

Systèmes d'exploitation

Introduction: shell, noyau, syscalls

Guillaume Salagnac

Insa de Lyon – Informatique

IFA-3-SYS : Systèmes d'Exploitation

Guillaume Salagnac <guillaume.salagnac@insa-lyon.fr>

- enseignement : architecture, compilation, système
- recherche : info. frugale, numérique pour l'anthropocène

Objectifs du cours

- Comprendre les «concepts clés» des systèmes d'exploitation
 - quel est le problème ? pourquoi se pose-t-il ?
 - quelle sont la/les solutions ? pourquoi ça marche ?
 - ▶ prenez des notes en cours !
- Pratiquer leur usage
 - TP de programmation C sous Linux (4×2h)
 - TD sur papier (2×2h)
 - ▶ prenez des notes aussi !

Ressources

- <http://moodle.insa-lyon.fr> > Informatique > IFA-3
- vidéos et transparents des cours ; sujets de TD et de TP

Plan du cours

- **Chap 1** Noyau, processus, appels système
TP manipulation de processus : `fork()`, `exec()`, `waitpid()`
- **Chap 2** Multitâche, temps partagé, ordonnancement
TD ordonnancement de processus
- **Chap 3** Mémoire virtuelle, isolation, pagination à la demande
TP allocation et entrées-sorties fichier avec `mmap()`

Contrôle continu (30 min, coeff 1)

19/02

- **Chap 4** Allocation dynamique
TP implémentation de `malloc()` et `free()`

Vacances d'hiver

26/02 .. 03/03

- **Chap 5** Synchronisation, concurrence, sémaphores
TD algorithmes concurrents avec sémaphores
TP programmation avec `pthread`s


Examen final (1h30, coeff 2)

20/03

Plan

1. Introduction : définition du terme «Système d'exploitation»
2. Interface entre OS et utilisateur : le shell
3. Interface entre logiciel et matériel : l'architecture
4. Isolation entre noyau et applications : les syscalls
5. Quelques syscalls UNIX incontournables

Vous avez dit «Système d'exploitation» ?



Quelques définitions

Utilisateur = l'humain devant la machine

- suivant le contexte : utilisateur final, ou développeur
- interagit directement... avec le matériel !


Applications = les logiciels avec lesquels veut interagir l'**utilisateur final**

- messagerie, traitement de texte, lecteur de musique, etc

Matériel = la machine physique

Et donc : **Operating System** = tout le reste

- logiciel d'infrastructure : «noyau», «pilotes», «services», etc
- «entre le matériel et les applications»



Rôle de l'OS : les deux fonctions essentielles

et largement interdépendantes !

Machine virtuelle

- cacher la complexité sous une interface «plus jolie»
- fournir certains services de base aux applications
 - IHM, stockage persistant, accès internet, gestion du temps
- permettre la portabilité des programmes
 - pouvoir lancer un même exécutable sur différents matériels

Gestionnaire de ressources

- partager chaque ressource entre les applications
- exploiter «au mieux» les ressources disponibles
- assurer la protection des applications (et du système)

Plan

1. Introduction : définition du terme «Système d'exploitation»
2. Interface entre OS et utilisateur : le shell
3. Interface entre logiciel et matériel : l'architecture
4. Isolation entre noyau et applications : les syscalls
5. Quelques syscalls UNIX incontournables

Interface entre OS et utilisateur : le shell

Les services offerts par un shell :

- **exécution** de programmes
 - charger un programme en mémoire, le lancer, l'arrêter
 - choisir quel programme est au premier-plan
- exploration et administration des **espaces de stockage**
 - naviguer dans les fichiers, copier, supprimer
- confort et **ergonomie**
 - presse-papiers, drag-and-drop, corbeille
- ...

Différents types de shell : l'interpréteur de commandes





```
gsalagnac@plouf:~  
19:08:18 (1)% ls -l /  
total 196  
drwxr-xr-x 58 root admin 2.8k Dec 22 14:37 Applications/  
drwxr-xr-x 65 root wheel 2.3k Apr 15 2016 Library/  
drwxr-xr-x 2 root wheel 68 Sep 16 2015 Network/  
drwxr-xr-x 4 root wheel 136 Dec 15 12:24 System/  
drwxr-xr-x 5 root admin 170 Feb 4 2016 Users/  
drwxr-xr-x 7 root admin 238 Jan 12 18:05 Volumes/  
drwxr-xr-x 39 root wheel 1.4k Jul 27 09:48 bin/  
drwxr-xr-t 2 root admin 68 Sep 16 2015 cores/  
dr-xr-xr-x 3 root wheel 4.4k Jan 18 17:28 dev/  
lnsr-xr-x 1 root wheel 11 Dec 3 2015 etc -> private/etc/  
dr-xr-xr-x 2 root wheel 1 Jan 10 17:29 home/  
dr-xr-xr-x 2 root wheel 1 Jan 10 17:29 net/  
drwxr-xr-x 5 root wheel 170 Feb 11 2016 opt/  
drwxr-xr-x 6 root wheel 284 Dec 3 2015 private/  
drwxr-xr-x 59 root wheel 2.1k Dec 15 12:23 shin/  
lnsr-xr-x 1 root wheel 11 Dec 3 2015 tmp -> private/tmp/  
drwxr-xr-x 13 root wheel 442 Feb 10 2016 usr/  
lnsr-xr-x 1 root wheel 11 Dec 3 2015 var -> private/var/  
  
gsalagnac@plouf:~  
19:08:18 (2)%
```

Attention : **terminal** (ou émulateur de terminal) \neq **shell** !

Interface textuelle = **Command-Line Interface** = CLI

exemples : Bourne shell (1977), bash, zsh...



Différents types de shell : le bureau graphique



Interface graphique = **Graphical User Interface** = GUI

exemples : Gnome, bureau de Windows, Aqua (Mac OSX)...

et encore : l'écran d'accueil du smartphone



exemples : Android Launcher, Nova Launcher, Square Home...

Conclusion : le shell

différents types de shell : CLI vs GUI à souris vs GUI tactile

- ▶ fonctionnalités similaires
- ▶ pour l'OS : une «application» comme les autres !

vosre OS contient volontiers des applications **pré-installées**...

- shell, navigateur web, explorateur de fichiers, messagerie, lecteur multimedia, app store, etc


... et aussi plein de «**programmes système**» :

- développement : compilateur, assembleur, linker, etc
- sécurité : antivirus, pare-feu, sauvegarde
- maintenance : mise à jour, panneau de configuration
- services réseau : web, base de données, accès distant

Remarque :

dorénavant je vais appeler tous ces programmes des **applications**

Positionnement de l'OS



Définition : **Noyau**, ou en VO kernel

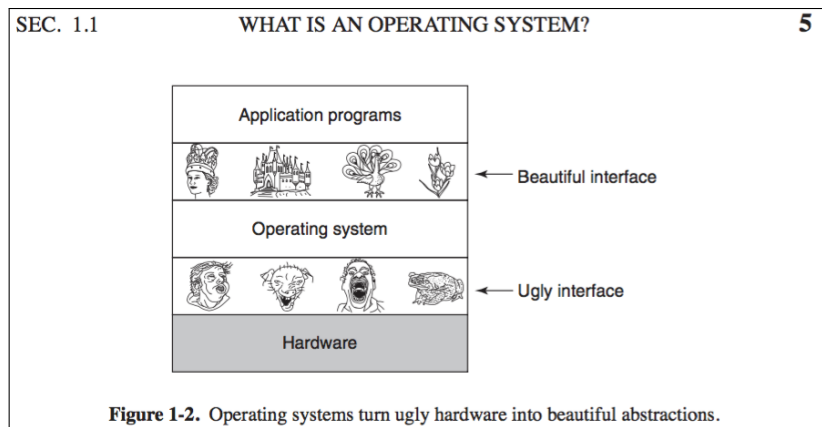
Le noyau c'est la partie de l'OS qui n'est pas une application

Plan

1. Introduction : définition du terme «Système d'exploitation»
2. Interface entre OS et utilisateur : le shell
3. Interface entre logiciel et matériel : l'architecture
4. Isolation entre noyau et applications : les syscalls
5. Quelques syscalls UNIX incontournables

Vous avez dit «une interface plus jolie» ?

et c'est vraiment cette formule qui est donnée dans les livres :




source : Tanenbaum. *Modern Operating Systems (4th ed, 2014)*. page 5

Un exemple de programme : la commande cat

```
int main() {  
    char buffer[100];  
    int n;  
  
    int fd=open("filename.txt", O_RDONLY);  
    if(fd == -1)  
        exit(1);  
  
    n=read(fd, buffer, 100);  
    while( n > 0) {  
        write(STDOUT, buffer, n);  
        n=read(fd, buffer, 100);  
    }  
    exit(0);  
}
```

Architecture d'une machine typique




Langage de programmation vs langage machine

00401be5 <main>:

401be5:	55	push	%rbp
401be6:	48 89 e5	mov	%rsp,%rbp
401be9:	48 83 ec 70	sub	\$0x70,%rsp
401bed:	be 00 00 00 00	mov	\$0x0,%esi
401bf2:	bf 10 20 48 00	mov	\$0x482010,%edi
401bf7:	b8 00 00 00 00	mov	\$0x0,%eax
401bfc:	e8 7f c5 03 00	callq	43e180 <__libc_open>
401c01:	89 45 f8	mov	%eax,-0x8(%rbp)
401c04:	83 7d f8 ff	cmpl	\$0xffffffff,-0x8(%rbp)
401c08:	75 0a	jne	401c14 <main+0x2f>
401c0a:	bf 01 00 00 00	mov	\$0x1,%edi
401c0f:	e8 7c 6a 00 00	callq	408690 <exit>
401c14:	48 8d 4d 90	lea	-0x70(%rbp),%rcx
401c18:	8b 45 f8	mov	-0x8(%rbp),%eax
401c1b:	ba 64 00 00 00	mov	\$0x64,%edx
401c20:	48 89 ce	mov	%rcx,%rsi
401c23:	89 c7	mov	%eax,%edi
401c25:	e8 86 c6 03 00	callq	43e2b0 <__libc_read>
401c2a:	89 45 fc	mov	%eax,-0x4(%rbp)
401c2d:	eb 30	jmp	401c5f <main+0x7a>
401c2f:	8b 45 fc	mov	-0x4(%rbp),%eax

Applications = CPU en «mode restreint»



Rappel : le cycle de Von Neumann

while True do :

charger une instruction depuis la «mémoire»

décoder ses bits : quelle opération, quelles
opérandes, etc

exécuter l'opération et enregistrer le résultat

repeat

Définition : restricted mode = slave mode = ring 3 = user mode


- vue **partielle** de la machine : 1 CPU + 1 mémoire
- certaines instructions **interdites**, certaines adresses **interdites**
- utile pour exécuter sereinement du code applicatif
- instructions disponibles : opérations ALU, accès mémoire, sauts

ADD R1 <- R3, R4

WRITE [R8] <- R5

CALL 123456

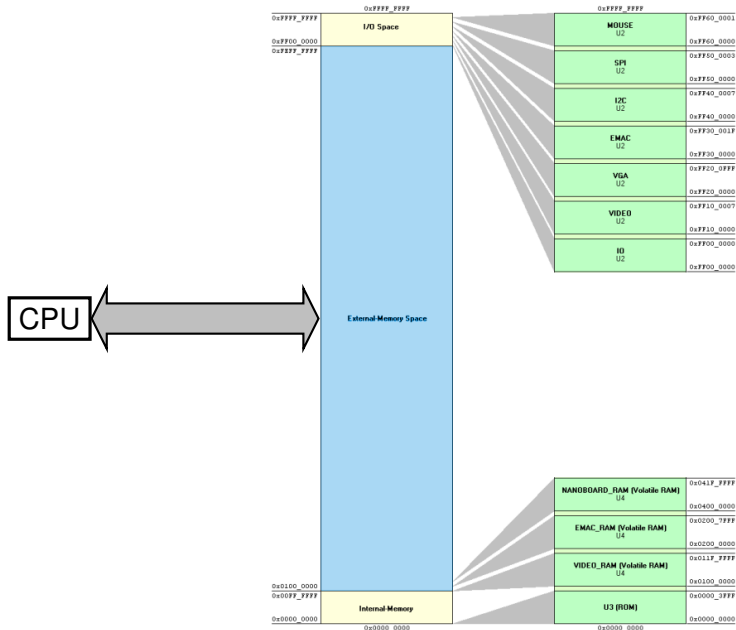
Noyau = CPU en «mode superviseur»



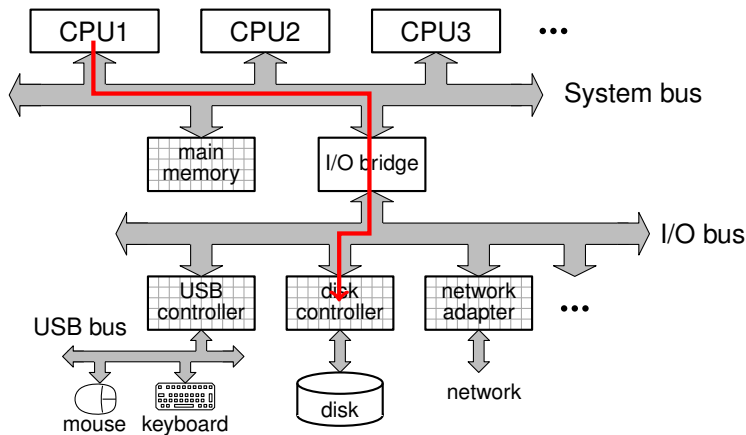
Définition : supervisor mode = ring 0 = kernel mode = privileged mode

- accès **direct** au matériel : nécessaire pour le noyau et les **drivers**
- SW_→HW = Memory-mapped I/O HW_→SW = Interruptions
- mode par défaut au démarrage de la machine (boot)

Accès au matériel = Memory-mapped Input/Output



Exemple : lecture sur le disque 1/3




Pour initier l'opération, le CPU écrit une requête à l'adresse mémoire du contrôleur de disque.

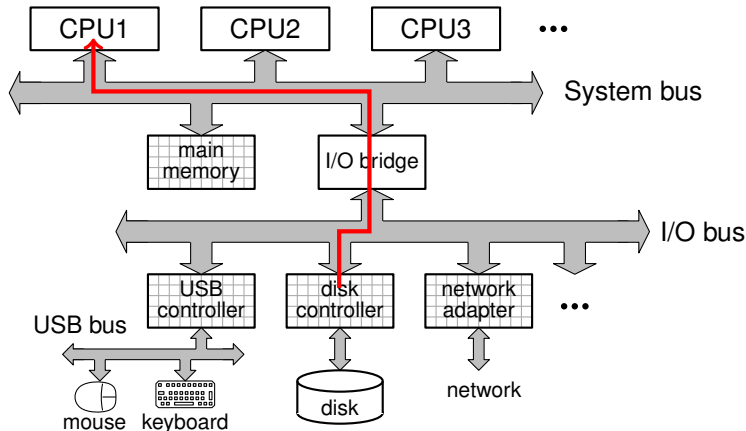
requête = commande + n° de bloc + addr. mem destination

Exemple : lecture sur le disque 2/3

DMA



Le contrôleur de disque lit le secteur demandé et transfère les données directement en mémoire vive à l'adresse voulue : c'est un **transfert DMA** (Direct Memory Access)



À la fin du transfert DMA, le contrôleur du périphérique notifie le CPU en lui envoyant une **Requête d'Interruption (IRQ)**

Un processeur avec support des interruptions

Le cycle de Von Neumann avec interruptions

while True do :

 charger une instruction depuis la mémoire

 décoder ses bits : quelle opération, quelles opérandes, etc

 exécuter l'opération et enregistrer le résultat

 if interruption demandée then :

 sauvegarder le contenu des registres

 déterminer l'adresse de la routine de traitement

 passer en mode superviseur

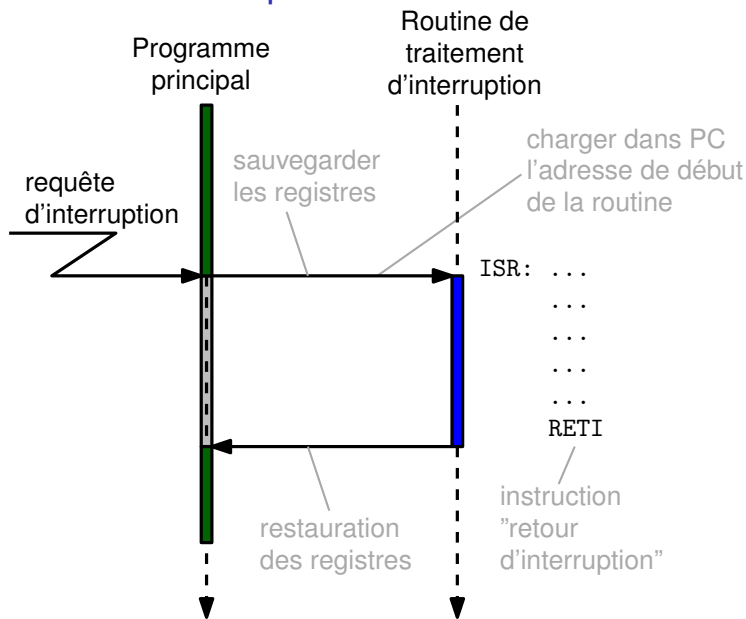
 sauter à la routine = écrire son adresse dans le compteur ordinal

 endif

repeat

Note : à la fin de la routine de traitement, une instruction RETI repassera le CPU en *mode restreint*.

Mécanisme d'interruptions : déroulement



Mécanisme d'interruptions : vocabulaire

- IRQ = **Interrupt Request**
 - un «message» envoyé par un périphérique vers le processeur
 - de façon asynchrone (vs polling, inefficace)
 - chaque IRQ porte un numéro identifiant le périphérique d'origine
- ISR = **Interrupt Service Routine**
 - un fragment de programme (= séquence d'instructions) exécuté à chaque occurrence de l'évènement matériel associé
 - termine toujours par une instruction RETI «retour d'interruption»
 - pendant une ISR : nouvelles IRQ temporairement mises en attente (permet au programmeur d'être «seul au monde»)
- Table des Vecteurs d'Interruptions
 - tableau de pointeurs indiquant l'adresse de chaque ISR
 - le CPU utilise le numéro d'IRQ pour savoir où sauter

Définition : **Noyau**, ou en VO kernel

Le noyau c'est (exactement) l'ensemble des ISR de la machine

- et de toutes les fonctions que celles-ci appellent

Différentes sources d'interruptions

- Périphériques d'entrées-sorties
 - clavier, souris, disque, GPU, réseau, etc
- Pannes matérielles
 - température excessive, coupure de courant, etc
- Minuteur système, ou en VO System Timer
 - interruptions périodiques, typiquement 100Hz ou 1000Hz
 - permet à l'OS de percevoir le passage du temps
 - bonus : permet au noyau de reprendre la main sur les applications (cf chap. 2)
- Évènements logiciels exceptionnels
 - erreurs fatales : division par zéro, instruction invalide, etc
 - trappes volontaires : appels système (cf diapos suivantes)
 - fautes de pages : constatées par la MMU (cf chap 3)

Plan

1. Introduction : définition du terme «Système d'exploitation»
2. Interface entre OS et utilisateur : le shell
3. Interface entre logiciel et matériel : l'architecture
4. Isolation entre noyau et applications : les syscalls
5. Quelques syscalls UNIX incontournables

Changement de mode d'exécution : trappes

Problème : comment une application peut-elle invoquer une méthode du noyau ?

Mauvaise solution : autoriser les applications à sauter vers les fonctions situées dans le noyau

- destination arbitraire ► failles de sécurité
- passage en mode superviseur ► quand ? comment ?

Solution : se donner une instruction spécialisée pour cet usage

- exemples : TRAP (68k), INT (x86), SWI (ARM), SYSCALL (x64)
- **interruption logicielle** = **trappe** = **exception**
- fonctionnement : similaire aux autres types d'interruption
 - sauvegarde en mémoire l'état du CPU
 - bascule vers mode superviseur
 - branche dans le noyau vers une adresse bien connue

Appel système : principe

Appel système, ou en VO system call = syscall

Fonction située dans le noyau, invoquée par un processus utilisateur via une interruption logicielle

Côté application :

- l'appel est invoqué avec une instruction TRAP
- indifférent au langage de programmation utilisé
- encapsulation dans des fonctions de bibliothèque (ex : libc)

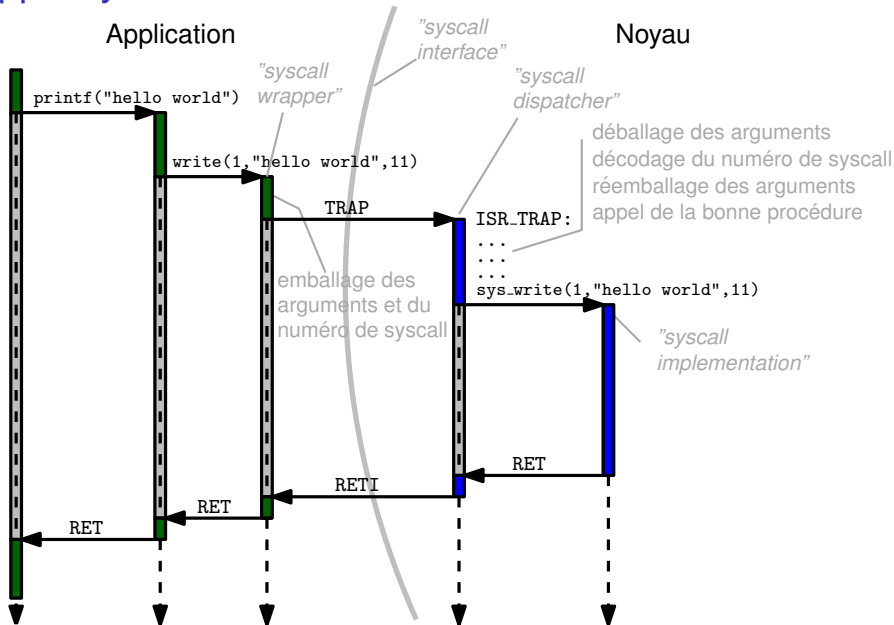
Côté noyau :

- on passe à chaque fois par l'ISR de TRAP
- qui appelle la bonne fonction dans le noyau,
- puis qui rend la main à l'application avec RETI

Exemples :

- `read()`, `write()`, `fork()`, `gettimeofday()`...
- plusieurs centaines en tout sous Linux

Appel système : déroulement



Appel système : langage machine

00410700 <__libc_read>:

410700:	f3 0f 1e fa	endbr64
410704:	80 3d 6d f3 08 00 00	cmpb \$0x0,0x8f36d(%rip)
41070b:	74 13	je 410720 <__libc_read+0x20>
41070d:	31 c0	xor %eax,%eax
41070f:	0f 05	syscall
410711:	48 3d 00 f0 ff ff	cmp \$0xffffffffffffffff000,%rax
410717:	77 4f	ja 410768 <__libc_read+0x68>
410719:	c3	ret
41071a:	66 0f 1f 44 00 00	nopw 0x0(%rax,%rax,1)
410720:	55	push %rbp
...	...	

004107a0 <__libc_write>:

4107a0:	f3 0f 1e fa	endbr64
4107a4:	80 3d cd f2 08 00 00	cmpb \$0x0,0x8f2cd(%rip)
4107ab:	74 13	je 4107c0 <__libc_write+0x20>
4107ad:	b8 01 00 00 00	mov \$0x1,%eax
4107b2:	0f 05	syscall
4107b4:	48 3d 00 f0 ff ff	cmp \$0xffffffffffffffff000,%rax
4107ba:	77 54	ja 410810 <__libc_write+0x70>
4107bc:	c3	ret
4107c0:	...	

Notion de processus

Applications exécutées sur la «**machine virtuelle userland**» :

- jeu d'instructions restreint (CPU en mode utilisateur)
 - pas accès au mécanisme d'interruptions
- accès **interdit** à certaines adresses mémoire
 - ex : code et données du noyau, périphériques matériels

Protection par «**sandboxing**» : une nouvelle instance de cette machine virtuelle pour chaque application en cours d'exécution

- **CPU virtuel** (cf chap 2), **mémoire virtuelle** (cf chap 3)
- périphériques : accessibles seulement au travers du noyau

Notion de **processus** (ou en VO **process**)

« Un programme en cours d'exécution »

Système d'exploitation = illusionniste (VM) + sous-traitant (HW)

Notion de processus : remarques

Intuitions :

- un processus = un programme + son état d'exécution
- état d'exécution = valeurs des registres + contenu mémoire + «contexte d'exécution»


Le noyau :

- partage les ressources matérielles entre les processus
- crée/recycle les processus lorsqu'on lui demande
 - dans le noyau : un **Process Control Block** par processus vivant
 - PCB = carte d'identité du processus ► stocke le **contexte** : numéro (**PID**), répertoire courant, liste des fichiers ouverts...

À faire chez vous :


- essayer les commandes `ps aux` et `top`
 - puis `man ps` et `man top`
- et aussi `strace ./monprogramme`

La VM userland : en résumé



- code applicatif exécuté par CPU en mode utilisateur
- pour faire appel au noyau : interface des appels système

Positionnement de l'OS



- chaque application qui s'exécute est un **processus** userland
- le **noyau** virtualise et arbitre les accès au matériel

Plan

1. Introduction : définition du terme «Système d'exploitation»
2. Interface entre OS et utilisateur : le shell
3. Interface entre logiciel et matériel : l'architecture
4. Isolation entre noyau et applications : les syscalls
5. Quelques syscalls UNIX incontournables

Appels système : exemples

EXAMPLES OF WINDOWS AND UNIX SYSTEM CALLS

	Windows	Unix
Process Control	CreateProcess()	fork()
	ExitProcess()	exit()
	WaitForSingleObject()	wait()
File Manipulation	CreateFile()	open()
	ReadFile()	read()
	WriteFile()	write()
	CloseHandle()	close()
Device Manipulation	SetConsoleMode()	ioctl()
	ReadConsole()	read()
	WriteConsole()	write()
Information Maintenance	GetCurrentProcessID()	getpid()
	SetTimer()	alarm()
	Sleep()	sleep()
Communication	CreatePipe()	pipe()
	CreateFileMapping()	shmget()
	MapViewOfFile()	mmap()
Protection	SetFileSecurity()	chmod()
	InitializeSecurityDescriptor()	umask()
	SetSecurityDescriptorGroup()	chown()

source : Silberschatz. *Operating Systems Concepts Essentials* (2011). p 59

Une fonction qui cache un syscall : getpid()

Pour connaître notre numéro de processus

```
#include <unistd.h>
```

```
int getpid(void);
```

Remarques :

- le noyau donne un **numéro unique** à chaque processus
- attribué à la **création** du processus. ne change jamais ensuite.
- stocké dans le PCB du processus

Une fonction qui cache un syscall : exit()

Pour cesser définitivement l'exécution du programme

```
#include <stdlib.h>

void exit(int status);
```

Remarques :

- l'exécution ne «revient jamais» d'un appel à exit()
- exit(n) équivalent à un return n depuis le main()
- le «exit status» n est transmis au processus parent
 - convention : 0=OK, 1–255=erreur
 - stocké dans le PCB en attendant un syscall wait() du parent

Une fonction qui cache un appel système : fork()

Pour dupliquer le processus en cours

```
#include <unistd.h>
```

```
int fork(void);
```

Remarques :


- sous unix : créer un processus \neq changer de programme
- `fork()` duplique le processus qui a invoqué le syscall
 - processus d'origine = «parent», nouveau = «enfant»
- **duplication** intégrale de la machine virtuelle userland
 - CPU virtuel : les deux processus s'exécutent **en concurrence**
 - mémoire virtuelle : chacun s'exécute dans un **espace privé**
 - contexte : même répertoire courant, mêmes fichiers ouverts...

Paradigme «*Call once, return twice*»

- dans le nouveau processus `fork()` renvoie 0
- dans le parent, `fork()` renvoie le PID de l'enfant

Appel système fork : illustration

```
1  // only one process
2  int y = 5 ;
3  int x = fork();
4  if ( x != 0 ) {
5      // parent only
6      y = y + 1;
7  } else {
8      // child only
9      y = y - 1;
10 }
11 // both processes
```



Mon premier interpréteur de commandes

```
char command[...];
char params[...];
main() {
    while(true) {
        print_prompt();
        read_command(&command, &params);
        x = fork();

        if (x == 0) { // we are the child process
            exec(command, params);
        } else { // we are the parent process
            wait(&status);
        }
    }
}
```

Encore des appels système

D'autres exemples, qu'on reverra en TP :

`exec(filename)` charger un autre programme (exécutable)
dans mon processus

`sleep(int num)` suspendre l'exécution de mon processus
pendant `num` secondes

`wait(...)` «attendre» qu'un de mes processus enfants ait
terminé son exécution

`getppid()` connaître le PID de son processus parent

`open()`, `read()`, `write()` accéder aux fichiers

À retenir

Architecture

- cycle de Von Neumann, MMIO, DMA, interruptions
- CPU avec *dual-mode operation* : mode restreint vs privilégié
- instruction TRAP pour lever une interruption

Noyau

- l'ensemble des routines de traitement d'interruption (ISR)
 - en particulier le *syscall dispatcher*
- et des fonctions appelées par les ISR
 - en particuliers les *drivers* et les implems des syscalls

Processus

- une «machine virtuelle» offerte aux applications
- vue simplifiée et restreinte de l'architecture

Appels système

- interface entre les processus et le noyau
- accessibles via des fonctions de bibliothèque

OS = noyau + bibliothèques + programmes utilitaires