Costruire un device driver per Linux

Testo di riferimento:
Alessandro Rubini, Jonathan Corbet, *Linux Device Drivers*, terza edizione

Scaricabile liberamente: http://www.xml.com/ldd/chapter/book/

Un semplice modulo

```
#define __KERNEL__
#define MODULE
#include <linux/module.h>

MODULE_LICENSE(GPL);

int init_module() {
  printk(«1>Hello, world!\n);
  return 0;
}

int cleanup_module() {
  printk(«1>Goodbye, world!\n);
}
```

Esempio di uso

```
$ gcc -c -I/usr/src/linux/include/ hello.c
$ su
Password:
# insmod hello.o
Hello, world!
# rmmod hello
Goodbye, world!
#
```

Per vedere quali moduli sono caricati

```
$ lsmod
Module                  Size  Used by    Not tainted
ds                      6624   1
i82365                 22416   1
eepro100               17264   1
esssolo1               25504   0 (unused)
apm                     9148   1
```

Notare l'*usage count*

Un modulo può modificare il suo usage count

Quando l'usage count è a 0, il modulo può essere scaricato

Le due componenti fondamentali di un modulo

int init_module(void);
- chiamata quando il modulo è caricato
- serve a dichiarare al kernel quello che il modulo sa fare
- restituisce 0 per indicare successo

void cleanup_module(void);
- chiamata quando il modulo è scaricato
- dobbiamo ritirare tutte le dichiarazioni fatte in init_module()

printk

Non possiamo usare stdio nel kernel

Non possiamo usare nessuna libreria!

printk è la versione kernel di printf

"<1>" è la priorità del messaggio (vedi /usr/include/sys/syslog.h)

Simboli di preprocessor

Perché `#define __KERNEL__`? ⇒ perché i file di include sono usati occasionalmente nei programmi applicativi; il simbolo `__KERNEL__` dice che stiamo compilando codice che eseguirà in modo kernel

Perché `#define MODULE`? ⇒ perché alcuni driver possono essere compilati sia come moduli che linkati staticamente nel kernel; il simbolo `MODULE` dice che stiamo compilando codice che eseguirà come modulo

Perché MODULE_LICENSE("GPL")?

Dobbiamo dichiarare una licenza *libera*

Altrimenti installare il modulo *contamina* (taint) il kernel

```
# insmod hello.o
Warning: loading hello.o will taint the kernel: no license
  See http://www.tux.org/lkml/#s1-18 for information about tainted modules
```

Registrare un character driver

int register_chrdev(unsigned int major, const char *name,

struct file_operations *fops);

- major: il major number desiderato
- name: il nome del device
- fops: insieme di procedure
- restituisce: 0 se ha successo, < 0 se fallisce

Va chiamato in init_module();

Il major number può essere scelto fra quelli a disposizione per esperimenti (p. es. 42)

(punti extra per chi sa perché proprio 42... :-)

Esempio di uso di register_chrdev()

Eseguire in init_module()

```
#define MY_MAJOR 42

result = register_chrdev(MY_MAJOR, "mydevice", &my_fops);
if (result < 0) {
    printk(KERN_WARNING "mydevice: can't get major %d\n", MY_MAJOR);
    /* restituiamo un risultato negativo;
       il modulo non verrà caricato */
    return result;
}
```

Il contraltare

int unregister_chrdev(unsigned int major, const char *name);

- major, name: devono avere gli stessi valori passati a register_chrdev()
- restituisce: 0 se ha successo, < 0 se fallisce

Va chiamata in cleanup_module();

Cosa succede se scarichiamo il modulo con rmmod(1), ma dimentichiamo di eseguire unregister_chrdev() nella cleanup_module() ?

⇒ disastro!

(occorre fare un reboot)

File Operations

Linux ragiona in modo object-oriented

Un "file" è una classe astratta

I suoi "metodi" sono raccolti nella struct file_operations

struct file_operations ha il ruolo di una *interface* di Java

Abbiamo un metodo per ogni syscall relativa a un file

Un driver può lasciare NULL i puntatori a metodi che non implementa

In <linux/fs.h>

```
struct file_operations {
  loff_t (*llseek) (struct file *, loff_t, int);
  ssize_t (*read) (struct file *, char *, size_t, loff_t *);
  ssize_t (*write) (struct file *, const char *, size_t, loff_t *);
  int (*ioctl) (struct inode *, struct file *, unsigned int, unsigned long);
  int (*mmap) (struct file *, struct vm_area_struct *);
  int (*open) (struct inode *, struct file *);
[...]
};
```

Utilizziamo una variabile globale

```
struct file_operations my_fops;
```

La inizializziamo in init_module():

```
my_fops.open = my_open;
my_fops.read = my_read;
[...]
```

Tutti gli altri campi restano a NULL

La struct file

Non centra niente con FILE di stdio.h

Rappresenta un *file aperto*

Contiene i dati su cui operano le file_operations

Definita in <linux/fs.h>; alcuni campi sono:

`loff_t f_pos;`
posizione corrente nel "file"

`struct file_operations *f_op;`
contiene un puntatore alle fops passate con register_chrdev()

`void *private_data;`
può essere usata dal driver per conservare dati privati

La open()

int my_open(struct inode *inode, struct file *filp);
- inode: identifica il file speciale sul disco che è stato aperto
- filp: dati allocati dal kernel per questa open

cosa deve fare la open() di un driver:
- incrementa l'usage count
- inizializza il dispositivo se necessario
- alloca dati privati e li assegna a `filp->private_data`

Usare il minor number

int my_open(struct inode *inode, struct file *filp);

Il minor number si trova in `inode->i_rdev` (Occorre usare la macro MINOR())

Il minor number può essere usato dal driver in due modi
- identificare dispositivi diversi
- aprire lo stesso dispositivo in modi diversi

es.
/dev/hda1 e /dev/hda2 sono lo stesso device, ma partizioni diverse
/dev/hda1 e /dev/hdb1 sono device diversi

```
brw-rw--    1 root     disk       3,   1 Jun  9  2002 /dev/hda1
brw-rw--    1 root     disk       3,   2 Jun  9  2002 /dev/hda2
brw-rw--    1 root     disk       3,  65 Jun  9  2002 /dev/hdb1
brw-rw--    1 root     disk       3,  66 Jun  9  2002 /dev/hdb2
```

Implementazione di Scull_Dev

```
typedef struct Scull_Dev {
  void * data;          /* punta alla nostra zona di memoria */
  int size;             /* lunghezza della nostra zona di memoria */
  struct_semaphore sem; /* per la mutua esclusione */
} Scull_Dev;
```

I nostri "device"

/dev/scull0, /dev/scull1, /dev/scull2, /dev/scull3

con major = 42 e minor $\in \{0, 1, 2, 3\}$

("scull": vedi il Rubini)

creati con

```
# mknod /dev/scull0 c 42 0
# mknod /dev/scull1 c 42 1
# mknod /dev/scull2 c 42 2
# mknod /dev/scull3 c 42 3
```

Ciascun *scull* permette di accedere a una zona di memoria *globale* e *persistente* di max 4000 byte

Allochiamo memoria staticamente

Ci serve una struttura dati per ogni "device"

```
#define NR_SCULL_DEVICES 4
Scull_Dev scull_devices[NR_SCULL_DEVICES];
```

I semafori vanno inizializzati: mettiamo questo codice nella nostra module_init()

```
for (i=0; i<NR_SCULL_DEVICES; i++) {
  sema_init(&scull_devices[i].sem, 1);
}
```

La nostra open()

```
int scull_open(struct inode *inode, struct file *filp) {
  int       minor = MINOR(inode->i_rdev);
  Scull_Dev  *dev = (Scull_Dev *) filp->private_data;

  if (!dev) {
    if (minor >= NR_SCULL_DEVICES) return -ENODEV;
    dev = &scull_devices[minor];
    filp->private_data = dev;
  }

  /* se siamo stati aperti write-only, tronca il contenuto */
  if ((filp->f_flags & O_ACCMODE) == O_WRONLY) {
    scull_trim(dev);
  }

  return 0; /* success */
}
```

C'è una race condition in questo codice; riuscite a vederla?

Alcune parole sui semafori del kernel

```
if (down_interruptible(&dev->sem)) return -ERESTARTSYS;
```

Se la down_interruptible() restituisce nonzero, vuol dire che abbiamo ricevuto un signal

La down() invece non permette di ricevere signal

(Ma rischio di creare processi che non possono essere uccisi...)

-ERESTARTSYS dice al chiamante che la operazione è stata interrotta da un signal

Trova la race condition

Una race condition si verifica in generale quando manipolo variabili globali

In questo caso ho una race condition su `scull_trim(dev)`

Per evitarla uso il semaforo:

```
if ((filp->f_flags & O_ACCMODE) == O_WRONLY) {
  if (down_interruptible(&dev->sem)) return -ERESTARTSYS;
  scull_trim(dev);
  up(&dev->sem);
}
```

read() e write()

ssize_t read(struct file *filp, char *buf, size_t count, loff_t *offp);
ssize_t write(struct file *filp, const char *buf, size_t count, loff_t *offp);

- filp: puntatore a file
- buf: area dati da trasferire
- count: dimensione del buffer
- offp: posizione di I/O

Il succo di read() e write() è copiare dati fra spazio kernel e spazio utente

Non possiamo usare memcpy(): cosa succede se accedendo a *buf abbiamo un page fault?

Come copiare dati fra spazio kernel e spazio utente?

Linux offre due funzioni che risolvono il problema:

unsigned long copy_to_user(void *to, const void *from, unsigned long count);
unsigned long copy_from_user(void *to, const void *from, unsigned long count);

Queste funzioni controllano anche che l'indirizzo sia corretto (appartiene allo spazio di indirizzamento del processo, ecc.)

Come vengono usati gli argomenti di read()

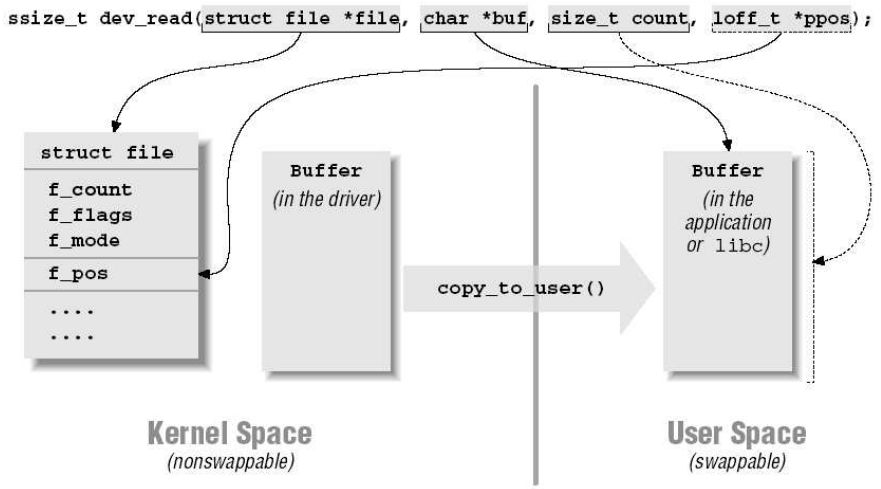

Il valore restituito da read()

- positivo: il numero di byte letti (può essere meno di `count`)
- zero: siamo a end-of-file
- negativo: condizione di errore. Il valore indica il motivo dell'errore (es. -EFAULT: bad address). Vedi <linux/errno.h> per i valori possibili

Nota:
Le applicazioni utente ricevono sempre -1 in caso di errore; il valore specifico è nella variabile `errno`

```
ssize_t scull_read(struct file *filp, char *buf, size_t count,
    loff_t *f_pos)
{
  Scull_Dev *dev = (Scull_Dev *) filp->private_data;
  int ret = 0;

  if (down_interruptible(&dev->sem)) return -ERESTARTSYS;

  if (*f_pos >= dev->size) goto out;
  if (*f_pos + count > dev->size) count = dev->size - *f_pos;
  if (copy_to_user(buf, dev->data + *f_pos, count)) {
    ret = -EFAULT;  /* bad address */
    goto out;
  }

  *f_pos += count;
  ret = count;

out:
  up(&dev->sem);
  return ret;
}
```

Il valore restituito da write()

- positivo: il numero di byte scritti (può essere meno di count)
- zero: non ha scritto nulla. Non è un errore.
- negativo: condizione di errore. Il valore indica il motivo dell'errore

```
ssize_t scull_write(struct file *filp, const char *buf, size_t count,
    loff_t *f_pos)
{
  Scull_Dev *dev = (Scull_Dev *) filp->private_data;
  int ret = -ENOMEM;  /* default in caso di errore: out of memory */

  if (down_interruptible(&dev->sem)) return -ERESTARTSYS;

  if (*f_pos + count > MAX_SCULL_SIZE) {
    ret = -ENOSPC;  /* no space left on device */
    goto out;
  }

  /* se la scrittura va oltre la dimensione corrente, devo riallocare
     il buffer del device */
  if (*f_pos + count > dev->size) {
    void * p = kmalloc(*f_pos + count, GFP_KERNEL);
    if (!p) goto out;
    memcpy(p, dev->data, dev->size);
    kfree(dev->data);
    dev->data = p;
  }
```

```
  if (copy_from_user(dev->data, buf, count)) {
    ret = -EFAULT;  /* bad address */
    goto out;
  }
  *f_pos += count;
  ret = count;

  if (*f_pos > dev->size) dev->size = *f_pos;

out:
  up(&dev->sem);
  return ret;
}
```

int release(struct inode *, struct file *);

Viene chiamata quando il file viene chiuso (da tutti i processi che l'hanno aperto)

Potremmo usarla per rilasciare la memoria ... se scull non fosse persistente

Invece il rilascio lo dobbiamo fare in module_cleanup()

Interrupt service routines

Per poter ricevere un interrupt, il driver deve "registrarlo" al sistema operativo (durante la "open")

```
result = request_irq(my_irq, my_interrupt,
                     SA_INTERRUPT, "my_device", NULL);
if (result) {
     printk(KERN_INFO "my_device: can't get assigned irq %i\n",
     short_irq = -1;
}
else { /* actually enable it -- assume this *is* a parallel port
     outb(0x10,short_base+2);
}
```

```
int request_irq(unsigned int irq,
    void (*handler)(int, void *, struct pt_regs *),
    unsigned long flags,
    const char *dev_name,
    void *dev_id);

unsigned int irq
     This is the interrupt number being requested.
void (*handler)(int, void *, struct pt_regs *)
     The pointer to the handling function being installed. We'll disc
     ments to this function later in this chapter.
unsigned long flags
     As you might expect, a bit mask of options (described later) rel
     rupt management.
const char *dev_name
     The string passed to request_irq is used in /proc/interrupts to
     of the interrupt (see the next section).
void *dev_id
     This pointer is used for shared interrupt lines. When no sharing
     is in force, dev_id can be set to NULL, but it a good idea
```

Osservare quali interrupt sono riservati

```
$ cat /proc/interrupts
           CPU0       CPU1
  0:   34584323   34936135   IO-APIC-edge    timer
  1:     224407     226473   IO-APIC-edge    keyboard
  2:          0          0         XT-PIC    cascade
  5:    5636751    5636666   IO-APIC-level   eth0
  9:          0          0   IO-APIC-level   acpi
 10:     565910     565269   IO-APIC-level   aic7xxx
 12:     889091     884276   IO-APIC-edge    PS/2 Mouse
 13:          1          0         XT-PIC    fpu
 15:    1759669    1734520   IO-APIC-edge    ide1
NMI:   69520392   69520392
LOC:   69513717   69513716
ERR:          0
$
```

Come faccio a sapere qual'è la mia linea di interrupt?

a) probing

b) mi affido ai default "ben noti" per questo device, se esistono

```
switch(short_base) {
  case 0x378: my_irq = 7; break;
  case 0x278: my_irq = 2; break;
  case 0x3bc: my_irq = 5; break;
}
```