Systèmes embarqués 2/7

J.-M Friedt

FEMTO-ST/département temps-fréquence

jmfriedt@femto-st.fr

transparents à `jmfriedt.free.fr`

14 octobre 2018

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 $\rightarrow$ 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 MIO9
```

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 [1]

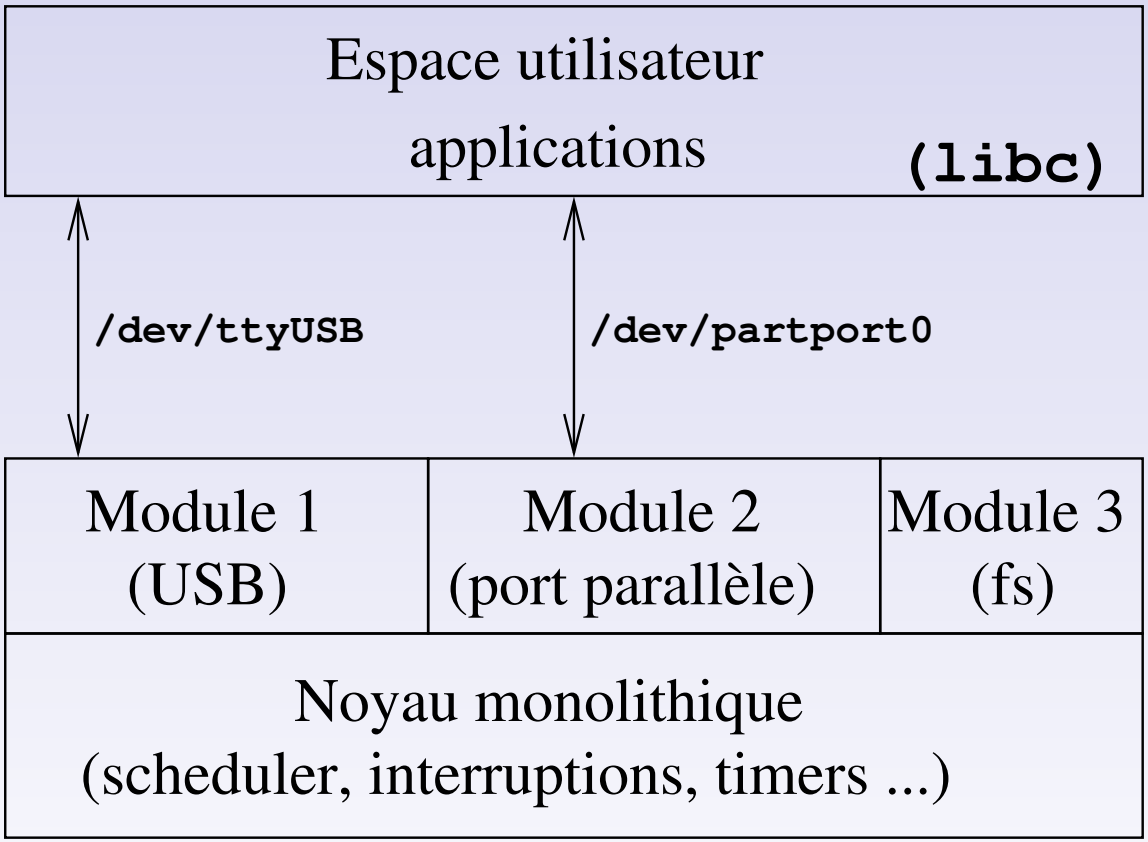

fonctions système, réseau, gestion processus et mémoire, vfs

1. Répertoire `/dev` : `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 romp 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 [2]) 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

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 acceder a 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

```c
#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, msg);
  ret_val = ioctl(file_desc, IOCTL_GET_MSG, msg);
}
```

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

```
#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`
- confguration 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 (`rmmod`)
- 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 = orange, 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__` [3]

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.

$\Rightarrow$ 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

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 < ULLONG_MAX)      // recherche toute la mem
  {sct = (unsigned long *)offset;
   if (*sct == (unsigned long)&sys_close)    // @ sys_close
      return sct;                  // on a trouve' l'@ de debut
   offset += sizeof(void *);
  }
 return NULL;
}
[...]
```

```
[100266.370251] PAGE_OFFSET=ffff880000000000
[100266.433568] table: ffff8800016001f8
[100266.433570] NR close: 3
[100266.433571] NR mkdir: 83 => ffffffff812020d0
```

cohérent (16001f8-24=16001e0 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

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
```