

# Systèmes embarqués 2/7

J.-M Friedt

FEMTO-ST/département temps-fréquence

[jmfriedt@femto-st.fr](mailto:jmfriedt@femto-st.fr)

transparents à [jmfriedt.free.fr](mailto:jmfriedt.free.fr)

6 septembre 2017

# Système d'exploitation : pourquoi les pilotes

- Fournir une abstraction du matériel : cacher les fonctions bas niveau pour que le développeur se focalise sur la fonction du périphérique → un point d'entrée avec des appels système (`open`, `read`, `write`, `close`) qui cache l'accès au matériel
- Homogénéiser les interfaces à tous les périphériques ("tout est fichier")
- Seul le noyau a accès à toutes les ressources de la machine (DMA, interruptions)
- Distribuer les ressources et s'assurer de la cohérence des accès
- Ajout de fonctionnalités au noyau Linux : les **modules**

# Mémoire virtuelle/mémoire matérielle

- Espace utilisateur : mmap sur le descripteur de /dev/mem
- Espace noyau : fonction ioremap après avoir réservé une plage d'adresses.

```
#include <linux/io.h>      // ioremap
#define IO_BASE 0xe000a000 // UG585 p.1347
```

et dans la fonction d'initialisation

```
if (request_mem_region(IO_BASE,0x2e4,"GPIO test")==NULL)
    printk(KERN_ALERT "mem request failed");
jmf_gpio=(u32)ioremap(IO_BASE, 0x2e4); // UG585 p.1349
writel(1<<9,jmf_gpio+0x204); // dir. of MI09
```

Pour libérer la ressource :

```
release_mem_region(IO_BASE, 0x2e4);
```

**Tester** si la plage mémoire requise est disponible (sinon kernel panic)

# Accès au matériel depuis l'espace utilisateur

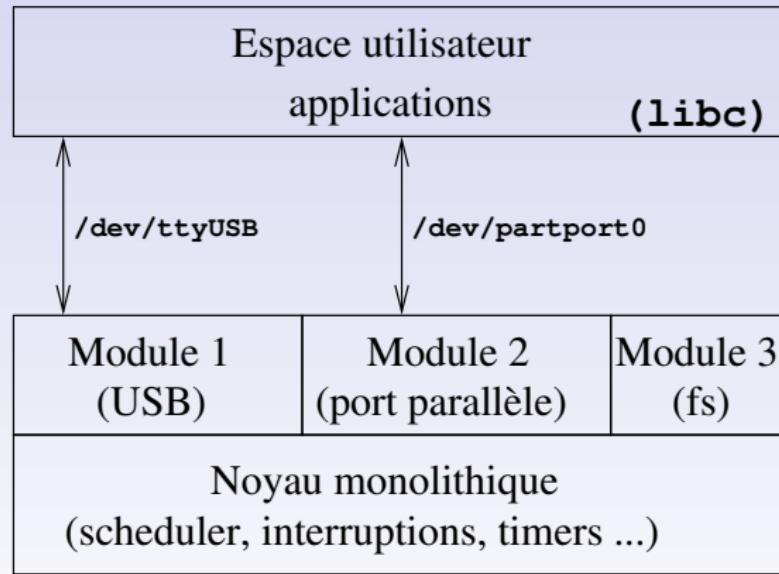
## Au travers de /dev

- écriture, lecture ou contrôle (`ioctl`)
- passage au travers du module noyau qui implémente les diverses méthodes
- chaque périphérique est identifié par sa classe (*major number*) et son indice (*minor number*)

```
brw-rw---- 1 root      disk      8,   0 Feb 28 06:21 sda
brw-rw---- 1 root      disk      8,   1 Feb 28 06:21 sda1
brw-rw---- 1 root      disk      8,   2 Feb 28 06:21 sda2
brw-rw---- 1 root      disk      8,   3 Feb 28 06:21 sda3
[...]
crw-rw---- 1 root      dialout   4,  64 Feb 28 07:21 ttyS0
crw-rw---- 1 root      dialout   4,  65 Feb 28 07:21 ttyS1
crw-rw---- 1 root      dialout   4,  66 Feb 28 07:21 ttyS2
crw-rw---- 1 root      dialout   4,  67 Feb 28 07:21 ttyS3
```

En l'absence d'une entrée (par udev) dans /dev : `mknod`

# Architecture d'un OS compatible POSIX<sup>1</sup>



1. Répertoire `/dev` :

[pubs.opengroup.org/onlinepubs/009695399/basedefs/xbd\\_chap10.html](https://pubs.opengroup.org/onlinepubs/009695399/basedefs/xbd_chap10.html)

## Le répertoire /dev

- contient des pseudo-fichiers faisant le lien entre un module noyau et l'espace utilisateur
- chaque *device* est défini par un *major number* et, dans sa classe, un *minor number*
- du côté du noyau, un pilote (*driver*) s'est lié au même major number et fournit des méthodes standard

(appels système)

- open()
- close()
- write()
- read()
- ioctl()

```
static struct file_operations fops =  
{.read:           qadc_read,  
 .open:          qadc_open,  
 .unlocked_ioctl: qadc_ioctl,  
 .release:       qadc_release,  
 // pas de .write sur un ADC !  
};  
  
static int __init qadc_init (void)  
{...  
 register_chrdev (qadc_major, "ppp", &fops);  
 ...}  
  
module_init (qadc_init);  
module_exit (qadc_exit);
```

# Input/Output Control (ioctl)

- mécanisme qui rompt avec la philosophie "tout est fichier"
- passage de la configuration d'un périphérique sous forme "nature de la configuration" et argument "valeur"
- pas de commande standardisée : voir dans le fichier d'entête commun au pilote et programme utilisateur les IOCTL disponibles
- exemple OSS (Open Sound System<sup>2</sup>) dans include/uapi/linux/soundcard.h des sources du noyau :

```
/* Use ioctl(fd, OSS_GETVERSION, &int) to get the version number of
 * the currently active driver. */
...
/* IOCTL commands for /dev/dsp and /dev/audio
 */
#define SNDCTL_DSP_RESET           _SIO ('P', 0)
#define SNDCTL_DSP_SYNC            _SIO ('P', 1)
#define SNDCTL_DSP_SPEED           _SIOWR('P', 2, int)
#define SNDCTL_DSP_STEREO          _SIOWR('P', 3, int)
```

- Espace utilisateur :

```
sample_rate = 48000;
if (ioctl (fd, SNDCTL_DSP_SPEED, &sample_rate) == -1)
    {perror ("SNDCTL_DSP_SPEED"); exit (-1);}
```

2. [http://www.linuxdevcenter.com/pub/a/linux/2007/08/02/  
an-introduction-to-linux-audio.html](http://www.linuxdevcenter.com/pub/a/linux/2007/08/02/an-introduction-to-linux-audio.html)

## IOCTL : noyau

```
static long dev_ioctl(struct file*, unsigned int ,unsigned →  
    ↪long);  
  
static struct file_operations fops=  
{.read=dev_read ,  
 .open=dev_open ,  
 .unlocked_ioctl=dev_ioctl ,  
 .write=dev_write ,  
 .release=dev_rls ,};  
  
static long dev_ioctl(struct file *f, unsigned int cmd, →  
    ↪unsigned long arg)  
{static char var[10]; // NE PAS accéder à arg  
 int dummy;           // ... qui est en userspace  
 printk(KERN_ALERT "ioctl CMD%d",cmd);  
 switch ( cmd )       // one of the known ioctl  
 {case 0: dummy=copy_from_user(var,(char*)arg,5);  
         printk(KERN_ALERT "ioctl0: %s\n", (char*)var);  
         break;  
 case 1: printk(KERN_ALERT "ioctl1: %s\n", (char*)var);  
         dummy=copy_to_user((char*)arg,var,5);  
         break;  
 default: printk(KERN_ALERT "unknown ioctl");break;  
 }  
 return 0;}
```

## IOCTL : utilisateur

Introduction

```
#include <sys/ioctl.h> /* ioctl */
#define IOCTL_SET_MSG 0
#define IOCTL_GET_MSG 1

main( int argc , char **argv )
{ int file_desc , ret_val ;
    char msg[30] = "Message passed by ioctl\n";

    file_desc = open( "/dev/jmf" , 0 );
    msg[4]=0;
    ret_val = ioctl( file_desc , IOCTL_SET_MSG , message );
    ret_val = ioctl( file_desc , IOCTL_GET_MSG , message );
}
donne (dmesg)
```

```
[ 943.551282] Hello ioctl
[ 946.385700] ioctl open
[ 946.385757] ioctl CMD0
[ 946.385758] ioctl0: Mess
[ 946.385762] ioctl CMD1
[ 946.385763] ioctl1: Mess
[ 946.385766] bye
```

## Timer noyau – accès direct GPIO

Introduction

```
#define mio 0

int hello_start()
{int delay = 1;
 unsigned int s;

if (request_mem_region(IO_BASE1,0x12c,"GPIO cfg") == NULL)
    printk(KERN_ALERT "mem request failed");
jmf_gpio = (void __iomem*)ioremap(IO_BASE1, 0x4);
s=readl(jmf_gpio+0x12c); // PAS assignation (crash): mask
s|=(1<<22);           // ... GPIO clock
	writel(s,jmf_gpio+0x12c);
release_mem_region(IO_BASE1, 0x12c);

if (request_mem_region(IO_BASE2,0x2E4,"GPIO test") == NULL)
    printk(KERN_ALERT "mem request failed");
jmf_gpio = (void __iomem*)ioremap(IO_BASE2, 0x2E4);
	writel(1<<mio,jmf_gpio+0x204); // direction
	writel(1<<mio,jmf_gpio+0x208); // enable
	writel(1<<mio,jmf_gpio+0x40); // value
```

User Guide : Appendix B (Register Details) p.785 → gpio @ 0xE000A000  
→ DATA\_0 en 0x040, DIRM\_0 en 0x204 et OEN\_0 en 0x208.

# Timer du noyau – accès direct GPIO (2)

```
init_timer_on_stack(&exp_timer);
exp_timer.expires = jiffies + delay * HZ; // HZ specifies →
    ↪ number of clock ticks generated per second
exp_timer.data = 0;
exp_timer.function = do_something;
add_timer(&exp_timer);
}

void hello_end() // cleanup_module(void)
{release_mem_region(IO_BASE2, 0x2e4);
 del_timer(&exp_timer);
}
```

Timer et finir par relâcher les ressources

## Timer du noyau – gpiolib

- Mieux : utiliser des bibliothèques existantes du noyau
- Accès aux GPIO : gpiolib
- configuration noyau (`make linux-menuconfig`)

CONFIG\_GPIO\_XILINX:

Say yes here to support the Xilinx FPGA GPIO device

Symbol: GPIO\_XILINX [=m]

Type : tristate

Prompt: Xilinx GPIO support

Location:

    -> Device Drivers

        -> GPIO Support (GPIOLIB [=y])

            -> Memory mapped GPIO drivers

- nous avons choisi de *ne pas* compiler les modules en statique afin de pouvoir les désactiver en les retirant du noyau (`rmmmod`)
- comme en espace utilisateur, MIOx est appelé par 906+x

## Timer du noyau – gpiolib

```
int hello_start(void);
void hello_end(void);

int hello_start()
{int jmf_gpio=906+0; // 0 = orage , 7 = rouge (heartbeat)
err=gpio_is_valid(jmf_gpio);
err=gpio_request_one(jmf_gpio, GPIOF_OUT_INIT_LOW, "→
→jmf_gpio");
// voir dans linux-XXX/linux/gpio.h pour les appels

init_timer_on_stack(&exp_timer);
exp_timer.expires = jiffies + delay * HZ;
// HZ = number of clock ticks generated per second
exp_timer.data = 0;
exp_timer.function = do_something;
add_timer(&exp_timer);
return 0;
}

void hello_end() // cleanup_module(void)
{gpio_free(jmf_gpio); del_timer(&exp_timer);
}
```

manipuler la broche : gpio\_set\_value(jmf\_gpio,jmf\_stat);  
Exploitation de gpiolib : la licence (GPL) du module importe !

## Structure de base

- deux points d'entrée et de sortie :  
`module_init (fonction_debut); et`  
`module_exit (fonction_fin);`
  - initialisation du point de liaison avec l'espace utilisateur  
`register_chrdev (90 , "jmf" ,&fops );`
  - des affichages au travers de /var/log/syslog par  
`printk (KERN_ALERT "message formaté"); (sans virgule !)`
  - possibilité de création dynamique de l'entrée dev  
`insmod module crée /dev/jmf par`  
`struct miscdevice jmfdev;`
- ```
{jmfdev.name = "jmf"; // /dev/jmf: major = classe misc
 jmfdev.minor = MISC_DYNAMIC_MINOR;
 jmfdev.fops = &fops;
 misc_register(&jmfdev); // creation dynamique /dev/jmf
}
qui se conclut par (rmmod module) :
misc_deregister(&jmfdev);
```

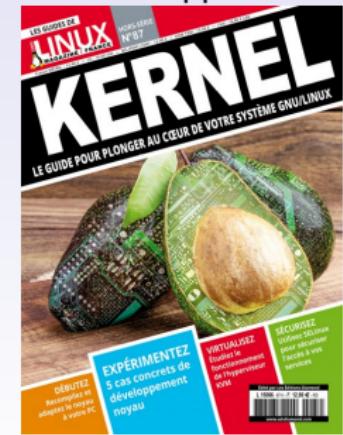
## Démonstration

- ① compilation d'un module simple (`init`, `exit`) sur PC – Makefile faisant appel aux sources du noyau,

```
obj-m +=mon_module.o
all:
    make -C /lib/modules/$(shell uname -r)/build M=$(PWD) modules
car
$ ls -l /lib/modules/4.12.0-1-amd64/
build -> /usr/src/linux-headers-4.12.0-1-amd64
```

- ② compilation du *même* module pour Redpitaya en faisant appel aux sources du noyau dans buildroot – transfert et exécution sur Zynq
- ③ ajout des fonctions `open`, `ioctl`, `close` – création de l'entrée dans `/dev` par `mknod` et test par un programme en C faisant appel à `ioctl()`

Pour proposer une compilation conditionnelle  
`x86 v.s ARM : #ifdef __ARMEL__`<sup>3</sup>



3. J.-M Friedt, *Modification des appels systèmes du noyau Linux : manipulation de la mémoire du noyau*, GNU/Linux Magazine Hors Série 87 (Nov.-Déc 2016)

# Détournement des appels système

```
$ strace mkdir toto
[...]
mkdir("toto", 0777)          = 0
```

- Un appel système est une méthode fournie par le noyau pour accéder aux ressources gérées par le système (norme POSIX : open, close, read, write, mkdir ...)
- un programme utilisateur fait appel à un appel système ...
- ... qui correspond à une fonction en espace noyau.
- Une table des appels système fait la correspondance entre les deux.

⇒ manipuler les appels systèmes consiste en

- ① identifier l'emplacement en mémoire de cette table de correspondance
- ② modifier l'adresse de la fonction appelée vers notre fonction ou ...
- ③ ... modifier le contenu de la mémoire contenant l'adresse de destination.

# Détournement des appels système

## Introduction

Attaque évidente contre lesquelles les protections sont

- interdiction d'écrire dans les pages mémoire contenant la table des appels système

```
/boot/System.map-4.6.0-1-amd64: ffffffff816001e0 R sys_call_table  
/proc/kallsyms : ffffffff816001e0 R sys_call_table
```

- ne pas exporter les symboles des appels systèmes (portée des fonctions : `static` dans le fichier, `EXPORT_SYMBOL`)

Question : quelles sont les fonctions exportées par le noyau vers les modules ?

```
linux-4.4.2$ grep -r EXPORT_SYMBOL * | grep \(`sys_  
[...]  
fs/open.c:EXPORT_SYMBOL(sys_close);  
kernel/time/time.c:EXPORT_SYMBOL(sys_tz);
```

**Seul sys\_close() est exporté**

# Détournement des appels système

```
#include <linux/module.h>
#include <linux/syscalls.h>

static unsigned long* cherche_table(void)
{unsigned long int offset = PAGE_OFFSET;      // debut kernel
 unsigned long *sct;
 printk(KERN_INFO "PAGE_OFFSET=%lx\n",PAGE_OFFSET);
 while (offset < ULONG_MAX)          // recherche toute la mem
 {sct = (unsigned long *)offset;
 if (*sct == (unsigned long)&sys_close)    // @ sys_close
     return sct;                         // on a trouvé l'@ de debut
 offset += sizeof(void *);
 }
 return NULL;
}
[...]
```

```
[100266.370251] PAGE_OFFSET=fffff880000000000
[100266.433568] table: ffff8800016001f8
[100266.433570] NR close: 3
[100266.433571] NR mkdir: 83 => ffffffff812020d0
```

cohérent ( $16001\text{f}8 - 24 = 16001\text{e}0$  car `sys_close` est appel 3) avec

```
/boot/System.map-4.6.0-1-amd64: ffffffff816001e0 R sys_call_table
/proc/kallsyms                      : ffffffff816001e0 R sys_call_table
```

# Détournement des appels système

## Introduction

### Pointeur de fonction

```
#include <linux/module.h>
#include <linux/syscalls.h>

asmlinkage          // passage params par pile
long (*ref_sys_mkdir)(const char __user*,int);

asmlinkage
long mon_mkdir(const char __user *pnam, int mode)
{ printk(KERN_INFO "intercept: %s:%x\n", pnam, mode);
  return 0;
}

static int __init module_start(void)
{addr_table = cherche_table();
 ref_sys_mkdir=(void *)addr_table[__NR_mkdir-__NR_close];
 addr_table[__NR_mkdir-__NR_close]=(unsigned long)→
     ↪mon_mkdir;
 return(0);
}

$ mkdir toto
[103669.045129] intercept: toto:1ff
```