核的大部分功能。例如，进程调度程序功能或省电功能就可以直接使用Linux内核的功能。

KVM的使用方法

KVM一般通过virt-manager来控制，但为了看到KVM是如何运行的，这里尝试使用qemu-kvm来控制KVM。使用qemu-kvm就可以使用qemu的大部分选项。qemu-kvm的选项非常多，这里仅介绍经常用到的一部分选项（见表5-2）。

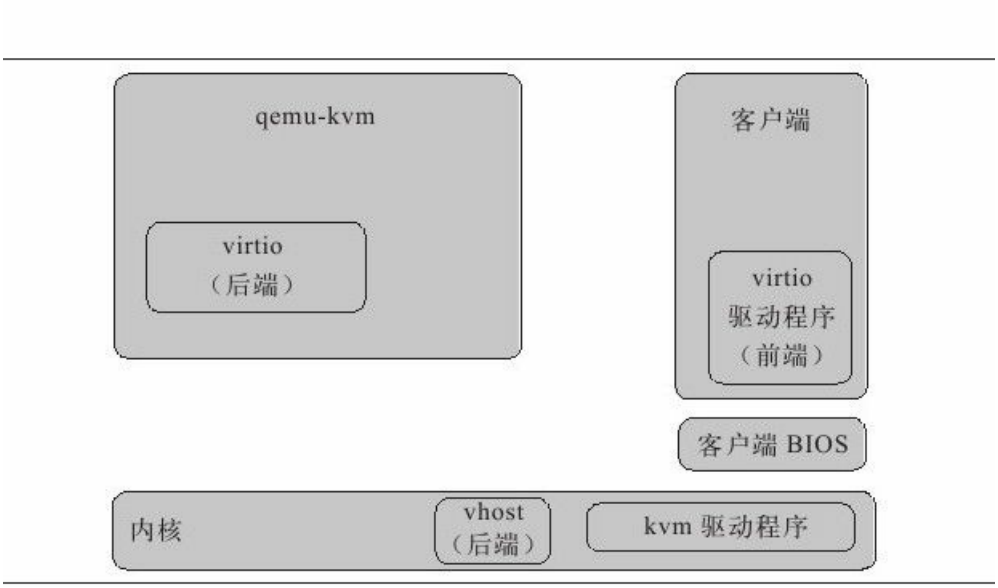

图　5-3　KVM的概要

表 5-2　qemu 的主要选项

选　项	说　明
-M	指定仿真机器的种类（通过 -M? 可以显示 qemu 支持的机器种类的列表）
-cpu	指定 CPU 的模型（通过 -cpu? 可以显示可指定的模型的列表）
-smp	指定 CPU 数（未指定时设置为 1）。 smp 选项的子选项如下（用逗号分开指定）： maxcpus=cpus　包括可以动态添加的 CPU 在内的最大 CPU 数 cores=cores　平均 1 个套接字的核数 threads=threads　平均 1 个核的线程数 sockets=sockets　系统的套接字数
-fda/-fdb	分别将文件指定为第一台计算机的软盘、第二台计算机的软盘的映像
-hda/-hdb/-hdc/-hdd	分别将文件指定为第一台计算机、第二台计算机、第三台计算机、第四台计算机的 IDE 硬盘的映像
-cdrom	将文件指定为 IDE CD-ROM 映像（CD-ROM 连接到第二台计算机的 IDE 的主设备）
-drive	详细指定磁盘驱动程序 drive 选项的子选项如下（用逗号分开指定）： file=file　将 file 指定为磁盘映像 if=interface　指定连接驱动器的接口种类（ide、scsi、sd、mtd、floppy、pflash、virtio）

（续）

选　项	说　明
-drive	bus=bus,unit=unit　指定连接驱动器的总线编号和单元 id
	index=index　指定将驱动器连接到第几个接头
	media=media　指定驱动器的种类（disk、cdrom）
	cache=cache　指定访问磁盘上的数据时怎样使用主机操作系统上的磁盘缓存（none、write back、unsafe、writethrough）
	aio=aio　指定 threads 或 native。threads 表示基于 pthread 的非同步 I/O，native 表示 Linux AIO
	format=format　指定磁盘格式。这时不会自动检测磁盘格式，因此，如果指定 format=raw 就可以避免错误运行
	serial=serial　赋予设备的串行号
	addr=addr PCI　指定 PCI 地址（仅 if=virtio 时）
-boot	指定启动顺序。启动顺序可以指定软盘（a）、硬盘（c）、CD-ROM（d）、网络（n）。
-m	指定内存量（单位为 MB）
-k	指定键盘布局
-usb	启用 usb
-usbdevice	指定 usb 设备（mouse、tablet、disk、host、serial、braille、net）
-device	指定添加的设备。可用的驱动程序列表可以通过 -device? 来显示。各驱动程序的可设置属性可以通过 -device driver,? 来显示
-name	设置客户端名称
-uuid	指定机器的 UUID
-nographic	禁用图形模式
-spice	启用 spice 远程桌面协议
-vga	指定显卡的种类（std、cirrus、vmware、xenfb、qxl、none）
-vnc	开启 VNC 服务器
-enable-kvm	启用 KVM

在RHEL6中使用qemu-kvm启动KVM的客户端操作系统时，操作步骤如下。

```
#/usr/libexec/qemu-kvm-M rhel6.0.0-enable-kvm-m 1024-smp 2-name rhel6-4
-boot c-hda/dev/sdc-vnc 127.0.0.1：2
```

如果是第一次安装等情况，则需要指定cdrom选项，并向boot选项指定CD-ROM（d）来启动。

```
#/usr/libexec/qemu-kvm-M rhel6.0.0-enable-kvm-m 1024-smp 2-name rhel6-4
-boot d-hda/dev/sdc-cdrom/root/rhel6.iso-vnc 127.0.0.1：2
```

在这里启动的是1GB内存、2CPU的客户端操作系统。将主机操作系统的/dev/sdc显示为客户端操作系统的第一台计算机的IDE磁盘，设备驱动程序就是virtio。客户端操作系统的VGA可以通过VNC连接到2号显示器。这里省略了网络的选项，可以使用默认设置的-net nic-net user选项。

KVM的网络选项

用于网络连接的选项也有一些（见表5-3），但一般使用网桥或者NAT连接到外部网络。这里介绍经由网桥连接的方法。需要事先在主机操作系统内安装如下工具包。

```
bridge-utils
tunctl
iproute
```

将外部连接用的NIC设置为eth0时，为了将eth0连接到网桥，需要编辑/etc/sysconfig/network-scripts/ifcfg-eth0的如下内容。

```
DEVICE="eth0"
NM_CONTROLLED="no"
ONBOOT=yes
HWADDR=00：1D：7D：53：C1：EC
TYPE=Ethernet
BRIDGE=br0
NAME="System eth0"
UUID=5fb06bd0-0bb0-7ffb-45f1-d6edd65f3e03
```

此外，将/etc/sysconfig/network-scripts/ifcfg-br0按下列内容进行编辑，以用于网桥。

```
DEVICE="br0"
NM_CONTROLLED="no"
ONBOOT=yes
TYPE=Bridge
BOOTPROTO=none
IPADDR=192.168.1.2
PREFIX=24
GATEWAY=192.168.1.1
DNS1=192.168.1.3
DEFROUTE=yes
IPV4_FAILURE_FATAL=yes
IPV6INIT=no
```

要让编辑后的网络脚本立刻生效，需要重新启动网络服务。

```
#service network restart
```

在/etc/qemu-ifup中准备qemu-kvm用的网络脚本。

```
#！/bin/sh
set-x
switch=br0
if[-n"$1"]；then
/usr/bin/sudo/usr/sbin/tunctl-u'whoami'-t$1
/usr/bin/sudo/sbin/ip link set$1 up
sleep 0.5s
/usr/bin/sudo/usr/sbin/brctl addif$switch$1
exit 0
else
echo"Error：no interface specified"
exit 1
fi
```

指定下列网络选项，启动qemu。

```
#/usr/libexec/qemu-kvm-M rhel6.0.0-enable-kvm-m 1024-smp 2-name rhel6-4-boot c
-hda/dev/sdc-vnc 127.0.0.1：2-net nic-net tap
```

表 5-3 qemu 的主要网络选项

选 项	说 明
-net nic	创建网络接口
	-net nic 选项的子选项如下（用逗号分开指定）：
	vlan=n 指定 vlan id
	macaddr=mac MAC 地址
	model=type 网卡的模型类型（virtio、i82551、i82557b、i82559er、ne2k_pci、ne2k_isa、pcnet、rtl8139、e1000、smc91c111、lance、mcf_fe）
	name=name 网卡名称
	addr=addr PCI 的设备号
	vectors=v MSI-X 的矢量号
-net user	使用以用户模式运行的网络栈
	-net user 选项的子选项如下（用逗号分开指定）：
	vlan=n 指定 vlan id
	name 网卡名称
	net=addr[/mask] 指定 IP 网络地址和子网掩码（默认为 10.0.2.0/24）
	host=addr 指定从客户端操作系统看到的主机操作系统的 IP 地址
	restrict=y|yes|n|no 如果指定 yes，则客户端操作系统被隔离

（续）

选　项		说　明
-net user	hostname=name	指定的主机通过 DHCP 服务器被通知到客户端操作系统
	dhcpstart=addr	指定安装的 DHCP 服务器可以分配的 IP 地址。使用指定的 IP 地址中的 16 个地址
	dns=addr	指定从客户端操作系统看到的虚拟 DNS 服务器的 IP 地址
-net tap	利用 TAP 的网络接口	
	-net tap 选项的子选项如下（用逗号分开指定）：	
	vlan=n	指定 vlan id
	name=name	网卡名称
	fd=h	已打开的 TAP 设备号
	ifname=name	TAP 设备的名称
	script=file	指定 Up 网络接口时使用的网络脚本。未指定时为 /etc/qemu-ifup
	downscript=dfile	指定 Down 网络接口时使用的网络脚本。未指定时为 /etc/qemu-ifdown
	sndbuf=nbytes	send buffer size 的上限大小。未指定时为 1 048 576
	vnet_hdr=off|on	off 表示禁用 IEF_VNET_HDR 标记 on 表示启用 IEF_VNET_HDR 标记
	vhost=on	启用内核的 vhost 功能
	vhostfd=h	连接到已经打开的 vhost net 设备
-net none	不使用网络设备。（qemu 的默认设置为 -net nic -net user）	

小结

这里介绍了通过qemu-kvm使用KVM的方法。从virt-manager等使用时也是在内部执行qemu-kvm。使用ps命令等进行确认，就可以根据这里介绍的内容，了解KVM的客户端操作系统是如何启动的。qemu-kvm的选项除了这里介绍的以外还有很多，推荐参考qemu的用户手册。

参考文献

·KVM Howto's

http://www. linux-kvm.org/page/HOWTO

·QEMU Emulator User Documentation

http://qemu. weilnetz.de/qemu-doc.html

——Akio Takebe

HACK#30　如何不使用DVD安装操作系统

本节介绍不使用KVM，而是利用KVM安装在物理机器环境下启动的Linux。

一般安装操作系统时需要将安装用的ISO映像刻录到DVD然后再进行，但是刻录DVD需要花费时间和精力，更重要的是要用到DVD盘，不利于环境保护。

本节介绍的是不需要刻录DVD，使用KVM安装虚拟环境下的客户端操作系统并用在物理环境中的方法。

使用KVM安装操作系统时是通过virt-manager来进行的。这里使用的主机操作系统是Fedora 14，客户端操作系统是CentOS 5.6。另外，客户端操作系统安装的地方是USB HDD。启动virt-manager，根据提示安装，就可以顺利地将客户端操作系统安装到USB HDD。

需要的准备

安装用媒体的映像

选择CentOS 5.6的ISO映像文件。本次使用的是CentOS 5.6-i386-bin-DVD.iso。

安装用磁盘

这里将USB HDD分配为安装客户端操作系统的磁盘区。在笔者的环境下/dev/sdb为USB HDD，因此按照图5-4所示进行选择。请向客户端操作系统分配整个磁盘，而不是磁盘分区表。

図　5-4　安装界面

成功地将CentOS 5.6安装为客户端操作系统后，登录到客户端操作系统，使用mkinitrd命令重新生成initrd。在笔者的环境下安装的磁盘是USB HDD，因此按照下列方法将usb-storage驱动程序模块安装到initrd。

```
#mkinitrd-f/boot/initrd-2.6.18-238.el5.2.img 2.6.18-238.el5--with usb-storage
```

接下来，在客户端操作系统上修改/boot/grub/grub.conf，改为通过UUID指定root设备。initrd指的是刚才生成的initrd。

```
default=0
timeout=5
splashimage=（hd0，0）/grub/splash.xpm.gz
hiddenmenu
title CentOS（2.6.18-238.el5）
root（hd0，0）
#kernel/vmlinuz-2.6.18-238.el5 ro root=LABEL=/rhgb quiet
kernel/vmlinuz-2.6.18-238.el5 ro root=UUID=b04d14e9-1a6c-417f-a981-
c9f2e9a4ce26 rhgb quiet
#initrd/initrd-2.6.18-238.el5.img
initrd/initrd-2.6.18-238.el5.2.img
```

UUID可以通过blkid命令来确认。

```
#blkid/dev/vda2
/dev/vda2：LABEL="/"UUID="b04d14e9-1a6c-417f-a981-c9f2e9a4ce26"
SEC_TYPE="ext2"TYPE="ext3"
```

到这一步准备工作就完成了。在物理环境下启动时，请从BIOS的boot菜单中选择USB HDD作为启动磁盘。选择USB HDD作为启动磁盘后，BIOS就会读入USB HDD最前面的MBR，执行bootloader。在这里是从USB HDD启动GRUB。内核会安装initrd中的内核模块，但在虚拟环境下启动时是使用virtio-blk驱动程序模块读入磁盘，在物理环境下是使用usb-storage驱动程序模块读入磁盘，因此生成的磁盘不论在哪个环境下都可以启动。

需要注意的是，不能在grub.conf或/etc/fstab里直接写入/dev/sdb等设备文件名；因为在虚拟环境下，如果使用了IDE的仿真器就会分配hda设备文件名；如果使用了virtio等PV驱动程序就会分配vda的名称。

如果使用UUID，操作系统的功能会屏蔽上述设备名的变更，因此不论在哪个环境下操作系统都可以启动。卷标号也可以屏蔽设备，但是使用其他磁盘时就可能会存在相同的卷标号。在这种情况下无法判断指定了哪个磁盘设备，有时无法顺利启动。

小贴士：如果实在不行，还可以按照下列方法解压缩initrd，直接编辑其中的init文件。

1.解压缩initrd。

```
#mkdir work
#cd work
#gzip-cd/boot/initrd-2.6.18-238.el5.img|cpio-id
```

2.编辑init文件。

```
#vim init
```

3.重新生成initrd。

```
#fnd.-print|cpio--quiet-c-o|gzip-9＞/boot/initrd-2.6.18-
```

238.el5.new.img

小结

本节介绍了使用CentOS 5.6作为客户端操作系统时的例子，而在RHEL6和Fedora 14等最近的发布版中采用的是initramfs。initramfs可以创建比initrd更加通用的preboot环境。RHEL6等的initramfs一般包含驱动程序，默认使用的是通过UUID指定设备。因此多数情况下不用进行上述的特殊操作，就可以直接在物理、虚拟两种环境中使用。本次测试中使用的环境如下，仅供参考。

·系统：FMV-P8230

·客户端操作系统：CentOS-5.6-i386

·USB-HDD：I-O Data HDPC-U320

——Akio Takebe

HACK#31　更改虚拟CPU分配方法，提高性能

本节介绍虚拟环境下的虚拟CPU分配方法的技巧。

虚拟化环境下客户端操作系统的各虚拟CPU可以各自独立地分配物理CPU。例如，可以将客户端操作系统A的虚拟CPU1分配（pin指定）给主机操作系统的物理CPU3。当各虚拟CPU这样占用物理CPU时，人们容易认为物理CPU的资源相互完全分离。但是，在现代的多核CPU中，各物理CPU资源多数未完全分离，如果不能正确选择分配给虚拟CPU的物理CPU，就有可能导致性能大幅降低。本节将介绍应当使用怎样的分配方法。

首先，有的多核CPU是在核之间共享L2缓存或L3缓存的。例如，Intel®Core TM 2 Quad CPU Q6700中有4个核，其中两个核共享1个L2缓存（见图5-5）。

在将某个虚拟机的两个虚拟CPU分别分配给不共享L2缓存的核时，一旦加大内存负载就有可能造成CPU性能降低（见图5-6）。

使用virt-manager的物理CPU分配方法

virt-manager可以如图5-7所示，通过CPU pinning菜单将虚拟机的虚拟CPU固定分配给物理CPU。这里显示的CPU编号为Linux内核所识别的CPU编号，而不是用来标识核的位置。要找出共享缓存的CPU，可以参照/sys/devices/system/cpu/cpuN/cache/indexM/shared_cpu_list[1]。

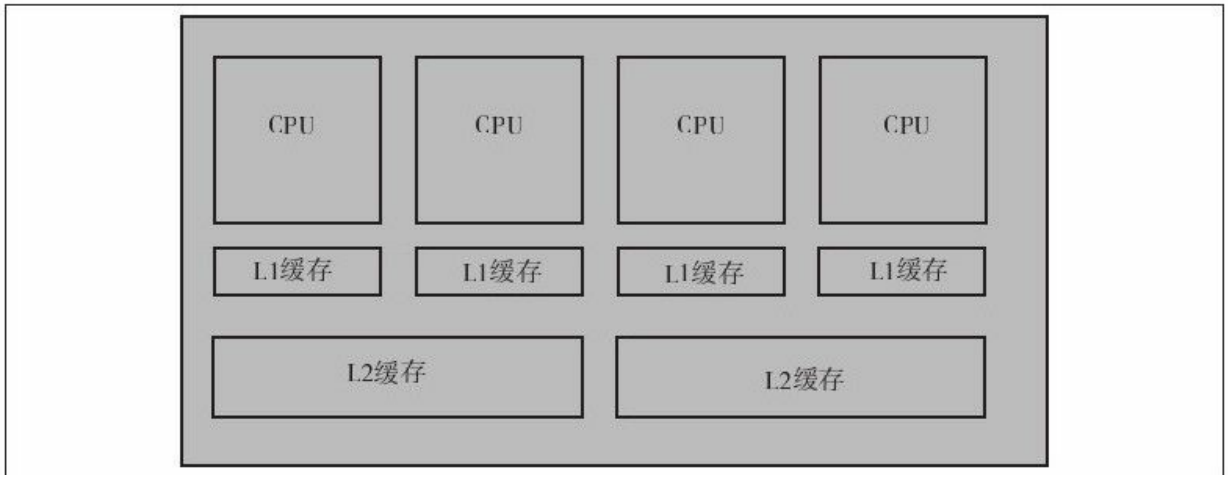

图　5-5　Q6700

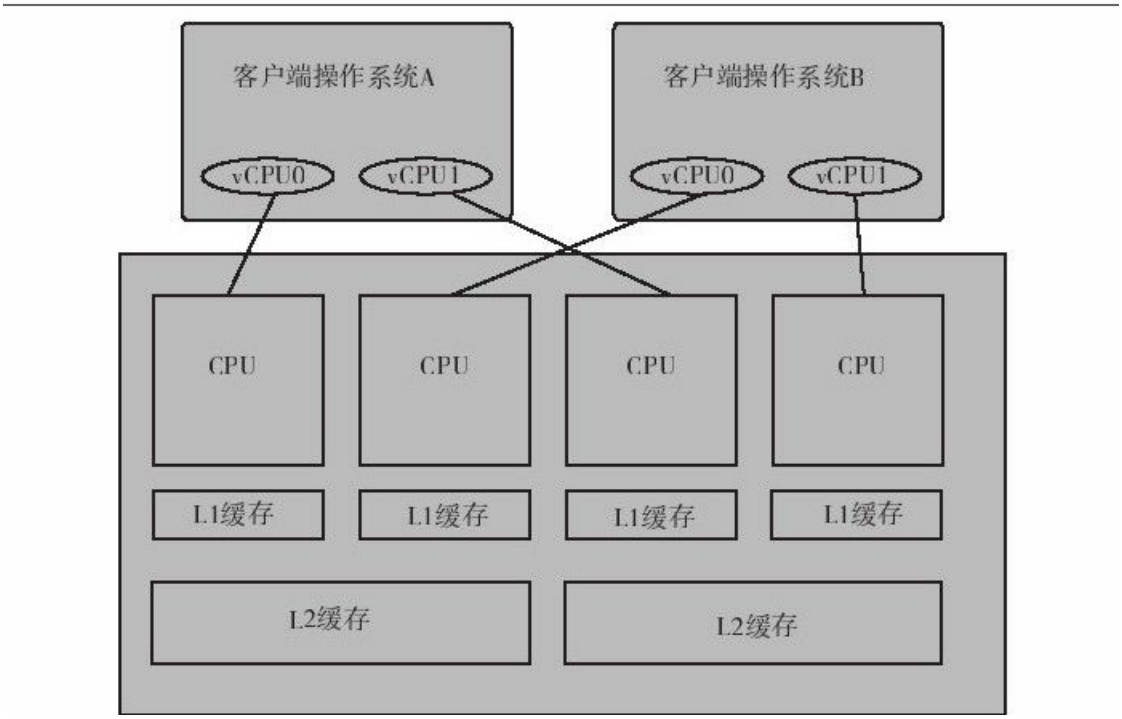

图　5-6　导致性能降低的分配方法

在这个环境下，可以得知CPU0和CPU2，CPU1和CPU3共享缓存。

```
#cat/sys/devices/system/cpu/cpu0/cache/index2/shared_cpu_list 0，2
#cat/sys/devices/system/cpu/cpu1/cache/index2/shared_cpu_list 1，3
```

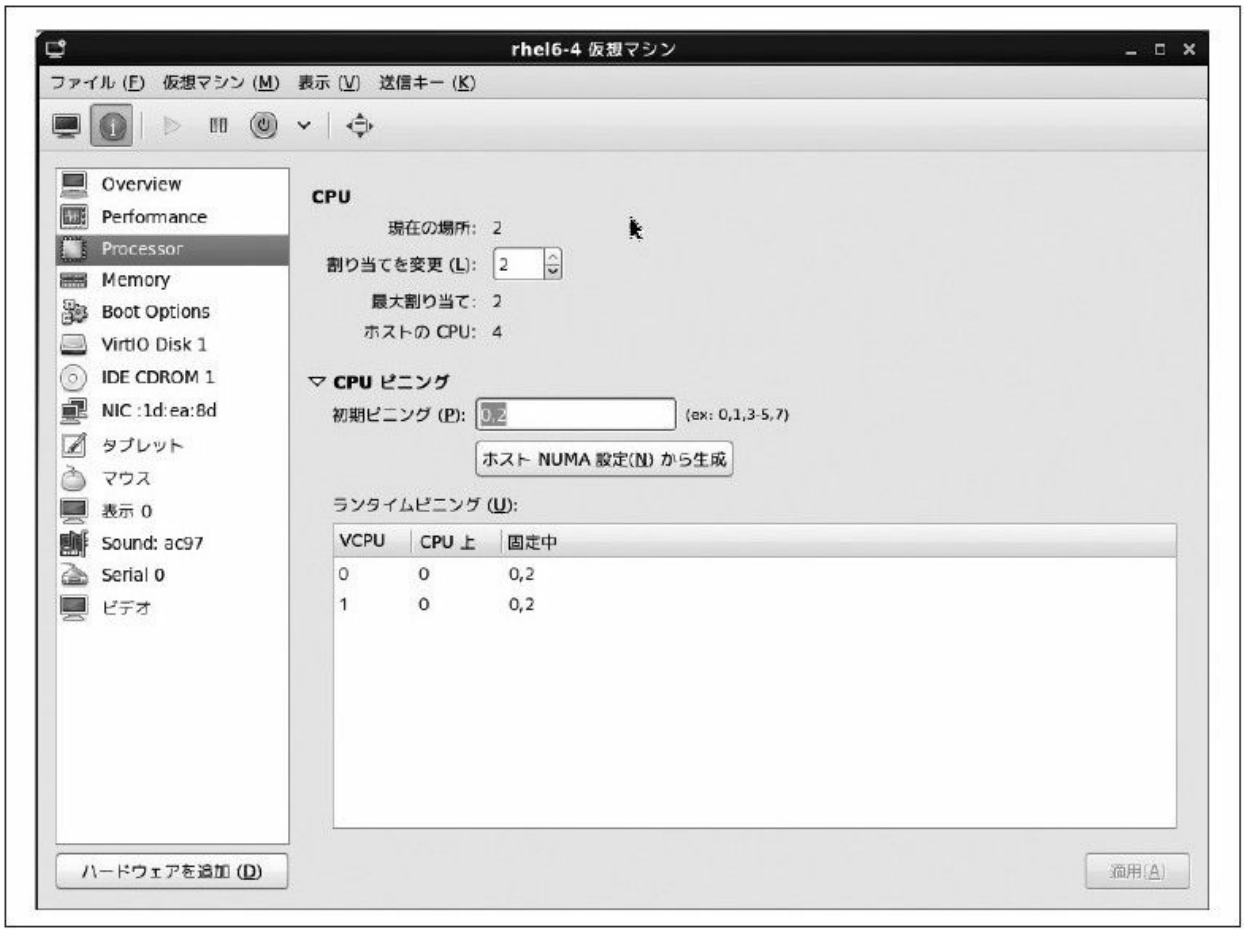

图　5-7　在CPU pinning菜单上设置物理CPU的固定分配

[1]N、M代表数字。

概要分析

下面查看在共享L2缓存的情况和不共享的情况下性能会有多大的变化（如图5-8和图5-9所示）。这里准备了两个客户端操作系统，在客户端操作系统A中执行UnixBench，在客户端操作系统B中加大CPU或内存负载。

CPU	Intel ® Core™ 2 Quad CPU Q6700 @ 2.66GHz
内存	4GB
主机操作系统	RHEL6
客户端操作系统	RHEL6
客户端操作系统 CPU	虚拟 CPU
客户端操作系统内存	1GB

CPU和内存的负载工具是stress[1]。

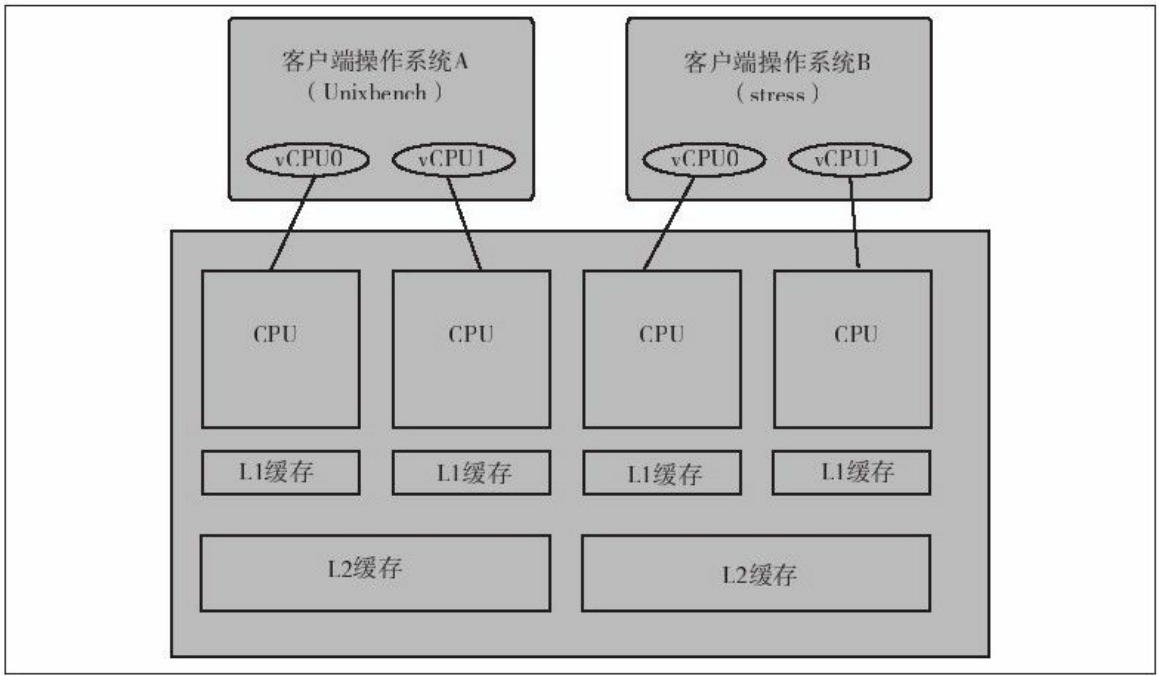

图　5-8　各客户端操作系统分别共享L2缓存的情况

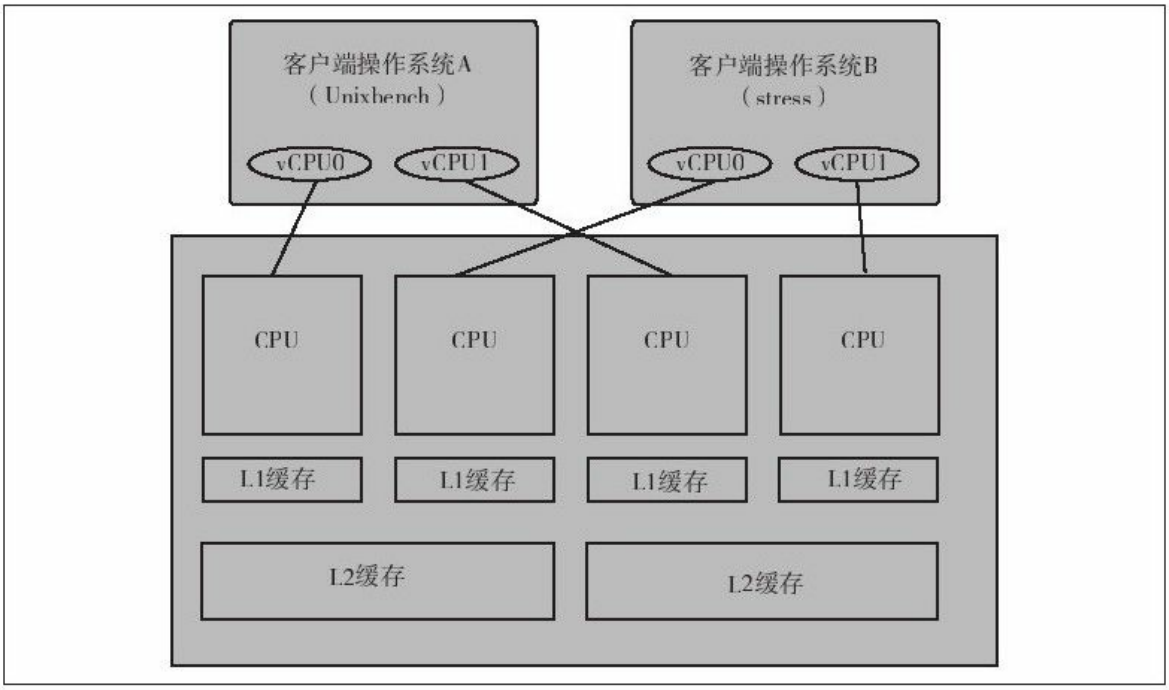

图　5-9　两个客户端操作系统共享L2缓存的情况

图5-10所示为UnixBench的结果。纵轴为与客户端操作系统B空间状态的比例。横轴为UnixBench的各基准测试的种类。从结果来看，在客户端操作系统之间共享L2缓存的情况下，对客户端操作系统B加大CPU负载时，客户端操作系统A的性能降低并不明显。但是对客户端操作系统B加大内存负载时，客户端操作系统A的性能降低了70%左右。但是，对客户端操作系统B加大内存负载时，客户端操作系统A的CPU相关基准测试中并未出现太大的性能降低。

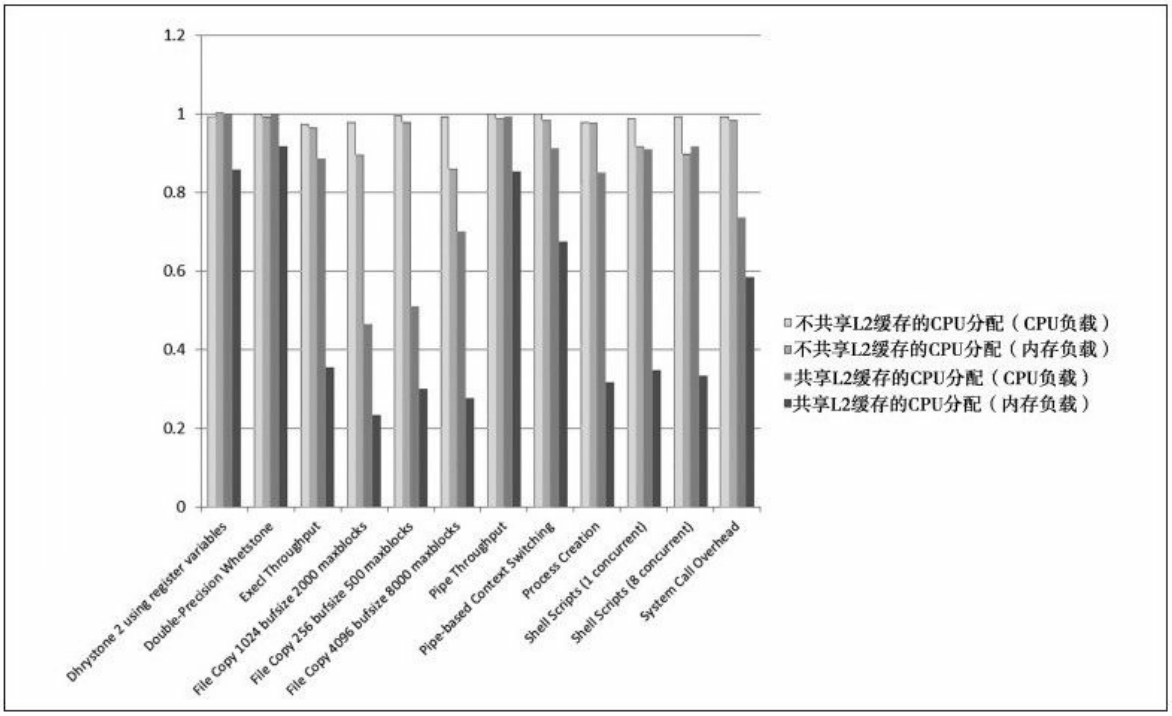

图　5-10　UnixBench的结果

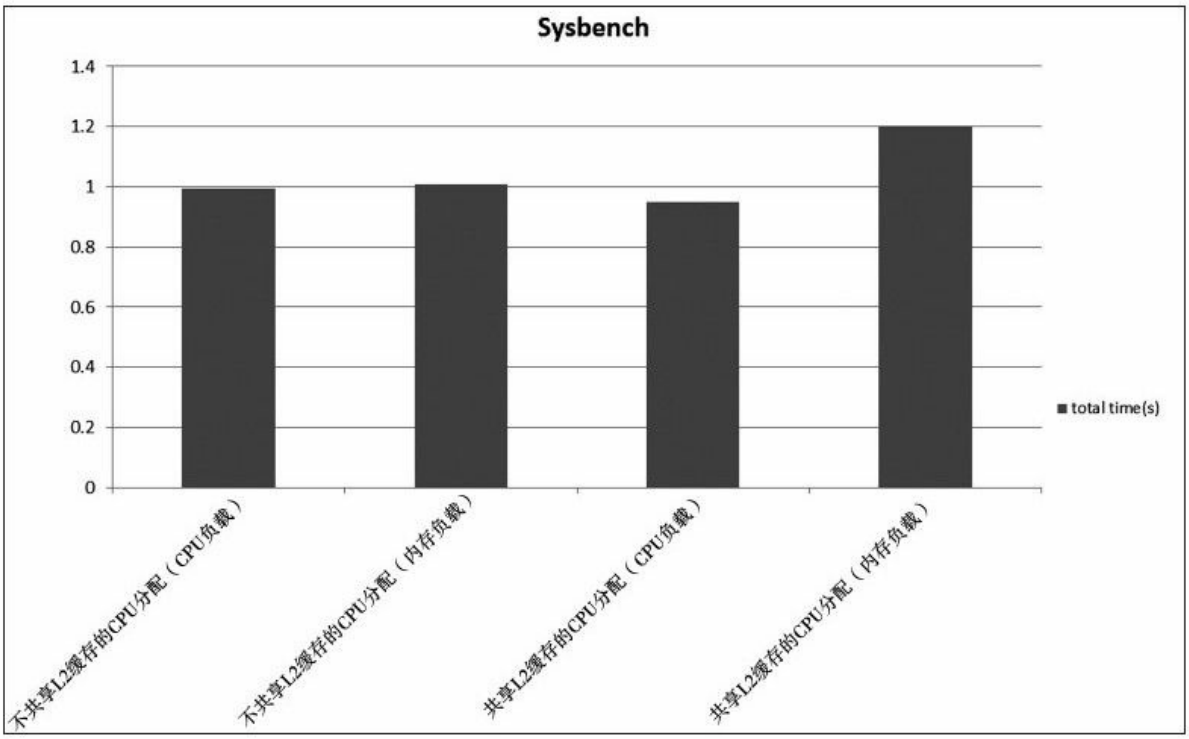

图　5-11　sysbench的结果

那么，在实际的DB服务器等上会产生多大的影响呢？图5-11所示为进行sysbench而非UnixBench时的示例。纵轴为执行sysbench的合计时间。在客户端操作系统共享L2缓存的情况下，如果加大对客户端操作系统B的内存负载，从客户端操作系统A的sysbench结果也能够看出性能降低了20%左右。

根据以上结果，可以得知：

1.内存负载较高的客户端操作系统在分配CPU时必须让该客户端操作系统的虚拟CPU共享缓存。

2.由于CPU负载较高的客户端操作系统在共享CPU缓存时会产生的影响较小，因此可用它来与内存负载较高的客户端操作系统共享CPU缓存。

[1]http：//weather.ou.edu/～apw/projects/stress/stress-1.0.4.tar.gz

小结

这里介绍了通过CPU分配来改善客户端操作系统性能的技巧。一般在Java等应用程序服务器或DB服务器中内存负载有增加的倾向。

除CPU以外，对各客户端操作系统共享的资源或组件进行一些改进，也可以改善性能。例如，在使用virtio等半虚拟化驱动程序时，就会共享主机操作系统的I/O调度程序。已有论文提出在这种情况下如果将主机操作系统的I/O调度程序换成更适合系统的noop或deadline等，就可以改善性能[1]。

在云等大规模环境下，如果能够较好地配置客户端操作系统，就可以实现不会产生性能降低的系统，大家可以尝试一下。

[1]SOSP HotStorage'09 Dave Boutcher and Abhishek Chandra（University of Minnesota）：Does Virtualization Make Disk Scheduling Passe? http：//www.sigops.org/sosp/sosp09/hotstorage.html

参考文献

·XenSummit 2007 November Padmashree K Apparao：Characterization and Ana

lysis of a Server Consolidation Benchmark

·UnixBench

http://code. google.com/p/byte-unixbench/

·sysbench

http://sysbench. sourceforge.net/

——Akio Takebe

HACK#32　如何使用EPT提高客户端操作系统的性能

这里将介绍Memory Management Unit（MMU）的虚拟化功能—Extended Page Table（EPT）功能。

MMU

Memory Management Unit（MMU）是具有内存管理功能的硬件。MMU有一个主要功能是将虚拟地址转换为物理地址。一般在x86系列的CPU上运行的操作系统是使用分页（paging）功能将虚拟地址转换为物理地址的。分页功能涉及进行地址转换的转换表。这个表称为页表（page table）。MMU使用从CPU的CR3寄存器找到的页表，从虚拟地址转化为物理地址。IA-32的分页结构如图5-12所示。

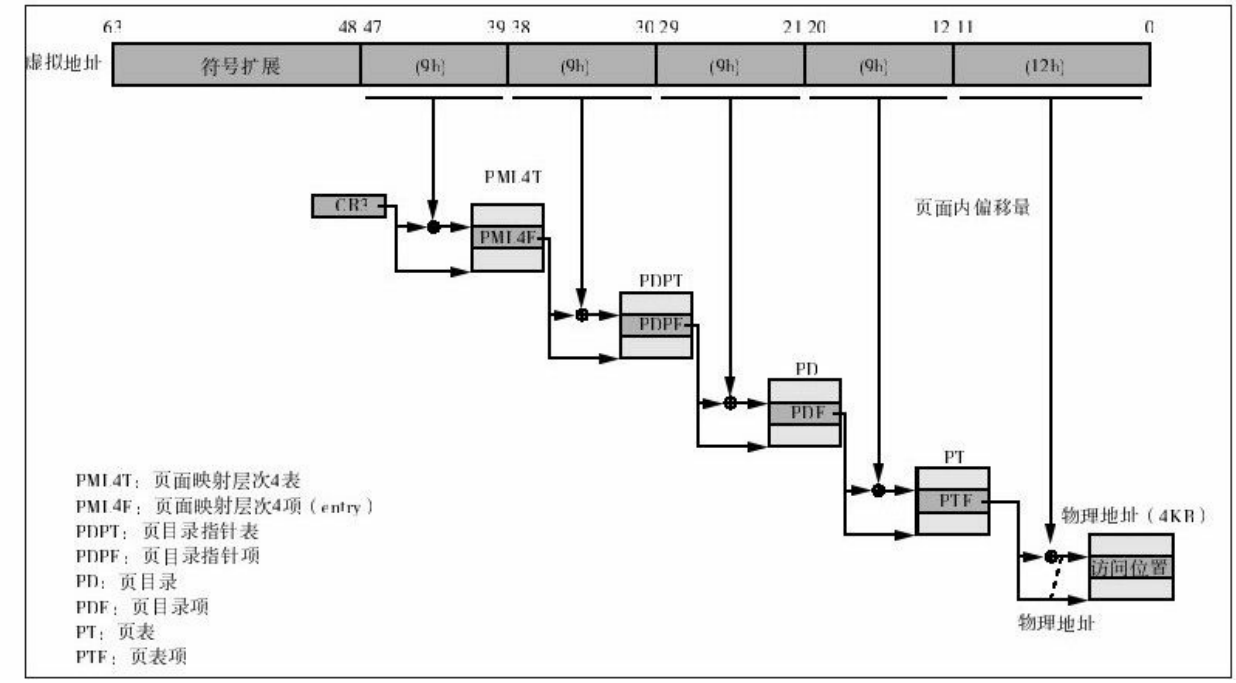

图　5-12　IA-32的分页结构（IA-32e模式、4KB页面）

影子页表

在虚拟环境下的内存地址有以下种类（见图5-13）。

·客户端虚拟地址—从客户端操作系统上看到的虚拟地址。

·客户端物理地址—从客户端操作系统上看到的物理地址。管理程序仿真的模拟物理地址。·主机虚拟地址—从主机操作系统上看到的虚拟地址。

·主机物理地址—从主机操作系统上看到的物理地址。与实际的物理地址相同。在虚拟化环境下有时也称为机器地址（绝对地址）。

在虚拟化环境下，不能由客户端操作系统来管理物理地址，因此客户端物理地址就是管理程序仿真的模拟地址。但使用这个客户端物理地址是无法访问实际的内存的，因此需要转换成主机物理地址。在Xen或KVM中，管理程序通过影子分页（shadow page table）的方法进行MMU的仿真。如图5-14所示，在影子分页中，管理程序先检测出客户端操作系统的页表配置处理方式，再仿真客户端操作系统的页表配置处理方式。管理程序会设置将客户端虚拟地址转换为主机物理地址的表。这个表称为影子表。管理程序将影子表设置为CPU的CR3寄存器。从而MMU就可以将客户端操作系统访问的客户端虚拟地址转换为主机物理地址。

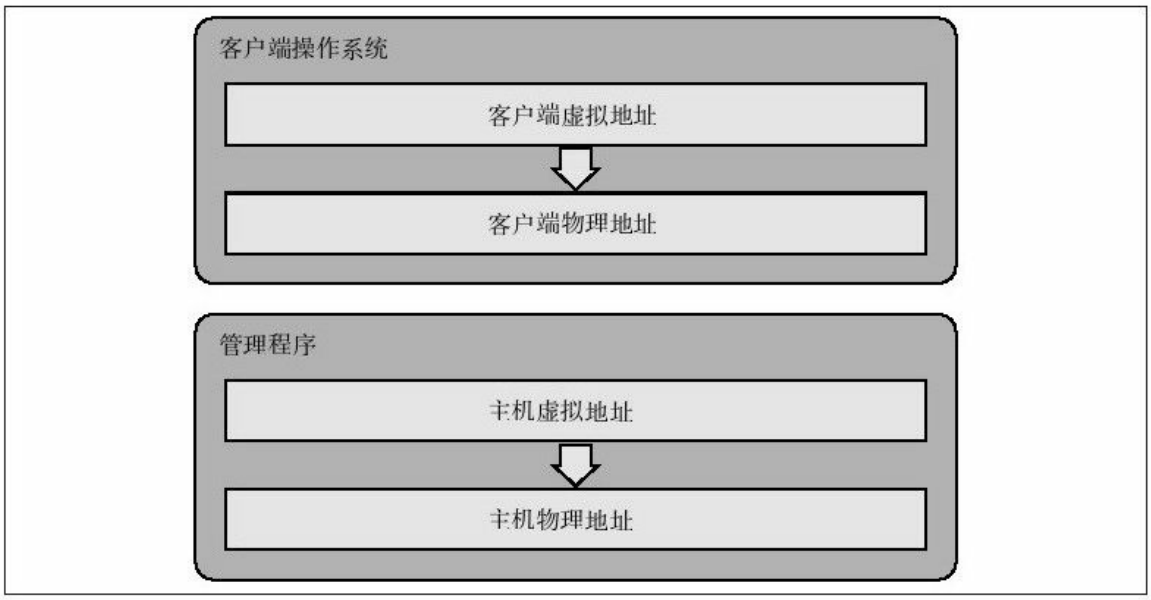

图　5-13　4种地址

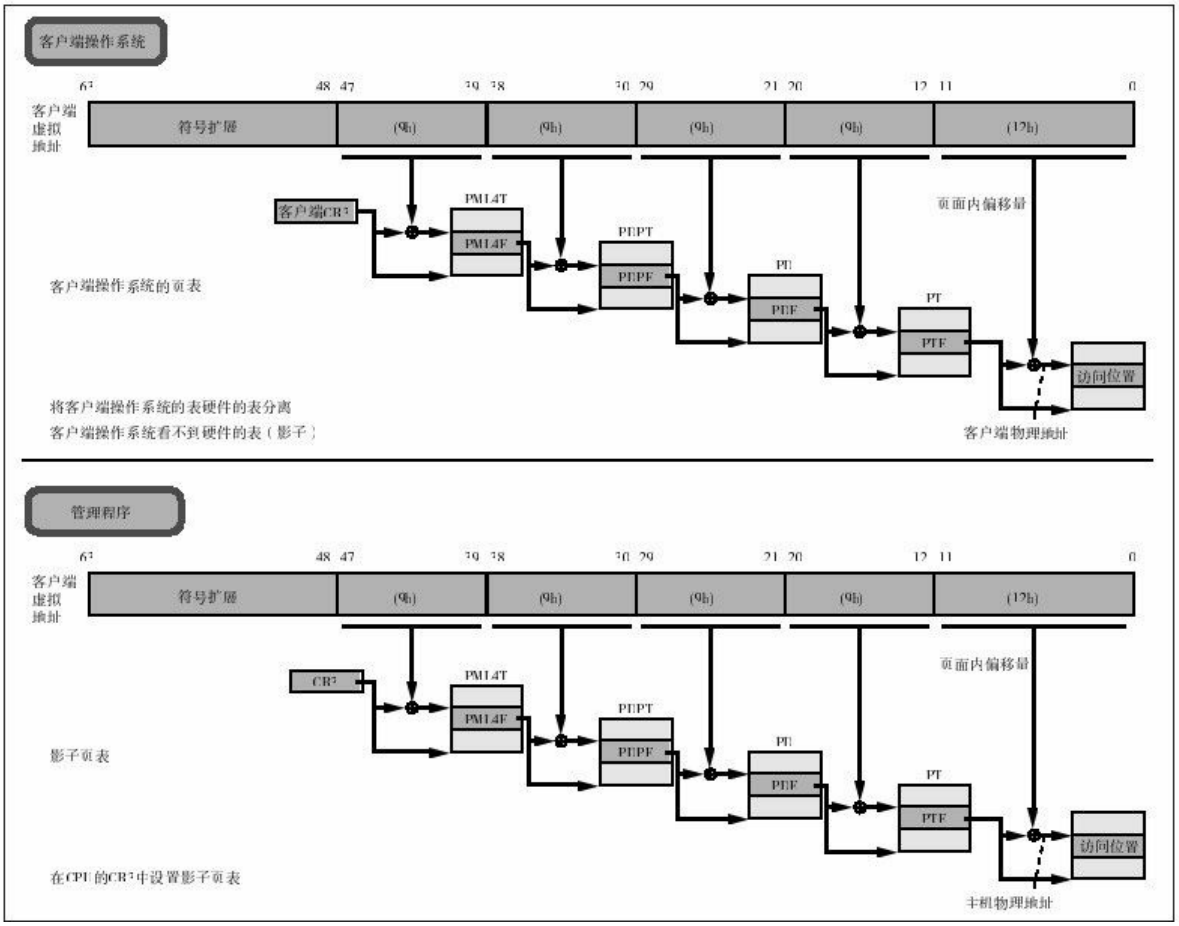

图　5-14　影子分页

EPT

EPT（Extended Page Table）是Intel公司的CPU所拥有的硬件虚拟化支持功能，如图5-15所示。通过在硬件中将MMU虚拟化，就可以减少管理程序的系统开销，提高客户端操作系统运行速度。AMD公司的CPU中也有同样的NPT（Nested Page Table）功能。这些功能由于使用两种页表而称为2维（2D）页表。EPT中准备了管理程序将客户端物理地址转换为主机物理地址的表。当启用EPT时，在客户端操作系统运行时CPU使用这个表自动将客户端虚拟地址转换为主机物理地址。

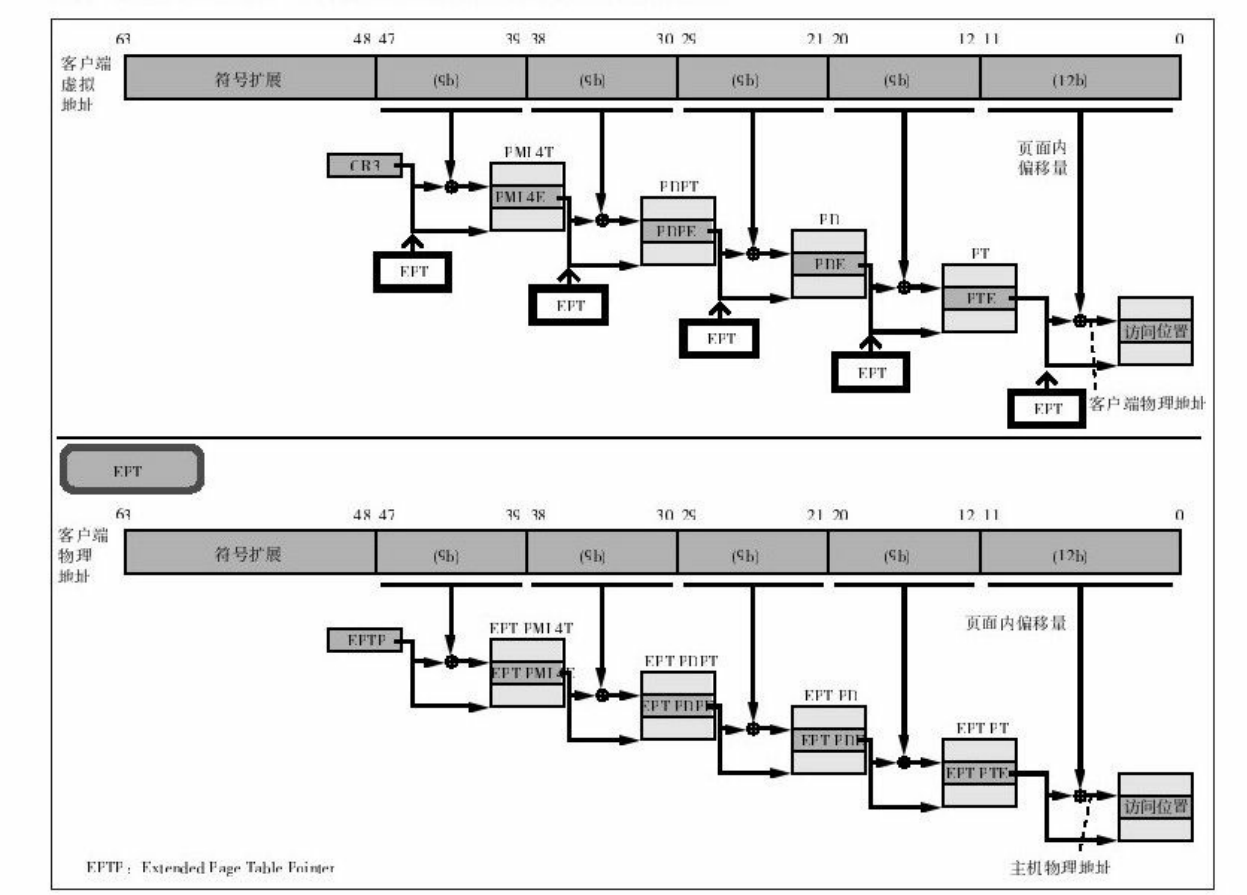

图　5-15　EPT

如何使用EPT

当CPU拥有EPT时，/proc/cpuinfo的flags会显示ept。

```
processor       : 0
vendor_id       : GenuineIntel
cpu family      : 6
model           : 26
model name      : Intel(R) Xeon(R) CPU           E5520  @ 2.27GHz
stepping        : 5
cpu MHz         : 2266.651
cache size      : 8192 KB
physical id     : 0
```

```
siblings        : 8
core id         : 0
cpu cores       : 4
apicid          : 0
initial apicid  : 0
fpu             : yes
fpu_exception   : yes
cpuid level     : 11
wp              : yes
flags           : fpu vme de pse tsc msr pae mce cx8 apic sep mtrr pge mca
cmov pat pse36 clflush dts acpi mmx fxsr sse sse2 ss ht tm pbe syscall nx
rdtscp lm constant_tsc arch_perfmon pebs bts rep_good nopl xtopology nonstop_
tsc aperfmperf pni dtes64 monitor ds_cpl vmx est tm2 ssse3 cx16 xtpr pdcm dca
sse4_1 sse4_2 popcnt lahf_lm ida dts tpr_shadow vnmi flexpriority ept vpid
bogomips        : 4533.30
clflush size    : 64
cache_alignment        : 64
address sizes   : 40 bits physical, 48 bits virtual
power management:
```

在RHEL6等Linux的最新发布版中基本上都启用了EPT。因此不需要特别的操作就可以使用EPT。在使用KVM的情况下，如果/sys/module/kvm_intel/parameters/ept为Y，就已启用EPT。禁用EPT时显示为N。

```
#cat/sys/module/kvm_intel/parameters/ept
Y
```

要禁用EPT，可以把kvm_intel的模块参数指定为ept=0，使用modprobe命令将其安装到内核中。

```
#modprobe kvm_intel ept=0
```

下面是禁用EPT时和启用EPT时UnixBench的比较。如图5-16所示，从UnixBench的结果也可以看出EPT的速度非常快。尤其是Process Creation（进程生成）等性能得到大幅提高。

客户端操作系统的构成	
CPU 数量	2（Intel ® Xeon ® CPU E5520 @2.27GHz）
内存	2GB
操作系统	RHEL6

图5-17中的图表是lmbench的结果。*Local*Communication bandwidths in MB/s的值越大表示性能越高，其他的基准测试都是较小的值，表示性能较高。从lmbench的结果也能看出EPT是能够有效提高性能的。

在lmbench的结果中，还有Context switching等在禁用EPT时性能较高的项目。这表示EPT容易引起TLB错误。发生TLB错误时，在影子分页的情况下最多发生5次内存访问，而在启用EPT时最多发生24次内存访问。EPT消耗的TLB很多，因此在容易发生TLB错误的基准测试中，影子分页的性能更高。

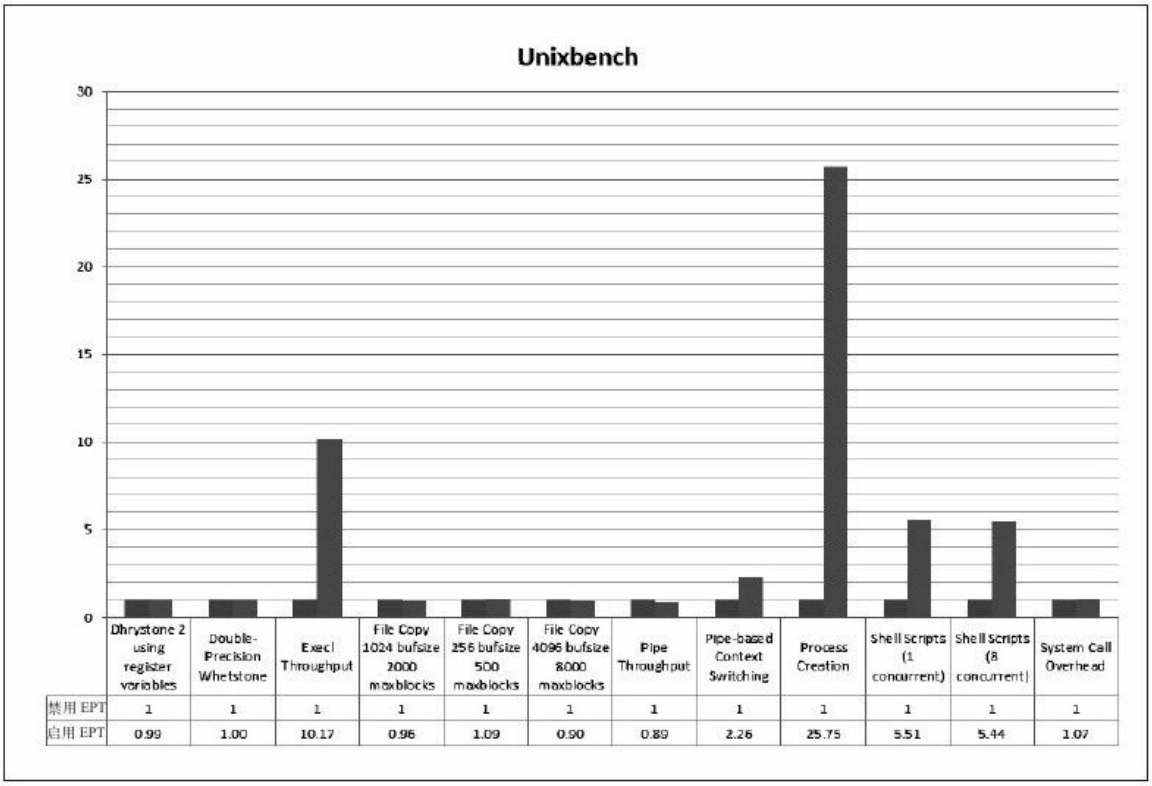

图　5-16　UnixBench的结果

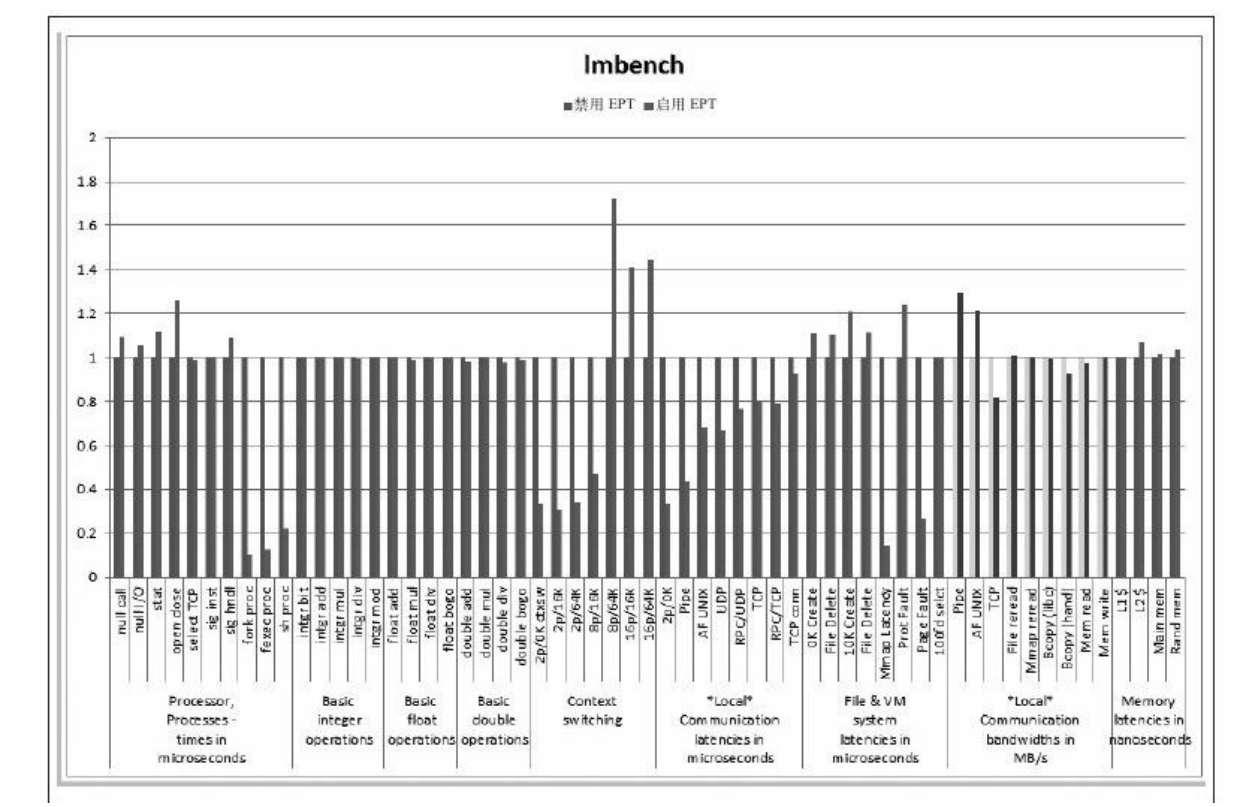

图　5-17　lmbench的结果

EPT+hugepage

可以使用hugepage来减轻EPT的TLB错误。下面介绍在KVM中使用hugepage的方法。hugepage在使用影子分页的情况下也能提高性能。

1.生成hugepage。

```
#mkdir/hugepages
#mount-t hugetlbfs hugetlbfs/hugepages/
#echo 4096＞/proc/sys/vm/nr_hugepages
```

2.重新启动libvirtd。

#service libvirtd restart

3.使用virsh edit，将客户端的结构文件改写为使用hugepage的设置。

在memory标签下添加memoryBacking、hugepage的标签。

```
#virsh edit＜客户端操作系统名＞
＜domain type='kvm'id='1'＞
＜name＞rhel6-4＜/name＞
＜uuid＞983f2e4e-baa8-e5d7-a97c-b574a72484b8＜/uuid＞
＜memory＞1048576＜/memory＞
＜currentMemory＞1048576＜/currentMemory＞
＜memoryBacking＞
＜hugepages/＞
＜/memoryBacking＞
＜vcpu cpuset='0，2'＞2＜/vcpu＞
＜os＞
＜type arch='x86_64'machine='rhel6.0.0'＞hvm＜/type＞
＜boot dev='hd'/＞
＜/os＞
……snip……
```

4.启动客户端操作系统。

```
#virsh start＜客户端操作系统名＞
```

小结

本节介绍了EPT的性能特性。一般认为使用EPT时的性能较高。但是正如本节介绍的，在极少的环境下EPT性能也较低。在这种情况下需要理解EPT的特性，灵活使用EPT和影子分页。

参考文献

Intel®64 and IA-32 Architectures software Developer's Manual

——kio Takebe

HACK#33　使用IOMMU提高客户端操作系统运行速度

本节介绍IOMMU功能，并说明如何提高客户端操作系统运行速度。

虚拟环境下客户端操作系统的I/O方式

本节将介绍在虚拟化环境下客户端I/O是通过什么样的方式进行的。Xen或KVM等管理程序中主要使用的有下列三种方式。

1.仿真方式（见图5-18）

2.半虚拟化方式（见图5-19）

3.直接I/O方式（见图5-20）

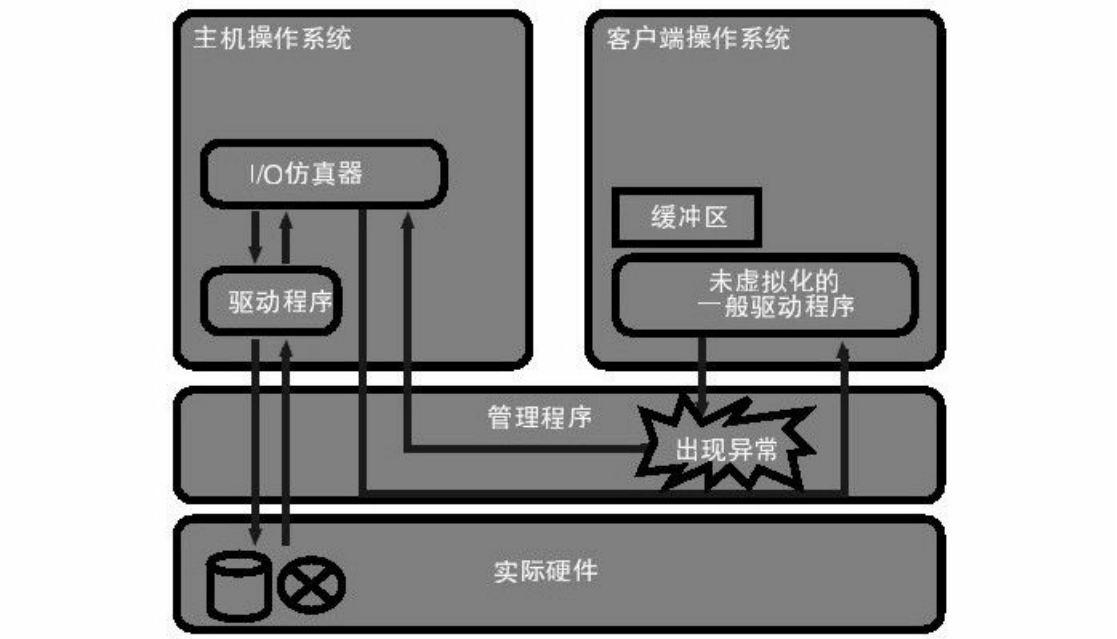

图　5-18　仿真方式

仿真方式是指使用仿真的PCI设备的I/O方式。从客户端操作系统看起来仿真设备与一

般设备是同样的。Xen或KVM在I/O仿真中采用的是qemu，因此可以通过qemu仿真的设备都可以使用。使用这个方式时，客户端操作系统完全不需要考虑虚拟化，因此已有的设备驱动程序也可以直接使用，是这种方式的优点之一。但是进行I/O时必须进行下列仿真。仿真在I/O寄存器层进行，因此针对客户端操作系统的一次I/O请求需要进行多次的仿真，就会造成系统额外开销过大，I/O速度缓慢。

1.客户端操作系统发布I/O命令。

2.管理程序进行捕捉（trap）。

3.管理程序分析客户端操作系统发布的命令。

4.如果是I/O命令，则通知主机操作系统上的I/O仿真器。

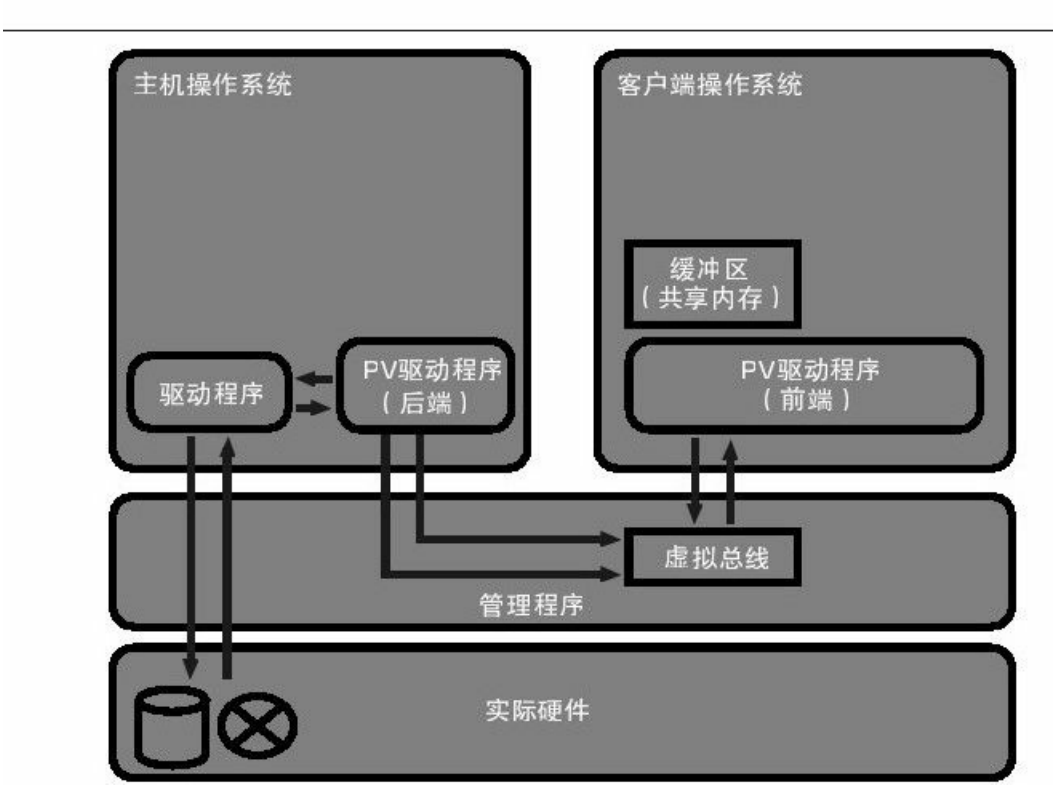

图　5-19　半虚拟化方式

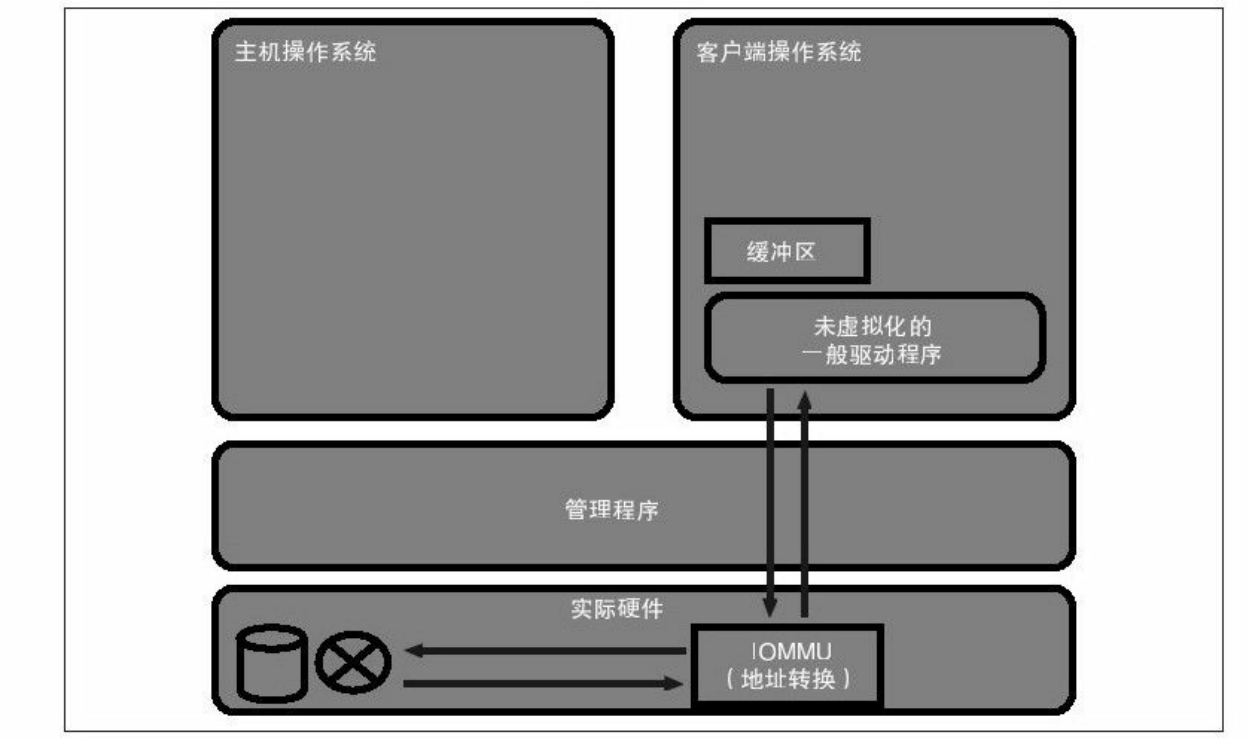

图　5-20　直接I/O方式

5.I/O仿真器仿真I/O命令。

6.如果需要实际的I/O发布，则I/O仿真器作为主机操作系统上的应用程序发布系统调用，实施I/O。

7.I/O仿真器一旦完成I/O，就会进行设置中断位（interrupt bit）、存取数据等的仿真。

8.通知管理程序I/O完成。

9.管理程序将中断提交给客户端操作系统。

半虚拟化方式是指使用称为Para Virtual驱动程序（PV驱动程序）或Split驱动程序的方式。PV驱动程序是指利用客户端操作系统使用的前端驱动程序和主机操作系统使用的后端驱动程序进行客户端I/O的方式。这个方式需要根据磁盘或网络、控制台等的I/O种类来生成驱动程序，但是可以非常快速地进行I/O处理。使用这种方式，可以减少客户端操

作系统发出每一次I/O请求时必须进行的处理数量，从而提高I/O速度。但是，实际发出I/O请求的是主机操作系统或管理程序，因此这部分系统开销是仍然存在的。在这种情况下，就出现了能够将这部分系统开销也消除的硬件。这就是Intel公司的Virtualization Technology for Directed I/O（VT-d）和AMD公司的AMD IOMMU。Xen或KVM中安装了称为PCI设备的直接I/O方式，就是运用这些硬件的。后面将介绍什么是直接I/O方式，以及如何使用。

关于DMA

在介绍直接I/O方式前，先温习一下DMA（Direct Memory Access）传输。DMA传输是指可以在内存和I/O之间直接进行数据交换的结构（如图5-21所示）。

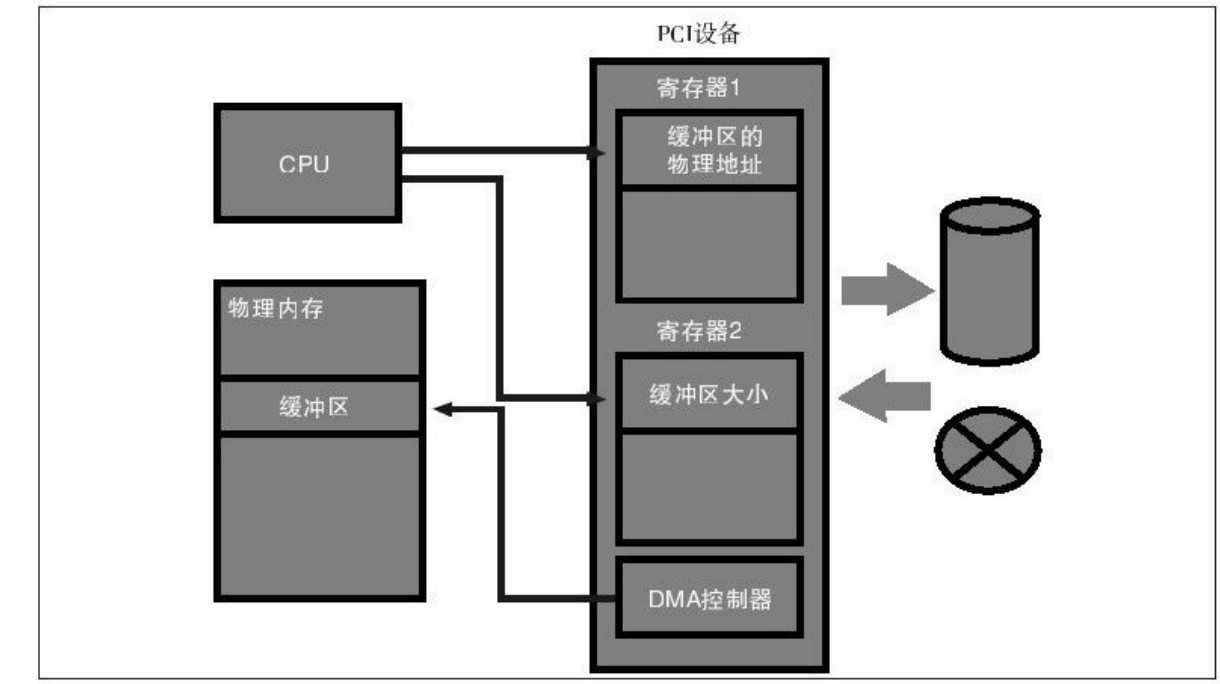

图　5-21　Native操作系统的DMA传输

现在的PCI设备大多数都具有称为总线控制DMA方式的传输结构。DMA传输一般按照如下流程进行。

1.确保DMA传输用的内存。

2.在设备的寄存器中确保第1步设置中的DMA传输用内存的地址。

3.在设备的寄存器中确保第1步设置中的DMA传输用内存的大小。

4.向DMA控制器请求开始在设备和内存之间进行数据传输。

5.DMA传输完成后，设置DMA完成标志，将中断提交给CPU。

第2步中设置的设备的寄存器地址就是物理内存的地址。第4步处理完成后，设备就会对所设置的物理内存进行数据的访问。这时物理内存和设备不在由CPU直接进行数据交换。

IOMMU

IOMMU是指I/O设备的MMU（Memory Management Unit），如图5-22所示。在虚拟化环境下使用IOMMU，就可以直接从客户端操作系统发出I/O命令。

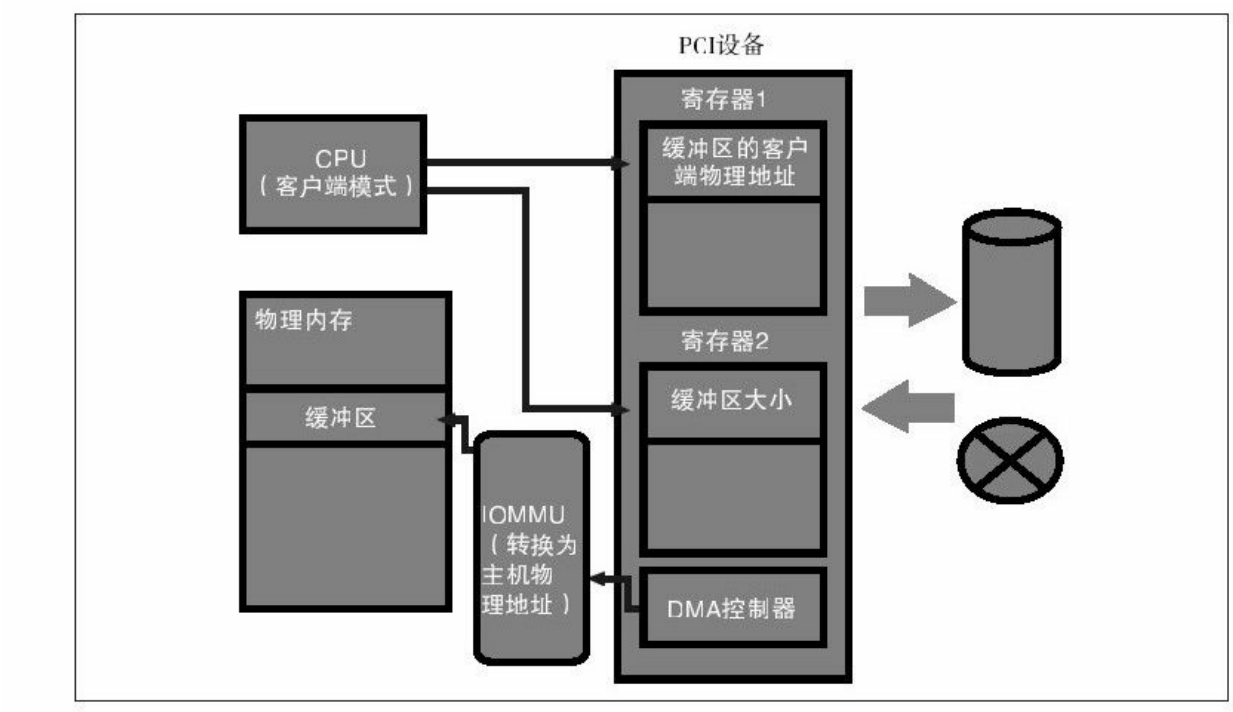

图　5-22　IOMMU的运行

在Xen/KVM等虚拟化环境下，客户端操作系统无法识别主机物理内存地址。客户端操作系统识别通过管理程序虚拟化的客户端物理地址来运行。因此PCI设备的DMA传输就需要将客户端物理内存地址转换为主机物理内存地址的结构。

IOMMU就是用来进行这个转换的硬件结构。客户端操作系统在PCI设备的寄存器中设置客户端物理内存地址，并向设备请求进行DMA传输。而设备则向所设置的物理内存地址写入数据，但将这个客户端物理内存地址转换为主机物理内存地址的任务是由IOMMU来承担的。

从客户端物理内存地址转换为主机物理内存地址时，管理程序必须事先在IOMMU中设置每个PCI设备的页表。在这个页表中，将使PCI设备的客户端操作系统的客户端物理内存地址和主机物理内存地址进行对应。

通过这样的方式使用IOMMU，就可以不经由主机操作系统或管理程序，在客户端操作系统和I/O设备之间进行DMA数据传输，因此将使用IOMMU的方式称为直接I/O方式。另外，使用IOMMU时，所分配的设备只能从该客户端操作系统进行操作。PCI设备的控制直接被传递到客户端操作系统，因此也称为PCI传递（pass through）方式。

KVM的IOMMU的使用方法

下面介绍KVM的IOMMU方法。本节以Intel VT-d的使用方法为中心进行说明。PCI传递通过下列流程来设置（如图5-23所示）。

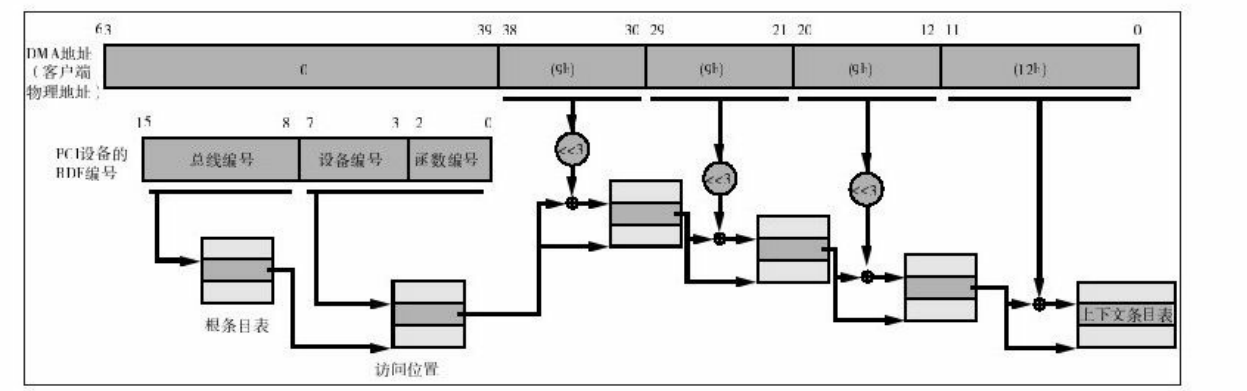

图　5-23　在IOMMU中设置的页表

1.在BIOS中启用VT-d。

2.在内核启动选项中启用VT-d。

3.决定PCI传递的设备。

4.从主机操作系统拆除设备。

5.向客户端操作系统分配设备。

首先，为了检查系统是否可以使用IOMMU，需要检查ACPI的表。在Intel VT-d中，使用dmesg按照下列方式来检查ACPI表中是否存在签名为DMAR的表。如果没有DMAR，请回到BIOS，启用VT-d。

#dmesg|grep DMAR
ACPI：DMAR 00000000bf7cadb4 000E8（v01 Intel OEMDMAR 00060000 LOHR 00000001）★DMAR：Host address width 39
DMAR：DRHD base：0x000000fed14000 flags：0x1
DMAR：RMRR base：0x000000bf7df000 end：0x000000bf7eefff

```
DMAR：ATSR flags：0x0
```

使用VT-d时，需要将intel_iommu内核启动选项设置如下。也像Fedora 13等这样默认为on的发布版。

```
default=0
timeout=5
splashimage=（hd0，0）/grub/splash.xpm.gz
hiddenmenu
title Red Hat Enterprise Linux（2.6.32-71.el6.x86_64）
root（hd0，0）
kernel/vmlinuz-2.6.32-71.el6.x86_64 ro root=UUID=234a4e64-a785-48b7-
a8a9-
fd88428d62fe
rd_NO_LUKS rd_NO_LVM rd_NO_MD rd_NO_DM LANG=ja_JP.UTF-8 KEYBOARDTYPE=pc KEYTABLE=jp106
rhgb quiet intel_iommu=on
initrd/initramfs-2.6.32-71.el6.x86_64.img
```

然后决定将哪个设备PCI传递到哪个客户端操作系统。决定PCI传递的设备后，使用lscpi命令检查PCI的BDP编号（Bus：Device.Function编号）。

```
00：00.0 Host bridge：Intel Corporation 5520 I/O Hub to ESI Port（rev 13）
00：01.0 PCI bridge：Intel Corporation 5520/5500/X58 I/O Hub PCI Express Root Port 1（rev 13）
00：03.0 PCI bridge：Intel Corporation 5520/5500/X58 I/O Hub PCI Express Root Port 3（rev 13）
……snip……
00：1e.0 PCI bridge：Intel Corporation 82801 PCI Bridge（rev 90）
00：1f.0 ISA bridge：Intel Corporation 82801JIB（ICH10）LPC Interface Controller
00：1f.2 IDE interface：Intel Corporation 82801JI（ICH10 Family）4 port SATA IDE Controller#1
00：1f.3 SMBus：Intel Corporation 82801JI（ICH10 Family）SMBus Controller
00：1f.5 IDE interface：Intel Corporation 82801JI（ICH10 Family）2 port SATA IDE Controller#2
01：00.0 RAID bus controller：LSI Logic/Symbios Logic MegaRAID SAS 1078（rev 04）
05：00.0 Fibre Channel：Emulex Corporation Zephyr LightPulse Fibre Channel Host Adapter（rev 02）
06：00.0 SCSI storage controller：LSI Logic/Symbios Logic SAS1068E PCI-Express Fusion-MPT SAS（rev 08）
07：00.0 Fibre Channel：Emulex Corporation Zephyr LightPulse Fibre Channel Host Adapter（rev 02）
08：00.0 Ethernet controller：Intel Corporation 82575EB Gigabit Network Connection（rev 02）
08：00.1 Ethernet controller：Intel Corporation 82575EB Gigabit Network Connection（rev 02）
09：00.0 VGA compatible controller：Matrox Graphics, Inc.MGA G200e[Pilot]ServerEngines（SEP1）（rev 02）
……snip……
```

例如，假设将08：00.0的以太网控制器进行PCI传递。

```
08：00.0 Ethernet controller：Intel Corporation 82575EB Gigabit Network Connection（rev 02）
```

还需要得知这个设备的PCI设备的厂商ID、设备ID。

#lspci-n-s 0000：08：00. 0

08：00. 0 0200：8086：10a7（rev 02）

在找出BDF编号和厂商ID、设备ID后，将这个设备从主机操作系统上拆除。拆除的方法如下所示。不具有FLR（Function-Level Reset）[1]功能的多功能设备在向客户端操作系统分配时，会重启所有的功能设备，因此需要将这些功能设备全部拆除。

```
#echo"8086 10a7"＞/sys/bus/pci/drivers/pci-stub/new_id
#echo 0000：08：00.0＞/sys/bus/pci/devices/0000：08：00.0/driver/unbind
#echo 0000：08：00.0＞/sys/bus/pci/drivers/pci-stub/bind
#echo"8086 10a7"＞/sys/bus/pci/drivers/pci-stub/new_id
#echo 0000：08：00.1＞/sys/bus/pci/devices/0000：08：00.1/driver/unbind
#echo 0000：08：00.1＞/sys/bus/pci/drivers/pci-stub/bind
```

最后指定PCI传递的PCI设备，使用KVM启动客户端操作系统。

```
#qemu-kvm-smp 2-m2048-drive file=/var/lib/libvirt/images/f13-kvm.img, if=virtio, boot=on-pcidevice host=08：00.0
```

从客户端操作系统可以看到传递到00：05.0的PCI设备。

```
#lspci
00：00.0 Host bridge：Intel Corporation 440FX-82441FX PMC[Natoma]（rev 02）
00：01.0 ISA bridge：Intel Corporation 82371SB PIIX3 ISA[Natoma/Triton II]
00：01.1 IDE interface：Intel Corporation 82371SB PIIX3 IDE[Natoma/Triton II]00：01.3 Bridge：Intel Corporation 82371AB/EB/MB PIIX4 ACPI（rev 03）
00：02.0 VGA compatible controller：Cirrus Logic GD 5446
00：03.0 Ethernet controller：Realtek Semiconductor Co.，Ltd.RTL-8139/8139C/8139C+（rev 20）
00：04.0 SCSI storage controller：Qumranet, Inc.Virtio block device
00：05.0 Ethernet controller：Intel Corporation 82575EB Gigabit Network Connection（rev 02）
```

可以使用qemu的控制台时，在打开客户端操作系统的VGA控制台界面后，使用Ctrl+Alt+2快捷键切换到qemu控制台。在qemu控制台上，还可以使用下列命令将PCI设备动态添加到客户端操作系统中。

```
（qemu）pci_add pci_addr=auto host host=08：00.0
```

将PCI设备动态删除需进行如下操作。向pci_addr指定的编号为在客户端操作系统上

看到的PCI设备的Bus编号。

```
（qemu）pci_del pci_addr=5
```

在RHEL6或Fedora13等发布版中，可以使用virt-manager通过PCI传递（pass-through）将设备添加到客户端操作系统或者从客户端操作系统中删除（见图5-24）。

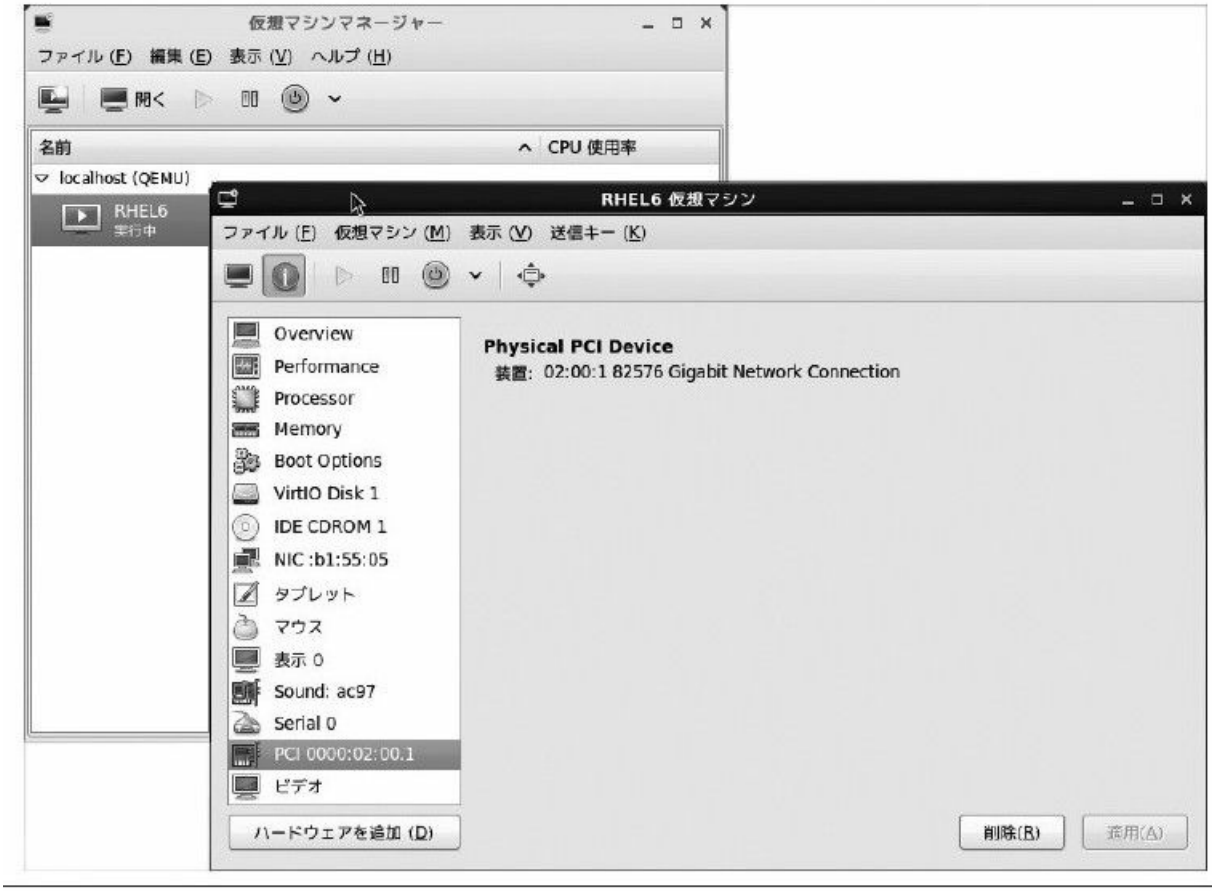

图　5-24　通过RHEL6的PCI传递添加设备

[1]以PCI设备的Function为单位重启的功能。

Xen的IOMMU的使用方法

在Fedora 13中，Xen并未作为正式的工具包发布，因此需要从以下网页下载RPM包。

Dom0内核的RPM
http：//repos.fedorapeople.org/repos/myoung/dom0-kernel/
Xen的其他RPM
http：//ftp.funet.fi/pub/mirrors/fedora.redhat.com/pub/fedora/linux/updates/testing/14/

要启用VT-d，需要在Xen中将选项iommu=1指定为管理程序的启动选项。下面是grub.conf的示例。

```
default=0
timeout=10
splashimage=（hd0，0）/grub/splash.xpm.gz
hiddenmenu
root（hd0，0）
kernel/xen.gz iommu=1 dom0_mem=2G
module/vmlinuz-2.6.32.23-170.xendom0.fc12.x86_64 ro root=UUID=293a5a8e-9dde-40a4-9356-5c8492d70eaa
rd_NO_LUKS rd_NO_LVM rd_NO_MD rd_NO_DM LANG=ja_JP.UTF-8 KEYTABLE=jp106 rhgb
module/initramfs-2.6.32.23-170.xendom0.fc12.x86_64.img
```

将分配给主机操作系统的设备从主机操作系统拆除的方法与KVM相同。这种情况下拆除方法如下。

```
#echo"8086 10a7"＞/sys/bus/pci/drivers/pci-stub/new_id
#echo 0000：08：00.0＞/sys/bus/pci/devices/0000：08：00.0/driver/unbind
#echo 0000：08：00.0＞/sys/bus/pci/drivers/pci-stub/bind
#echo"8086 10a7"＞/sys/bus/pci/drivers/pci-stub/new_id
#echo 0000：08：00.1＞/sys/bus/pci/devices/0000：08：00.1/driver/unbind
#echo 0000：08：00.1＞/sys/bus/pci/drivers/pci-stub/bind
```

在Xen中可以使用下列命令检查可分配的设备。

```
#xm pci-list-assignable-devices
0000：08：00.0
0000：08：00.1
```

在Xen中，客户端操作系统的配置文件可以通过设置下列选项，将PCI设备分配给客

户端操作系统。

```
pci=['08：00.0'，'08：00.1']
```

分配给客户端操作系统的PCI设备默认依次分配到空的虚拟插槽，但如果使用@＜slot号＞选项，就可以指定要分配的插槽。

```
pci=['08：00.0'，'08：00.1@7']
```

在本次使用的PCI这种Multi-Function设备中，有一些必须从操作系统角度看也是Multi-Function设备，才能顺利运行。USB控制器或显卡类设备尤其需要注意。

pci=['08：00.*']

下面是将Multi-Function设备直接作为Multi-Function设备分配给客户端操作系统的设置示例。

```
import os, re
arch_libdir='lib'
arch=os.uname（）[4]
if os.uname（）[0]=='Linux'and re.search（'64'，arch）：
arch_libdir='lib64'
kernel="/usr/lib/xen/boot/hvmloader"
builder='hvm'
memory=2048
name="f13-hvm"
vcpus=4
pae=1
acpi=1
apic=1
vif=['']
disk=['file：/var/lib/xen/images/f13-hvm.img, hda, w'，'file：/root/Fedora-13-
x86_64-DVD.iso, hdc：cdrom, r']
device_model='/usr/'+arch_libdir+'/xen/bin/qemu-dm'
boot="cda"
sdl=0
opengl=1
vnc=1
vnclisten="0.0.0.0"
vncpasswd=''
stdvga=0
serial='pty'
keymap='ja'
xen_platform_pci=1
pci=['08：00.*@6']
```

pci_msitranslate=1
使用上述配置文件，启动客户端操作系统。
#xm create/etc/xen/f13-hvm
#xm pci-list f13-hvm
VSlt VFn domain bus slot func
0x06 0x0 0x0000 0x08 0x00 0x0
0x06 0x1 0x0000 0x08 0x00 0x1

在客户端操作系统上确认PCI设备，可以看到如下结果。

#lspci
00：00.0 Host bridge：Intel Corporation 440FX-82441FX PMC[Natoma]（rev 02）
00：01.0 ISA bridge：Intel Corporation 82371SB PIIX3 ISA[Natoma/Triton II]
00：01.1 IDE interface：Intel Corporation 82371SB PIIX3 IDE[Natoma/Triton II]00：01.3 Bridge：Intel Corporation 82371AB/EB/MB PIIX4 ACPI（rev 01）
00：02.0 VGA compatible controller：Cirrus Logic GD 5446
00：03.0 Class ff80：XenSource, Inc.Xen Platform Device（rev 01）
00：04.0 Ethernet controller：Realtek Semiconductor Co.，Ltd.RTL-8139/8139C/8139C+（rev 20）
00：06.0 Ethernet controller：Intel Corporation 82575EB Gigabit Network Connection（rev 02）
00：06.1 Ethernet controller：Intel Corporation 82575EB Gigabit Network Connection（rev 02）

在笔者手头的客户端操作系统上设置NIC，就可以进行网络通信了。

进行动态删除时，需在Dom0上执行下列命令。

#xm pci-detach f13-hvm"08：00.*"

进行动态添加时，需在Dom0上执行下列命令。

#xm pci-attach f13-hvm"08：00.*"

小结

VT-d的基本功能是DMA Remapping，同时也具有IRQ Remapping等功能。通过使用IOMMU，就可以提高客户端之间的隔离性，同时安全性也得到加强。但是在没有IOMMU的PCI设备中，有一些是用于识别固件物理内存地址的，运行可能会异常。Xen的论坛就收集了SCSI的PCI设备或图形的PCI设备中出现问题的报告。NIC中这种设备较少，DMA Remapping的效果也较好，因此如果想要尝试使用VT-d，推荐首先在NIC中尝试。

另外，VT-d的优点是可以发挥出与物理环境相同的性能，但同时也存在客户端操作系统无法动态迁移（live migration）的缺点。在使用PCI传递时，请充分考虑这些优缺点。

参考文献

·Intel®Virtualization Technology for directed I/O

http://download. intel.com/technology/computing/vptech/intel（r）_VT_for_Direct_IO.pdf

·http：//www. linux-kvm.org/page/Hotadd_pci_devices

·http：//wiki. xensource.com/xenwiki/Fedora13Xen4Tutorial

·http：//wiki. xensource.com/xenwiki/VTdHowTo

——Akio Takebe

HACK#34　使用IOMMU+SR-IOV提高客户端操作系统速度

本节介绍SR-IOV功能以及在虚拟环境下使用SR-IOV的方法。

SR-IOV

以往的PCI设备必须经由管理程序或设备仿真器，才能在多个客户端操作系统上共享一个设备。x86中由于出现了IOMMU，就可以增加客户端操作系统使用PCI设备的机会。为了应对这种虚拟化环境，就出现了SR-IOV（Single Root I/O Virtualization）。SR-IOV是一个PCI Express设备向操作系统提供多个虚拟设备的功能。通过这个功能，就可以在管理程序中得到很多虚拟设备，因此就更容易使客户端操作系统使用PCI设备。

SR-IOV的功能

SR-IOV是PCI Express的功能。在各PCI Express设备中，都安装了这个功能，作为PCI Express扩展功能。SR-IOV是让操作系统将一个设备识别为多个虚拟设备的功能。在SR-IOV中，将以往以物理方式存在的设备称为Physical Function（PF）。在PF中可以进行SR-IOV的设置。通过SR-IOV功能虚拟添加的设备称为Virtual Function（VF）。Intel 82576 Gigabit Ethernet Controller SR-IOV对应的PCI Express卡有Intel 82576千兆以太网控制器等。在Linux中，可以使用lspci命令来显示SR-IOV的信息。下面是Intel 82576的lspci-vvvv的结果。

02：00.0 Ethernet controller：Intel Corporation 82576 Gigabit Network Connection（rev 01）
……snip……
Capabilities：[160]Single Root I/O Virtualization（SR-IOV）
IOVCap：Migration-，Interrupt Message Number：000
IOVCtl：Enable-Migration-Interrupt-MSE-ARIHierarchy+
IOVSta：Migration-
Initial VFs：8，Total VFs：8，Number of VFs：8，Function
Dependency Link：00
……snip……
Capabilities：[160]Single Root I/O Virtualization（SR-IOV）的部分就是SR-IOV的信息。
Initial VFs：VF数的初始值。在SR-IOV中是与Total VFs相同的值。
Total VFs：可以启用的最大VF数。
Number of VFs：当前启用的VF数。

尝试启用Intel 82576的VF

如图5-25所示，要启用Intel 82576的VF，可以在使用modprobe将驱动程序安装到内核时指定max_vfs选项。向max_vfs选项指定希望启用的VF数量。VF从操作系统方面来看是普通的PCI设备，因此可以使用lspci来确认已启用的VF。另外，要使用SR-IOV, BIOS必须也支持该功能。如果BIOS不支持，就会导致VF无法启用或只能对一部分PF启用VF。

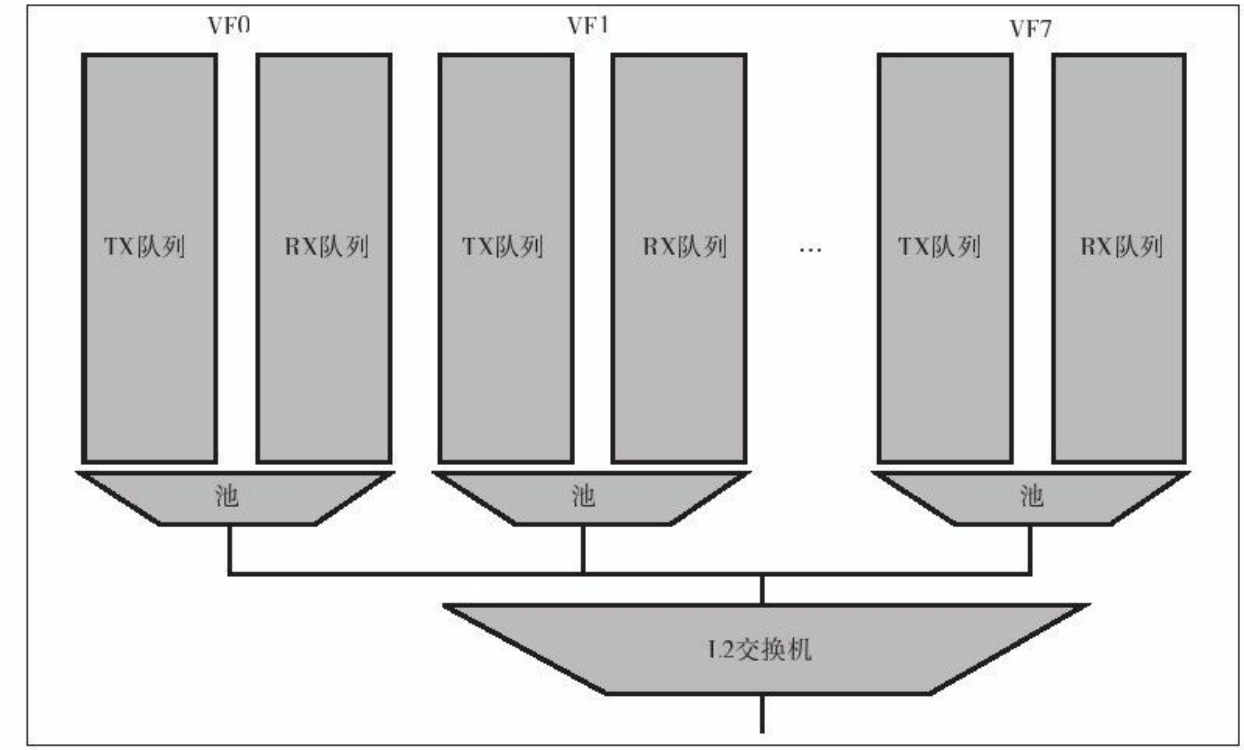

图　5-25　Intel 82576内的L2交换机

```
#lscpi|grep 82576
02：00.0 Ethernet controller：Intel Corporation 82576 Gigabit Network
Connection（rev 01）
#rmmod igb；modprobe igb max_vfs=1
#lscpi|grep 82576
02：00.0 Ethernet controller：Intel Corporation 82576 Gigabit Network Connection（rev 01）
02：10.0 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
```

Intel 82576最大能够提供8个VF。使用了SR-IOV时，把PF的通信带宽分配给各VF。Intel 82576只有在每个PF上有物理端口，因此所有VF共享一个PF端口。PF内部有L2交换机，VF经由L2交换机进行通信。发送（TX）队列和接收（RX）队列统称为池（pool）。把池分配给各VF，在各个池中可以设置MAC过滤器和VLAN过滤器。

在KVM中使用SR-IOV的方法

在RHEL6中，通过virt-manager将VF指定为PCI传递设备，就可以在客户端操作系统使用VF。在这里传递的是02：11.4的VF。

```
#modprobe-r igb；modprobe igb max_vfs=7
#lspci
02：00.0 Ethernet controller：Intel Corporation 82576 Gigabit Network Connection（rev 01）
02：00.1 Ethernet controller：Intel Corporation 82576 Gigabit Network Connection（rev 01）
02：10.0 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
02：10.2 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
02：10.4 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
02：10.6 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
02：11.0 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
02：11.2 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
02：11.4 Ethernet controller：Intel Corporation 82576 Virtual Function（rev 01）
```

如图5-26所示，启动virt-manager，选择“编辑”→“虚拟机详细”。在弹出的窗口上，选择“显示”→“详细”，就会显示虚拟机的硬件详细界面。这里在“添加硬件”中将硬件类型选择为物理主机设备。然后选择02：11.4的VF，单击“完成”按钮（如图5-27所示）。

图　5-26　virt-manager的设置界面

图　5-27　virt-manager的完成界面

启动客户端操作系统后，在客户端操作系统上对igbvf模块执行modprobe命令，安装到内核。

```
#modprobe igbvf
```

这样就可以在客户端操作系统上使用VF了。由于使用了IOMMU，因此使用VF的客户端操作系统基本不借助管理程序或主机操作系统就可以进行网络通信。

小结

这里介绍了VF的使用方法。VF的功能还有一些难以使用的地方。MAC地址就是其中之一。VF的MAC地址在每次启用VF时都会改变。这对于使用DHCP的用户来说是非常麻烦的事。但是，在使用libvirt等工具时会向qemu的mac option分配虚拟MAC，就不会出现每次启动MAC都改变的情况。如果在主机操作系统上直接使用VF，在主机操作系统上进行如下操作就可以将VF的MAC地址更改为任意值。

```
ip link set dev＜ethN＞vf 0 mac＜MAC地址＞
```

小贴士：通常在更改MAC地址时，可以使用如下所示的ip命令。ip link set dev＜ethN＞address＜MAC地址＞

另外，SR-IOV是与IOMMU配合使用的，因此就会产生客户端操作系统无法迁移的限制。单独在迁移时使用vhost-net，就可以解决这个问题。从将来的发展趋势来看，将能够实现使用Multi Root I/O Virtualization（MR-IOV）硬件功能来进行迁移。

——Akio Takebe

HACK#35　SR-IOV带宽控制

本节介绍Intel 82576的带宽控制功能的使用方法。

Intel 82576的带宽控制

Intel 82576是搭载了SR-IOV功能的NIC。Intel 82576可以在利用SR-IOV时使用带宽限制。Linux 2.6.39以后的版本都可以使用这个带宽控制功能。带宽的设置是通过使用iproute2的ip命令来进行的。

Intel 82576的带宽控制的使用方法

ip命令可以对NIC拥有的带宽进行设置，将其分配给各VF。通过下列方法可以向VF分配任意带宽。这里分别为两个VF设置200Mbps、800Mbps的带宽。

1.创建VF。下面创建两个VF。

```
#modprobe igb max_vfs=2
```

2.确认VF已创建。

```
#lspci
……snip……
01：00.0 Ethernet controller：Intel Corporation 82576 Gigabit Network
Connection（rev 01）eth0
01：00.1 Ethernet controller：Intel Corporation 82576 Gigabit Network
Connection（rev 01）eth1
01：10.0 Ethernet controller：Intel Corporation 82576 Virtual Function（rev
01）eth0的VF0
01：10.2 Ethernet controller：Intel Corporation 82576 Virtual Function（rev
01）eth0的VF1
……snip……
```

3.在主机OS上使用ip命令设置VF的带宽。将想要设置带宽的VF编号指定为ip参数中vf选项的变量。向rate选项指定带宽。这里为VF0设置的带宽是200Mbps，为VF1设置的带宽是800Mbps。

```
#ip link set eth0 vf 0 rate 200
#ip link set eth0 vf 1 rate 800
#ip link show
1：lo：＜LOOPBACK, UP, LOWER_UP＞mtu 16436 qdisc noqueue state UNKNOWN
link/loopback 00：00：00：00：00：00 brd 00：00：00：00：00：00
2：eth0：＜BROADCAST, MULTICAST, UP, LOWER_UP＞mtu 1500 qdisc mq state UP qlen 1000
link/ether 00：24：21：f1：e1：ec brd ff：ff：ff：ff：ff：ff
vf 0 MAC de：c4：b4：78：00：1b, tx rate 200（Mbps）☆
vf 1 MAC 8a：46：ef：e6：a8：e5，tx rate 800（Mbps）☆
3：eth1：＜BROADCAST, MULTICAST＞mtu 1500 qdisc noop state DOWN qlen 1000
link/ether 00：24：21：f1：e1：ed brd ff：ff：ff：ff：ff：ff
6：virbr0：＜BROADCAST, MULTICAST, UP, LOWER_UP＞mtu 1500 qdisc noqueue state UP
link/ether 52：54：00：93：33：79 brd ff：ff：ff：ff：ff：ff
7：virbr0-nic：＜BROADCAST, MULTICAST＞mtu 1500 qdisc noop master virbr0 state DOWN qlen 500
link/ether 52：54：00：93：33：79 brd ff：ff：ff：ff：ff：ff
```

9：vnet0：＜BROADCAST, MULTICAST, UP, LOWER_UP＞mtu 1500 qdisc pfifo_fast master virbr0 state UNKNOWN qlen 500

link/ether fe：54：00：74：e4：98 brd ff：ff：ff：ff：ff：ff

10：vnet1：＜BROADCAST, MULTICAST, UP, LOWER_UP＞mtu 1500 qdisc pfifo_fast master virbr0 state UNKNOWN qlen 500

link/ether fe：54：00：a7：05：b9 brd ff：ff：ff：ff：ff：ff

尝试测量带宽

然后实际测量一下确认带宽是否已得到了控制。这里创建了两个客户端OS，分别向客户端OS分配刚才创建的VF。测量带宽时使用的是netperf。

测量环境

主机	
OS	RHEL6.1 64bit
内核	2.6.39-rc7(intel_iommu=on)
iproute2	iproute2-ss091226
客户端 1	
OS	RHEL6.1 64bit
内存	1G
VF	eth0 VF06
客户端 2	
OS	RHEL6.1 64bit
内存	1G
VF	eth0 VF1
netperf 服务器机器	192.168.0.200

测量结果如下所示。可以看出基本上达到了指定的性能。

例5-1　客户端1与netperf服务器之间的通信

```
#netperf-t UDP_STREAM-l 50-H 192.168.0.200
UDP UNIDIRECTIONAL SEND TEST from 0.0.0.0（0.0.0.0）port 0 AF_INET to
```

```
192.168.0.200 (192.168.0.200) port 0 AF_INET
Socket  Message  Elapsed      Messages
Size    Size     Time         Okay Errors   Throughput
bytes   bytes    secs            #      #   10^6bits/sec

124928   65507   50.00       18591      0     194.85     约200Mbps
262144           50.00       18591            194.85
```

例5-2　客户端2与netperf服务器机器之间的通信

```
# netperf -t UDP_STREAM -l 50 -H 192.168.0.200
UDP UNIDIRECTIONAL SEND TEST from 0.0.0.0 (0.0.0.0) port 0 AF_INET to
192.168.0.200 (192.168.0.200) port 0 AF_INET
Socket  Message  Elapsed      Messages
Size    Size     Time         Okay Errors   Throughput
bytes   bytes    secs            #      #   10^6bits/sec

124928   65507   50.00       73154      0     766.73     约800Mbps
262144           50.00       73154            766.73
```

小结

本节介绍了使用Intel 82576的硬件结构控制带宽的方法。控制网络带宽的方法有不少，如果使用SR-IOV也可以选择设备所集成的功能进行尝试。

参考文献

Intel®82576EB Gigabit Ethernet Controller Datasheet

http://download. intel.com/design/network/datashts/82576_Datasheet.pdf

——Akio Takebe

HACK#36　使用KSM节约内存

本节介绍共享相同内容的内存以节约内存的KSM。

KSM（Kernel Samepage Merging），是通过共享相同内容的存储页面，将其整合为一体，从而有效使用内存的功能。原始版本是在KVM上开发的Kernel Shared Memory，从Linux 2.6.32开始合并到上游内核。在虚拟环境下启动多个相同OS映像的客户端OS时，就会出现相同内容的存储页面。在这样的情况下KSM就非常有效。

使用方法

编译内核时，需要设置为CONFIG_KSM=y。

KSM会通过内核线程ksmd定期对用户内存进行扫描。如果为同一内容，则在COW＆nbsp；（Copy On Write）模式下合并该区域（存储页面）。这个存储区更新时，内核自动重新生成存储页面的副本。

要扫描的区域是通过madvise的MADV_MERGEABLE指定的内存，并且匿名页面成为合并对象。

sysfs

KSM可以使用/sys/kernel/mm/ksm/下的特殊文件来进行设置（见表5-4）。

表5-4 KSM的设置

项　目	说　明
pages_to_scan	单次扫描的页数。体现在KSM通过MADV_MERGEABLE指定的页面扫描和确认是否可以合并时的扫描这二者当中
sleep_millisecs	ksmd在下一次扫描前休眠的时间（毫秒）
run	设置为0~2的值。0为停止ksmd。到目前为止合并的页仍保持原状。1为启动ksmd。2为停止ksmd。到目前为止合并的页全部生成副本，取消页面共享
pages_shared	共享后的页面数。例如，如果1000页均为同一内容，可以合并到1页，则pages_shared的值为1
pages_sharing	可共享的页面数。如果1000页可以合并为1页，则pages_sharing的值为1000
pages_unshared	当前未合并的页数。通过MADV_MERGEABLE指定的页且没有同一内容的页，即，不能合并的页数
pages_volatile	输入到KSM所管理的树中的页数。KSM将MADV_MERGEABLE指定的页输入专用的管理树中。这个页数是扫描对象的页数，还未确认是否可以合并。经过扫描，确认是否合并后，这个值就会减小
full_scans	从头至尾扫描合并区域的次数

可以认为，pages_sharing与pages_shared的比值越高，KSM的效果越明显。相反，如果这个比值较低，则表示即使进行扫描也无法进行页面合并。接下来，在例子程序（mergeable.c）中确认运行情况。

```
#cat mergeable.c
#include＜stdio.h＞
#include＜string.h＞
#include＜unistd.h＞
#include＜sys/mman.h＞//for madvise
#include＜sys/types.h＞
#include＜sys/stat.h＞
#include＜fcntl.h＞
#include＜stdlib.h＞
#include＜time.h＞
int main（int argc, char*argv[]）
{
int fd=0；
char*file=NULL；
char filename[64]=""；
struct stat stat；
if（argc＜2）{
printf（"Usage：%s[file]\n"，argv[0]）；
return 1；
}
```

```
strcpy（filename, argv[1]）；
if（（fd=open（filename, O_RDWR|O_CREAT，0664））＜0）{
printf（"Could not open file\"%s\"with O_RDWR"，filename）；
return 1；
}
if（fstat（fd，＆stat）＜0）{
printf（"Could not stat file\"%s\""，filename）；
goto close；
}
if（（file=（char*）mmap（NULL, stat.st_size, PROT_WRITE, MAP_PRIVATE，
fd，0））
==MAP_FAILED）{
printf（"Could not mmap file\"%s\""，filename）；
goto close；
}
if（madvise（（void*）file, stat.st_size, MADV_MERGEABLE）！=0）{
printf（"Could not madvise file\"%s\""，filename）；
goto unmap；
}
memset（file，'1'，stat.st_size）；
memset（file，'2'，stat.st_size/2）；
memset（file，'3'，stat.st_size/4）；
memset（file，'4'，stat.st_size/8）；
/*write random pages*/
{
long long i, j；
int dpage_size=4096*20；/*20 pages size*/
srand（（unsigned int）time（（time_t*）0））；
for（i=0；i＜dpage_size；i++）
{
j=rand（）；
file[i]=j；
}
}
printf（"sleeping forever……\n"）；
while（1）
sleep（100）；
madvise（（void*）file, stat.st_size, MADV_UNMERGEABLE）；
unmap：
munmap（file, stat.st_size）；
close：
close（fd）；
return 1；
}
```

在上例中向mmap指定了PROT_WRITE和MAP_PRIVATE。

在mmap的区域中写入20页的随机值（见图5-28）。这20页应该是不能合并的。

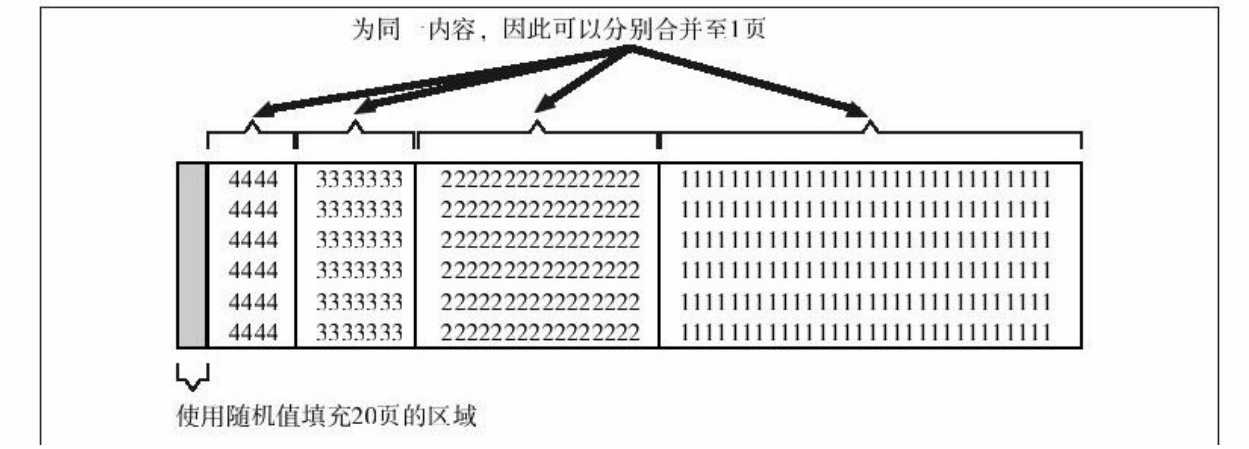

图　5-28　mergeable.c的mmap区域映像

首先，使用dd命令生成100MB的文件。

```
#dd if=/dev/zero of=ksm.dat bs=1M count=100
```

对mergeable.c进行编译。

#gcc mergeable. c-o mergeable

指定dd命令生成的文件，执行进程。

```
#./mergeable ksm.dat
#head/sys/kernel/mm/ksm/*
==>/sys/kernel/mm/ksm/full_scans<==247
==>/sys/kernel/mm/ksm/pages_shared<==
0
==>/sys/kernel/mm/ksm/pages_sharing<==
0
==>/sys/kernel/mm/ksm/pages_to_scan<==
```

```
2046
==> /sys/kernel/mm/ksm/pages_unshared <==
0
==> /sys/kernel/mm/ksm/pages_volatile <==
18414        设置了 madvise 的 MADV_MERGEABLE 后，首先这个值增加
==> /sys/kernel/mm/ksm/run <==
1            ksmd 正在运行
==> /sys/kernel/mm/ksm/sleep_millisecs <==
188
```

经过一段时间后，再次执行下列命令。

```
# head /sys/kernel/mm/ksm/*
==> /sys/kernel/mm/ksm/full_scans <==
252          全部扫描的次数
==> /sys/kernel/mm/ksm/pages_shared <==
4            pages_sharing 的页数最终合并到 4 页
==> /sys/kernel/mm/ksm/pages_sharing <==
25576        合并的页数
==> /sys/kernel/mm/ksm/pages_to_scan <==
2046
==> /sys/kernel/mm/ksm/pages_unshared <==
20           写入随机值的页面
==> /sys/kernel/mm/ksm/pages_volatile <==
0            如果检查是否可以通过 KSM 合并，则这个值减小
==> /sys/kernel/mm/ksm/run <==
1
==> /sys/kernel/mm/ksm/sleep_millisecs <==
188
```

在RHEL6中，由ksmtuned（Kernel Samepage Merging（KSM）Tuning Daemon）定期地将pages_to_scan等改变为适当的值。

小结

本节介绍了KSM。可以先确认内存的合并比例，作为检测内存容量的大致标准。由于KSM原本就是为虚拟环境而设计的，因此在有多个客户端操作系统的系统中，尤其能够发挥较大效果。但是，KSM在扫描内存时会产生一些不算大的负载，因此在用不到KSM的系统中也可以禁用ksmd、ksmtuned。

参考文献

·Increasing memory density by using KSM

http://www. kernel.org/doc/ols/2009/ols2009-pages-19-28.pdf

·KSM tries again

http://lwn. net/Articles/330589/

——Naohiro Ooiwa

HACK#37　如何挂载客户端操作系统的磁盘

本节介绍挂载客户端操作系统磁盘的方法。

如果使用KVM或Xen等，有时就需要将客户端操作系统的磁盘挂载到主机操作系统上。例如，想在客户端操作系统启动前更改IP地址或主机名称，想把某个文件放到客户端操作系统的磁盘中等。

对于笔者来说，由于会对客户端操作系统的磁盘进行备份，但是很容易忘记是哪个磁盘，因此就需要确认磁盘的内容。

但是客户端操作系统的磁盘有时实际上是主机操作系统上的文件，大部分情况下难以使用一般的mount命令将客户端操作系统挂载到主机操作系统上。

这里就将介绍使用一些工具将客户端操作系统挂载到主机操作系统上的方法。

guestfish

guestfish是可以读写客户端操作系统的文件系统的工具。RHEL6也包含这个工具，可以通过yum install guestfish来安装。

使用virt-manager生成客户端操作系统时，将在/var/lib/libvirt/images/下生成客户端操作系统的磁盘映像。

尝试使用guestfish来挂载这个客户端操作系统的磁盘。

```
# guestfish ... ①

Welcome to guestfish, the libguestfs filesystem interactive shell for
editing virtual machine filesystems.

Type: 'help' for help with commands
      'quit' to quit the shell

><fs> add /var/lib/libvirt/images/test.img ... ②
><fs> launch ... ③
><fs> list-devices  ... ④
/dev/vda
><fs> sfdisk-l /dev/vda ... ⑤

Disk /dev/vda: 16644 cylinders, 16 heads, 63 sectors/track
Units = cylinders of 516096 bytes, blocks of 1024 bytes, counting from 0

   Device Boot Start     End   #cyls    #blocks   Id  System
/dev/vda1   *      2+   1017-   1016-    512000   83  Linux
/dev/vda2       1017+  16644-  15627-   7875584   8e  Linux LVM
/dev/vda3          0       -       0          0    0  Empty
/dev/vda4          0       -       0          0    0  Empty

><fs> lvs ... ⑥
/dev/VolGroup/lv_root
```

```
/dev/VolGroup/lv_swap
><fs> mount /dev/VolGroup/lv_root / ... ⑦
><fs> mounts ... ⑧
/dev/mapper/VolGroup-lv_root
><fs> ls / ... ⑨
bin
boot
cgroup
dev
etc
home
lib
lib64
lost+found
media
mnt
opt
proc
root
sbin
selinux
srv
sys
tmp
usr
var
><fs>
><fs> touch /root/hoge.txt ... ⑩
><fs> edit /root/hoge.txt ... ⑪
aaaa
bbbb
cccc

><fs> cat /root/hoge.txt  ... ⑫
aaaa
bbbb
cccc

><fs> upload /root/foo /root/foo2 ... ⑬
><fs> cat /root/foo2
foofoo

><fs> download /root/hoge.txt /tmp/hoge2 ... ⑭
><fs> umount /dev/VolGroup/lv_root  ... ⑮
><fs> mounts
><fs> quit ... ⑯
```

首先①启动guestfish。guestfish的shell就会启动，因此②使用add命令将客户端操作系

统的磁盘映像添加到guestfish。③启动qemu的子进程。在主机操作系统上执行ps命令就可以看到，guestfish在后台启动qemu的子进程，并让在这个qemu上运行的用于作业的客户端操作系统来处理磁盘映像。

```
3145 pts/1 S+0：00|\_guestfish
3368 pts/1 Sl+0：04|\_/usr/libexec/qemu-kvm-drive file=/
var/lib/libvirt/images/test.img, cache=off, if=virtio
-enable-kvm-nodefaults-nographic-serial stdio-m 500-no-reboot-net user, vlan=0，net=169.254.0.0/16-net nic,
model=virtio, vlan=0
-kernel/tmp/libguestfsp5ipPA/kernel-initrd/tmp/libguestfsp5ipPA/initrd-append panic=1 console=ttyS0 udevtimeout=300
noapic
acpi=off printk.time=1 cgroup_disable=memory selinux=0 guestfs_vmchannel=tcp：169.254.2.2：33653 TERM=xterm
3369 pts/1 S+0：00|\_guestfish
```

④使用list-devices命令找出要挂载到的设备。⑤然后使用sfdisk-l命令获取分区表信息。这里使用的是LVM，⑥因此使用lvs命令获取逻辑卷。⑦然后使用mount命令将/dev/VolGroup/lv_root挂载到/下。⑧使用mounts命令确认是否已完成挂载。到这一步，挂载操作就完成了。⑨使用ls命令可以看到磁盘的内容。⑩使用touch命令在挂载的磁盘映像内生成文件。[11]使用edit命令后，vi启动，就可以编辑文件。[12]还可以使用cat命令来参照文件的内容。[13]如果使用upload命令，就可以将主机操作系统上的文件复制到客户端操作系统的磁盘映像内。写法为upload＜主机操作系统上的文件名＞＜客户端操作系统上的文件名＞。[14]使用download命令，就可以将客户端操作系统上的文件复制到主机操作系统上。[15]最后使用umount命令卸载。[16]再使用quit命令结束guestfish。

除了这个guestfish以外，libguest-tools工具包中还有能够更简单地将guestfish作为命令使用的命令（见表5-5）。

表 5-5　其他命令

项　目	说　明
virt-cat	显示磁盘映像中的文件
virt-df	显示磁盘映像的磁盘使用量
virt-edit	编辑磁盘映像中的文件
virt-inspector	显示磁盘映像中的操作系统版本、内核、驱动程序、挂载点等
virt-list-filesystems	显示磁盘映像中的文件系统列表
virt-list-partitions	显示磁盘映像中的分区表列表
virt-ls	显示磁盘映像中的目录里的文件列表
virt-rescue	启动救援 rescue shell
virt-resize	扩大磁盘映像的大小
virt-tar	从磁盘映像中将文件以 tar 格式复制，或将 tar 格式文件解压缩并复制到磁盘映像中
virt-win-reg	显示、编辑磁盘映像中的 Windows 注册表项

例5-3　virt-ls

```
#virt-ls/var/lib/libvirt/images/test.img/root
.bash_history
.bash_logout
.bash_profile
.bashrc
.cshrc
.tcshrc
anaconda-ks.cfg
foo
foo2
hoge.txt
install.log
install.log.syslog
```

例5-4　virt-cat

```
#virt-cat/var/lib/libvirt/images/test.img/root/hoge.txt
aaaa
bbbb
cccc
```

lomount

在RHEL5等环境下，Xen的RPM包中含有lomount命令。lomount命令可以像普通的mount命令一样使用。与guestfish相比，由于不需要像guestfish那样启动操作用的客户端操作系统，因此速度较快，使用方便。

lomount的使用方法如下。

lomount-t＜文件系统的种类＞-diskimage＜挂载对象的磁盘映像名称＞

-partition＜分区表编号＞＜挂载位置＞

下面所示为使用lomount命令的示例。

```
#lomount-diskimage./x8664_domU_centos54.img……①
Please specify a partition number.Table is：
Num Start-End OS Bootable
1：32256-106928128：83 80
2：106928640-10733989888：83 0
#lomount-diskimage./x8664_domU_centos54.img-partition 2/mnt……②
#ls/mnt
bin boot dev etc home lib lib64 lost+found media misc mnt net opt proc root sbin selinux srv sys tmp usr var
#umount/mnt……③
```

①使用lomount命令获取挂接磁盘映像的分区表信息。②使用lomount命令挂接磁盘映像的2号分区表。到这一步挂接就完成了。文件编辑等操作结束后，③使用mount命令卸载。

kpartx

lomount命令虽然非常方便，但是如果在挂载对象的磁盘映像中使用LVM，就无法使用该命令。要挂载LVM的磁盘映像，就需要使用kpartx命令。kpartx用于设备映射的分区表管理工具。

首先，不使用LVM的磁盘映像的挂接方式如下。

```
#kpartx-av./x8664_domU_centos54.img……①
add map loop3p1：0 208782 linear/dev/loop3 63
add map loop3p2：0 20755980 linear/dev/loop3 208845
#mount/dev/mapper/loop3p2/mnt……②
#ls/mnt/
bin boot dev etc home lib lib64 lost+found media misc mnt net opt
proc root sbin selinux srv sys tmp usr var
#umount/mnt/……③
#kpartx-dv./x8664_domU_centos54.img……④
del devmap：loop3p1
del devmap：loop3p2
loop deleted：/dev/loop3
```

①使用kpartx命令的a选项将磁盘映像映射到设备。②磁盘映像内的2号分区表可以作为/dev/mapper/loop3p2使用，因此可以使用mount命令挂载。③卸载时使用umount命令来进行。最后④使用kpartx的d选项删除设备映射。

下列介绍的是挂接使用LVM的磁盘映像的情况。

```
# kpartx -av /var/lib/libvirt/images/test.img  ...⑤
add map loop0p1 (253:0): 0 1024000 linear /dev/loop0 2048
add map loop0p2 (253:1): 0 15751168 linear /dev/loop0 1026048
# vgscan  ...⑥
  Reading all physical volumes.  This may take a while...
  Found volume group "VolGroup" using metadata type lvm2
# vgchange -ay VolGroup  ...⑦
  2 logical volume(s) in volume group "VolGroup" now active
# lvs  ...⑧
  LV      VG       Attr   LSize Origin Snap%  Move Log Copy%  Convert
  lv_root VolGroup -wi--- 5.54g
  lv_swap VolGroup -wi--- 1.97g
# mount /dev/VolGroup/lv_root /mnt  ...⑨
# ls /mnt
bin  boot  cgroup  dev  etc  home  lib  lib64  lost+found  media  mnt  opt
proc  root  sbin  selinux  srv  sys  tmp  usr  var
# umount /mnt/  ...⑩
# vgchange -an VolGroup  ...⑪
  0 logical volume(s) in volume group "VolGroup" now active
# kpartx -dv /var/lib/libvirt/images/test.img  ...⑫
del devmap : loop0p2
del devmap : loop0p1
loop deleted : /dev/loop0
```

首先与前例相同，⑤使用kpartx的a选项将磁盘映像映射到设备。⑥使用vgscan命令检索LVM的卷组（volume group）。⑦使用vgchange命令启用卷组。⑧使用lvs命令确认逻辑卷，⑨使用mount命令将要挂接的逻辑卷挂接。这里指定的是在/dev下生成的逻辑卷的设备文件。⑩使用umount命令卸载后，[11]使用vgchange命令禁用卷[12]组，使用kpartx命令的d选项删除设备映射。

执行vgscan后，LVM的卷组名有时会检测出相同的名称。卷组在系统中必须是唯一的，因此如果存在相同的卷组名，需要使用vgrename命令更改卷组名。下面是使用vgrename命令更改卷组名的例子。通过vgdisplay检查VG UUID，使用vgrename来更改卷组名。操作结束后，再次使用vgrename命令将卷组名改回。

#vgdisplay
---Volume group---
VG Name VolGroup
System ID
Format lvm2
Metadata Areas 1
Metadata Sequence No 3
VG Access read/write
VG Status resizable
MAX LV 0

Cur LV 2
Open LV 0
Max PV 0
Cur PV 1
Act PV 1
VG Size 2.50 GiB
PE Size 32.00 MiB
Total PE 80
Alloc PE/Size 80/2.50 GiB
Free PE/Size 0/0
VG UUID GvnrGk-xA3M-9M20-qIlX-zA94-IoQv-4JYKDM
---Volume group---
VG Name VolGroup
System ID
Format lvm2
Metadata Areas 1
Metadata Sequence No 3
VG Access read/write
VG Status resizable
MAX LV 0
Cur LV 2
Open LV 1
Max PV 0
Cur PV 1
Act PV 1
VG Size 2.50 GiB
PE Size 32.00 MiB
Total PE 80
Alloc PE/Size 80/2.50 GiB
Free PE/Size 0/0
VG UUID Z48bLY-U9wv-Xrwy-0ZV3-23b7-Zv8N-SUNswN
#vgrename GvnrGk-xA3M-9M20-qIlX-zA94-IoQv-4JYKDM VolGroup_1
Volume group"VolGroup"successfully renamed to"VolGroup_1"
#vgscan
Reading all physical volumes.This may take a while……
Found volume group"VolGroup_1"using metadata type lvm2
Found volume group"VolGroup"using metadata type lvm2
#vgs
VG#PV#LV#SN Attr VSize VFree
VolGroup 1 2 0 wz--n-2.50g 0
VolGroup_1 1 2 0 wz--n-2.50g 0
#vgchange-ay VolGroup_1
2 logical volume（s）in volume group"VolGroup_1"now active

小结

在客户端操作系统无法与主机操作系统进行通信或客户端操作系统无法启动等情况下，有时会想要直接修改客户端操作系统的磁盘映像的内容。这时就可以用到本节介绍的内容。

参考文献

·http：//libguestfs. org/guestfish.1.html

——Akio Takebe

HACK#38　从客户端操作系统识别虚拟机环境

本节介绍识别客户端操作系统在哪个管理程序上运行的方法。

在使用虚拟环境的过程中，有时会需要确认已启动的操作系统在虚拟环境下是如何运行的。有时也会想要识别是在哪个管理程序上运行的。但是，客户端通过操作系统设备仿真实现仿真，基本上没有什么可以判别的信息。本节将介绍用来判别的关键信息和工具。

CPUID命令

CPUID命令是根据输入到EAX寄存器的值，返回CPU识别信息或CPU功能信息的命令。例如，CPU的型号或主频就可以使用CPUID命令来得知。也有一些管理程序使用在Intel和AMD CPU中不使用的值（0x40000000等）来获取管理程序信息。

在客户端操作系统上发布如下CPUID命令，可以得到表5-6所示的返回值。

```
#include＜stdio.h＞
#include＜stdint.h＞
static void cpuid（uint32_t idx，
uint32_t*a，
uint32_t*b，
uint32_t*c，
uint32_t*d）
{
asm volatile（"movl%1，%%eax；cpuid"："=a"（*a），"=b"（*b），"=c"（*c），"=d"（*d）：1"（idx））；
}
static int check_with_cpuid（void）
{
uint32_t eax, ebx, ecx, edx；
char signature[13]；
uint32_t base；
for（base=0x40000000；base＜0x4000000f；base+=0x1）
{
eax=0；
ebx=0；
ecx=0；
edx=0；
cpuid（base，＆eax，＆ebx，＆ecx，＆edx）；
*（uint32_t*）（signature+0）=ebx；
*（uint32_t*）（signature+4）=ecx；
*（uint32_t*）（signature+8）=edx；
signature[12]='\0'；
```

```
if（ebx！=0||ecx！=0||edx！=0）
printf（"%x：signature=%12s eax=%x ebx=%x ecx=%x edx=%x\n"，
base, signature, eax, ebx, ecx, edx）；
}
return 0；
}
int main（void）
{
return check_with_cpuid（）；
}
```

表 5-6 CPUID（0x40000000）的返回值的示例

管理程序	返回值
KVM	KVMKVMKVM
Xen	XenVMMXenVMM
Hyper-V	Microsoft Hv

在RHEL5 Xen中还有xen-detect命令同样使用CPUID命令识别Xen的客户端操作系统。但需要注意的是，有一些版本（如旧的VMware等管理程序的版本）不支持对这个CPUID识别方法，因此不能使用这一功能。

固有文件

在KVM的情况下，将Linux作为KVM的主机操作系统使用时，存在名为/dev/kvm的特殊文件。在Xen的情况下，则会生成名为/proc/xen/capabilities的特殊文件。在Dom0上/proc/xen/capabilities内写有“control_d”，而在半虚拟化客户端操作系统上/proc/xen/capabilities什么也没有。

ACPI DSDT/FADT的OEM ID

有些情况可以使用ACPI DSDT或FADT的OEM_ID/OEM_TABLEID中的下列信息。这是因为各管理程序中准备了客户端操作系统用的BIOS, FADT的OEM_ID/OEM_TABLEID中多数情况下也写有与管理程序相应的值。

例如，在RHEL5 Xen的情况下，可以使用下列shell脚本识别。

```
#！/bin/bash
FADT=/proc/acpi/fadt
CAPABILITY=/proc/xen/capabilities
DD=/bin/dd
TR=/usr/bin/tr
if[-r$FADT]；then
OEMID=$（$DD if=$FADT bs=1 skip=10 count=6 2＞/dev/null|$TR-d"）
OEM_TABLEID=$（$DD if=$FADT bs=1 skip=16 count=8 2＞/dev/null|$TR-d"）
case$OEMID/$OEM_TABLEID in
Xen/HVM|INTEL/int-xen）
echo hvm
exit 0；
esac
fi
if[-r$CAPABILITY]；then
["$（＜$CAPABILITY）"=control_d]＆＆echo dom0＆＆exit 0
echo pv；exit 0
fi
echo native
```

System Management BIOS（SMBIOS）

从SMBIOS可以获取BIOS提供的系统属性。例如，BIOS的版本、CPU、内存等信息。有时通过SMBIOS的System Information（Manufacturer/Product Name）可以识别管理程序。相应在操作系统上确认SMBIOS的内容时，可以使用dmidecode命令。

例5-5　KVM的示例

```
Handle 0x0100，DMI type 1，27 bytes
System Information
Manufacturer：Red Hat
Product Name：KVM
Version：RHEL 6.0.0 PC
Serial Number：Not Specified
UUID：983F2E4E-BAA8-E5D7-A97C-B574A72484B8
Wake-up Type：Power Switch
SKU Number：Not Specified
Family：Red Hat Enterprise Linux
```

例5-6　Xen的示例

```
Handle 0x0100，DMI type 1，27 bytes
System Information
Manufacturer：Xen
Product Name：HVM domU
Version：3.1.2-164.28.1.el5
Serial Number：46fdb192-71ba-c2a1-fb69-4810f0e00c53
UUID：46FDB192-71BA-C2A1-FB69-4810F0E00C53
Wake-up Type：Power Switch
SKU Number：Not Specified
Family：Not Specified
```

例5-7　Hyper-V的示例

```
Handle 0x0001，DMI type 1，25 bytes.
System Information
Manufacturer：Microsoft Corporation
Product Name：Virtual Machine
Version：5.0
Serial Number：3061-9271-3107-7137-6198-0205-37
UUID：18570B26-2DF1-514F-ADF0-C6B8720F9636
Wake-up Type：Power Switch
```

例5-8　VMware环境下的示例

```
Handle 0x0001，DMI type 1，27 bytes
System Information
Manufacturer：VMware, Inc.
Product Name：VMware Virtual Platform
Version：None
Serial Number：VMware-42 2a 4f e9 90 e7 9b 39-c5 60 90 3d 57 6d 3d ad
UUID：422A4FE9-90E7-9B39-C560-903D576D3DAD
Wake-up Type：Power Switch
SKU Number：Not Specified
Family：Not Specified
```

virt-what

virt-what是将前面所述的程序整合起来的工具。

http://people. redhat.com/～rjones/virt-what/

在客户端操作系统上进行如下操作，就可以识别各种管理程序。下面是KVM对应的示例。

```
#wget http：//people.redhat.com/～rjones/virt-what/fles/virt-what-1.9.tar.gz
#tar xzf virt-what-1.9.tar.gz
#cd virt-what-1.9
#./confgure
#make；make install
#virt-what
kvm
```

表5-7为virt-what能够识别的客户端操作系统环境。可以看出能够识别的管理程序种类非常多。

表 5-7　virt-what 能够识别的客户端操作系统的运行环境

virt-what 的输出	客户端操作系统的运行环境
hyperv	Microsoft Hyper-V 环境

（续）

virt-what 的输出	客户端操作系统的运行环境
ibm_systemz	IBM SystemZ（或 S/390）的硬件划分系统环境 以下为附加信息： ibm_systemz-direct Linux 直接运行的环境 ibm_systemz-lpar LPAR 上 Linux 直接运行的环境 ibm_systemz-zvm LPAR 中 z/VM 客户端的环境
linux_vserver	Linux VServer 容器环境
kvm	KVM 环境
openvz	OpenVZ 或 Virtuozzo 环境
parallels	Parallels Virtual Platform（Parallels Desktop、Parallels Server）环境
powervm_lx86	IBM PowerVM Lx86 环境
qemu	qemu 环境
uml	User-Mode Linux（UML）环境
virtage	Virtage 环境
virtualbox	VirtualBox 环境
virtualpc	Microsoft VirtualPC 环境
vmware	VMware 环境
xen	Xen 环境 以下为追加信息： xen-dom0 Xen 的 Dom0 环境 xen-domU Xen 的半虚拟化客户端环境 xen-hvm 全虚拟化客户端环境

小结

当存在只想安装到客户端操作系统的内核的驱动程序时，或根据管理程序的种类想要更换驱动程序时等，这个Hack就能起到很大的作用。

参考文献

·CPUID usage for interaction between Hypervisors and Linux.

http://lwn. net/Articles/301888/

·System Management BIOS Reference Specification

·virt-what

http://people. redhat.com/～rjones/virt-what/

·[Xen-devel][RFC]Is this process running on which machine?

http://lists. xensource.com/archives/html/xen-devel/2006-11/msg01349.html

——Akio Takebe

HACK#39　如何调试客户端操作系统

本节介绍客户端操作系统的调试方法。

客户端操作系统的调试关系到很多组件，因此经常会困惑应该从哪里下手？例如，当客户端操作系统的驱动程序出现异常时，很多情况下都难以分辨是设备驱动程序有问题？还是设备仿真器有问题？还是主机操作系统的驱动程序有问题？当客户端操作系统意外停机（hang up）时，有时也不知道应当从哪里检查。

这里就介绍可以用于客户端操作系统调试的一些技巧。

Xen的情况

首先，进行调试时需要确认日志（见表5-8）和客户端操作系统的状态。确认客户端操作系统的状态时可以使用xm list或virsh list命令。

```
# xm list
Name                                        ID Mem(MiB) VCPUs State   Time(s)
Domain-0                                     0     2048     1 r-----   1507.8
testPV                                       5      511     1 -b----    208.6
testvm54b                                   12     1031     1 -b----     48.3
# virsh list
 Id 名称                 状态
----------------------------------
  0 Domain-0             运行中
  5 testPV               idle
 12 testvm54b            idle
```

表5-8　Xen的日志文件

表 5-8　Xen 的日志文件

日志文件	说　明
/var/log/xen/xend.log	xend 输出的日志
/var/log/xen/xend-debug.log	xend 输出的日志
/var/log/xen/xen-hotplug.log	Xen 的 hotplug 事件的日志
/var/log/xen/domain-builder-ng.log	客户端操作系统启动中 Xen 的库输出的日志
/var/log/xen/qemu-dm-<客户端操作系统名或进程 ID>.log	各个客户端操作系统的 qemu-dm 输出的日志
/var/log/xen/console/hypervisor.log	Xen 的管理程序输出的日志

（续）

日志文件	说　明
/var/log/xen/console/guest-<客户端操作系统名>.log	半虚拟化客户端操作系统输出的日志
/var/log/messages	主机操作系统的日志

使用xenctx命令，就可以简单方便地确认客户端操作系统是否意外停机。xenctx命令是显示指定客户端操作系统的虚拟CPU上下文信息的命令。从主机操作系统观察rip寄存器的值或栈的内容是否发生变化，就可以确认客户端操作系统是否意外停机。xenctx[选项]＜domid＞＜虚拟CPU编号＞

例5-9　半虚拟化客户端操作系统的情况

```
#/usr/lib64/xen/bin/xenctx 5 0
rip：ffffffff802063aa
rsp：ffffffff8063bf58
rax：00000000 rbx：00000000 rcx：ffffffff802063aa rdx：00000001
rsi：00000000 rdi：00000001 rbp：00000000
r8：00000081 r9：1001d5381 r10：ffff88001fd3a3e0 r11：00000246
r12：00000000 r13：00000000 r14：00000000 r15：00000000
cs：0000e033 ds：00000000 fs：00000000 gs：00000000
Stack：
0000000231002060 0000000000000000 ffffffff8026f4d5 0000000000000000
0000000000000000 0000000007020800 ffffffff8026ca50 0000000000000000
ffffffff8024afa1 0000000007020800 ffffffff80644b05 0000000000000000
0000000000000000 ffffffff80683d20 ffffffff806441e5 ffff800000000000
Code：
cc cc cc cc cc cc cc cc cc cc cc 51 41 53 b8 1d 00 00 00 0f 05＜41＞5b 59 c3
cc cc cc cc cc cc cc
Call Trace：
[＜ffffffff802063aa＞]＜--
[＜ffffffff8026f4d5＞]
[＜ffffffff8026ca50＞]
[＜ffffffff8024afa1＞]
[＜ffffffff80644b05＞]
```

```
[<ffffffff80683d20>]
[<ffffffff806441e5>]
```

例5-10　全虚拟化客户端操作系统的情况

```
#/usr/lib64/xen/bin/xenctx 12 0
rip：ffffffff8006b319
rsp：ffffffff803f3f90
rax：00000000 rbx：ffffffff8006b2f0 rcx：00000000 rdx：00000000
rsi：00000001 rdi：ffffffff80303698 rbp：00090000
r8：ffffffff803f2000 r9：0000003f r10：ffff81003ffa0008 r11：00000286
r12：00000000 r13：00000000 r14：00000000 r15：00000000
cs：00000010 ds：00000000 fs：00000000 gs：00000000
Stack：
ffffffff8004959b 0000000007000800 ffffffff803fd7fd 0000000000090000
0000000000000000 ffffffff80448740 ffffffff803fd22f 80008e000010019c
00000000ffffffff 0000000000000000 0000000000000000 0000000000200000
0000000000000000 0000000000000000
Code：
page entry not present in PT
page entry not present in PT
……snip……
page entry not present in PT
page entry not present in PT
53 ff 00 f0 53 ff 00 f0 53 ff 00 f0 53 ff 00 f0 53 ff 00 f0 53<ff>00 f0 53
ff 00 f0 53 ff 00 f0
Call Trace：
[<ffffffff8006b319>]<--
[<ffffffff8004959b>]
[<ffffffff803fd7fd>]
[<ffffffff80448740>]
[<ffffffff803fd22f>]
```

不停止客户端操作系统，提取客户端操作系统的内存转储时，使用xm dump-core命令（见表5-9）。

```
xm dump-core[-L|--live][-C|--crash]<Domain>[Filename]
```

表 5-9　xm dump-core 命令的选项

选　项	功　能
-L|- -live	不停止客户端操作系统，提取转储
-C|- -crash	提取转储后停止客户端操作系统
Domain	客户端操作系统名
Filename	指定转储的输出位置

```
#xm dump-core rhel5hvm/tmp/hoge
Dumping core of domain：rhel5hvm……
```

不指定文件名时，将在/var/lib/xen/dump下生成转储文件。也有一些发布版是

在/var/xen/dump下生成转储文件。

转储文件通过使用crash命令来参照。然后，就可以与普通的crash命令一样进行调试。

#crash/usr/lib/debug/lib/modules/2.6.18-164.el5xen/vmlinux/tmp/hoge
crash 4.0-8.9.1.el5

```
This GDB was configured as "x86_64-unknown-linux-gnu"...

      KERNEL: /usr/lib/debug/lib/modules/2.6.18-164.el5xen/vmlinux
    DUMPFILE: /tmp/hoge
        CPUS: 1
        DATE: Fri May 20 01:10:48 2011
      UPTIME: 00:00:10
LOAD AVERAGE: 0.00, 0.00, 0.00
       TASKS: 24
    NODENAME: (none)
     RELEASE: 2.6.18-164.el5xen
     VERSION: #1 SMP Mon Sep 27 12:59:01 EDT 2010
     MACHINE: x86_64  (1861 MHz)
      MEMORY: 1 GB
       PANIC: ""
         PID: 0
     COMMAND: "swapper"
        TASK: ffffffff804eeb00  [THREAD_INFO: ffffffff8063c000]
         CPU: 0
       STATE: TASK_RUNNING (ACTIVE)
     WARNING: panic task not found

crash> ps
   PID    PPID  CPU       TASK        ST  %MEM     VSZ    RSS  COMM
> >     0      0   0  ffffffff804eeb00  RU   0.0       0      0  [swapper]
      1      0   0  ffff880000f2d7a0  IN   0.1    2684    700  init
      2      1   0  ffff880000f2d040  IN   0.0       0      0  [migration/0]
      3      1   0  ffff88000003f7e0  IN   0.0       0      0  [ksoftirqd/0]
      4      1   0  ffff88000003f080  IN   0.0       0      0  [watchdog/0]
      5      1   0  ffff88003ff28820  IN   0.0       0      0  [events/0]
      6      1   0  ffff88003ff280c0  IN   0.0       0      0  [khelper]
      7      1   0  ffff88003fff4860  IN   0.0       0      0  [kthread]
      9      7   0  ffff88003f80e7a0  IN   0.0       0      0  [xenwatch]
     10      7   0  ffff88003f80e040  IN   0.0       0      0  [xenbus]
     14      7   0  ffff88003f8120c0  IN   0.0       0      0  [kblockd/0]
     15      7   0  ffff88003f85f860  IN   0.0       0      0  [cqueue/0]
     19      7   0  ffff88003f8677e0  IN   0.0       0      0  [khubd]
     21      7   0  ffff88003f868820  IN   0.0       0      0  [kseriod]
     80      7   0  ffff88003faa70c0  IN   0.0       0      0  [pdflush]
     81      7   0  ffff88003faab860  IN   0.0       0      0  [pdflush]
     82      7   0  ffff88003faab100  IN   0.0       0      0  [kswapd0]
     83      7   0  ffff88003fad27a0  IN   0.0       0      0  [aio/0]
    213      7   0  ffff88003f10d0c0  IN   0.0       0      0  [kpsmoused]
    214      1   0  ffff88003f10d820  IN   0.0    2684    396  nash-hotplug
    240      7   0  ffff88003f118860  IN   0.0       0      0  [ata/0]
    241      7   0  ffff88003f118100  IN   0.0       0      0  [ata_aux]
    248      7   0  ffff88003f10e860  IN   0.0       0      0  [fc_sc_wq]
    255      7   0  ffff88003f0eb860  IN   0.0       0      0  [kstriped]
crash> q
```

KVM的情况

KVM的日志中有如下内容。

```
/var/log/libvirt/qemu/＜客户端操作系统名＞.log：libvirt的日志
/var/log/messages：主机操作系统的日志
```

在KVM中也和Xen一样可以使用virsh list命令确认客户端操作系统的状态。

```
#virsh list
Id名称状态
13rhel6-4运行中
14rhel6-1运行中
```

在KVM中调试客户端操作系统时使用gdb就会非常简单。KVM中是经由qemu将gdb连接到客户端操作系统。在qemu启动选项中加上-s，就可以调试客户端操作系统。

在使用libvirt的情况下，有时也可以通过virsh edit来改写客户端操作系统的配置文件，以使用-s选项。但需要[1]意，一部分旧的libvirt是不支持这个XML的。另外，在系统中只能使用一个gdb来进行客户端操作系统调试。

```
#virsh edit＜domain名＞
```

修改如下注7：

```
-＜domain type='kvm'＞
+＜domain type='kvm'xmlns：qemu='http：//libvirt.org/schemas/domain/qemu/1.0'＞
+＜qemu：commandline＞
+
＜qemu：arg value='-s'/＞
+＜/qemu：commandline＞
```

#LC_ALL=C PATH=/sbin：/usr/sbin：/bin：/usr/bin QEMU_AUDIO_DRV=none/u s r/l i b e x e c/q e m u-k v m-M r h e l 6. 0.0-e n a b l e-k v m-m 1 0 2 4-s m p 2，sockets=2，cores=1，threads=1-name test-uuid 031cda76-6500-7f53-6250-f44bec96a5a8-nodefconfig-

nodefaults-chardev socket, id=monitor, path=/var/lib/libvirt/qemu/test.monitor, server, nowait-mon chardev=monitor, mode=control-rtc base=utc-boot c-drive file=/var/lib/libvirt/images/test.img, if=none, id=drive-virtio-disk0，boot=on, format=raw, cache=none-device virtio-blk-pci, bus=pci.0，addr=0x5，drive=drive-virtio-disk0，id=virtio-disk0-drive if=none, media=cdrom, id=drive-ide0-1-0，readonly=on, format=raw-device ide-drive, bus=ide.1，unit=0，drive=drive-ide0-1-0，id=ide0-1-0-chardev pty, id=serial0-device isa-serial, chardev=serial0-usb-device usb-tablet, id=input0-vnc 127.0.0.1：3-vga cirrus-device AC97，id=sound0，bus=pci.0，addr=0x4-device virtio-balloon-pci, id=balloon0，bus=pci.0，addr=0x6-s

从其他终端启动gdb。使用target remote命令连接到127.0.0.1的1234号端口。连接后客户端操作系统就会进入停止状态。使用gdb的info register命令等可以确认寄存器的内容或内存状态等。

```
#gdb--quiet/usr/lib/debug/lib/modules/2.6.32-71.el6.x86_64/vmlinux
Reading symbols from/usr/lib/debug/lib/modules/2.6.32-71.el6.x86_64/
vmlinux……done.
（gdb）target remote 127.0.0.1：1234
Remote debugging using 127.0.0.1：1234
native_safe_halt（）at/usr/src/debug/kernel-2.6.32-71.el6/linux-2.6.32-71.
```

```
el6.x86_64/arch/x86/include/asm/irqflags.h:50
50      }
(gdb) info registers
rax            0x0      0
rbx            0xffffffff8170dfd8       -2123309096
rcx            0x0      0
rdx            0x0      0
rsi            0x1      1
rdi            0xffffffff81a101e8       -2120154648
rbp            0xffffffff8170dec8       0xffffffff8170dec8
rsp            0xffffffff8170dec8       0xffffffff8170dec8
r8             0x0      0
r9             0x0      0
r10            0x0      0
r11            0x0      0
r12            0xffffffff818a1b60       -2121655456
r13            0x0      0
r14            0xffffffffffffffff       -1
r15            0x93780  604032
rip               0xffffffff8103be8b         0xffffffff8103be8b <native_safe_
halt+11>
eflags         0x246    [ PF ZF IF ]
cs             0x10     16
ss             0x18     24
ds             0x18     24
es             0x18     24
fs             0x0      0
gs             0x0      0
(gdb) x/2s log_buf
0xffffffff81a59b60:        "<6>Initializing cgroup subsys cpuset\
n<6>Initializing cgroup subsys cpu\n<5>Linux version 2.6.32-71.el6.x86_64
(mockbuild@x86-007.build.bos.redhat.com) (gcc version 4.4.4 20100726 (Red Hat
4.4.4-13) (GC"...
0xffffffff81a59c28:      "C) ) #1 SMP Wed Sep 1 01:33:01 EDT 2010\n<6>Command
line: ro root=/dev/mapper/VolGroup-lv_root rd_LVM_LV=VolGroup/lv_root rd_LVM_
LV=VolGroup/lv_swap rd_NO_LUKS rd_NO_MD rd_NO_DM LANG=ja_JP.UTF-8 KEYBOA"...
(gdb) detach
Ending remote debugging.
(gdb) q
```

使用这个gdb功能，还可以使操作系统像应用程序一样单步运行。另外，还可以设置断点（break point），在任意地方停止客户端操作系统运行等，这是非常强大的调试功能。

```
# gdb --quiet /usr/lib/debug/lib/modules/2.6.32-71.el6.x86_64/vmlinux
Reading symbols from /usr/lib/debug/lib/modules/2.6.32-71.el6.x86_64/
vmlinux...done.
(gdb) target remote 127.0.0.1:1234
Remote debugging using 127.0.0.1:1234
0xffffffff8103cc88 in pvclock_clocksource_read (src=0xffff880001e16900) at
arch/x86/kernel/pvclock.c:124
124     {
(gdb) info registers
rax            0x16900  92416
rbx            0x3dcc7011       1036808209
rcx            0x0      0
rdx            0x0      0
```

```
rsi            0x2      2
rdi            0xffff880001e16900       -131941363783424
rbp            0xffff880001e03ee8       0xffff880001e03ee8
rsp            0xffff880001e03ed8       0xffff880001e03ed8
r8             0x0      0
r9             0x1      1
r10            0x0      0
r11            0xfffcb9 16776377
r12            0x61     97
r13            0x883a   34874
r14            0xffffffff81736440       -2123144128
r15            0x93780  604032
rip                0xffffffff8103cc88         0xffffffff8103cc88 <pvclock_
clocksource_read+8>
eflags         0x86     [ PF SF ]
cs             0x10     16
ss             0x18     24
ds             0x18     24
es             0x18     24
fs             0x0      0
gs             0x0      0
(gdb) info b
No breakpoints or watchpoints.
(gdb) x/8i $rip
=> 0xffffffff8103cc88 <pvclock_clocksource_read+8>:     push   %r13
   0xffffffff8103cc8a <pvclock_clocksource_read+10>:    push   %r12
   0xffffffff8103cc8c <pvclock_clocksource_read+12>:    push   %rbx
   0xffffffff8103cc8d <pvclock_clocksource_read+13>:    mov    %rdi,%rbx
   0xffffffff8103cc90 <pvclock_clocksource_read+16>:    sub    $0x18,%rsp
   0xffffffff8103cc94 <pvclock_clocksource_read+20>:    mov    (%rdi),%r12d
   0xffffffff8103cc97 <pvclock_clocksource_read+23>:
jmp    0xffffffff8103cca3 <pvclock_clocksource_read+35>
   0xffffffff8103cc99 <pvclock_clocksource_read+25>:    nopl   0x0(%rax)
(gdb) stepi
0xffffffff8103cc8a      124     {
(gdb) b *0xffffffff8103cc94
Breakpoint 1 at 0xffffffff8103cc94: file arch/x86/kernel/pvclock.c, line 124.
(gdb) info b
Num     Type           Disp Enb Address            What
1       breakpoint     keep y   0xffffffff8103cc94 in pvclock_clocksource_read
at arch/x86/kernel/pvclock.c:124
(gdb) cont
Continuing.

Breakpoint 1, pvclock_clocksource_read (src=0xffff880001e16900) at arch/x86/
kernel/pvclock.c:124
124     {
(gdb) info registers
rax            0x16900  92416
rbx            0xffff880001e16900       -131941363783424
rcx            0x0      0
rdx            0x0      0
rsi            0x2      2
rdi            0xffff880001e16900       -131941363783424
rbp            0xffff880001e03ee8       0xffff880001e03ee8
rsp            0xffff880001e03ea8       0xffff880001e03ea8
r8             0x0      0
r9             0x1      1
```

```
r10            0x0      0
r11            0xfffcb9 16776377
r12            0x61     97
r13            0x883a   34874
r14            0xffffffff81736440       -2123144128
r15            0x93780  604032
rip                0xffffffff8103cc94         0xffffffff8103cc94 <pvclock_
clocksource_read+20>
eflags         0x92     [ AF SF ]
cs             0x10     16
ss             0x18     24
ds             0x18     24
es             0x18     24
fs             0x0      0
gs             0x0      0
(gdb)
```

在KVM上调试BIOS等情况必须在8086模式下，因此一定不能忘记使用下列命令更改模式。

```
（gdb）set arch i8086
```

也可以与Xen一样提取客户端操作系统的内存转储。在KVM的情况下使用virsh dump。由于virsh dump是最近才添加的功能，因此也有一些发布版尚不能使用。

```
#virsh dump rhel6-1/tmp/test-dump
```

域rhel6-1转储到/tmp/test-dump。

转储文件的内容可以使用crash命令来查看。

```
#crash/usr/lib/debug/lib/modules/2.6.32-71.el6.x86_64/vmlinux/tmp/test-dump
```

注意事项：crash-4.0-8.12中添加了能够分析使用virsh dump提取的内存转储文件的功能。然后进行了各种修改和改善。旧版的crash命令有时不能查看使用virsh dump提取的转储文件，建议尽量使用最新的crash命令。

[1]7：‘-’表示删除，‘+’表示添加。

小结

本章介绍了调试客户端操作系统的技巧。除了调试以外，在学习BIOS或内核的运行等时也可以使用。

参考文献

·QEMU Emulator User Documentation

http://qemu. weilnetz.de/qemu-doc.html

·What monitor commands does libvirt support?What QEMU/KVM command line flags does libvirt support?

http://wiki. libvirt.org/page/QEMUSwitchToLibvirt

——Akio Takebe

第6章　省电

近年来，为了应对全球气候变暖、电力不足以及降低成本等，省电技术受到人们的广泛关注。从电脑方面来说，不打开电源最为省电，但这显然是不现实的。电脑省电的技巧和方法非常多，但是人们总是不知不觉中就浪费了电能。例如，关掉充满动画广告的Web网页就可以省电，减少使用进行无用的文件检索的软件也可以省电。在最近的电脑中都配备了各种各样的省电功能，但是也经常遇到不知道该怎么使用这些功能的情况。为了丰富大家的省电知识，本章将介绍Linux中的省电技术。

HACK#40　ACPI

本节介绍在ACPI（Advanced Configuration and Power Interface）系统的功能。

ACPI是进行各设备及整个系统的电源管理接口。ACPI不仅能向操作系统提供各设备的资源和CPU的结构信息等，还具有操作系统直接对设备电源进行操作的接口。从省电的角度来看，ACPI的作用非常大，在当前PC的省电中起核心作用。了解安装方法，就可以找到更加正确的省电方法或Hack。但是，除了操作系统以外，ACPI还需要硬件和BIOS等固件的支持，用户会觉得它的结构很复杂。因此在介绍ACPI相关的省电Hack前，先介绍一下ACPI的概要。

ACPI的用语

首先介绍一些不常见的ACPI用语。ACPI中定义了G、D、S、C、P这5个大的电力状态。图6-1介绍了各电力状态的定义。

G状态与S状态

G状态（Global System State）表示的是用户看到的整个系统的电力状态。G状态的电力状态定义见表6-1。

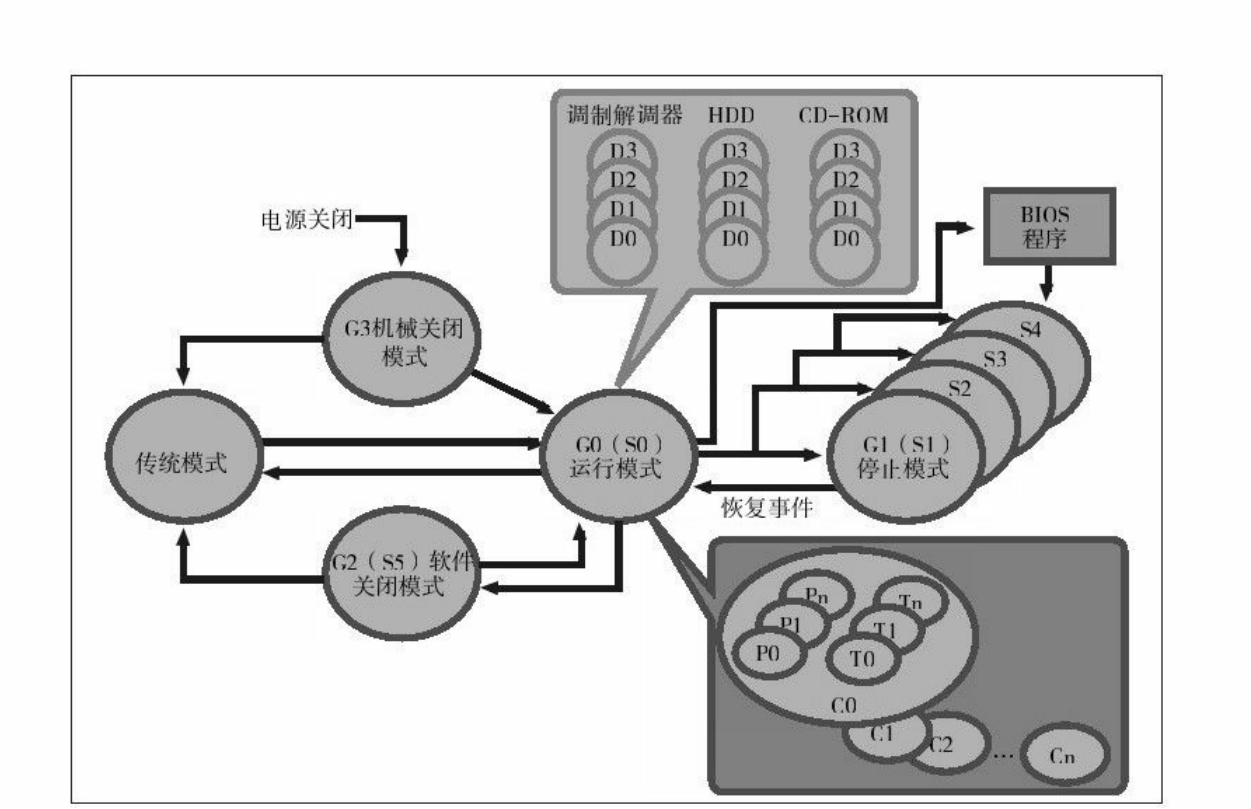

图　6-1　ACPI的各状态之间的转换图

表 6-1　G 状态的说明

状　态	说　明
G0	运行模式，向硬件提供电源，软件可以运行的状态
G1	停止模式，所谓的待机或休眠状态
G2	软件为关闭状态，硬件消耗若干电力的状态
G3	系统完全关闭，电源关闭的状态

而S状态（Sleeping state）表示G状态的停止模式的种类。S1～S4表示G1的详细状态，描述的是停止的“深度”。各S状态的意义如表6-2所示。

表 6-2　S 状态的说明

状　态	说　明
S0	运行模式。与 G0 含义相同
S1	到恢复为止的延迟时间较少的停止模式。CPU 的上下文等都不会丢失
S2	丢失 CPU 和系统缓存上下文。这些上下文需要在操作系统唤醒时进行恢复。在 Linux 中与 S3 相同
S3	丢失除软件以外的系统上下文。这些上下文需要在操作系统唤醒时进行恢复

（续）

状　态	说　明
S4	最省电，到恢复为止花费时间最多的停止模式。停止向所有设备提供电源。启动时 BIOS 会通知是从 S4 恢复的
S5	除了不保存上下文以外，其他与 S4 相同。S5 在恢复时进行的处理与普通的操作系统相同。与 G2 含义相同

停止模式根据停止的方法一般有多种叫法，参见表6-3。

表 6-3　停止模式的种类

S 状态	名　称
S0	运行中
S1	睡眠（stand by）
S2	待机 suspend（CPU 的待机）
S3	待机 suspend（CPU 的待机）
S4	休眠（磁盘的待机）
S5	软件关闭

D状态

D状态（Device Power State）定义的是各个设备的电力状态。设备的状态有如下内容。

·耗电量

·保存设备内寄存器上下文的状态

·直到设备驱动程序可使用为止必须进行的操作量

·直到设备可使用为止所需时间

D状态的定义如表6-4所示，但几乎没有设备可以支持所有状态。一般设备主要只使用D0和D3状态。将设备的电源状态设置为D3再设置为D0，就可以将设备重启后再进行设备的初始化。

表 6-4　设备的电力状态

状　态	说　明
D0	设备可以完全运行的状态。所有上下文全部有效，最耗电
D1	D1 对于每个设备类型的意义不同。一般来说，耗电量比 D0 少，丢失的上下文比 D2 更少
D2	D2 对于每个设备类型的意义也不同。一般来说，耗电量比 D1 更少，丢失的上下文比 D1 更多

（续）

状　态	说　明
D3hot	D3hot 对于每个设备类型的意义也不同。D3hot 状态的设备主电源开启，可以从软件访问设备。但上下文是否能保留取决于实际安装的设备
D3	设备电源完全断开的状态。设备的上下文全部丢失，到恢复为止花费的时间最长。在 PCI 用语中称为 D3cold。在 PCI 用语中将 D3hot 和 D3cold 统称为 D3

C状态

C状态（Processor Power State）是G0中CPU空闲时进行的省电模式。各C状态的意义如表6-5所示。

表 6-5　C 状态的说明

状　态	说　明
C0	运行中状态。通常的运行模式
C1	CPU 停止状态。使用 hlt 命令停止 CPU 的时钟。到恢复为止几乎没有延迟时间，软件不需进行特殊操作
C2	总线的时钟也停止。恢复所花费的最长延迟时间传递给 ACPI 的固件，操作系统基于这个延迟时间判断使用 C1 还是 C2
C3	将花费时间最长的延迟传递给 ACPI 的固件，操作系统使用这个延迟时间判断使用 C2 还是 C3。操作系统需要考虑缓存的同步

ACPI说明书中没有记载的C状态也已经在各CPU厂商的CPU数据表中出现。例如，Intel公司的CPU中的定义就如表6-6所示。

表 6-6　Intel 公司 CPU 的 C 状态的定义

状　态	定　义
C1	Autohalt State
C1E	Enhanced Autohalt State
C3	Deep Sleep State
C3E	Enhanced Deep Sleep State
C4	Deeper Sleep State
C4E	Enhanced Deeper Sleep State
C5	Enhanced Deeper Sleep State
C6	Deep Power Down State
CC	核心层 C 状态

处理器的耗电量指标中有TDP（Thermal Design Power），通过尽量延长CPU空闲时间，即使运行中的TDP较高的CPU中也可以降低单位时间的平均耗电。

在Intel®Core 2 Duo等CPU中将每个核的C状态定义为CC状态，而在Intel®Atom Processor Z5xx系列等CPU中是将每个线程的C状态（TC）和每个核的C状态分别安装的。例如，当核内所有线程的C状态都变成C2时，核的C状态也会变成C2。参见表6-7。

表 6-7　Core 2 Duo 的 TDP（根据 Core 2 Duo 处理器数据表）

状　态	TDP
C0	35 瓦
C1	13.5 瓦
C2	12.9 瓦
C3	7.7 瓦
C4	1.2 瓦

使用C状态时要注意，C状态的程度越深，恢复到C0状态所需的时间越长。在对应答性要求非常高的系统中，需要避免使用C状态，或在使用时十分注意。

P状态

P状态（Device and Processor Performance State）的目的是以控制电量消耗来代替降低设备或CPU的性能，对D0状态的设备、C0状态的CPU进行了更细致的状态划分。参见表6-8。

表 6-8　P 状态的说明

状　态	说　明
P0	通常的模式。以最高性能、最大耗电量运行
P1	运行在低于最高性能、最大耗电量的模式
Pn	n 的值越大，性能和耗电量越低。可以定义各设备或 CPU 中性能和耗电量的状态

每种CPU所支持的P状态级别不同。例如，Intel的CPU中采用的是Enhanced Intel SpeedStep Technology技术，可以灵活地进行P状态控制。例如，Core 2 Duo的Enhanced Intel SpeedStep可以对每个核进行设置，使用CPU的MSR（model specific register）进行控制。

使用P状态时，必须要在省电和性能之间取得平衡。例如，在必须确保单位时间性能的系统中，需要避免使用P状态，或在使用时充分注意。

此外还有为了温度控制而控制CPU时钟的T状态throttling。在ACPI T状态下使用throttling（切换C0状态和C1状态）就可以控制CPU温度和耗电。

ACPI的结构

构成ACPI的主要组件定义如下。

·ACPI系统描述表

·ACPI寄存器

·ACPI BIOS

从操作系统来看，ACPI系统描述表在ACPI的接口中是核心组件，提供ACPI寄存器等信息。另外ACPI BIOS可以提供ACPI系统描述表以及启动、停止、唤醒等功能。

下面将介绍这些组件，以及获取ACPI信息的方法。

两个编程模型

ACPI的硬件模型有下面两种：

·固定硬件编程模型

·通用硬件编程模型

固定硬件编程模型使用ACPI中定义的寄存器来访问ACPI的功能。使用这个编程模型仅限于操作系统几乎不能运行，或者从性能来看操作系统不应运行。例如，C2/C3电源控制或电源管理计时器等重视性能的功能。硬件的事件通过System Control Interrupt（SCI）种类的中断获知，启动操作系统的驱动程序。通用硬件编程模型是让各厂商能够灵活安装硬件的模型。各厂商可以使用ACPI Machine Language（AML）将硬件固有的处理安装到BIOS中。操作系统可以通过分析BIOS提供的AML代码，来理解寄存器的地址和访问方法等。AML是二进制码，通过编译ACPI Source Language（ASL）来生成。操作系统分析AML，将AML中所写的内容按照解释器（interpreter）来执行。硬件的事件与固定硬件编程模型同样是通过SCI获知，而通用硬件编程模型则执行AML中的控制方法。通用硬件编程模型用于设备电源管理和设备热插拔等。

ACPI寄存器

ACPI寄存器中有固定硬件寄存器和通用硬件寄存器。固定硬件寄存器是固定硬件编程模型中所使用的寄存器，是ACPI中定义的接口。通用硬件寄存器是在安装通用硬件编程模型中使用的硬件时所需的寄存器。ACPI中还定义了寄存器块和寄存器组。寄存器块将多个寄存器集中到一个地址区域，例如，PM1a_STS寄存器和PM1a_EN寄存器组成地址为PM1a_EVT_BLK、大小为PM1_EVT_LEN的寄存器块，前半部分为PM1a_STS寄存器，后半部分为PM1a_EN寄存器。寄存器组是在想要将一个寄存器块放到不同地址时使用的。例如，名为PM1 EVT Grouping的寄存器组就是由PM1a_EVT_BLK和PM1b_EVT_BLK构成的。寄存器组的值通过取各寄存器块的逻辑和来决定。

ACPI可以通过读写ACPI寄存器来控制硬件或是获取硬件所支持功能的信息。例如，转变为S状态时使用固定硬件寄存器PM1 Control寄存器。

ACPI系统描述表

ACPI中定义了描述控制系统信息、功能、系统的ACPI方法的表。所有表都具有ACPI中规定的头文件。表的头文件中有签名，签名是从内存中检索表时识别表的关键。参见表6-9。

表 6-9 ACPI 描述的头文件

字 段	字节长度	字节偏移量	说 明
Signature	4	0	识别表的 ASCII 字符串
Length	4	4	包括头文件在内的整个表的长度（字节）
Revision	1	8	与该表相关的结构的修订
Checksum	1	9	该表整体的校验和
OEMID	6	10	用来识别 OEM 的字符串
OEM Table ID	8	16	OEM 为了识别特殊数据包而使用的字符串
OEM Revision	4	24	OEM 的修订
Creator ID	4	28	创建表的实用工具的厂商 ID
Creator Revsion	4	32	创建表的实用工具的修订

这些表的位置是从系统内存中Root System Description Pointer（RSDP）结构的表开始的。RSDP通过从BIOS内存中查找“RSD PTR”字符串来定位。“RSD PTR”是RSDP的签名。RSDP指向的是RSDT或XSDT。RSDT或XSDT是管理各表位置的表，具有各表的位置信息。

XSDT指向的表一定从FADT（Fixed ACPI Description Table）开始。FADT中有Firmware ACPI Control Structure（FACS）、Differentiated System Description Table（DSDT）、寄存器块。

寄存器块表示固定硬件寄存器的位置。FACS是BIOS为使用ACPI而预留的内存空间，其中有记录从S状态唤醒时要执行的代码的物理地址的Firmware Waking Vector等。

DSDT表示定义块的表。定义块是称为ACPI命名空间的AML中记载的树状数据结构，包括系统硬件安装的详细信息、通用硬件编程模型中使用的寄存器或方法等。

访问定义块的数据对象称为“评价”，是指通过AML解释器解码定义块的AML。AML解释器的动态数据对象具有可以通过I/O或访问系统内存进行程序评价的功能。

ACPI中定义的表有如图6-2所示。

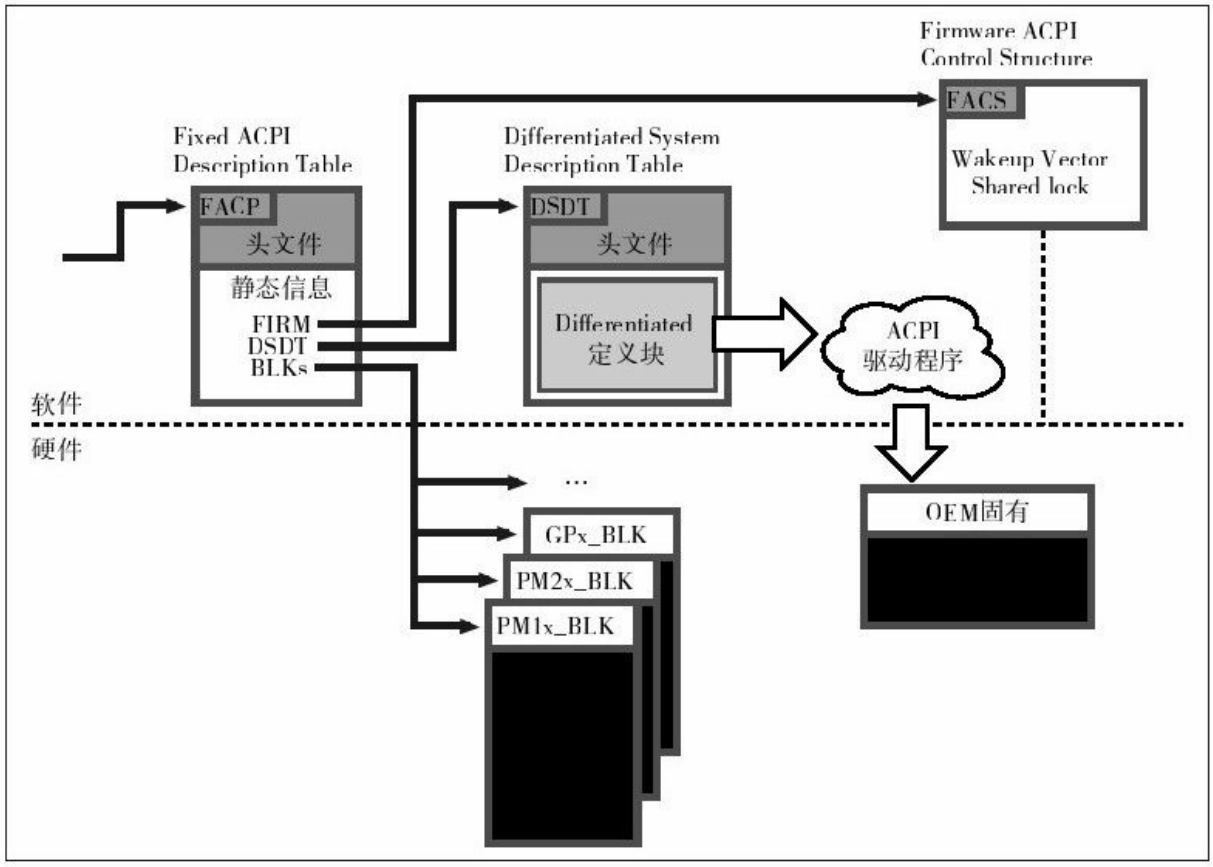

图　6-2　描述表结构

·Root System Description Pointer（RSDP）

·System Description Table Header

·Root System Description Table（RSDT）

·Fixed ACPI Description Table（FADT）

·Firmware ACPI Control Structure（FACS）

·Differentiated System Description Table（DSDT）

·Secondary System Description Table（SSDT）

·Multiple APIC Description Table（MADT）

·Smart Battery Table（SBST）

·Extended System Description Table（XSDT）

·Embedded Controller Boot Resources Table（ECDT）

·System Locality Distance Information Table（SLIT）

·System Resource Affinity Table（SRAT）

ACPI系统描述表除了ACPI说明书中规定的表以外，还有PCI等说明书中规定的表。ACPI表是通过签名来识别表的，因此其他说明书定义的表的签名作为ACPI的预留表保留。

·Simple Boot Flag Table（BOOT）

·DMA Remapping Table（DMAR）

·IA-PC High Precision Event Timer Table（HPET）

·iSCSI Boot Firmware Table（IBFT）

·I/O Virtualization Reporting Structure（IVRS）

·PCI Express memory mapped configuration space base address Description Table（MCFG）

ACPI命名空间和AML（ASL）

ACPI命名空间是定义块的层次性命名空间，所有定义块都被读入相同命名空间中。因此可以在命名空间内从其他位置参照对象或数据，但必须注意名称不要重复。下面介绍ACPI命名空间的命名规则。

ACPI命名空间的命名规则

·所有名称的长度为固定长度32位

·第一个字节为‘A’～‘Z’、‘_’（0x41～0x5A、0x5F）

·其他3个字节为‘A’～‘Z’、‘0’～‘9’、‘_’（0x41～0x5A、0x30～0x39、0x5F）

·ASL编译器为了将4个字以下的名称改为4个字，而添加‘_’。

·以‘_’开头的名称在ACPI的说明书中预留。

·以‘\’开头的名称就是参照命名空间的root的名称（‘\’不包括在32位固定长度的名称中）。

·以‘^’开头的名称就是参照当前命名空间的上一层的名称（‘^’不包括在32位固定长度的名称中）。

另外，写BIOS的人使用ASL语言来描述这个定义块。将使用ASL写出的源代码编译，就可以生成AML的二进制码。操作系统通过执行这个AML的代码，来读取、写入定义块的系统结构。关于ASL的解释非常复杂，本书只作简单的介绍。

ASL

ASL是用来定义ACPI对象的语言。在ASL语言中，ACPI对象由ObjectType、

FixedList、VariableList这三者来定义。FixedList和VariableList存在null的情况。

Object：=ObjectType FixedList VariableList

Object ACPI对象

ObjectType ACPI对象的类型

FixedList通过固定长度的列表来表示ObjectType的实例。表示为（a, b，c，……）

VariableList通过非固定长度的列表来表示子对象。表示为{x, y，z, aa, bb, cc}

例如，查看Bochs emulator[1]的DSDT。以下为_S3对象的部分。

```
Name（\_S3，Package（0x04）
{
0x01，/*PM1a_CNT.SLP_TYP*/
0x01，/*PM1b_CNT.SLP_TYP*/
Zero，/*reserved*/
Zero/*reserved*/
}）
```

Name（）生成名为_S3的对象。Package（）的使用方法如下：

```
Package（NumElements）{PackageList}
```

在Package（）中，ObjectType为Package, NumElements为FixedList, PackageList为VariableList。NumElements（0x4）表示PackageList的数量，用PackageList的值初始化_S3。_Sx对象定义见表6-10。

表 6-10 _Sx 对象的定义

字 节 长度	字节偏移量	说　明
1	0	系统进入 Sx 状态时 PM1a_CNT.SLP_TYP 寄存器的值
1	1	系统进入 Sx 状态时 PM1b_CNT.SLP_TYP 寄存器的值
2	2	预留

从上述示例中可以看出，要进入S3状态，写入PM1 Control Grouping的PM1 Control寄存器的PM1a_CNT.SLP_TYP、PM1b_CNT.SLP_TYP的值为1。

[1]http：//bochs.sourceforge.net/

查看ACPI的表

本节介绍如何在Linux上查看ACPI的表。首先安装用于将ACPI的信息输出到文件的名为pmtools工具包，该包是RPM格式，用于反汇编（disassemble）AML的工具包iasl，该包为RPM格式。在Fedora 13的情况下可以使用yum命令来安装。

```
#yum install pmtools
#yum install iasl
```

如果是不包含pmtools和iasl的发布版，pmtools可以从http：//www.lesswatts.org/projects/acpi/utilities.php下载。iasl可以从http：//www.acpica.org/下载。

首先，使用pmtools中的acpidump命令输出ACPI的表。想要输出DSDT表时的操作如下。

```
#acpidump-b-t DSDT-o dsdt.dat
```

然后使用iasl将这些数据反汇编。

```
#iasl-d dsdt.dat
Intel ACPI Component Architecture
AML Disassembler version 20090123[Feb 25 2009]
Copyright（C）2000-2009 Intel Corporation
Supports ACPI Specification Revision 3.0a
Loading Acpi table from file dsdt.dat
Acpi table[DSDT]successfully installed and loaded
Pass 1 parse of[DSDT]
Pass 2 parse of[DSDT]
Parsing Deferred Opcodes（Methods/Buffers/Packages/Regions）
……
……
Parsing completed
Disassembly completed, written to"dsdt.dsl"
```

这样就生成了名为dsdt.dsl的文件。从其中可以看到DSDT的ACPI表头文件和使用ASL

写的定义块。查看DSDT等ACPI的表，就可以看到系统支持的功能。

```
/*
* Intel ACPI Component Architecture
* AML Disassembler version 20090123
*
* Disassembly of dsdt.dat, Fri Sep 24 07:45:31 2010
*
*
* Original Table Header:
*     Signature        "DSDT"
*     Length           0x00001E22 (7714)
*     Revision         0x01 **** ACPI 1.0, no 64-bit math support
*     Checksum         0x71
*     OEM ID           "BXPC"
*     OEM Table ID     "BXDSDT"
*     OEM Revision     0x00000001 (1)
*     Compiler ID      "INTL"
*     Compiler Version 0x20090123 (537461027)
*/
DefinitionBlock ("dsdt.aml", "DSDT", 1, "BXPC", "BXDSDT", 0x00000001)
{
    Scope (\)
    {
        OperationRegion (DBG, SystemIO, 0xB044, 0x04)
        Field (DBG, DWordAcc, NoLock, Preserve)
        {
            DBGL,   32
        }
    }

    Scope (_SB)
    {
        Device (PCI0)
        {
```

Name（_HID, EisaId（"PNP0A03"））
Name（_ADR, Zero）
Name（_UID, One）
Name（_PRT, Package（0x80）
{
……

小结

本节介绍了ACPI的表和定义块的参照方法。下面的Hack将参照ACPI的数据，介绍关于系统省电的Hack。

参考文献

·http：//download. intel.com/technology/itj/2008/v12i3/Paper1.pdf

·Advanced Configuration and Power Interface Specification

http://www. acpi.info/DOWNLOADS/ACPIspec40a.pdf

——Akio Takebe

HACK#41　使用ACPI的S状态

本节介绍使用系统整体省电（S状态）的方法。

不使用系统时，关闭系统是最省电的。但是，一旦关闭后，系统启动的时间就会变长，因此，如果只是暂时不用就不想关闭系统。这时，使用S状态就可以缩短系统恢复时间，省电效果也十分理想。

S3状态的使用方法

使用S状态时，硬件、BIOS、操作系统必须能够支持。在Linux下可以通过下列命令来确认可否利用S状态：

#cat/sys/power/state

standby disk

standby表示S1、disk为S4、mem表示S3，参见表6-11。

表6-11　可利用的S状态

standby	S1
mem	S3
disk	S4

在Linux中使用各S状态时，进行如下操作：

```
#echo"各状态"＞/sys/power/state
```

要使用S3（mem）时，可以进行下列操作：

```
#echo"mem"＞/sys/power/state
```

按下电源按钮，就可以重新恢复。

S3状态的结构

使用S3状态时，不同系统的反应也不同，但内核进行的操作大致如下。

1.停止进程。

2.停止设备运行。

3.将唤醒时的开始地址作为wakeup vector登录到BIOS。

4.停止BSP（Boot Strap Processor）以外的CPU运行。

5.停止系统设备运行。

6.保存内核和CPU的状态。

7.将评价ACPI的_S3对象得到的值写入FADT的PM1寄存器，进入待机模式。

系统恢复时，从登录到wakeup vector的地址启动，按下列方式恢复到待机前的状态。

1.启用ACPI。

2.恢复系统设备。

3.启用CPU。

4.消除wakeup vector。

5.恢复停止的设备。

6.恢复进程。

S4状态的使用方法

ACPI中定义了两种进入S4的方法。一个是BIOS主导的方法（S4BIOS），另一个是操作系统主导的方法。如果使用S4BIOS，则BIOS恢复内存，与从S3恢复的情况相同。S4BIOS状态要求系统必须支持S4BIOS。但是，Linux 2.6.30中使用的不是S4BIOS，而是操作系统主导的方法。Linux中S4也称为swap待机，Linux 2.6.30的S4处理通过将内存上的所有数据保存在交换区磁盘来停止电源，恢复时由引导加载程序（bootloader）启动内核，在内核初始化时，把之前保存到交换区磁盘的数据读入内存来快速恢复到原来的状态。

S4状态的使用方法如下，与S3状态同，都是按下电源按钮来重新恢复。

```
#echo"platform"＞/sys/power/disk
#echo"disk"＞/sys/power/state
```

休眠要使用交换区磁盘，因此需要有内存量+α的磁盘容量用于交换。一般认为需要准备内存的1.5～2倍的磁盘容量。Linux 2.6.30中默认保存在交换区磁盘的内存数据大小为500MB。如果需要保存500MB以上的内存，可以进行如下操作。

```
#echo"0"＞/sys/power/images_size
```

还需要注意恢复系统前的硬件结构。在ACPI中，恢复系统时只要有一个引导设备发生变更，恢复就会失败。由于依存于BIOS的实际安装，因此建议在待机时和系统恢复时不要改变硬件结构。与硬件一样，恢复时如果更改内核启动参数也有可能会出现问题。

另外，有的PC上有可能出现BIOS无法顺利运行，休眠失败的情况。这时可以尝试下列方法。

1.编辑grub.conf，在内核启动参数中添加用于恢复系统的交换设备“resume=＜交换设

备名称＞”。

```
e.g.
title Fedora（2.6.30.10-105.2.16.fc11.i586）
root（hd0，4）
kernel/boot/vmlinuz-2.6.30.10-105.2.16.fc11.i586 ro root=UUID=eb600401-
ba10-44da-aa90-802740929780 nomodeset rhgb resume=/dev/sdb1
initrd/boot/initrd-2.6.30.10-105.2.16.fc11.i586.2.img
```

2.将休眠设置为shutdown模式。

```
#echo shutdown＞/sys/power/disk
```

3.进行休眠。

```
#echo disk＞/sys/power/state
```

如果恢复系统后系统运行状态有所不同，有时会通过将交换区的数据强制读入内存来改善性能。命令如下。

```
#swapoff-a
#swapon-a
```

小结

Fedora13等中还有pm-utils的pm-suspend、pm-hibernate等便利的命令，可以轻松尝试待机或休眠。如果不能成功，可以查看/var/log/messages，就可能找出原因。当交换区不足时，会出现kernel：PM：Not enough free swap消息，可以增大交换设备或停止一些应用程序。

HACK#42　使用CPU省电（C、P状态）

本节介绍使用C状态和P状态的CPU省电方法。

C状态的使用方法

C状态是CPU空闲时的电力状态。通过设置为更深的C状态就可以减少电能消耗。C状态的层次越深入，C状态将停止更多CPU功能，因此C状态的层次越深，从空闲状态恢复的时间越长。ACPI中从C状态的恢复基本上是以中断为契机进行的。因此，降低中断频率可以让C状态持续更长时间，从而抑制电能消耗。

ACPI具有两个用来控制C状态的接口。

1.Processor寄存器块（P_BLK）的P_LVL2和P_LVL3寄存器。

2.定义块中定义的处理器的对象列表的_CST对象。

使用_CST的C状态控制对使用P_BLK的控制进行了扩展。它可以使用称为Functional固定硬件（FFH）接口的厂商固有接口。可以根据CPU架构使用C状态，如Intel公司的CPU使用的就是MWAIT命令等。从而可以使用ACPI中未定义的C状态。_CST对象针对各个状态分别定义了下列内容。

Register	处理器进入 Type 所示的 C 状态时必须读出的位置
Type	表示用于 C1、C2、C3 等中的哪个 C 状态的字段
Latency	进入 C 状态时最差情况下的延迟时间（毫秒）
Power	处于 Type 所示 C 状态时处理器的平均耗电量

Linux中有用来控制包括x86在内的各种CPU空闲状态的cpuidle子系统。通过cpuidle子系统可以设置CPU空闲时的轮询（polling）方法和策略（governor）。从而可以将每个

CPU的空闲状态的特性抽象化，使用CPU固有功能或ACPI的功能。

控制Linux的cpuidle的用户接口位于/sys/devices/system/cpu/cpuidle/下。各接口的说明如下所示。

available_governors	可利用的策略
current_governor_ro	显示当前的策略
current_governor	通过读出，可以显示当前的策略；通过写入，可以切换
current_driver	当前 cpuidle 子系统的驱动程序

Linux中现有策略列表如下。

menu	Linux 中使用的标准策略
ladder	阶段性改变状态的策略。使用以往的定期中断计时器时可以顺利运行，而最近的 Linux 内核的计时器并不使用定期计时器中断。

menu策略从中断等情况预测可以休眠的时间，选择与该休眠时间相符的最深C状态。使用CPU负载、中断、I/O负载等进行预测。

基本上可以使用默认的cpuidle的策略来控制电能消耗。策略虽然有在运行中可以变更的接口，但切换的接口是面向开发者的，启动中不应进行切换。

每个CPU的C状态信息可以从/sys/devices/system/cpu/cpuN/cpuidle/stateM/下获取（N、M为整数。N为CPU编号，M为C状态的状态编号）。

desc	状态 M 下 cpuidle 的说明
latency	到恢复为止的延迟时间
name	状态 M 的名称（C1、C2、C3 等）
power	状态 M 运行时的电量
time	使用状态 M 的时间
usage	使用状态 M 的次数

除sysfs以外，还有可以通过proc文件系统参照的信息。其示例如下所示。/proc/acpi/processor/cpuN/power（N为CPU编号）。

```
#cat/proc/acpi/processor/CPU0/power
active state：C0
max_cstate：C8
maximum allowed latency：2000000000 usec
states：
C1：type[C1]promotion[--]demotion[--]latency[001]
usage[00008972]duration[0000000000000000000]
C2：type[C2]promotion[--]demotion[--]latency[001]
usage[00339308]duration[0000000000238036741]
C3：type[C3]promotion[--]demotion[--]latency[017]
usage[05986201]duration[0000000089960255002]
#cat/proc/acpi/processor/CPU0/info
processor id：0
acpi id：0
bus mastering control：yes
power management：yes
throttling control：no
limit interface：no
```

关于sched_mc_power_savings、sched_smt_power_savings

/sys/devices/system/cpu下存在sched_mc_power_savings、sched_smt_power_savings这些对进程调度程序进行调整的参数。它们可以在多核、同时多线程（Intel Hyper-threading等）的CPU中发挥作用。

sched_mc_power_savings

设置为0或1。设置为1时，进程调度程序尽量仅针对某个特定CPU套接字调度进程数。只有在运行中的所有内核都繁忙时，才能对位于其他CPU套接字的核进行进程调度。这在每个核具有各自的C状态，所有的核超过某个特定C状态才能进入更深C状态的CPU中有效。

sched_smt_power_savings

设置为0或1。设置为1时，进程调度程序尽量仅对位于某个特定内核的线程进行调度。只有在运行中的所有线程繁忙时，才对其他内核的线程进行调度。这与上述

sched_mc_power_savings同样，对于每个线程具有各自的C状态的CPU有效。

Linux下x86 CPU中的C状态运行情况如下所示。

1.Linux下一旦变成空闲状态，就会调度idle进程，调用pm_idle函数。

2.在使用cpuidle子系统的系统下，pm_idle调用cpuidle_idle_call（）。

3.cpuidle_idle_call（）中通过cpuidle governor的select方法选择下一个状态。

4.每个状态各自调用登录的enter方法，迁移到所选择的状态。

想要确保CPU的bug和应答性时，有时需要限制C状态。这时通过使用max_cstate这一内核启动参数，就可以限制C状态的最大值。向max_cstate输入希望使用的最深层的C状态的值。将CI设置为最大值时，在/etc/grub.conf中设置max_cstate=1。

```
    title Fedora（2.6.35.12-88.fc14.i686）
    root（hd0，0）
    kernel/boot/vmlinuz-2.6.35.12-88.fc14.i686 ro root=UUID=82f8f09d-b0d7-49ee-a57b-13e6484bd840 rd_NO_LUKS
rd_NO_LVM rd_NO_MD rd_NO_DM LANG=ja_JP.UTF-8 KEYTABLE=jp106 rhgb quiet processor.max_cstate=1
    initrd/boot/initramfs-2.6.35.12-88.fc14.i686.img
    title Fedora（2.6.35.11-83.fc14.i686）
```

使用max_cstate后，可以在/proc/acpi/processor/CPUN/power（N为CPU编号）确认max_cstate已变更。

```
    #cat/proc/acpi/processor/CPU0/power
    active state：C0
    max_cstate：C1
    maximum allowed latency：2000000000 usec
    states：
    C1：type[C1]promotion[--]demotion[--]latency[001]
    usage[00000000]duration[0000000000000000000]
```

P状态的使用方法

P状态是CPU正在运行时的电力状态。通过设置为更深的P状态就可以控制电能消耗。P状态下是通过降低频率来降低电能消耗的，因此性能和电能之间是不可兼得的关系。Linux下可以根据CPU的使用情况来设置P状态。另外，与C状态同样，根据用户设置的策略P状态有不同的性能。

与P状态相关的ACPI接口如下。在启用ACPI的系统中，在Linux下使用这些接口来控制cpufreq驱动程序。

_PCT（Performance Control）

使处理器进入P状态的接口。向PERF_CTRL写入控制寄存器（control register）值来进入P状态。根据使用_PPC方法得到的值来选择P状态的值。写入时使用的控制寄存器值是通过_PPC的Control字段获得的值。

写入成功后，PERF_STATUS的值与相关的_PSS的Status字段相同。在x86的情形下，PERF_CTRL、PERF_STATUS安装在PIO或MSR中（作为Functional固定硬件（FFH）安装时）。

Performance Control Register（PERF_CTRL）	通过写入来进入 P 状态
Performance Control Register（PERF_STATUS）	确认向 PERF_CTRL 写入后已进入 P 状态。如果与 _PSS 的 Status 是相同的值，则表示已进入 P 状态

_PSS（Performance Supported Status）

该接口用来显示处理器支持的P状态。各P状态中分别保存了CPU频率、电能消耗、控制寄存器值、status寄存器值。

Core Frequency	Px 状态下 CPU 内核的运行频率（MHz）
Power	Px 状态下的最大耗电量（mW）
Latency	迁移到 Px 状态时 CPU 变得无效的最大延迟时间（ms）
Bus Master Latency	迁移到 Px 状态时阻碍总线主控器访问内存的最大延迟时间（ms）
Control	写入 _PCT 的 PERF_CTRL 的控制寄存器值
Status	用来与从 _PCT 的 PERF_STATUS 读取的值作比较的值

_PPC（Performance Present Capabilities）

_PPC用于动态显示某个时间点平台所支持的P状态值。操作系统等从_PSS内的入口中，选择电能低于_PPC所得的值的P状态。例如，当_PSS有P0～P3的入口，而_PCC显示为1时，必须从P1状态到P3状态中选择P状态。_PPC的值是在连接、切断如DCMI[1]等这样的外部接口或电源适配器（AC adapter）时，通过BIOS动态变更。_PPC的值一旦变更，就会发生通知事件，操作系统再次执行_PPC。

_PSD（P-State Dependency）

P状态的控制中用来获取CPU之间依存关系的信息的对象如下所示。

NumEntries	ACPI4.0 中为 5。包括 NumEntries 在内的 _PSD 入口数
Revision	ACPI4.0 中为 0。_PSD 的修订编号
Domain	该 P 状态入口所属的域名的编号
CoordType	设置为下列类型之一。 SW_ALL（要改变 P 状态时软件必须改变所有 CPU） SW_ANY（要改变 P 状态时软件必须改变域名中的 CPU） HW_ALL（要改变 P 状态时硬件执行域名的迁移）
Num Processor	有依存关系的 CPU 数量。只有在有依存关系的所有 CPU 都在该 P 状态以下时才能迁移

在Linux的cpufreq子系统中，存在用来运行cpufreq的驱动程序和决定驱动程序运行策略的驱动程序。运行cpufreq的驱动程序在每个CPU或系统中各不相同，而在支持ACPI的

系统中基本上使用的是acpi-cpufreq驱动程序。由于一些系统的acpi-cpufreq无法正常运行，因此有的系统使用powernow-k8、p4-clockmod、speedstep-centrino等驱动程序。

Linux中可使用的省电governor如下。

performance	以可设置的最高频率运行
powersave	以可设置的最低频率运行
ondemand	根据系统负载更改频率
conservative	根据系统负载缓慢更改频率
userspace	可以从用户应用程序设置 P 状态

performance、powersave作为governor比较容易理解，但有时ondemand、conservative、userspace会不清楚应使用哪一个。一般多使用ondemand或userspace。ondemand在内核内测定负载，根据负载改变频率。因此，就可以在不察觉性能降低的情况下降低电能消耗。但是由于需要立刻改变频率的功能，因此并不是所有CPU中都可以使用。在userspace中cpuspeed等守护进程考虑/etc/sysconfig/cpuspeed等的设置内容来改变频率。在userspace中检测负载、更改频率是有延迟的，因此在负载变化剧烈的系统中，系统的应答时间可能会很紧迫。conservative和ondemand的区别就是conservative并非无论在哪种负载下都立即设置为最大频率，而是慢慢地改变频率。这个功能在笔记本电脑之类使用电池的系统中可以有效地发挥抑制电能消耗的效果。

需要注意的是，一般来说，performance和powersave并不是以抑制电能消耗为目的的governor。performance无论何时都以最高频率运行，因此无法抑制电能消耗。powersave由于降低运行频率，因此可以抑制电能消耗，但只有在进程几乎停止时才有效果。频率降低一般会导致运行时间增加，因此就会造成空闲时间（可以进入C状态的时间）减少，消耗的电能增加。

Linux的cpufreq子系统在/sys/devices/system/cpu/cpuN/cpufreq下提供了下列（见表6-12）与CPU性能相关的接口（N为CPU编号）。

表 6-12　cpufreq 子系统的接口

接　口	功　能
affected_cpus	因 P 状态的改变而受影响的 CPU。这里的 CPU 编号的 CPU 同时进入 P 状态

（续）

接　口	功　能
cpuinfo_min_freq	CPU 最低频率（kHz）
cpuinfo_transition_latency	改变频率所需的延迟时间（nm）
related_cpus	与 affected_cpus 的意思相同，但考虑 _PSD 的 CoordType=HW_ALL 时的情况
scalling_available_frequencies	可利用的频率列表
scalling_available_governors	可利用的 governor 名列表
scalling_cur_freq	最后设置的当前 CPU 频率（kHz）。由于不使用驱动程序重新获取值，因此有可能与 cpuinfo_cur_freq 的值不同（BIOS 等有时会更改 CPU 频率）
scalling_driver	用来处理 acpi-cpufreq 这样的 cpufreq 的驱动程序名称
scalling_governor	governor 的驱动程序名称。通过写入这个文件就可以更改 governor
scalling_max_freq	governor 可利用的最高频率。从 scalling_available_frequencies 中选择频率，通过写入这个文件就可以更改最高频率
scalling_min_freq	governor 可利用的最低频率。从 scalling_available_frequencies 中选择频率，通过写入这个文件就可以更改最高频率
scalling_setspeed	使用 userspace governor 时，通过在这里写入频率的值，就可以更改 CPU 频率

使用cpufrequitls等就可以使上述接口更容易使用。下面是cpufrequtils中包含的cpufreq-info的例子。

```
#cpufreq-info
cpufrequtils 005：cpufreq-info（C）Dominik Brodowski 2004-2006
Report errors and bugs to cpufreq@vger.kernel.org, please.
analyzing CPU 0：
driver：p4-clockmod
CPUs which need to switch frequency at the same time：0
hardware limits：317 MHz-2.53 GHz
available frequency steps：317 MHz，633 MHz，950 MHz，1.27 GHz，1.58 GHz，1.90 GHz，2.22 GHz，2.53 GHz
available cpufreq governors：ondemand, userspace, performance
```

current policy：frequency should be within 317 MHz and 2.53 GHz.
The governor"userspace"may decide which speed to use
within this range.
current CPU frequency is 2.22 GHz（asserted by call to hardware）.
cpufreq stats：317 MHz：0.00%，633 MHz：0.00%，950 MHz：0.00%，1.27
GHz：0.00%，1.58 GHz：0.00%，1.90 GHz：0.00%，2.22 GHz：0.00%，2.53 GHz：0.00%（5）

在安装了cpufreq-stats内核模块的情况下，/sys/devices/system/cpu/cpuN/cpufreq/stats下还准备了下列接口，用于powertop等应用程序（N为CPU编号）。

time_in_state	各 P 状态下使用的时间
total_trans	改变 P 状态的次数
trans_table	各 P 状态进入不同 P 状态的次数列表

ondemand中提供了下列接口（见表6-13），以便进行更加详细的调整。

表 6-13　ondemand 的接口

接　口	功　能
ignore_nice_load	设置为 0 或 1。设置为 1 时，具有 nice 值的进程所使用的时间在 cpufreq 中不参加计算。不用于判断 P 状态的更改
powersave_bias	设置为 0~1000 的值。表示 0.1%~100%，减少按照指定比例改变的频率。当 CPU 频率降低对用户几乎没有影响时，用来减少电能消耗
sampling_rate	对 CPU 使用率进行采样的间隔（微秒）。一般为 10000 左右的值，默认值为 transition_latency*1000
sampling_rate_max	sampling_rate 可以设置的最大值
sampling_rate_min	sampling_rate 可以设置的最小值
up_threshold	判断是否要更改 P 状态的 CPU 使用率的阈值

使用ondemand governor时acpi-cpufreq的运行情况如下。

1.cpufreq_ondemand驱动程序将初始化时用来计算负载的函数输入到计时器。

2.cpufreq_ondemand驱动程序定期根据空闲时间测量系统负载，决定要改变的P状态。

-CPU使用率一旦超过up_threshold中指定的值，就将频率提高到scalling_max_freq。

-CPU使用率如果保持up_threshold-10以下的状态，就将频率逐渐降低到

scalling_min_freq为止。

3.cpufreq驱动程序（acpi-cpufreq等）让CPU进入期望实现的P状态。

conservative中提供的接口如表6-14所示。

表 6-14 conservative 中提供的接口

接口名称	功能
down_threshold	判断是否要降低 P 状态的 CPU 使用率的阈值。CPU 使用率一旦低于 down_threshold-10，就判断为降低 P 状态

（续）

接口名称	功能
freq_step	提高 / 降低 CPU 频率的比例。为 0 则不改变频率。为 100 则与 ondemand 同样运行
ignore_nice_load	设置为 0 或 1。设置为 1 时，具有 nice 值的进程所使用的时间在 cpufreq 中不参加计算。不用于判断 P 状态的更改
sampling_down_factor	赋予 sampling_rate 的乘数因子。用于降低采样频率
sampling_rate	对 CPU 使用率进行采样的间隔（μs）。sampling_rate × sampling_down_factor 就是采样间隔
sampling_rate_max	sampling_rate 可以设置的最大值
sampling_rate_min	sampling_rate 可以设置的最小值
up_threshold	判断是否要提高 P 状态的 CPU 使用率的阈值

在使用服务器等系统中，有时想要抑制电力峰值但是不停止服务器。这种情况下可以使用P状态限制电力峰值。下面介绍能够方便地限制P状态的设置方法。cpuspeed服务中可以在/etc/sysconfig/cpuspeed中进行限制P状态的设置。下列是将P状态固定在800MHz的例子。

```
MAX_SPEED=800000
MIN_SPEED=800000
```

对/etc/sysconfig/cpuspeed进行编辑后，重新启动cpuspeed服务，设置就会发挥作用。在scalling_max_freq、scalling_min_freq中设置MAX_SPEED、MIN_SPEED。需要注意的是，如果删除/etc/sysconfig/cpuspeed中设置的值，则需要手动重新设置scalling_max_freq、

scalling_min_freq等，或者重新启动操作系统。另外，如图6-3和图6-4所示，在可以使用GUI的环境中，gnome-applets数据包中包含的CPU频率测量监控器（CPU Frequency Scalling Monitor），这个小应用程序的使用也十分方便。

Intel®智能加速技术

powertop（参考Hack#50）是确认P状态的工具之一。但是通过powertop命令仅能显示P状态的额定频率。

下面是在Intel®Xeon®CPU E3-1225的机器（Sandy Bridge）上执行powertop时的输出内容。可以确认以1.60～3.11GHz运行时的情况。

图　6-3　添加CPU频率测量监控器小程序（monitor applet）

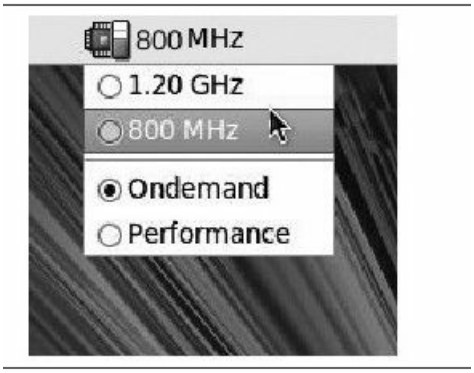

图　6-4　使用CPU频率测量监控器的例子

```
# powertop

    PowerTOP version 1.11       (C) 2007 Intel Corporation

C 状态          平均滞留时间            P 状态（频率）
C0（CPU 运行状态）          (13.7%)          3.11 GHz      0.0%
轮询     C1 halt              0.0m  3.10 GHz      0.0%
C1 halt             0.3ms ( 0.0%)          2.90 GHz      0.0%
C3 mwait           39.5ms (86.2%)          2.71 GHz      0.0%
                                           1.60 GHz    100.0%

平均 1 秒的 CPU 分配次数：23.4      时间间隔：0.6 秒
...
```

具有智能加速技术（Intel Turbo Boost Technology）的CPU自动以高于固定频率的频率运行。从内核2.6.38开始，内核源代码内都包含turbostat命令，可以确认智能加速的运行频率。

下载内核2.6.38，编译turbostat。

```
#wget-t0-c http：//www.kernel.org/pub/linux/kernel/v2.6/linux-2.6.38.tar.bz2
#tar jxvf linux-2.6.38.tar.bz2
```

```
# cd linux-2.6.38/tools/power/x86/turbostat
# make ; make install
```

在没有运行任何代码的状态下执行 turbostat。

```
# turbostat -v
GenuineIntel 13 CPUID levels; family:model:stepping 0x6:2a:7 (6:42:7)
16 * 100 = 1600 MHz max efficiency                以最低电压运行的频率
31 * 100 = 3100 MHz TSC frequency                 额定频率
32 * 100 = 3200 MHz max turbo 4 active cores      4 个内核运行时的频率
33 * 100 = 3300 MHz max turbo 3 active cores      3 个内核运行时的频率
33 * 100 = 3300 MHz max turbo 2 active cores      2 个内核运行时的频率
34 * 100 = 3400 MHz max turbo 1 active cores      1 个内核运行时的频率
core CPU   %c0   GHz  TSC   %c1    %c3    %c6    %c7   %pc2   %pc3   %pc6   %pc7
          0.01 1.59 3.09   0.02   0.00  99.96   0.00   6.48   0.00  93.40   0.00
  0   0   0.02 1.59 3.09   0.03   0.00  99.95   0.00   6.48   0.00  93.40   0.00
  1   1   0.01 1.60 3.09   0.02   0.00  99.97   0.00   6.48   0.00  93.40   0.00
  2   2   0.01 1.60 3.09   0.02   0.00  99.98   0.00   6.48   0.00  93.40   0.00
  3   3   0.01 1.60 3.09   0.02   0.00  99.96   0.00   6.48   0.00  93.40   0.00
```

所有的 CPU 以约 1.60GHz 的频率运行，然后启动一个通过无限循环利用 CPU 的进程。

```
# while [ 0 ] ; do : ; done &
# turbostat
core CPU   %c0   GHz  TSC   %c1    %c3    %c6    %c7   %pc2   %pc3   %pc6   %pc7
         24.87 3.39 3.09   1.15   0.00  73.98   0.00   0.00   0.00   0.00   0.00
  0   0   0.02 3.29 3.09   0.02   0.00  99.95   0.00   0.00   0.00   0.00   0.00
  1   1  98.59 3.39 3.09   1.41   0.00   0.00   0.00   0.00   0.00   0.00   0.00
  2   2   0.85 3.29 3.09   3.18   0.00  95.97   0.00   0.00   0.00   0.00   0.00
  3   3   0.00 3.29 3.09   0.01   0.00  99.99   0.00   0.00   0.00   0.00   0.00
```

一直提高到3.39GHz，可以看出智能加速正在运行。turbostat的详细情况请参考man 8 turbostat。

[1]Data Center Manageability Interface。

小结

性能和省电之间是平衡的关系。建议根据系统分析需要什么样的性能，再启用省电功能。

参考文献

·英特尔®智能加速技术

http://www. intel.co.jp/jp/technology/turboboost/

——Akio Takebe、Naohiro Ooiwa

HACK#43　PCI设备的热插拔

本节介绍PCI设备的热插拔。

热插拔功能，是指在不停止系统的情况下向系统添加、删除设备的功能。PCI中也考虑了热插拔的结构，在部分系统中可以使用。这与USB的热插拔是不同的，需要首先了解热插拔的流程才能更好地使用PCI设备的热插拔，因此本节对其概述并介绍Linux下的使用方法。

PCI相关设备的热插拔规格有使用PCI Standard Hot-Plug Controller（SHPC）的热插拔、PCI Express的热插拔、ACPI热插拔、厂商固有功能的热插拔等。其中，作者认为使用最广的热插拔规格是SHPC。理解SHPC的规格就可以理解其他PCI热插拔的流程。PCI Express的热插拔基本上也是与SHPC规格相同的。

SHPC是安装在PCI-to-PCI桥或PCI主桥上的热插拔用控制器。SHPC中定义了Standard Usage Model这个热插拔的标准用户操作，其中构成Standard Usage Model的要素参见表6-15。

表 6-15　构成 SHPC Standard Usage Model 的要素

要　素	目　的
Indicators	显示插槽（slot）的 power 和 attention 状态
Manual-operated Retention Latch（MRL）	固定 PCI 卡的物理锁扣（latch）
MRL Sensor	SHPC 和操作系统用来检测 MRL 已打开
Electromechanical interlock	防止插槽通电时拔出 PCI 卡
Attention Button	使用户能够进行热插拔操作的硬件结构
Software User Interface	使用户能够进行热插拔操作的软件接口
Slot Numbering	物理插槽的识别符

Indicator有Power Indicator（见表6-16）和Attention Indicator（见表6-17）。各个Indicator分别有on（亮灯）、off（灭灯）、blinking（闪烁）这三个状态，Indicator由软件完全控制，可以单独显示各个状态。

表 6-16　Attention Indicator（黄色或橙色）

状　态	说　明
off（灭灯）	灭灯。通常状态
on（亮灯）	亮灯。操作上发生问题的状态
blinking（闪烁）	闪烁。出现在操作系统进行了让用户识别指定插槽位置的操作时

表 6-17　Power Indicator（绿色）

状　态	说　明
off（灭灯）	灭灯。插槽未通电的状态。此时可以插拔 PCI 卡
on（亮灯）	亮灯。插槽通电的状态。此时不允许插拔 PCI 卡
blinking（闪烁）	闪烁。插槽渐渐通电或渐渐断电的状态。此时不允许插拔 PCI 卡

Hot-add的流程

SHPC中定义了使用软件接口的Hot-add和使用Attention按钮的Hot-add，这里介绍使用软件接口的Hot-add的流程。

1.打开MRL（物理固定PCI卡的锁扣）。

2.插入PCI卡，关闭MRL，安装连接线。

3.用户从软件发布让插槽变为可使用状态的要求。此时Power Indicator仍然为off（灭灯）状态。

4.用户从软件接口通知可以将插槽变为可使用状态。此时Power Indicator变为blinking（闪烁）状态。

5.用户等待插槽完全变为可使用状态。完全变为可使用状态后，Power Indicator变为on（亮灯）状态。

Hot-remove的流程

Hot-remove与Hot-add同样定义了使用软件接口的Hot-remove和使用Attention按钮的Hot-remove。这里介绍使用软件接口的Hot-remove的流程。

1.用户选择MRL关闭，插槽为可使用状态的PCI卡，使用软件发布要求让插槽变为不可使用状态的要求。此时Power Indicator仍为on状态。

2.用户从软件接口通知可以将插槽变为不可使用状态。此时Power Indicator变为blinking状态。

3.用户等待插槽变为不可使用状态。插槽完全变为不可使用状态后，Power Indicator变为off。

4.用户拆除连接线，打开MRL，拆除PCI卡。

确认热插拔功能

SHPC可以作为PCI桥的功能来确认。使用lspci-vvvv命令确认时，如果Capability列表中有SHPC Capability ID（0x0c），就可以确认具有SHPC功能（①）。实际上，也有MRL或BIOS等系统不支持的很多情况，因此使用的系统如果不是厂商支持的系统，则很多情况下无法使用。

例6-1　lspci-vvvv的例子

---

ad：00.0 PCI bridge：Intel Corporation 6700PXH PCI Express-to-PCI Bridge A（rev 09）（prog-if 00[Normal decode]）
Control：I/O-Mem+BusMaster+SpecCycle-MemWINV-VGASnoop-ParErr+
Stepping-SERR+FastB2B-
Status：Cap+66MHz-UDF-FastB2B-ParErr-DEVSEL=fast＞TAbort-
＜TAbort-＜MAbort-＞SERR-＜PERR-
Latency：0，Cache Line Size：128 bytes
Region 0：Memory at d78fe000（64-bit, non-prefetchable）[size=4K]
Bus：primary=ad, secondary=ae, subordinate=af, sec-latency=64
I/O behind bridge：0000f000-00000fff
Memory behind bridge：d6a00000-d77fffff
Prefetchable memory behind bridge：000000f580000000-000000f5bff00000 Secondary status：66MHz+FastB2B+ParErr-DEVSEL=medium＞TAbort-
＜TAbort-＜MAbort+＜SERR-＜PERR-
BridgeCtl：Parity+SERR+NoISA-VGA-MAbort-＞Reset-FastB2B-
Capabilities：[44]Express PCI/PCI-X Bridge IRQ 0
Device：Supported：MaxPayload 256 bytes, PhantFunc 0，ExtTag-
……
Link：Speed 2.5Gb/s, Width x4
Capabilities：[5c]Message Signalled Interrupts：64bit+Queue=0/0
Enable-
Address：0000000000000000 Data：0000
Capabilities：[6c]Power Management version 2
Flags：PMEClk-DSI-D1-D2-AuxCurrent=0mA PME（D0+，D1-，D2-
，D3hot+，D3cold+）
Status：D0 PME-Enable-DSel=0 DScale=0 PME-
Capabilities：[78]#0c[0004]……①
Capabilities：[d8]PCI-X bridge device
Secondary Status：64bit+133MHz+SCD-USC-SCO-SRD-Freq=conv
Status：Dev=ad：00.0 64bit-133MHz-SCD-USC-SCO-SRD-
Upstream：Capacity=65535 CommitmentLimit=65535
Downstream：Capacity=65535 CommitmentLimit=65535
Capabilities：[100]Advanced Error Reporting
Capabilities：[300]Power Budgeting

Linux的热插拔子系统

Linux中有用于PCI热插拔的子系统，SHPC、PCI Express、ACPI热插拔基本上是相同的。SHPC、PCI Express、ACPI热插拔所使用的驱动程序如下表所示。

规　　格	驱动程序名称
SHPC	shpchp
PCIExpress	pciehp
ACPI	acpihp

首先，需要安装热插拔驱动程序shachp。在SHPC的情况下，使用下列命令把shachp安装到内核。

```
#modprobe shpchp
```

将驱动程序安装到内核后，会在下列路径中显示可以热插拔的插槽编号。

```
/sys/bus/pci/slots
```

需要注意的是，这个插槽编号与PCI中的一般Segment：Bus：Device：Function编号并不相同。基本上就是系统厂商提供的使用手册中记载的插槽编号。

将0写入对象插槽编号的目录下的power文件，就会执行Hot-remove。Power Indicator变为off（灭灯）表示Hot-remove完成，可以拆除设备。

```
#echo 0＞/sys/bus/pci/slots/＜插槽编号＞/power
```

注意事项：将设备进行Hot-remove时，需要先停止正在使用的服务。

对于Hot-add的情况，请在安装设备后对power写入1。

#echo 1＞/sys/bus/pci/slots/＜插槽编号＞/power

小结

KVM/Xen虚拟环境等支持ACPI的PCI热插拔，接触PCI热插拔的机会也增多。将不使用的PCI设备暂时Hot-remove也可以省电，大家可以尝试一下。

——Akio Takebe

HACK#44　虚拟环境下的省电

本节介绍在使用KVM/Xen时虚拟环境下的省电方法。

怎样才能在虚拟环境下省电？掌握了基本思想就可以理解虚拟环境下的省电方法。

虚拟环境下的省电思想

例如，某个客户端进入S3状态，但其他客户端可能仍在运行，因此不能将主机操作系统更改为S状态。因此需要将客户端操作系统内的电力管理和主机操作系统内的电力管理分开考虑。

客户端操作系统内的电力管理

客户端操作系统不对其他客户端、主机操作系统或管理程序造成影响，不进行实际的电力管理，但有时会成为主机操作系统或管理程序的电力管理的触发器（trigger）（例如，也可以当所有客户端操作系统都进入S3状态时对主机操作系统进入S3等的配置）。

·关于客户端操作系统内的S状态

从客户端操作系统内可以进行待机等，因此客户端操作系统管理者不使用客户端操作系统时可以通过使用S状态来省电。

·关于客户端操作系统内的C状态

虚拟CPU变为空闲时就会发出hlt命令，被排除在管理程序的调度对象之外。因此，即使在客户端操作系统的各C状态下进行不同的运行也没有意义，于是多数管理程序中没有配置客户端操作系统的C状态。

·关于客户端操作系统内的P状态

与C状态基本相同，即使配置也没有意义，因此多数管理程序中没有配置客户端P状态。

主机操作系统内的电力管理

主机操作系统或管理程序内的电力管理是通过控制实际的硬件来进行电力控制的。

·关于主机操作系统的S状态

如图6-5所示，从管理程序来看，所有客户端操作系统的虚拟CPU都被操作系统看做进程同样处理。因此，保存客户端的虚拟CPU上下文等的方法，与操作系统变为S状态时保存进程状态的方法相同。像Xen管理程序一样不进行磁盘I/O的管理程序，不将内存内容写入磁盘，因此有时不支持S4状态。

·主机操作系统上的C状态

与非虚拟环境的普通操作系统一样，根据主机操作系统或管理程序中设置的策略选择C状态。虚拟环境下需要注意的是客户端操作系统的中断频率。C状态是通过中断来恢复的，因此需要尽量减小中断的频率才能产生省电的效果。虚拟环境下有多个操作系统是中断的发生源，因此如果某一个客户端操作系统内频繁中断，则该客户端操作系统使用的CPU就无法进入深层C状态。也就是说，想要通过C状态来省电，就必须努力减小所有客户端操作系统上的中断次数。

·主机操作系统上的P状态

主机操作系统上的P状态导致的性能变化直接反映客户端操作系统的性能。有时即使认为客户端操作系统的CPU以3GHz的频率运行，实际却是设置为600MHz的。可能有人会担心这一点，但客户端操作系统并不是原本就占用了CPU所有时间的。即使物理CPU原来具有3GHz的性能，实际也可能只使用其一半的时间，因此客户端操作系统降低运行中的CPU频率本身是没问题的。在主机操作系统中改变P状态时，根据CPU使用率决定进入哪个P状态，但管理程序的种类或设置不同，运行情况有时也有所不同，这将在后面介绍。

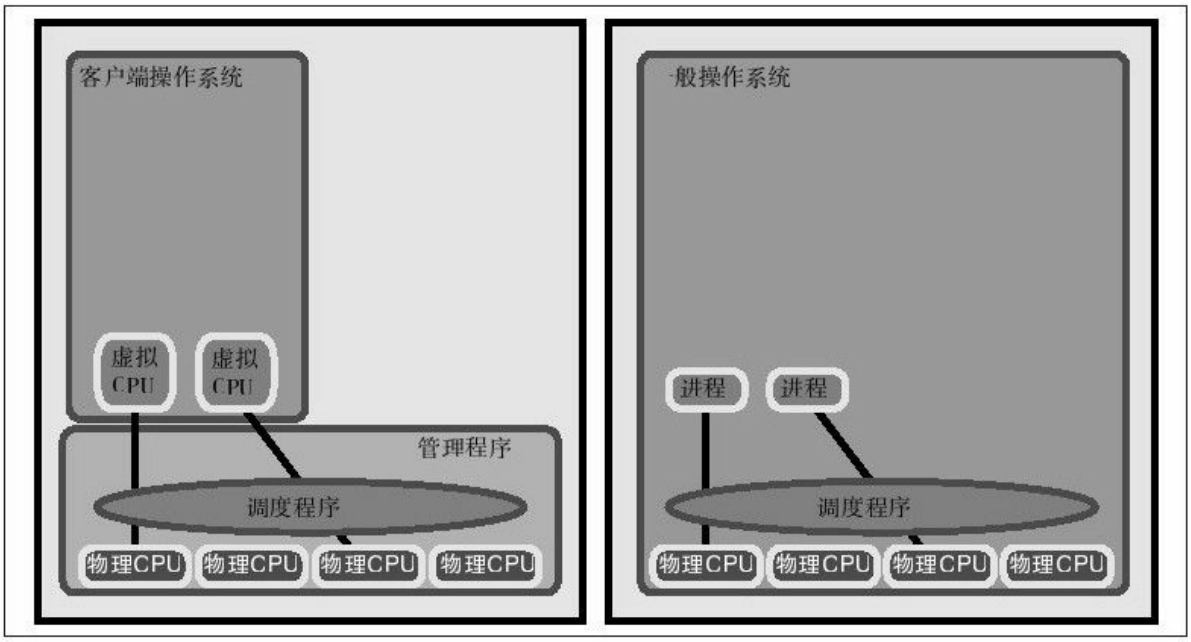

图　6-5　管理程序的虚拟CPU和操作系统的进程

Xen的P状态

Xen是将管理程序和特权客户端Dom0作为主机操作系统的管理程序。Xen准备了管理程序控制P状态的方法和Dom0控制P状态的方法。RHEL5等Linux发布版采用的是Dom0控制P状态的方式。使用Dom0控制P状态的方式时，通过下列命令添加Xen的启动选项cpufreq=dom0-kernel。在RHEL5等中，这个选项是默认的。这个方式的优点是可以在Dom0上使用cpuspeed等工具，因此可以设置与不使用Xen时的Linux相同的策略。

```
title Xen
root（hd0，0）
kernel/boot/xen.gz cpufreq=dom0-kernel
module/boot/vmlinuz-2.6.18.8-xen ro root=/dev/sda1
module/boot/initrd-2.6-xen.img
```

但是cpufreq=dom0-kernel的情形必须由dom0的虚拟CPU直接控制物理CPU的P状态，因此所有的虚拟CPU必须与所有物理CPU一对一固定，如图6-6所示。指定cpufreq=dom0-kernel时，会自动执行将虚拟CPU与物理CPU固定的处理，但如果通过dom0_max_vcpus启动选项将虚拟CPU的数量指定为少于物理CPU，或者无法将虚拟CPU固定分配给物理CPU时，cpufreq=dom0-kernel选项可以忽略。

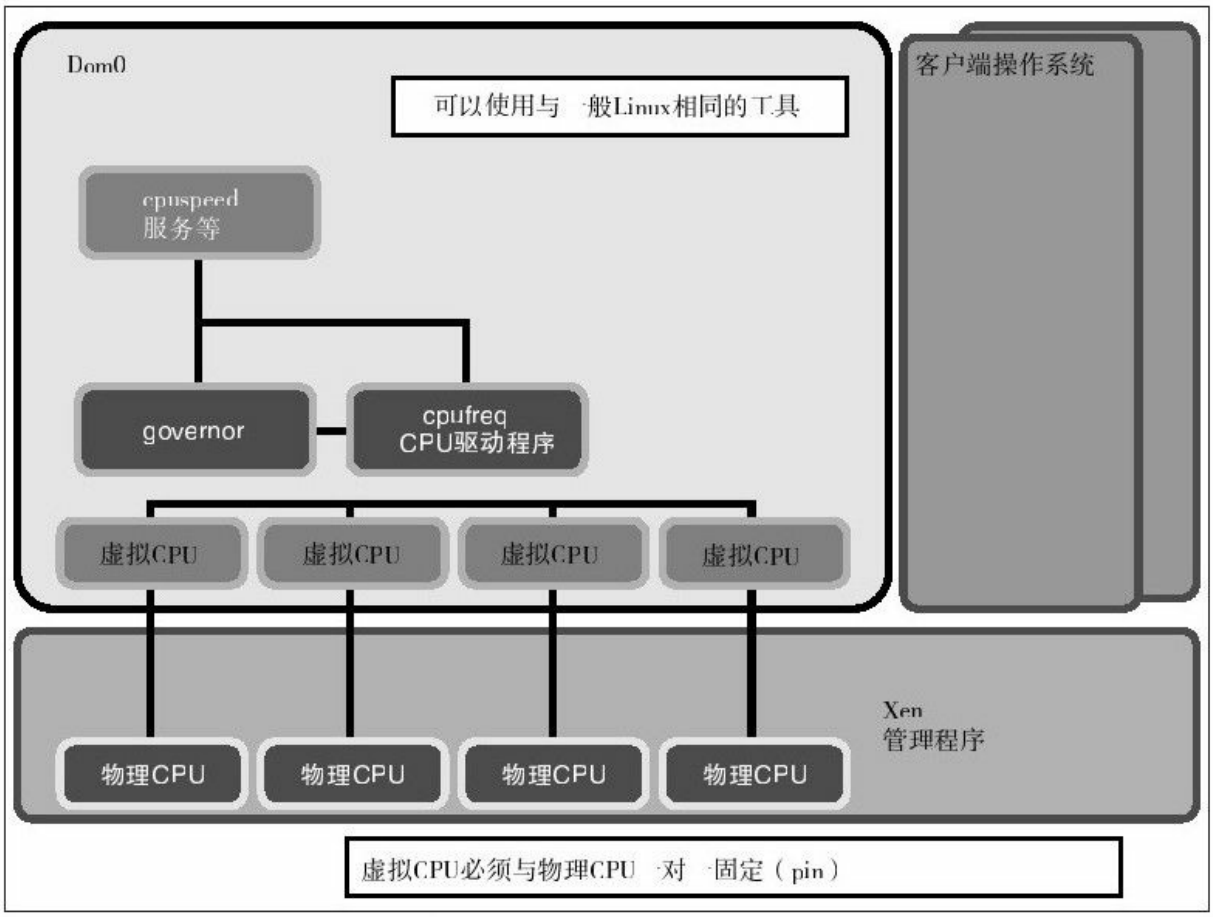

图　6-6　cpufreq=dom0-kernel时虚拟CPU和物理CPU的关系图

Xen3. 4以后可以通过在启动选项中指定cpufreq=xen来使用管理程序控制P状态的方式（也有RHEL5等无法使用的发布版）。策略等的设置必须由管理程序来进行，因此不使用cpuspeed服务，而是使用自身特有的工具xenpm。这种方式的优点是能够立即改变P状态。在cpufreq=dom0-kernel情形下，到Dom0的虚拟CPU被调度为止都不能改变P状态，但对于cpufreq=xen情形（如图6-7所示），是通过管理程序改变P状态的，因此必要时能够立即改变P状态。

```
title Xen
root（hd0，0）
kernel/boot/xen.gz cpufreq=xen
module/boot/vmlinuz-2.6.18.8-xen ro root=/dev/sda1
module/boot/initrd-2.6-xen.img
```

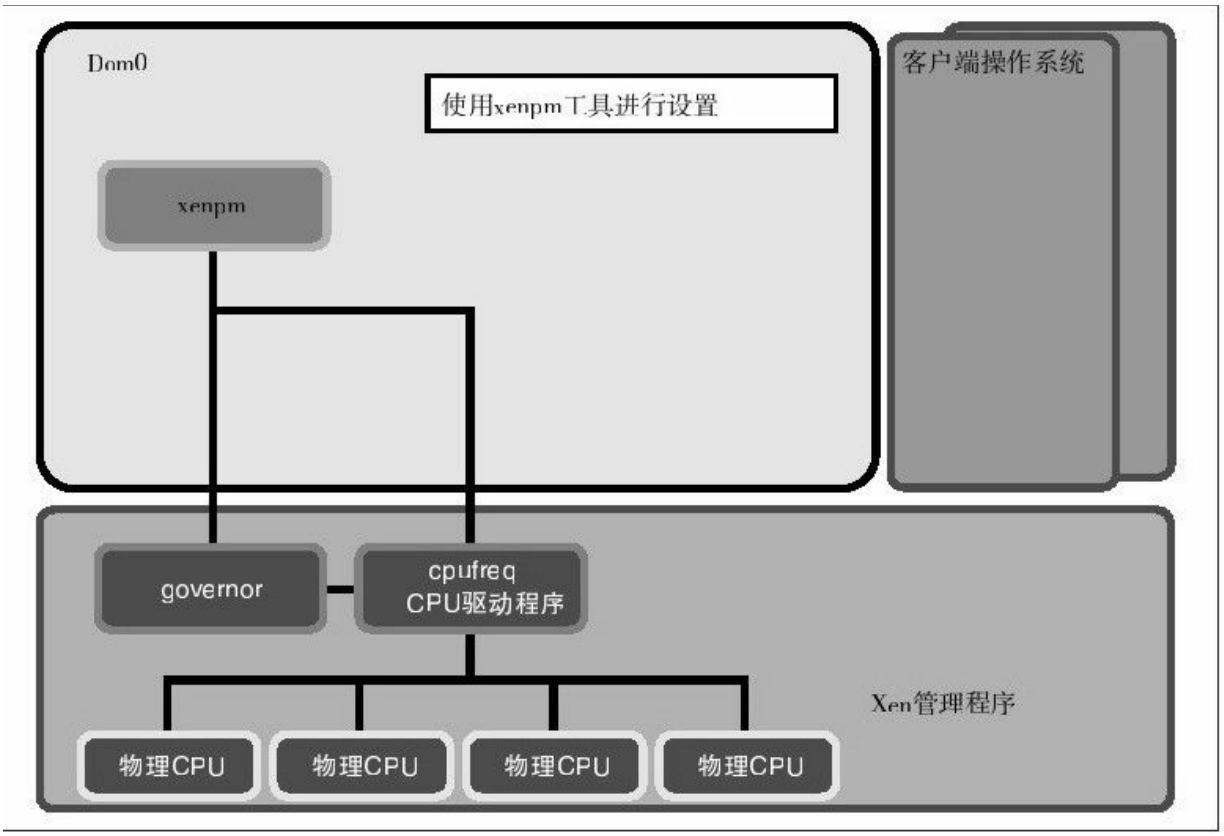

图　6-7　cpufreq=xen时的虚拟CPU和物理CPU的关系图

表6-18是xenpm的使用方法。设置为xenpm start，就可以像powertop实用程序（utility）一样观测CPU的C/P状态使用情况。

表 6-18　xenpm 的使用方法

子 命 令	变　量	说　明
get-cpuidle-states	[cupid]	显示指定 cpuid 的 CPU 或者所有的 cpuidle 信息（C 状态信息）
get-cpufreq-states	[cupid]	显示指定 cpuid 的 CPU 或者所有的 cpufreq 信息（P 状态信息）

（续）

子 命 令	变 量	说 明
get-cpufreq-para	[cupid]	显示指定 cpuid 的 CPU 或者所有的 cpufreq 设置信息
set-scaling-maxfreq	[cupid]<HZ>	在 <HZ> 中设置指定 cpuid 的 CPU 或者所有 CPU 的最大频率
set-scaling-minfreq	[cpuid]<HZ>	在 <HZ> 中设置指定 cpuid 的 CPU 或者所有 CPU 的最小频率
set-scaling-speed	[cpuid]<num>	在 <num> 中设置指定 cpuid 的 CPU 或者所有 CPU 的 scaling speed。用于 user space governor 的情形
set-scaling-governor	[cpuid]<gov>	在 <gov> 中设置指定 cpuid 的 CPU 或者所有 CPU 的 governor。可设置的 governor 有 userspace、performance、powersave、ondemand
set-sampling-rate	[cpuid]<num>	在 <num>（微秒）中设置指定 cpuid 的 CPU 或所有 CPU 的采样间隔。用于 ondemand governor
set-up-threshold	[cpuid]<num>	在 <num>（CPU 使用率）中设置指定 cpuid 的 CPU 或者所有 CPU 的阈值。用于 ondemand governor
start		获取 C 状态、P 状态的统计信息，在按下 CTRL+C 或收到 SIGINT 信号后输出结果

Xen的C状态

管理程序中安装有Xen的cpuidle子系统。要启用Xen的cpuidle子系统，需要按下列方法在管理程序的启动选项中添加cpuidle。

```
title Xen
root（hd0，0）
kernel/boot/xen.gz cpuidle
module/boot/vmlinuz-2.6.18.8-xen ro root=/dev/sda1
module/boot/initrd-2.6-xen.img
```

在多个CPU的系统中，将sched_smt_power_savings用做管理程序的启动选项就可以更加省电。

启用cpuidle时，如果系统运行出现异常，可以尝试在管理程序的启动选项中添加max_cstate=2和lapic_timer_c2_ok，限制使用的C状态。有时，在某些系统中也可以通过使用consistent_tscs启动选项来解决。

```
title Xen
root（hd0，0）
kernel/boot/xen.gz cpuidle max_cstate=2 lapic_timer_c2_ok
module/boot/vmlinuz-2.6.18.8-xen ro root=/dev/sda1
module/boot/initrd-2.6-xen.img
```

KVM的C/P状态

KVM上的客户端操作系统从主机操作系统来看，只能看到qemu这个进程。在KVM中Linux内核自身就是管理程序。因此，KVM中无须特别安装就可以直接使用Linux的省电功能。这是KVM的优点之一，使Linux内核中安装的大多数功能不需改造就可以作为管理程序的功能使用。也就是说，要在KVM上启用省电功能，只需像一般的Linux一样启用cpuspeed服务等（见图6-8）。

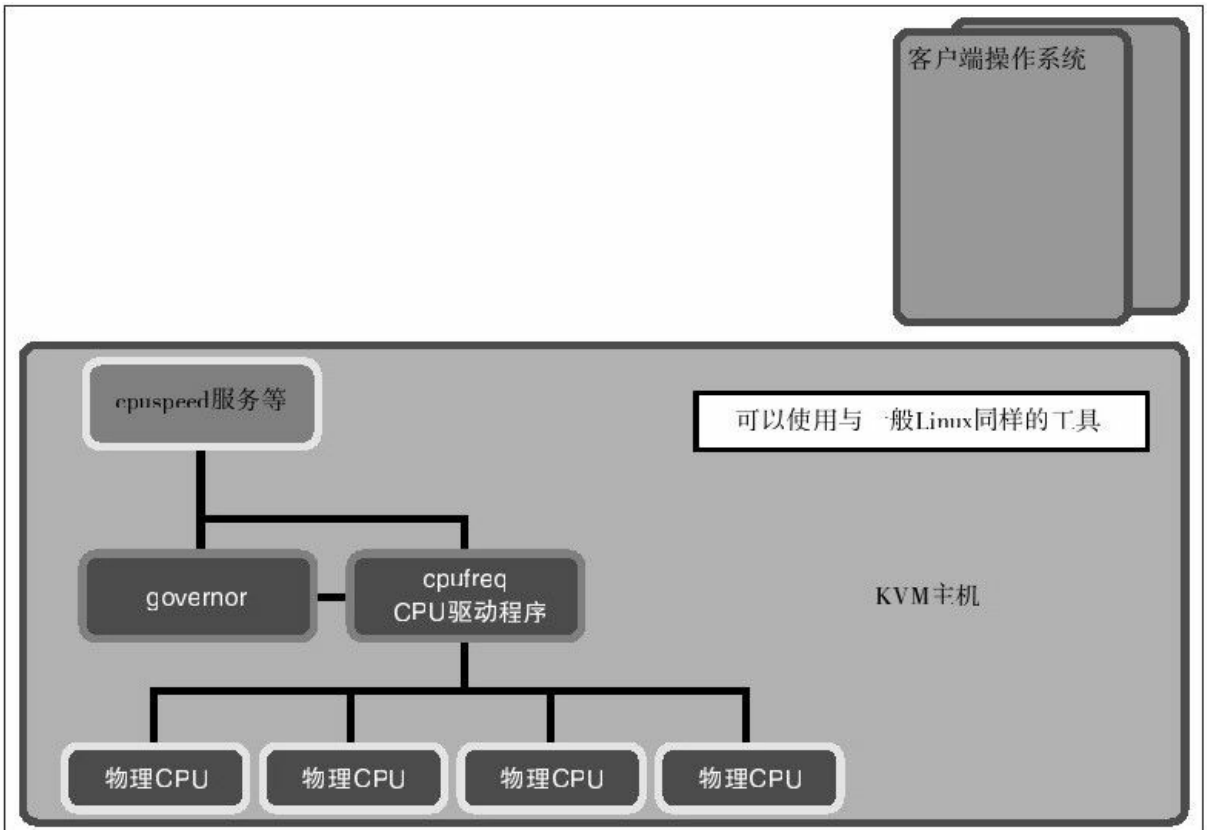

图　6-8　KVM的省电关系图

小结

本节介绍了虚拟环境下的省电功能。在数据中心等地方，存在多个管理程序的虚拟环境下，有时使用动态迁移（live migration）改变客户端操作系统运行的系统配置，就可以关闭系统本身。例如，在云（cloud）等环境下就考虑了注重省电的客户端操作系统配备逻辑。具体来说，有白天和黑夜将负载峰值不同的客户端操作系统在一个系统中运行的方法，计算管理程序资源的空闲容量将客户端操作系统动态移动到其他系统上的方法等。在虚拟环境下，对各个客户端操作系统的应答性能要求等是不同的，因此需要设计出满足各客户端操作系统的性能条件等的省电方法。

参考文献

·xenpm（http：//wiki. xensource.com/xenwiki/xenpm）

·OLS2007 How virtualization makes power management different（Kevin Tian, Ke Yu, Jun Nakajima, and Winston Wang）

——Akio Takebe

HACK#45　远程管理机器的电源

本节介绍使用WOL和IPMI远程管理机器电源的方法。

从远程接通或断开电源的方法有使用NIC（Network Interface Card）功能的WOL和IPMI（BMC）的方法。本节将介绍这些方法。

Wake On LAN

Wake On LAN（WOL）是指经由网络发送称为魔术包（magic packet）的特殊数据包，从网络设备接通系统电源的功能。

设置WOL

在使用WOL接入电源的机器上需要事先进行设置。首先，要在BIOS的设置中启用WOL（也称为Remote Power）的功能。

本节中使用的DELL机器是在BIOS设置界面上选择“Power Management”→“Remote Wake Up”，设置为On。

然后，在操作系统启动后，使用ethtool命令进行网络设备的设置。下面是英特尔82571EB千兆位以太网控制器的例子。

```
#ethtool eth4
Settings for eth4：
……
Transceiver：internal
Auto-negotiation：on
Supports Wake-on：pumbag……①
Wake-on：d……②
Current message level：0x00000001
Link detected：yes
#
```

①的Supports Wake-On显示的是这个网络设备所支持的魔术包的种类。每个拉丁字母为显示种类。详细内容可以使用man命令来确认。

```
p Wake on phy activity
u Wake on unicast messages
m Wake on multicast messages
b Wake on broadcast messages
a Wake on ARP
g Wake on MagicPacket（tm）
s Enable SecureOn（tm）password for MagicPacket（tm）
d Disable（wake on nothing）.
```

②的Wake-on：显示的是WOL的设置情况。在这个例子中为d，因此是关闭的。如果要启用WOL，可以使用ethtool的-s选项来设置。下面是启用MagicPacket的例子。

```
#ethtool-s eth4 wol g
#ethtool eth4|grep Wake-on
Supports Wake-on：pumbag
Wake-on：g
```

启用多个时需要执行下列命令。

```
#ethtool-s eth4 wol pumbag
#ethtool eth4|grep Wake-on
Supports Wake-on：pumbag
Wake-on：pumbag
```

这样就进行了WOL的设置，即使切断一次电源也可以从远程重新接通电源。使用ethtool命令启用了WOL的NIC，在切断电源后，如果连接上LAN电缆，LED也会闪光。

发送魔术包

在远程机器上发送称为魔术包的数据包作为接通电源的命令。

本Hack中使用的是net-tools工具包中的ether-wake命令。按照下列方式指定MAC地址，执行ether-wake命令，就可以发送魔术包。

```
#/sbin/ether-wake 00：10：60：60：60：01
```

设置密码

为保证安全，也可以设置密码。使用ethtool启用SecureOn。

```
#ethtool-s eth4 wol s
```

接下来设置密码。密码与MAC地址相似，设置以“：”分隔的4～6字节的字符串。下面是设置6字节密码的例子。

```
#echtool-s eth4 sopass xx：yy：zz：aa：bb：cc
```

在远程方按照下列方式指定密码，执行ether-wake命令。

```
#ether-wake-p xx：yy：zz：aa：bb：cc 00：10：60：60：60：01
```

IPMI

IPMI中有LAN接口。可以使用这个接口通过网络从远程进行电源管理。

由于WOL在接收地址中指定MAC地址，因此在有些网络结构下魔术包无法到达。而IPMI可以将IP地址指定为接收地址进行电源管理，因此IPMI比WOL更为通用。

设置IPMI

事先安装关于IPMI的数据包。

```
#yum install OpenIPMI.x86_64
```

由于使用ipmitool命令，因此需要安装OpenIPMI-tools。

```
#yum install OpenIPMI-tools.x86_64
```

Fedora 12等中的工具包名称有所不同，称为ipmitool。安装ipmitool。

```
#yum install ipmitool.x86_64
```

由于要将IPMI模块安装到内核中，因此需要启动ipmi。

```
#/etc/init.d/ipmi start
```

小贴士：如果ipmi启动失败，可能是该机器中未配置IPMI。

设置IPMI LAN接口

IPMI中有多个接口。这些接口称为信道（channel）。不同机器的信道编号也不相同，因此首先需要确认哪个信道编号相当于LAN接口。按照下列方式一个一个地指定信道编号，执行ipmitool。

```
#ipmitool channel info 0
Channel 0x0 info：
Channel Medium Type：IPMB（I2C）
Channel Protocol Type：IPMB-1.0
Session Support：session-less
Active Session Count：0
Protocol Vendor ID：7154
#ipmitool channel info 1
Channel 0x1 info：
Channel Medium Type：802.3 LAN……①
Channel Protocol Type：IPMB-1.0
Session Support：multi-session
Active Session Count：0
Protocol Vendor ID：7154
Volatile（active）Settings
Alerting：disabled
Per-message Auth：disabled
User Level Auth：enabled
Access Mode：disabled……②
Non-Volatile Settings
Alerting：disabled
Per-message Auth：disabled
User Level Auth：enabled
Access Mode：disabled
```

这个机器的信道编号1为LAN接口。通过①就可以确认其为LAN接口。

当②为disabled时，使用下列命令启用。

```
#ipmitool lan set 1 access on
#ipmitool channel info 1
Channel 0x1 info：
Channel Medium Type：802.3 LAN
……
Volatile（active）Settings
……
Access Mode：always available
Non-Volatile Settings
……
Access Mode：always available
```

这时就可以确认LAN接口的设置内容。

```
#ipmitool lan print
Set in Progress：Set Complete
Auth Type Support：NONE MD2 MD5 PASSWORD
Auth Type Enable：Callback：MD2 MD5
：User：MD2 MD5
：Operator：MD2 MD5
：Admin：MD2 MD5
：OEM：MD2 MD5
```

IP Address Source：Static Address
IP Address：0.0.0.0
Subnet Mask：0.0.0.0
MAC Address：00：19：19：19：19：1a
SNMP Community String：public
IP Header：TTL=0x40 Flags=0x40 Precedence=0x00 TOS=0x10
Default Gateway IP：0.0.0.0
Default Gateway MAC：00：00：00：00：00：00
Backup Gateway IP：0.0.0.0
Backup Gateway MAC：00：00：00：00：00：00
802.1q VLAN ID：Disabled
802.1q VLAN Priority：0
Cipher Suite Priv Max：Not Available

由于没有设置IP地址，因此使用ipmitool设置。

有的服务器在一般的LAN设备之外准备了IPMI专用的管理端口，有的服务器是共享LAN设备。在共享的情况下，IPMI的LAN接口在内部与一般LAN设备相连接。在这种情况下设置IPMI的LAN接口的IP地址时，要使段（segment）与一般LAN设备相同。

#ifconfg
eth0 Link encap：Ethernet HWaddr 00：19：19：19：19：18
inet addr：192.168.0.220 Bcast：192.168.0.255 Mask：255.255.255.0
……
#ipmitool lan set 1 ipaddr 192.168.0.221
Setting LAN IP Address to 192.168.0.221
#ipmitool lan set 1 netmask 255.255.255.0
Setting LAN Subnet Mask to 255.255.255.0
#ipmitool lan print
……
I P A d d r e s s S o u r c e：Static Address
IP Address：192.168.0.221
Subnet Mask：255.255.255.0
MAC Address：00：19：b9：f7：8f：1a
……

还可以通过DHCP获取IP地址。

#ipmitool lan set 1 ipsrc dhcp
#ipmitool lan print
……
IP Address Source：DHCP Address
IP Address：10.2.0.134
Subnet Mask：255.255.255.0
MAC Address：00：17：a4：3f：18：82
……

从远程机器执行下列命令，就可以确认电源状态。

#ipmitool-I lan-H 192. 168.0.221-P""chassis power status Chassis Power is on

在-H选项中指定IP地址或主机名称。-P为密码。默认为NULL。当然也可以设置为任意短语（phase）。命令的最后指定了确认电源状态的status，除此以外，还有其他命令，如表6-19所示。

表6-19 chassis power命令列表

命令选项	说　明
status	显示电源的状态
on	接通电源
off	断开电源
cycle	重新启动。至少等待1秒钟直到断开电源为止。电源断开后，重新接入电源
reset	执行硬启动（hard reset）。瞬时重启
diag	使CPU发生NMI
soft	通过ACPI执行操作系统的软关闭（soft shutdown）。等同于按下电源按钮的情况，因此由操作系统执行一般的关闭处理（clean shutdown）

像下面这样指定为on，就可以从远程接通电源。

```
#ipmitool-I lan-H 192.168.0.221-P""chassis power on
```

小结

本节介绍了从远程对机器的电源进行操作的功能。WOL将MAC地址作为接收地址接通电源。只要NIC能够对应，无论笔记本电脑还是台式机都可以使用。但是由于位于网络中的以太网交换机的种类或设置，魔术包有时无法到达。

如果使用IPMI，就可以将IP地址作为接收地址接入电源。还可以确认电源的状态或切断电源。但是必须安装有IPMI（BMC），因此仅限定于服务器等的机器。

通过这些功能就可以控制机器的电源，抑制电能消耗。

使用IPMI还可以控制NMI的产生和硬重启，因此也可以用于开发Linux内核时的调试等。

参考文献

·Intelligent Platform Management Interface Specification

http://www. intel.com/design/servers/ipmi/

——Naohiro Ooiwa

HACK#46　USB的电力管理

Linux中可以对经由sysfs的USB设备进行电力管理，本节介绍这种管理电力的方法。

概要

从Linux内核2.6.21开始安装了USB设备的自动待机（auto suspend）功能。自动待机是指USB设备在一定时间内一直保持空闲状态时，内核自动使USB设备待机的功能。要使用USB设备时自动重启（auto resume）。

也可以手动进行待机。不需要将USB线拔出后再插上就可以重新开始（resume）供电。自己编译内核时，需要将内核的config设置为CONFIG_PM_RUNTIME=y、CONFIG_USB_SUSPEND=y。make menuconfig有下列内容。

Power management and ACPI options--->
Run-time PM core functionality
Device Drivers--->
USB support--->
USB runtime power management（suspend/resume and wakeup）

设置方法

在sysfs的文件/sys/bus/usb/devices/＜USB设备ID＞/power/中进行设置。下面介绍其中的一些设置选项。

/sys/bus/usb/devices/＜USB设备ID＞/power/autosuspend

这个文件设置的是各个USB设备切换到自动待机为止的时间（秒）。标准设置值为2秒。USB设备处于空闲状态达到2秒以上时，内核就会自动使该设备待机。设置为0时，USB设备一旦空闲就尽快待机。设置为-1时，关闭自动待机。

值的更改通过下列命令来进行。

```
#echo 5＞/sys/bus/usb/devices/＜USB设备ID＞/power/autosuspend
```

小贴士：标准设置的2秒这个值是在/sys/module/usbcore/parameters/autosuspend中设置的。如果将/sys/modules/usbcore/parameters/autosuspend改为5，则新连接的USB设备的/sys/bus/usb/devices/＜USB设备ID＞/power/autosuspend的标准设置值也为5秒。/sys/modules/usbcore/parameters/autosuspend还可以通过内核启动参数usbcore.autosuspend=＜值＞来更改。

USB设备ID是指内核对USB设备添加的编号。下面是台式机的例子。编号为1～7。

$ls/sys/bus/usb/devices/

```
1-0：1.0 3-0：1.0 5-0：1.0 6-2 7-0：1.0 7-1：1.0 usb2 usb4 usb6
2-0：1.0 4-0：1.0 6-0：1.0 6-2：1.0 7-1 usb1 usb3 usb5 usb7
```

连接USB存储器后，就会输出如下所示的内核信息。

```
#dmesg
……
```

usb 1-3：new high speed USB device using ehci_hcd and address 21检测到新的连接
usb 1-3：configuration#1 chosen from 1 choice
scsi25：SCSI emulation for USB Mass Storage devices
usb-storage：device found at 21
usb-storage：waiting for device to settle before scanning
usb-storage：device scan complete
scsi 25：0：0：0：Direct-Access BUFFALO USB Flash Disk 3.10 PQ：0
ANSI：0 CCS
sd 25：0：0：0：[sdb]2015232 512-byte hardware sectors（1032 MB）
sd 25：0：0：0：[sdb]Write Protect is off
sd 25：0：0：0：[sdb]Mode Sense：23 00 00 00
sd 25：0：0：0：[sdb]Assuming drive cache：write through
sd 25：0：0：0：[sdb]2015232 512-byte hardware sectors（1032 MB）
sd 25：0：0：0：[sdb]Write Protect is off
sd 25：0：0：0：[sdb]Mode Sense：23 00 00 00
sd 25：0：0：0：[sdb]Assuming drive cache：write through
sdb：unknown partition table
sd 25：0：0：0：[sdb]Attached SCSI removable disk
sd 25：0：0：0：Attached scsi generic sg2 type 0

这时的USB设备ID为1～3。下面是连接了CD-ROM驱动器时输出的内核信息的例子。USB设备ID为1～4。

#dmesg
……
usb 1-4：new high speed USB device using ehci_hcd and address 22
usb 1-4：configuration#1 chosen from 1 choice
scsi26：SCSI emulation for USB Mass Storage devices
usb-storage：device found at 22
usb-storage：waiting for device to settle before scanning
usb-storage：device scan complete
scsi 26：0：0：0：CD-ROM GENERIC DVD-ROM B763B 1.00 PQ：0
ANSI：0
sr1：scsi3-mmc drive：24x/24x cd/rw xa/form2 cdda tray
sr 26：0：0：0：Attached scsi CD-ROM sr1
sr 26：0：0：0：Attached scsi generic sg3 type 5

这样连接USB设备后，输出内核信息，目录下就会变成下列内容。

```
# ls
1-0:1.0  1-4      3-0:1.0  6-0:1.0  7-0:1.0  usb1  usb4  usb7
1-3      1-4:1.0  4-0:1.0  6-2      7-2      usb2  usb5
1-3:1.0  2-0:1.0  5-0:1.0  6-2:1.0  7-2:1.0  usb3  usb6
```

此外，使用/sys/bus/usb/devices/＜USB设备ID＞/product、lsusb命令等也可以确认所连接的USB设备。

#cat/sys/bus/usb/devices/5-2/product

USB Optical Mouse
$lsusb
……
Bus 005 Device 002：ID 0461：4d15 Primax Electronics, Ltd Dell Optical Mouse
……

在/sys/bus/usb/devices/＜USB设备ID＞/power/level中设置auto就可以启用自动待机功能。默认设置为on，因此需要使用下列命令改为auto。

```
#echo auto＞/sys/bus/usb/devices/＜USB设备ID＞/power/level
```

这样就启用了自动待机功能。但是这个功能比较难以确认。即使USB设备通过自动待机进入待机状态，从外表上也是看不出变化的。

其中USB激光鼠标是比较容易看出效果的一种设备。鼠标经过一定秒数后，背面LED的红光就会消失。这就是已待机的状态。这时鼠标也不会自动移动。单击鼠标的按钮才会自动恢复。LED也发出红光，鼠标就进入可使用状态。

键盘在经过一定秒数后也会自动待机，但从键盘的外观就看不出变化。按键后才会自动恢复。而在按下Numlock键、Shift+CapsLock键、ScreenLock键之一的状态下不会进入自动待机模式。

在USB存储器、CD-ROM设备、软盘驱动器等其他设备上也进行了尝试，但有一些设备内部事件发生频繁，不会进入自动待机模式。

想要确认是否进入自动待机模式，可以启用内核编译选项Device Driver→USB support→USB verbose debug message，重新编译内核，就可以通过内核信息确认自动待机和自动恢复。

/sys/bus/usb/devices/＜USB设备ID＞/power/level

在这个文件中设置on、auto。默认为on。到内核2.6.32为止还可以设置suspend。

如前所述，如果设置为auto，就可以启用USB设备的自动待机和自动恢复。

按下列方式设置，则对USB设备待机。

```
#echo suspend＞/sys/bus/usb/devices/＜USB设备ID＞/power/level
```

设备的LED熄灭，在操作系统上也识别不到设备。

指定为on时，就会向待机状态下的USB设备供电。与重新接上USB线时的运行情况相同。

```
#echo on＞/sys/bus/usb/devices/＜USB设备ID＞/power/level
```

/sys/bus/usb/devices/＜USB设备ID＞/power/connected_duration

/sys/bus/usb/devices/＜USB设备ID＞/power/active_duration

从内核2.6.25开始安装了connected_duration和active_duration。connected_duration为USB设备处于连接状态的总时间。单位为毫秒。active_duration为USB设备运行的总时间，也就是USB设备未待机的时间。单位也为毫秒。可以通过这些值来确认自动待机的效果或待机的时间。

下面是刻意待机约10秒的例子。active_duration的值比connect_duration小。

```
#cd/sys/bus/usb/devices/2-1/power/
#head*duration
==＞active_duration＜==
23100994
==＞connected_duration＜==
23100994
#echo suspend＞level；sleep 10；echo on＞level
#head*duration
==＞active_duration＜==
23124290比connected_duration还要少约10 000毫秒
==＞connected_duration＜==
23134371
```

小结

本节介绍了如何管理USB设备电力的自动待机功能。如果USB设备持续处于空闲状态，Linux内核就会自动将使USB设备待机。一旦使用到USB设备，就会自动恢复。

参考文献

·Document/usb/power-management. txt

——Naohiro Ooiwa

HACK#47　显示器的省电

本节介绍关于显示器的省电方法。

显示器的电源控制

关于显示器的硬件规格有Video Electronics Standards Association（VESA）标准中的DPMS（Display Power Management Signaling）。DPMS有on、standby、suspend、off模式，对于视频控制器和显示器也有规定。ACPI的规格中配合DPMS规格定义了D状态。表6-20和表6-21分别是LCD和视频控制器的规格，以供参考。

表 6-20　LCD 设备的规格

状　态	DPMS 状态	说　明
D0	on	显示器完全 on 的状态。亮度完全 on 的状态。画面为显示状态
D1	standby	显示器完全 off。画面为无显示状态。到恢复 D0 状态的延迟时间必须为 500 毫秒[注3]以下。这个状态有可能未安装。与 D3 状态不同的是一旦接收到 resume 请求，驱动程序就会将显示器恢复到原来的状态。显示器在内部保存状态，有可能抑制耗电量
D2	suspend	显示器完全 off。画面为无显示状态。到恢复 D0 状态为止的延迟时间为 500 毫秒[注4]以下。这个状态有可能未安装。与 D3 状态不同的是，一旦接收到 resume 请求，驱动程序就会将显示器恢复到原来的状态。显示器保存状态，可以抑制耗电量
D3	off	显示器不工作的状态。显示器为完全 off 状态。画面为无显示状态。通知已无电源。到恢复 D0 状态的延迟时间为 500 毫秒[注5]以下

[2] [3]

表 6-21　视频控制器的规格

状　态	DPMS 状态	说　明
D0	on	连接到控制器的设备为 on 状态。视频控制器保存内容。保存视频存储器的内容
D1	standby	连接到控制器的设备（除显示器 /LCD 控制信号以外）为 off 状态。视频控制器保存内容。保存视频存储器的内容。到恢复 D0 状态为止的延迟时间为 100 毫秒以下
D2	suspend	连接到控制器的设备（除显示器 /LCD 控制信号以外）为 off 状态。视频控制器不保存内容。视频存储器的内容不保存。到恢复 D0 状态为止的延迟时间为 200 毫秒以下
D3	off	连接到控制器的设备为 off 状态。视频控制器不保存内容（也停止供电）。视频存储器的内容不保存（也停止供电）。到恢复 D0 状态为止的延迟时间为 200 毫秒以下

在命令行进行这些DPMS设置时可以使用xset命令等，表6-22是使用xset命令的例子。

表 6-22　使用 xset 命令的例子

命　令	说　明
xset -dpms	将 DPMS 设置为 off
xset +dpms	将 DPMS 设置为 on
xset dpms force on	强制设置 DPMS 的 on 模式
xset dpms force standby	强制设置 DPMS 的 standby 模式
xset dpms force suspend	强制设置 DPMS 的 suspend 模式
xset dpms force off	强制设置 DPMS 的 off 模式

[1]新设备中使用的是100毫秒，DPMS中规定必须在5秒以下。

[2]新设备中使用的是100毫秒，DPMS中规定为10秒以下。

[3]新设备中使用的是100毫秒，DPMS中未规定到恢复为止的延迟时间。

显示器的亮度控制

ACPI中还有控制亮度的规格，如果DSDT中有控制亮度的定义块，就可以进行亮度控制。亮度控制所需的主要是ACPI的定义块中定义的_BCL、_BCM、_BQC方法。要确认ACPI的定义块请参考Hack#40。

还准备了从键盘的功能键等通知更改显示器亮度的结构。

_BCL（Query List of Brightness Control Levels Supported）

通过这个方法，操作系统可获取内置显示器设备所支持的亮度水平的列表。另外还显示LCD是否支持更改亮度水平。将亮度水平分别用0～100的数字来表示百分比。

参数	无
返回值	包括所支持的亮度水平的整数列表的 Package

```
Method（_BCL，0）{
//List of supported brightness levels
Return（Package（7）{
80，//level when machine has full power
50，//level when machine is on batteries
//other supported levels：
20，40，60，80，100
}
}
```

_BCM（Set the Brightness Level）

通过这个方法，操作系统设置内置显示器设备的亮度。

操作系统只能设置通过BCL获取的值。

参数	要设置的亮度水平的整数
返回值	无

_BQC（Brightness Query Current level）

这个方法返回当前的亮度水平。

参数	无
返回值	当前的亮度水平的整数

除ACPI以外，也有厂商固有的视频控制，但Linux中有控制背光灯的子系统，可以经由/sys来进行。

表 6-23 /sys/devices/virtual/backlight/acpi_videoN/ 的接口

接口名称	功 能
actual_brightness	当前的亮度水平
brightness	读入则显示 user 最后设置的亮度水平。写入则改变亮度水平。把亮度水平的更改通知到背光灯
max_brightness	最大亮度

现在已经出现了一些用于显示器省电控制的便捷的应用程序。Fedora 13等中可以使用名为gnome-preference的应用程序来设置显示器的亮度等（见图6-9）。

使用xbacklight命令还可以调节显示器的亮度。

根据需要可以安装xbacklight工具包。

#yum install xbacklight

图　6-9　gnome-power-preference的设置界面

表 6-24　xbacklight 命令的使用方法

命　令	说　明
xbacklight -get	以百分比形式显示当前亮度
xbacklight -set <百分比>	设置为指定的亮度
xbacklight -inc <百分比>	在当前亮度上增加指定的百分比
xbacklight -dec <百分比>	在当前亮度上减少指定的百分比
xbacklight -time <毫秒>	到变为新亮度为止的时间
xbacklight -steps <数值>	变为新亮度时的单步（step）次数

下面是使用xbacklight命令的例子。

#xbacklight-steps 10-time 1000-dec 50

小结

本节介绍了显示器的控制方法。除此以外，还有如下所示的显示器省电方法。

·为了抑制图形设备的负载，将桌面的壁纸换成单一颜色。

·在LCD的显示器上使用有抑制背光效果的颜色。

小贴士：液晶显示器有normally white（白色背光）型和normally black（黑色背光）型，一般normally white使用白色比较省电，normally black使用黑色比较省电。视角较狭窄或20型以下的液晶显示器多为normally white型。

·干脆不使用显示器（用于服务器等）

方法是多种多样的，可以根据各自的目的来选择适合的省电方法。

参考文献

·Advanced Configuration and Power Interface Specification Revision 4. 0

——Akio Takebe

Black Google

有些网站为了省电，想用黑色作为显示器的显示颜色。

在CRT（阴极射线管）显示器上，黑色比白色更为省电，因此就出现了将白底的Google检索画面改成黑色的Black Google。简单检索一下，就找到了下列网页。

http://black-google. blogspot.com/
http://www. google.com/intl/en/
http://www. blackl.com/black-google.html
http://www. blackgoogle.eu/
http://black-google. net/
http://www. blackle.com/

这些网页都把Google检索画面改成了黑底（均为写作过程中存在的URL。现在有些已经无法连接）。

在CRT上黑色是不耗电的，因此能产生效果。但是最近LCD（液晶显示器）已经普及。相反，LCD是白色不耗电，但也有一些新的LCD抑制黑色显示效果的耗电量。在SHARP的AQUOS（42寸，关闭省电功能）上进行了测定。测定的情况如图6-10所示，测定结果如图6-11所示。

图　6-10　测定的情形

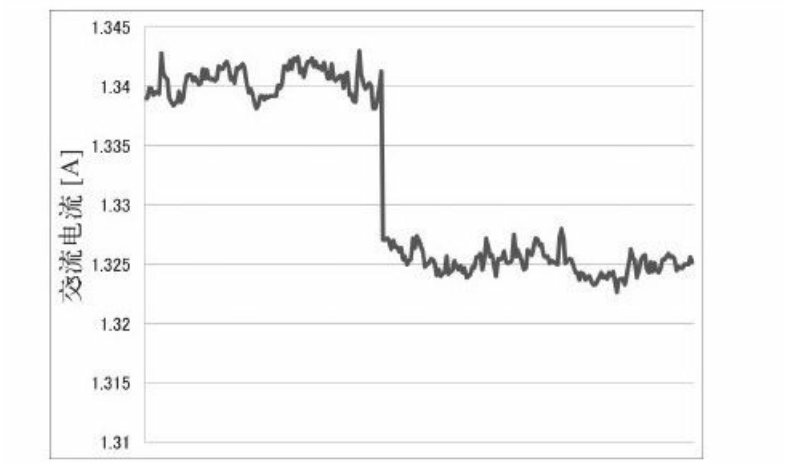

图　6-11　gnome-power-preference的设置界面

将笔记本电脑连接到AQUOS，测定Web浏览器显示一般的Google画面和设置为Black Google时的电流值。图6-11是反映电流变化的图表。中间电流急剧下降的地方正好从白色Google画面切换到Black Google的时刻。表6-25所示为大致的平均值。通过本次测定确认了Black Google更为省电。

表 6-25　Google 界面与大致的交流电流值

界面	交流电流值
一般的白色 Google	1.34A
Black Google	1.325A

HACK#48　通过网络设备节省电能

本节介绍通过控制网络设备节省电能的方法。

本节将介绍Intel Less Watts项目提出的省电方法和笔者实际向论坛发布的Hack方案。

禁用WOL

如果启用Hack#45中介绍的WOL（Wake On LAN），那么机器的电源关闭后也会消耗极少的电能。

如果不使用WOL，可以禁用它。

```
#ethtool-s eth0 wol d
```

降低速度

最近，千兆位以太网成为网络设备的主流。但是有的时间段内，较低的通信速度可能就足够了。如果某种程度上可以预测到这个时间段，就可以通过降低通信速度来抑制电能消耗。

网络设备的速度可以使用ethtool命令来更改。使用下列命令就可以设置为100Mbps。其自动协商（auto negotiation）功能也禁用。

```
#ethtool-s eth0 autoneg off speed 100
```

要回到1000Mbps，可以执行下列命令。

```
#ethtool-s eth0 autoneg on speed 1000
```

使用ethtool控制通信速度就可以节省电能。

在降低性能节省电能这个想法上与CPU的C状态、P状态是相同的。

进行改造

前面介绍的是LessWatts项目。下面介绍从另一个角度改善网络设备的例子。使用ifdown命令明确禁用网络设备就可以省电。

下面是安装在e1000设备驱动程序中的补丁。

Signed-off-by：Naohiro Ooiwa＜nooiwa@miraclelinux.com＞---
drivers/net/e1000/e1000_main.c|32++++++++++++++++++++++++++++++
1 files changed，32 insertions（+），0 deletions（-）
diff--git a/drivers/net/e1000/e1000_main.c b/drivers/net/e1000/e1000_main.c index bcd192c..12e1a42 100644
---a/drivers/net/e1000/e1000_main.c
+++b/drivers/net/e1000/e1000_main.c
@@-26，6+26，11@@
***/
+/*
+*define this if you want pci save power while ifdown.
+*/
+#define E1000_PCI_POWER_SAVE
+
#include"e1000.h"
#include＜net/ip6_checksum.h＞
@@-1248，6+1253，23@@static int e1000_open（struct net_device*netdev）
struct e1000_hw*hw=＆adapter-＞hw；
int err；
+#ifdef E1000_PCI_POWER_SAVE
+struct pci_dev*pdev=adapter-＞pdev；
+
+pci_set_power_state（pdev, PCI_D0）；
+pci_restore_state（pdev）；
+
+if（adapter-＞need_ioport）
+err=pci_enable_device（pdev）；
+else
+err=pci_enable_device_mem（pdev）；
+if（err）{
+printk（KERN_ERR"e1000：Cannot enable PCI device from power-
save\n"）；
+return err；
+}
+pci_set_master（pdev）；
+#endif
+
/*disallow open during test*/
if（test_bit（__E1000_TESTING，＆adapter-＞flags））
return-EBUSY；
@@-1265，6+1287，7@@static int e1000_open（struct net_device*netdev）
goto err_setup_rx；
e1000_power_up_phy（adapter）；
+e1000_reset（adapter）；
adapter-＞mng_vlan_id=E1000_MNG_VLAN_NONE；

```
if（（hw-＞mng_cookie.status＆
@@-1341，6+1364，15@@static int e1000_close（struct net_device*netdev）
e1000_vlan_rx_kill_vid（netdev, adapter-＞mng_vlan_id）；
}
+#ifdef E1000_PCI_POWER_SAVE
+#ifdef CONFIG_PM
+pci_save_state（adapter-＞pdev）；
+#endif
+pci_disable_device（adapter-＞pdev）；
+pci_wake_from_d3（adapter-＞pdev, true）；
+pci_set_power_state（adapter-＞pdev, PCI_D3hot）；
+#endif
+
return 0；
}
--1.5.4.1
```

在ifdown命令处理（e1000_close函数）的最后，调用pci_wake_from_d3（），启用PCI的Power Management寄存器的PME pin。使用pci_set_power_state（）将设备改为D3状态。执行ifup命令时回到D0状态。

最近像电视这样的数码家电产品中也安装了网络设备。但是电视实际上大部分时间都只是用来收看节目。在这种情况下，如果可以使用应用程序ifdown，仅在连接网络的时候执行ifup命令，就可以减少耗电量。

注意事项：这个补丁正在开发中。还未能考虑支持ethtool命令。因此如果安装了这个补丁，执行ethtool命令的一些选项，就会死机。论坛称当ethtool也能够顺利运行时，就会合并这些选项。

小结

本节探讨了网络设备省电的可能性。基本原则是“不使用时就彻底断电”。CPU等在Linux中也已进行了设备省电的改善。但是设备驱动程序数量非常多，还有一些不支持省电功能的。可以尝试对已有的设备驱动程序进行新的修改，相信会很有意思的。

参考文献

·LessWatts. org Tips＆Tricks Ethernet

http://www. lesswatts.org/tips/ethernet.php

·IEEE 802. 3 Energy Efficient Ethernet Study Group

http://www. ieee802.org/3/eee_study/index.html

·Linux Foundation Collaboration Summit 2009 Green Linux Saving Large Amounts of Energy With Network Connectivity Proxying

http://events. linuxfoundation.org/archive/lfcs09_nordman.pdf

·Linux Foundation Collaboration Summit 2009 Green Linux Survey of Green IT in Linux and Tooling to Support Measuring Electrical Power Consumption

http://events. linuxfoundation.org/archive/lfcs09_ooiwa.pdf

·カーネルドキメントPCI Power Management

Documentation/power/pci. txt

——Naohiro Ooiwa

HACK#49　关闭键盘的LED来省电

为了尽量减少电能消耗，关闭键盘LED灯等，对键盘进行控制。

小时候，父母经常教育我“房间里没人的时候要关灯”。突然看到键盘上还有LED灯闪着美丽的光芒却无人欣赏。要省电就必须关掉这些没有必要的LED。使用无线键盘等时，为了抑制电能消耗，可能会想要关闭显示键盘NumLock是否启用的LED等。这种情况下禁用NumLock也可以，这里介绍的是启用NumLock的同时关闭LED的方法。首先介绍怎样控制键盘，即PS/2键盘的规格。

PS/2键盘

我第一次接触电脑的时候，说起键盘，都是PS/2连接的。我家的电脑至今还有PS/2连接的键盘。AT键盘和PS/2键盘是IBM发布的主流键盘。PS/2键盘是作为能够与AT键盘互换的键盘发布的。PS/2是AT的扩展，添加了一些命令。笔者家用的键盘是PS/2兼容的键盘，但是操作系统启动时显示的是AT互换键盘。也有不少键盘不支持PS/2的所有命令。IBM原本只是将Intel i8042作为键盘输入的编码用控制器使用。

因此，PS/2兼容键盘一般是以PS/2兼容模式连接到Intel i8042互换芯片组的。PS/2连接的键盘，是通过PC主板上的i8042互换控制器（板载的微控制器）与键盘中的微控制器（键盘微控制器）进行通信来控制键盘。可以使用in命令、out命令经由0x60、0x64的I/O端口从CPU访问控制器。

通过读出（in命令）I/O端口0x64，就可以检查板载微控制器的状态。板载微控制器的Status寄存器各位的意义如表6-26所示。

表 6-26　板载微处理器的状态

位	说　明
0	OBF（Output Buffer Full）（1= 有数据，0= 空）
1	IBF（Input Buffer Full）（1= 有数据，0= 空）
2	系统标志 system flag（1= 启动完成，0= 正在启动）
3	命令 / 数据（0= 由 IO 端口 0x60 处理数据，1= 由 IO 端口 0x64 处理命令）
4	Inhibit Switch（1= 启用键盘，0= 禁用键盘）
5	Auxiliary Device Output Buffer Full（1= 传输错误，0= 正常）
6	General Time-out（1= 键盘超时，0= 正常）
7	Parity error（1= 奇偶错误，0= 正常）

针对I/O端口0x64执行Write（out命令）就可以向板载控制器发送命令。针对I/O端口0x60的Write命令被发送到键盘微控制器。

从键盘微控制器发送的数据，从I/O端口0x60读出。用于读取一般键盘输入等的数据。Status的第0位和第1位用于信号交换（握手）。在向I/O端口0x60、0x64进行写入（发送命令）前需要确认第0位是否为0（Output Buffer empty）。当第1位为1（Input Buffer full）时，可以从I/O端口0x60读取数据。细节参见表6-27。

表 6-27　板载微控制器（端口 0x64）

值	说　明
0x20	将板载微控制器的命令字节的结果传递给 I/O 端口 0x60
0x60	将写入 I/O 端口 0x60 的下一个内容发送到板载微控制器的命令字节
0xA4	测试是否设置了密码（仅 PS/2）。把结果发送到 I/O 端口 0x60。0xFA 表示设置了密码，0xF1 表示没有密码
0xA5	传递密码（仅 PS/2）。依次导入写入 I/O 端口 0x60 的内容，直到写入 NULL 文字为止。将所写的内容作为新密码
0xA6	启用密码
0xA7	禁用鼠标设备（仅 PS/2）。与把命令字节的第 5 位设置为 1 表示相同的意义
0xA8	启用鼠标设备（仅 PS/2）。与把命令字节的第 5 位清 0 表示相同的意义
0xAD	禁用键盘。将命令字节的第 4 位设置为 1
0xAE	启用键盘。将命令字节的第 4 位设置为 0
0xC0	将键盘的输入端口读取到 I/O 端口 0x60
0xC1	将输入端口（上述）第 0 ～ 3 位复制到 Status 的第 4 ～ 7 位（仅 PS/2）
0xC2	将输入端口（上述）第 4 ～ 7 位复制到 Status 的第 4 ～ 7 位（仅 PS/2）
0xD0	将板载微控制器的输出端口的值复制到 I/O 端口 0x60（参考以下定义）
0xD1	将写入 I/O 端口 0x60 的下一个内容发送到板载微控制器的输出端口
0xD2	向键盘缓冲区写入。将写入 I/O 端口 0x60 的下一个值作为生成的键盘输入的值返回板载微控制器（仅 PS/2）
0xD3	向鼠标缓冲区写入。将写入 I/O 端口 0x60 的下一个值作为生成的鼠标操作的值返回板载微控制器（仅 PS/2）
0xD4	将写入下一个 I/O 端口 0x60 的数据输出到鼠标（辅助）设备（仅 PS/2）
0xE0	读取测试输入，向 I/O 端口 0x60 返回测试结果 第 0 位 =Keyboard clock input，第 1 位 =Keyboard data input
0xFx	向输出端口输出脉冲

命令0x20和0x60对板载微控制器的命令字节进行读写。这个命令字节的各位含义如表6-28所示。

表 6-28　读写命令字节的各位含义

位	说　明
0	键盘中断（1= 启用，0= 禁用）
1	鼠标设备中断（1= 启用，0= 禁用）
2	写入 Status 的系统标志的值
3	预约
4	键盘（1= 禁用键盘）
5	鼠标设备（1= 禁用鼠标）
6	键盘转换（1= 启用，0= 禁用）
7	预约

向I/O端口0x60写入表示直接向键盘微控制器发送命令。向I/O端口0x60写入必须在确认Status的第0位为0后进行。向键盘微控制器发送的命令如表6-29所示。

表 6-29　键盘微控制器的命令（端口 0x60）

值	说　明
0xED	操作 LED。按照写入 I/O 端口 0x60 的下一个内容更新键盘的 LED。写入 I/O 端口 0x60 的下一个参数的意义如下 第 3 ～ 7 位：必须为 0 第 2 位：Capslock LED（1=on，0=off） 第 1 位：Numlock LED（1=on，0=off） 第 0 位：Scroll lock LED（1=on，0=off）
0xEE	Echo 命令。向输入端口 0x60 返回 0xEE
0xF0	选择 scan code set（仅 PS/2）。写入 I/O 端口 0x60 的内容从下列选项中选择。 00：读取当前的 scan code set（下一个值从 I/O 端口 0x60 读取） 01：选择 scan code set #1（standard PC/AT scan code set） 02：选择 scan code set #2 03：选择 scan code set #3
0xF2	要求键盘的 ID 信息
0xF3	设置自动重复的延迟和重复率。由写入 I/O 端口 0x60 的下一个内容决定重复率 第 7 位：必须为 0 第 5、6 位：延迟（00=1/4sec，01=1/2sec，10=3/4sec，11=1sec） 第 0 ～ 4 位：重复率（0= 约 30chras/sec -> 0x1F= 约 2chars/sec）
0xF4	启用键盘
0xF5	复位到 PowerON 的状态，等待命令启用

（续）

值	说　明
0xF6	复位到 PowerON 的状态，开始键盘的扫描
0xF7	将所有键设置为自动重复（仅 PS/2）
0xF8	进行设置使所有键生成 up code 和 down code（仅 PS/2）
0xF9	进行设置使所有键只生成 up code（仅 PS/2）
0xFA	进行设置使所有键自动重复，生成 up code 和 down code（仅 PS/2）
0xFB	将写入 I/O 端口 0x60 的下一个键设置为自动重复（仅 PS/2）
0xFC	进行设置使写入 I/O 端口 0x60 的下一个键生成 up code 和 down code（仅 PS/2）
0xFD	进行设置使写入 I/O 端口 0x60 的下一个键只生成 down code（仅 PS/2）
0xFE	重新发送最后的结果。当存在错误的接收数据时，使用这个命令
0xFF	将键盘复位到 PowerON 的状态，开始自我诊断

通过上面的介绍，你应该已经了解LED的控制方法了。下面介绍如何控制LED的代码作为参考。

```
1#include＜stdio.h＞
2#include＜sys/io.h＞
3#define KBD_CMD_PORT 0x60
4#define OBD_STS_PORT 0x64
5
6#define OBS_FULL 0x1
7#define SEND_LED 0xED
8
9#define SCROLL_LOCK（1＜＜0）
10#define NUM_LOCK（1＜＜1）
11#define CAPS_LOCK（1＜＜2）
12
13 void send_cmd（cmd, port）
14{
15 char sts；
16 do{
17 sts=inb（OBD_STS_PORT）；
18}while（sts＆OBS_FULL）；
19 outb（cmd, port）；
20 usleep（100000）；
21}
22
23 int main（void）
24{
25 ioperm（KBD_CMD_PORT，1，1）；
26 ioperm（OBD_STS_PORT，1，1）；
27
28/*Turn on a LED of CAPS_LOCK*/
29 send_cmd（SEND_LED, KBD_CMD_PORT）；
```

```
30 send_cmd（CAPS_LOCK, KBD_CMD_PORT）；
31
32/*Turn on a LED of NUM_LOCK*/
33 send_cmd（SEND_LED, KBD_CMD_PORT）；
34 send_cmd（NUM_LOCK, KBD_CMD_PORT）；
35
36/*Turn on a LED of SCROLL_LOCK*/
37 send_cmd（SEND_LED, KBD_CMD_PORT）；
38 send_cmd（SCROLL_LOCK, KBD_CMD_PORT）；
39
40/*Turn off LEDs*/
41 send_cmd（SEND_LED, KBD_CMD_PORT）；
42 send_cmd（0，KBD_CMD_PORT）；
43
44 ioperm（KBD_CMD_PORT，1，0）；
45 ioperm（OBD_STS_PORT，1，0）；
46 return 0；
47}
```

首先在第25、26行允许I/O端口0x60、0x64的访问。然后使用send_cmd（）函数，在写入指定的I/O端口（port）前获取板载控制器的Status，确认Output Buffer为empty，确认后向I/O端口写入值（cmd）。在第29行为了点亮CAPS_LOCK的LED灯，发送命令（0xED）。然后写入用来亮灯的CAPS_LOCK的LED值（4）。按同样方法依次点亮NUM_LOCK、SCROLL_LOCK后，将所有的LED熄灭。

各式各样的键盘

现在市场上也出现了很多种USB连接的键盘等。虽然各自的规格并不相同，但是也无须担心。Linux的input子系统中准备了十分方便的接口。通过访问/dev/input/eventN文件*，就可以从用户空间控制键盘（*N为数字）。查找已分配给键盘的事件文件时，可以使用下列命令从/proc/bus/input/devices寻找键盘的设备。

```
#cat/proc/bus/input/devices
……
I：Bus=0011 Vendor=0001 Product=0001 Version=ab41
N：Name="AT Translated Set 2 keyboard"
P：Phys=isa0060/serio0/input0
S：Sysfs=/devices/platform/i8042/serio0/input/input3
U：Uniq=
H：Handlers=kbd event3
B：EV=120013
B：KEY=4 2000000 3803078 f800d001 feffffdf ffefffff ffffffff fffffffe
B：MSC=10
B：LED=7
……
```

从Handlers入口可以看出event3为键盘用的事件文件。EV入口是表示可操作事件的位图（bitmap）。当EV入口中有LED的位时，显示LED入口。如果有LED入口，表示可以使用事件文件对LED进行操作。LED入口为位图，各个位表示所支持的LED。LED的位图意义如下。

```
#define LED_NUML 0x00
#define LED_CAPSL 0x01
#define LED_SCROLLL 0x02
#define LED_COMPOSE 0x03
#define LED_KANA 0x04
#define LED_SLEEP 0x05
#define LED_SUSPEND 0x06
#define LED_MUTE 0x07
#define LED_MISC 0x08
#define LED_MAIL 0x09
#define LED_CHARGING 0x0a
```

具体来说，可以用以下这些代码来控制。在第34行打开参数文件。

将/dev/input/eventN作为write函数的参数。通过向事件文件写入，可以点亮或熄灭LED。

```
1#include＜stdlib.h＞
2#include＜stdio.h＞
3#include＜sys/types.h＞
4#include＜sys/stat.h＞
5#include＜fcntl.h＞
6#include＜unistd.h＞
7#include＜sys/ioctl.h＞
8#include＜stdint.h＞
9#include＜errno.h＞
10#include＜linux/input.h＞
11
12#define OFF 0
13#define ON 1
14
15 void usage（char**argv）
16{
17 printf（"Usage：%s＜event-device＞\n"，argv[0]）；
18 printf（"e.g.%s/dev/input/evdev0\n"，argv[0]）；
19 return；
20}
21
22 int main（int argc, char**argv）
23{
24
25 int fd；
26 int ret=0；
27 struct input_event ev；
28
29 if（argc！=2）{
30 usage（argv）；
31 exit（1）；
32}
33
34 if（（fd=open（argv[1]，O_WRONLY））＜0）{
35 perror（"evdev file open"）；
36 usage（argv）；
37 exit（1）；
38}
39
40/*Turn on a LED of CAPS_LOCK*/
41 ev.type=EV_LED；
42 ev.value=ON；
43 ev.code=LED_CAPSL；
44 ret=write（fd，＆ev, sizeof（struct input_event））；
45 usleep（100000）；
46/*Turn off a LED of CAPS_LOCK*/
47 ev.value=OFF；
48 ret=write（fd，＆ev, sizeof（struct input_event））；
49 usleep（100000）；
50
51/*Turn on a LED of NUM_LOCK*/
52 ev.code=LED_NUML；
53 ev.value=ON；
54 ret=write（fd，＆ev, sizeof（struct input_event））；
55 usleep（100000）；
```

```
56/*Turn off a LED of NUM_LOCK*/
57 ev.value=OFF；
58 ret=write（fd，&ev, sizeof（struct input_event））；
59 usleep（100000）；
60
61/*Turn on a LED of SCROLL_LOCK*/
62 ev.code=LED_SCROLLL；
63 ev.value=ON；
64 ret=write（fd，&ev, sizeof（struct input_event））；
65 usleep（100000）；
66/*Turn off a LED of SCROLL_LOCK*/
67 ev.value=OFF；
68 ret=write（fd，&ev, sizeof（struct input_event））；
69 usleep（100000）；
70
71 close（fd）；
72
73 return 0；
74}
```

参考文献

·IBM Personal System/2 Hardware Interface Technical Reference

·Intel®UPI-41AH/42AH UNIVERSAL PERIPHERAL INTERFACE 8-BIT SLAVE MICROCONTROLLER

——Akio Takebe

HACK#50　PowerTOP

本节介绍显示应用程序电能消耗指标的PowerTOP。通过这个工具可以看到影响CPU省电状态的应用程序的运行情况。

概要

PowerTOP是由Intel公司运营的LessWatts项目开发出的工具，显示表示电能消耗的指标WPS（Wakeups per second）。WPS表示CPU从休眠状态迁移到运行状态的事件每秒发生次数。因此，如果WPS较多，则CPU相应地难以进入省电状态。C0状态和C5状态之间的状态迁移需要花费不少时间，因此WPS越少效率越高。

图6-12所示为笔记本电脑，型号为DELL Inspiron Mini 12（两个CPU）、操作系统为Ubuntu 8.04时的例子。

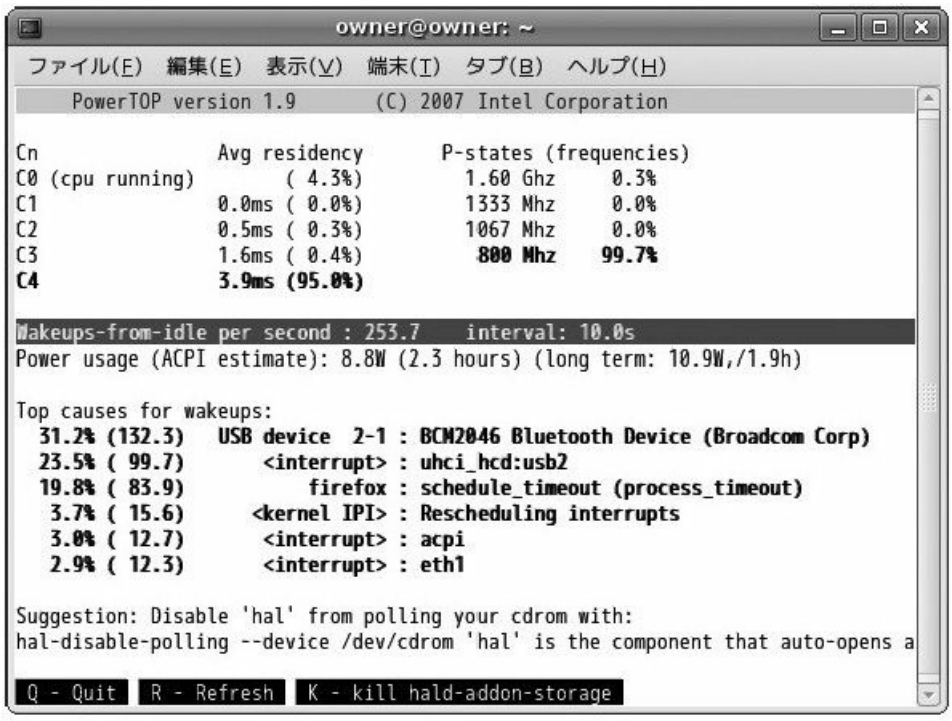

图　6-12　powertop命令的输出

启动firefox，在连接LAN电缆、USB鼠标的状态下运行PowerTop。图6-12显示了进程和WPS的比例。WPS最多的是Bluetooth设备。

然后关闭firefox，拔掉LAN电缆、USB鼠标，禁用Bluetooth。图6-13为此时powertop命令的输出。

整体的WPS（Wakeups-form-idle per second：）减少到62。

PowerTOP的详细情况和结构

图6-12左上方出现了Cn。这表示的是CPU状态的层次和处于该状态的时间（比例）。从这里可以看出PowerTOP测量期间内运行的CPU状态的比例。

图6-14显示的是运行了无限循环脚本loop.sh时的情况。

由于测量期间内一直无限循环，因此C0状态超过了50%。测量的电脑有两个CPU，其中一个由loop.sh占用，因此表示整体上有50%为C0状态。

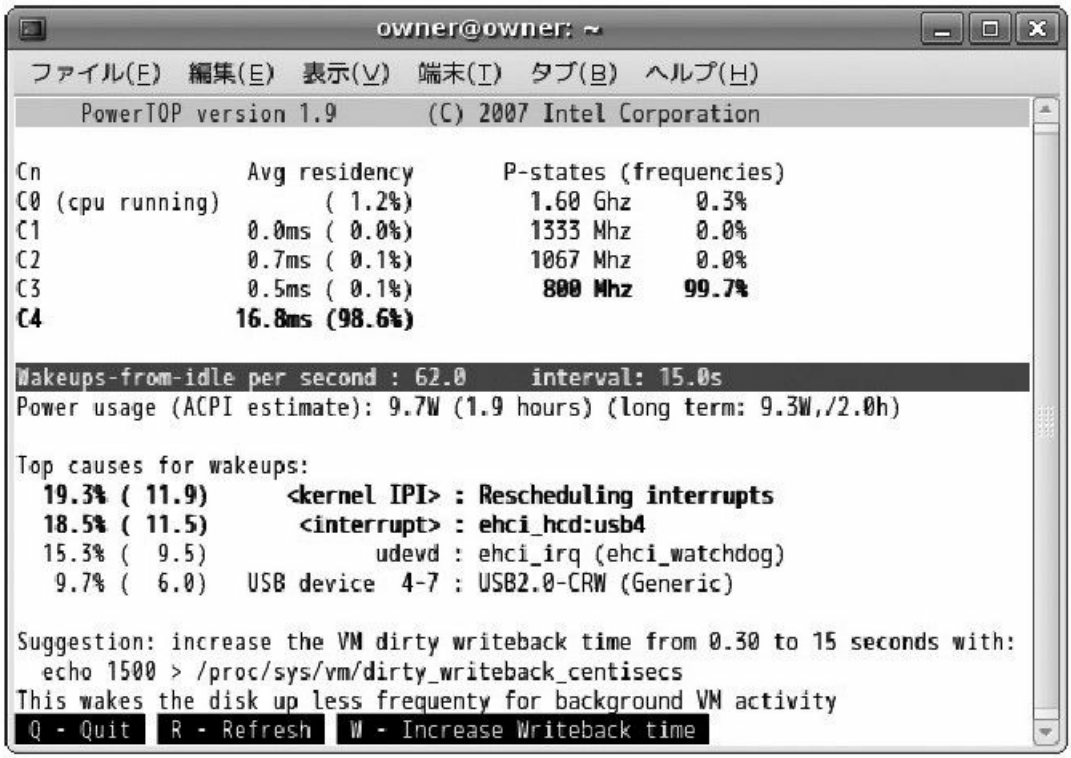

图　6-13　结束应用程序后的powertop命令

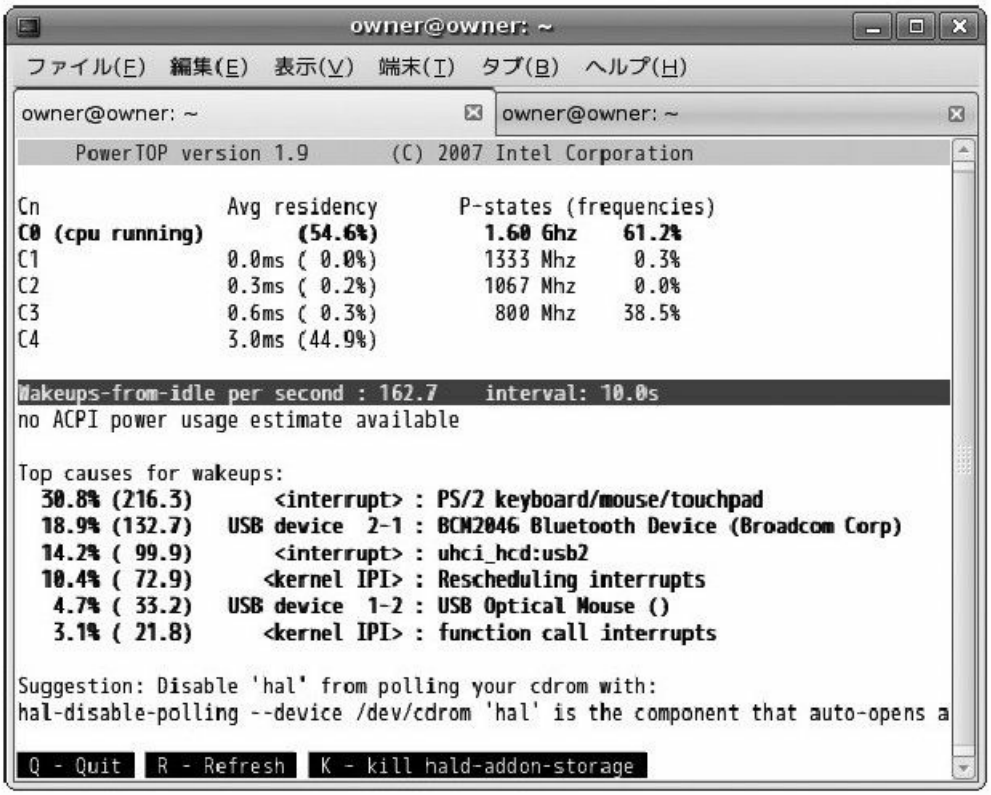

图 6-14 执行loop.sh时的powertop命令

图6-15显示的是此时的top命令。

执行top命令，按下键盘的【1】键，上面就会显示Cpu0、Cpu1，显示各CPU的使用率。loop.sh几乎使用了100%的Cpu0。

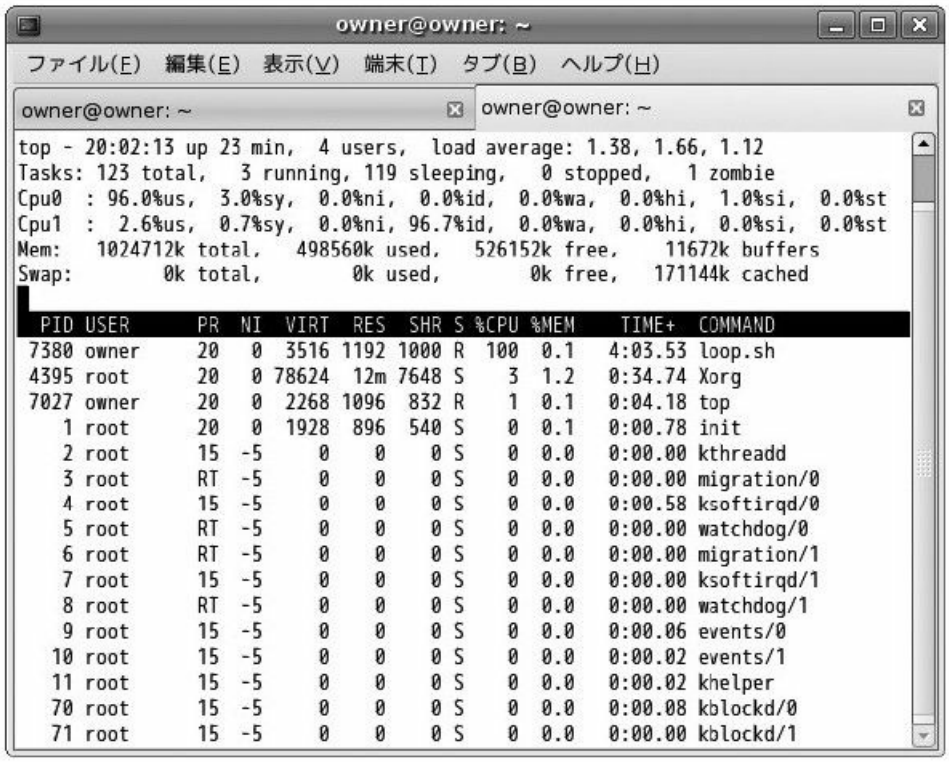

图　6-15　执行loop.sh时的top命令

关于颜色变化

图6-14中WPS的行是蓝色的。这是因为WPS的数值较少。

Wakeups-from-idle per second WPS的数值为0～10时为绿色，11～25时为黄色，26以上为红色。但是，最后查看C0状态的时间如果在25%以上，就显示蓝色。

另外，图6-14中WPS的下一行有no ACPI power usage estimate available。这是在连接AC电源的状态下执行powertop命令时输出的。拔掉AC电源线就会如图6-12一样输出瓦数和剩余时间等电池信息。

Top causes for wakeups：显示的是使CPU从休眠状态迁移到运行状态的每个事件种类的发生次数。

关于各事件的WPS

PowerTOP参照/proc/interrupts和/proc/timer_stats，重新排序显示使其看起来更清晰。另外，PowerTOP在Tickless内核时能够正确测量，因此必须为Linux内核2.6.21以后的版本，并且启用Tikeless（CONFIG_NO_HZ=y）进行编译。

各事件显示的WPS数字，是从硬件中断（/proc/interrupts）和timer启动次数（/proc/timer_status）计算出的。

PowerTOP的建议

PowerTOP界面下方在每次更新显示时就会显示省电的建议。建议仅显示与系统相符的内容。在PowerTOP界面上根据建议按键，就会执行这个建议。表6-30整理了部分建议，可以作为省电设置的参考。

表 6-30　PowerTOP 的建议列表

建 议 内 容	按键动作详细内容
建议：使用下列命令可以禁用未使用的 Bluetooth 接口。 hciconfig hci0 down;rmmod hci_usb Bluetooth 消耗较多的电力，使 USB 进入 busy 状态	按【B】键，就会执行建议的命令
建议：使用下列命令可以禁用 NMI 监视。 echo 0 > /proc/sys/kernel/nmi_watchdog NMI 监视是用来检出死锁（deadlock）的内核调试结构	按【N】键，就会执行建议的命令。NMI 看门狗（watchdog）请参考 Hack#57
建议：使用下列命令可以启用文件系统的 noatime 设置。 mount -o remount,noatime / 或按【T】键 不通过 noatime 记录访问时间，抑制磁盘 I/O 的发生	按【T】键，就会执行下列命令。 /bin/mount -o remount, noatime,nodiratime
建议：使用下列命令可以启用 CPU 调度程序的省电模式。 echo 1 > /sys/devices/system/cpu/sched_mc_power_savings 或按【C】键	按【C】键，就会执行建议的命令。CPU 调度程序的省电模式请参考 Hack #42
建议：使用下列命令可以将页面缓存的延迟写回间隔从 5 秒延长到 15 秒。 echo 1500 > /proc/sys/vm/dirty_writeback_centisecs 这个设置可以降低 VM 背景运行访问磁盘的频率	按【W】键，就会执行建议的命令
建议：使用下列命令启用所有 CPU 的 ondemand 频率控制。 echo ondemand > /sys/devices/system/cpu/cpu0/cpufreq/scaling_governor	按【O】键，就会执行建议命令。CPU 频率控制请参考 Hack #42

（续）

建 议 内 容	按键动作详细内容
建议：使用下列命令可以启用 SATA 连接（link）电源管理。 echo min_power > /sys/class/scsi_host/host0/link_power_management_policy 或按【S】键	按【S】键，就会执行建议的命令。硬盘的省电请参考 Hack #51
建议：使用下列命令可以禁用 TV 输出。 xrandr - -output TV - -off 或按【V】键	按【V】键，就会执行下列命令。 xrandr - -auto;xrandr - -output TV - -off
建议：请使用下列命令禁用以太网的 Wake-on-LAN。 ethtool -s eth0 wol d 在 Wake-on-LAN 设置中 PHY 总是运行，因此消耗电能	按【W】键，就会执行建议的命令（仅 eth0）。 WakeOnLAN 请参考 Hack #45
建议：按【U】键可以启用除输入设备以外的 USB 设备的自动待机模式	按【U】键，就会执行下列命令。 echo auto > /sys/bus/usb/devices/%s/power/control USB 的省电请参考 Hack #46
建议：按【P】键可以启用设备的电源管理	按【T】键，就会执行下列命令（建议中的【P】键，在有的版本中是【T】键）。 echo auto > /sys/bus/pci/devices/%s/power/control echo auto > /sys/bus/spi/devices/%s/power/control echo auto > /sys/bus/i2c/devices/%s/power/control

表6-31所示为PowerTOP关于无线网络的建议。

表 6-31 PowerTOP 关于无线网络的建议列表

建议内容	按键动作详细内容
建议：使用下列命令可以启用无线的省电模式。 iwpriv < 无线设备名称 > set_power 5 这个设置会降低一些网络性能	按【W】键使无线设备进入省电模式。执行建议的命令
建议：使用下列命令可以启用无线的省电模式。 echo 5 > /sys/bus/pci/devices/< 无线设备名称 >/power_level 这个设置会降低一些网络性能	按【W】键启用无线省电模式。执行建议的命令。实际为 bug，echo 1 > /sys/bus/pci/devices/< 无线设备名称 >/power_level

（续）

建议内容	按键动作详细内容
建议：使用下列命令可以禁用未使用的 Wi-Fi 通信。 echo 1 > /sys/bus/pci/devices/< 无线设备名称 >/rfkill/rfkill0/state	按【I】键禁用 Wi-Fi 通信。执行建议的命令
建议：使用下列命令可以禁用未使用的 Wi-Fi 接口。 ifconfig < 网络设备 > down	按【D】键禁用无线 LAN。执行建议的命令
建议“使用下列命令可以启用无线的省电模式。 iwconfig < 无线设备名称 > power timeout 500ms 这个设置会降低一些网络性能	按【W】键启用无线设备的省电模式。执行建议中的命令

PowerTOP对进程结束的建议如表6-32所示。

表 6-32 PowerTOP 对进程结束的建议列表

建议内容	按键动作详细内容
建议：请禁用或卸载 gnome-power-manager。旧版本的 gnome-power-manager 过于频繁地启动检查电力，反而消耗电能	按【K】键就会通过 kill 系统调用向 gnome-power-manager 发送 SIGTERM，使其结束
建议：使用下列命令可以禁用 hal 的 cdrom 查询功能。 hal-disable-polling --device /dev/cdrom hal 提供插入 CD 时的自动执行功能，但禁用 SATA 的省电模式	按【K】键就会通过 kill 系统调用向 hald-addon-storage 发送 SIGTERM，使其结束
建议：请卸载 setroubleshoot-server，禁用 SE-Alert。对 SELinux 的违反策略发出警告的 SE-Alert 存在每 1 秒中断 10 次的 bug	按【K】键就会通过 kill 系统调用向 /usr/bin/sealert 发送 SIGTERM，使其结束

改善应用程序的示例

PowerTOP的项目中进行了实际减少应用程序的WPS的修改。这些成果在下列URL上公开。对kernel、firefox、xterm等众多应用程序作出了贡献。

http://www. Linuxpowertop.org/known.php

小结

PowerTOP是非常优秀的工具。应用程序的稳定性和性能虽然重要，但在使用电池的系统中省电也是非常重要的，PowerTOP的指标对于改善应用程序是非常有效的。

参考文献

·PowerTOP

http://www. lesswatts.org/projects/powertop/

·Documentation/hrtimer/timer_stats. txt

——Naohiro Ooiwa

HACK#51　硬盘的省电

本节介绍SATA的LPM和hdparm命令的电力控制。

从内核2.6.24开始支持SATA的LPM（Link Power Management）和AHCI SATA控制器ALPM（Aggressive Link Power management）。

本节将介绍LPM、ALPM和使用hdparm命令进行省电设置。

LPM

SATA的LPM（Link Power Management，链路电源管理）有DIPM（Device Initiated Link Power Management）和HIPM（Host Initiated Power Management）两种控制方法。DIPM是由设备控制链路状态。从操作系统设置一次LPM，然后设备就会自动迁移到省电状态。

HIPM通过AHCI SATA主控制器的ALPM（Aggressive Link Power Management）控制链路状态。因此HIPM必须SATA能够支持AHCI，并在BIOS中设置为AHCI模式。

LPM的链路状态有ACTIVE、PARTIAL、SLUMBER这三个状态。ACTIVE为运行状态，不进行电能控制。PARTIAL和SLUMBER为省电状态，SLUMBER比PARTIAL更省电。

在AHCI规格中，从PARTIAL恢复到ACTIVE需要在10微秒以内完成，从SLUMBER恢复到ACTIVE需要在10毫秒以内完成。

与CPU等不同的是，省电状态不会进行ACTIVE→PARTIAL→SLUMBER的迁移。只会如图6-16所示的从ACTIVE进行迁移。

LPM的设置是经由sysfs进行的。通过下面的设置使其能够迁移到SLUMBER状态。设

置的字符串如表6-33所示。

```
#echo min_power＞/sys/class/scsi_host/host0/link_power_management_policy
```

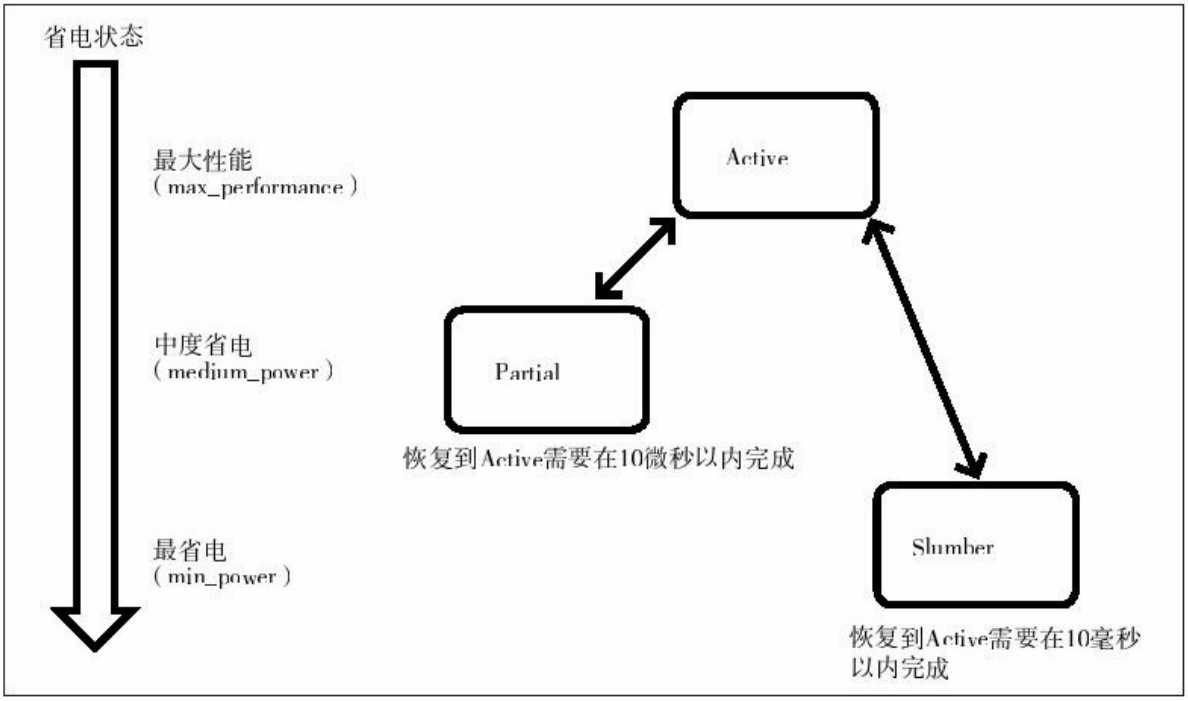

图　6-16　SATA_LPM

表 6-33　LPM 设置的种类

种　类	功　能
min_power	尽可能以最低电力状态运行。启用 DIPM。当处于 AHCI 模式时，迁移到 PARTIAL 状态和 SLUMBER 状态
max_performance	不进行电能控制。禁用 DIPM
medium_power	迁移到较低电能状态，但不会进入最低状态。禁用 DIPM。AHCI 模式的情况下仅迁移到 PARTIAL 状态

除LPM以外，还可以使用hdparm命令进行关于硬盘（SATA/PATA/SAS/IDE）的设置。设置中有关于省电的和关于I/O性能的内容。虽然省电与性能是矛盾的关系，但是对于服务器或台式机等有一些有效的设置。后半部分将介绍关于性能的设置。

显示正在使用的硬盘信息

首先使用hdparm命令查看硬盘的信息。可以确认能够支持的功能和当前的配置情况。显示信息-i是旧的选项。在这里使用的是显示内容比-i更为详细的-I选项。下面是-I选项的输出结果。关于设置选项的地方用阴影表示。

#hdparm-I/dev/sda
/dev/sda：
ATA device, with non-removable media
Model Number：WDC WD1600AAJS-19M0A0
Serial Number：WD-WCAV32353380
Firmware Revision：01.03E01
Transport：Serial, SATA 1.0a, SATA II Extensions, SATA Rev 2.5
Standards：
Supported：8 7 6 5
Likely used：8
Configuration：
……
Logical/Physical Sector size：512 bytes
device size with M=1024*1024：152627 MBytes
device size with M=1000*1000：160041 MBytes（160 GB）
cache/buffer size=8192 KBytes
Capabilities：
LBA, IORDY（can be disabled）
Queue depth：32-Q选项（硬件中支持的最大值）
Standby timer values：spec'd by Standard, with device specific minimum
R/W multiple sector transfer：Max=16 Current=16-m选项
Recommended acoustic management value：128，current value：128
-M选项
DMA：mdma0 mdma1 mdma2 udma0 udma1 udma2 udma3 udma4 udma5*udma6
-X选项
Cycle time：min=120ns recommended=120ns
PIO：pio0 pio1 pio2 pio3 pio4
Cycle time：no flow control=120ns IORDY flow control=120ns
Commands/features：
Enabled Supported：
*
SMART feature set
Security Mode feature set
*
Power Management feature set
*
Write cache-W选项
*
Look-ahead-A选项
*
Host Protected Area feature set
*
WRITE_BUFFER command
*
READ_BUFFER command

*
NOP cmd
*
DOWNLOAD_MICROCODE
Power-Up In Standby feature set
*
SET_FEATURES required to spinup after power up
SET_MAX security extension
*
Automatic Acoustic Management feature set-M选项
*
48-bit Address feature set
*
Device Configuration Overlay feature set
*
Mandatory FLUSH_CACHE
*
FLUSH_CACHE_EXT
*
SMART error logging
*
SMART self-test
*
General Purpose Logging feature set
……
*
Native Command Queueing（NCQ）-Q选项
*
Host-initiated interface power management HIPM
*
Phy event counters
DMA Setup Auto-Activate optimization
Device-initiated interface power management DIPM
……
Security：
Master password revision code=65534
……

这样就可以通过-I选项了解磁盘的详细情况。Commands/features：显示的是磁盘功能列表。Enabled列中有*标记的，是这个硬盘支持的。

下面介绍hdparm命令的选项。

关于省电的设置

APM

-B选项进行的是APM（Advanced Power Management）的设置。值较小时比较省电，值较大时优先考虑性能。255表示禁用APM。

待机standby、休眠模式

-y选项可以将硬盘更改为待机模式。-C选项显示的是当前电源模式的状态。

```
#hdparm-C/dev/sda
/dev/sda：
drive state is：active/idle
#hdparm-y/dev/sda
/dev/sda：
issuing standby command
```

再次执行-C选项，就会显示standby。

```
#hdparm-C/dev/sda
/dev/sda：
drive state is：standby
```

使用-Y选项可以设置为休眠模式。

```
#hdparm-Y/dev/sdb
/dev/sdb：
issuing sleep command
```

待机超时

使用-S选项设置到待机（spindown）为止的超时时间。不访问磁盘的状态超过设置时间就会自动进入待机状态，节省电能。

关于设置值在man页面中作出了详细说明。下面是从man页面摘录的重点。241～255

的设置值请参考man hdparm。

·值为0时表示“禁用超时”，不自动进入待机模式。

·值为1～240时表示5秒×设置值就是超时时间。超时为5秒至20分。

要在最短时间内进入待机模式，需要设置为1（5秒）。

关于I/O性能的设置

预读功能

·使用-a选项获取并设置文件系统的预读扇区。

·-A选项指定是否有IDE驱动器的预读（read-ahead）。

-使用-A0设置为无预读，使用-A1设置为有预读。

```
#hdparm-A1/dev/sda
/dev/sda：
setting drive read-lookahead to 1（on）
look-ahead=1（on）
```

-如果仅指定-A选项，就可以确认当前的预读设置。从hdparm的版本7.0开始可以使用。·使用hdparm命令的-aA选项可以确认当前的设置。

```
#hdparm-aA/dev/sda
/dev/sda：
readahead=256（on）预读扇区数为256
look-ahead=1（on）启用预读
```

32位I/O支持

使用-c选项进行32位I/O的设置。设置值为0、1、3。32位数据传输为0时表示禁用，为1时表示启用，为3时表示使用sync序列sequence的32位数据传输。

DMA设置

使用-d选项进行IDE的DMA设置。使用-X选项可以更改Singleword DMA、Multiword DMA、Ultra DMA的模式。

上例中的硬盘支持mdma0～2、udma0～6，Ultra DMA的模式6（udma6）中显示了

*。这表示当前启用的设置。

如果设备驱动程序、磁盘支持，只要按hdparm-X mdma0这样执行就可以改变。

同步

使用-f选项进行缓存的更新。在hdparm命令的内部依次执行sync、fsync、fdatasync、sync，最后执行ioctl（BLKFLSBUF）。这个ioctl需要文件系统支持该命令。可以在grub-install这样想要完全写出到磁盘时执行。

使用-F选项可以更新硬盘内的灯光缓存（light cache）。

多扇区I/O

使用-m选项进行多扇区I/O的设置。通过1次I/O操作向多个扇区进行数据传输。使用-I选项，如果显示（例如R/W multiple sector transfer：Max=16），就可以指定到16扇区为止。下面是执行的例子。Current显示的是当前的设置值。

```
#hdparm-I/dev/sda|grep multiple
R/W multiple sector transfer：Max=16 Current=8
#hdparm-m 16--yes-i-know-what-i-am-doing/dev/sda
#hdparm-I/dev/sda|grep multiple
R/W multiple sector transfer：Max=16 Current=16
```

静音性能控制

使用-M选项可以对自动音响管理（Automatic Acoustic Management, AAM）进行设置。设置值为128～254或为0。0表示禁用。128表示以静音性能为最优先（低速），254表示设置为性能最优先。

```
#hdparm-M 254/dev/sdb
```

设置为254就能听到硬盘运行的声音。在台式机上可能会比较明显。

命令队列

NCQ（Native Command Queuing）是Serial ATA Ⅱ所支持的功能。NCQ将对硬盘驱动器的多条命令进行排队，按照查找时间由长到短的顺序更换并执行命令的功能。

hdparm命令的-Q选项用来设置这个NCQ队列的深度。必须内核和设备驱动程序都支持。可以通过sysfs下的文件是否具有写入权限来判断是否能够支持。

```
#ls-l/sys/block/sda/device/queue_depth
-rw-r--r--1 root root 4096 2010-03-21 20：30/sys/block/sda/device/queue_depth^^^^有写入权限
#cat/sys/block/sda/device/queue_depth
31
```

灯光缓存

使用-W选项可以设置灯光缓存。这是硬盘内部的缓存。0表示禁用，1表示启用。

笔者在身边从旧到新一共5台机器上进行了确认，发现灯光缓存默认都是启用的。停电或系统发生障碍等时，灯光缓存的数据不会反映到磁盘上，数据有可能会破坏。因此旧的hdparm中-W的设置为（DANGEROUS），但RHEL6安装的hdparm中（DANGEROUS）被串删除了。

参考文献

·Documentation/scsi/link_power_management_policy. txt

·AHCI Specification

http://www. intel.com/technology/serialata/ahci.htm

——Naohiro Ooiwa

第7章　调试

IT系统越来越多样化，也变得越来越复杂。同时，出现的故障也变得非常复杂。要通过事前评估来网罗所有的实验在实际操作上也是很困难的。

因此，一旦发生故障，就需要迅速应对解决。为此就必须研究对策，作好万全的准备。本章将介绍内核的调试功能。主要介绍检测死机的看门狗（watchdog）和内核崩溃转储（crash dump）功能。

HACK#52　SysRq键

本节介绍SysRq键的功能和使用方法。

SysRq键一般在键盘的右上方。Magic System Request Key（Magic SysRq）就是指通过这个SysRq键获取内核信息的功能。一般可以通过proc文件系统或命令来获取信息。但是如果系统死机，就无法输入命令。SysRq键可以直接从内核输出信息。只要不是禁止中断状态，即使死机时也可以获取信息。SysRq键在确认内核运行、调查内核死机原因等各种情况下都非常有效。

使用方法

要使用SysRq键，需要启用内核配置CONFIG_MAGIC_SYSRQ，编译内核。

```
#make menuconfg
Kernel hacking--->
[*]Magic SysRq key
```

RedHat系列的发布版的内核中并未安装SysRq功能。

启动后可以使用sysctl来切换启用、禁用。有的发布版在启动时是禁用的。可以使用下列命令来启用。

```
#sysctl-w kernel.sysrq=1
或
#echo 1>/proc/sys/kernel/sysrq
```

如果在/proc/sys/kernel/sysrq中设置为1，则所有SysRq键都可以使用。这个特殊文件的值是位掩码，还可以通过添加数字来限制可使用的SysRq键的命令。各值如表7-1所示。括号内为命令键（关于命令键将在后面介绍）。

表 7-1　在 /proc/sys/kernel/sysrq 中设置的位掩码

值	允许的命令
1	允许所有
2	允许控制控制台日志级别（0～9）
4	允许控制键盘（kr）
8	允许显示进程等信息（lptwmcz）
16	允许 Sync 命令（s）
32	允许只读下的重新挂载（u）
64	允许发送信号（ei）
128	允许重启（b）
256	允许控制即时进程（q）

要允许Sync（s）和重新挂载（u），而不能进行其他操作，可以进行如下设置。

```
#echo 48＞/proc/sys/kernel/sysrq
```

这个控制是从键盘和串行（serial）接口限制控制台的输入。后面将介绍的/proc/sysrq-trigger的操作没有限制。

另外，在内核启动参数中，无论/proc/sys/kernel/sysrq的设置如何，都可以启用SysRq键。

```
boot＞linux sysrq_always_enabled
```

这个内核启动参数在Linux 2.6.20以后的版本中可以使用。

SysRq键的输入方法

SysRq键有很多命令。可以使用这些命令控制机器或输出信息。命令键是指用来指定这些动作的键输入。

从键盘输入SysRq键时，需要同时输入Alt键、SysRq键和命令键。

从串口控制台输入时，是在发送break信号后5秒内输入命令键。

此外向proc文件系统/proc/sysrq-trigger写入命令键可以进行与SysRq相同的动作。

```
#echo[命令键]＞/proc/sysrq-trigger
```

SysRq命令键

首先将上游内核的版本中支持的命令汇总到表7-2中。

表 7-2　各内核版本的命令键支持情况

命　令　键	命 令 名 称	2.6.9 ~ 2.6.11	2.6.16 ~ 2.6.19	2.6.29	2.6.30 ~ 2.6.35
0 ~ 9	loglevel0 ~ 8	○	○	○	○
b	reBoot	○	○	○	○
c	Crashdump 注1		○	○	○
d	show-all-locks(D) 注2		○	○	○
e	tErm	○	○	○	○
f	Full		○	○	○
i	kIll	○	○	○	○
j	thaw-filesystem(J) 注3				○
k	saK	○	○	○	○
l	aLlcpus 注4	○	○	○	○
m	showMem		○	○	○
n	Nice	○	○	○	○
p	showPc			○	○
q	show-all-timers(Q) 注5	○	○	○	○
r	unRaw	○	○	○	○
s	Sync	○	○	○	○
t	showTasks	○	○	○	○
u	Unmount			○	○
w	shoW-blocked-tasks			○	○
z	dump-ftrace-buffer(Z) 注6		○		○

[2] [3] [4] [5] [6]

○表示内核能够支持。命令名称是表示命令键内容的名称。命令名称中的大写字母就是键。例如，命令“reBoot”中的大写字母B就是命令键。命令名称最后有（）的，（）内的文字为键。

如果输入表7-2以外的键，就会输出如下的帮助信息，可以确认命令键。

例7-1　Linux2.6.32-44.2.el6的情形

主要命令键的内容如表7-3所示。

表 7-3　SysRq 命令键的详细内容

命　令　键	说　　明
0 ~ 9	设置控制台层次。与设置 /proc/sys/kernel/printk 是相同的
b	重新启动 Linux 内核
c	获取崩溃转储。用于故意造成系统故障时
d	输出获取的所有 lock 信息。但是 TASK_RUNNING 状态的进程获取的 lock 不显示。这是因为这个进程立刻就会释放
e	向 init 进程（PID 为 1）以外的所有进程发送 SIGTERM 信号
f	运行 OOM Killer（详细内容参考 HACK #16）
i	向 init 进程（PID 为 1）以外的所有进程发送 SIGKILL 信号
l	输出系统中的所有 CPU 的栈。还会显示进程栈的回溯（backtrace）
n	将所有实时进程强制改变为普通进程。与在 sched_setscheduler(2) 中指定 SCHED_NORMAL 为调度策略相同
m	输出内存、交换区的状态
p	输出 CPU 的寄存器和进程的信息。有多个 CPU 时，仅输出处理键中断的 CPU 的信息
q	输出所有计时器的信息
s	在所有文件系统中尝试 sync（把内存缓冲区的内容写入磁盘）。内部是通过强制运行 pdflush 来实现的。在命令键 b 之前执行，就可以减少文件系统或文件破坏的风险，重启内核
t	输出运行中的所有进程的栈、回溯
u	对所有文件系统尝试只读的重新挂接
w	仅输出处于 UNINTERRUPTABLE 状态（无视信号的进程状态）的进程信息
z	输出 ftrace 的缓冲区

RHEL5的命令键w与上游内核中的不同。命令键w（shoWcpus）输出系统中的所有CPU的栈。这与上游内核的命令键l（aLlcpus）进行的操作相同。RHEL6的w与上游内核相同。RHEL4/5/6的支持情况如表7-4所示。

表 7-4　RHEL4、RHEL5、RHEL6 的 SysRq 键支持情况

命令键	命令名称	RHEL4	RHEL5	RHEL6
0 ~ 9	loglevel0 ~ 8	○	○	○
b	reBoot	○	○	○
c	Crash	○	○	○
d	show-all-locks(D)		○	○
e	terminate-all-tasks(E)	○	○	○
f	memory-full-oom-kill(F)		○	○
i	kill-all-tasks(I)	○	○	○
j	thaw-filesystems(J)			○
k	saK	○	○	○
l	show-backtrace-all-active-spus(L)			○
m	show-memory-usage(M)	○	○	○
n	nice-all-TR-tasks(N)		○	○
p	show-registers(P)	○	○	○
q	show-all-timers(Q)			○
r	unRaw	○	○	○
s	Sync	○	○	○
t	show-task-states(T)	○	○	○
u	Unmount	○	○	○
w	shoWcpus		○	
w	show-blocked-tasks(W)			○
z	dump-ftrace-buffer(Z)			

[1]需要启用CONFIG_KEXEC。

[2]到2.6.17为止的版本需要启用CONFIG_DEBUG_MUTEXES，从2.6.18开始需要启用CONFIG_LOCKDEP。

[3]需要启用CONFIG_BLOCK。

[4]需要启用CONFIG_SMP。

[5]需要启用CONFIG_GENERIC_CLOCKEVENTS。

[6]需要启用CONFIG_TRACING。SysRq：HELP：loglevel（0-9）reBoot Crash terminate-all-tasks（E）memory-full-oom-kill（F）kill-all-tasks（I）thaw-filesystems（J）saK show-backtrace-all-active-cpus（L）show-memory-usage（M）nice-all-RT-tasks（N）powerOff show-registers（P）show-all-timers（Q）unRaw Sync show-task-states（T）Unmount force-fb（V）show-blocked-tasks（W）dump-ftrace-buffer（Z）

上游内核的SysRq键显示的例子

下面是命令键m（showMem）的输出示例。输出的是内存和交换区的使用情况。

```
SysRq：Show Memory
Mem-info：
Node 0 DMA per-cpu：
……
Active：128436 inactive：87353 dirty：93 writeback：0 unstable：0
free：6411 slab：30787 mapped：1294 pagetables：435 bounce：0
Swap cache：add 0，delete 0，find 0/0
Free swap=1020116kB
Total swap=1020116kB
261920 pages of RAM
5716 reserved pages
9262 pages shared
0 pages swap cached
```

下面是命令键t（showTasks）的输出示例。

```
SysRq：Show State
task PC stack pid father
……
sshd S ffffffff8048d5e0 0 3121 2908
ffff81003ec31a28 0000000000000082 0000000000000000 ffff810032c455b8
……
Call Trace：
[＜ffffffff80471eb6＞]schedule_timeout+0x1e/0xad
[＜ffffffff8036bc83＞]tty_poll+0x5f/0x6d
……
[＜ffffffff802982f4＞]sys_select+0xc1/0x183
[＜ffffffff8028c00a＞]sys_write+0x45/0x6e
……
```

使用命令键w（shoW-blocked-tasks）也会输出同样的信息。

下面是命令键l（aLlcpus）的输出示例。输出的有安装的模块、SysRq键的处理程序运行的CPU寄存器值、栈、回溯，这里省略部分内容。

```
SysRq：Show backtrace of all active CPUs
CPU 0：
Modules linked in：ipmi_watchdog ipmi_devintf ipmi_si ipmi_msghandler
……
Pid：0，comm：swapper Not tainted 2.6.26#2
RIP：0010：[＜ffffffff80211d85＞][＜ffffffff80211d85＞]mwait_idle+0x41/0x44
```

RSP：0018：ffffffff8087df60 EFLAGS：00000246
RAX：0000000000000000 RBX：0000000000000000 RCX：0000000000000000
……
Call Trace：
[＜ffffffff8020ab7b＞]?cpu_idle+0x6d/0x8b
CPU1：
……
Call Trace：
＜IRQ＞[＜ffffffff8037c71d＞]showacpu+0x0/0x52
[＜ffffffff8037c75d＞]showacpu+0x40/0x52
[＜ffffffff8021a118＞]smp_call_function_interrupt+0x3b/0x62
[＜ffffffff8020c8d6＞]call_function_interrupt+0x66/0x70
＜EOI＞[＜ffffffffa0049994＞]：ext3：ext3_bmap+0x0/0x78
……

使用命令键p（showPc）也会输出同样的信息。使用命令键q（show-all-timers）输出与/proc/timer_list相同的信息。如果是启用CONFIG_SCHEDSTATS编译的内核，在命令键t和w输出的信息中添加与/proc/sched_debug相同的信息。

各种情况下的使用方法

某进程看似停止的情况

使用命令键t确认进程运行的地方。通过确认回溯，就有可能找出等待获取资源、等待获取lock等的进程之所以停止的原因。如果在等待获取lock时停止，有可能通过并用命令键d根据lock的依存关系找出原因。如果正在用户空间运行，就有可能是编程错误。机器看似死机的情况为了保全数据，使用命令键s将内存中还未完成写入的数据写出到磁盘。然后，使用命令键u将文件系统以只读形式重新挂接，可以防止发生数据不匹配。需要重新开始工作时，使用命令键b重启内核。如果不需重新开始工作，可以使用命令键c提取崩溃转储，找出死机的原因。

此外，还可以在死机时通过命令键i向所有进程发送SIGKILL信号尝试从死机状态恢复。内核在允许中断状态下死机时，在死机的状态下执行几次命令键w或p，就可以知道死机的位置。进行再现时，事先禁用看门狗计时器就可以分析出死机的原因。

由于某些故障输出Oops信息等的情况

未进行内核崩溃转储的设置时，有时控制台的最后会输出Kernel panic-not syncing：～，然后就只能重新启动。这时，可以先使用命令键s尝试把文件系统的数据写入磁盘，再重新启动，这更为安全。

小结

本节介绍了SysRq键。每次内核版本更新时都会添加方便的新功能。由于某些故障导致内核没有反应时，可以使用SysRq键来确认内存使用量和进程的状态。当发生故障机器停止时，建议在按电源键之前首先使用SysRq键收集信息。

另外，命令键c经常用于确认内核崩溃转储的情况。

参考文献

·Documentation/sysrq. txt

——Naohiro Ooiwa

HACK#53　使用diskdump提取内核崩溃转储

本节介绍RHEL4等中采用的diskdump的使用方法。

diskdump是RHEL4等RedHat系列的部分发布版中所采用的内核崩溃转储功能。需要注意的是，这里介绍的功能中有的在某些发布版中不能使用。本节将介绍在RHEL 4.7中已经确认的步骤。使用的架构是x86_64。

内核崩溃转储

内核崩溃转储是将系统内存的内容输出到文件的功能。如果应用程序发生段错误segmentation fault，就会输出core文件，而内核崩溃转储就类似于内核的core文件。发生故障时输出当时的系统内存内容。通过对其进行分析，就可以了解此时内核进行了怎样的处理。因此内核崩溃转储是不可或缺的调试功能。

diskdump的限制事项

为了使diskdump内核中即使发生所有故障也能获取内核崩溃转储，在设置为禁止中断的状态下获取转储。磁盘驱动程序必须能够支持不使用中断执行I/O的结构—轮询I/O。在RHEL 4.7中下列驱动程序能够支持轮询I/O。

---

aic7xxx sym53c8xx IDE ibmvscsi
aic79xx sata_promise qla2xxx sata_nv
ipr ata_piix lpfc aacraid
megaraid CCISS stex
mptfusion megaraid_sas ips

---

diskdump不经由文件系统或设备映射器功能，直接对设备驱动程序进行操作。因此不能向文件或LVM上生成的磁盘分区写入。

启用diskdump

diskdump中必须指定转储用的分区。可以准备用于转储的分区，也可以将swap分区指定为转储位置。但是不使用compress选项时，分区必须大于系统中安装的内存。这次不使用交换分区，而是准备了专用于转储的分区/dev/sda3。配置文件/etc/sysconfig/diskdump中有下列内容。

```
DEVICE=/dev/sda3
```

然后将/dev/sda3格式化，作为转储用分区。

```
#service diskdump initialformat
```

启用diskdump服务。

```
#chkconfg diskdump on
#service diskdump start
```

可以通过service命令或/proc/diskdump来确认diskdump是否已启用。/proc/diskdump中显示的内容如下。

```
#cat/proc/diskdump
#sample_rate：8
#block_order：2
#fallback_on_err：1
#allow_risky_dumps：1
#dump_level：0
#compress：0
#total_blocks：98197
#
sda3 14329980 2441880
```

另外，需要设置sysctl变量kernel.panic，使Linux内核在转储提取完成后自动重新启动。这是在/etc/sysctl.conf中进行设置的。

```
kernel.panic=10
```

通过这样的设置，转储完成后10秒就会重新启动。指定设置后使用sysctl命令启用设置。

```
#sysctl-p
```

到这一步设置就完成了，可以尝试提取崩溃转储。

```
#echo c＞/proc/sysrq-trigger
```

转储文件在内核崩溃后重新启动时另存为/var/crash/127.0.0.1-＜日期＞/vmcore。可以使用crash命令确认转储文件的内容。关于crash命令的内容请参考HACK#59。

使用压缩和部分转储功能缩小转储文件的大小

diskdump可以缩小转储文件。关于Kdump的内容请参考HACK#54。

压缩功能和部分转储功能可以使用diskdump内核模块的内核选项来指定。要启用压缩功能可以将compress选项指定为1。部分转储功能则是在dump_level选项中指定转储级别。表7-5所示为每个转储级别跳过skip的页面种类。

但是，启用这个功能时需要注意，有些种类的页面在跳过时需要检索内核内部内存管理用的列表。

有时故障是由于该列表的破坏而引起的，这是因为diskdump在检索列表的过程中有时也会引起双重重大故障或系统死机。

表 7-5　转储级别与跳过的页面

转储级别	缓存页面（cache page）	私有缓存（cache private）	零页面（zero page）	可用页面（free page）	用户页面（user page）
0					
1	×	×			
2			×		
3	×	×	×		
4				×	
5	×	×		×	
6			×	×	
7	×	×	×	×	
8					×
9	×	×			×

（续）

转储级别	缓存页面（cache page）	私有缓存（cache private）	零页面（zero page）	可用页面（free page）	用户页面（user page）
10			×		×
11	×	×	×		×
12				×	×
13	×	×		×	×
14			×	×	×
15	×	×	×	×	×
17	×				
19	×		×		
21	×			×	
23	×		×	×	
25	×				×
27	×		×		×
29	×			×	×
31	×		×	×	×

如果使用这个功能，建议选择转储级别19。这是因为选择19时，就不需要检索内存管理用的列表。按下列方式在/etc/modprobe.conf中记载传递到diskdump内核模块的选项。

```
options diskdump dump_level=19 compress=1
```

为了启用这个设置，重新启动diskdump服务。

```
#service diskdump restart
```

通过/proc/diskdump可以确认指定的选项是否正确。

```
#cat/proc/diskdump
#sample_rate：8
#block_order：2
#fallback_on_err：1
#allow_risky_dumps：1
```

#dump_level：19
#compress：1
#total_blocks：98197
#
sda3 14329980 2441880

发生故障时通过邮件通知

diskdump具有将转储文件保存到/var/crash/之后启动用户定义的脚本的功能。使用这个功能，还可以在提取转储时（即发生系统故障时）通过邮件通知。/usr/share/doc/diskdumputils-＜version＞/example_scripts/下有示例，可以尝试一下。本次使用的是diskdump-success脚本。将其复制到/var/crash/scripts/下，进行如下编辑。

```
#cat/var/crash/scripts/diskdump-success
#！/bin/sh
ADDRESS=****@oreilly.com
mail-s"[diskdump]'hostname'crashed"$ADDRESS＜＜_EOF
The machine'hostname'crashed.
Writing crash dump to$1
_EOF
#savecore always returns 0 whatever the result of this script because this is
#called after a dump file is created.
exit 0
```

将转储输出到的设备冗长化

在本节前面的“diskdump的限制事项”中提到，diskdump不经由文件系统，直接访问磁盘驱动程序。因此，如果转储用分区所使用的磁盘驱动程序发生故障，提取转储就有可能失败。因此diskdump可以将多个分区指定为转储用分区。在/etc/sysconfig/diskdump下进行具体设置的方法如下。

```
DEVICE=/dev/sda3：/dev/had
```

/dev/sda3是至今为止使用的转储专用分区。在笔者的环境下，mptfusion驱动程序正在运行。另一方面，/dev/hda是由IDE驱动程序运行的其他磁盘设备。如果mptfusion驱动程序发生故障，向/dev/sda3写入转储就有可能失败。在这种情况下，diskdump向下一个输入的/dev/hda进行转储。这是IDE驱动程序，因此可以顺利进行转储的写入。

小结

diskdump在RHEL4系列等中都已采用。必须要有转储用的分区。另外，磁盘驱动程序也必须能够支持。而在下一代转储功能—Hack#54中提到的Kdump中则不需要这些条件。

参考文献

关于配置的详细内容在diskdumpREADME的README文件（/usr/share/doc/diskdumputils-＜version＞/README）中可以看到。

——Naohiro Ooiwa

HACK#54　使用Kdump提取内核崩溃转储

本节介绍最近的发布版中采用的Kdump的使用方法。

Kdump是从Linux 2.6.13开始安装到主线（mainline）中的内核崩溃转储功能。在2.6.13以后的内核的Linux发布版中都可以使用。本节将介绍在RHEL6中进行确认的Kdump使用步骤。所使用的架构为x86_64。

启用崩溃转储

首先向内核启动参数添加crashkernel=128M。分配128MB的内存用于Kdump。笔者的环境在RHEL6的/etc/grub.conf中显示下列内容。

```
title RHEL6（2.6.32-71.el6.x86_64）
root（hd0，0）
kernel/boot/vmlinuz-2.6.32-71.el6.x86_64 root=UUID=987aa4dd-a712-4ff3-8ad9-28edb4ddcaae ro rd_NO_LUKS rd_NO_LVM rd_NO_MD rd_NO_DM LANG=ja_JP.UTF-8 KEYBOARDTYPE=pc KEYTABLE=jp106 crashkernel=128M rhgb quiet
initrd/boot/initramfs-2.6.32-71.el6.x86_64.img
```

从RHEL6开始扩展crashkernel内核启动参数，也可以按下列形式设置。

```
crashkernel=＜range1＞：＜size1＞[，＜range2＞：＜size2＞，……][@offset]
```

可以不根据机器安装的物理内存大小分配内存，或者改变分配的内存量。例如，可以指定如下内存分配情况。

```
crashkernel=512M-2G：64M，2G-：128M
```

它表示的意义是：

·如果物理内存不足512MB，则不分配内存作为Kdump用。

·如果物理内存大于512MB小于2GB，则分配64MB作为Kdump用。

·如果物理内存大于2GB，则分配128MB。

进行这样的指定后，即使从机器上拔下内存，也无须改变参数。

内存分配成功后，内核启动时就会输出下列信息。

```
#dmesg
……
Reserving 128MB of memory at 32MB for crashkernel（System RAM：1022MB）
```

然后，启用kdump服务。使用chkconfig命令、service命令。

```
#chkconfg kdump on
#service kdump start
```

可以通过service命令或/sys/kernel/kexec_crash_loaded确认是否已设置成功。

如果使用service命令显示出如下信息，就表示设置已启用。

```
#service kdump status
Kdump is operational
```

kexec_crash_loaded的内容为1时表示设置已启用。

```
#cat/sys/kernel/kexec_crash_loaded
```

1

准备工作做好后，就可以尝试提取崩溃转储。

```
#echo c＞/proc/sysrq-trigger
```

如果转储成功，内核重新启动后就会在/var/crash/下生成目录，其中存放vmcore文

件。

使用makedumpfile缩小转储的文件大小

使用前面介绍的设置，将生成与实际安装内存量大小相同的崩溃转储文件。也就是说，如果安装了8GB的内存，转储文件也是8GB。但是Kdump也和diskdump一样可以压缩转储映像，使其变小。kexec-tools中的makedumpfile命令就是负责这个处理过程的实用程序。使用这条命令前需要在/etc/kdump.conf中添加core_collector的设置。

```
ext3/dev/sda5
core_collector makedumpfile-c
```

一开始的ext3/dev/sda5指定了具有root文件系统的设备。把转储文件输出到这个分区的./var/crash下。要将转储输出的位置设置为其他分区，例如，设置为挂接到/dump目录下的/dev/sda6，需进行下列操作。

```
ext3/dev/sda6
path.
```

这样，在/dump目录下就会生成各个日期的目录，把转储输出到这里。

-c是压缩选项。设置转储级别的-d选项也非常方便。转储级别选项用来指定崩溃转储中不包括的页面（内存）种类。表7-6所示为各转储级别跳过的页面种类。

表 7-6　跳过的页面种类

转储级别	零页面（zero page）	缓存页面（cache page）	私有缓存（cache private）	用户数据	可用页面（free page）
0					
1	×				
2		×			
3	×	×			
4		×	×		
5	×	×	×		

（续）

转储级别	零页面（zero page）	缓存页面（cache page）	私有缓存（cache private）	用户数据	可用页面（free page）
6		×	×		
7	×	×	×		
8				×	
9	×			×	
10		×		×	
11	×	×		×	
12		×	×	×	
13	×	×	×	×	
14		×	×	×	
15	×	×	×	×	
16					×
17	×				×
18		×			×
19	×	×			×
20		×	×		×
21	×	×	×		×
22		×	×		×
23	×	×	×		×
24				×	×
25	×			×	×
26		×		×	×
27	×	×		×	×
28		×	×	×	×
29	×	×	×	×	×
30		×	×	×	×
31	×	×	×	×	×

转储级别可以通过表7-6中的数值来指定。例如，当不想包括零页面和可用页面时，

可以将转储级别指定为17。还可以像下面这样用“，”将转储级别分开，指定两个转储级别。core_collector makedumpfile-c-d 11，31通过这个配置，makedumpfile命令如果在使用转储级别11时失败，就会使用转储级别31重试。这个配置在磁盘容量不足且makedumpfile命令失败时十分有效。这是因为转储级别31跳过的页面比转储级别11多，转储文件更小。

要使设置生效，需要重启kdump服务。

```
#service kdump restart
```

使用前面介绍的方法确认转储。根据vmcore文件的大小可以判断出提取的转储是否已压缩。已压缩的转储文件就不再是ELF格式，因此不能使用gdb进行调试，必要时请使用crash命令。

使用makedumpfile提取自己重新构建的内核的转储时，需要将带调试信息的内核放到下列位置。

```
/usr/lib/debug/lib/modules/'uname-r'/vmlinux
```

在最近的RHEL6的发布版中，是不需要带调试信息的内核包的。这是因为内核中添加了vmcoreinfo功能。kexec-tools数据包也相应地进行了修改。如果所使用的系统的内核和kexec-tools同时都支持vmcoreinfo，则不需要专门安装带调试信息的内核。

向远程服务器传输崩溃转储

Kdump具有使用NFS或SSH将获取的转储文件向远程传输的功能。

在/etc/kdump.conf添加net的设置。

/*挂接NFS传输时*/

net＜服务器名称或IP地址＞：＜导出的目录＞

/*经由SSH传输时*/

net＜用户名＞@＜服务器名称或IP地址＞

使用NFS时，需要在导出的目录下创建./var/crash目录。使用SSH时，将转储传输到远程服务器的/var/crash目录下。/etc/kdump.conf中设置的登录用户必须具有向/var/crash写入的权限。如果觉得不够安全，可以另外准备转储用的目录，并将转储到的目录进行如下更改。

```
path/dump
```

转储用目录必须事先创建。使用SSH时指定为path的目录不是相对路径而是绝对路径。此外，还需要先输入公开密码，使人们不用输入密码就能登录。使用Kdump的init脚本的propagate选项，脚本就会进行这个操作。

```
#service kdump propagate
```

link_delay指定的是从连接到NIC到开始传输为止的等待时间，单位为秒。这是因为有时NIC初始化需要花费一定时间。笔者为了以防万一，添加了link_delay的设置。

link_delay 10

注意事项：在配合使用makedumpfile和SSH时，就需要对转储文件进行转换。从输出到远程服务器的转储文件，可以看到文件名为vmcore.flat。这样从crash命令是无法直接读入的，因此需要按下列方式转换文件格式。

```
#makedumpfile-R vmcore＜vmcore.flat
```

小结

本节介绍了使用Kdump提取内核崩溃转储的方法。

参考文献

RHEL5系列的使用方法请参考《Debug Hacks》中的HACK#20“使用Kdump提取内核崩溃转储”。

——Naohiro Ooiwa

HACK#55　崩溃测试

本节使用lkdtm进行内核的崩溃测试。

介绍为了测试HACK#54中介绍的内核崩溃转储功能是否正常运行，使用lkdtm功能在内核的各种位置使用崩溃测试的方法。

崩溃转储功能虽然在开发过程中非常完善，但也有可能因为PC的各种设备或设备驱动程序的操作导致运行失败。事先找出这些问题并进行修正，才能保证系统的品质。

lkdtm是Linux Kernel Dump Test Module的缩写，能通过各种处理使内核崩溃。这个模块可以测试Kdump等崩溃转储功能是否能够正常运行。lkdtm是用来进行崩溃测试这种特殊测试的，因此一般发布版内核中并未安装它。使用lkdtm时，需要启用CONFIG_LKDTM编译内核。CONFIG_LKDTM可以通过选择下列内核选项来启用。

Kernel hacking--->
<M>Linux Kernel Dump Test Tool Module

---

lkdtm的崩溃测试运行通过内核模块的变量或debugfs文件系统的接口来指定。需要指定发生崩溃的位置和崩溃原因这两个值作为崩溃测试运行的参数。将这些值作为内核模块参数时，分别作为cpoint_name和cpoint_type变量。cpoint_name的种类、cpoint_type的种类分别如表7-7、表7-8所示。

表 7-7　崩溃位置（cpoint_name）的种类

cpoint_name	说　明
INT_HARDWARE_ENTRY	硬件中断处理程序共同入口（do_IRQ）
INT_HW_IRQ_EN	中断的处理程序处理（handle_IRQ_event）
INT_TASKLET_ENTRY	软中断（tasklet_action）

（续）

cpoint_name	说　明
FS_DEVRW	从文件系统向块设备发出的 I/O 请求处理（ll_rw_block）
MEM_SWAPOUT	内存的换出处理（shrink_inactive_list）
TIMERADD	添加计时器（hrtimer_start）
SCSI_DISPATCH_CMD	发布 SCSI 命令（scsi_dispatch_cmd）
IDE_CORE_CP	针对 IDE 设备的 ioctl（generic_ide_ioctl）
DIRECT	内核模块的安装处理或延长向 debugfs 的写入

表 7-8　崩溃原因（cpoint_type）的种类

cpoint_type	说　明
PANIC	调用 panic() 函数
BUG	调用 BUG 宏
EXCEPTION	向 NULL 指针写入值，使产生例外
LOOP	执行无限循环
OVERFLOW	进行递归调用
CORRUPT_STACK	产生栈溢出
UNALIGNED_LOAD_STORE_WRITE	无视内存的对齐写入
OVERWRITE_ALLOCATION	向分配的内存区域外写入
WRITE_AFTER_FREE	释放保留的内存后，（先等到进程调度程序运行）写入数据
SOFTLOCKUP	在可中断状态下执行无限循环
HARDLOCKUP	在禁止中断状态下执行无限循环
HUNG_TASK	使当前进程进入不可中断状态，调用进程调度程序

除这些选项以外，还有下列追加选项（见表7-9）。

表 7-9　其他选项

选　项	说　明
recur_count	发生栈溢出时的递归调用次数（默认为 10 次）
cpoint_count	经过崩溃位置多少次会发生崩溃（默认为 10 次）

通过组合指定上述选项，就可以造成需要的崩溃。例如，在下例中，如果从文件系统进行20次I/O，就会产生例外（访问NULL指针）。

```
#modprobe lkdtm cpoint_name=FS_DEVRW cpoint_type=EXCEPTION cpoint_count=20
```

稍微过一段时间内核就会出现重大故障。也可以通过debugfs来指定崩溃位置和崩溃原因。如果在不指定cpoint_name和cpoint_type的情况下将lkdtm安装到内核中，就会出现/sys/kernel/debug/provoke-crash目录。这个目录下存在表示崩溃位置的特殊文件，如果表7-8中表示崩溃原因的字符串写入这些文件中的某一个，就会发生相应的内核崩溃。下例通过debugfs进行与前面同样的操作。

```
#modprobe lkdtm cpoint_count=20
#cd/sys/kernel/debug/provoke-crash
#ls
DIRECT IDE_CORE_CP INT_HW_IRQ_EN MEM_SWAPOUT TIMERADD
FS_DEVRW INT_HARDWARE_ENTRY INT_TASKLET_ENTRY SCSI_DISPATCH_CMD
#echo EXCEPTION＞FS_DEVRW
```

小结

本节介绍了使用LKDTM功能在内核中造成崩溃的方法。一般情况下，必须避免内核崩溃，但在想要检查系统品质和故障时，LKDTM却是非常有效的功能。尤其是在Kdump和集群系统（cluster system）的测试中更能发挥作用。

——Masami Hiramatsu

HACK#56　IPMI看门狗计时器

本节使用IPMI看门狗计时器可以检查出操作系统死机。

IPMI看门狗计时器

IPMI看门狗计时器是Intelligent Platform Management Interface（IPMI）标准中使用硬件的看门狗计时器。系统死机时可以执行机器自身的重启（reset）等，从而可以提高系统的可用性。

IPMI是数家电脑相关厂商制定的标准，为了获取电脑各部位的温度、电压、风扇等状态以及控制电源等而规定的接口。其中就包括本节要介绍的看门狗计时器的标准。

它与NMI看门狗计时器（参考Hack#57）的不同之处在于可以通过硬件（IPMI）执行硬启动（hard reset）。IPMI与CPU是相互独立的，因此即使硬件出现问题也有可能恢复（硬启动）。必须在服务器上安装有IPMI才能使用它。

小贴士：笔者经常遇到的硬件故障是执行shutdown或reboot命令，界面上输出Power down.或Restarting system.等最后的信息，机器却依然处于停止状态。CPU中应当执行了shutdown或reboot命令，但由于某些原因导致未执行重启。

这种情况在非正式硬件（产品版）尤其是评估版的试验机上比较多见。这种情况下可以设置后面要介绍的nowayout参数，这样即使CPU未执行重启命令，IPMI也会进行硬启动。

IPMI看门狗计时器的使用方法

要使用IPMI看门狗计时器，需要先启动将内核配置为CONFIG_IPMI_WATCHDOG=y的内核。在RHEL6中，接下来需要对配置文件/etc/sysconfig/ipmi进行如下编辑。

```
#cat/etc/sysconfg/ipmi
……
IPMI_WATCHDOG=yes
……
IPMI_WATCHDOG_OPTIONS="timeout=60 action=reset pretimeout=30 preaction=pre_int preop=preop_panic"
……
```

表7-10～表7-13分别表示各参数的意义。图7-1所示为timeout、pretimeout、action、preaction的关系。

表 7-10　指定 timeout 的各参数时的处理

参　数	说　明
timeout	到超时为止的时间（单位：秒）
pretimeout	到执行超时运行为止的时间与到执行预超时（pretimeout）运行为止的时间差（单位：秒）
action	超时的处理（reset、none、power_cycle、power_off）
preaction	预超时的处理（pre_none、pre_smi、pre_nmi、pre_int）
preop	预超时驱动程序的运行（preop_none、preop_panic）
start_now	设置为 1 时，ipmi_watchdog 模块安装到内核后立刻启动计时器。内核启动后立刻就可以通过看门狗计时器监视系统
nowayout	设置为 1 时，一旦打开 IPMI 看门狗计时器，就不会停止

表 7-11　指定 action 的各参数时的处理

参　数	说　明
none	不作任何处理
reset	重启系统（默认）
power_cycle	切断电源后重新接入
power_off	切断电源

表 7-12　指定 preaction 的各参数时的处理

参　数	说　明
pre_none	不作任何处理（默认）
pre_smi	通过 SMI（System Management Interface）通知
pre_int	使用中断向 IPMI 驱动程序通知信息
pre_nmi	使用 NMI 中断通知信息（RHEL5 系列中不能使用）

表 7-13　指定 preop 的各参数时的处理

参　数	说　明
preop_none	不作任何处理（默认）
preop_panic	使发生内核重大故障

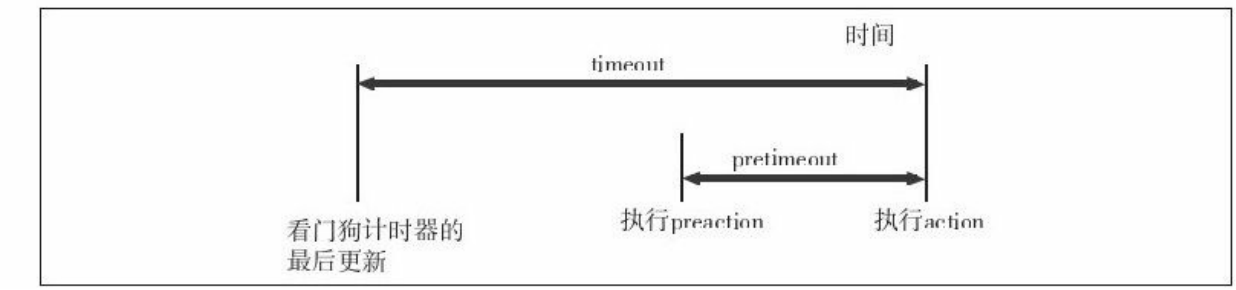

图　7-1　timeout、pretimeout、action、preaction的关系

设置nowayout参数后，就可以根据计时器不停止的情况，在reboot/shutdown命令执行后期检测出watchdog守护进程结束后的死机。

指定pre_nmi参数后，会通过NMI通知IPMI看门狗计时器超时，因此在禁止中断状态下preaction、preop也会运行。pre_nmi在RHEL5系列中不能使用。可以在上游内核、RHEL6中使用。

在/etc/sysconfig/ipmi中进行设置后，启动ipmi服务，安装IPMI模块。

启动ipmi服务，安装IPMI模块。

```
#service ipmi start
#lsmod
Module Size Used by
ipmi_watchdog 53344 0
ipmi_devintf 44944 0
ipmi_si 77644 1
ipmi_msghandler 71768 3 ipmi_watchdog, ipmi_devintf, ipmi_si
……
```

在RHEL6中启动的是watchdog守护进程。

```
#service watchdog start
```

watchdog守护进程的设置使用/etc/watchdog.conf来进行。设置如下。

```
#vi/etc/watchdog.conf
……
watchdog-device=/dev/watchdog
……
```

启动watchdog守护进程，就会启动IPMI看门狗计时器。watchdog守护进程定期对IPMI看门狗计时器进行重启（实时处理）。IPMI看门狗计时器的结构如图7-2所示。

系统正常运行时，调度watchdog守护进程，因此实时处理继续进行，但系统如果死机，watchdog守护进程作出的实时处理就会中断。这样计时器就不重启，而IPMI看门狗计时器超时。此时的运行情况如图7-3所示。

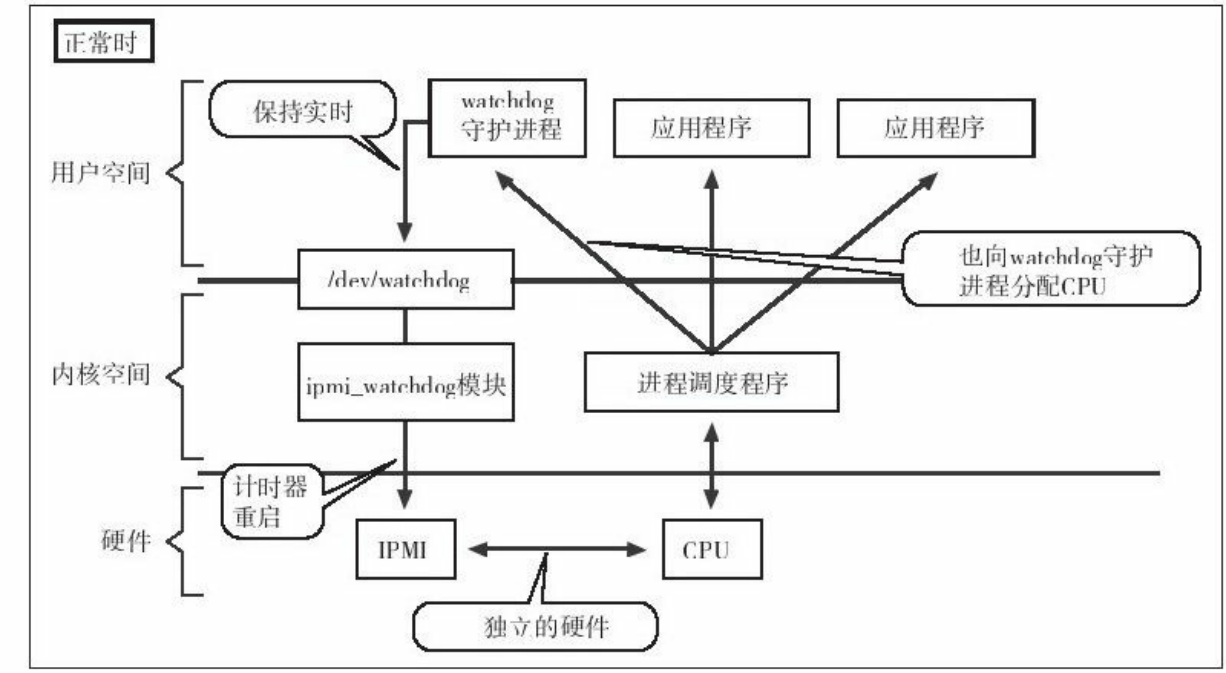

图　7-2　正常时的IPMI看门狗计时器

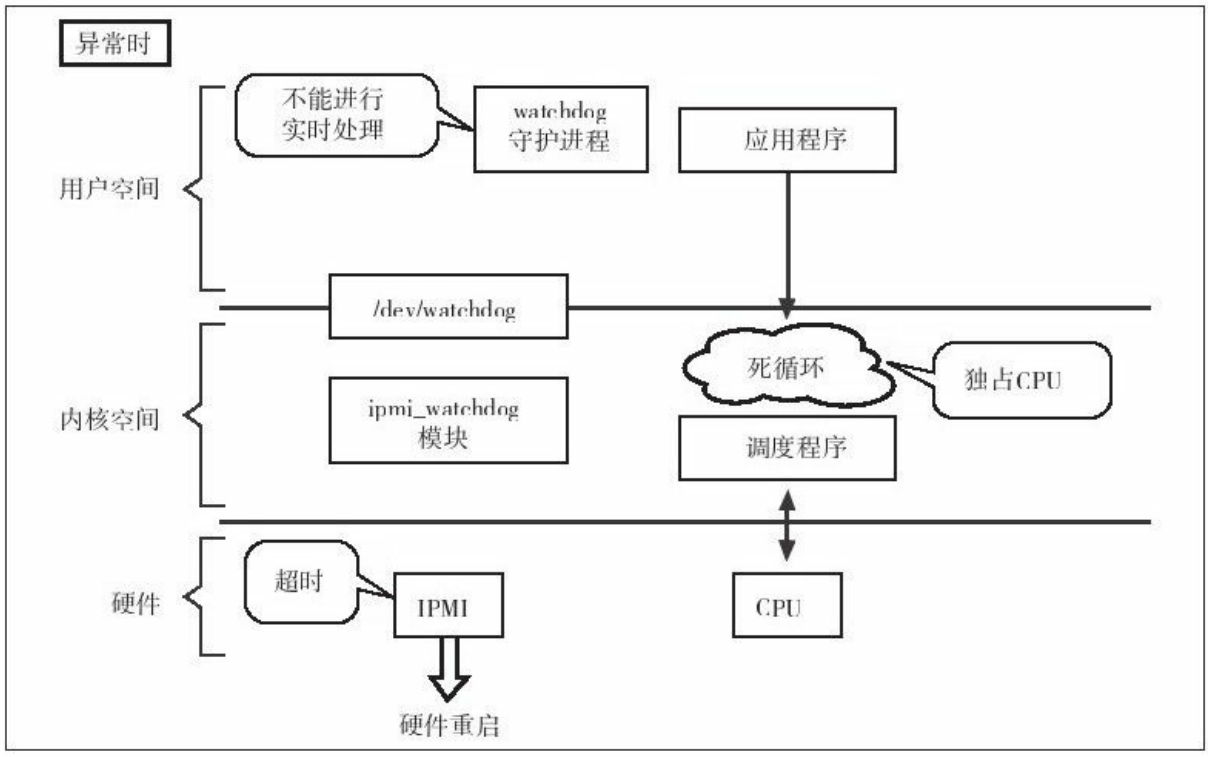

图　7-3　异常时的IPMI看门狗计时器

设置为start_now=1时，把ipmi_watchdog模块安装到内核时IPMI看门狗计时器就会开始运行，因此需要选择使watchdog守护进程启动前不会超时的pretimeout/timeout时间。

设置示例

举个一般的例子，向pretimeout设置小于timeout的值，向preaction设置pre_nmi或pre_int。将timeout设置为90、pretimeout设置为30时，IPMI看门狗计时器最后一次更新后的60秒内没有再次进行更新（系统已死机）时，执行preaction指定的操作。

另外，向preaction指定pre_int，向preop指定preop_panic，也可以获取转储。这种情况下，超过预超时时间就会通知ipmi_watchdog驱动程序，发生重大故障。

操作系统无法进行重大故障处理的情况下，接下来就会发生超时。这将通过IPMI执行action。action在不通知软件的情况下由硬件执行。

确认运行

向/dev/watchdog写入字符串，就可以确认IPMI看门狗计时器的运行。写入V则禁用IPMI看门狗计时器。

使用echo命令执行时，写入时需要按照下面这样不加入换行符。

```
#echo-n V＞/dev/watchdog
```

按照下列方式将其他字符串（在该示例中为\0）写入/dev/watchdog，文件就会关闭，通过实时处理进行的计时器重启过程就会停止。

```
#echo-n"\0"＞/dev/watchdog
#dmesg
……
IPMI Watchdog：Unexpected close, not stopping watchdog!
```

计时器不会重启，因此假设设置为timeout=60 action=reset时，执行这条命令后60秒系统就会重启。

由于是从硬件执行的，因此重启时不会输出信息等，但IPMI会在System Event Log（SEL）中记录简单的日志。重新启动后可以使用下列命令确认通过IPMI看门狗计时器进行的系统重启。

```
#ipmitool sel list
1|08/23/2007|00：21：59|Event Logging Disabled#0x51|Log area reset/cleared|Asserted
……
1b|03/10/2011|12：03：12|Watchdog 2#0x50|Timer expired|Asserted……①
1c|03/10/2011|12：11：59|Watchdog 2#0x50|Hard reset|Asserted……②
1d|03/17/2011|15：05：28|Watchdog 2#0x50|Power down|Asserted……③
```

例如，①是在执行echo-n V＞/dev/watchdog时记录的。②是在action=reset时执行重启时记录的日志。③是执行action的power_off时的记录。

NMI看门狗计时器和pre_nmi

设置了pre_nmi时，如果死机发生的时间超过pretimeout所指定的时间，就捕获主板上的NMI信号，发生NMI中断。内核上的IPMI看门狗计时器使NMI处理程序启动，如果设置了preop_panic，则发生重大故障。如果进行了Kdump等的设置，就可以获取转储。即使IPMI看门狗计时器使用pre_nmi，通过NMI通知的内存错误、I/O错误也会正常运行。

在使用NMI看门狗计时器的情况下，即使向preaction设置pre_nmi，也会输出下列信息，无法使用。这时pretimeout不运行，只有timeout的action运行。

```
#dmesg
……
IPMI Watchdog：IPMI NMI didn't seem to occur.The NMI pretimeout will likely not work
IPMI Watchdog：driver initialized
```

其他看门狗计时器

在RHEL6等中也可以使用各厂商的主板上安装的看门狗计时器。Intel TCO（Total Cost of Ownership）看门狗计时器就是其中之一。这是ICH（I/O Controller Hub, I/O控制器集线器）的一个功能。这个看门狗计时器不使用IPMI，因此机器中不需要安装IPMI。Intel TCO看门狗驱动程序的内核模块名称为iTCO_wdt。机器能够支持该内核模块时它会自动安装到内核中。使用dmesg命令时出现下列信息就表示该内核模块已经安装到内核中。

```
#dmesg
……
iTCO_vendor_support：vendor-support=0
iTCO_wdt：Intel TCO WatchDog Timer Driver v1.05
iTCO_wdt：Found a ICH7 or ICH7R TCO device（Version=2，TCOBASE=0x0860）
iTCO_wdt：initialized.heartbeat=30 sec（nowayout=0）
……
#lsmod|grep iTCO
iTCO_wdt 49232 0
iTCO_vendor_support 37124 1 iTCO_wdt
```

Intel TCO看门狗计时器的功能没有IPMI看门狗计时器那么多。只是在超时（默认为30秒）时内核重新启动。iTCO_wdt也是通过watchdog守护进程启动计时器。

iTCO_wdt驱动程序也是使用/dev/watchdog。向/dev/watchdog写入V或\0时的情况与IPMI看门狗计时器相同。

/dev/watchdog不能被多个内核模块同时使用。但是如果机器上安装了IPMI，则对于IPMI看门狗计时器的ipmi_watchdog模块和iTCO_wdt模块，先安装到内核的驱动程序将使用/dev/watchdog，后安装到内核的看门狗计时器不能使用。

要使用IPMI看门狗计时器，但是先安装到内核的是iTCO_wdt，需要通过如下方式禁止iTCO_wdt的安装。在/etc/modprobe.d/blacklist.conf中添加下列内容。

```
blacklist iTCO_wdt
```

或者在/etc/modprobe.d/dist.conf中添加下列内容。

install iTCO_wdt/bin/true

参考文献

·The Linux IPMI Driver

Documentation/IPMI. txt

·《Debug Hacks》“使用IPMI看门狗在死机时获取崩溃转储”[Hack#22]

——Naohiro Ooiwa

HACK#57　NMI看门狗计时器

本节使用x86_64或i386架构的NMI看门狗计时器功能，可以检测出系统死机。

NMI看门狗计时器

顾名思义，NMI看门狗计时器是使用NMI的看门狗计时器。可以检测出PC在禁止中断的状态下的死机。

NMI是Non Maskable Interrupt的缩写，表示无法禁止的中断。因此内核在禁止中断状态下也可以接收到NMI的通知。

中断是从硬件发出的信号，I/O的完成或数据包的接收通过中断传递到内核。内核接收到这个中断时会进行各种处理，但如果进行并行处理就会出现数据不匹配，因此在接收到1个中断时，就会禁止此后的中断直到这个中断的处理完成。

NMI并不是用来处理I/O或数据包等一般数据，而是用来通知紧急情况的，因此进行了无法禁止中断的特别处理。

内存的奇偶校验错误等系统致命错误就是需要通知的紧急情况。最近出现了定期发生NMI的功能。NMI看门狗计时器就是使用这个功能的看门狗计时器。通过NMI看门狗计时器检测出系统死机。另外在检测出死机时还可以获取内核崩溃转储。

内核使用NMI看门狗计时器检测死机的结构如下（如图7-4所示）。一般来说，计时器中断在1秒钟内发生的次数为内核配置中设置的次数（100～1000次）。

但是，例如，在禁止中断的状态下，内核进入无限循环或死锁时，就不会执行计时器中断处理。另一方面，NMI即使在这种情况下也会发生，CPU执行NMI处理程序。NMI处理程序监视是否执行了计时器中断，如果执行了计时器中断，就会超时，认为系统已死

机，如图7-5所示。

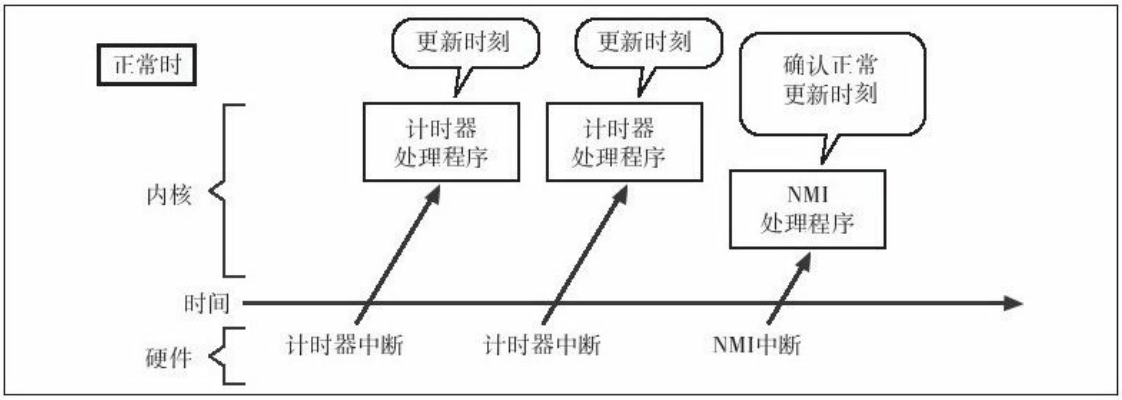

图　7-4　内核检测死机的结构

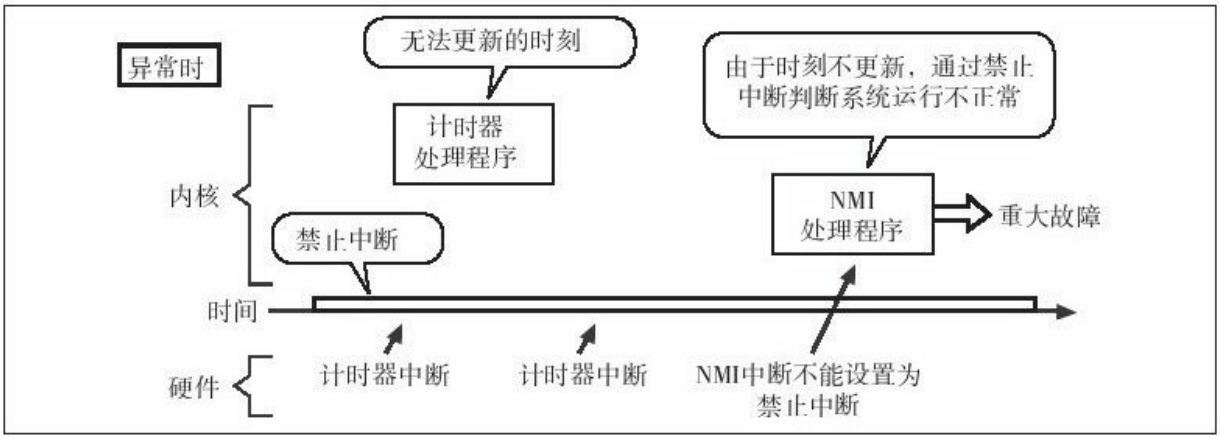

图　7-5　检测出死机时

RHEL6中的超时时间默认为30秒。上游内核中为5秒。

NMI看门狗计时器的使用方法

使用NMI看门狗计时器前需要将内核启动参数进行如下设置。

```
nmi_watchdog=N
```

N可以写入0～2的值。0用来禁用NMI看门狗。如果是具有IO-APIC的机器则设置为1（I/O-APIC模式）；如果不具有IO-APIC则设置为2（本地APIC模式）。

安装了Local APIC NMI的机器上将输出如①所示的信息。此时如果设置为nmi_watchdog=2，就会输出②，NMI看门狗计时器运行。

```
#dmesg
……
ACPI：LAPIC_NMI（acpi_id[0xff]high level lint[0x1]）……①
……
Testing NMI watchdog……OK……②
```

如果在Local APIC的机器上设置为nmi_watchdog=1，则在RHEL6的情况下就会登录虚拟的APIC计时器，执行NMI看门狗计时器。

#dmesg……

APIC timer registered as dummy, due to nmi_watchdog=1！……

Testing NMI watchdog……OK.

NMI看门狗计时器超时，就是指系统由于某些故障死机。想要找出原因时，可以在NMI看门狗计时器超时时提取内核崩溃转储。设置如下。

nmi_watchdog=panic, N（N为1或2）

必须事先进行Kdump（Hack#54）或diskdump（Hack#53）的设置。在内核运行过程

中，

禁用NMI看门狗计时器时，可以将/proc/sys/kernel/nmi_watchdog设置为0。

关于NMI的其他参数

sysctl中还有其他关于NMI的参数，下面就将进行介绍。

/proc/sys/kernel/unknown_nmi_panic

如果将这个参数设置为0以外的值，就会在发生不明情况的NMI时造成重大故障[1]。当服务器上有NMI键时，需要事先将unknown_nmi_panic设置为0以外的值。当系统死机时，有时按NMI键就可以获取转储。

/proc/sys/kernel/panic_on_unrecovered_nmi

如果将这个参数设置为0以外的值，就会在发生内存奇偶校验错误或不明情况的NMI时造成重大故障。即使unknown_nmi_panic为0，如果将panic_on_unrecovered_nmi设置为1等，也会在发生不明情况的NMI时造成重大故障。不明情况的错误有内存故障或PCI总线的错误等。设置了EDAC（Error Detection And Correction，错误检测和校正）时不会造成重大故障，而是由EDAC运行。

/proc/sys/kernel/panic_on_io_nmi

如果将这个参数设置为0以外的值，就会在因I/O错误而发生NMI时造成重大故障。

——Naohiro Ooiwa

[1]注1：重大故障对应的英文为panic。

HACK#58　soft lockup

本节介绍Linux内核中安装的锁定检测功能soft lockup。

Linux内核中安装了称为soft lockup的锁定检测功能。使用soft lockup，可以检测出由于内核或设备驱动程序等软件的故障导致内核功能无法运行的状态。

在关键任务（critical mission）等领域，如果一直处于服务停止的状态，就会造成很大的问题。因此，就需要使用这样的锁定检测功能，尽早检测出服务停止的情况。在检测锁定的同时使内核出现重大故障，就可以更简单地自动重启内核以恢复服务，或从外部检测出故障，尽快恢复服务。

soft lockup的结构

soft lockup的锁定检测是使用名称为watchdog的内核线程进行的。watchdog内核线程采用优先级最高的实时等级的FIFO调度策略。如果这个watchdog线程没有达到一定的运行时间，就可以检测出进程调度程序未正常运行，即发生锁定。

使用ps命令，可以确认watchdog内核线程是存在的，详情如下。

```
# ps aux|grep watchdog
root         5  0.0  0.0      0     0 ?        S    19:14   0:00 [watchdog/0]
root         8  0.0  0.0      0     0 ?        S    19:14   0:00 [watchdog/1]
root        11  0.0  0.0      0     0 ?        S    19:14   0:00 [watchdog/2]
root        14  0.0  0.0      0     0 ?        S    19:14   0:00 [watchdog/3]
```

这些内核线程定期（检测时间的20%）由计时器唤醒。唤醒的watchdog内核线程会记录自己唤醒的时刻。如果从这个watchdog记录的时刻开始，不更新的时间超过指定的时间，则判断发生了锁定。

soft lockup的设置

soft lockup可以使用sysctl进行设置。

softlockup_thresh

指定到检测出锁定为止的时间。单位为秒，初始值为60秒。

softlockup_panic

选择检测出锁定时是否使内核出现重大故障。如果将值设置为on（1），则在检测出锁定时立刻发生内核重大故障。初始值为off（0）。

例如，要将检测时间设置为10秒，检测出锁定时发生重大故障，需将sysctl进行如下设置。

```
#sysctl-w kernel.softlockup_thresh=10
#sysctl-w kernel.softlockup_panic=1
```

soft lockup的确认

接下来实际确认锁定的检测情况。本次使用的是Fedora 14。

这里在初始化代码中生成执行死循环的内核模块。安装这个模块后，内核就会进行无限循环处理，进入锁定状态。

源文件和Makefile如下所示。

```
#cat Makefle
obj-m：=lockup.o
#cat lockup.c
#include＜linux/module.h＞
static int lockup_init（void）
{
for（；）
；
return 0；
}
static void lockup_exit（void）
{
}
module_init（lockup_init）；
module_exit（lockup_exit）；
```

执行make，创建内核模块。

```
#make-C/lib/modules/2.6.35.11-83.fc14.x86_64/build M='pwd'modules
```

当前目录下应当生成了lockup.ko。下面使用insmod命令将问题模块安装到内核中。当执行insmod命令时，内核就会因无限循环而进入锁定状态。约60秒后锁定检测出来，就会输出如下所示的BUG：soft lockup之后的内容。

这个模块初始化无限循环不会结束，因此需要在确认锁定之后重启。

```
#insmod lockup.ko
[1001.569249]lockup：module license'unspecified'taints kernel.
[1001.571751]Disabling lock debugging due to kernel taint
[1066.226006]BUG：soft lockup-CPU#0 stuck for 61s！[insmod：1374]
```

[1066.226006]Modules linked in：lockup（P+）ip6t_REJECT nf_conntrack_ipv6 ip6table_filter ip6_tables ipv6 i2c_piix4 ppdev parport_pc parport virtio_net i2c_core virtio_blk virtio_pci virtio_ring virtio[last unloaded：scsi_wait_scan]
[1066.226006]CPU 0
[1066.226006]Modules linked in：lockup（P+）ip6t_REJECT nf_conntrack_ipv6 ip6table_filter ip6_tables ipv6 i2c_piix4 ppdev parport_pc parport virtio_net i2c_core virtio_blk virtio_pci virtio_ring virtio[last unloaded：scsi_wait_scan]
[1066.226006]
[1066.226006]Pid：1374，comm：insmod Tainted：P 2.6.35.11-83.
fc14.x86_64#1/Bochs
[1066.226006]RIP：0010：[＜ffffffffa00fa009＞][＜ffffffffa00fa009＞]lockup_init+0x9/0xb[lockup]
[1066.226006]RSP：0018：ffff880037b59f08 EFLAGS：00000246
[1066.226006]RAX：ffff880037b59fd8 RBX：ffff880037b59f08 RCX：0000000000000000
[1066.226006]RDX：0000000000000001 RSI：0000000000000000 RDI：ffffffffa00fa000
[1066.226006]RBP：ffffffff8100a68e R08：0000000000000000 R09：ffff88003d51a128
[1066.226006]R10：ffffffffa00fa280 R11：0000000000000000 R12：ffffffffa00fa050
[1066.226006]R13：ffffffffa00fa280 R14：ffffffff810c3200 R15：ffff880037b59ea8
[1066.226006]FS：00007fb3b696b720（0000）GS：ffff880002000000（0000）knlGS：0000000000000000
[1066.226006]CS：0010 DS：0000 ES：0000 CR0：000000008005003b
[1066.226006]CR2：0000000000e58050 CR3：000000003bbe9000 CR4：0000000000006f0
[1066.226006]DR0：0000000000000000 DR1：0000000000000000 DR2：0000000000000000
[1066.226006]DR3：0000000000000000 DR6：00000000ffff0ff0 DR7：0000000000000400
[1066.226006]Process insmod（pid：1374，threadinfo ffff880037b58000，task ffff88003b961740）
[1066.226006]Stack：
[1066.226006]ffff880037b59f38 ffffffff810021a1 00000000000164e3 ffffffffa00fa050
[1066.226006]＜0＞0000000000000000 0000000001d0e030 ffff880037b59f78 ffffffff8107cce1
[1066.226006]＜0＞0000000001d0e010 00000000000164e3 00000000000164e3 00007fffedd1fe69
[1066.226006]Call Trace：
[1066.226006][＜ffffffff810021a1＞]?do_one_initcall+0x5e/0x155
[1066.226006][＜ffffffff8107cce1＞]?sys_init_module+0xa6/0x1e4
[1066.226006][＜ffffffff81009cf2＞]?system_call_fastpath+0x16/0x1b
[1066.226006]Code：＜eb＞fe 55 48 89 e5 0f 1f 44 00 00 c9 c3 90 90 04 00 00 00 14 00 00
[1066.226006]Call Trace：
[1066.226006][＜ffffffff810021a1＞]?do_one_initcall+0x5e/0x155
[1066.226006][＜ffffffff8107cce1＞]?sys_init_module+0xa6/0x1e4
[1066.226006][＜ffffffff81009cf2＞]?system_call_fastpath+0x16/0x1b

---

此外，也可以应对像下面这样适用实时等级的FIFO调度策略的进程持续占用CPU的情况。而Fedora 14在标准设置中对于实时等级的CPU时间不加限制，因此无法直接检测出锁定。这里设置为sched_rt_runtime_us=-1，来解除对实时级进程的CPU时间的限制。

```
#cat lockup.c
#include＜sched.h＞
int main（int argc, char**argv）
{
struct sched_param p={.sched_priority=99}；
sched_setscheduler（0，SCHED_FIFO，＆p）；
for（；）
；
return 0；
}
----
#gcc-g-O2-o lockup lockup.c
#sysctl-w kernel.sched_rt_runtime_us=-1
kernel.sched_rt_runtime_us=-1
#./lockup
```

[638.877007]BUG：soft lockup-CPU#0 stuck for 61s！[lockup：1204]
[638.877007]Modules linked in：ip6t_REJECT nf_conntrack_ipv6 ip6table_filter ip6_tables ipv6 ppdev parport_pc parport i2c_piix4 virtio_net i2c_core virtio_blk virtio_pci virtio_ring virtio[last unloaded：scsi_wait_scan]
[638.877007]CPU 0
[638.877007]Modules linked in：ip6t_REJECT nf_conntrack_ipv6 ip6table_filter ip6_tables ipv6 ppdev parport_pc parport i2c_piix4 virtio_net i2c_core virtio_blk virtio_pci virtio_ring virtio[last unloaded：scsi_wait_scan]
[638.877007]
[638.877007]Pid：1204，comm：lockup Not tainted 2.6.35.11-83.fc14.x86_64#1/Bochs
[638.877007]RIP：0033：[＜00000000004004fa＞][＜00000000004004fa＞]0x4004fa
[638.877007]RSP：002b：00007fff4e495fb0 EFLAGS：00000217
[638.877007]RAX：0000000000000000 RBX：0000000000000000 RCX：00007eff7c9395a7
[638.877007]RDX：00007fff4e495fb0 RSI：0000000000000001 RDI：0000000000000000
[638.877007]RBP：ffffffff8100a68e R08：00007eff7cc075e0 R09：00007eff7cc1b230
[638.877007]R10：00007fff4e495d20 R11：0000000000000202 R12：00007fff4e4960a0
[638.877007]R13：00000000004003f0 R14：0000000000000000 R15：00000000004003f0
[638.877007]FS：00007eff7ce22720（0000）GS：ffff880002000000（0000）
knlGS：0000000000000000
[638.877007]CS：0010 DS：0000 ES：0000 CR0：0000000080050033
[638.877007]CR2：00007eff7c9395a0 CR3：000000003750c000 CR4：00000000000006f0
[638.877007]DR0：0000000000000000 DR1：0000000000000000 DR2：0000000000000000
[638.877007]DR3：0000000000000000 DR6：00000000ffff0ff0 DR7：0000000000000400
[638.877007]Process lockup（pid：1204，threadinfo ffff88003dc38000，task ffff88003b961740）
[638.877007]
[638.877007]Call Trace：

锁定检测的限制

前面对内核soft lockup功能的锁定检测进行了确认，但是该功能的结构不能检测出禁止中断状态下的锁定。这是因为soft lockup的检测是通过计时器中断的延长来进行的。禁止中断状态下的锁定检测可以使用NMI看门狗计时器Hack#57或IPMI看门狗计时器Hack#56。

为了验证soft lockup功能是无法检测的，这里使用测试用内核模块（hardlockup.c）在禁止中断状态下进行无限循环。

```
#cat hardlockup.c
#include＜linux/module.h＞
#include＜linux/irqflags.h＞
static int lockup_init（void）
{
local_irq_disable（）；
for（；）
；
return 0；
}
static void lockup_exit（void）
{
}
module_init（lockup_init）；
module_exit（lockup_exit）；
```

避免soft lockup的错误检测

在自己生成的Linux内核的驱动程序或模块中，soft lockup功能有时会出问题。当要实现的功能需要长时间的CPU运行时，soft lockup功能有可能错误地识别锁定（或死档）。在这种情况下，可以从相应的功能中调用_touch_watchdog（）函数，在不禁用soft lockup功能的情况下避免错误检测。

此外，也可以向内核启动参数传递nosoftlockup来禁用soft lockup功能。

小结

本节介绍了Linux内核中的锁定检测功能之一—soft lockup。使用soft lockup，可以检测出软件bug引起的问题，并通过造成内核出现重大故障等自动进行恢复。在Linux应用中，为了不使服务由于内核的问题而一直处于停止状态，需要进行一些设置。

——Hiroshi Shimamoto

HACK#59　crash命令

本节介绍使用方便的crash命令和使用方法。

crash命令是可以分析内核映像的调试工具。它在gdb命令的基础上设计，可以运行用来引用内核内部各种信息的众多命令，以会话形式进行操作。通过Kdump等转储机构提取的内核崩溃转储和运行中的实时内核就是作为分析对象的内核映像。本节将介绍便捷的crash命令和使用方法。

支持范围

本书写作时crash命令的最新版为5.1.5。主要的Linux发布版都提供了工具包包。RHEL4和RHEL5中的版本号为crash命令的4系列，RHEL6中为5系列。

支持的架构如下。

·X86

·X86_64

·LA64

·PPC64

·s390

·s390x

·ARM

可以处理通过下列方法提取的内核映像。

·通过diskdump/netdump提取的内核崩溃转储（RHEL4）。

·通过Kdump提取的内核崩溃转储（RHEL5、RHEL6）。

·通过makedumpfile转换的内核崩溃转储（RHEL5、RHEL6）。

·通过virsh dump命令提取的KVM客户端的内核崩溃转储（RHEL6）。

·实时内核

小贴士：crash的设计可以应对各种Linux内核的版本或发布版，以约1个月的较短周期进行更新。如果使用发布版的crash无法正常运行，可以先尝试论坛上的最新版。如果还是不能运行请向论坛报告。

安装与启动的方法

crash命令的最新版可以从论坛的网页（http：//people.redhat.com/anderson/）获取。有tar文件格式和source rpm数据包格式。tar文件格式的创建方法如下。

```
$wget-c"http：//people.redhat.com/anderson/crash-5.1.5.tar.gz"
$tar xf crash-5.1.5.tar.gz
$cd./crash-5.1.5
$make
```

小贴士：从5.0.7版开始可以在X86上创建用于ARM的执行文件。在X86上创建的方法如下。

```
$make target=ARM
```

同样，从5.0.8版开始可以在X86_64上创建用于X86的执行文件。在X86_64上创建的方法如下。

```
$make target=X86
```

要使用crash命令，必须要有与内核映像对应的调试信息文件。调试信息文件就是内核创建时生成的名称为vmlinux的文件。在RHEL的工具包命名为kernel-debuginfo。

启动crash的方法如下所示。vmlinux为调试信息文件，vmcore为内核崩溃转储文件。

```
$crash vmlinux vmcore
```

分析实时内核时只需要第1个参数。

```
$crash vmlinux
```

小贴士：在实时内核的情况下，crash为了参照物理内存，使用/dev/mem、/proc/kcore

以及/dev/crash中的某一个的内核接口。也可以将这些直接指定为第2个参数。但是有些内核无法使用/dev/mem和/proc/kcore，这时使用/dev/crash。/dev/crash是为其他两个不能使用的情况而准备的crash特有驱动程序。省略第2个参数后，crash就会在各个接口依次进行激活处理，选择可使用的接口。

小贴士：在crash 5.1.3以后的版本中，可以处理以gzip格式和bzip2格式压缩的vmlinux。可以节约磁盘空间。

启动crash后，就会开始对话形式的命令输入。然后使用各种命令分析内核映像。

实用工具命令（utility command）

首先介绍使用crash时的实用工具命令。

set命令

set命令是运用非常广泛的命令。指定进程后，就会将进程的上下文切换到指定的进程，显示这个上下文。没有指定时显示当前进程的上下文。进程上下文的初始值为内核发生重大故障时运行的进程的初始值。

```
crash＞set
PID：1474
COMMAND："sh"
TASK：ffff88001c5c9740[THREAD_INFO：ffff88001b76a000]
CPU：0
STATE：TASK_RUNNING（PANIC）
```

使用-c选项可以指定CPU，并显示之前在这个CPU上运行的进程。使用-p选项可以显示发生重大故障时运行的进程。

使用set命令可以确认当前的编辑器设置。

```
crash＞set-v|grep edit
edit：vi
```

要指定命令行编辑模式时，需要在crash启动时指定。

```
#crash-e[vi|emacs]……
```

设置为emacs，就可以进行与bash相同的键操作。

crash命令有时会输出大量的信息，可以使用下列命令禁用界面的scroll功能。

```
crash＞set scroll off
```

此外使用下列命令也可以禁用界面的scroll功能。

```
crash＞sf
```

sf是通过别名定义设置的，是set scroll off的别名。默认的别名定义可以使用alias来确认。

```
crash> alias
ORIGIN   ALIAS    COMMAND
builtin  man      help
builtin  ?        help
builtin  quit     q
builtin  sf       set scroll off
builtin  sn       set scroll on
builtin  hex      set radix 16
builtin  dec      set radix 10
builtin  g        gdb
builtin  px       p -x
builtin  pd       p -d
builtin  for      foreach
builtin  size     *
builtin  dmesg    log
builtin  lsmod    mod
builtin  last     ps -l
```

eval命令

eval命令将输入的表达式的计算结果以十六进制、十进制、八进制以及二进制显示。指定-b选项就会显示在二进制中第几位是1。表达式可以使用四则运算（-、+、*、/、%）、位运算（&、|、^）、shift运算（＜＜、＞＞）。

```
crash＞eval 1＜＜12
hexadecimal：1000（4KB）
decimal：4096
octal：10000
binary：0000000000000000000000000000000000000000000000000001000000000000
crash＞eval（～4096-1）
hexadecimal：fffffffffffeffe
decimal：18446744073709547518（-4098）
octal：1777777777777777767776
binary：1111111111111111111111111111111111111111111111111110111111111110
crash＞eval-b 10001e1
hexadecimal：10001e1
decimal：16777697
```

octal：100000741
binary：00000000000000000000000000000000000000000000100000000000000000111100001
bits set：24 8 7 6 5 0

---

ascii命令

ascii命令将十六进制转换为字符串。

---

crash＞rd modprobe_path 2
ffffffff813213a0：6f6d2f6e6962732f 000065626f727064/sbin/modprobe..
crash＞ascii 6f6d2f6e6962732f
6f6d2f6e6962732f：/sbin/mo

---

history命令

history命令显示已输入命令的记录。也可以使用别名h。

---

crash＞history
[1]set
[2]set vi
[3]set scroll off
crash＞h
[1]set
[2]set vi
[3]set scroll off

参照内核信息的命令

这里介绍用来获取内核内部信息的命令。

bt命令

bt命令输出进程的内核栈的遍历。它是使用频率较高的命令。要显示所有进程的遍历，可以使用下列foreach命令。

```
crash＞foreach bt-tf
```

当栈上存在具有内核文本符号（text symbol）的地址时，-t选项显示这些符号。在一般的回溯处理失败时可以使用该选项。

```
crash＞bt 839
PID：839 TASK：ffff88001ca82e80 CPU：2 COMMAND："rsyslogd"
#0[ffff88001d8fdd58]schedule at ffffffff8146888f
#1[ffff88001d8fde20]do_syslog at ffffffff8104e167
#2[ffff88001d8fdea0]kmsg_read at ffffffff81169c80
#3[ffff88001d8fdec0]proc_reg_read at ffffffff81160cac
#4[ffff88001d8fdf00]vfs_read at ffffffff8111750d
#5[ffff88001d8fdf40]sys_read at ffffffff811175ab……
crash＞bt-t 839
PID：839 TASK：ffff88001ca82e80 CPU：2 COMMAND："rsyslogd"
START：schedule at ffffffff8146888f
[ffff88001d8fde20]do_syslog at ffffffff8104e167
[ffff88001d8fde48]autoremove_wake_function at ffffffff81066633
[ffff88001d8fde60]pvclock_clocksource_read at ffffffff8102c275
[ffff88001d8fdea0]kmsg_read at ffffffff81169c80
[ffff88001d8fdec0]proc_reg_read at ffffffff81160cac
[ffff88001d8fdf00]vfs_read at ffffffff8111750d
[ffff88001d8fdf40]sys_read at ffffffff811175ab
……
```

-f选项显示框架（frame）内的所有栈数据。这个选项可以在确认函数的参数时使用。

-l选项显示文件名和行数。

```
crash＞bt-l 839
PID：839 TASK：ffff88001ca82e80 CPU：2 COMMAND："rsyslogd"
#0[ffff88001d8fdd58]schedule at ffffffff8146888f
```

/usr/src/debug/kernel-2.6.35.fc14/linux-2.6.35.x86_64/kernel/sched.c：2820#1[ffff88001d8fde20]do_syslog at ffffffff8104e167
/usr/src/debug/kernel-2.6.35.fc14/linux-2.6.35.x86_64/kernel/printk.c：289#2[ffff88001d8fdea0]kmsg_read at ffffffff81169c80
/usr/src/debug/kernel-2.6.35.fc14/linux-2.6.35.x86_64/fs/proc/kmsg.c：39#3[ffff88001d8fdec0]proc_reg_read at ffffffff81160cac
/usr/src/debug/kernel-2.6.35.fc14/linux-2.6.35.x86_64/fs/proc/inode.c：165#4[ffff88001d8fdf00]vfs_read at ffffffff8111750d
/usr/src/debug/kernel-2.6.35.fc14/linux-2.6.35.x86_64/fs/read_write.c：310#5[ffff88001d8fdf40]sys_read at ffffffff811175ab
/usr/src/debug/kernel-2.6.35.fc14/linux-2.6.35.x86_64/fs/read_write.c：388……

-a选项仅显示各CPU上原本正在运行的进程。但是针对运行中的系统（实时内核）启动crash命令时，不支持这个选项。

---

crash＞bt-a
bt：-a option not supported on a live system

小贴士：从5.1.1版开始，当指定-t时，即使是活动系统也会运行。

使用task命令获取栈指针，通过rd-s引用栈区域，就可以得到接近bt-t的信息。

---

crash＞task 839|grep sp
sp0=0xffff88001d8fe000，
sp=0xffff88001d8fdd58，
……
crash＞rd 0xffff88001d8fdd58-e 0xffff88001d8fe000-s
……
ffff88001d8fde18：ffff88001d8fde98 do_syslog+0x10f
ffff88001d8fde28：ffff880000000004 ffffffff00000000
ffff88001d8fde38：0000000000000000 ffff88001ca82e80
ffff88001d8fde48：autoremove_wake_function log_wait+0x8
ffff88001d8fde58：log_wait+0x8 pvclock_clocksource_read+0x48
ffff88001d8fde68：00007f96ffffffff 00007f969248b360
ffff88001d8fde78：0000000000000fff ffff88001d8fdf58
ffff88001d8fde88：0000000000000000 0000000000000003
ffff88001d8fde98：ffff88001d8fdeb8 kmsg_read+0x4d
ffff88001d8fdea8：ffff88001b455d80 ffff88001b6cc000
ffff88001d8fdeb8：ffff88001d8fdef8 proc_reg_read+0x73
ffff88001d8fdec8：ffff88001d8fdef8 ffff88001d8fdf58
ffff88001d8fded8：0000000000000fff 00007f969248b360
ffff88001d8fdee8：ffff88001b6cc000 00007f969248b360
ffff88001d8fdef8：ffff88001d8fdf38 vfs_read+0xa9
ffff88001d8fdf08：ffff88001d8fdf18 ffff88001db55000
ffff88001d8fdf18：ffff88001d8fdf38 ffff88001b6cc000
ffff88001d8fdf28：00007f969248b360 00007f968bfff9c0
ffff88001d8fdf38：ffff88001d8fdf78 sys_read+0x4a
……

---

dev命令

dev命令显示字符设备（character device）的列表。使用-p选项显示PCI设备。它的输出与lspci命令相同。使用-i选项显示I/O端口和I/O内存。内容基本与下列命令相同。

```
#cat/proc/ioports
#cat/proc/iomem
```

dis命令

dis命令是进行反汇编的命令。如果指定-l选项，还会显示源代码名称和行编号。

```
crash＞dis-l schedule
/usr/src/debug/kernel-2.6.35.fc14/linux-2.6.35.x86_64/kernel/sched.c：3813
0xffffffff81468385＜schedule＞：push%rbp
0xffffffff81468386＜schedule+0x1＞：mov%rsp，%rbp
0xffffffff81468389＜schedule+0x4＞：push%r15
0xffffffff8146838b＜schedule+0x6＞：push%r14
0xffffffff8146838d＜schedule+0x8＞：push%r13
0xffffffff8146838f＜schedule+0xa＞：push%r12
0xffffffff81468391＜schedule+0xc＞：push%rbx
……
```

files命令

files命令显示进程打开的文件的信息。

```
crash＞fles 1474
PID：1474 TASK：ffff88001c5c9740 CPU：0 COMMAND："sh"
ROOT：/CWD：/home/hat
FD FILE DENTRY INODE TYPE PATH
0 ffff88001bccd900 ffff88001eb23cc0 ffff88001edfbc30 CHR/dev/tty1
1 ffff88001b655b40 ffff88001d215f00 ffff88001909d1b0 REG/proc/sysrq-trigger
2 ffff88001bccd900 ffff88001eb23cc0 ffff88001edfbc30 CHR/dev/tty1
10 ffff88001bccd900 ffff88001eb23cc0 ffff88001edfbc30 CHR/dev/tty1
```

irq命令

irq命令显示关于内核内部管理的中断的信息。

kmem命令

显示关于内核的内存使用情况的信息。-s选项显示slab缓存（slab cache）的信息。信息与/proc/slabinfo相同。

```
crash> kmem -s
CACHE            NAME                 OBJSIZE  ALLOCATED     TOTAL  SLABS  SSIZE
ffff88001f511840 rpc_inode_cache          816         19        19      1    16k
ffff88001f8ab540 ndisc_cache              320         17        24      2     4k
ffff880019ca66c0 UDPLITEv6               1000          0         0      0    16k
ffff880019ca6840 UDPv6                   1000         48        48      3    16k
...
```

-i选项显示内存的整体使用情况。等同于free命令。

crash＞kmem-i
PAGES TOTAL PERCENTAGE

```
      TOTAL MEM     93411      364.9 MB         ----
           FREE     46292      180.8 MB    49% of TOTAL MEM
           USED     47119      184.1 MB    50% of TOTAL MEM
         SHARED     10469       40.9 MB    11% of TOTAL MEM
        BUFFERS      5290       20.7 MB     5% of TOTAL MEM
         CACHED     20584       80.4 MB    22% of TOTAL MEM
           SLAB      9231       36.1 MB     9% of TOTAL MEM

     TOTAL SWAP    507647        1.9 GB         ----
      SWAP USED         0             0     0% of TOTAL SWAP
      SWAP FREE    507647        1.9 GB   100% of TOTAL SWAP
```

使用-p选项显示内存映射。也可以指定地址。[]中的页面表示尚未释放内存。

```
crash> kmem ffff88001faf1cf0
CACHE            NAME                 OBJSIZE  ALLOCATED     TOTAL  SLABS  SSIZE
ffff88001ec04780 vm_area_struct           184       3614      3630    165     4k
  SLAB              MEMORY            NODE  TOTAL  ALLOCATED  FREE
  ffffea00006ee4b8  ffff88001faf1000     0     22         21     1
  FREE / [ALLOCATED]
  [ffff88001faf1cf0]

      PAGE        PHYSICAL      MAPPING       INDEX CNT FLAGS
ffffea00006ee4b8 1faf1000                0 ffff88001faf17e8  1 20000000000080
```

当引用某个内存发生重大故障时，如果使用-p选项，就可以确认这个内存是已释放还是仍在使用。

list命令

list命令查找在内核中共同使用的list_head结构的链接列表，依次显示列表上的对象（object）。

```
crash＞list modules
ffffffff81a59120
ffffffffa01e7598
……
ffffffffa0007e08
ffffffffa0000828
crash＞list modules|wc-l
28
crash＞
```

可以看出modules列表中连接了28个对象。下面是对象中间存在list_head结构的成员的例子。这种情况下使用-o选项指定对象中的list_head结构的位置，同样会查找列表。

```
crash＞struct packet_type.list
struct packet_type{
[0x40]struct list_head list；
}
```

可以得知list_head结构的offset为0x40，这可以在-o选项中指定。

```
crash＞list-o 0x40 ip_packet_type
ffffffff81b881a0
ffffffff81b85ea0
ffffffff81b85ee0
ffffffff81b85f20
ffffffff81b88720
```

可以看出ip_packet_type的list成员连接了5个对象。

加上-s选项，这个对象的成员也会同时显示。下面是查找列表并显示各对象的func成员的例子。

```
crash＞list-o 0x40 ip_packet_type-s packet_type.func
ffffffff81b881a0
func=0xffffffff813f109b＜ip_rcv＞，
ffffffff81b85ea0
func=0xffffffff81b85eb0，
```

ffffffff81b85ee0
func=0xffffffff81b85ef0，
ffffffff81b85f20
func=0xffffffff81b85f30，
ffffffff81b88720
func=0，

---

mod命令

mod命令显示内核模块的信息，读入符号信息或调试信息。不指定选项时只显示内核模块信息。使用-s选项指定要读入的内核模块。使用-S选项指定目录，就会尝试从所指定的目录自动检索并读入模块。

```
crash> mod
     MODULE       NAME                 SIZE  OBJECT FILE
ffffffffa0000d80  virtio_blk           5009  (not loaded)  [CONFIG_KALLSYMS]
ffffffffa003f900  ipv6               282108  (not loaded)  [CONFIG_KALLSYMS]
ffffffffa00514c0  ip6_tables          16850  (not loaded)  [CONFIG_KALLSYMS]
...
crash> mod -s virtio_blk /lib/modules/2.6.38.6-27.fc15.x86_64/kernel/drivers/
block/virtio_blk.ko
     MODULE       NAME                 SIZE  OBJECT FILE
ffffffffa0000d80  virtio_blk             5009  /lib/modules/2.6.38.6-27.fc15.
x86_64/kernel/drivers/block/virtio_blk.ko
crash> mod -S
     MODULE       NAME                 SIZE  OBJECT FILE
ffffffffa0000d80  virtio_blk             5009  /lib/modules/2.6.38.6-27.fc15.
x86_64/kernel/drivers/block/virtio_blk.ko
ffffffffa003f900  ipv6                 282108  /lib/modules/2.6.38.6-27.fc15.
x86_64/kernel/net/ipv6/ipv6.ko
ffffffffa00514c0  ip6_tables            16850  /lib/modules/2.6.38.6-27.fc15.
x86_64/kernel/net/ipv6/netfilter/ip6_tables.ko
...
```

net命令

net命令显示网络设备的信息列表。指定显示的net_device结构的地址，使用struct命令进行转储，就可以获取更加详细的信息。

---

crash＞net
NET_DEVICE NAME IP ADDRESS（ES）
ffffffff8030f680 lo 127.0.0.1
ffff81007ea24000 eth2 192.168.0.155
ffff81007f7b8000 eth3 192.168.0.156
ffff81007ebbd000 eth0 172.16.0.153
ffff81007e1ff000 eth1
ffff81007d50a000 sit0

```
crash＞struct net_device ffff81007ea24000
struct net_device{
name="eth2￥00045090668￥000￥000"，
name_hist={
next=0x0，
pprev=0xffffffff804bae90
}，
……
```

p命令

向gdb的print命令传递输入时，p命令可以显示结果。

```
crash＞p init_mm
init_mm=$14={
mmap=0x0，
mm_rb={
rb_node=0x0
}，
mmap_cache=0x0，
get_unmapped_area=0，
……
```

输入为CPU个别符号（percpu）时，显示各CPU个别区域的地址。

```
crash＞p x86_bios_cpu_apicid
PER-CPU DATA TYPE：
u16 x86_bios_cpu_apicid；
PER-CPU ADDRESSES：
[0]：ffff88003fc0dc10
[1]：ffff88003fd0dc10
```

ps命令

ps命令显示进程信息。-a选项显示赋予该进程的命令行变量和环境变量。

```
crash＞ps-a rsyslogd
PID：624 TASK：ffff880037b9dc80 CPU：0 COMMAND："rsyslogd"
ARG：/sbin/rsyslogd-n-c 5
ENV：PATH=/usr/local/sbin：/usr/local/bin：/usr/sbin：/usr/bin：/sbin：/bin
LANG=ja_JP.UTF-8
LISTEN_PID=624
LISTEN_FDS=1
SYSLOGD_OPTIONS=-c 5
```

-t选项显示进程的运行时间、开始时刻、用户空间及内核空间上的执行时间。

```
crash＞ps-t rsyslogd
PID：624 TASK：ffff880037b9dc80 CPU：0 COMMAND："rsyslogd"
RUN TIME：07：43：23
START TIME：10
UTIME：2
STIME：13
```

rd命令

rd命令是读取内存内容的命令。本节在ascii命令、bt命令、wr命令的解说中都使用过该命令。

runq命令

runq命令显示连接到进程调度程序的运行队列（run queue）的进程（运行中的进程）。

search命令

search命令检索内存空间中指定的值。

```
crash＞search deadbeef
ffff880011a43dd0：deadbeef
……
ffff88001620add0：deadbeef
```

使用-c选项也可以检索字符串。

```
crash＞search-c"Linux version"
ffff880001600050：Linux version 2.6.35.11-83.fc14.x86_64（mockbuild@x86-01
……
ffffffff81cebcc7：Linux version 2.6.35.11-83.fc14.x86_64（mockbuild@x86-01
```

sig命令

sig命令显示进程的信号处理程序。另外，还会显示挂起（pending）的信号信息。-l选项等同于kill-l，显示已定义的信号编号。

struct命令

struct命令根据结构的定义和实际的地址，配合结构显示数据。

```
crash＞struct timespec xtime
struct timespec{
tv_sec=0x492ae39c，
tv_nsec=0x25218473
}
```

swap命令

swap命令输出交换设备的信息。输出内容与swapon-s基本相同。

sym命令

sym命令是解析符号（symbol）的命令。sym-l与cat System.map相同。

sys命令

sys命令显示系统的信息。显示时刻或CPU的平均负载（load average）、描述出现重大故障原因的信息等。与crash命令启动时显示的信息相同。内核配置CONFIG_IKCONFIG启用时，执行sys config就可以显示内核配置的列表。内容与/proc/config.gz解压缩后的文件相同。

```
crash＞sys confg
#
#Automatically generated make config：don't edit
#Linux/x86_64 2.6.39 Kernel Configuration
#Sun May 29 05：46：04 2011
#
CONFIG_64BIT=y
#CONFIG_X86_32 is not set
CONFIG_X86_64=y
CONFIG_X86=y
CONFIG_INSTRUCTION_DECODER=y
CONFIG_OUTPUT_FORMAT="elf64-x86-64"
CONFIG_ARCH_DEFCONFIG="arch/x86/configs/x86_64_defconfig"
……
```

对运行中的（live）系统运行crash命令时，可以使用sys-panic故意引起内核出现重大

故障。运行结果与echo c＞/proc/sysrq-trigger相同。

task命令

task命令是显示task_struct结构（进程管理所用的数据结构）的命令。

timer命令

timer命令显示加入到计时器列表中的计时器。

whatis命令

whatis命令显示结构等的类型或变量的定义。下面是显示全局变量modules的例子。可以看出modules是list_head结构类型的变量。

```
crash＞whatis modules
struct list_head modules；
```

wr命令

wr命令是改写内存内容的命令。下例使用crash命令，在运行中的系统上改写表示时间的jiffies变量。改写后，表示从启动开始经过的时间的UPTIME增加了3天以上。

```
crash＞sys
KERNEL：../linux-2.6/vmlinux
```

```
    DUMPFILE: /dev/mem
      CPUS: 2
        DATE: Sun May 29 05:26:13 2011
      UPTIME: 00:01:57
...
crash> rd jiffies_64
ffffffff81b43880:  00000000fffd7f69                    i.......
crash> wr jiffies_64 000000010ffd7f69
crash> sys
      KERNEL: ../linux-2.6/vmlinux
    DUMPFILE: /dev/mem
        CPUS: 2
        DATE: Sun May 29 05:26:57 2011
      UPTIME: 3 days, 02:36:20
...
```

小贴士：/proc/kcore和/dev/crash是只读的，因此要使用wr命令必须是/dev/mem。2.6.27版以后的内核在安全对策中引进了CONFIG_STRUCT_DEVMEM，想要使用wr命令时，必须将这个选项设置为off。

扩展命令

可以使用crash的库生成扩展模块，添加自己特有的命令。这里介绍3个方便的扩展命令。创建扩展模块时，可以在解压缩crash的目录下方，输入下列内容来进行。

```
$make extensions
```

使用extend命令进行扩展命令的安装（load）和卸载（unload）。

```
crash＞extend snap.so
./extensions/snap.so：shared object loaded
crash＞extend-u snap.so
./extensions/snap.so：shared object unloaded
```

snap命令

使用snap命令，可以生成实时内核的内核崩溃转储。生成的内核崩溃转储文件也可以使用crash命令来分析的。

```
crash＞snap vmcore
vmcore：[100%]
-rw-r--r--1 root root 536855288 2011-05-28 18：07 vmcore
```

trace命令

使用trace命令，可以得到内核映像中包含的ftrace的管理信息或者将其写出到文件。写出的文件可以使用trace-cmd命令来处理。除内核崩溃转储以外，在运行中的系统上也可以使用该命令。

trace命令是由表7-14所示的子命令构成的。

表7-14　trace命令的子命令

表 7-14　trace 命令的子命令

名　称	功　能
trace	显示当前的追踪器（tracer）。与 current_tracer 相同
trace show	显示追踪（trace）信息。与从 trace 读出的信息相同 trace-cmd 命令在内部调用
trace report	与 trace show 相同
trace dump < 目录名 >	根据 debugfs 的 tracing 目录下的结构，将环形缓冲区（ring buffer）或管理信息写到文件
trace dump < 文件名 >	将环形缓冲区或管理信息生成 trace-cmd report 命令可以处理的数据格式的文件

详细内容请参考HACK#67、HACK#69、HACK#70。

gcore命令

使用gcore命令可以生成内核崩溃转储中包括的用户模式进程的核心转储。详细内容请参考HACK#61。

crash选项

下面介绍crash命令启动时的一些选项。

-i选项

向-i指定包含crash命令的文件，crash就可以在启动时自动执行命令。使用这个选项可以使用crash进行自动处理。下面是执行help命令，使用exit结束crash命令的示例。

```
$ cat crash_cmd.txt
help
exit
$ cat -s -i crash_cmd.txt
*               files           mod             runq            union
alias           foreach          mount           search          vm
ascii           fuser            net             set             vtop
bt              gdb              p               sig             waitq
btop            help             ps              struct          whatis
dev             irq              pte             swap            wr
dis             kmem             ptob            sym             q
eval            list             ptov            sys
exit            log              rd              task
extend          mach             repeat          timer

crash version: 5.1.5    gdb version: 7.0
For help on any command above, enter "help <command>".
```

For help on input options, enter"help input".
For help on output options, enter"help output".
$/*显示help后返回bash*/

-s选项

像上例这样添加-s选项，就不再显示crash命令启动信息。

参考文献

·White Paper：Red Hat Crash Utility

http://people. redhat.com/anderson/crash_whitepaper/

——HATAYAMA Daisuke

HACK#60　核心转储过滤器

本节介绍如何控制应用程序的core文件中包含的内存区域。

从内核2.6.23版本开始安装了核心转储过滤器（core dump filter）功能。

应用程序中一旦发生分段错误（segement fault）等，就会生成该进程的核心转储文件（core文件）。core文件包括发生崩溃并强制结束的进程（崩溃进程）的内存区域。core文件可以使用gdb命令等进行分析。

如果进程占用了大量内存，core文件的大小也会相应地变大。另外，生成core文件也需要花费时间。可以使用ulimit来限制生成的core文件的大小，但如果进程内存的数据大小超过这个值，就无法全部获取数据。

注意事项：在RHEL6中，当abrtd运行时，根据abrtd的报告大小设置（MaxCrashReportsSize），核心文件有时不是在当前目录中生成，而是在/var/spool/abrt下生成。

使用核心转储过滤器限制core文件中包含的内存区域。例如，可以将共享内存的区域设置为不包括在core文件中。这样就可以缩小core文件的大小，并缩短获取core文件的时间。

使用方法

核心转储过滤器通过/proc/＜pid＞/coredump_filter来设置。由于coredump_filter是/proc/＜pid＞/的文件，因此可以对每个进程分别设置。

coredump_filter为位掩码。表7-15所示为各值与指定的内存区域。

表 7-15　coredump_filter 的位值与内存区域

位　值	内存区域
第 0 位	进程内存
第 1 位	共享内存
第 2 位	映射到文件的进程固有内存
第 3 位	映射到文件的进程共享内存
第 4 位	在文件的进程固有内存中，仅 ELF 头文件部分的页面。在未指定第 2 位（第 2 位为 0）时有效
第 5 位	hugetlb 进程内存
第 6 位	hugetlb 共享内存

内存区域的设置是位掩码为1时包括，为0时则不包括。

RHEL6的默认为0x33。0x33的设置为将第0、1、4、5位的内存区域包括在core文件中。不想将共享内存包括在PID 1234的core文件中时，仅将第0位、第2位、第5位设置为1。执行下列命令。

```
$echo 0x21＞/proc/1234/coredump_flter
```

可以使用内核启动参数coredump_filter设置默认的值。如果在/etc/grub.conf等中设置coredump_filter=0x21，则所有进程的默认值都变成0x21。

sysctl

/proc/sys/kernel/下有关于core文件的sysctl文件。下面针对这些进行介绍。

/proc/sys/kernel/core_pattern

使用core_pattern可以设置核心转储文件的命名规则。在Fedora 12中默认为core。在RHEL6中默认的是下列内容，实际上这也是core。

```
#cat/proc/sys/kernel/core_pattern
|/usr/libexec/abrt-hook-ccpp/var/spool/abrt%p%s%u%c
```

当第一个字符为|时，将执行在其后指定的进程（这个进程成为core_pattern进程）。/usr/libexec/abrt-hook-ccpp是生成自动bug报告工具（ABRT）文件的命令。

默认的文件名最后有.＜PID＞（参考后面介绍的core_uses_pid）。在core的情况下为core.＜PID＞。

更改core_pattern，可以设置为core以外的文件名。如表7-16所示，除了字符串以外，core_pattern还可以指定以%开始的模式（pattern）。

表 7-16　core_pattern 的字符串模式

模　式	内　容
%p	进程 ID
%u	用户 ID
%g	组 ID
%s	信号编号
%t	core 文件生成的时刻
%h	主机名称
%e	执行文件名称（命令名称）
%c	core 文件大小的限制值（ulimit -c 的大小）（2.6.24 以后）

指定%p时，文件名的最后不加.＜PID＞。下面是更改core_pattern时的例子。

```
#echo"coredump-%p-%s-%h-%e"＞/proc/sys/kernel/core_pattern
#ulimit-c unlimited
#sleep 1000＆kill-11$!
```

```
[1]2968
[1]+段错误（核心转储）sleep 1000
#ls
coredump-2968-11-localhost.localdomain-bash
```

/proc/sys/kernel/core_pipe_limit

core_pipe_limit是限制收集核心转储的进程同时执行的sysctl参数次数。在RHEL6中由abrt工具包将默认值设置为4。

当/proc/sys/kernel/core_pattern的第一个字符为|时，core_pattern进程会获取核心文件，但此时内核会停止崩溃进程译[1]。这是为了获取/proc/＜崩溃进程的PID＞/的数据。

内核等待core_pattern进程结束后，删除崩溃进程。但是，当core_pattern进程存在bug时，核心转储处理可能不会结束。不断崩溃的进程都会由于这个有bug的core_pattern进程而被迫停止。

要让数量超过core_pipe_limit的值的进程同时生成core文件时，会放弃生成core文件，输出下列信息。

```
Pid 9322（stress）over core_pipe_limit
Jan 12 19：30：46 localhost kernel：Skipping core dump
```

/proc/sys/kernel/core_uses_pid

将core_uses_pid设置为1，core文件的最后就会自动添加.＜PID＞。设置为0时则不添加。RHEL6中默认为1。

[1]崩溃进程对应的英文是crash process。

小结

获取运行中进程的核心转储的gdb的gcore命令不支持核心转储过滤器。对于crash的扩展模块—gcore命令，如果使用-f选项，同样可以限制获取的内存区域。详细内容请参考Hack#61。

参考文献

·Documentation for/proc/sys/kernel/*

Documentation/sysctl/kernel. txt

·3. 4/proc/＜pid＞/coredump_filter-Core dump filtering settings

Documentation/filesystems/proc. txt

——Naohiro Ooiwa

HACK#61　生成用户模式进程的进程核心转储

本节介绍使用crash的gcore命令的方法，它生成内核崩溃转储中包含的用户模式进程的核心转储。

使用crash的gcore命令，可以生成内核崩溃转储中包含的用户模式进程的进程核心转储。gcore命令并非crash的标准功能，而是作为扩展模块开发的。

使用案例

由于应用程序（用户模式进程）而造成崩溃时需要使用gcore命令。这时，应用程序的数据包含在内核崩溃转储中，因此某种程度上也可以使用crash进行故障分析。但是，对于应用程序开发人员来说，与要求具有内核相关知识的crash相比，gdb作为应用程序的调试工具，使用起来更加方便。使用gcore命令将内核崩溃转储内的应用程序数据作为进程核心转储提取出来，就可以使用gdb进行故障分析。

另外，使用gdb还可以对crash命令不提供的下列用户模式进程进行操作：

·用户空间的栈上的回溯。

·显示代码级别上的执行点。

与gdb一样，也可以从crash获取用户模式进程的符号信息，这将在后面介绍。

小贴士：应用程序造成内核崩溃的情况很多，例如，在以确保较高可用性为目的的群集环境下运行应用程序的情况。在这种群集环境下，为了缩短检测出故障时的节点切换时间，有时会通过刻意造成崩溃来停止活动节点。与一般的关闭（shutdown）处理方法相比，崩溃时不用结束运行中的应用程序，速度相应得到提高。应用程序的数据包含在崩溃时生成的内核崩溃转储中，因而此后也可以进行故障分析。

安装

gcore扩展模块在crash论坛网站（http：//people.redhat.com/anderson/）的扩展模块发布页（http：//people.redhat.com/anderson/extensions.html）上可以找到。

crash的详细安装方法在HACK#59中已经介绍。创建gcore扩展模块时需要将源代码解压缩到扩展模块用的extensions目录下。

```
$cd extensions
$tar xf～/src/gcore.tar.bz2
$cd../
$make extensions
```

创建处理程序如果正常结束，在extensions目录下就会生成gcore.so文件。

```
$ls-hld./extensions/gcore.so
-rwxr-xr-x 1 root root 235K 2011-05-28 18：02./extensions/gcore.so
```

基本使用方法

启动crash命令后，将gcore扩展模块安装到crash中，提取用户模式进程的进程核心转储，使用gdb显示提取的进程核心转储的回溯译[1]。crash启动后安装gcore.so。安装时使用extend命令。

```
$pwd
./crash-5.1.5/
$./crash vmcore vmlinux
……
crash＞extend gcore.so
./extensions/gcore.so：shared object loaded
```

如果安装成功，就会添加gcore命令。可以使用help命令进行确认。

```
crash＞help|grep gcore
bt gcore net set vtop
```

gcore命令的语法如下所示。

```
gcore[-v＜冗长级别＞][-f＜过滤器级别＞][＜PID＞|＜任务地址＞]*
```

向gcore命令指定想要获取进程核心转储的用户模式进程的PID或任务地址。不指定时，就是作为crash命令对象的进程上下文。

下面尝试使用gcore生成进程核心转储。使用ps命令找到获取进程核心转储的用户进程的PID。本次将udevd进程作为对象。

```
crash＞ps
PID PPID CPU TASK ST%MEM VSZ RSS COMM
……
369 1 0 ffff88003c701730 IN 0.2 17524 1692 udevd
```

最左边的项目PID中显示PID，从左边开始第4个项目TASK显示任务地址。crash进程的PID为369，任务地址为ffff88003c701730。

下面尝试使用gcore命令。这里指定的是udevd进程的PID 369。

```
crash＞gcore 369
WARNING：page fault at 7f4a5fc98000
……＜snip＞……
WARNING：page fault at 7fffc3d6c000
Saved core.369.udevd
crash＞ls-hl./core.369.udevd
-rw-------1 hat hat 18M Jul 4 20：23./core.369.udevd
```

gcore命令的处理顺利结束，生成了进程核心转储文件core.369.udevd。gcore生成的进程核心转储的文件名为如下格式。

```
core.＜PID＞.＜执行文件名＞
```

在gcore命令执行过程中，显示说明页面错误的下列信息。

```
gcore：WARNING：page fault at＜地址＞
```

用户内存空间中的下列页面区域不能从crash命令得到。

·一次也没有分配内存的区域

·分配过内存，但位于当前pageout的区域

gcore命令对于这样的内存区域，都写入0来生成核心转储。为了让用户能够意识到这一点，将按照标准输出下列信息。

除页面错误以外，还可以显示gcore命令处理的进展信息。如表7-17所示，使用-v选项向gcore命令指定要显示的信息。例如，如果认为不需要上述页面错误的通知信息时，可以在-v选项中指定0，来抑制信息的显示。

```
crash＞gcore-v 0 369
Saved core.369.udevd
crash＞
```

gcore命令中也有与核心转储过滤器对应的功能，在这里没有用到。在-f选项中指定位掩码的值。能够过滤的内存种类与核心转储过滤器相同。过滤的内存种类和-f选项的值的对应关系如表7-18所示。

表 7-17　冗长信息的种类与 -v 选项的值的对应关系

值	crash 进展信息	crash 库错误	页面错误
0			
1	×		
2		×	
4（默认值）			×
7	×	×	×

表 7-18　过滤的内存区域种类与 -f 选项的值的对应关系

	AP	AS	FP	FS	ELF	HP	HS
0							
1	×						
2		×					
4			×				
8				×			
16			×		×		
32						×	
64							×
127	×	×	×	×	×	×	×

AP　匿名个人内存
AS　匿名共享内存
FP　映射到文件的个人内存
FS　映射到文件的共享内存
ELF　映射到 ELF 文件的个人内存
HP　大页面（hugepage）个人内存
HS　大页面（hugepage）共享内存

下面使用gdb来显示该进程核心转储的回溯。

```
$gdb/usr/lib/debug/sbin/udevd.debug./core.369.udevd（gdb）bt
#0 0x00007f4a60398258 in__poll（fds=0x7f4a610da020，nfds=5，timeout=-1）at../sysdeps/unix/sysv/linux/poll.c：83
#1 0x00007f4a60ebb483 in main（argc=＜optimized out＞，argv=＜optimized out＞）at udev/udevd.c：1406
```

从回溯的信息可以看出，提取内核崩溃转储时，udevd进程执行了函数__poll内的地址0x00007f4a60398258。从函数名称可以看出，udevd进程当时正在执行轮询（polling）。如果使用gdb命令的x选项对这个地址进行反汇编，可以发现插入了执行系统调用的命令syscall的下列命令。

```
（gdb）x/2i 0x00007f4a60398256
0x7f4a60398256＜__poll+22＞：syscall
=＞0x7f4a60398258＜__poll+24＞：cmp$0xfffffffffffff000，%rax
```

使用syscall命令执行系统调用时，使用RAX寄存器指定系统调用编号。在把模式转移到内核时的寄存器值可以使用gcore命令的info register选项来找出。

```
（gdb）info register
rax 0x7 7
rbx 0x7f4a61a61ec0 139957442584256
rcx 0xffffffffffffffff-1
rdx 0xffffffffffffffff-1
rsi 0x5 5
rdi 0x7f4a610da020 139957432590368
rbp 0x0 0x0
rsp 0x7fffc3d739e0 0x7fffc3d739e0
r8 0x7f4a60655230 139957421560368
r9 0x0 0
r10 0x0 0
r11 0x246 582
r12 0x7f4a61a03010 139957442195472
r13 0x7f4a610da130 139957432590640
……
```

如上所示，RAX的值就是x86_64架构中poll系统调用的系统调用编号。可以看出udevd进程正在等待轮询的事件。

[1]回溯对应的英文是back trace。

使用crash参照用户进程的符号信息的方法

crash命令不使用gcore命令也可以获得添加了符号信息的进程用户内存。使用add-symbol-file命令添加用户进程的符号信息。add-symbol-file命令是gdb命令之一。crash沿用gdb的代码，可以从crash使用一些gdb命令。crash启动时读入的符号信息与gdb vmlinux的情况相同。

add-symbol-file命令的第1参数提取包括应用程序符号信息的obj文件，第2参数提取与符号信息相对应的文本区域的开始地址。按照如下方式找出文本区域的开始地址。

```
crash> vm | head
PID: 1771   TASK: ffff8800370ae080  CPU: 1   COMMAND: "crash"
       MM               PGD          RSS    TOTAL_VM
ffff880037910780  ffff88003a4c1000  153044k  187904k
      VMA           START       END     FLAGS FILE
ffff8800377e1e90      400000      a64000 8001875 /home/hat/build/crash-5.1.5/
crash
ffff880037aba250      c64000      c87000 8101873 /home/hat/build/crash-5.1.5/
crash
ffff8800377e1850     c87000     e15000 100073
ffff8800376ffb70    2423000    50a6000 100073
```

首先使用vm命令显示crash进程所管理的部分内存区域。可以看出，从第5行以后的FILE项目开始，把crash的执行文件映射到最前面的2个内存区域。

---

crash＞vm-f 8001875
8001875：（READ|EXEC|MAYREAD|MAYWRITE|MAYEXEC|DENYWRITE|EXECUTABLE）

然后使用vm-f命令，在FLAGS项目显示设置的标志。由于设置了EXECUTABLE标志，因此可以看出是映射到可执行文件的文本区域。这个文本区域的开始地址是START项目中显示的400000。请注意是以十六进制显示的。

按照下列方式，根据文本区域添加符号信息。

---

crash＞add-symbol-fle./crash 0x400000

这样就可以从crash命令使用crash的符号信息。尝试显示crash中使用的全局变量program_context。为了根据变量名称能够联想到这个变量，这个变量中保存了crash的程序上下文的相关数据。对应的地址为用户空间的地址，因此就需要在p命令中使用-u选项。

```
crash＞p-u program_context|head
$7={
program_name=0x7fff3a2f7955"crash"，
program_path=0x7fff3a2f7953"./crash"，
program_version=0x89f92d"5.1.5"，
gdb_version=0x9129a0"7.0"，
prompt=0x2435ce0"crash＞"，
flags=2306124484192570375，
namelist=0x7fff3a2f795b"/usr/lib/debug/lib/modules/2.6.32-71.el6.x86_64/vmlinux"，
dumpfile=0x0，
live_memsrc=0x7fff3a2f7993"/dev/crash"，
```

支持范围

现在，gcore命令可以支持下列架构和内核版本（见表7-19）。在较近的版本中也有可能运行。

表 7-19　可以使用 gcore 命令的环境

架　构	X86 X86_64（包括 32 位模式进程）
内核版本（已确认运行）	RHEL4.8（基于 2.6.9） RHEL5.6（基于 2.6.18） RHEL6.0（基于 2.6.32） Linux2.6.36

注意事项

注意事项：如前所述，crash不能处理一次也没有分配内存的区域或交换出swap out的内存区域。gcore将这些区域全部设置为0。

注意事项：crash命令不能获得通过makedumpfile进行的内核部分转储中排除在转储对象以外的内存区域。想要获得排除在转储区域外的内存区域时，会显示下列信息。

```
crash＞rd-u 0x400000
rd：page excluded：user virtual address：400000 type："64-bit UVADDR"
```

也可以将排除在转储对象外的内存区域改写为0进行引用。使用set命令将crash参数zero_excluded改为on。其初始设置为off。

```
crash＞set-v
……
zero_excluded：off
……
crash＞set zero_excluded on
zero_excluded：on
crash＞rd-u 0x400000
400000：0000000000000000……
```

在gcore命令处理中获得排除在转储对象外的内存区域时也是一样。这时gcore命令将中断处理，crash返回命令行输入。对内核的部分转储使用gcore命令时，需要将crash参数zero_excluded设置为on。

小贴士：gcore命令生成的进程核心转储所包含的执行信息中包含寄存器信息。这是崩溃时用户进程具有的用户空间中寄存器的值。崩溃时，在用户进程的不同状态下寄存器的退出位置也不同，因此需要根据各状态从适当的位置回收寄存器信息。但是，有时难以指定适当的位置，也有寄存器值自身没有退出的情况，并不一定能够回收全部的寄存器信息。但大多数情况下都能充分回收gdb进行回溯所需的寄存器信息。

小贴士：使用gcore命令生成的进程核心转储中并没有提取引起核心转储的信号。因此使用gdb对gcore命令生成的核心转储进行分析时不会显示下列信息。

Program terminated with signal 6，Aborted.

参考文献

·White Paper：Red Hat Crash Utility

http://people. redhat.com/anderson/

——HATAYAMA Daisuke

HACK#62　使用lockdep查找系统的死锁

本节使用lockdep，检查系统是否可能发生死锁。

内核中存在自旋锁（spinlock）、Mutex、信号量（semaphore）等各种锁。这些锁用于内核中的资源的排他控制，但是如果使用方法错误，就会造成称为死锁的状态，等待锁的进程就永远无法恢复，最严重的情况会导致内核死机。

典型的情况包括自己递归地获取锁的情况，以及多个处理顺序不当引起死锁的情况。例如，下面就是递归死锁的例子。

```
int func1（struct object*a）
{
mutex_lock（&a->lock）;
……
ret=func1（a）;
……
mutex_unlock（&a->lock）;
}
```

下面是AB-BA死锁的例子。

```
proc1（）{
mutex_lock（&lockA）;
mutex_lock（&lockB）;
……
}
proc2（）{
mutex_lock（&lockB）;
mutex_lock（&lockA）;
……
}
```

lockdep的正式名称为“Runtime locking correctness validator”，其负责检查内核运行时锁之间的依存性和使用方法，检测系统发生死锁的可能性。

lockdep的结构

lockdep记录内核启动后各个锁的获取状态（中断）、锁之间的获取顺序，将其作为锁的规则，对于这个规则以外的锁显示警告。

中断处理和单个锁

一般来说，递归死锁很容易就能通过程序的运行发现，在开发过程中也并不是非常难以发现。但是在编写操作系统时，中断处理是非常复杂的。也就是说，执行原来的程序时，处理过程中有时会收到硬件发出的中断（hardirq）或者软件中断（softirq）。在这些中断处理程序的内部获取与原来的程序相同的锁，就有可能发生意想不到的死锁。特别是像Linux这样，多个开发人员对一个程序进行增量式（incremental）开发时，就有可能由于相互之间未能沟通好而造成这样的死锁。

为了避免产生这样的死锁，对于中断处理程序中使用的锁，一般会在原来的程序上禁止hardirp和softirq以避免中断处理的运行。lockdep记录在获取各锁时的禁止中断状态，在softirq或hardirq未禁止的地方获取的锁一旦用在禁止softirq或hardirq的地方，就会发出警告。像这样在不同情况下使用锁，很有可能是因为某一个锁的使用方法发生错误。另外，也因为禁止hardirq或softirq后使用的锁，一般在它们的中断处理程序内部使用的可能性较高。

在lockdep中，根据获取锁时的情况，将这些锁进行了如下的分类（见表7-20）。

表 7-20　根据中断状态对锁进行分类

	允许 hardirq	禁止 hardirq
允许 softirq	Hardirq-unsafe	softirq-unsafe
禁止 softirq	softirq-safe	hardirq-safe

实际上禁止hardirq时softirq也会自动禁止，因此softirq-unsafe的意义与hardirg-unsafe相同，不存在仅允许softirq的情况。

多个锁之间的依存关系

另一方面，多个锁之间也有可能发生死锁。例如，称为AB-BA锁的死锁就非常有

名，这是在某个处理路径与另一个处理路径上两个锁的获取顺序不同的情况下发生的。这样的处理看起来不太可能发生，但其实像Linux这样必须在别人制作的子系统上加入自己的代码时，就有可能弄错API的调用顺序，造成这样的死锁。

lockdep会动态记录所有锁的依存关系（获取顺序），每次获得锁时都会与在此之前的获取模式进行比较，就可以确认会不会实际发生这样的问题。

在多个锁之间，还需要与单个锁时一样检查是否可以中断。

·获取了hardirq-safe的锁后，获取hardirq-unsafe的锁时

·获取了softirq-safe的锁后，获取softirq-unsafe的锁时

在这些情况下，第一个锁有可能在中断处理程序内部使用，但依存于后面仅在中断处理程序外部使用的锁。也就是说，在这个状态下进行处理并发生中断时，中断处理程序内有可能不获取irq-safe的锁就发生死锁。

锁的嵌套

在Linux内核内部，有时需要按照某个顺序获取相同种类的类（数据结构）的不同实例（instance）的锁。例如，从块设备（sda）机器内部的分区（sda1）来看，应当先获取块设备的锁，再获取分区的锁，才是正确的顺序。

lockdep为了把握这个顺序，准备了专用的锁API。对于mutex，要向mutex_lock_nested（mutex, subclass）的subclass传递1以上的值。subclass的值越大，嵌套的层次就一定越深（顺序必须是后获取的）。

在bdev结构的示例中，将传递给subclass的变量按如下方式定义。

```
enum bdev_bd_mutex_lock_class
{
BD_MUTEX_NORMAL=0，
BD_MUTEX_WHOLE=1，
BD_MUTEX_PARTITION=2
```

```
};
mutex_lock_nested（＆bdev-＞bd_contains-＞bd_mutex, BD_MUTEX_PARTITION）；
```

如果在使用BD_MUTEX_PARTITION锁定以后，再使用BD_MUTEX_WHOLE锁定，就是未按照应有的顺序锁定。

lockdep的系统开销

lockdep必须记录所有的锁定操作，并与到目前为止的执行结果进行比较，因此这是非常重要的处理。但是lockdep将锁的使用方法设置为对于锁的各个使用模式仅处理一次，从而减轻负担。因此，lockdep针对锁的每个使用模式，生成64位的散列值并记录下来，散列值相同的使用模式则从第二次以后不进行处理。

创建启用了lockdep的内核

要启用lockdep，需要将内核配置的DEBUG_LOCKDEP项目设置为y。但是，在最近的内核中，必须要先启用CONFIG_LOCK_STAT或CONFIG_PROVE_LOCKING之一才会出现这个项目。

```
%cd linux-2.6.xx
%make confg
……
Lock debugging：prove locking correctness（PROVE_LOCKING）[N/y/?]y
……
Lock dependency engine debugging（DEBUG_LOCKDEP）[N/y/?]（NEW）y
……
%make bzImage
```

这样创建的内核中就包含lockdep功能，能够使用死锁检测功能。

尝试使用lockdep功能

为了实际运行lockdep功能，向内核中添加“带有bug”的锁定处理的代码，查看bug是怎样检测出来的。

请看下面的代码，其中刻意地设置了AB←→BA死锁。

```
/*Lockdep test code*/
static DEFINE_SPINLOCK（hack_spinA）；
static DEFINE_SPINLOCK（hack_spinB）；
void hack_spinAB（void）
{
printk（KERN_ERR"hack_lockdep：A-＞B\n"）；
spin_lock（＆hack_spinA）；
spin_lock（＆hack_spinB）；
spin_unlock（＆hack_spinB）；
spin_unlock（＆hack_spinA）；
}
void hack_spinBA（void）
{
printk（KERN_ERR"hack_lockdep：B-＞A\n"）；
spin_lock（＆hack_spinB）；
spin_lock（＆hack_spinA）；
spin_unlock（＆hack_spinB）；
spin_unlock（＆hack_spinA）；
}
void hack_lockdep_test（void）
{
hack_spinAB（）；
hack_spinBA（）；
}
```

这段代码包括按照A→B、B→A的相反顺序获取锁的处理。因此，就存在潜在死锁的危险（hack_spinAB（）和hack_spinBA（）如果同时从不同的上下文中调用，则两个处理过程将互相等待而停止，造成死锁）。

这些反序的调用是由hack_lockdep_test（）函数来进行的。实际运行这个处理过程时需要将向hack_lockdep_test（）函数的调用添加到内核中。添加的位置可以设置为init/main.c的kernel_init（）函数（必须在lockdep_init（）的调用之后）。

```
extern void hack_lockdep_test（void）；
```

```
static int__init kernel_init（void*unused）
{
lock_kernel（）；
/*
*init can run on any cpu.
*/
：
if（sys_access（（const char__user*）ramdisk_execute_command，0）！=0）
{
ramdisk_execute_command=NULL；
prepare_namespace（）；
}
hack_lockdep_test（）；
/*
*Ok, we have completed the initial bootup, and
*we're essentially up and running.Get rid of the
*initmem segments and start the user-mode stuff..
*/
init_post（）；
return 0；
}
```

在进行了上述修改的内核中启动系统，在启动中就会检测并指出存在发生死锁的危险，如下所示。

```
[    1.715230] hack_lockdep: A->B
[    1.717816] hack_lockdep: B->A
[    1.720204]
[    1.720206] =====================================================
[    1.721178] [ INFO: possible circular locking dependency detected ]
[    1.721178] 2.6.38 #1
[    1.721178] -------------------------------------------------------
[    1.721178] swapper/1 is trying to acquire lock:
[    1.721178]  (hack_spinA){+.+...}, at: [<c040135b>] hack_spinBA+0x26/0x3d
[    1.721178]
[    1.721178] but task is already holding lock:
[    1.721178]  (hack_spinB){+.+...}, at: [<c0401351>] hack_spinBA+0x1c/0x3d
[    1.721178]
[    1.721178] which lock already depends on the new lock.
[    1.721178]
[    1.721178]
[    1.721178] the existing dependency chain (in reverse order) is:
[    1.721178]
[    1.721178] -> #1 (hack_spinB){+.+...}:
[    1.721178]        [<c04626a3>] lock_acquire+0x98/0xba
[    1.721178]        [<c07a738b>] _raw_spin_lock+0x20/0x2f
[    1.721178]        [<c040131e>] hack_spinAB+0x26/0x3d
[    1.721178]        [<c040137f>] hack_lockdep_test+0xd/0x16
[    1.721178]        [<c0a53994>] kernel_init+0x1a2/0x1b1
[    1.721178]        [<c0403882>] kernel_thread_helper+0x6/0x10
[    1.721178]
```

```
[    1.721178] -> #0 (hack_spinA){+.+...}:
[    1.721178]        [<c0461fcb>] __lock_acquire+0x9af/0xc3f
[    1.721178]        [<c04626a3>] lock_acquire+0x98/0xba
[    1.721178]        [<c07a738b>] _raw_spin_lock+0x20/0x2f
[    1.721178]        [<c040135b>] hack_spinBA+0x26/0x3d
[    1.721178]        [<c0401384>] hack_lockdep_test+0x12/0x16
[    1.721178]        [<c0a53994>] kernel_init+0x1a2/0x1b1
[    1.721178]        [<c0403882>] kernel_thread_helper+0x6/0x10
[    1.721178]
[    1.721178] other info that might help us debug this:
[    1.721178]
[    1.721178] 1 lock held by swapper/1:
[    1.721178]  #0:  (hack_spinB){+.+...}, at: [<c0401351>] hack_spinBA+0x1c/0x3d
[    1.721178]
[    1.721178] stack backtrace:
[    1.721178] Pid: 1, comm: swapper Not tainted 2.6.38 #1
[    1.721178] Call Trace:
[    1.721178]  [<c045fcf0>] ? print_circular_bug+0x8a/0x96

[    1.721178]  [<c0461fcb>] ? __lock_acquire+0x9af/0xc3f
[    1.721178]  [<c04626a3>] ? lock_acquire+0x98/0xba
[    1.721178]  [<c040135b>] ? hack_spinBA+0x26/0x3d
[    1.721178]  [<c07a738b>] ? _raw_spin_lock+0x20/0x2f
[    1.721178]  [<c040135b>] ? hack_spinBA+0x26/0x3d
[    1.721178]  [<c040135b>] ? hack_spinBA+0x26/0x3d
[    1.721178]  [<c0401384>] ? hack_lockdep_test+0x12/0x16
[    1.721178]  [<c0a53994>] ? kernel_init+0x1a2/0x1b1
[    1.721178]  [<c0a537f2>] ? kernel_init+0x0/0x1b1
[    1.721178]  [<c0403882>] ? kernel_thread_helper+0x6/0x10
```

在测试代码中只是将这些函数依次调用，因此并不会发生死锁。但是，内核注意到两个锁按照反序调用，并指出这段代码违反了避免死锁的规则。

小结

lockdep在对内核的锁进行修改时可以起到很大的帮助作用。即使在没有使用锁定的情况下，也可以事先检测出因未按照开发人员设想的顺序使用内核API而有可能导致的锁竞争。在发布关于内核的补丁之前，可以使用lockdep进行检查，确认代码是否有发生死锁的可能性。这样就可以提高发布的补丁的质量，减少通过评价接受批评的可能性，缩短到合并补丁所需的时间。

参考文献

·Documentation/lockdep-design. txt

——Masami Hiramatsu

HACK#63　检测内核的内存泄漏

本节介绍检测内核内存是否有泄漏的工具kmemleak（Kernel memory leak detector）。

kmemleak是检测内核空间的内存泄漏的调试功能。监测对象是通过内核的函数kmalloc（）、vmalloc（）、kmem_cache_alloc（）分配的内存区域。从Linux 2.6.31开始安装了这个功能。启用kmemleak，对内核、驱动程序、模块进行测试，就可以很方便地得出内存泄漏的可能性。

编译内核

要使用kmemleak，需要启用内核配置CONFIG_DEBUG_KMEMLEAK，重新构建内核。如果使用make menuconfig，则配置项目如下。

```
Kernel hacking--->
[*]Kernel memory leak detector
（400）Maximum kmemleak early log entries
```

关于Maximum kmemleak early log entries

make menuconfig中除了Kernel memory leak detector以外还有Maximum kmemleak early log entries。kmemleak准备了仅在内核启动时使用的锁的缓冲区。这个项目就是用来设置这个缓冲区大小的最大值。

一旦内核启动就会进行kmemleak的初始化。初始化完成后，就可以随时输出日志，并定期对内存进行检查。从kmemleak的结构也可以检测出初始化结束之前的内存泄漏，但是不能输出日志。这时就将初始化结束之前的内存泄漏信息暂时存放在这个缓冲区。启动时如果检测出大量的内存泄漏，输出了Early log buffer exceeded, please increase DEBUG_KMEMLEAK_EARLY_LOG_SIZE的信息，就需要增大Maximum kmemleak early log entries的值。单位是为输出日志而记录的内存个数。可以设置为200～40000。默认为

400。

使用方法

启动使用CONFIG_DEBUG_KMEMLEAK=y重新构建的内核，kmemleak线程就会每隔10分钟扫描一次内存。

当检测出可能存在内存泄漏时，就会输出信息。不需要进行设置等。

本节通过在样本程序中刻意加入内存泄漏，确认kmemleak检测出内存泄漏的过程。使用的内核版本为2.6.35。

然后准备用来造成内存泄漏的内核模块kmleak.c，进行编译。在所分配的内存区域写入了字符串memory leak test。

```
#cat kmleak.c
#include＜linux/module.h＞
#include＜linux/slab.h＞
static int leak_func（void）
{
char*p;
char mark[]="memory leak test"；
p=kmalloc（sizeof（mark），GFP_KERNEL）；
if（！p）{
printk（"kmleak can't allocate memory\n"）；
return-ENOMEM；
}
printk（"pointer to the allocated memory：%p\n"，p）；信息
memcpy（p，＆mark, sizeof（mark））；
if（！p）这里就是错误
kfree（p）；不释放
return 0；
}
static int__init kmleak_init（void）
{
leak_func（）；
return 0；
}
static void__exit kmleak_exit（void）
{
return；
}
module_init（kmleak_init）；
module_exit（kmleak_exit）；
```

准备内核模块用的Makefile，编译模块。向make的-C选项指定内核2.6.35的路径。

#cat Makefle

obj-m：=kmleak. o

#ls

kmleak. c Makefile linux-2.6.35

#make-C./linux-2. 6.35 M=pwdmodules

编译完成后，就生成了kmleak.ko。然后将这个模块安装到内核中，接着从内核中卸载。

```
#insmod./kmleak.ko
#lsmod
Module Size Used by
kmleak 914 0
……
#rmmod kmleak
```

在释放内存的函数kfree（）不调用的情况下，该内存的持有者消失。kmemleak如果执行内存扫描，就会输出表示内存泄漏的信息。kmemleak进行内存扫描的间隔默认为10分钟。

虽然最多只需等待10分钟就会输出信息，但也可以在任意时刻执行内存扫描。首先挂载debugfs。

```
#mount-t debugfs nodev/sys/kernel/debug/
```

向/sys/kernel/debug/kmemleak文件写入字符串scan, kmemleak线程就会在这时进行内存扫描。

```
#echo scan＞/sys/kernel/debug/kmemleak
```

使用dmesg命令确认检测出内存泄漏的信息是否输出。

```
#dmesg
……
pointer to the allocated memory：ffff88003c5b5960
这是kmleak模块输出的信息
kmemleak：1 new suspected memory leaks（see/sys/kernel/debug/kmemleak）
kmemleak输出的信息
```

这个信息会在检测出内存泄漏的可能性时显示。详细信息可以在/sys/kernel/debug/kmemleak中确认。

```
#cat/sys/kernel/debug/kmemleak
……
unreferenced object 0xffff88003c5b5960（size 32）：地址
comm"insmod"，pid 6105，jiffies 4602131386（age 2520.563s）PID、jiffies
hex dump（first 32 bytes）：
6d 65 6d 6f 72 79 20 6c 65 61 6b 20 74 65 73 74 memory leak test内存的内容
00 00 00 00 00 00 00 00 80 00 00 00 00 00 00 00……
backtrace：回溯
[＜ffffffff813c33a3＞]kmemleak_alloc+0x21/0x3e
[＜ffffffff810c9aa8＞]kmem_cache_alloc+0xc7/0xd6
[＜ffffffffa040901a＞]0xffffffffa040901a
[＜ffffffff8100205f＞]do_one_initcall+0x59/0x154
[＜ffffffff8106ca16＞]sys_init_module+0x9c/0x1da
[＜ffffffff810089c2＞]system_call_fastpath+0x16/0x1b
[＜ffffffffffffffff＞]0xffffffffffffffff
```

显示的内容从上到下依次输出的是内存的地址、分配这个内存的进程（PID）、内存的分配时间（jiffies）与分配后经过的时间、内存的内容（最大32位）、回溯。

/sys/kernel/debug/kmemleak参数

/sys/kernel/debug/kmemleak中还有除scan以外的参数，如表7-21所示。

表 7-21　/sys/kernel/debug/kmemleak 参数列表

参　数	内　容
off	禁用 kmemleak。不再追踪内存和分配和释放。一旦在这个参数中禁用，就不能再次启用

（续）

参　数	内　容
stack=on	启用任务栈区域的扫描。默认为 on
stack=off	禁用任务栈区域的扫描
scan=on	开始 kmemleak 线程的自动扫描。默认为 on
scan=off	停止 kmemleak 线程的自动扫描
scan=<secs>	设置 kmemleak 线程执行扫描的间隔。单位为秒。默认为 600 秒（10 分钟）。设置为 0 则停止自动扫描
scan	立刻执行内存扫描
clear	清除检测出的数据。清除处理以前判断为存在内存泄漏可能的内存信息，不在 /sys/kernel/debug/kmemleak 中显示 只是不显示，但在 kmemleak 内部是作为数据保存的，因此清除后也可以使用 dump 参数进行确认。在使用 kmemleak 前删除没有关系的信息时使用
dump=<addr>	显示内存信息

下面是使用了dump参数的例子。

```
#echo dump=0xffff88003c5b5960＞/sys/kernel/debug/kmemleak
#dmesg
……
pointer to the allocated memory：ffff88003c5b5960
kmemleak：1 new suspected memory leaks（see/sys/kernel/debug/kmemleak）
kmemleak：Object 0xffff88003c5b5960（size 32）：
kmemleak：comm"insmod"，pid 6105，jiffies 4602131386
kmemleak：min_count=1
kmemleak：count=0
kmemleak：flags=0x3
kmemleak：checksum=1470842492
kmemleak：backtrace：
[＜ffffffff813c33a3＞]kmemleak_alloc+0x21/0x3e
[＜ffffffff810c9aa8＞]kmem_cache_alloc+0xc7/0xd6
[＜ffffffffa040901a＞]0xffffffffa040901a
[＜ffffffff8100205f＞]do_one_initcall+0x59/0x154
[＜ffffffff8106ca16＞]sys_init_module+0x9c/0x1da
[＜ffffffff810089c2＞]system_call_fastpath+0x16/0x1b
[＜ffffffffffffffff＞]0xffffffffffffffff
```

内核启动参数

在安装了kmemleak的内核中，要禁用kmemleak功能，需要在内核启动参数中设置

kmemleak=off。

小结

使用kmemleak可以很方便地检测出内核的内存泄漏。可以用于设备驱动程序或内核模块的评估。也可以用于分辨内存泄漏的原因是应用程序还是Linux内核。

参考文献

·Documentation/kmemleak. txt

——Naohiro Ooiwa

第8章　概要分析与追踪

通过改善软件、系统的吞吐量或延迟，可以提高计算机的使用效率。特别是在OSS中可以自己获取源代码来改善这些性能。

Linux内核的开发人员为了提高品质也会进行性能分析。因此，内核中就添加了各种性能分析和运行分析的功能。本章将介绍使用perf tools的性能分析、使用ftrace的运行分析、使用SystemTap的可编程追踪（programmable tracing）等。当然，这些功能对于内核的性能分析、用户程序的分析、系统的故障排除（trouble shooting）等也非常有用。

HACK#64　使用perf tools的概要分析（1）

发现Linux内核功能变差时，或想要改善性能但不知道当前哪里有问题时等，可以通过进行程序概要分析来定位有问题的位置。

perf tools

perf tools是由内核维护人员Ingo Molnar等人开发的Linux内核的综合性能概要分析工具。可以使用CPU中内置的性能计数器（performance counter）功能、内核的追踪点等，进行内核或应用程序的概要分析。同样的工具中Oprofile比较有名。perf tools工具就是由于Oprofile与Linux内核的维护频率不同导致Oprofile不能识别内核上支持的CPU而开始开发的。因此把perf tools的源代码合并到Linux内核的源码树中之后，tools/perf下面有最新版的代码（反过来说，如果不使用与所用内核相对应的perf tools代码，就有可能无法正常运行）。

顾名思义，perf tools是由多个子命令（工具）构成的。tools/perf/Documents/下的文件中整理了各个子命令的使用方法等。这里首先介绍创建一个能够完整使用perf tools的环境的方法。

确认perf tools的运行

perf tools是至今仍在不断进行开发的内核的附属工具，因此也在不断地进行bug修正和功能添加。这里以Linux 2.6.35为基础进行介绍，同时也介绍新版本中所需的一些信息。可以根据下列配置选项是否启用来确认内核是否支持perf tools。

CONFIG_PERF_EVENTS

在运行中的系统中，可以按照下列方式直接运行perf命令来确认运行情况。

```
#perf list
#perf top
```

安装perf tools

使用比发布版更新的内核时，建议重新创建这个内核附带的perf tools再使用。在版本不同的内核中，perf tools可能无法正常运行。另外，创建之前必须添加一些头文件或库，但在不同发布版中创建perf tools所需的数据包不同。Debian系列的发布版中需要下列deb数据包。

glibc-dev, libelf-dev, libdw-dev, libnewt-dev, binutils-dev, zlib-static

Red Hat系列的发布版中需要下列RPM数据包。

```
glibc-devel, elfutils-devel, elfutils-libelf-devel, newt-devel, binutils-devel
```

更新版本的perf tools的创建有时需要Perl或Python的开发版数据包。虽然没有这些也可以创建，但会失去Perl或Python脚本扩展的支持。perf tools按照下列方式创建后就可以安装。

```
#cd tools/perf
#make
```

#make install

执行perf tools

perf tools命令是像top命令那样及时显示系统运行状态。二者根本上的不同在于top命令显示的是关于进程运行的统计信息，而perf tools命令显示的是通过性能计数器获取的用户进程和内核自身的概要分析信息。使用这个功能，就可以得知运行中内核的哪个函数影响了性能。执行perf tools需要执行下列命令

#perf top

将显示下列输出内容。默认为每隔2秒更新一次。

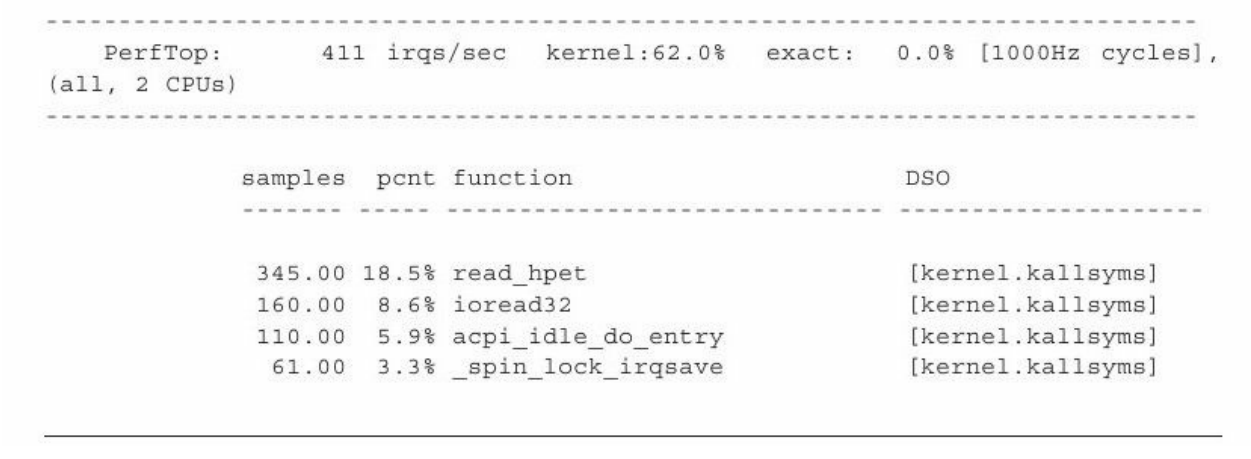

59.00 3.2%mls_compute_sid[kernel.kallsyms]
42.00 2.2%__GI_strstr libc-2.11.2.so
41.00 2.2%hpet_next_event[kernel.kallsyms]
34.00 1.8%native_read_tsc[kernel.kallsyms]
30.00 1.6%__pthread_mutex_lock_internal libpthread-2.11.2.so
27.00 1.4%_spin_lock[kernel.kallsyms]
26.00 1.4%unix_poll[kernel.kallsyms]
24.00 1.3%_spin_unlock_irqrestore[kernel.kallsyms]
24.00 1.3%schedule[kernel.kallsyms]
20.00 1.1%fget_light[kernel.kallsyms]
20.00 1.1%__pthread_mutex_unlock libpthread-2.11.2.so

perf top命令在运行过程中，可以使用【d】键更改显示的更新频率。按下【q】键结束命令。perf top命令通过对CPU上发生的事件进行采样来进行概要分析。perf top默认通过统计所消耗的CPU周期的事件进行概要分析，此外还可以从缓存未命中（cache miss）

事件、执行命令条数事件、分支预测错误事件等多个视图进行内核的概要分析。使用perf list命令可以获取这些事件的列表。

```
#perf list
```

由于种类非常多，这里仅介绍具有代表性的概要事件（profile event），见表8-1。

表 8-1　perf 中可使用的概要事件列表

事件名称	说　明
cpu-cycles 或 cycles	CPU 的消耗周期（时间）的概要事件
instructions	执行的命令条数的概要事件
cache-misses	缓存未命中的概要事件
branch-misses	分支预测错误的概要事件
page-faults 或 faults	页面错误的概要事件
minor-faults	次要页面错误（不需 I/O 的页面错误）的概要事件
major-faults	严重页面错误（需要 I/O 的页面错误）的概要事件
context-switches 或 cs	上下文切换的概要事件

将这些事件名称作为-e选项的参数，就可以进行基于不同指标的概要分析。例如，使用下列命令就可以获取缓存未命中的概要。

```
#perf top-e cache-misses
```

小结

本节介绍了perf tools及其安装方法、使用perf top命令及时进行概要分析的方法。perf top的概要分析可以用于查找系统整体性能降低的原因。

参考文献

·tools/perf/Documentation/perf. txt

·tools/perf/Documentation/perf-top. txt

——Masami Hiramatsu

HACK#65　使用perf tools的概要分析（2）

本节介绍使用perf tools进行详细概要分析的方法。

Hack#64介绍了使用perf top进行及时系统概要分析的方法。这里将进一步介绍实际的概要分析技术，使用perf tools的其他功能，获取更详细的概要，特别是在x86命令代码或C语言源代码层面追踪热点（hot spot）的方法。

使用perf进行概要分析的步骤

perf top通过一条命令就可以进行概要分析，而perf tools的其他子命令则基本上是按照下列步骤进行概要分析。

1.选定概要事件。

2.记录概要分析和数据。

3.分析记录的数据。

因此，首先从使用perf list显示的事件列表中，决定使用哪个事件，然后使用perf record记录事件，最后使用perf report或perf annotate进行详细的事件信息分析。关于进行概要分析的事件请参考Hack#64中的表8-1。除了表8-1介绍的事件以外，有些处理器还可以在L1缓存信息、TLB缓存信息等更为详细的信息的基础上进行概要分析。这里将介绍对发生了缓存未命中的位置进行详细概要分析的方法。perf record命令需要使用下列方法之一指定进行概要分析的对象来执行。

·通过进程ID指定（--pid）。

·通过线程ID指定（--tid）。

·指定特定CPU上的所有进程（--profile_cpu）。

·指定所有CPU上的进程（--all）。

·从命令行指定要执行的命令。

然后与perf top一样，指定属于所记录种类的事件并将启动。例如，要对所有CPU上发生的缓存未命中进行概要分析时，进行下列操作。

```
#perf record-e cache-misses--all
```

可以在事件的“：”后面传递选项。

```
#perf record-e cache-misses：k--all
```

表8-2所示为x86上可以传递给事件的选项。

表 8-2　perf tools 事件的选项

选　项	说　明
k	仅获取内核（ring0）的事件
u	仅获取用户空间（ring3）的事件
p	获取事件更为准确的发生地址。如果可以使用 PEBS 和 LBR 则启用（LBR 为可选项）。最少也可以通过启用 PEBS，获取发生事件的命令之后下一个命令的地址
pp	如果可以配合使用 PEBS 和 LBR 则都两者启用。其中一个不能使用时出错。可以获取事件准确的发生地址

使用PEBS和LBR的正确采样

PEBS为Precise Event Based Sampling的缩写，是从Intel Core微架构（与NetBurst中的一部分）开始导入的更为准确的性能计数器结构。虽然可以适用PEBS的事件有限，但是对于找出事件准确的发生地址是非常有用的。在此之前的性能计数器都是在事件发生后造成外部中断，因此发生中断的时间比事件发生时命令的地址稍靠后。因此从中断处理程序可以看到的IP寄存器显示的地址并不是正确的地址。而PEBS则可以在事件发生后立刻造成异常，从而能获取事件发生时命令运行的地址。但是，事件发生的命令本身已经运行，因此IP寄存器显示的值就是事件发生的命令的下一条命令的地址。

x86架构采用了CISC命令，各命令的长度各不相同，当事件发生的命令为分支命令时，难以从分支的节点找出从哪里分出的，仅使用PEBS很难正确地找到事件发生的命令。

在perf tools中将这个功能和LBR（Last Branch Record）配合使用，通过逆运算求出事件实际发生的命令的地址。LBR是记录最后执行分支命令的地址的功能。PEBS如果在事件发生后立即调用处理程序，则首先参照LBR。LBR中记录了最后分支的起点和终点的地址，当IP寄存器显示的地址与LBR显示的分支终点地址一致时，分支起点地址就是真正的事件发生地址。

当与LBR的信息不一致时，PEBS处理程序对从分支终点的地址到IP寄存器显示的地址为止的各命令依次进行解码，找出到达IP寄存器显示地址前的一个命令的地址。这样就可以得知事件真正发生的地址。

但是，在使用有些处理器时是无法启用这些功能的。这时就会返回-ENOTSUPP错误。PEBS的功能对于某些类型的事件也不能使用。在使用时需要注意。

进行缓存未命中的概要分析

perf record基本上是将概要事件和概要对象的命令指定为参数。一般来说，如果指定测量对象的基准测试软件或stress命令，则基准测试软件结束时perf tools也自动结束。例如，在下列命令中运行称为stress的命令10秒钟，并记录其概要信息。

```
#perf record-e cache-misses stress-c 8-i 2-m 2--timeout 10s
stress：info：[12035]dispatching hogs：8 cpu，2 io，2 vm，0 hdd
stress：info：[12035]successful run completed in 10s
[perf record：Woken up 1 times to write data]
[perf record：Captured and wrote 0.450 MB perf.data（～19640 samples）]
```

记录的概要结果可以使用perf report命令来查看。

#perf report

启动perf report命令就会如图8-1所示在TUI（文本用户界面）的界面上显示概要结果。

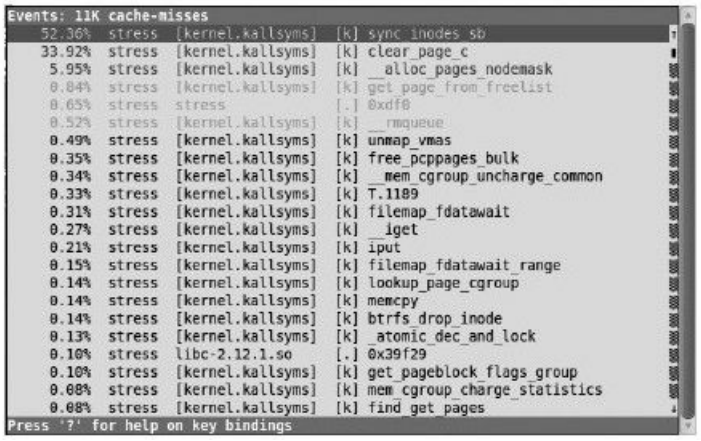

图　8-1　perf report命令启动后

概要结果中显示了在哪个执行文件、库或者内核的哪个函数发生了缓存未命中。根据这个结果，与汇编程序（assembler）源代码进行对比时，将光标（cursor）移动到想要查看详细内容的行，按下【Enter】键就可以打开子窗口（见图8-2）。

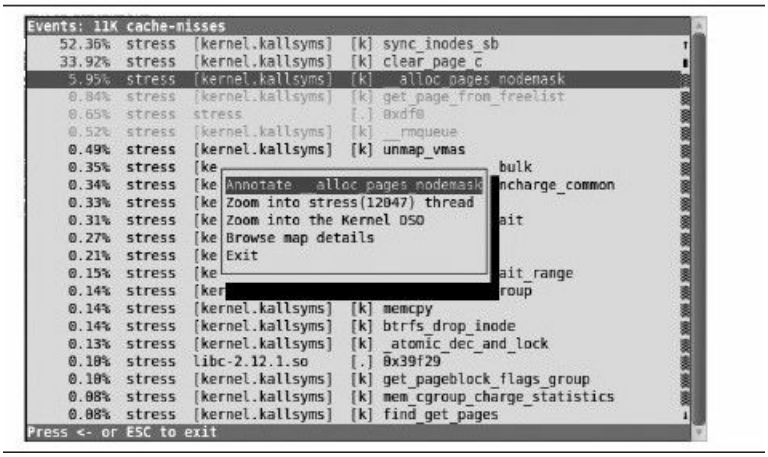

图　8-2　perf report的子窗口

在这里选择“Annotate__alloc_pages_nodemask”的项目，就会显示包括事件发生位置周边的反汇编程序在内的详细报告（见图8-3）。当分析对象（这里为内核）具有调试信息时，还会显示C的源代码和事件发生的行。本节是以分析内核中的缓存未命中为例的，此外还可以分析用户空间的应用程序。

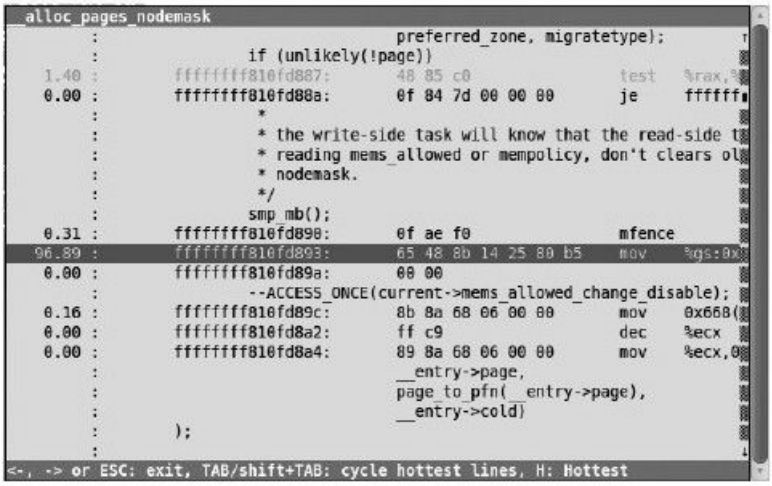

图　8-3　显示详细报告

在这个示例中，可以看出地址ffffffff810fd893的mov命令发生了缓存未命中。在这个界面按【Tab】键就会依次显示相同文件内的不同缓存未命中的位置。另外，按左箭头键可以返回与图8-1相同的画面。如果选择图8-2的项目中的“Zoom into stress（12047）thread”，就会如图8-4所示仅显示与选择的事件在相同线程内的缓存未命中。

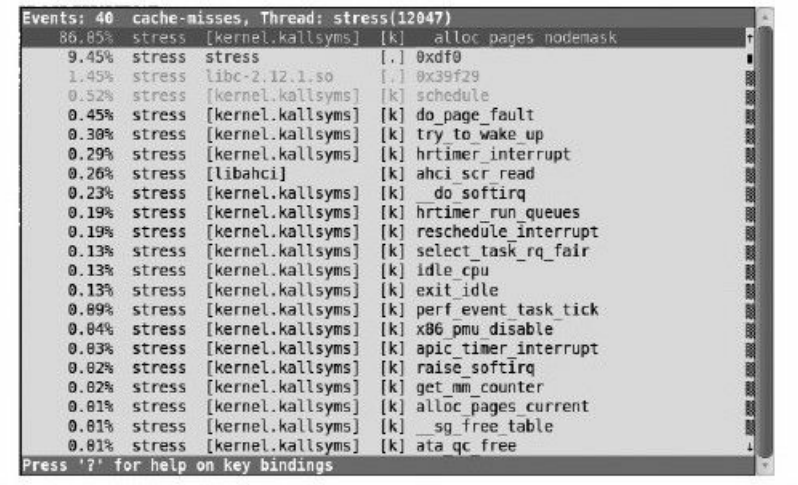

图　8-4　仅显示与线程相关的事件

要从这里返回图8-1的界面，同样需要按左箭头键。如果选择图8-2的项目中的“Zoom into the kernel DSO”，则仅显示内核中发生的缓存未命中。关于键盘操作，可以按【？】键，就会出现如图8-5所示的帮助界面，可以作为参考。

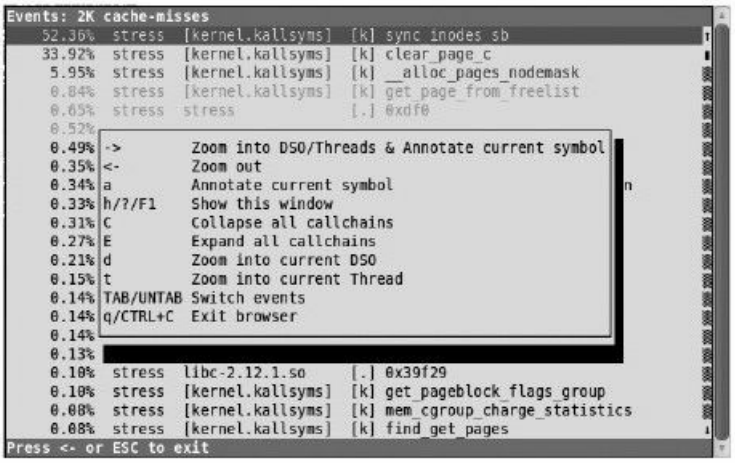

图　8-5　键盘帮助

小结

本节介绍了使用perf tools功能中的perf record和perf report进行详细的概要分析的方法。perf record仅可以记录任意命令的运行。perf report可以详细分析概要结果，添加反汇编程序显示出来。因此，在想要对使用perf top时觉得异常的部分进行集中分析的情况下，perf record和perf report能够起到很大的作用。

——Masami Hiramatsu

HACK#66　进行内核或进程的各种概要分析

本节使用perf tools从各种角度对内核或进程进行概要分析。

perf tools的子命令中具有特定用途的性能分析功能。本节将举例说明其中一部分功能的使用方法。

使用perf stat获取综合统计信息

perf top或perf record/report可以用来分析特定的性能，但是不适用于汇总综合性能。perf stat就是针对指定的命令显示汇总的性能测量结果的功能。下面是显示执行“ls/”时汇总的所有命令的方法。

```
[~]# perf stat ls /
bin   dev  home  lib32        media  opt   root  selinux  sys  tracing  var
boot  etc  lib         lib64        mnt   proc  sbin  srv            tmp  usr
Performance counter stats for 'ls /':
        1.879831 task-clock-msecs         #      0.791 CPUs
               0 context-switches         #      0.000 M/sec
               1 CPU-migrations           #      0.001 M/sec
             269 page-faults              #      0.143 M/sec
       1,562,779 cycles                   #    831.340 M/sec
       1,562,779 instructions             #      1.000 IPC
```

313，491 branches#166.766 M/sec
11，971 branch-misses#3.819%
24，521 cache-references#13.044 M/sec
7，571 cache-misses#4.027 M/sec
0.002377647 seconds time elapsed

通过使用这个功能，可以测量测定对象程序的缓存未命中、执行命令条数、周期数等，还可以推测出性能特别差的处理是由于缓存未命中、分支预测错误，还是其他原因。一部分开发人员还经常将其用于比较安装性能改善补丁前后的结果，定量地显示效果。

下面查看测定结果的信息。第一个task-clock-msecs表示执行所花费的时间。还会显示消耗了多少CPU时间。context-switches为进程或线程的切换次数。本次仅使用ls进行简单

的处理，因此没有发生切换。CPU-migrations为正在运行的CPU切换的次数。page-faults表示按需分页或交换（swapping）等中使用的页面错误的发生次数和频率。cycles是用时钟数量来表示进程执行所花费的CPU时间。instructions表示执行的命令条数。instructions中的IPC是Instructions Per Cycle的缩写。如果这个值较小的话，则每条命令的时钟数量越大，因此认为效率较低（例如，内存访问或I/O的频率较高）。branches表示分支命令的数量和频率，branch-misses表示分支预测错误的比例。另外，cache-references表示缓存的参照，cache-misses表示缓存未命中的频率等。一般来说，缓存未命中的次数越少，IPC越大，就认为程序的执行效率越高。

使用perf script进行追踪

perf tools记录内核中的采样事件，对其进行分析并得出性能信息。perf tools还可以记录内核中的追踪事件。也就是说，可以与Hack#69中介绍的ftrace进行同样的操作。perf script是显示已追踪的事件，或启动处理事件的脚本的功能。通过改写脚本，就可以根据需要对事件进行分析。可以记录的事件的种类除了可以如前所示从ftrace的debugfs接口获取，还可以使用perf list命令来获取。

```
#perf list
……
kvmmmu：kvm_mmu_pagetable_walk[Tracepoint event]
kvmmmu：kvm_mmu_paging_element[Tracepoint event]
kvmmmu：kvm_mmu_set_accessed_bit[Tracepoint event]
kvmmmu：kvm_mmu_set_dirty_bit[Tracepoint event]
kvmmmu：kvm_mmu_walker_error[Tracepoint event]
kvmmmu：kvm_mmu_get_page[Tracepoint event]
kvmmmu：kvm_mmu_sync_page[Tracepoint event]
kvmmmu：kvm_mmu_unsync_page[Tracepoint event]
kvmmmu：kvm_mmu_prepare_zap_page[Tracepoint event]
```

在perf list的输出中，Tracepoint event所示的事件就是追踪用的事件。

在下例中，将使用perf record获取的进程调度程序相关事件并通过perf script输出。

```
#perf record-e sched：'*'-a ls/
bin dev home lib32 media opt root selinux sys tracing var
boot
etc lib lib64 mnt proc sbin srv tmp usr
[perf record：Woken up 1 times to write data]
[perf record：Captured and wrote 0.627 MB perf.data（～27391 samples）]
#perf script
perf 5179[000]26985.658132：sched_stat_runtime：comm=perf
pid=5179 runtime=5751845[ns]vruntime=392262038[ns]
Xorg 1115[001]26985.658132：sched_stat_runtime：comm=Xorg
pid=1115 runtime=4757708[ns]vruntime=106804101116[ns]
Xorg 1115[001]26985.658142：sched_stat_sleep：comm=kworker/1：0
pid=4552 delay=9975987[ns]
perf 5179[000]26985.658143：sched_stat_sleep：comm=kworker/0：2
pid=4027 delay=9972425[ns]
swapper 0[003]26985.658144：sched_stat_sleep：comm=kworker/3：0
pid=4983 delay=9920987[ns]
Xorg 1115[001]26985.658144：sched_wakeup：comm=kworker/1：0
pid=4552 prio=120 success=1 target_cpu=001
perf 5179[000]26985.658144：sched_wakeup：comm=kworker/0：2
```

```
pid=4027 prio=120 success=1 target_cpu=000
swapper 0[003]26985.658145：sched_wakeup：comm=kworker/3：0
pid=4983 prio=120 success=1 target_cpu=003
Xorg 1115[001]26985.658145：sched_stat_runtime：comm=Xorg
pid=1115 runtime=13009[ns]vruntime=106804114125[ns]
perf 5179[000]26985.658145：sched_stat_runtime：comm=perf
pid=5179 runtime=12798[ns]vruntime=392274836[ns]
……
```

在不向perf script赋予脚本的情况下运行时，只显示记录的追踪事件。也可以将这个追踪事件作为脚本的输入进行处理并返回结果。在perf script中添加--list选项并执行，就可以获取可使用的脚本列表。

```
#perf script--list
List of available trace scripts：
workqueue-stats workqueue stats（ins/exe/create/destroy）
rw-by-pid system-wide r/w activity
failed-syscalls[comm]system-wide failed syscalls
rwtop[interval]system-wide r/w top
rw-by-file＜comm＞r/w activity for a program, by file
wakeup-latency system-wide min/max/avg wakeup latency
sched-migration sched migration overview
syscall-counts-by-pid[comm]system-wide syscall counts, by pid
futex-contention futext contention measurement
netdev-times[tx][rx][dev=][debug]display a process of packet and
processing time
sctop[comm][interval]syscall top
syscall-counts[comm]system-wide syscall counts
failed-syscalls-by-pid[comm]system-wide failed syscalls, by pid
```

脚本可以分为可在线处理的和不可在线处理的。但是一般sctop、rwtop等命令处理的事件频率非常高，因此如果在线处理，即进行追踪的同时运行脚本，则不可避免地会增加负载。另一方面，进行离线处理时是先追踪后处理的，因此可以抑制处理方式对追踪对象的影响。

要进行在线处理，需要在perf script后面指定脚本名称，如下所示。这里使用的是sctop（测量系统调用次数）脚本。

#perf script sctop syscall events：

```
event                                          count
---------------------------------------  ----------
read                                          936451
futex                                          10839
ioctl                                           4359
write                                           1661
close                                           1133
swapoff                                          694
getdents                                         417
poll                                             225
semop                                            210
munmap                                           198
setitimer                                        148
writev                                           146
sched_setparam                                   137
wait4                                            106
fcntl                                             99
epoll_wait                                        84
select                                            76
mmap                                              30
nanosleep                                         24
open                                              19
fstat                                             16
inotify_add_watch                                 14
madvise                                            9
recvmsg                                            8
rt_sigprocmask                                     8
sendmsg                                            4
socket                                             4
rt_sigaction                                       4
stat                                               4
recvfrom                                           1
...
```

要进行离线处理，需要在perf script的record和report后面指定脚本名称，如下所示。这里使用scscall-counts脚本，与前一次一样测量系统调用的次数。

```
#perf script record syscall-counts ls/
bin dev home lib32 media opt root selinux sys tracing var
boot etc lib lib64 mnt proc sbin srv tmp usr
[perf record：Woken up 1 times to write data]
[perf record：Captured and wrote 0.028 MB perf.data（～1226 samples）]
#perf script report syscall-counts
Press control+C to stop and show the summary
syscall events：
event count
---------------------------------------------------
```

```
mmap                                    26
mprotect                                16
close                                   13
fstat                                   11
open                                    11
access                                   9
read                                     9
brk                                      3
munmap                                   3
futex                                    2
getdents                                 2
ioctl                                    2
rt_sigaction                             2
write                                    2
set_robust_list                          1
exit_group                               1
set_tid_address                          1
arch_prctl                               1
statfs                                   1
getrlimit                                1
fcntl                                    1
rt_sigprocmask                           1
stat                                     1
```

使用自己的脚本处理数据

有时我们会打算自己写脚本来实现事件的统计处理，而不是执行现存的脚本。perf script考虑这样的需求，准备了根据记录的事件生成脚本模型的功能。

下面查看一个用来调查系统调用和内核中分配内存的kmalloc（）关系的脚本实例。首先生成使用perf record记录必要事件的数据文件。

```
#perf record-e kmem：kmalloc-e raw_syscalls：sys_enter ls/
bin dev home lib32 media opt root selinux sys tracing var
boot etc lib lib64 mnt proc sbin srv tmp usr
[perf record：Woken up 1 times to write data]
[perf record：Captured and wrote 0.037 MB perf.data（～1633 samples）]
```

然后，向perf script传递-g选项，根据数据文件生成脚本的模型。-g选项将生成的脚本语言（当前为Perl或Python）作为参数。在下例中，生成的是perf脚本。

```
#perf script-g perl
generated Perl script：perf-script.pl
```

生成的脚本直接就具有显示事件内容的功能。

```
#perf script event handlers, generated by perf script-g perl
#Licensed under the terms of the GNU GPL License version 2
#The common_*event handler fields are the most useful fields common to
#all events.They don't necessarily correspond to the'common_*'fields
#in the format files.Those fields not available as handler params can
#be retrieved using Perl functions of the form common_*（$context）.
#See Context.pm for the list of available functions.
use lib"$ENV{'PERF_EXEC_PATH'}/scripts/perl/Perf-Trace-Util/lib"；
use lib"./Perf-Trace-Util/lib"；
use Perf：Trace：Core；
use Perf：Trace：Context；
use Perf：Trace：Util；
sub trace_begin
{
#optional
}
sub trace_end{
#optional
}
sub raw_syscalls：sys_enter
```

```
{
my（$event_name，$context，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm，
$id，$args）=@_；
print_header（$event_name，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm）；
printf（"id=%d, args=%s\n"，
$id，$args）；
}
sub kmem：kmalloc
{
my（$event_name，$context，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm，
$call_site，$ptr，$bytes_req，$bytes_alloc，
$gfp_flags）=@_；
print_header（$event_name，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm）；
printf（"call_site=%u, ptr=%u, bytes_req=%u, bytes_alloc=%u，".
"gfp_flags=%s\n"，
$call_site，$ptr，$bytes_req，$bytes_alloc，
flag_str（"kmem：kmalloc"，"gfp_flags"，$gfp_flags））；
}
sub trace_unhandled
{
my（$event_name，$context，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm）=@_；
print_header（$event_name，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm）；
}
sub print_header
{
my（$event_name，$cpu，$secs，$nsecs，$pid，$comm）=@_；
printf（"%-20s%5u%05u.%09u%8u%-20s"，
$event_name，$cpu，$secs，$nsecs，$pid，$comm）；
}
```

从生成的脚本的内容，可以看出是事件触发类型的程序，perf script依次处理事件，然后将信息传递给与事件名称相对应的函数。通过更改处理这个事件的函数的内容，可以执行任意的处理。例如，要统计哪个系统调用调用了几次kmalloc（），可以将生成的脚本修改为如下内容。

```
use lib"$ENV{'PERF_EXEC_PATH'}/scripts/perl/Perf-Trace-Util/lib"；
use lib"./Perf-Trace-Util/lib"；
use Perf：Trace：Core；
use Perf：Trace：Context；
use Perf：Trace：Util；
@count=（）；
$current_id=-1；
sub trace_end
{
for（$id=0；$id＜1024；$id++）{
if（@count[$id]！=0）{
printf（"syscall%d invokes kmalloc%d times.\n"，
```

```
$id，@count[$id]）；
}
}
}
sub raw_syscalls：sys_enter
{
my（$event_name，$context，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm，
$id，$args）=@_；
$current_id=$id；
}
sub kmem：kmalloc
{
my（$event_name，$context，$common_cpu，$common_secs，$common_nsecs，
$common_pid，$common_comm，
$call_site，$ptr，$bytes_req，$bytes_alloc，
$gfp_flags）=@_；
if（$current_id！=-1）{
@count[$current_id]++；
}
}
```

将这个脚本另存为kmalloc-syscall.pl，并使用perf script来尝试运行。

```
#perf script-s kmalloc-syscall.pl
syscall 0 invokes kmalloc 1 times.
syscall 2 invokes kmalloc 25 times.
syscall 9 invokes kmalloc 16 times.
syscall 10 invokes kmalloc 16 times.
syscall 21 invokes kmalloc 9 times.
syscall 137 invokes kmalloc 1 times.
```

可以像这样使用现有的脚本语言非常简单地记述事件的处理方式，就是perf script的特点。从这个功能也可以使用Hack#71介绍的通过perf probe生成的事件，因此实质上也就是可以使用脚本来处理内核中的大部分信息。

小结

本节介绍了perf stat和perf script的使用方法等。perf stat可以用于在应用程序的性能分析、性能改善时数值指标的确认等，使用非常简单。另一方面，perf script也可以使用Perl或Python等常用脚本来处理追踪结果的统计处理等。

参考文献

·tools/perf/Documentation/perf-stat. txt

·tools/perf/Documentation/perf-script. txt

·"Perf Tools：Recent Improvements"Arnaldo Carvalho de Melo

http://pdxplumbers. osuosl.org/2010/ocw/system/presentations/579/original/perf-plumbers2010.pdf

_Masami Hiramatsu

HACK#67　追踪内核的函数调用

本节介绍使用ftrace研究从哪里调用哪个函数的方法。

追踪是指记录对象软件何时、如何运行的调试或系统监控的方法之一。对引起故障的内核操作进行分析时，有时仅根据源代码是无法获悉实际调用顺序等的。出现性能问题时，或想要改善特定处理的延迟等问题时，就会想要追踪哪里存在瓶颈。使用基于采样的分析工具（profile）虽然也能大致知道性能降低的位置，但终究只能进行概率性的判断，有时不适合用于追踪某特定位置。

这种情况下，采用的方法是通过追踪器依次记录对象程序内部发生的处理并进行分析。有用的追踪主要有下列情况。

·引起bug的条件的分析

·定时（timing）bug的分析

·性能降低的分析

另外，有时也会为了进行系统性能监控或故障监控，而进行日常维护型的追踪。

ftrace

最近发布了Linux内核的标准追踪功能ftrace。ftrace是内核的追踪器框架，有时也将作为ftrace母体的函数调用的追踪器称为ftrace。这里将ftrace作为一般的追踪器框架来使用，函数调用的追踪器用函数追踪器来描述。

ftrace大致有两个功能。一个包括插件追踪器（plugin tracer）分析的追踪功能。另一个是追踪内核事件的功能（将来通过引进uprobes，也可能支持用户空间的追踪），称为追踪事件的。

插件追踪器中有一些是基于追踪事件的，但除了记录事件内容以外，还具有处理事件状态，显示整理结果的功能。在代表性的插件追踪器中，除了成为ftrace名字来源的函数追踪器以外，还有生成调用图表（call graph）的追踪器、MMIO（内存映射I/O）的追踪器等。

另一方面，追踪事件是为了记录内核中代表性操作的状态而安装的追踪代码。通过记录这些追踪事件的信息，就可以记录内核中的代表性操作。

插件追踪器可以与追踪事件同时使用，因此除了插件追踪器的信息以外还可以使用追踪事件。

创建启用ftrace的内核

在最近的Fedora或Ubuntu等发布版的内核中多数是启用了ftrace的，但在想使用最新内核其ftrace未启用，就需要启动下列选项重新构建内核（重新构建的方法请参考Hack#2）。

这些选项都在Kernel Hacking-＞Tracers下。在表8-3所示的选项中，可以选择CONFIG_BRANCH_PROFILE_NONE、CONFIG_PROFILE_ANNOTATED_BRANCHES、CONFIG_PROFILE_ALL_BRANCHES。CONFIG_PROFILE_ANNOTATED_BRANCHES可以通过替换内核中的所有unlikely、likely宏，可以检查unlikely和likely的预测是否正确。CONFIG_PROFILE_ALL_BRANCHES可以替换内核中的所有if（）语句，检查哪个分支多被分配到哪里。大家也可以预见到，这些选项将造成很大的系统开销，需要注意。

表 8-3　ftrace 的配置选项

选项名称	功　能
CONFIG_FTRACE	启用 ftrace 自身的功能
CONFIG_FUNCTION_TRACER	启用函数追踪器

（续）

选项名称	功　能
CONFIG_FUNCTION_GRAPH_TRACER	启用函数调用图表追踪器
CONFIG_IRQSOFF_TRACER	启用禁止中断时间追踪器
CONFIG_SCHED_TRACER	启用调度程序追踪器
CONFIG_BRANCH_PROFILE_NONE	不启用条件分支追踪器功能
CONFIG_PROFILE_ANNOTATED_BRANCHES	启用分支预测追踪器
CONFIG_PROFILE_ALL_BRANCHES	启用条件分支追踪器
CONFIG_BLK_DEV_IO_TRACE	启用块 I/O 追踪器
CONFIG_MMIOTRACE	启用 MMIO 追踪器
CONFIG_FUNCTION_PROFILER	启用函数分析追踪器
CONFIG_STACK_TRACER	启用栈使用量追踪器
CONFIG_FTRACE_SYSCALLS	启用系统调用的追踪事件
CONFIG_KPROBE_EVENT	启用动态追踪事件

操作ftrace的debugfs接口

ftrace的用户界面是在debugfs这个特殊的文件系统上生成的。debugfs多数情况下在标准配置中是未挂接的，因此多数情况下需要手动挂载到/sys/kernel/debug（相关追踪人员为了打字方便，多数会创建/debug目录来挂接，这里使用的是内核标准的挂接位置）。

```
[～]#mount-t debugfs debugfs/sys/kernel/debug
```

ftrace的目录为/sys/kernel/debug/tracing。在这个目录下有ftrace的相关特殊文件。这里介绍一些具有代表性的文件（见表8-4～表8-6）。

表 8-4　控制整体追踪运行情况的文件

文　件　名	说　　明
tracing_on	启用向追踪缓冲区写入的功能。1 为启用。0 为禁用
tracing_enabled	启用插件追踪器。1 为启用。0 为禁用
available_tracers	显示当前内核中可使用的插件追踪器。关于各个插件追踪器请参考表 8-8
current_tracer	指定想要使用的插件追踪器
trace_options	指定追踪的文本格式的调整运行选项。想要取消设置时，执行以“no”开头的选项

（续）

文　件　名	说　　明
tracing_cpumask	以十六进制的位掩码指定要作为追踪对象的处理器。例如，指定 0xb 时仅在处理器 0、1、3 上进行追踪
set_ftrace_pid	指定要作为追踪对象的进程的 PID

表 8-5　追踪缓冲区的相关文件

文　件　名	说　　明
trace	以文本格式输出内核中追踪缓冲区的内容
trace_pipe	与 trace 相同，但是运行时像管道一样，可以在每次事件发生时读出。但是一旦读过的内容就不能再次读出
buffers_size_kb	以 KB 为单位指定各 CPU 的追踪缓冲区大小。系统整体的缓冲区大小就是这个值乘以 CPU 数量。缓冲区以页面为单位分配，但是有一些字节用于缓冲区的管理结构，因此实际分配的缓冲区比指定的值更大。指定追踪缓冲区大小时，必须设置为 nop 追踪器

表 8-6　函数追踪器的相关文件

文　件　名	说　　明
set_ftrace_filter	指定追踪调用的函数名称。函数名称仅可以包含 1 个通配符（wildcard）
set_ftrace_notrace	指定不追踪调用的函数名称

表8-4中有控制向追踪缓冲区写入的tracing_on和控制插件追踪器的tracing_enabled这两个文件。这个文件的值的组合情况如表8-7所示。这些看起来不太容易发现运行的不同之处，因此tracing_enabled在最新的内核（Linux 2.6.39以后）中成为废弃（deprecated）对象。今后将只使用tracing_on。

表 8-7　tracing_on 和 tracing_enabled

tracing_on	tracing_enabled	运　行
0	0	插件追踪器禁用。追踪事件的信息也不写入缓冲区
0	1	插件追踪器启用，但插件追踪器和追踪事件二者的信息不写入缓冲区
1	0	插件追踪器禁用，但追踪事件的信息写入缓冲区
1	1	插件追踪器启用，追踪事件的信息也写入缓冲区

显示表8-4中的available_tracers，可以看出存在多个插件追踪器。ftrace中可以使用的代表性插件追踪器如表8-8所示。

表 8-8　插件追踪器的种类

种　类	说　明
function	记录函数调用（仅调用）的追踪器。可以看出哪个函数何时调用
function_graph	记录函数的调用图表的追踪器。可以得知哪个函数被哪个函数调用，何时返回
mmiotrace	记录 MMIO（Memory Mapped I/O，内存映射 I/O）的运行的追踪器。用于 Nouveau 驱动程序等逆向工程（reverse engineering）
blk	调查块 I/O 运行的追踪器
wakeup	记录进程的调度延迟较长的
wakeup_rt	与 wakeup 相同，但以实时进程为对象
irqsoff	记录禁止中断期间花费时间最多的
preemptoff	记录禁止优先权期间花费时间最多的
preemptirqsoff	记录禁止优先权和中断的期间花费时间最多的
sched_switch	进行上下文切换的追踪。可以得知从哪个进程切换到了哪个进程
nop	不执行任何操作。不使用插件追踪器时指定

下面使用这些接口尝试实际使用ftrace。

使用ftrace追踪函数调用

顾名思义，ftrace原本是记录函数调用时间而开发出来的。首先介绍它的使用方法。作为示例，尝试追踪Linux的进程调度程序是从哪个函数调用的。首先根据available_tracers的内容确认是否支持记录函数调用的函数追踪器。

```
[～]#cd/sys/kernel/debug/tracing
[tracing]#cat available_tracers
blk function_graph wakeup_rt wakeup irqsoff function sched_switch nop
```

函数追踪器为表8-8中的function。available_tracers包含function，因此可见在这个内核中可以使用函数追踪器。

一旦将函数追踪器启用，ftrace就会记录所有函数的运行情况。但是本次只想查看调度程序函数schedule（）的调用情况，因此事先使用追踪函数过滤器设置为仅记录schedule（）。[tracing]#echo schedule＞set_ftrace_flter设置好追踪函数过滤器后，将函数追踪器funciton写入current_tracer特殊文件。

```
[tracing]#echo function＞current_tracer
```

追踪结果可以从trace特殊文件读出。这时的结果如下所示。

```
[tracing]#head trace
#tracer：function
#
#TASK-PID CPU#TIMESTAMP FUNCTION
#|||||
tee-7470[000]16107.974550：schedule＜-do_exit
＜idle＞-0[000]16107.975318：schedule＜-cpu_idle
bash-5210[000]16107.976277：schedule＜-schedule_timeout
events/0-9[000]16107.976371：schedule＜-worker_thread
＜idle＞-0[001]16108.054539：schedule＜-cpu_idle
flush-8：0-284[001]16108.054557：schedule＜-schedule_timeout
```

可以看出进程调度程序是从几个不同的函数调用的。

可以使用多个函数名称或通配符向过滤器指定模式、模块。例如，按照下列方式，就可以记录函数名以irq开头的所有函数调用。

[tracing]#echo'irq*'＞set_ftrace_flter

另外，在参数前面加上：mod：，还可以仅追踪特定的内核驱动程序模块中包含的函数。在下例中，仅追踪btrfs模块中包含的函数。

[tracing]#echo：mod：btrfs＞set_ftrace_flter
为了如前所述仅获取以irq开头的函数，需要更换过滤器。
[tracing]#echo'irq*'＞set_ftrace_flter
[tracing]#echo 0＞trace
[tracing]#head trace
#tracer：function
#
#TASK-PID CPU#TIMESTAMP FUNCTION
#|||||
bash-1911[000]55477.514345：irq_enter＜-smp_apic_timer_interrupt
bash-1911[000]55477.514677：irq_exit＜-smp_apic_timer_interrupt
bash-1911[000]55477.514939：irq_enter＜-smp_apic_timer_interrupt
bash-1911[000]55477.514995：irq_exit＜-smp_apic_timer_interrupt
＜idle＞-0[000]55477.515953：irq_enter＜-smp_apic_timer_interrupt
＜idle＞-0[000]55477.516041：irq_exit＜-smp_apic_timer_interrupt

可以看出记录了以irq开头的函数。切换了过滤器后，就向trace写入0，这是为了将缓冲区内容暂时清除。仅通过切换过滤器是不能清除缓冲区内容的，因此需要这样手动清除缓冲区内容。

小结

本节介绍了什么是追踪、ftrace的基本使用方法，以及实际使用函数追踪器找出特定内核函数的调用起点的方法。函数追踪器对于研究实际运行中系统函数调用关系非常有效。

参考文献

·Documentation/trace/ftrace. txt

——Masami Hiramatsu

HACK#68　ftrace的插件追踪器

本节介绍如何使用ftrace的插件追踪器进行内核的追踪。

ftrace中有很多插件追踪器。这里介绍一些可用于内核调整或开发的追踪器，如进程调度程序和中断处理延迟的追踪、函数调用和栈使用情况的概要分析。

获取函数的调用关系

想要调查内核中特定部位的运行情况时，使用较多的是函数指针，有时会难以追踪源代码。在这种情况下，使用ftrace的函数调用图表追踪器和回溯追踪器可以更高效地研究调用的起点。

函数调用图表追踪器通过向current_tracer写入function_graph来运行。在这个追踪器中将体现Hack#67中介绍的set_ftrace_filter的设置，因此可以进行限定在一部分函数的追踪上。下面所示为仅追踪ext4文件系统的驱动程序内部的结果。

```
[~] # cd /sys/kernel/debug/tracing
[tracing] # echo :mod:ext4 > set_ftrace_filter
[tracing] # echo function_graph > current_tracer
[tracing] # head trace
# tracer: function_graph
#
#     TIME        CPU  DURATION                  FUNCTION CALLS
#      |          |     |   |                     |   |   |   |
 0)   5.781 us    |  ext4_write_inode();
 1)   5.227 us    |  ext4_check_acl();
 1)               |  ext4_check_acl() {
 1)   0.615 us    |    ext4_get_acl();
 1)   1.564 us    |  }
 1)   1.536 us    |  ext4_check_acl();
```

各行开头的数字表示CPU编号。TIME的位置显示的是执行该函数所花费的时间。以微秒为单位显示，超过10微秒的数值前面会显示‘+’，超过100微秒的数值前面显示‘！’。另外，函数名称按照函数调用的形式显示，使用缩进和大括号更为清晰地显示出调用关

系。

另一方面，函数回溯是ftrace自身的扩展功能之一。需要运行事件追踪或函数追踪器，同时向options/func_stack_trace写入1来启动。这个功能在每次调用对象函数时进行回溯，因此需要事先使用set_ftrace_filter来缩小对象函数的范围。

```
[tracing]#echo schedule＞set_ftrace_flter
[tracing]#echo function＞current_tracer
[tracing]#echo 1＞options/func_stack_trace
[tracing]#echo 0＞trace
[tracing]#head-n 20 trace
#tracer：function
#
#TASK-PID CPU#TIMESTAMP FUNCTION
```

```
#              | |       |          |         |
            bash-1001  [000]  6371.701772: schedule <-schedule_timeout
            bash-1001  [000]  6371.701774: <stack trace>
 => schedule_timeout
 => n_tty_read
 => tty_read
 => vfs_read
 => sys_read
 => system_call_fastpath
          <idle>-0     [000]  6371.701877: schedule <-cpu_idle
          <idle>-0     [000]  6371.701878: <stack trace>
 => cpu_idle
 => rest_init
 => start_kernel
 => x86_64_start_reservations
 => x86_64_start_kernel
              sshd-981    [000]   6371.702056: schedule <-schedule_hrtimeout_
range_clock
```

对象函数的追踪入口后面出现了＜stack trace＞入口，它的后面显示的是回溯的结果。

进行函数的概要分析

使用perf tools的概要分析中，进行了基于采样的概要分析，而使用ftrace可以研究实际处理的函数调用次数或平均处理时间。

```
[tracing] # echo nop > current_tracer
[tracing] # echo 1 > function_profile_enabled
[tracing] # head trace_stat/function0
  Function                               Hit    Time            Avg             s^2
  --------                               ---    ----            ---             ---
  schedule                               825    30261574 us     36680.69 us     1847361176 us
  poll_schedule_timeout                  124    8010094 us      64597.53 us     58239034039 us
  schedule_hrtimeout_range               124    8010001 us      64596.78 us     58238992673 us
  schedule_hrtimeout_range_clock         124    8009946 us      64596.34 us     58238973829 us
  default_idle                           483    6859897 us      14202.68 us     7136583263 us
  native_safe_halt                       483    6858505 us      14199.80 us     7136531144 us
  sys_select                              82    6652916 us      81133.13 us     84536914899 us
  core_sys_select                         82    6652773 us      81131.38 us     84536991091 us
```

Time表示累计值，Avg表示平均值，S^2表示平均方差。但是这个值包含函数内休眠的时间和被该函数调用的其他函数的处理时间。这些时间可以分别使用options/sleep-time和options/graph-time来修正。

将options/sleep-time设置为0，就可以在函数内修正休眠的时间。仅改变选项的话，就只是添加到之前的结果中。将function_profile_enabled先设置为0再恢复为1，就可以重置为到这时为止的结果。

[tracing]#echo 0＞options/sleep-time
[tracing]#echo 0＞function_profle_enabled
[tracing]#echo 1＞function_profle_enabled
[tracing]#head trace_stat/function0

```
  Function                               Hit    Time            Avg             s^2
  --------                               ---    ----            ---             ---
  schedule                              1431    305067863 us    213185.0 us     3333149560 us
  schedule_hrtimeout_range               326    305016911 us    935634.6 us     17783347272 us
  schedule_hrtimeout_range_clock         326    305016701 us    935634.0 us     17783619420 us
  poll_schedule_timeout                  322    305016644 us    947256.6 us     6964013622 us
  sys_poll                                41    305003855 us    7439118 us      361774855912 us
  do_sys_poll                             41    305003347 us    7439106 us      361953750054 us
  default_idle                          1393    237675932 us    170621.6 us     11207125794 us
  native_safe_halt                      1393    237669316 us    170616.8 us     11206960460 us
```

同样的，将options/graph-time设置为0，就可以修正调用其他函数的时间。

```
[tracing] # echo 0 > options/graph-time
[tracing] # echo 0 > function_profile_enabled
[tracing] # echo 1 > function_profile_enabled
[tracing] # head trace_stat/function0
  Function                               Hit    Time            Avg             s^2
  --------                               ---    ----            ---             ---
  native_safe_halt                        66    2524613 us      38251.71 us     5833974146 us
  native_apic_mem_write                  171    3921.759 us     22.934 us       4288.712 us
  read_pmtmr                             509    3350.586 us     6.582 us        10.813 us
  smp_apic_timer_interrupt                61    2381.892 us     39.047 us       19776.76 us
  ack_APIC_irq                            61    1932.587 us     31.681 us       17289.86 us
  apic_write                             136    1516.866 us     11.153 us       3312.367 us
  _cond_resched                          521    1233.437 us     2.367 us        2095.993 us
  vp_interrupt                            11    717.574 us      65.234 us       32837.94 us
```

调查占用内核栈最大的位置

ftrace中有一个栈追踪功能，是在内核内部函数获取内核栈的消耗量，从消耗量最大的位置进行回溯的功能。内核栈是有限的（x86中为约8KB），因此栈的消耗量一旦超过上限，就有可能引起内存破坏或内核重大故障。

栈追踪器准确来说并不是ftrace的插件追踪器。但是由于接口使用的是ftrace，因此本节将其作为ftrace功能之一进行介绍。使用栈追踪器时需要使用下列方法之一。

·向Linux内核的启动选项传递stacktrace后启动。

·向/proc/sys/kernel/stack_tracer_enabled写入1。

这里使用第二个方法尝试进行栈追踪。

```
[tracing] # echo 1 > /proc/sys/kernel/stack_tracer_enabled
[tracing] # cat stack_trace
        Depth    Size   Location    (10 entries)
        -----    ----   --------
  0)     2688     464   find_busiest_group+0x129/0x90e
  1)     2224     288   load_balance+0xbc/0x66a
  2)     1936     192   schedule+0x302/0x681
  3)     1744     160   schedule_hrtimeout_range_clock+0x52/0x11b
  4)     1584      16   schedule_hrtimeout_range+0x13/0x15
  5)     1568      48   poll_schedule_timeout+0x48/0x64
  6)     1520     880   do_select+0x4e8/0x52c
  7)      640     400   core_sys_select+0x174/0x213
  8)      240     112   sys_select+0x96/0xbe
  9)      128     128   system_call_fastpath+0x16/0x1b
```

与其他追踪器最大的不同在于使用procfs来控制启用或禁用，以及从stack_trace这个特殊文件而不是从trace进行读出。

Depth表示该函数内最大的栈消耗量，Size表示仅该函数上使用的栈消耗量。加大负

载一段时间后再次读入stack_trace，就会出现消耗了栈的执行路径。

测量中断的延迟

Linux的进程会由于各种原因发生运行延迟。使用ftrace的延迟追踪器有时也可以找到调度延迟的原因。

在ftrace的插件追踪器中，irqsoff、preemptoff、preemptirqsoff、wakeup、wakeup-rt分别为测量中断、优先权、调度的延迟时间的功能，统称为延迟追踪器（Latency Tracer）。（各自的内容请参考Hack#67的表8-8）。

之所以开发ftrace，是因为在开发实时内核（实际上是尽量缩短处理延迟的软实时（soft realtime）内核）时，出现了测量内核中的延迟时间、调查瓶颈在哪里的要求。这些延迟追踪器就是为了满足这个要求而开发的功能。

延迟追踪器测量的对象不同，但输出基本上是相同的。这里使用追踪禁止中断时间的追踪器作为示例。

```
[tracing] # echo irqsoff > current_tracer
[tracing] # echo 1 > tracing_on
[tracing] # echo 0 > tracing_on
[tracing] # cat trace
# tracer: irqsoff
#
# irqsoff latency trace v1.1.5 on 3.0.0-rc4+
# --------------------------------------------------------------------
# latency: 222 us, #294/294, CPU#0 | (M:desktop VP:0, KP:0, SP:0 HP:0 #P:4)
#    -----------------
#    | task: docky-2157 (uid:1000 nice:0 policy:0 rt_prio:0)
#    -----------------
#  => started at: schedule
#  => ended at:   schedule
#
#
#                  _------=> CPU#
#                 / _-----=> irqs-off
#                | / _----=> need-resched
#                || / _---=> hardirq/softirq
#                ||| / _--=> preempt-depth
#                |||| /     delay
#  cmd     pid   ||||| time  |   caller
#     \   /      |||||  \    |   /
notify-o-2227    0d...    0us : _raw_spin_lock_irq <-schedule
```

---

notify-o-2227 0d……1us：deactivate_task＜-schedule
notify-o-2227 0d……1us：dequeue_task＜-deactivate_task
notify-o-2227 0d……2us：update_rq_clock＜-dequeue_task
notify-o-2227 0d……3us：dequeue_task_fair＜-dequeue_task
notify-o-2227 0d……3us：update_curr＜-dequeue_task_fair
notify-o-2227 0d……4us：cpuacct_charge＜-update_curr
notify-o-2227 0d……4us：clear_buddies＜-dequeue_task_fair
notify-o-2227 0d……5us：update_cfs_load＜-dequeue_task_fair
notify-o-2227 0d……6us：update_cfs_shares＜-dequeue_task_fair
……
notify-o-2227 0d……219us：native_load_sp0＜-__switch_to
notify-o-2227 0d……219us：native_load_tls＜-__switch_to
notify-o-2227 0d……220us：native_read_cr0＜-__switch_to
notify-o-2227 0d……220us：native_write_cr0＜-__switch_to
docky-2157 0d……221us：finish_task_switch＜-schedule
docky-2157 0d……222us：finish_task_switch＜-schedule
docky-2157 0d……223us：trace_hardirqs_on＜-schedule
docky-2157 0d……223us：＜stack trace＞
=＞finish_task_switch
=＞schedule
=＞schedule_hrtimeout_range_clock
=＞schedule_hrtimeout_range
=＞poll_schedule_timeout
=＞do_sys_poll
=＞sys_poll
=＞system_call_fastpath

显示了禁止中断期间最长、从开始禁止中断的位置到允许中断的位置之间的执行路

径。与其他追踪器的输出相似，而不同之处在于其中有6个标志，且显示的不是从记录的时间开始而是从开始禁止中断开始的延迟时间。

6个标志显示的信息分别是CPU编号、是否禁止中断（d）、是否必须重新调度对象进程（N）、是不是硬中断（h）或软中断（s）、锁定了几个优先权计数、BKL。

小结

本节通过一些实例介绍了ftrace的追踪器。Ftrace源于函数追踪器的功能，但现在已经成为整合了众多追踪器和追踪功能的接口，也成为Linux标准的追踪框架。根据不同的需要选择使用ftrace的追踪器，可以对系统或内核的开发起到很大的作用。

参考文献

·Secrets of the Ftrace function tracer

http://lwn. net/Articles/370423/

——Masami Hiramatsu

HACK#69　记录内核的运行事件

本节介绍使用ftrace记录追踪事件的方法。

追踪事件是以过去称为追踪点（即，非常小型的追踪器调用的钩子（hook））功能为基础，在内核中的代表性操作位置上安装用来记录该处理的状态的追踪事件。通过记录这些追踪事件的内容，就可以记录内核中的典型性操作。在Linux 2.6.28中安装了这个追踪事件功能以后，通过内核内部的各种处理定义了追踪事件，使用户能够通过ftrace或perf tools等观测到这些事件。Linux内核中已经安装了100多个追踪点，追踪事件的数量超过了200个（也有系统调用事件等从一个追踪点生成多个追踪事件的情况）。

本节将介绍从ftrace获取这些事件的方法、与ftrace的其他追踪器合作记录事件的方法及其效果。

首先，尝试调查内核中的中断处理程序何时运行。与中断处理程序相对应的事件为irq：irq_handler_entry和irq：irq_handler_exit，因此可以使用下列命令进行追踪。

```
[～]#cd/sys/kernel/debug/tracing
[tracing]#cd/sys/kernel/debug/tracing
[tracing]#echo irq：irq_handler_entry＞set_event
[tracing]#echo irq：irq_handler_exit＞＞set_event
[tracing]#cat trace
……
kblockd/0-20[000]6854.611683：irq_handler_entry：irq=21 name=ahci
kblockd/0-20[000]6854.611735：irq_handler_exit：irq=21 ret=handled
kblockd/0-20[000]6854.611736：irq_handler_entry：irq=21 name=Intel
82801AA-ICH
kblockd/0-20[000]6854.611760：irq_handler_exit：irq=21 ret=unhandled
＜idle＞-0[000]6854.614767：irq_handler_entry：irq=16 name=virtio1
＜idle＞-0[000]6854.614779：irq_handler_exit：irq=16 ret=handled
dbus-daemon-839[000]6854.630395：irq_handler_entry：irq=12 name=i8042
dbus-daemon-839[000]6854.630417：irq_handler_exit：irq=12 ret=handled
……
```

可以看出系统上发生的中断通过各种子系统得到填补和处理。下面更加详细、集中地查看特定的中断（21号）。

```
[tracing]#echo"irq==21"＞events/irq/irq_handler_entry/flter
[tracing]#echo"irq==21"＞events/irq/irq_handler_exit/flter
[tracing]#echo 0＞trace
[tracing]#cat trace
……
jbd2/sda1-8-312[000]6883.399116：irq_handler_entry：irq=21 name=ahci
jbd2/sda1-8-312[000]6883.399167：irq_handler_exit：irq=21 ret=handled
jbd2/sda1-8-312[000]6883.399169：irq_handler_entry：irq=21 name=Intel
82801AA-ICH
jbd2/sda1-8-312[000]6883.399202：irq_handler_exit：irq=21 ret=unhandled
jbd2/sda1-8-312[000]6883.399374：irq_handler_entry：irq=21 name=ahci
jbd2/sda1-8-312[000]6883.399550：irq_handler_exit：irq=21 ret=handled
……
```

例如，在上述示例中，可以看出在系统启动后的6883.399秒左右，jbd2/sda1-8-312进程（在本例中为内核线程）在CPU0（[000]）上运行，这时发生了中断处理。此外，还可以读出想要在ahci或Intel 82801AA-ICH设备上处理IRQ编号21的中断，且ahci处理已成功。

要删除已经设置的过滤器，可以在过滤器规则中写入“0”。需要注意的是，虽然默认的过滤器规则中所写的是“none”，但如果写入“none”就会出错。

```
[tracing]#echo 0＞events/irq/irq_handler_entry/flter
[tracing]#echo 0＞events/irq/irq_handler_exit/flter
```

接下来介绍更为详细的设置方法等。

调查可使用的追踪事件

要查看当前运行在内核中可追踪的事件，可以查看/sys/kernel/debug/tracing/目录下的特殊文件available_events的内容，或者在/sys/kernel/debug/tracing/events/目录下列举下列内容。

```
[tracing]#less available_events
kvmmmu：kvm_mmu_pagetable_walk
kvmmmu：kvm_mmu_paging_element
kvmmmu：kvm_mmu_set_accessed_bit
kvmmmu：kvm_mmu_set_dirty_bit
kvmmmu：kvm_mmu_walker_error
kvmmmu：kvm_mmu_get_page
```

```
……
[tracing]#fnd events/
events/
events/kvmmmu
events/kvmmmu/kvm_mmu_pagetable_walk
events/kvmmmu/kvm_mmu_pagetable_walk/format
events/kvmmmu/kvm_mmu_pagetable_walk/filter
events/kvmmmu/kvm_mmu_pagetable_walk/id
events/kvmmmu/kvm_mmu_pagetable_walk/enable
……
```

各追踪事件具有组名和事件名。available_events的内容格式为“组名：事件名”。而在events目录下，首先有与组相对应的目录，其下有与事件相对应的目录。与只有事件列表的available_events不同的是，events目录下存在用来获取更为详细的信息与进行控制的特殊文件（见表8-9）。

表 8-9 事件的特殊文件

文 件 名	内 容
id	记录事件的 ID 编号。只读
format	记录 ftrace 缓冲区上的事件入口的详细格式。只读

（续）

文 件 名	内 容
enable	决定是否记录这个事件的标志。只读
filter	记录这个事件的条件的过滤器

分组目录下也存在filter和enable特殊文件。这些特殊文件可以在以组为单位记录多个事件或进行过滤时使用。

调查事件的格式

可以从各事件的format特殊文件中查看各事件中记录的信息和该信息的显示格式等。

```
[tracing]#cat events/irq/irq_handler_entry/format
name：irq_handler_entry
ID：98
format：
field：unsigned short common_type；offset：0；size：2；signed：0；
field：unsigned char common_flags；offset：2；size：1；signed：0；
field：unsigned char common_preempt_count；offset：3；s i z e：1；
signed：0；
field：int common_pid；offset：4；size：4；signed：1；
field：int common_lock_depth；offset：8；size：4；signed：1；
field：int irq；offset：12；size：4；signed：1；
field：__data_loc char[]name；offset：16；size：4；signed：1；
print fmt："irq=%d name=%s"，REC->irq，__get_str（name）
```

这个格式中同时记录了ftrace将事件记录到缓冲区时的二进制格式信息、用户将事件读出为文本信息时的格式信息（见表8-10）。

表 8-10　事件格式的内容

项　目	内　容
name	事件的名称
ID	事件 ID 编号
format	二进制格式项的结构
field	关于二进制格式项内的变量信息
print fmt	ftrace 输出文本时的格式

二进制格式信息在field：后面分别显示各参数的（C语言的）类型名称、项上的变量名称、离入口开头的字节偏移量、字节大小、变量是否带符号。各参数的类型名称基本与C语言的类型名称相同，因此这个入口的内存映像与下列结构基本相同。

```
struct irq_handler_entry_structure{
unsigned short common_type；
unsigned char common_flags；
unsigned char common_preempt_count；
int common_pid；
int common_lock_depth；
int irq；
char*name；
}__attribute__（（__packed））；
```

可以看出，字段的定义分为上面5个字段和其他字段。空行上方为所有事件共同的变量，空行下方为这个事件特有的变量。追踪事件共同的变量具有下列意义（见表8-11）。

表 8-11 追踪事件共同变量

变 量	说 明
common_type	数据入口的类型 ID。插件追踪器各自具有不同的数据项类型 ID。追踪事件的每个不同事件都具有类型 ID
common_flags	事件发生时标志寄存器的值
common_preempt_count	事件发生时优先权计数的值
common_pid	事件发生时当前进程的 PID
common_lock_depth	事件发生时当前进程获取了多少 BKL（Big Kernel Lock）（仅 CONFIG_BKL=y 时存在）

如果有内核的源代码，还可以查看各事件特有变量的意义。例如，irq_handler_entry事件在内核源码树的include/trace/events/irq.h下写有下列命令。

```
/**
*irq_handler_entry-called immediately before the irq action handler
*@irq：irq number
*@action：pointer to struct irqaction
*
*The struct irqaction pointed to by@action contains various
*information about the handler, including the device name，
*@action-＞name, and the device id，@action-＞dev_id.When used in
*conjunction with the irq_handler_exit tracepoint, we can figure
*out irq handler latencies.
*/
```

但是，这里有一点需要注意。上述注释并不是irq_handler_entry追踪事件的注释，而是内核内部使用的API的注释，因此参数有一些不同。要调查各追踪事件的参数相当于API的哪个参数，需要阅读各个事件的代码。在这个示例中，备注中的@action-＞name在追踪事件中为name。

控制事件

事件可以分别设置为启用（记录）、禁用（不记录），或者设置过滤。另外，也可以以事件组为单位进行统一控制。

记录/不记录的控制可以通过操作set_events或各事件、各组的enable特殊文件来进行。以与available_events相同的“组名：事件名”的格式向set_events写入想要开始记录的事件列表。

```
[tracing]#cat＞set_events
irq：irq_handler_entry
irq：irq_handler_exit
^D
```

使用events目录下的enable特殊文件的方法是向各事件或各组写入启用或禁用选项。

```
[tracing]#echo 1＞events/irq/irq_handler_entry/enable
[tracing]#echo 1＞events/irq/irq_handler_exit/enable
```

不管使用的是哪个方法，在其中一个接口上设置的状态都会自动反映到另一个接口上，因此一般来说可以这样使用。

·想要从命令行添加事件时，使用events目录。

·想要保存已添加事件的设置时，或想要将已保存的设置恢复时，使用set_events。例如，还可以暂时保存事件，并发送到想要获取同一事件的其他机器后再写入。

```
手头的机器
[tracing]#cat set_events＞/tmp/event_set1
[tracing]#scp/tmp/event_set1 remote：～/
远程机器
[tracing]#cat～/event_set1＞set_events
```

而事件过滤器是使用events目录下的filter特殊文件进行设置的。事件过滤器是通过事

件发生时的参数值来设置是否记录的功能。参数大致可以分为数值参数和字符串参数，各自可使用的比较运算符有所不同（见表8-12）。过滤器的比较表达式必须是左边为参数名，右边为值。也就是说，可以指定irq＜=10，但不能指定10＞=irq。

表 8-12　事件过滤器中可使用的比较运算符

比较运算符	适 用 对 象	说　　明
= =	数值、字符串	参数的值等于给出的值则记录
!=	数值、字符串	参数的值不等于给出的值则记录
~	字符串	将参数与字符串进行比较，如果一致则记录。可以将通配符（“*”）用做字符串的一部分
<	数值	参数的值小于给出的值则记录
<=	数值	参数的值等于或小于给出的值则记录
>	数值	参数的值大于给出的值则记录
>=	数值	参数的值等于或大于给出的值则记录

另外，也可以使用逻辑运算符和小括号组合多个过滤器。例如，在参数irq的值介于10～20或name以ata开头的情况下，想要记录事件时的过滤器如下所示。

```
（irq＞=10＆＆irq＜20）||name～ata*
```

另外，ftrace有一个特点，就是文本输出的追踪结果即使看起来像字符串，有些参数也只是在输出文本时在内部进行了转换，它们实际还是数值。对于这样的参数不能使用用于字符串参数的比较运算符。

```
[tracing]#echo"ret==unhandled"＞events/irq/irq_handler_exit/flter#这个出错
bash：echo：write error：Invalid argument
[tracing]#echo"ret==0"＞events/irq/irq_handler_exit/flter#这个没问题
```

要找出这样的疑似字符串参数，就需要阅读format特殊文件。

```
[tracing]#cat events/irq/irq_handler_exit/format
name：irq_handler_exit
ID：97
format：
field：unsigned short common_type；offset：0；size：2；signed：0；
field：unsigned char common_flags；offset：2；size：1；signed：0；
field：unsigned char common_preempt_count；offset：3；s i z e：1；
signed：0；
field：int common_pid；offset：4；size：4；signed：1；
field：int common_lock_depth；offset：8；size：4；signed：1；
field：int irq；offset：12；size：4；signed：1；
field：int ret；offset：16；size：4；signed：1；
print fmt："irq=%d ret=%s"，REC-＞irq, REC-＞ret?"handled"："unhandled"
```

根据format可以看出，参数ret记录为int类型，在print fmt中，如果ret！=0则显示为handled，如果ret==0则显示为unhandled。过滤器可以适用于format部分所示格式的数据，因此ret必须作为数值参数。

使用ftrace的事件加强其他的追踪器输出

ftrace的追踪事件可以与其他插件追踪器组合输出。这样就可以更清晰地查看输出量较多的函数追踪器的结果等。

例如，尝试同时使用进程调度程序的相关事件和函数追踪器，就可以得知进程的切换处理和函数调用关系等。在下例中实际显示了从发生sched_switch事件到进程切换为止的步骤，可以更加详细地了解事件前后发生的情况。

```
[tracing]#echo'sched：*'＞set_event
[tracing]#echo'function'＞current_tracer
[tracing]#cat trace
……
less-3569[001]16957.997983：sched_stat_wait：comm=events/1 pid=10
delay=53796[ns]
less-3569[001]16957.997984：task_of＜-pick_next_task_fair
less-3569[001]16957.997984：hrtick_start_fair＜-pick_next_
task_fair
less-3569[001]16957.997985：__raw_local_save_flags＜-ftrace_
raw_event_sched_switch
less-3569[001]16957.997985：sched_switch：prev_comm=less
prev_pid=3569 prev_prio=120 prev_state=R==＞next_comm=events/1 next_pid=10 next_prio=120
less-3569[001]16957.997985：atomic_inc＜-schedule
less-3569[001]16957.997986：enter_lazy_tlb.clone.16
＜-schedule
less-3569[001]16957.997986：native_load_sp0＜-__switch_to
less-3569[001]16957.997987：load_TLS＜-__switch_to
less-3569[001]16957.997987：native_load_tls＜-load_TLS
less-3569[001]16957.997988：__unlazy_fpu＜-__switch_to
less-3569[001]16957.997988：read_cr0＜-__unlazy_fpu
less-3569[001]16957.997988：native_read_cr0＜-read_cr0
less-3569[001]16957.997989：native_write_cr0＜-__unlazy_fpu
events/1-10[001]16957.997995：finish_task_switch＜-schedule
events/1-10[001]16957.997999：raw_local_irq_enable＜-finish_task_
switch
```

另外，还可以使用事件的参数，研究函数调用的终点实际进行的处理和处理所花费的时间之间的关系。

```
[tracing]#echo do_IRQ＞set_ftrace_flter
[tracing]#echo 1＞events/irq/irq_handler_entry/enable
[tracing]#echo function_graph＞current_tracer
[tracing]#cat trace
……
```

```
0）==========>|
0）|do_IRQ（）{
0）|/*irq_handler_entry：irq=19 name=ehci_hcd：usb1*/
0）|/*irq_handler_entry：irq=19 name=virtio0*/
0）！244.859 us|}
0）<==========|
0）==========>|
0）|do_IRQ（）{
0）|/*irq_handler_entry：irq=21 name=ahci*/
0）|/*irq_handler_entry：irq=21 name=Intel 82801AA-ICH*/
0）==========>|
0
）|do_IRQ（）{
0）|/*irq_handler_entry：irq=21 name=ahci*/
0）|/*irq_handler_entry：irq=21 name=Intel 82801AA-ICH*/
0）！286.214 us|}
0）<==========|
0）！620.506 us|}
0）<==========|
```

例如，这里就使用do_IRQ的函数调用图表显示了处理所花费的时间（出现了超过100微秒的数值，因此数值前面显示了‘！’），但是仅使用函数调用图表难以调查出哪个中断进行了什么处理。但是事件会显示各个中断的处理方式，这样就可以很简单地得知启动了哪个中断处理程序，以及此时花费了多少时间。

小结

本节介绍了从ftrace记录追踪事件的方法、追踪事件特有的过滤器的设置方法，以及通过将追踪事件和插件追踪器组合使用来帮助分析插件追踪器结果的方法。追踪事件可以获取事件发生时的变量值等状态，因此在调试中可以起到非常大的作用。

参考文献

·Documentation/trace/ftrace. txt

·Documentation/trace/events. txt

——Masami Hiramatsu

HACK#70　使用trace-cmd的内核追踪

本节介绍使用trace-cmd工具简单地操作ftrace的方法。

本章将介绍关于追踪的知识。

为了能够简单地使用ftrace的功能并加以扩展，可以使用trace-cmd工具。本节将介绍使用trace-cmd代替ftrace获取内核追踪的方法。

trace-cmd的获取与创建

ftrace是不需要使用特别的命令，就可以轻松地追踪内核的运行情况，但是每次更改追踪条件时就需要对多个特殊文件进行设置，为了找出故障或处理延迟的原因而扩大或缩小条件，就需要花费很多时间和精力。

在这种情况下，为了能够方便地从命令行使用ftrace，就开发了trace-cmd工具。trace-cmd在有些发布版中还未作为工具包安装，因此需要通过从开发数据仓库获取的源代码来创建并使用。

trace-cmd的数据仓库为git：//git.kernel.org/pub/scm/linux/kernel/git/rostedt/trace-cmd.git。可以执行下列命令来获取和创建。

```
#git clone git：//git.kernel.org/pub/scm/linux/kernel/git/rostedt/trace-cmd.git
#cd trace-cmd
#make
#make install
```

trace-cmd虽然支持Python脚本的绑定（binding），但要启用这个功能必须事先安装python-dev（el）、swig。默认将命令安装到/usr/local/下。

使用trace-cmd进行追踪

trace-cmd命令中也有一些子命令，但只要有trace-cmd record命令和trace-cmd report，就可以使用ftrace的基本功能。例如，下列命令就可以同时与记录函数追踪器和进程调度程序相关的事件。（停止追踪时按Ctrl+C快捷键。）

```
#trace-cmd record-p function-e'sched：*'
```

向trace-cmd的-p选项指定插件追踪器的名称，与向ftrace的current_tracer指定的内容相同。按照向ftrace的set_event指定的相同格式，向-e选项指定事件名称。事件的过滤器可以使用-f选项来指定。指定多个事件时，要在事件后面接着指定过滤器。例如，下列命令就是向irq_handler_entry事件指定“irq＞=10”过滤器，向irq_handler_exit事件指定“ret==0”。

```
#trace-cmd record-e irq_handler_entry-f"irq＞=10"-e irq_handler_exit-f"ret==0"
```

在trace-cmd中还可以进行仅使用ftrace时难以控制的指定。在执行特定的用户命令期间，也可以仅获取该进程相关的事件。例如，下列命令仅在执行ls命令期间运行函数追踪器和进程调度程序的相关事件，仅追踪ls命令的相关事件（-F选项）。ls命令结束后，追踪也自动结束。

```
#trace-cmd record-p function-e'sched：*'-F ls
```

获取的数据记录在执行目录的trace.dat文件中（记录的位置可以使用-o选项来更改）。这个数据文件包含获取追踪时的系统信息（定义的事件或内核的符号信息等）。另外，追踪数据是作为二进制数据记录的，因此要使用trace-cmd report将内容进行整理再读出。

```
#trace-cmd report
version=6
cpus=2
ls-25316[000]7031.618254：function：fsnotify_
```

modify<--vfs_write
ls-25316[000]7031.618258：function：inotify_
inode_queue_event<--fsnotify_modify
ls-25316[000]7031.618258：function：fsnotify_
parent<--fsnotify_modify
ls-25316[000]7031.618258：function：__
fsnotify_parent<--fsnotify_parent
ls-25316[000]7031.618259：function：inotify_
dentry_parent_queue_event<--fsnotify_parent
ls-25316[000]7031.618259：function：fsnotify
<--fsnotify_modify
ls-25316[000]7031.618260：function：fput_
light<--sys_write
ls-25316[000]7031.618260：function：audit_
syscall_exit<--sysret_audit
……

使用trace-cmd进行后台追踪

使用trace-cmd record时，不能像直接使用ftrace时在后台不断记录。另外，由于总是将追踪的结果写出到文件，因此追踪过程的系统开销也会变大。系统管理人员经常建议希望随时将追踪放到内存中，并以发生某种情况为契机，将到此时为止记录的追踪数据的最新信息写出到文件。trace-cmd中使用trace-cmd start、trace-cmd extract、trace-cmd stop来进行这个操作。

trace-cmd start和trace-cmd extract中使用的参数与trace-cmd record相同。trace-cmd start具有除了文件输出或进程执行相关选项以外的选项。相反，trace-cmd extract具有文件输出的相关选项。

在下例中，向irq_handler_entry事件指定“irq＞=10”过滤器，向irq_handler_exit事件指定“ret==0”过滤器，并将追踪结果记录到内核的内存中。

```
#trace-cmd start-e irq_handler_entry-f"irq＞=10"-e irq_handler_exit-f"ret==0"
```

命令程序已经结束，但追踪程序仍在后台运行。执行中的追踪内容可以从/sys/kernel/debug/tracing/trace特殊文件阅读。如果发生异常情况，可以使用trace-cmd stop停止追踪，然后使用trace-cmd extract写到文件中。

```
（发生情况）
#trace-cmd stop
#trace-cmd extract-o result.data
#trace-cmd report-i result.data
```

在不执行trace-cmd stop命令的情况下，也可以执行trace-cmd extract，但这种情况下追踪数据将不断写入文件直到按下Ctrl+C快捷键为止。

另外需要注意的是，trace-cmd extract命令会在提取追踪数据的同时进行追踪的初始化（完成）。也就是说，一旦执行trace-cmd extract，在此之前运行的追踪的设置就会从内核

中消失。

因此，由于发生异常情况想要临时获取快照文件时，建议按下列方法直接使用ftrace的trace。

（发生情况）
#echo 0＞/sys/kernel/debug/tracing/tracing_on
#cp/sys/kernel/debug/tracing/trace snapshot1.log
#echo 1＞/sys/kernel/debug/tracing/tracing_on

在复制的前停止追踪，是为了防止混入关于复制行为自身的无用追踪数据。

使用trace-cmd结束追踪

从命令行操作ftrace时，结束追踪时可能会忘记返回参数，过滤器等设置的初始化也非常麻烦。如果执行trace-cmd reset，就可以将这些参数全部初始化，同时还将删除内核内存中的旧追踪记录。

另外，如前所述，使用trace-cmd stop结束追踪时，实际上内核内部的追踪设置也未完全初始化。也就是说，current_tracer和set_event都是正在追踪的设置。作为代替，trace-cmd stop中使用tracing_on特殊文件来开始或结束追踪。tracing_on特殊文件不改变追踪器自身的运行，只是将追踪器向追踪缓冲区写入的处理方式禁用，这样的话追踪器的系统开销是未完全消失的。因此，在结束追踪时，最后必须执行trace-cmd reset命令。

使用trace-cmd获取远程机器的追踪

trace-cmd中具有跨网络进行远程机器的ftrace操作、接收数据的功能。在接收数据的本地机器上运行trace-cmd listen命令，在远程机器上运行trace-cmd record，将追踪信息传送到本地机器的trace-cmd。

在通过trace-cmd记录的文件中，同时还记录了追踪器运行的机器的字节顺序（endian）等，即使是不同架构的机器之间也可以从远程进行追踪。从而也可以以嵌入式机器这样本地存储较小的机器将追踪信息提取到开发机器上进行分析。

要获取远程机器的追踪，首先在保存追踪数据的机器上以等待远程连接的模式启动trace-cmd。这时必须要设置等待端口号。此外，如果添加-D选项，还可以在后台作为守护进程运行。例如，在下例中是在11223号端口等待追踪会话（session）。

```
[host]#trace-cmd listen-p 11223
```

然后，在实际想获取追踪的机器上，向trace-cmd record的-N选项指定“主机名称：端口编号”并执行。例如，在下例中是连接到host的11223号端口，传送执行ls命令期间的函数追踪结果。

```
[client]#trace-cmd record-N host：11223-p function ls
```

这样就会在host的界面上出现下列显示结果。

```
connected!
Connected with client：33186
cpus=4
pagesize=4096
version=6
offset=31b000
offset=36d000
offset=3ce000
offset=483000
connected!
```

在主机的本地目录下就会生成trace.客户端名：端口.dat数据文件。要分析这个数据文件，需要如下例所示在trace-cmd report的-i选项中指定数据文件。

```
[host]#trace-cmd report-i trace.client：33186.dat
version=6
cpus=4
＜……＞-5453[000]7366.159374：function：down_read＜--m_start
＜……＞-5454[003]7366.159374：function：__fsnotify_parent＜--
vfs_write
＜……＞-5453[000]7366.159375：function：_cond_resched＜--
down_read
＜……＞-5454[003]7366.159375：function：fsnotify＜--vfs_write
＜……＞-5454[003]7366.159375：function：__srcu_read_lock＜--
fsnotify
＜……＞-5453[000]7366.159375：function：seq_list_start＜--m_
start
……
```

追踪的客户端的磁盘上未写入任何数据文件，因此可以用来在安装机器等保存追踪数据的空间较小的机器上获取追踪。但是由于是经由一般的TCP通信进行数据传输的，如果是在安全性有问题的环境中，还需要使用VPN或SSH端口映射（Prot Forward）等。

小结

本节介绍了在使用trace-cmd的ftrace操作中，使用record/report进行记录、分析，使用start/extract在后台获取追踪，使用listen向远程机器传送追踪数据的三种方法。通过使用trace-cmd，就不需要考虑debugfs的接口，可以简便地进行追踪。

——Masami Hiramatsu

HACK#71　将动态追踪事件添加到内核中

本节使用ftrace和perf probe，将动态追踪事件添加到内核中。

Hack#69介绍了使用ftrace记录追踪事件的方法。本节将介绍使用Linux 2.6.33开始添加的新结构“动态追踪事件”，简单方便地添加追踪事件的方法。

动态追踪事件

从Linux 2.6.33开始，ftrace和perf tools中开始添加了使用kprobes的动态追踪事件功能。通过使用这个功能，就可以在内核运行过程中添加新的追踪事件。这个功能的优点在于即使添加追踪事件也不需要重新构建或者重新启动内核。另外，通过使用perf tools的probe子命令，还可以添加源代码层次的追踪事件。可以看做是调试程序（debugger）的断点（break point）这样的功能。在动态追踪事件中还可以获取寄存器或栈的值（进而获取相应的内存值）。

动态追踪事件与其他内核内部事先定义的追踪事件一样，可以针对每个定义的事件进行启用或过滤。还可以使用perf probe，在源代码层次指定事件发生位置、从事件获取的本地变量、结构成员等。

如上所述，动态追踪事件是非常便利的功能，但是也受到一些约束。首先，内核中也有一部分无法添加追踪事件的区域。对于NMI、异常、kprobes的相关代码，无法添加追踪事件（这是kprobes的约束）。其次，动态追踪事件并不改写磁盘上的内核映像文件，因此只要重启系统就会消失。每次启动时都要添加相同事件的情况下，就需要将动态追踪事件的定义另行保存。虽然如此，但有了perf tools的帮助，就可以很轻松地添加动态追踪事件。寻找内核的bug时也是非常有用的工具。

经由ftrace将动态追踪事件添加到内核中

下面介绍经由ftrace的特殊文件添加动态追踪事件的方法。动态追踪事件在ftrace中的接口为/sys/kernel/debug/tracing/kprobe_events。经由ftrace定义动态追踪事件，就是按照下列格式向这个文件中写入信息。

[p|r][：[组名/]事件名]符号[+偏移量]|内存地址[参数]

开头的文字如果为p，就表示定义在指定动态追踪事件的地址上。开头的文字如果为r，则表示定义在指定动态追踪事件的函数（符号）返回调用起点的地方。未指定事件名时，从符号名称和偏移量生成任意的事件名。另外，参数的格式如表8-13所示。

表 8-13　参数的格式

参　数	说　明
%REG	获取寄存器 REG 的值（REG 的名称依赖于 CPU 架构）
@ADDR	获取内核地址 ADDR 中的数据
@SYM[+|-offs]	获取内核符号 SYM 加上或减去偏移量 offs 的地址中的数据
$stackN	获取栈的第 N 个入口（入口大小依赖于架构）
$stack	获取栈开头的地址
$retval	获取函数的返回值（但是只有位于函数调用的返回部分的追踪事件可以使用）
+|-offs（参数）	通过“参数”获取的值 ± 偏移量 offs 对应地址中的值（用于结

例如，在vfs_read的开头定义记录ax寄存器（x86-64作为RAX, x86-32作为EAX处理）和栈开头要素的动态追踪事件event1，使用下列方法进行确认。

```
[～]#cd/sys/kernel/debug/tracing/
[tracing]#echo p：event1 vfs_read%ax\$stack0＞kprobe_events
[tracing]#cat kprobe_events
p：kprobes/event1 vfs_read arg1=%ax arg2=$stack0
```

使用$stack或$retval时，请不要忘记转义特殊字符（$）。另外，如果不指定参数的类型，基本上就全部作为unsigned long类型进行处理，因此x86-64作为u64，x86-32作为u32处理。如果不向参数指定名称，就会自动分配arg1、arg2的名称。

下面讨论新添加的动态追踪事件是不是真的与其他事件相同。

```
[tracing]#fnd events/kprobes/
events/kprobes/
events/kprobes/event1
events/kprobes/event1/format
events/kprobes/event1/filter
events/kprobes/event1/id
events/kprobes/event1/enable
events/kprobes/enable
events/kprobes/filter
[tracing]#cat events/kprobes/event1/format
name：event1
ID：834
format：
field：unsigned short common_type；offset：0；size：2；
signed：0；
field：unsigned char common_flags；offset：2；size：1；
signed：0；
field：unsigned char common_preempt_count；offset：3；
size：1；signed：0；
field：int common_pid；offset：4；size：4；signed：1；
field：int common_lock_depth；offset：8；size：4；signed：1；
field：unsigned long__probe_ip；offset：16；size：8；signed：0；
field：u64 arg1；offset：24；size：8；signed：0；
field：u64 arg2；offset：32；size：8；signed：0；
print fmt："（%lx）arg1=%llx arg2=%llx"，REC->__probe_ip, REC->arg1，REC->arg2
```

可以看出，确实连格式的定义都是相同的。这个事件可以从ftrace使用，如下所示。

```
[tracing]#echo kprobes：event1＞set_event
[tracing]#head trace
#tracer：nop
#
#TASK-PID CPU#TIMESTAMP FUNCTION
#|||||
libvirtd-1242[003]22550.135210：event1：（vfs_read+0x0/0x190）arg1=0
arg2=ffffffff81148f81
libvirtd-1242[003]22550.135286：event1：（vfs_read+0x0/0x190）
arg1=400 arg2=ffffffff81148f81
libvirtd-1242[003]22550.135316：event1：（vfs_read+0x0/0x190）
arg1=800 arg2=ffffffff81148f81
libvirtd-1242[003]22550.135343：event1：（vfs_read+0x0/0x190）
arg1=c00 arg2=ffffffff81148f81
libvirtd-1242[003]22550.135346：event1：（vfs_read+0x0/0x190）
arg1=d28 arg2=ffffffff81148f81
libvirtd-1242[003]22550.135420：event1：（vfs_read+0x0/0x190）arg1=0
arg2=ffffffff81148f81
```

在上述示例中，向符号开头的地址添加了事件，也可以指定符号+偏移量。x86采用的是命令长度各不相同的CISC方式，因此必须进行反汇编才能知道可以向哪个地址添加事件。但是，即使指定了错误的地址，由于内核内部会进行命令范围的检查，因此会作为

定义时的错误被排除。

要删除这样定义的动态追踪事件，可以使用两种方法。

如果想删除所有定义，可以像下面这样向kprobe_events写入空白。

```
[tracing]#echo＞/sys/kernel/debug/tracing/kprobe_events
```

想删除单个事件，可以向kprobe_events追加“-：[组名/]事件名”命令。例如，只删除event1的方法如下。

```
[tracing]#echo-：kprobes/event1＞＞kprobe_events
```

使用perf probe将动态追踪事件添加到内核中

perf probe是为了定义动态追踪事件而开发的perf tools的功能之一。

如前所述，如果想要经由ftrace的接口直接定义事件，必须直接指定地址或寄存器来确定事件的内容。要添加源代码和执行二进制文件的内容，需要将二进制码反汇编、搜索作为本地变量的寄存器等，就要求能够熟练使用二进制。这对于刚刚开始进行内核编译的人来说使用比较困难，因此有人可能觉得使用printk更为方便。perf probe就是在这种情况下出现的。

perf probe可以分析内核的调试信息，在源代码层次定义动态追踪事件。另外，还可以查看源代码的哪一行可以追踪，哪个变量可以访问等。perf probe就像是小型的源代码调试程序。

启用调试信息和动态追踪事件构建内核

使用perf probe在源代码层次定义动态追踪事件时，必须要有内核的调试信息。

使用发布版附带的内核时，有些发布版（如RedHat和SuSE等）提供了所有的调试信息，而Debian和Ubuntu的内核调试信息数据包有时就不包括关于驱动程序的调试信息。每个发布版需要安装的数据包是不同的，因此需要根据所使用的发布版来选择。本节仅介绍作为一个内核技术人员（Kernel Hacker）如何从源代码构建内核，生成调试信息的方法。虽说如此，但也并非与已经提到很多次的内核构建方法有太大的不同。调试信息可以在编译时向编译器传递-g选项来生成，但内核中已经存在用来启用这个选项的配置项目（CONFIG_DEBUGINFO）。CONFIG_DEBUGINFO在内核配置中的位置如下。

```
Kernel hacking->
[*]Compile the kernel with debug info
```

除此以外，还需要启用动态追踪事件的支持。由于动态追踪事件使用kprobes和ftrace，因此需要启用CONFIG_KPROBES、CONFIG_FTRACE、CONFIG_KPROBE_EVENT。这三者分别位于下列位置。

```
General setup->
[*]Kprobes
Kernel hacking->
[*]Tracers->
[*]Enable kprobes-based dynamic events
```

启用这些选项构建内核，安装驱动程序模块和主体（body）。但是，安装了内核后，请注意不要删除创建的目录下的vmlinux文件。vmlinux文件包含调试信息，而安装到/boot目录等的vmlinuz的调试信息已删除。perf probe会从创建目录搜索vmlinux，以便读出调试信息，因此，如果这个文件被删除就会运行失败。另外，即使构建了新的内核，也不能改写或删除内核源代码。调试信息只包含创建时的源代码，因此，一旦源代码更改就会产生不一致。

包括perf probe在内的perf tools虽然在内核的源代码中也是存在的，但创建时需要与内核分开进行。perf tools的创建方法请参考Hack#64。

下面尝试使用新的内核运行perf probe。

perf probe的使用方法

perf probe具有多个运行选项。这里将按照实际添加追踪事件、使用并删除的步骤来介绍该命令的使用方法。

首先，需要确认用来定义追踪事件的源代码。perf probe具有显示源代码以及显示源代码的哪一行可以插入事件的功能。

```
[～]#perf probe--line vfs_symlink
＜vfs_symlink：0＞
0 int vfs_symlink（struct inode*dir, struct dentry*dentry，
const char*oldname）
1{
2 int error=may_create（dir, dentry）；
4 if（error）
return error；
7 if（！dir-＞i_op-＞symlink）
8 return-EPERM；
10 error=security_inode_symlink（dir, dentry, oldname）；
11 if（error）
return error；
14 error=dir-＞i_op-＞symlink（dir, dentry, oldname）；
15 if（！error）
16 fsnotify_create（dir, dentry）；
return error；
18}
SYSCALL_DEFINE3（symlinkat, const char__user*，oldname，
int, newdfd, const char__user*，newname）
```

根据不同的内核构建环境和perf tools的版本（即内核版本），有时会出现找不到源代码路径的错误。这时应当先移动到内核源代码解压缩到的目录再尝试执行。

通过perf probe的--line选项可以知道指定为参数的函数和文件的源代码，以及是否能向各自的行添加事件。从输出结果可以看出，有些行的最前面有编号，有些行没有编号。前面有编号的行可以添加追踪事件。在C语言中，空行等无意义的行在编译时会消失，因此不能向这些地方添加追踪事件。调试信息记录了与进行相关处理的行相对应的地址，因此perf probe可以对其进行分析并找出可以指定的行。

另外，从perf probe的--var选项可以看出指定为参数的行可以访问哪个变量。使用编译器的优化选项时，有的变量一旦进行优化就会消失，需要事先调查出可以访问的变量。下面实际列举的是从vfs_symlink的第4行可以访问的变量。

```
[～]#perf probe--vars vfs_symlink：4
Available variables at vfs_symlink：4
@＜vfs_symlink+36＞
char*oldname
int error
struct dentry*dentry
struct inode*dir
```

根据这个结果，可以看出能够访问oldname、error、dentry、dir这4个局部变量。如果加上--var选项的附加选项--externs，则除了上述局部变量以外，还会列举出全局变量。

实际定义追踪事件的是perf probe--add。perf probe--add指定追踪事件定义位置的格式如下。

·根据函数名定义时：

[事件名=]函数[@文件][：从函数开头的行数|+偏移量|%return|；模式]·根据文件名和行数或模式定义时：

[事件名=]文件[：从文件开头的行数|；模式]

文件名是基于绝对路径的，但不需要写出实际文件的所有绝对路径。perf probe只会检查文件名的末尾是否一致，因此，例如，当绝对路径为/usr/src/linux-2.6/kernel/timer.c时，只需要写出linux-2.6/kernel/timer.c就足够了。格式中的“模式”是在选择符合条件的多个行时使用的一种glob描述匹配。例如，schedule；cpu=[！=]*显示的是schedule（）函数中向变量cpu赋值的行。

在下例中，vfs_symlink的第4行定义了记录dentry结构的d_name.name、oldname、error各自值的事件。另外，为了提高事件的可读性，将dentry-＞d_name.name和oldname设置为以string类型记录。

```
[～]#perf probe--add'vfs_symlink：4 dentry-＞d_name.name：string oldname：string error'
Add new event：
probe：vfs_symlink（on vfs_symlink：4 with name=dentry-＞d_name.name：string
oldname：string error）
You can now use it on all perf tools, such as：
perf record-e probe：vfs_symlink-aR sleep 1
```

当前已定义的动态追踪事件列表可以通过perf probe--list看到。

```
#perf probe--list
probe：vfs_symlink（on vfs_symlink：4@fs/namei.c with name oldname_string error）
```

可以看出，使用perf probe--list可以看到该事件定义在哪个文件的哪一行（这个例中为fs/namei.c的vfs_symlink（）函数的第4行）。

下面，使用Hack#69介绍的方法来尝试获取追踪。

```
[～]#cd/sys/kernel/debug/tracing
[tracing]#echo probe：vfs_symlink＞set_event
[tracing]#ln-s/tmp/hoge/tmp/huga
[tracing]#head trace
#tracer：nop
#
#TASK-PID CPU#TIMESTAMP FUNCTION
#|||||
ln-2439[001]9061.438993：vfs_symlink：（vfs_symlink+0x24/0x78）
name="huga"oldname_string="/tmp/hoge"error=0
```

可以看出，记录了已执行的ln的变量等。

小结

本节介绍了使用ftrace及perf probe定义动态追踪事件的方法。通过使用动态追踪事件，可以在不停止正在运行的内核的情况下，轻松确认内核内部的详细运行。例如，可以对由于变量的值而导致处理速度不同，成为瓶颈的函数进行概要分析。

参考文献

·Documentation/trace/kprobetrace. txt

·tools/perf/Documentation/perf-probe. txt

——Masami Hiramatsu

HACK#72　使用SystemTap进行内核追踪

本节以进行定时（timing）的样本为例介绍SystemTap的使用方法。

概述

SystemTap是使用kprobes生成的工具。使用类似于AWK和C语言的特有脚本语言生成probe处理程序。将使用脚本写出的probe处理程序由专用解析器（parser）转换为C语言，自动生成内核模块。SystemTap可以对生成的代码进行安全检测，为称为tapset的库脚本提供便利的函数，可以提供比手写内核模块更为方便的环境。

为了加强自动生成的模块的安全性，除了生成代码时的安全性检测以外，生成的代码还包括执行过程中的循环次数和函数嵌套次数检测、处理的系统开销限制等的严格检测代码。极力缩小这样编写出的代码失控的可能性。

准备

使用SystemTap，必须要有带调试信息编译的内核。另外，stap命令会自动创建内核模块，因此还需要安装内核头文件等。本节使用Fedora 14。使用的内核版本为2.6.35.12-90.fc14，SystemTap的版本为1.4-2.fc14。Fedora 14使用下列命令安装必要的工具包。

```
#yum install systemtap yum-utils
#debuginfo-install kernel
```

另外，要检查函数内部的源代码时，导入内核的源代码比较方便，但是需要进行一些准备工作。准备工作的步骤包括：安装rpmbuild数据包，安装内核的SPRM（source rpm），指定kernel.spec文件，使用rpmbuild生成可编译的内核源码树，如下所示。

```
#yum install rpmbuild
#yumdownloader--source kernel-2.6.35.12-90.fc14
#rpm-i kernel-2.6.35.12-90.fc14.src.rpm
#rpmbuild-bp～/rpmbuild/SPECS/kernel.spec
```

这样就会在～/rpmbuild/BUILD/kernel-2.6.35.fc14/linux-2.6.35.i686/下解压缩源代码。（在RHEL、CentOS和之前的Fedora中，情况有所不同，安装SRPM后将解压缩到/usr/src/redhat下，而不是～/rmpbuild）。

样本脚本

这里使用的是如下所示的脚本。这是在SystemTap中附属的sleeptime.stp样本脚本的基础上进行了一些修改而生成的。是用来测量在nanosleeptest程序中nanosleep（）系统调用实际休眠了多少时间的脚本。

```
#！/usr/bin/stap-v
/*
*Format is：
*TIMESTAMP PID（EXECNAME）MESSAGE
*/
global start
global entry_nanosleep
global entry_nanosleep_restart
function timestamp：long（）{
return gettimeofday_us（）-start
}
function proc：string（）{
return sprintf（"%d（%s）"，pid（），execname（））
}
probe begin{
start=gettimeofday_us（）
}
probe syscall.nanosleep{
if（execname（）！="nanosleeptest"）next；
t=gettimeofday_us（）；p=pid（）
entry_nanosleep[p]=t
}
probe syscall.nanosleep.return{
if（execname（）！="nanosleeptest"）next；
t=gettimeofday_us（）；p=pid（）
elapsed_time=t-entry_nanosleep[p]
printf（"%d%s nanosleep：%d\n"，timestamp（），proc（），elapsed_time）
delete entry_nanosleep[p]
}
probe kernel.statement（"hrtimer_nanosleep@kernel/hrtimer.c：1599"）{
if（execname（）！="nanosleeptest"）next；
printf（"%d%s nanosleep is interrupted.\n"，timestamp（），proc（））；
p=pid（）；
entry_nanosleep_restart[p]=entry_nanosleep[p]；
}
probe kernel.function（"hrtimer_nanosleep_restart"）.return{
if（execname（）！="nanosleeptest"）next；
t=gettimeofday_us（）；p=pid（）
elapsed_time=t-entry_nanosleep_restart[p]
printf（"%d%s nanosleep_restart：%d\n"，timestamp（），proc（），elapsed_time）
delete entry_nanosleep_restart[p]；
}
```

追踪对象程序使用的是如下所示的nanosleeptest.c。

```
#include＜time.h＞
int main（int argc, char*argv[]）
{
struct timespec ts={0，0}；
if（argc！=2）
return 0；
ts.tv_sec=strtol（argv[1]，NULL，0）；
return nanosleep（＆ts, NULL）；
}
```

测量时间

使用SystemTap进行追踪可以很方便地测量出某个进程所需的时间。但是需要注意的是，不适合用于几微秒以下的时间测量。这是因为，虽然由于脚本的制作和机器的性能而有所不同，但SystemTap自身系统开销的影响是不能忽视的。

在内核内部的处理中，有很多是将非同步的事件作为触发器来推进处理。本节提到的nanosleep（）是将计时器的中断事件等作为触发器从休眠状态恢复。这个计时器的中断事件是非同步的事件，这个时刻会受到系统负载情况的影响。另外，将执行了nanosleep（）的进程从休眠状态唤醒，重新进行调度也需要花费时间。这样，进程一般就会在比所要求的休眠时间稍晚的时刻从nanosleep（）系统调用恢复。本次测量的就是实际休眠的时间。

为了测量实际的休眠时间，将执行了nanosleep（）后的时刻和从nanosleep（）恢复的时刻的差作为时间差显示。测量的时刻是使用SystemTap提供的gettimeofday_us（），以微秒为单位获取当前时刻。

定义探测点

插入probe的位置称为探测点（probe point）。探测点的定义方法有很多种，这里介绍其中一些经常使用的定义方法。

```
probe begin
probe end
```

定义脚本启动时、结束时运行的处理程序。它可以用于脚本内的全局变量的初始化，以及显示结束时收集的日志的情况等。

```
probe kernel.function（"函数名"）
probe kernel.function（"函数名"）.return
```

分别在定义“函数名”所指定的内核函数在调用时、返回时在执行的probe时使用。“函数名”对应的部分也可以使用通配符（*）。

```
probe kernel.function（"*init*"）
probe kernel.function（"*init*@kernel/sched.c"）
```

在第一个示例中，是向所有内核的初始化函数插入probe。在第二个示例中，是向所有定义在kernel/sched.c中的初始化函数插入probe。像这样，也可以通过在函数名后指定文件名来限制对象范围。当不同文件中存在相同名称的函数时，可以使用这个描述限定一个对象函数。另外，在文件名部分也可以使用通配符。

在内核模块中定义probe时描述如下。

```
probe module（"模块名"）.function（"函数名"）
probe module（"模块名"）.funciton（"函数名"）.return
```

只需要将之前写作kernel的地方改写成module（"模块名"），其他代码完全相同。

```
probe syscall.系统调用名
probe syscall.系统调用名.return
```

这是probe对象作为系统调用时的描述方法。这些是使用别名（alias）功能，对前面所述的kernel.function（）进行绑定（wrapping）。在系统调用的情况下，建议使用这个描述方法。

```
probe kernel.statement（"函数名@文件名：行编号"）
probe kernel.statement（地址）
```

这些用于在函数行中插入probe的情况。例如，可以在仅想调试满足函数内if语句的条件的情况时使用。当然，如果在对内核源代码进行了修改、行编号改变的情况下使用，就会出现偏差，因此要注意每次都要确认源代码。这是因为由stap命令从内核的调试信息推测出与行编号对应的地址，决定probe位置。至于地址的指定，由于在每次改变内核的条件进行创建时都会变化，因此需要经常对内核二进制映像文件进行反汇编，找出正确的位置。

同样，以内核模块为对象的描述如下。

```
probe module（"模块名"）.statement（"函数名@文件名：行编号"）
probe module（"模块名"）.statement（地址）
```

在本节的示例中使用这个描述，向nanosleep（）在信号中断时运行的代码中插入probe。probe kernel.statement（"hrtimer_nanosleep@kernel/hrtimer.c：1599"）

这样就可以引用已插入probe的部分的内核源代码。使用这样的方法，还可以生成用来判断函数内if语句的判断结果是真还是假的脚本。

```
[kernel/hrtimer.c]
1570 long hrtimer_nanosleep（struct timespec*rqtp, struct timespec__user
*rmtp，
1571 const enum hrtimer_mode mode, const clockid_t
clockid）
1572{
……
/*如果插入信号中，则该if语句为假*/
1584 if（do_nanosleep（＆t, mode））
```

```
1585 goto out；
……
1599 restart=＆current_thread_info（）-＞restart_block；
1600 restart-＞fn=hrtimer_nanosleep_restart；
1601 restart-＞nanosleep.index=t.timer.base-＞index；
1602 restart-＞nanosleep.rmtp=rmtp；
1603 restart-＞nanosleep.expires=hrtimer_get_expires_tv64（＆t.timer）；
1604
1605 ret=-ERESTART_RESTARTBLOCK；
1606 out：
1607 destroy_hrtimer_on_stack（＆t.timer）；
……
```

如果只是这样在检测点上记录处理方式，就会追踪系统上运行的所有nanosleep（），甚至不需要追踪的命令的运行情况也会被追踪。本次只想以nanosleeptest程序的运行为对象，因此需要进行下列过滤。

```
if（execname（）！="nanosleeptest"）next；
```

execname（）函数会返回当前进程的执行命令名称，因此，如果不是nanosleeptest，就会执行next跳过剩下的处理。

尝试执行

执行脚本的命令为stap。默认只显示脚本的执行结果，因此不知道脚本的生成和编译是何时进行的。要得知脚本的执行是何时开始的，需要尽量添加verbose选项（-v）并执行命令。

```
#stap-v sleeptime.stp
Pass 1：parsed user script and 76 library script（s）using 22624virt/13468res/2432shr kb, in 350usr/40sys/409real ms.
Pass 2：analyzed script：5 probe（s），7 function（s），23 embed（s），3 global（s）using 209844virt/58080res/3404shr kb, in 1650usr/1640sys/4818real ms.
Pass 3：translated to C into"/tmp/stapX8Wjed/stap_cf3acae223ba1d1359216122bbc07 f5e_15503.c"using 209564virt/61080res/6520shr kb, in 1340usr/40sys/1418real ms.Pass 4：compiled C into"stap_cf3acae223ba1d1359216122bbc07f5e_15503.ko"in 4380usr/740sys/5823real ms.
Pass 5：starting run.
```

如果显示上述信息，则表示probe已启用。从其他终端使用测试账号执行nanosleep（），休眠10秒钟。

```
$nanosleeptest 10
```

这样就会在执行了stap命令的终端上显示下列信息。

```
51245488 1296（nanosleeptest）nanosleep：10000180
```

信息显示格式如下。显示的时间差都是以微秒为单位。

```
从启用probe开始的时间差PID（命令名称）nanosleep：实际经过时间
```

可能是因为本次是在虚拟环境下运行的，所以可以看出延迟达到180微秒。

接下来确认在刻意使用信号中断时是怎样的情况。与之前一样使用nanosleeptest程序休眠10秒钟。但是，中途发送SIGSTOP，中断nanosleep（），这样等待大约10多秒再发送SIGCONT信号。

```
79008508 3016（nanosleeptest）nanosleep is interrupted.
79008521 3016（nanosleeptest）nanosleep：5943297
85588697 3016（nanosleeptest）nanosleep_restart：12523472
```

输出了表示nanosleep（）已中断的信息。从第2个信息可以看出，执行nanosleep（）后约5.9秒后接收了SIGSTOP信号。从第3个信息可以看出，重新开始执行的nanosleeptest从nanosleep（）恢复花费了约12.5秒。

确认完成后，可以按Ctrl+C快捷键结束SystemTap。SystemTap在结束时会自动将追踪用的内核模块从内核中移除。

小结

本节以测量nanosleep（）系统调用实际经过时间为例，介绍了SystemTap的使用方法。由于SystemTap使用的是kprobes，因此kprobes可以完成的工作基本上在SystemTap中也可以实现。

参考

除了man页面以外，还可以参考SystemTap附带的样本脚本和tapset。项目的网页上也有TUTORIAL等很多文档类。

·SystemTap附带的样本脚本

/usr/share/doc/SystemTap-version/examples/

·SystemTap附带的tapset

/usr/share/SystemTap/tapset/

·SystemTap项目网页

http://sourceware. org/SystemTap/documentation.html

——Masami Hiramatsu

HACK#73　使用SystemTap编写对话型程序

本节使用SystemTap在内核中执行交互式（interactive）程序。

虽然在执行时有一些制约，但SystemTap还是可以作为一种脚本语言来处理。既可以向控制台输出，也可以调用外部程序。另外，还可以追踪Linux内核上获取的信息，因此也可以得到键盘输入或鼠标输入的情况。也可以编写内核计时器的处理程序，因此可以每隔一定时间更新状态。但是反过来说，复杂且花费时间的处理就会长时间停止内核自身的处理，因此不适合使用SystemTap。

也就是说，SystemTap是适用于编写游戏等对话型程序的语言。特别是，计时器周边的处理不会发生延迟，因此如果无视禁止硬件中断的影响，就可以进行最快的周期处理。本节将介绍怎样使用SystemTap接受用户的输入，怎样进行简单的界面控制。

使用SystemTap进行输出界面控制

SystemTap的输出为控制台。要对控制台进行控制，使用ANSI转义序列（escape sequence）是最简单的。SystemTap为此准备了库函数（见表8-14）。

表 8-14　SystemTap 的库函数

函　数	说　明
ansi_clear_screen()	清除控制台界面
ansi_set_color(fg)	指定文字颜色
ansi_set_color2(fg,bg)	指定文字颜色和背景颜色
ansi_set_color3(fg,bg,attr)	指定文字颜色、背景颜色和颜色属性
ansi_reset_color()	将文字颜色恢复到默认状态

（续）

函　数	说　明
ansi_cursor_move(x,y)	将光标（下一个输出文字的位置）移动到任意位置。x 为横向，y 为纵向。(1,1) 为控制台画面左上角的坐标
ansi_cursor_hide()	隐藏光标
ansi_cursor_show()	将光标设置为可见
ansi_cursor_save()	保存光标的位置
ansi_cursor_restore()	将光标的位置返回最后保存的位置

熟练使用ansi_clear_screen和ansi_cursor_move，就可以每隔一定时间更改控制台界面，或者在任意位置写入任意文字。例如，执行下列脚本，就可以在看到“@”在界面上斜着运动。

```
global x=40，y=1；
probe timer.ms（100）{
ansi_clear_screen（）
ansi_cursor_move（x--，y++/2）
print（"@"）
if（x==0）
exit（）
}
```

像这样重复地使计时器失效，每隔一定时间刷新界面，并绘制新状态，就可以在界面上自由显示文字。

使用SystemTap接受来自键盘、鼠标的输入

Linux内核先使用input_event接受外部的输入，再传送到适当的子系统（subsystem）。这个事件包括键盘或鼠标的事件，因此通过检测input_event函数，就可以获取用户的键盘输入或鼠标输入。

```
void input_event（struct input_dev*dev，
unsigned int type, unsigned int code, int value）
```

如上所示，input_event函数可以接受对于设备的type、code、value输入。type表示设备种类，例如，1为键盘，2为鼠标（或相对坐标定点设备），3为触摸屏（或绝对坐标定点设备）。需要注意的是，便携式电脑的触摸板中1、2、3都存在。

另外，在鼠标的事件中按钮（button）操作的type也是1。这些组合的详细情况请参考Linux内核的头文件include/linux/input.h。

键盘输入

value为0表示键盘的键未按下，value非0则表示键按下。code中将出现按下的键的代码，因此可以通过这个组合来判断键盘的输入。当code小于256时，就表示键盘的事件。通过使用下列脚本，就可以确认键盘的输入代码。

```
probe kernel.function（"input_event"）{
if（$type！=1||$code＞=256）
next；
printf（"Keyboard：%d%s\n"，$code，$value?"Down"："Up"）；
}
```

表8-15为笔者的环境中经常使用的键的代码对应表。

表 8-15　使用频率较高的键的代码对应表

键	代码	键	代码
↑	103	Enter	28
↓	108	ESC	1
←	105	z	44
→	106	x	45
Space	57	c	46

那么使用键盘在界面上移动@的kbd_cursor.stp就如下所示。

```
global x=20，y=20
probe kernel.function（"input_event"）{
if（$type！=1||$code＞=256||$value！=1）
next
if（$code==103）
y--
else if（$code==108）
y++
else if（$code==105）
x--
else if（$code==106）
x++
}
probe timer.ms（100）{
if（x＜=0）
x=1
else if（x＞=41）
x=40
if（y＜=0）
y=1
else if（y＞=41）
y=40
ansi_clear_screen（）
ansi_cursor_move（x, y）
print（"@"）
}
```

鼠标输入

鼠标输入比键盘输入复杂。这是因为定点设备有小红帽（trackpoint）和触摸板、触摸屏等多种形式。本节将介绍一般鼠标（相对移动距离设备）、在笔者的环境下测试的触摸板（绝对坐标设备）。对于这些定点设备，都可以使用下列方法来确认设备的输入。

```
#stap-e'probe kernel.function（"input_event"）{println（$$parms）}'
```

让$$parms作为检测函数的参数，由此来获得系统的信息，并作为字符串传递给用户。执行这个脚本并操作鼠标等，就可以看出传送了什么样的事件。

一般的鼠标通过下列组合传送相对移动距离（见表8-16）。

表 8-16　一般鼠标的相对移动距离

类　型	代　码	说　明
2	0	x 移动距离
2	1	y 移动距离
2	8	z 移动距离（即所谓的滚轮）
1	0x110	是否按下左键（1：按下，0：松开）
1	0x111	是否按下右键（1：按下，0：松开）
1	0x112	是否按下中键（1：按下，0：松开）

在笔者的环境下，触摸板（Synaptics）是返回绝对坐标的设备。可以得知从这个设备发送的有下表所示的信号（见表8-17）。

表 8-17　触摸板的信号

类　型	代　码	说　明
3	0	x 位置坐标＋偏移量
3	1	y 位置坐标＋偏移量
1	0x145	是否碰下触摸板（1：碰下，0：松开）
1	0x110	是否按下左键（1：按下，0：松开）
1	0x111	是否按下右键（1：按下，0：松开）

但是，是否已按下按钮的信息容易造成连击（连续进入信号），因此处理时需要注意。另外，每个设备的位置信息的偏移量都是不同的，因此处理时也需要注意。

如何让绝对坐标和相对坐标进行相同的处理呢？最基本的方法是将所有的输入统一为绝对坐标或相对坐标进行处理。下面是如前面一样通过鼠标移动“@”的脚本。

```
global mpos_x=0，mpos_y=0
global x=20，y=20
#Mouse Button hooking
probe kernel.function（"input_event"）{
rx=0；ry=0
if（$type==2）{#Relative position
if（$code==0）
rx=$value
else if（$code==1）
ry=$value
}else if（$type==1＆＆$code==0x145＆＆$value==0）{
#Take a finger--Reset position
mpos_x=0；mpos_y=0
}else if（$type==3）{#Absolute-check slide
if（$code==0）{
if（mpos_x！=0）
rx=$value-mpos_x
mpos_x=$value；
}else if（$code==1）{
if（mpos_y！=0）
```

```
ry=$value-mpos_y
mpos_y=$value；
}
}
if（rx==0＆＆ry==0）
next
x+=rx/10；y+=ry/10
}
probe timer.ms（100）{
if（x＜=0）
x=1
else if（x＞=41）
x=40
if（y＜=0）
y=1
else if（y＞=41）
y=40
ansi_clear_screen（）
ansi_cursor_move（x, y/2）
print（"@"）
}
```

可以看出，timer部分的处理程序与键盘的情况相同，而input_event的处理程序则出现了很大的不同。在这个示例中，为了与通过绝对坐标返回的触摸板相对应，将触摸板返回的坐标改为与上一次的坐标（mpos_x、mpos_y）的相对距离。另外，使用松开手指的事件来重置上次的坐标。从触摸板的使用方法来思考就可以理解，用触摸板来移动光标需要用手指反复滑动很多次。一次滑动操作结束，下一次滑动操作开始时，又会从几乎与上次一致的位置开始滑动。从上次松开手指的位置来看，这时的位置就相当于回到了滑动前的初始位置，这样就很不方便。

小结

本节介绍了使用SystemTap编写对话型程序所需的界面控制和键盘、鼠标输入。SystemTap可以使用脚本方便地捕捉内核事件，是非常适合进行交互式处理的语言。

参考文献

·StapGames（https：//github. com/mhiramat/stapgames）

——Masami Hiramatsu

HACK#74　SystemTap脚本的重复利用

本节使用SystemTap的别名和Tapset功能，重复使用脚本。

Hack#73介绍了捕捉键盘和鼠标的输入的方法。可以直接在这个脚本的基础上不断扩大规模，但是想要重复使用这段输入代码等时，必须多次复制相同的代码，或者必须将大量的代码耗费在不必要的输入处理上。这就使得脚本看起来很复杂。

SystemTap中准备了别名功能和Tapset库功能，各个开发人员就可以重点进行自己想进行的操作，并提高代码的使用性。这里首先介绍别名。

使用别名分离逻辑

别名是为了更方便地重复使用SystemTap的处理程序而设置的别名定义功能。SystemTap，如果只是重复使用部分代码，可以作为函数提取出来，但是处理程序本身就不能这样。这时就可以使用别名为处理程序的预处理部分加上易懂的名字。

别名的格式是probe格式的扩展。在probe后面写上别名，然后在“=”后面写上想要命名的处理程序。下面使用别名来编写用键盘和鼠标移动“@”的程序。

```
#Alias Part
probe input.move.keyboard=kernel.function（"input_event"）{
rx=0；ry=0
if（$type！=1||$code＞=256||$value！=1）
next
if（$code==103）
ry--
else if（$code==108）
ry++
else if（$code==105）
rx--
else if（$code==106）
rx++
}
global mpos_x=0，mpos_y=0
probe input.move.mouse=kernel.function（"input_event"）{
rx=0；ry=0
if（$type==2）{#Relative position
```

```
if（$code==0）
rx=$value
else if（$code==1）
ry=$value
}else if（$type==1＆＆$code==0x145＆＆$value==0）{
#Take a finger--Reset position
mpos_x=0；mpos_y=0
}else if（$type==3）{#Absolute-check slide
if（$code==0）{
if（mpos_x！=0）
rx=$value-mpos_x
mpos_x=$value；
}else if（$code==1）{
if（mpos_y！=0）
ry=$value-mpos_y
mpos_y=$value；
}
}
rx/=10；ry/=10；
}
probe input.move=input.move.*{
if（rx==0＆＆ry==0）
next
}
#Logic Part
global x=20，y=20
probe input.move{
x+=rx；y+=ry
}
probe timer.ms（100）{
if（x＜=0）
x=1
else if（x＞=41）
x=40
if（y＜=0）
y=1
else if（y＞=41）
y=40
ansi_clear_screen（）
ansi_cursor_move（x, y）
print（"@"）
}
```

可以向别名赋予以字母开头，包括字母、数字和“.”的名称。别名内的局部变量，在使用别名的一方也可以继续使用。另外，还可以将功能上相似的别名组合起来用在其他别名中。在上例中，是将input.move.keyboard和input.move.mouse组合起来作为input.move别名。如别名input.move的定义，指定别名时也可以使用通配符。

通过使用别名，将想做的事情（#Logic Part）简单地表现出来。

编写Tapset

即使改为别名或函数，但是每次都要复制相同代码，就会影响可维护性。如果作为库文件重复使用，就可以只将逻辑部分分离出来。Tapset的编写和使用都非常简单。将想要重复使用的脚本放到目录下，执行要用的脚本时只需要使用-I选项指定该目录。将前面的脚本分割为#Alias Part和#Logic Part，并分别放到input.stp和cursor.stp这两个脚本里，进行下列操作。

```
#ls
input.stp cursor.stp
#mkdir tapset
#mv input.stp tapset
#stap-I./tapset cursor.stp
```

SystemTap脚本的Shebang

执行SystemTap脚本时，最麻烦的就是参数。例如，要指定自己编写的Tapset路径来执行时，必须每次使用-I选项指定。有没有像shell脚本一样作为可执行文件处理的方法呢？shell文件的第一行总是以#！/bin/sh或#！/bin/bash开头。这个称为Shebang, Linux内核获得执行文件的开头，如果是以#！开头的，就会将这个文件作为参数传递给此后的可执行文件。最简单的SystemTap脚本的Shebang如下所示。

```
#！/usr/bin/stap
```

这里如果指定-I选项作为参数，则变为：

```
#！/usr/bin/stap-I tapset
```

但是这个方法主要存在移植性方面的两个问题。

·stap命令并不一定总是在/usr/bin下。

·Tapset的相对位置并不一定是相同目录。例如，想从上一个目录直接执行脚本时就会出错。

前一个问题一般使用/usr/bin/env命令来解决，但实际上将env命令作为Shebang使用时有一个很大的问题。

```
#！/usr/bin/env stap-I tapset
```

编写这样的Shebang时，-I tapset就会变成env命令的选项，而不是SystemTap的选项。这时可以借用shell脚本的Shebang，一并解决这两个问题。这里以上一节的cursor.stp为例。

```
#！/bin/sh
//usr/bin/env stap-I'dirname$0'/tapset$@$0；exit$?
global x=20，y=20
probe input.move{
x+=rx；y+=ry
}
probe timer.ms（100）{
if（x＜=0）
x=1
else if（x＞=41）
x=40
if（y＜=0）
y=1
else if（y＞=41）
y=40
ansi_clear_screen（）
ansi_cursor_move（x, y）
print（"@"）
}
```

SystemTap将以//开头的行作为注释处理。而shell只是把//识别为根目录，因此可以在其后自由编写shell脚本。在这个示例中是使用dirname命令，使用（由$0传递的）可执行文件的相对路径指定Tapset。另外，将执行时传递给脚本的参数传递给SystemTap。通过这样的处理，可以向SystemTap脚本传递默认参数，同时自由添加SystemTap的参数。

小结

本节介绍了提高SystemTap的脚本重复使用性的别名功能以及SystemTap的Shebang。通过使用这些功能，就可以提高SystemTap的脚本生成效率，使脚本更易执行。

——Masami Hiramatsu

HACK#75　运用SystemTap

本节介绍在实际系统上运用SystemTap的方法。

SystemTap是优秀的追踪工具。除了作为工具以外，作为服务也具有十分优秀的功能。具有作为服务启动的后台执行模式，也具有作为系统服务管理的接口。另外，在集群（cluster）环境想要重新分配相同脚本时，也可以分配已编译的脚本。

在后台执行SystemTap

下面将介绍SystemTap的后台执行模式。SystemTap的后台执行，有内存飞行记录器模式（on memory flight mode）和文件飞行记录器模式（on file flight mode）这两个模式。前者是将输出结果保存在内核内存上的模式，使用方法与不断提取最新记录的飞行记录器或行车记录器（drive flight）相同。后者是在后台将输出结果写出到磁盘上的模式，适用于长期提取记录的系统监测方法。

为了介绍这个功能，实际编写SystemTap的脚本syscalltop.stp，它按照系统调用的种类分别显示每5秒钟执行系统调用的次数。

```
global syscalls, stime;
probe syscall.*{
stime[name, tid（）]=gettimeofday_us（）；
}
probe syscall.*.return{
if（！ stime[name, tid（）]）
next;
syscalls[name]<<<（gettimeofday_us（）-stime[name, tid（）]）；
delete stime[name, tid（）];
}
probe timer.s（5）{
println（"<name>\t<count>\t<avgtime（us）>---"）；
foreach（name-in syscalls）{
printf（"%s\t%d\t%d\n"，name，
@count（syscalls[name]），@avg（syscalls[name]））；
}
delete syscalls
}
```

下面是使用这个脚本执行飞行记录器的例子。

首先尝试将输出结果保存在内存上的内存飞行记录器模式。使用这个模式时需要向stap命令传递-F选项来启动。启动时使用-m决定脚本模块名称，后面的控制就会比较容易。另外还可以使用-s（小写）选项指定保存日志的缓冲区容量。缓冲区容量在启动后就无法更改，因此必须在这时指定最适合的容量。

```
#stap syscalltop.stp-m syscalltop-F
Disconnecting from systemtap module.
To reconnect, type"staprun-A syscalltop"
#lsmod|head
Module Size Used by
syscalltop 800448 0
ip6table_filter 1759 0
ip6_tables 19857 1 ip6table_filter
ipt_MASQUERADE 1927 3
iptable_nat 4430 1
nf_nat 18833 2 ipt_MASQUERADE, iptable_nat
nf_conntrack_ipv4 13057 4 iptable_nat, nf_nat
nf_defrag_ipv4 1609 1 nf_conntrack_ipv4
xt_state 1394 1
```

在内存飞行记录器模式下运行时，就会返回如上所示的提示（prompt）。但是从lsmod的结果可以看出，从syscalltop脚本生成的脚本模块在内核中不断运行。要确认syscalltop.stp的输出结果时，如界面输出所示执行staprun-A syscalltop。

```
#staprun-A syscalltop
＜name＞＜count＞＜avgtime（us）＞---
writev 5 7
write 11 16
wait4 2 6990840
tgkill 5 5
stat 1 722
setitimer 4 3
select 12 3295040
rt_sigtimedwait 2 6988895
……
```

即使不指定-F选项，在运行中也可以按下Ctrl+\或向stapio进程发送SIGQUIT信号，同样切换到内存飞行记录器模式。

接下来尝试将输出结果写出到文件的文件飞行记录器模式。这个模式与刚才的模式同

样可以使用-F选项，再指定-o选项，指定写出到的文件。这样的话文件的大小就会逐渐变大，对磁盘容量造成压力，因此可以使用-S选项来避免。-S选项可以指定文件的最大大小和最大文件数量。写出到的文件容量一旦超过-S选项指定的量，SystemTap就会打开另一个文件，并开始在这个文件中写出。这样不断增加的文件数量一旦超过-S选项指定的最大数量，就会从最旧的文件开始删除。

进行这样的后台执行时，为了减少运行时的系统开销，可以启用-b选项并启用bulk模式。启用bulk模式后，SystemTap就会在每个CPU上分配缓冲区，并记录追踪信息。向文件写出时，也会在每个CPU上创建线程，向其他文件写出。这样就可以防止数据记录时的竞争，因此系统开销就会减小。

-o选项可以向输出文件的名称指定strftime（）函数形式的格式。在下例中，将前面所述的syscalltop脚本在文件飞行记录器模式下启动，并将追踪日志输出到名称为tracelog-年-月-日-时：分：秒.log的文件。另外，输出文件的最大大小设置为256MB，只留下最新的两个日志。

```
#stap syscalltop.stp-m syscalltop-F-o tracelog-%F-%T.log-S 256，2
2565
#ps aux|grep 2565
root 2565 0.2 0.0 47244 596?Ssl 16：33 0：00/usr/
lib/systemtap/stapio-o syscalltop-%F-%T.log-D-S 256，2/tmp/stapSyNXqX/
syscalltop.ko
……
#ls tracelog*
tracelog-2011-04-17-16：33：14.log.0
```

在文件飞行记录器模式下启动stap命令时，会在命令结束前显示一直在后台运行的进程的PID。通过向这个PID发送信号，进行后台进程的控制。例如，如果发送SIGUSR2信号，就会切换正在写出的文件（参考下例），发送SIGQUIT信号就可以从文件飞行记录器模式转换到内存飞行记录器模式。想要结束运行时可以发送SIGTERM信号。

```
#ls tracelog*
tracelog-2011-04-17-16：33：14.log.0
#kill-USR2 2565
#ls syscalltop*
tracelog-2011-04-17-16：33：14.log.0
```

将SystemTap作为服务启动

将SystemTap添加到initscript中，就可以作为服务启动。这样除了可以集中操作用户生成的脚本以外，还可以根据内核版本的升级重新编写脚本。这个结构可以同时控制多个脚本。例如，系统设计时准备了很多不同作用的脚本，管理人员可以根据各个服务器的运用情况仅启用有效的脚本，或者复制到各服务器中。

SystemTap服务的设置

要使用文件SystemTap服务，首先需要安装systemtap-initscript工具包。Debian系列的发布版中也可能没有工具包，因此需要注意。

首先将SystemTap脚本复制到指定的目录（/etc/systemtap/script.d/）。这样就可以在内存飞行记录器模式下运行。要扩大脚本执行时的缓冲区大小，或者要在文件飞行记录器模式下运行时，必须对配置文件进行一些修改。如表8-18和表8-19所示，配置文件中有全局配置文件、脚本或脚本组用配置文件。前者生成的名称为/etc/systemtap/config，后者针对每个脚本生成/etc/systemtap/conf.d/*.config。

表 8-18　全局设置文件的参数（圆括号内为默认值）

参　数	说　明
SCRIPT_PATH	参照脚本文件的路径（/etc/systemtap/script.d）
CONFIG_PATH	参照配置文件的路径（/etc/systemtap/conf.d）
CACHE_PATH	保存缓存的路径（/var/cache/systemtap）
TEMP_PATH	工作目录的路径（/tmp）
STAT_PATH	保存运行状态的路径（/var/run/systemtap）
LOG_FILE	记录运行日志的位置（/var/log/systemtap.log）
PASSALL	脚本没有全部启动成功则不显示为 PASS（yes）
RECURSIVE	考虑脚本之间的依存关系执行脚本（no）
AUTOCOMPILE	检测到内核版本升级等时，自动重新编译（yes）
DEFAULT-START	未指定脚本时，自动执行的脚本。如果没有指定，则执行所有的脚本（""）
ALLOW-CACHEONLY	即使只有已编译的缓存也执行。一般没有脚本时，忽视缓存（no）

表 8-19　脚本配置文件的参数

参　数	说　明
<脚本名称>_OPT	向通过<脚本名称>指定的脚本赋予的选项。忽视一些选项。另外，自动添加“-m<脚本名称>-F”的选项
<脚本名称>_REQ	指定通过<脚本名称>指定的脚本所依存的脚本

下例显示了按照与上一节中文件飞行记录器模式的例子相同的设置登录syscalltop.stp的方法。

```
#cp syscalltop.stp/etc/systemtap/script.d/
#echo syscalltop_OPT=\"-o/var/log/tracelog-%F-%T.log-S 256，2\"＞/etc/systemtap/conf.d/syscalltap.conf
```

在文件飞行记录器模式下运行时，必须如上例所示使用绝对路径指定文件的输出位置。

脚本的启动与结束

systemtap-initscript包含/etc/init.d/systemtap。这个shell脚本与/etc/init.d中的其他脚本同样可以直接使用或通过service命令使用。

```
#service systemtap start
Compiling systemtap scripts：syscalltop[OK]
#service systemtap status
syscalltop（4956）is running……
```

此外，还可以像下面这样以脚本为单位进行操作。

```
#service systemtap start syscalltop
```

要结束服务，需要像其他服务一样添加stop选项执行脚本。

```
#service systemtap stop
```

另外，还可以使用chkconfig等，在启动时自动执行脚本。

```
#chkconfg systemtap on
```

SystemTap服务的初次运行需要花费一些时间。这是因为在初次运行时要编译脚本。但是，从下一次执行时开始就会跳过脚本的编译，执行速度就得到提高。也可以事先进行编译。例如，安装新脚本或者更新内核时，如果事先编译脚本，就可以避免重新启动后服

务的启动时间变慢。例如，下面就是对内核2.6.38进行脚本编译的示例。

```
#service systemtap compile-r 2.6.38
```

分配已编译的脚本模块

大规模的集群系统或为了负载均衡需运用多个服务器时，有时会对所有服务器进行相同的追踪。将脚本复制到systemtap-initscript的目录下，就可以在各个服务器上编译并执行脚本，但是要编译SystemTap的脚本，就必须要有内核驱动程序的编译环境、内核的调试信息等。这些的负载和磁盘容量也不能忽视，因此如果要创建相同的东西，最好尽量集中进行。

使用systemtap-initscript的CACHEONLY选项，就可以满足这些要求。在各客户端上安装systemtap-initscript，并在/ect/systemtap/config中添加下列两行。

AUTOCOMPILE=no

ALLOW_CACHEONLY=yes

在客户端上不进行隐式的编译，且存在已编译的脚本的缓存时就会执行。

在服务器上，将想要分配的脚本安装在/etc/systemtap/script.d/下，在为各个脚本编写配置文件后，使用/ect/init.d/systemtap compile进行编译。

```
#cp syscalltop.stp/etc/systemtap/script.d/
#echo syscalltop_OPT=\"-o/var/log/tracelog-%F-%T.log-S 256，2\"＞/etc/
systemtap/conf.d/syscalltap.conf
#service systemtap compile-r 2.6.38
Compiling systemtap scripts：Compiling syscalltop……done
[OK]
#ls/var/cache/systemtap/2.6.38/
syscalltop.ko syscalltop.opts
```

编译成功后，在/var/cache/systemtap/＜内核版本＞/下，生成了已编译的脚本模块和运行该脚本模块所需的选项文件。通过网络将这些文件分配到客户端。

```
#tar czPf cache-syscalltop-2.6.38.tar.gz\
/var/cache/systemtap/2.6.38/syscalltop.*/etc/systemtap/conf.d/syscalltop.conf
#scp cache-syscalltop-2.6.38.tar.gz stap-client：～/
```

在客户端上，将通过下列方式将传递的文件解压缩到与已编译的服务器相同的位置，并安装完成。

```
#tar xzf cache-syscalltop-2.6.38.tar.gz-C/
```

安装后可以按照下列方式运行并测试。

```
#service systemtap start
Starting systemtap：Warning：no script file（/etc/systemtap/script.d/syscalltop.stp）.Use compiled cache.
Starting syscalltop……done
[OK]
#service systemtap status
syscalltop（1654）is running……
```

这样可以看出，可以使用已编写的缓存在客户端上执行追踪。如果将分配已编译脚本的工具包作为RPM包或deb包，保持其与内核的依存关系，使用数据包管理工具，管理起来就更加轻松。

小结

本节介绍了实际在服务器运用环境中使用SystemTap的各种结构。通过使用这些结构，不仅能够简便地将SystemTap用于调试，还可以用来获取故障信息等。

参考资料

·/usr/share/doc/systemtap-initscript*/README. systemtap

——Masami Hiramatsu