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, algo
- recherche : numérique pour l'anthropocène, logiciel soutenable

Objectifs de ce cours

- Comprendre les «concepts clés» des systèmes d'exploitation
  - quel est le problème ? pourquoi se pose-t-il ? toujours ?
  - quelle sont la/les solutions ? pourquoi ça marche ?
  - ▶ prenez des notes en cours !
- Pratiquer leur usage
  - TP de programmation en C sous Linux (4×2h)
  - TD sur papier (3×2h, dont 1 contrôle continu)
  - ▶ pas de CR ; prenez des notes aussi !

Ressources

- `http://moodle.insa-lyon.fr` > Informatique > IFA-3
  - ▶ vidéos et diapos ; sujets de TD et de TP ; annales d'examen
- Permanence en salle 208 tous les jeudi de 13h à 14h

Plan du cours

- Chap 1 Noyau, processus, appels système — 28/01
  - 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) — 24/02 à 8h

- Chap 4 Allocation dynamique
  - TP implémentation de `malloc()` et `free()`
- Chap 5 Concurrence et synchronisation
  - TD algorithmes concurrents avec mutex et moniteurs
  - TP programmation avec `pthreads`

Examen final (1h30, coeff 2) — 18/03

Évaluation

Contrôle «continu»

- sous forme de QCM papier (30 min, le 24/02)
- questions de compréhension et petits exercices
  - dont des questions sur les TD/TP
- sans documents sauf une feuille A4 recto-verso manuscrite
- plusieurs contrôles au fil de l'eau pendant le semestre
- anciens sujets sur Moodle

Examen final

- épreuve écrite de 1h30 le 18/03
- sans documents sauf une feuille A4 recto-verso manuscrite
- anciens sujets sur Moodle

Plan

Vous avez dit «Système d'exploitation» ?

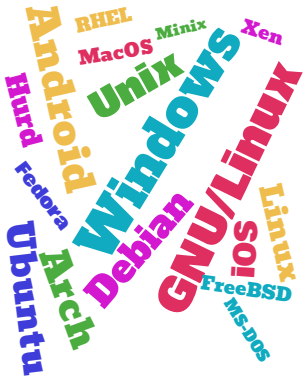

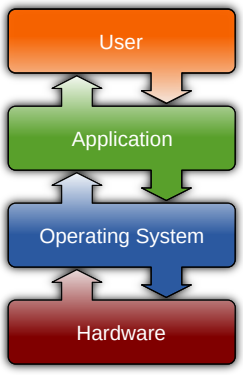

Quelques définitions

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»

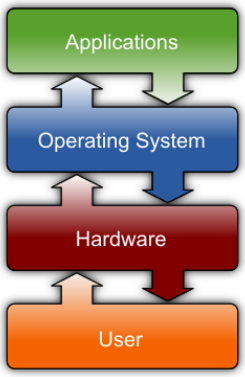

Rôle de l'OS : les deux fonctions essentielles

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

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

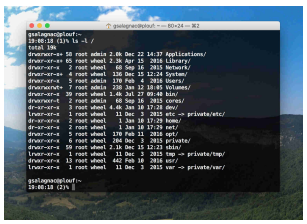

Attention : terminal (ou émulateur de terminal) ≠ shell !

Interface textuelle = Command-Line Interface = CLI

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

Différents types de shell : le bureau graphique

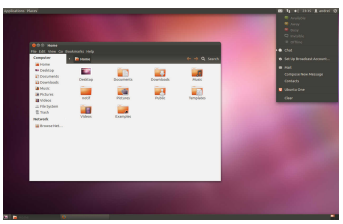

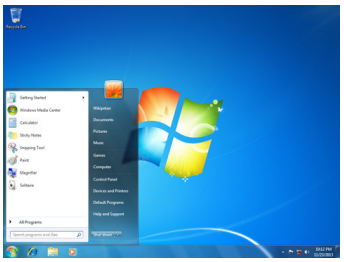

Interface graphique = Graphical User Interface = GUI

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

et encore : l'écran d'accueil du smartphone

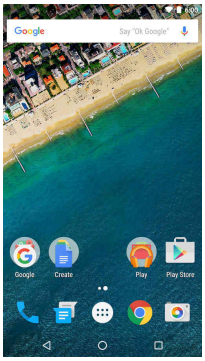

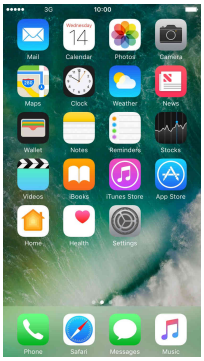

exemples : Android Launcher, Nova Launcher, Square Home...

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 !

votre 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

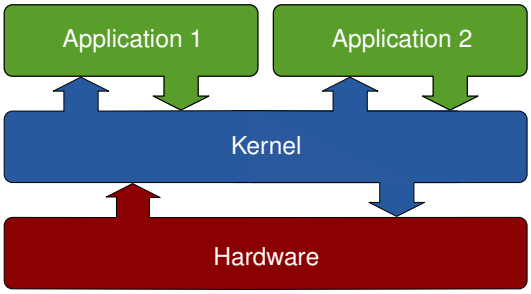

Définition : Noyau, ou en VO kernel
Le noyau c'est la partie de l'OS qui n'est pas une application

Plan

Vous avez dit «une interface plus jolie» ?

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

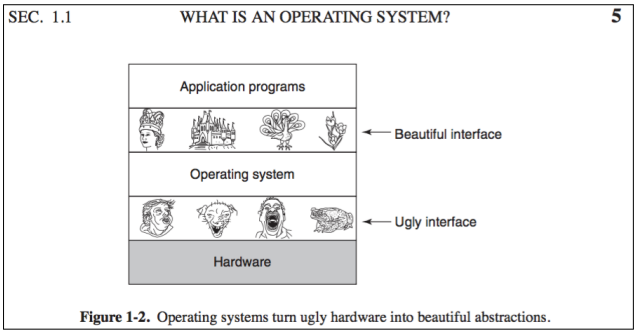

Figure 1-2. Operating systems turn ugly hardware into beautiful abstractions.

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

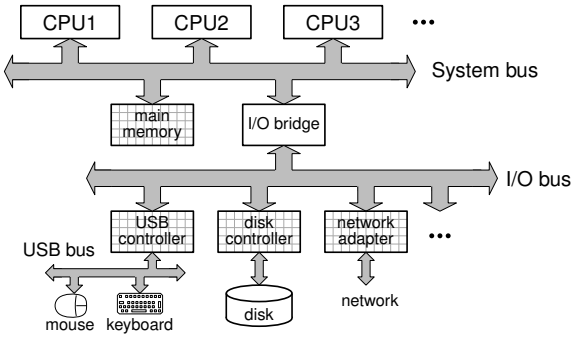

Langage de programmation vs langage machine

```
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»

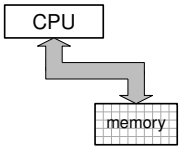

Rappel : le cycle de Von Neumann

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»

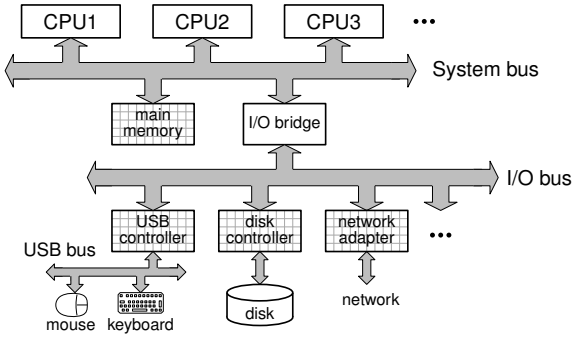

Définition : supervisor mode = ring 0 = kernel mode = privileged mode

- 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

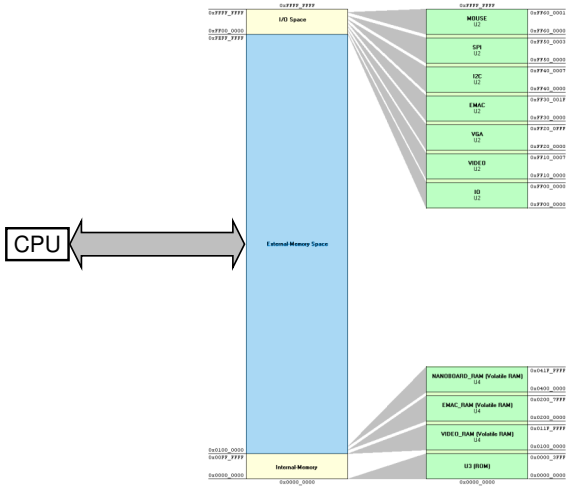

Exemple : lecture sur le disque 1/3 MMIO

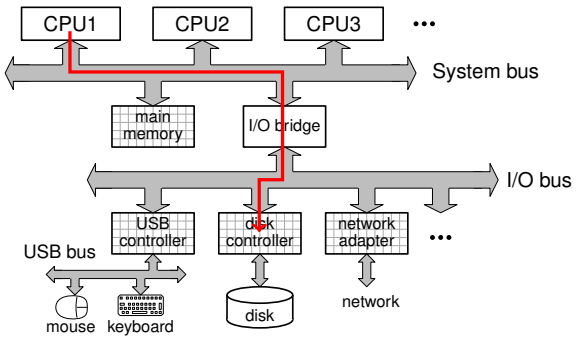

Pour initier l'opération, le CPU écrit une requête à l'addresse mémoire du contrôleur de disque.
requête = commande + nº de bloc + addr. mem destination

Exemple : lecture sur le disque 2/3 DMA

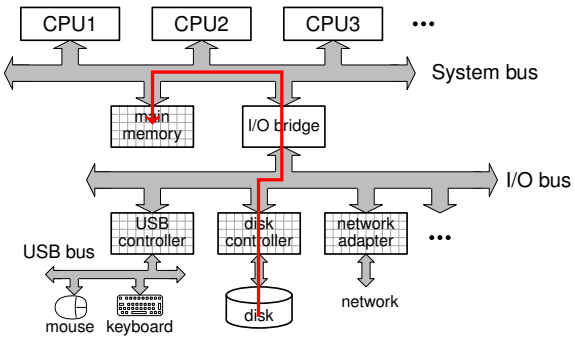

Le contrôleur de disque lit le secteur demandé et transfère les données directement en mémoire vive à l'adresse voulue : c'est un transfert DMA (Direct Memory Access)

Exemple : lecture sur le disque 3/3 IRQ

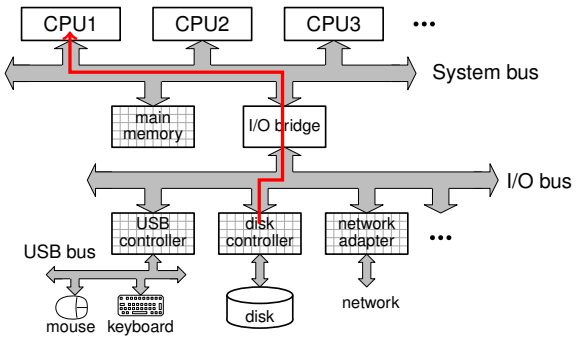

À la fin du transfert DMA, le contrôleur du périphérique notifie le CPU en lui envoyant une Requête d'Interruption (IRQ)

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

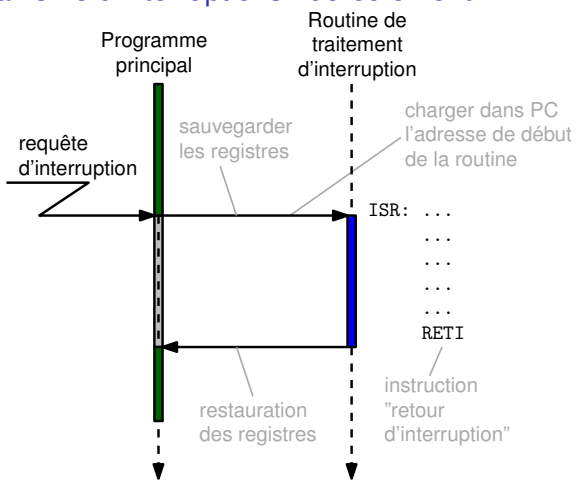

Mécanisme d'interruptions : vocabulaire

- 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 occurence 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
  - aka *Programmable interval 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

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

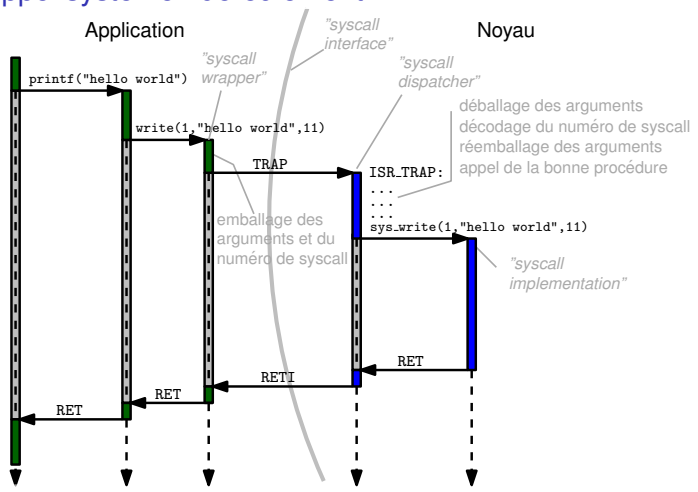

Appel système : langage machine

```
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    $0xfffffffffffff000,%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    $0xfffffffffffff000,%rax
  4107ba:       77 54                   ja     410810 <__libc_write+0x70>
  4107bc:       c3                      ret
```


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

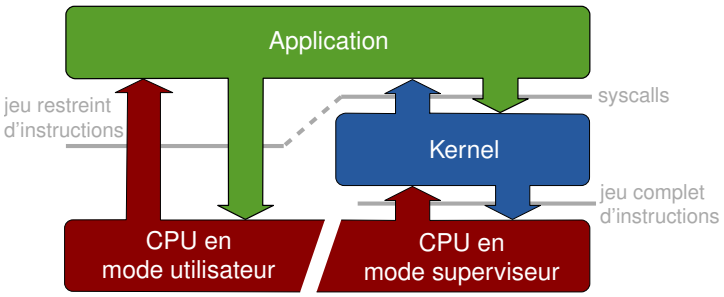

- code applicatif exécuté par CPU en mode utilisateur
- pour faire appel au noyau : interface des appels système

Positionnement de l'OS

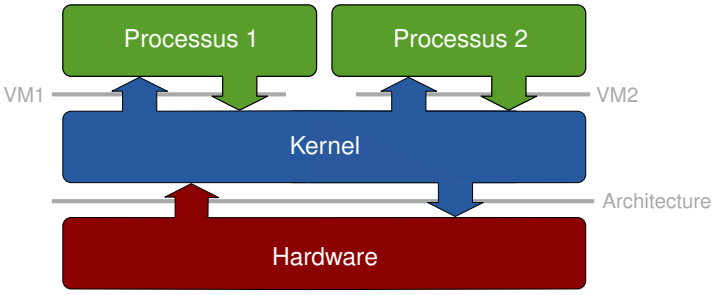

- chaque application qui s'exécute est un processus userland
- le noyau virtualise et arbitre les accès au matériel

Plan

Appels système : exemples

EXAMPLES OF WINDOWS AND UNIX SYSTEM CALLS

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

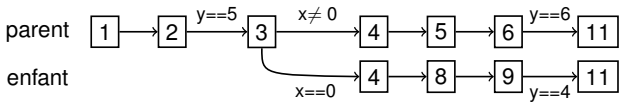

Mon premier interpréteur de commandes

```
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