

Linux 下系统调用原理解析及增加系统调用的方法

The principle of system call and the method of add new system call

胡盼盼 (华中科技大学计算机学院 湖北武汉 430074)

摘要: 系统调用是应用程序和操作系统之间进行交互的接口。程序的运行离不开系统调用。本文讨论了 Linux 下系统调用的实现机理, 并以一个简单的例子说明了在 Linux 下增加系统调用的实现方法, 本文的讨论基于 Linux 2.4 内核版本。

关键词: Linux 系统调用

1 Linux 系统调用概述

系统调用是内核提供的, 功能十分强大的一系列函数。这些函数在 Linux 的内核中实现, 用来完成一些系统级的功能。通过一定的方式呈现给用户, 是用户程序与内核交互的一个接口, 在用户程序每调用一次系统调用函数, 都将进行一次用户空间到内核空间的转换。如 Linux 中常用的 open, read 等函数, 都属于系统调用。

在 Linux 系统中, 系统调用是作为一种异常类型实现的, 它将执行相应的机器代码指令来产生异常信号。在执行系统调用异常指令时, 自动地将系统切换为核心态(模式切换, mode switch), 并安排异常处理程序的执行。用户态的程序只有通过门(gate)陷入(trap)到系统内核中去(执行 int 指令), 才能执行一些具有特权的内核函数。系统调用完成后, 系统执行另一组特征指令(iret 指令)将系统返回到用户态, 控制权返回给进程。Linux 用来实现系统调用异常的实际指令是: int \$0x80, 这一指令使用中断/异常向量号 128(即 16 进制的 80)将控制权转移给内核(进行模式切换)。为达到在使用系统调用时不必用机器指令编程, 在标准的 C 语言库中为每一系统调用提供了一段短的子程序, 完成机器代码的编程工作。这段子程序所要做的工作只是将送给系统调用的参数加载到 CPU 寄存器中, 接着执行 int \$0x80 指令。然后运行系统调用, 系统调用的返回值将送入 CPU 的一个寄存器中, 标准的库子程序取得这一返回值, 并将它送回用户程序。

2 Linux 系统调用结构分析

2.1 部分重要的宏的说明

我们以 Linux2.4 内核为例, 跟系统调用相关的内核代码主要有:

- /usr/src/linux-2.4/arch/i386/kernel/entry.S
- /usr/src/linux-2.4/arch/i386/kernel/trap.c
- /usr/src/linux-2.4/arch/i386/kernel/unistd.h

h

这三个内核文件中定义了系统调用所需的一些信息。下面将说明这些代码文件中与系统调用相关的一些重要的宏定义, 便于后面对系统调用过程的说明。
SAVE_ALL

SAVE_ALL 宏定义在 entry.S 中, 代码如下:

```
#define SAVE_ALL \
    cld; \
    pushl %es; \
    pushl %ds; \
    pushl %eax; \
    pushl %ebp; \
    pushl %edi; \
    pushl %esi; \
    pushl %edx; \
    pushl %ecx; \
    pushl %ebx; \
    movl $__KERNEL_DS,%edx; \
    movl %edx,%ds;
```

```
movl %edx,%es;
```

我们可以看到 SAVE_ALL 宏主要是保存寄存器信息,即进行现场保留。

RESTORE_ALL

RESTORE_ALL 也定义在 entry.S 中。其定义如下:

```
popl %ebx; \
popl %ecx; \
popl %edx; \
popl %esi; \
popl %edi; \
popl %ebp; \
popl %eax; \
popl %ds; \
popl %es; \
addl $4,%esp; \
iret; \
```

可以看出,RESTORE_ALL 与 SAVE_ALL 的过程是刚好相反的,主要完成现场恢复。iret 是返回指令。

_NR_syscallname NNN

这个宏定义在 unistd.h 中,其中 syscallname 表示系统调用函数名,NNN 表示系统调用序号。

```
#define __NR_exit 1
#define __NR_fork 2
#define __NR_read 3
#define __NR_write 4
```

Linux 系统给每个系统调用都编了号,当执行一个系统调用时,将按照系统调用号来索引系统调用。

```
_syscallN( type, name, parameter1, type, parameter1,
..., )
```

这是一个带参数宏,定义在 unistd.h 中,用来展开系统调用,N 是可变的,表示系统调用函数的参数个数。宏参数分别为系统调用函数的返回类型,系统调用函数名,系统调用参数类型,参数名。可以加多个参数。其展开后如下(假设此系统调用没有参数):

```
#define _syscall0( type, name )
type name( void )
{
```

```
long __res;
__asm__ volatile ("int $0x80
: "=a" (__res)
: "" (__NR_##name));
__syscall_return( type, __res );
}
```

系统调用表 sys_call_table

在 entry.S 文件中还有一个重要的表就是系统调用表,系统调用表保存着所有系统调用的函数指针,以方便进行系统调用的索引。其定义如下:

```
ENTRY( sys_call_table )
.long SYMBOL_NAME( sys_ni_syscall )
.long SYMBOL_NAME( sys_exit )
.long SYMBOL_NAME( sys_fork )
.long SYMBOL_NAME( sys_read )
```

2.2 系统调用过程解析

我们以 getuid() 这个系统调用为例示例。getuid() 的功能是获取当前进程的 ID 号。测试程序如下:

```
#include <linux/unistd.h>
int main() {
    int i = getuid();
    printf("my uid is : %d\n", i);
}
```

这个程序调用 getuid() 函数,来获得当前进程的 ID 号,并在终端输出。当程序调用 getuid() 这个函数时,便会调用头文件 unistd.h 中的定义的 _syscall0(int, getuid) 这个宏。这是个带参数宏,在 unistd.h 头文件中定义。通过查看 unistd.h 头文件,会发现 getuid 会被展开成以下代码:

```
getuid
int getuid( void ) {
    long __res;
    __asm__ volatile ("int $0x80"
    : "=a" (__res)
    : "" (__NR_getuid));
    __syscall_return( int, __res );
}
```

从中可以看出,程序通过调用宏 `__NR_getuid` 得到调用号,放到寄存器 `eax` 中,然后执行中断指令,“`int $ 0x80`”。

我们继续深入下去,看看 `int $ 0x80` 后面到底做了什么。因为这是一条软中断指令,那就要看看系统规定的这条中断指令的处理程序是什么。在 `traps.c` 文件中,有这样一行代码:

`set_system_gate(SYSCALL_VECTOR, &system_call)`, 其中宏 `SYSCALL_VECTOR` 在内核中是被定义成 `0x80` 的。所以,在进入 `int $ 0x80` 中断后,系统将会自动进行模式和堆栈切换,然后将控制转移到 `system_call` 的入口点。

在 `entry.S` 中,我们可以找到 `system_call` 的入口点:

```
ENTRY(system_call)
    pushl %eax
    SAVE_ALL
    GET_CURRENT(%ebx)
    testb $0x02, tsk_ptrace(%ebx)
    jne tracesys
    cmpl $(NR_syscalls), %eax
    jae badsys
    call \*SYMBOL_NAME(sys_call_table)(,%eax,
```

4)

```
    movl %eax,EAX(%ebx)
```

```
ENTRY(ret_from_sys_call)
```

```
    cli
```

```
    cmpl $0,need_resched(%ebx)
    jne reschedule
    cmpl $0,sigpending(%ebx)
    jne signal_return
```

```
Retore_all:
```

```
    RESTORE_ALL
```

这段代码的主要功能就是保留系统调用号拷贝,`SAVE_ALL` 保存现场,得到当前用户进程结构指针,并保存在 `ebx` 中,检测系统调用号是否合法,最后根据系统调用号索引 `sys_call_table`,并找到最终的内核函数 `sys_getuid16`。我们在 `linux` 终端下打开 `..../kernel/uid16.c`,便可看到这个系统调用函数的原始定义。

```
Asmlinkage long sys_getuid16(void) {
```

```
    return high2lowuid(current->uid);
}
```

这个内核系统调用函数仅返回一个当前进程的 `uid`。然后将得到的 `uid` 保存在 `eax` 中,最后调用 `RESTORE_ALL` 宏恢复现场。最后进程返回到用户态,用户程序最终执行完成。整个系统调用过程也就完成。整个过程可以用下图来表示:

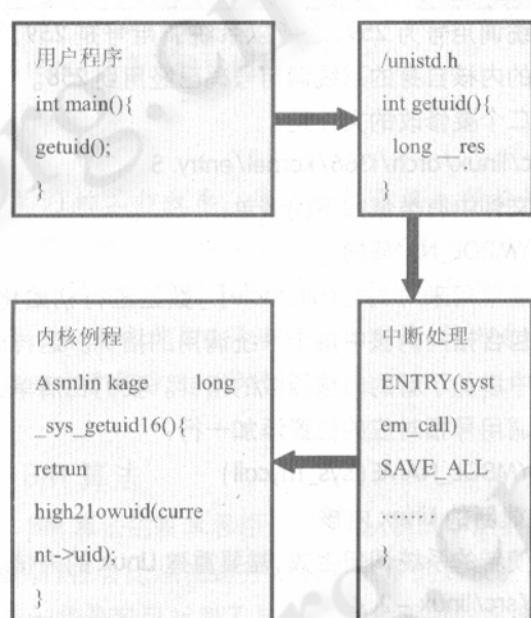


图 1

3 增加系统调用

3.1 添加源代码

首先是编写加到内核中的源程序,即将要加到一个内核文件中去的一个函数,该函数的名称应该是新的系统调用名称前面加上 `sys_` 标志。在 `/usr/src/linux/kernel/sys.c` 文件中添加源代码,如下所示:

```
asmlinkage int sys_mycall(int number)
{
    return number;
}
```

作为一个最简单的例子,我们新加的系统调用仅仅返回一个整型值。

3.2 连接新的系统调用

添加新的系统调用后,下一个任务是使 `Linux` 内核的其余部分知道该程序的存在。为了从已有的内核程

序中增加到新的函数的连接,需要编辑前面提到过的两个文件。

在我们所用的 Linux 内核版本(2.4.18)中,第一个要修改的文件是:

```
/usr/src/linux/include/asm-i386/unistd.h
```

文件中找到系统调用号的宏定义,然后在后面加上一行:

```
#define __NR_mycall 259
```

系统调用号为 259,之所以系统调用号是 259,是因为我的内核自身的系统调用号码已经用到 258。

第二个要修改的文件是:

```
/usr/src/linux/arch/i386/kernel/entry.S
```

该文件中有类似如下的清单:

```
.long SYMBOL_NAME()
```

该清单用来对 sys_call_table[] 数组进行初始化。该数组包含指向内核中每个系统调用的指针。这样就在数组中增加了新的内核函数的指针。我们在清单上与系统调用号相对应的位置添加一行:

```
.long SYMBOL_NAME(sys_mycall)
```

3.3 重建新的 Linux 内核

为使新的系统调用生效,需要重建 Linux 的内核。

```
cd /usr/src/linux-2.4
```

超级用户在当前工作目录(/usr/src/linux)下,才可以重建内核。

```
#make xconfig, 进行内核配置。
```

```
#make dep, 检测关联性。
```

```
#make clean, 清除不用的组件。
```

```
#make bzImage, 生成内核映像文件。
```

编译完毕后,系统生成一可用于安装的、压缩的内核映象文件:/usr/src/linux/arch/i386/boot/bzImage

3.4 用新的内核启动系统

将/usr/src/linux/arch/i386/boot/bzImage 拷贝到/boot/bzImage

配置启动文件:

假设所用的启动文件为 grub,修改/boot/grub/grub.conf,添加新的引导内核:

```
title Linuxtest
```

```
root(hd0,4)
```

```
kernel /boot/bzImage ro root=LABEL=/
```

```
initrd /boot/initrd-2.4.20-8.img
```

至此,新的 Linux 内核已经建立,新添加的系统调用已成为操作系统的一部分,重新启动,进入 Linux-test,就可以在应用程序中使用该系统调用了。

3.5 使用新的系统调用

在应用程序中使用新添加的系统调用 mycall。同样为实验目的,我们写了一个简单的例子 test.c。

```
#include <errno.h>
#include </usr/src/linux/include/asm-i386/unistd.h>
_syscall1(int, mycall, int, ret) // 系统调用函数声明
main()
{
    printf("%d\n", mycall(100));
}
```

编译该程序:

```
# gcc -o test test.c
```

执行:

```
# ./test
```

结果:

```
# 100
```

4 结束语

本文中我们解析了 Linux 下系统调用的整个实现过程,通过一个系统调用的实例分析一个系统调用在内核的完整实现,加深了对系统调用的认识。然后又通过一个简单的例子,叙述了在 Linux 下增加系统调用的方法。Linux 下的系统调用具有强大的功能。通过增加系统调用,我们可以根据自己的需求,来给内核增加特定的功能,方便我们的使用。

参考文献

- 陈莉君,《Linux 操作系统内核分》[M]北京>人民邮电出版社,2003.
- 毛德操、胡希明,《Linux 内核源代码情景分析》[M],杭州:浙江大学出版社,2001.
- 李善平、刘文峰、王伟波等,《Linux 内核源代码分析大全》[M]北京:机械工业出版社,2002.
- 李善平、陈文智等,《边干边学—Linux 内核指导》[M],杭州:浙江大学出版社.