Introduction aux systèmes d'exploitation (IF218)

Basé sur les cours de David Mazières (Stanford) et Arnaud Legrand (IMAG)

Ludovic Courtès [1]

ENSEIRB-MATMÉCA, septembre–octobre 2015

1. ludovic.courtes@inria.fr

Outline

Plan

Plan

Objectifs du cours

- introduction aux systèmes d'exploitation
  - on en utilise tous les jours
  - comprendre le fonctionnement d'un SE aide à programmer
- couvrir des concepts importants
  - concurrence, gestion mémoire, entrées/sorties, protection
  - notions de conception d'un SE : architecture, compromis
- un sujet vaste et passionnant !

Organisation du cours

- 3 séances de 4h (27 et 25 sept. ; 1er oct. 2015)
  - introduction aux systèmes d'exploitation
  - fils d'exécutions (*threads*) et processus
  - gestion de la mémoire virtuelle
- examen de cours (1er octobre 2015)
- suite des cours/TP/TD : programmation système
  - interface de programmation du système d'exploitation (POSIX)

Plan

Couche entre matériel et applications

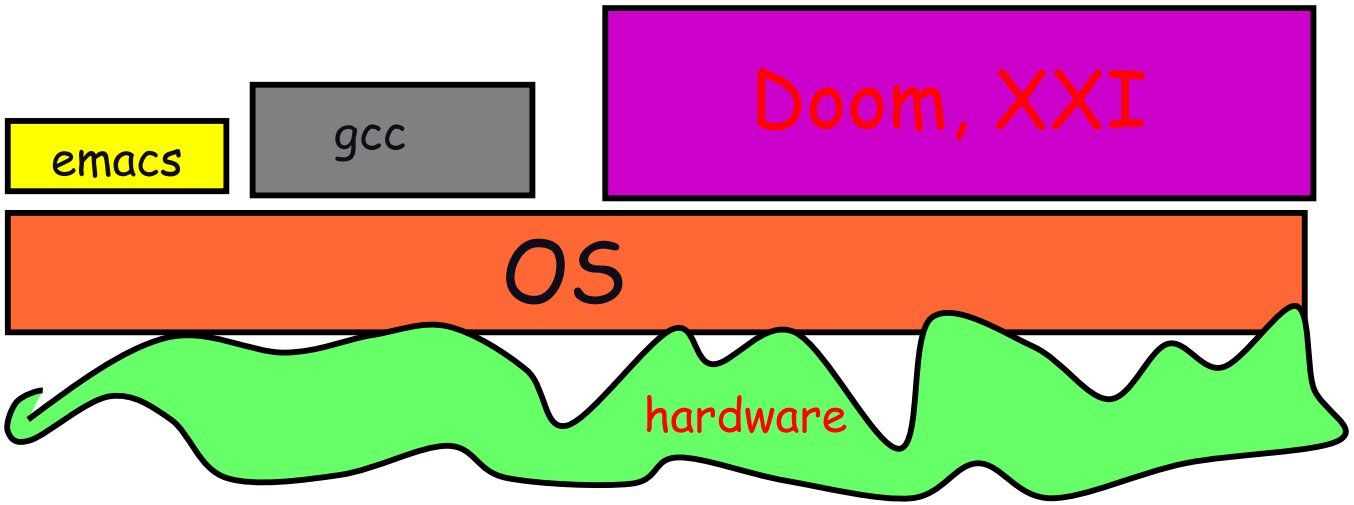

- rend le matériel utilisable
- fournit des abstractions aux applications
  - cache les détails du matériel
  - accède au matériel avec des moyens bas niveau
- protège les applications/utilisateurs les uns des autres

Pourquoi s'intéresser aux systèmes d'exploitation ?

- un problème réglé ?
  - oui : quelques SE mûrs utilisés par tous
  - non : questions ouvertes
    - programmes malintentionnés
    - extensibilité
    - adaptation à d'autres applications ou "machines"
- le SE est une fondation
  - pour la gestion des ressources
  - pour la sûreté de fonctionnement (sécurité, tolérance aux fautes, etc.)
- les problèmes de SE se retrouvent ailleurs
  - supports de langages de programmation
  - navigateurs web (?)

Système d'exploitation primitif

- limité à l'abstraction du matériel, pas de protection
- hypothèses simplificatrices
  - un seul programme s'exécute à chaque instant
  - les programmes n'ont pas de bugs, sont bien intentionnés
- pauvre utilisation des ressources matérielles
- exemple : MS DOS, systèmes critiques dédiés

Multi-tâche (« multi-programmation »)

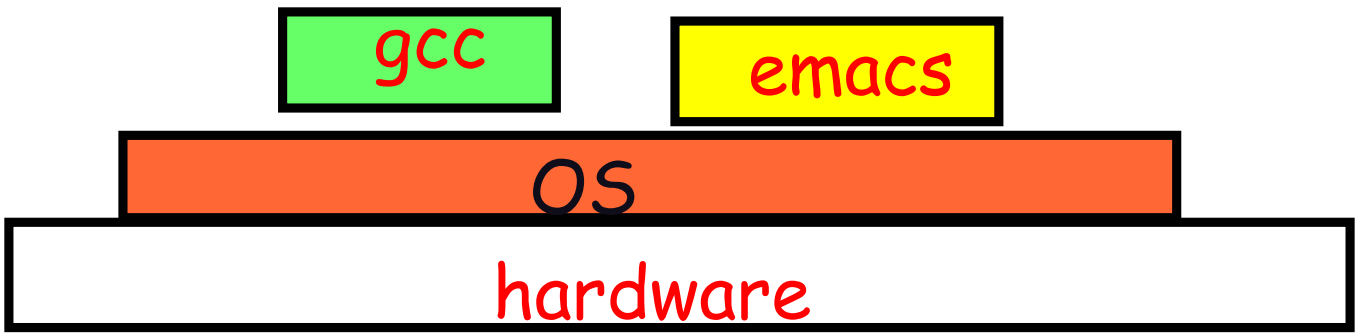

- plusieurs programmes s'exécutent en même temps
- quand un programme attend (le disque, le réseau, etc.), un autre tourne

Et si un programme se comporte mal ?

- exemples
  - entre dans une boucle infinie
  - accède à des endroits de la mémoire « où il ne fallait pas »
  - essaye de « faire tomber » les autres programmes
- solution : protection, isolation
  - préemption : reprend le temps CPU ou la mémoire physique allouée
  - protection mémoire : mémoire des autres programme inaccessibles
  - moindre autorité : un programme ne peut accéder qu'aux ressources explicitement données (idéalement. . .)

Multi-utilisateur

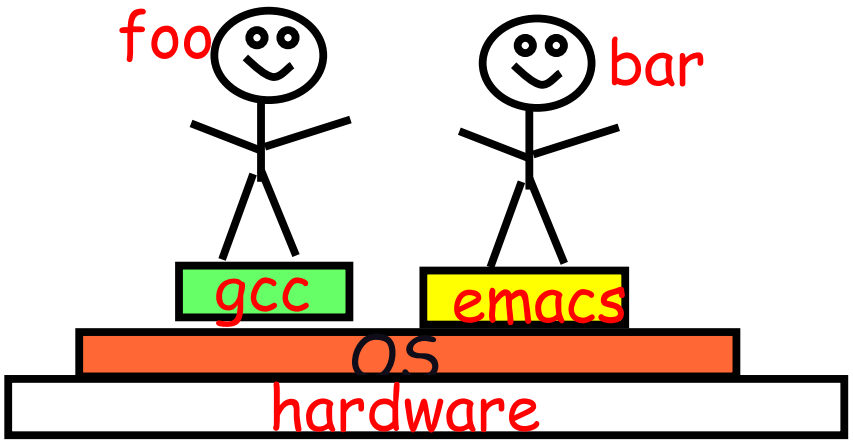

- utilisateurs mutuellement suspicieux
  - solution : protection, isolation, comme pour les applications
- utilisation efficace des ressources
  - ordonnancement des ressources entre utilisateurs
  - donner les ressources à ceux qui en ont vraiment besoin
- ce qui peut mal se passer
  - utilisateurs trop gloutons (besoin d'une politique)
  - demande mémoire trop grande (besoin de virtualisation)

Plan

Plan

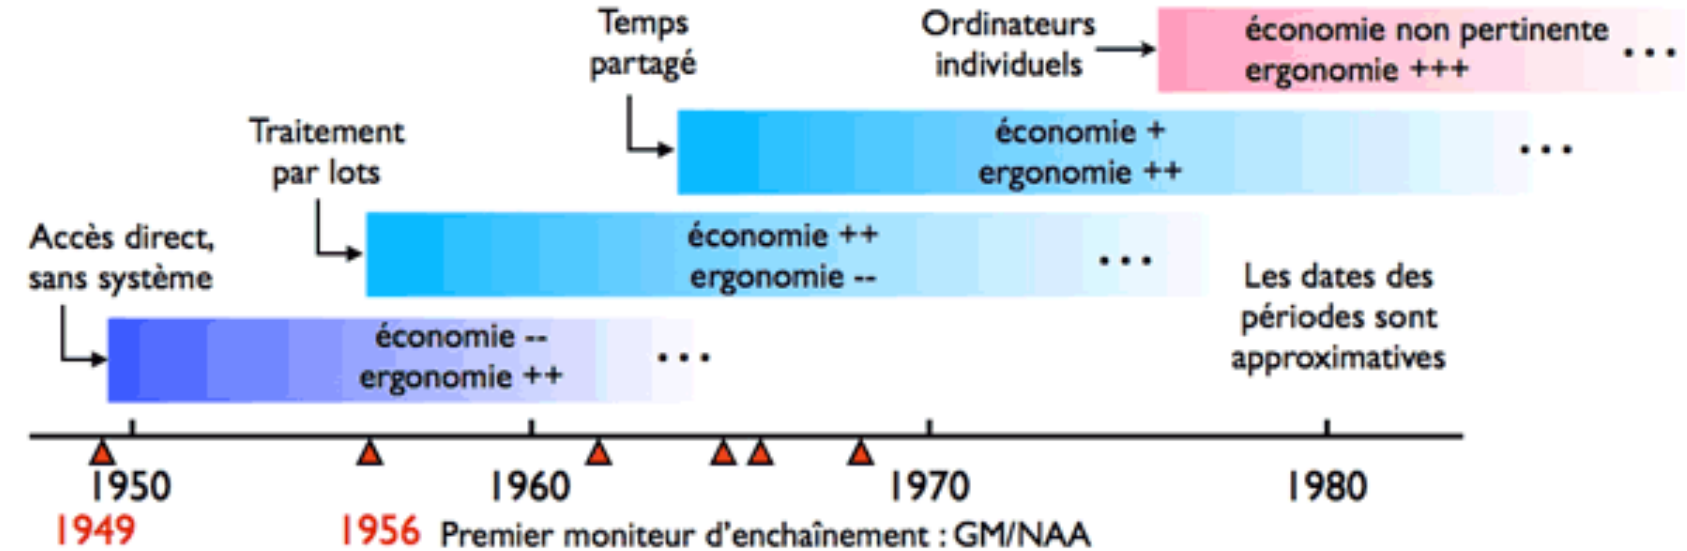

1949 Premiers ordinateurs à programme enregistré (EDSAC, Manchester Mk1)

1956 Premier moniteur d'enchaînement : GM/NAA

1961 Premier système en temps partagé : CTSS

1964 OS/360, moniteur d'enchaînement sur IBM 360

1965 Multics, fondation des systèmes modernes

1969 Première version d'Unix (simplification de Multics)

http://interstices.info/jcms/nn_72288/la-naissance-des-systemes-d-exploitation

Plan

Services fournis par un système d'exploitation

- gestion de la mémoire virtuelle
- fils d'exécution (*threads*) et processus
- stockage à long terme (système de fichiers)
- protocoles réseau (TCP, IP, etc.)
- interface de haut niveau au matériel
  - pilotes de disque dur, de carte son, de carte réseau, de périphériques USB, etc.
- ...

Protection

- seul le noyau du SE peut accéder directement au matériel
  - tourne en mode CPU privilégié
  - protège des applications malintentionnés
  - protège des applications buggées
  - espace noyau (*kernel space*)
- les applications sont non privilégiées
  - font appel au noyau pour accéder au matériel
  - espace utilisateur (*user space*)
- ordonnancement des ressources matérielles, préemption
  - donne une ressource, la reprend si besoin

Structure typique d'un SE

à base de noyau monolitique vs. micro-noyau

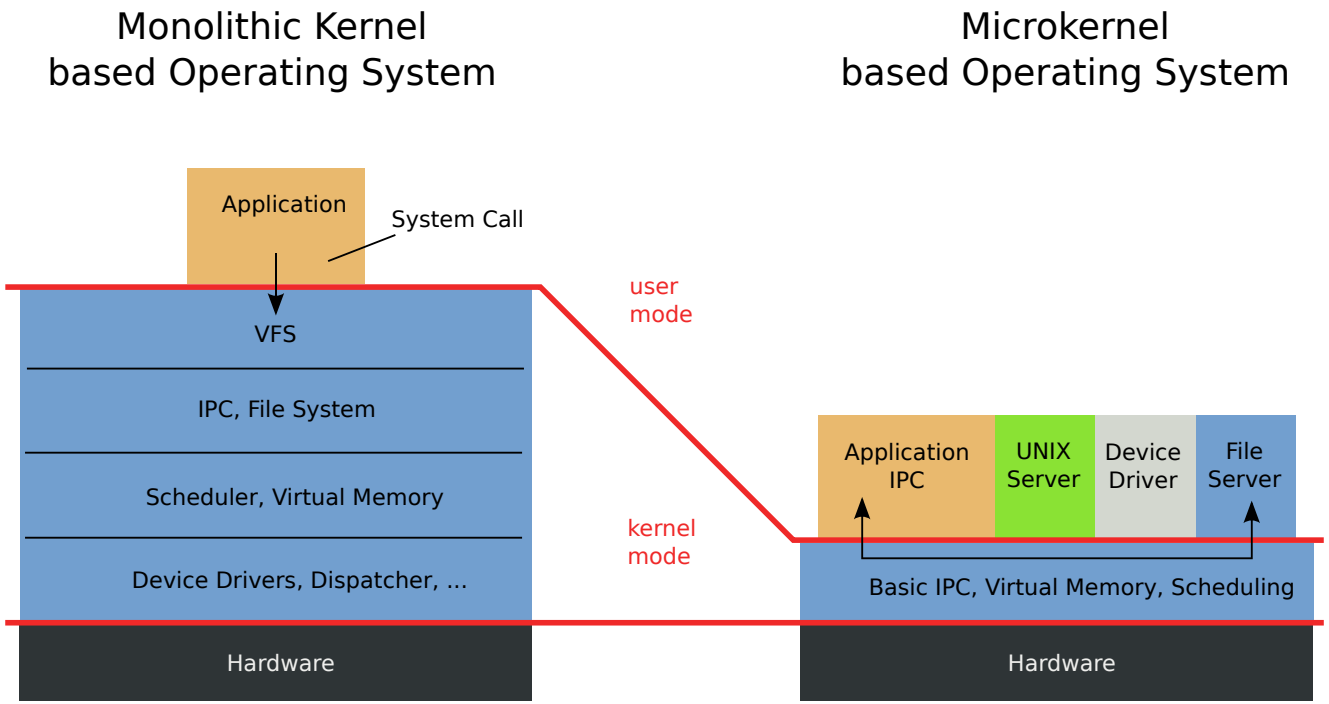

- GNU/Linux, Android, variantes BSD, Solaris, Windows, etc.
- GNU/Hurd, MINIX, QNX, INTEGRITY, Symbian, MacOS X

Noyau monolitique vs. micro-noyau + serveurs

un débat classique...

- noyau monolithique
  - toutes les fonctionnalités sont intimement liées
  - vue globale de l'utilisation des ressources : facilite l'ordonnancement
  - séparation nette utilisateur/noyau
  - difficulté d'étendre les fonctionnalités (code noyau difficile à écrire ; nouvelle fonctionnalité = `reboot`)
- micro-noyau + serveurs
  - fonctionnalités séparées dans des « serveurs » (processus)
  - conséquences d'un bug isolées
  - extensible : les serveurs sont des « programmes normaux »
  - ordonnancement & imputabilité des ressources plus difficiles

L'application parle au SE : « appels systèmes »

noyau monolitique

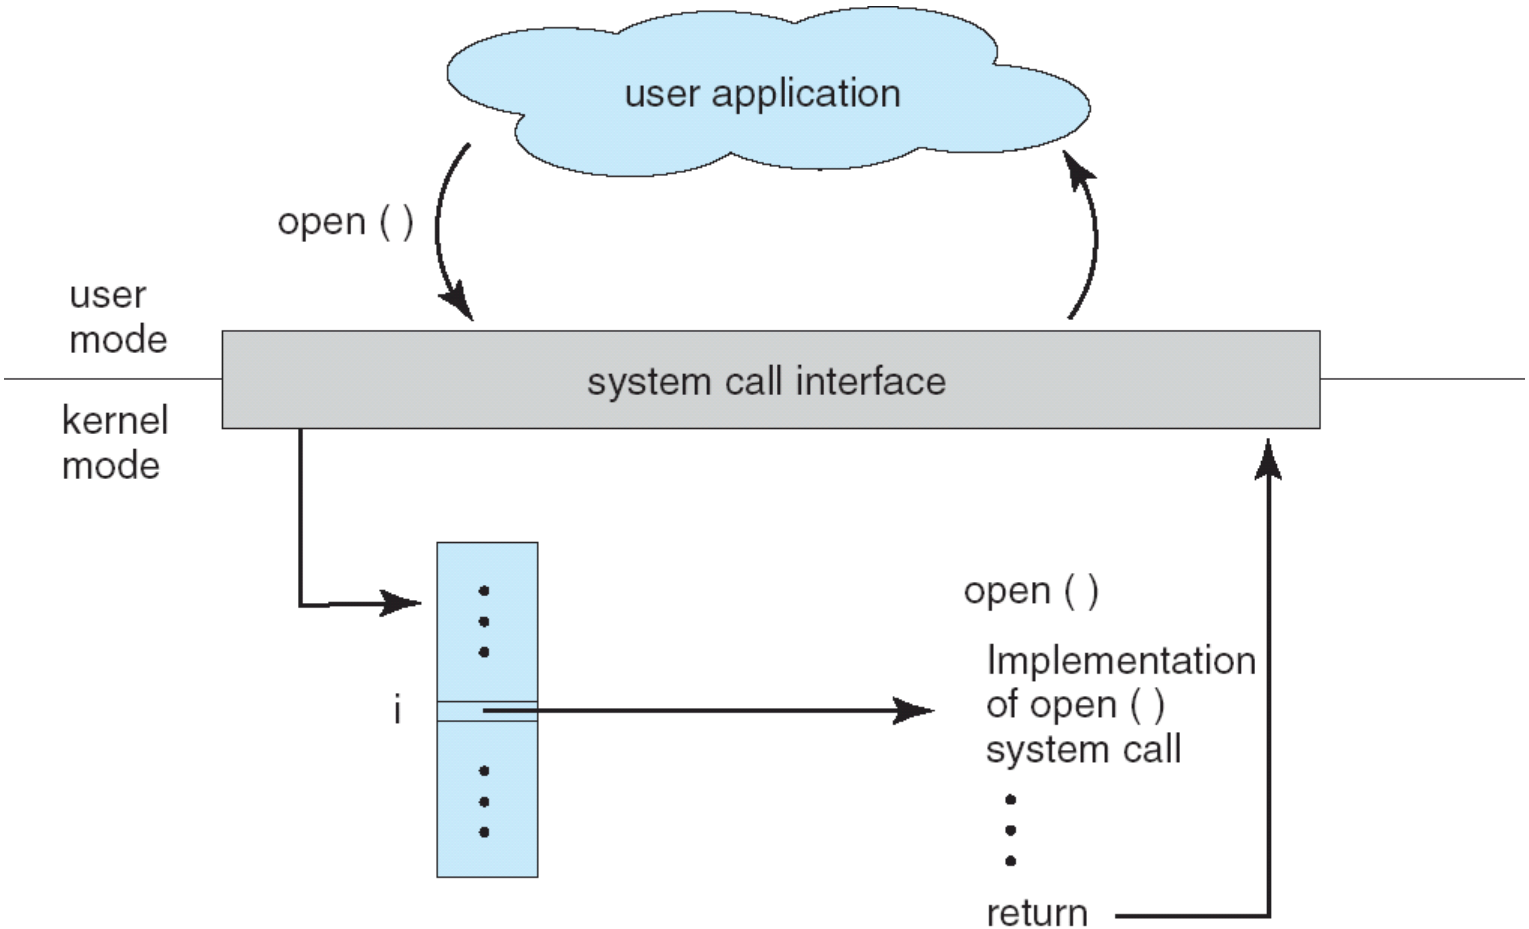

- services fournis par le noyau

L'application parle au SE : comm. inter-processus

système multi-serveur à base de micro-noyau

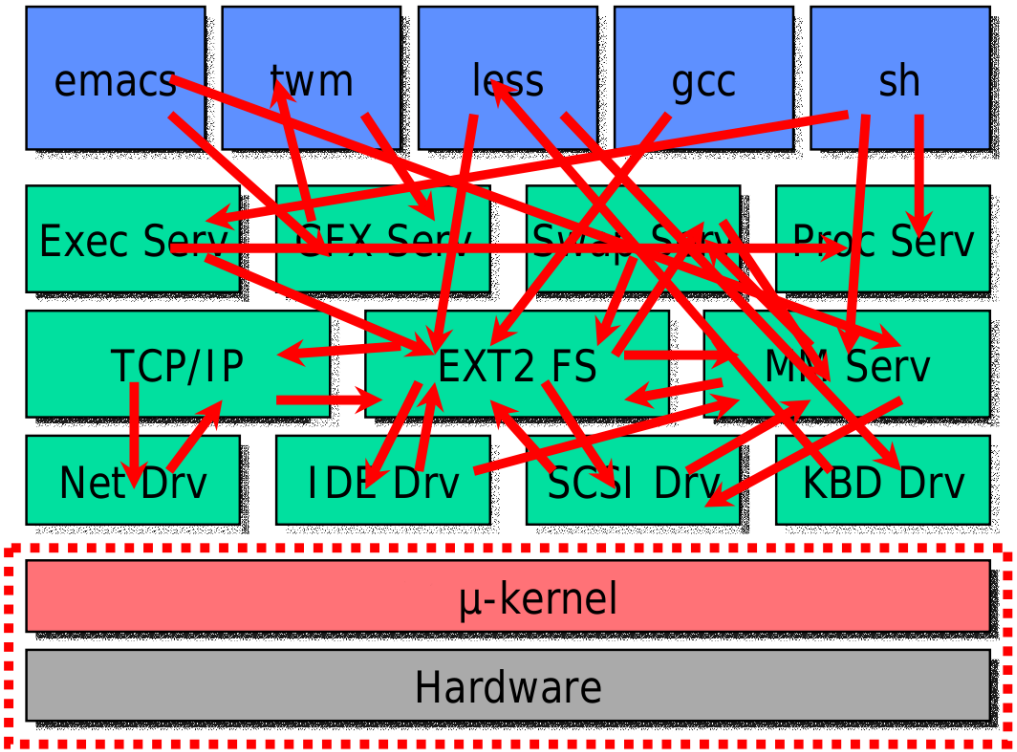

- services fournis par des "serveurs" en espace utilisateur
  - communication inter-processus (IPC) entre applications et serveurs

Exemples d'appels système POSIX (Unix, Windows, etc.)

- `void *sbrk (intptr_t increment);`
  - ajoute `increment` octets de mémoire accessible au programme
- `int open (const char *chemin, int drapeaux);`
  - ouvre le fichier situé à `chemin` (ex. : `cours.pdf`)
  - renvoie un *descripteur de fichiers*
  - ou renvoie une erreur (entier négatif)
- `ssize_t write (int desc_fich, const void *tampon, size_t combien);`
  - écrit au plus `combien` octets depuis `tampon` dans `desc_fich`
  - retourne le nombre d'octets effectivement écrits
  - ou retourne une erreur (entier négatif)

Appels systèmes, vu de l'application

- l'application utilise typiquement des fonctions de plus haut niveau
  - fonction `printf` vs. appel système `write`
  - fonction `malloc` vs. appel système `sbrk`

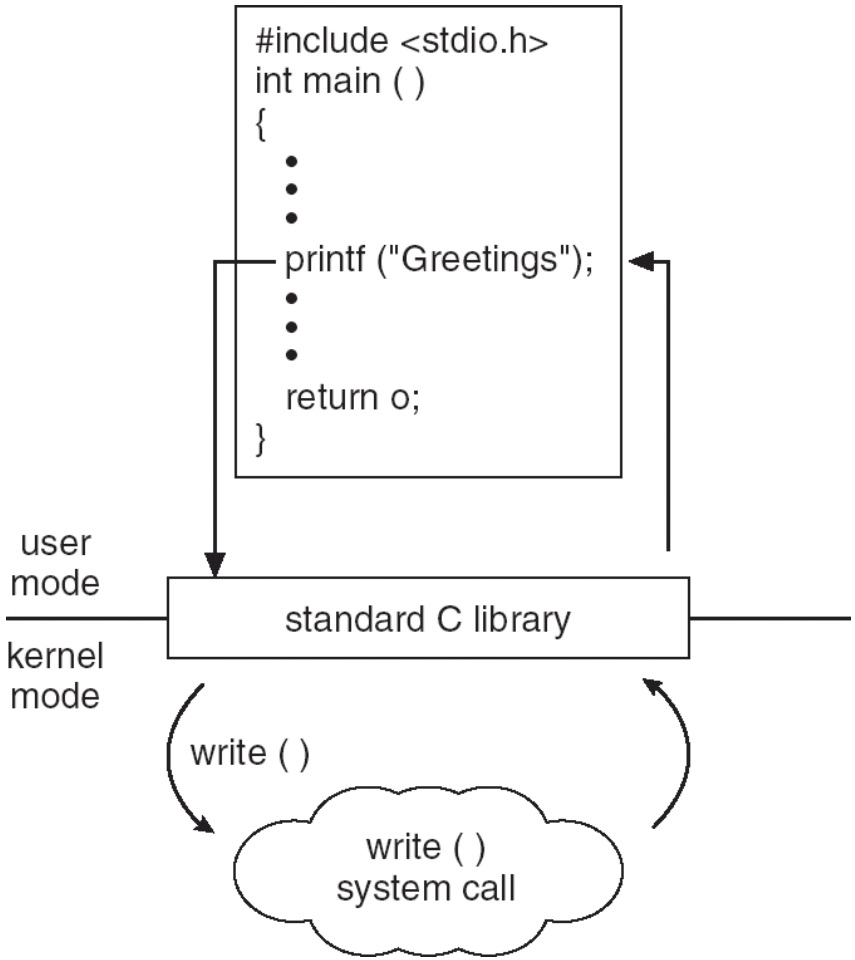

Plan

Ressources matérielles

- donner à chaque application l'impression de disposer seule de la ressource
  - chaque appli dispose de « tout le CPU pour elle »
  - chaque appli dispose de « toute la mémoire pour elle »
- garantir l'isolation entre applications par défaut
  - les calculs de l'appli A n'interfèrent pas sur ceux de l'appli B
  - les données de l'appli A ne sont pas visibles de B
- permettre le partage/l'échange
  - mémoire partagée entre deux applications

Ressources logicielles

- donner à chaque appli l'accès à des ressources « logicielles »
  - stockage persistent, p. ex., fichier
  - connexion TCP/IP
- garantir l'isolation
  - l'appli A n'accède qu'aux fichiers auxquels elle a le droit (+/-)
  - la connexion SSH de A n'interfère pas avec la connexion HTTP de B
- permettre le partage/l'échange
  - fichier partagé entre deux applications
  - connexion ouverte passée d'une application à une autre

Contextes systèmes

- contexte d'une application/processus utilisateur qui s'exécute
- contexte noyau d'une application
  - code exécuté dans le noyau à l'intention d'un processus (p. ex. un appel système)
- contexte noyau non associé à une application
  - gestion des interruptions matérielles
  - interruptions de la minuterie (*timer*)
  - tâches différées du noyau (« softirqs » et « tasklets » dans Linux)
- changement de contexte

Transitions entre contextes

- utilisateur vers noyau
  - appel système
  - défaut de page (*page fault*)
  - interruption temporelle, matérielle

Ordonnancement des ressources

- choix basé sur le comportement observé des applications
  - l'application n'est pas consultée
  - le noyau « devine » ce qu'essaye de faire l'application
- le SE a des heuristiques pour « bien ordonnancer » les ressources pour une « application typique »
  - gestion de la mémoire virtuelle constamment ajustée (Linux)
  - différents ordonnanceurs CPU, entrées/sorties (Linux)
- allocation de ressources transparente/opaque pour l'application
  - transparente : l'application ne se soucie de rien
  - opaque : l'application ne peut pas savoir ce que va chercher à faire le SE
  - parfois, interfaces pour désactiver/guider l'intelligence du SE (`O_DIRECT`, `mlock`, `madvise`, `pthread_setaffinity`)

Aperçu

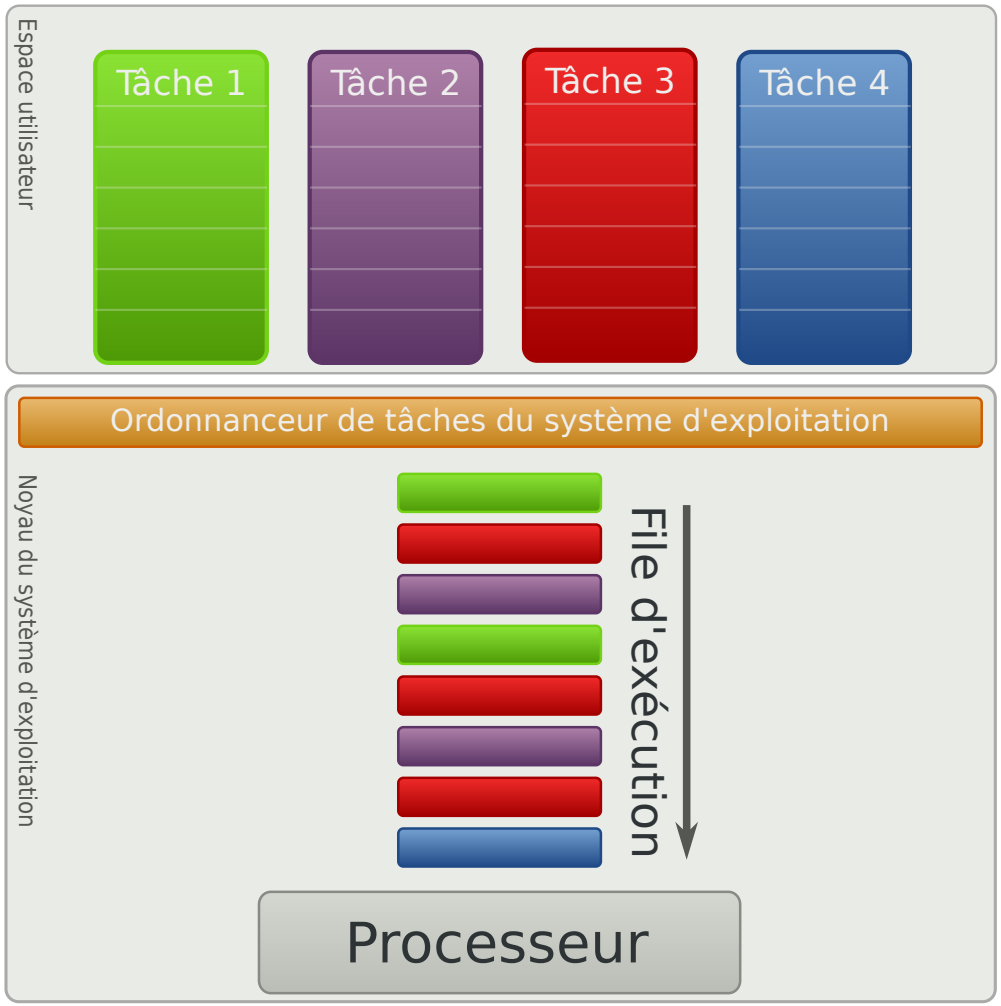
Espace utilisateur
Tâche 1
Tâche 2
Tâche 3
Tâche 4
Ordonnanceur de tâches du système d'exploitation
Noyau du système d'exploitation
File d'exécution
Processeur

Ordonnancement et préemption CPU

Définitions

- fil d'exécution ou *thread*
  - contexte d'exécution de code utilisateur
  - « unité de traitement » ordonnancée par le noyau

Ordonnancement et préemption CPU

- pour partager le CPU entre applications
  - chaque appli se voit donnée du temps de calcul
  - chaque appli a l'impression d'être seule sur le CPU
  - ex. : une appli ne monopolise pas le CPU avec une boucle infinie
- déroulement
  - interruption de la minuterie, p. ex., toutes les 10s
  - le noyau prend la main (*contexte noyau*)
  - installe le contexte utilisateur d'une appli
  - passe la main à cette appli

Gestion de la mémoire

Aperçu

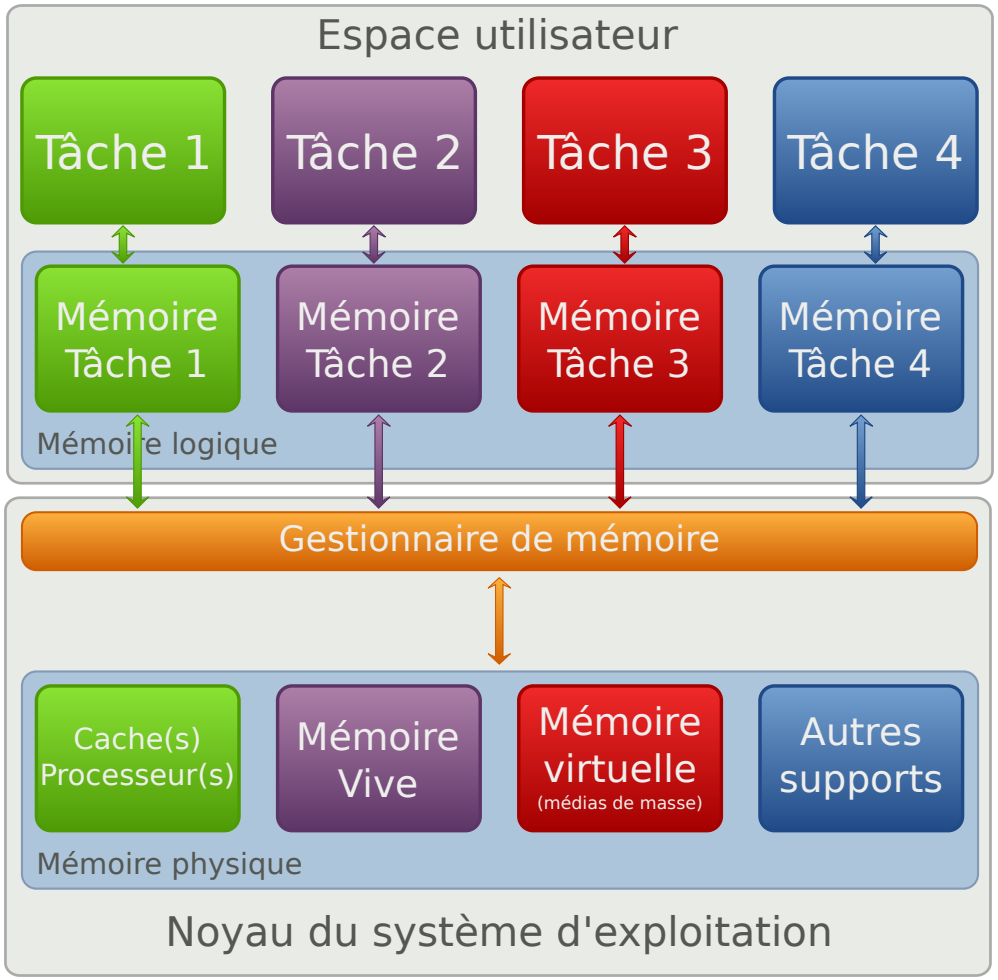

Ordonnancement mémoire

Définitions

- adresse physique : adresse dans la mémoire vive (la « vraie » mémoire)
- adresse virtuelle : utilisées par un programme pour désigner « sa » mémoire
- projection mémoire (*mapping*) : établissement d'une correspondance entre un intervalle d'adresses virtuelles et « quelque chose » (ex. : mémoire physique)
- traduction d'adresse : traduction virtuelle/physique
  - fait par le matériel, la MMU (*memory management unit*)
- espace d'adressage : ensemble d'adresses de mémoire virtuelle qu'un programme peut désigner
- processus : *thread(s)* + espace d'adressage

Ordonnancement et « préemption » mémoire

- pour partager la mémoire physique entre applications
  - chaque appli a accès a « de la mémoire »
  - tous ses accès mémoires sont contrôlés par le matériel/noyau
  - un programme ne peut désigner que la mémoire visible dans son espace d'adressage
  - le SE ordonnance la mémoire physique entre applis (envoie sur disque la mémoire inutilisée, alloue paresseusement, etc.)
- déroulement
  - le noyau créée un espace d'adressage pour chaque appli
  - l'appli demande au noyau la projection de mémoire physique dans son E.A.
  - le noyau maintient des tables de traduction d'adresses pour chaque E.A.

Bénéfices de la protection mémoire

- Firefox ne peut pas lire le mot de passe dans la mémoire de Thunderbird (*sécurité-immunité*)
- un pointeur fou dans un programme n'affecte pas les autres (*tolérance aux fautes*)
- mais un pointeur fou dans le noyau...

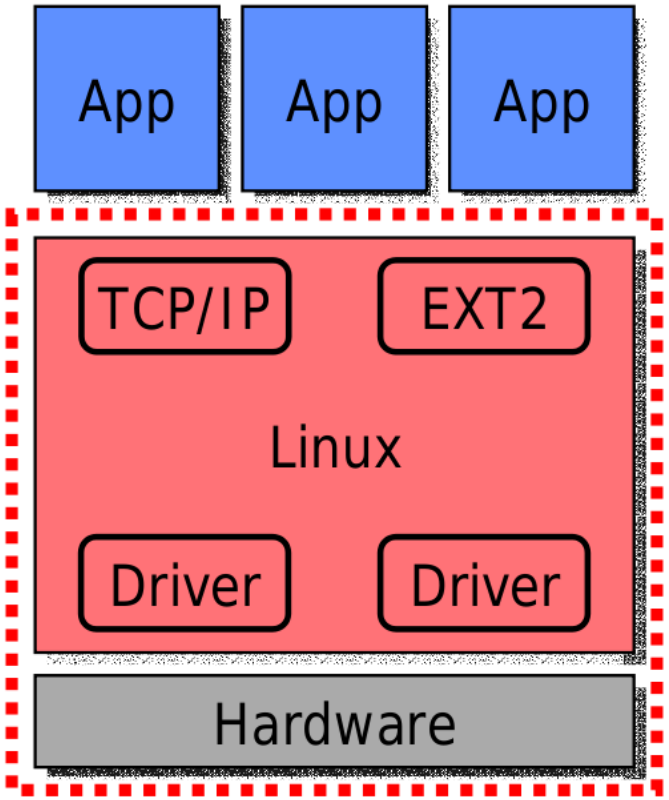

Bénéfices de la protection mémoire

- Firefox ne peut pas lire le mot de passe dans la mémoire de Thunderbird (*sécurité-immunité*)
- un pointeur fou dans un programme n'affecte pas les autres (*tolérance aux fautes*)
- mais un pointeur fou dans le noyau...

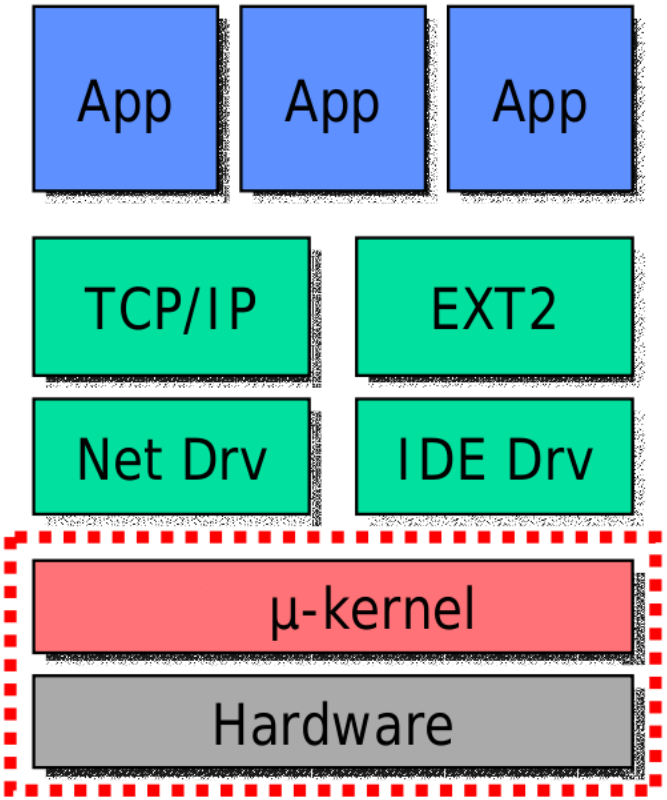

Remarque : Protection mémoire par le langage

- isolation mémoire au sein d'un même espace d'adressage
  - avec un langage de prog. à gestion de la mémoire automatique (Lisp/Scheme, Python, Java, etc.)
  - applications toutes écrites dans ce langage (ou avec langage intermédiaire commun)
  - un seul espace d'adressage
- exemples de SE « basé langage »
  - Microsoft Singularity (C#), JNode (Java), Genera (Lisp), Inferno (Limbo)
- *Cette approche n'est pas étudiée dans ce cours.*

Contrôle de la consommation de ressources

```
int main () {
  /* créée des processus */
  while (1)
    fork ();
}
```

```
int main () {
  /* alloue de la mémoire */
  while (1)
    malloc (1234);
}
```

```
# http://lwn.net/Articles/524301/
while true; do mkdir x; cd x; done
```

- quotas (processus fils, taille du tas, etc.)
- *out-of-memory killer* (Linux)
  - invoqué en cas de pénurie de mémoire
  - termine la tâche estimée la plus "mauvaise"
- ?

Plan

Propriétés utiles à exploiter

- biais
  - 80% du temps pris par 20% du code
  - 10% de la mémoire absorbe 90% des références
- prédictions basées sur l'historique (*localité temporelle*)
  - ex. : pré-charger la suite d'un fichier
  - ex. : évincer du cache les données pas accédées récemment

Partage de code entre applications

- exemples
  - 99% des programmes utilisent la bibliothèque C (libc)
  - beaucoup utilisent la bibliothèque GTK+ (interfaces graphiques)
  - le code binaire de ces bibliothèques est le même pour tous (code indépendant de la position, *PIC*)
- idée : ne charger qu'une seule fois le code de ces bibliothèques
  - pris en charge par l'éditeur de liens dynamique, `ld.so` (espace utilisateur)
  - tire partie de la gestion de la mémoire virtuelle
- l'édition de liens dynamique est un sujet à part entière...

Plan

Objectifs d'un système d'exploitation

- fournir une abstraction du matériel
- permettre le partage sans interférence des ressources matérielles/logicielles
- permettre la coopération choisie entre applications
- utiliser efficacement le matériel

Plan

Plan

Au quotidien

- processus = instance d'un programme qui s'exécute
- un SE moderne peut faire tourner plusieurs processus "simultanément"
- exemples de processus pouvant s'exécuter simultanément
  - `gcc foo.c` — compilateur qui compile `foo.c`
  - `gcc chbouib.c` — compilateur qui compile `chbouib.c`
  - `emacs` — éditeur de texte (et courrier électronique, etc.)
  - `firefox` — navigateur web
- non-exemples : mis en œuvre par un seul processus
  - plusieurs fenêtres Emacs
  - plusieurs fenêtres Firefox
- pourquoi des processus ?
  - meilleure utilisation du CPU
  - tâches concurrentes

Du fil d'exécution au processus

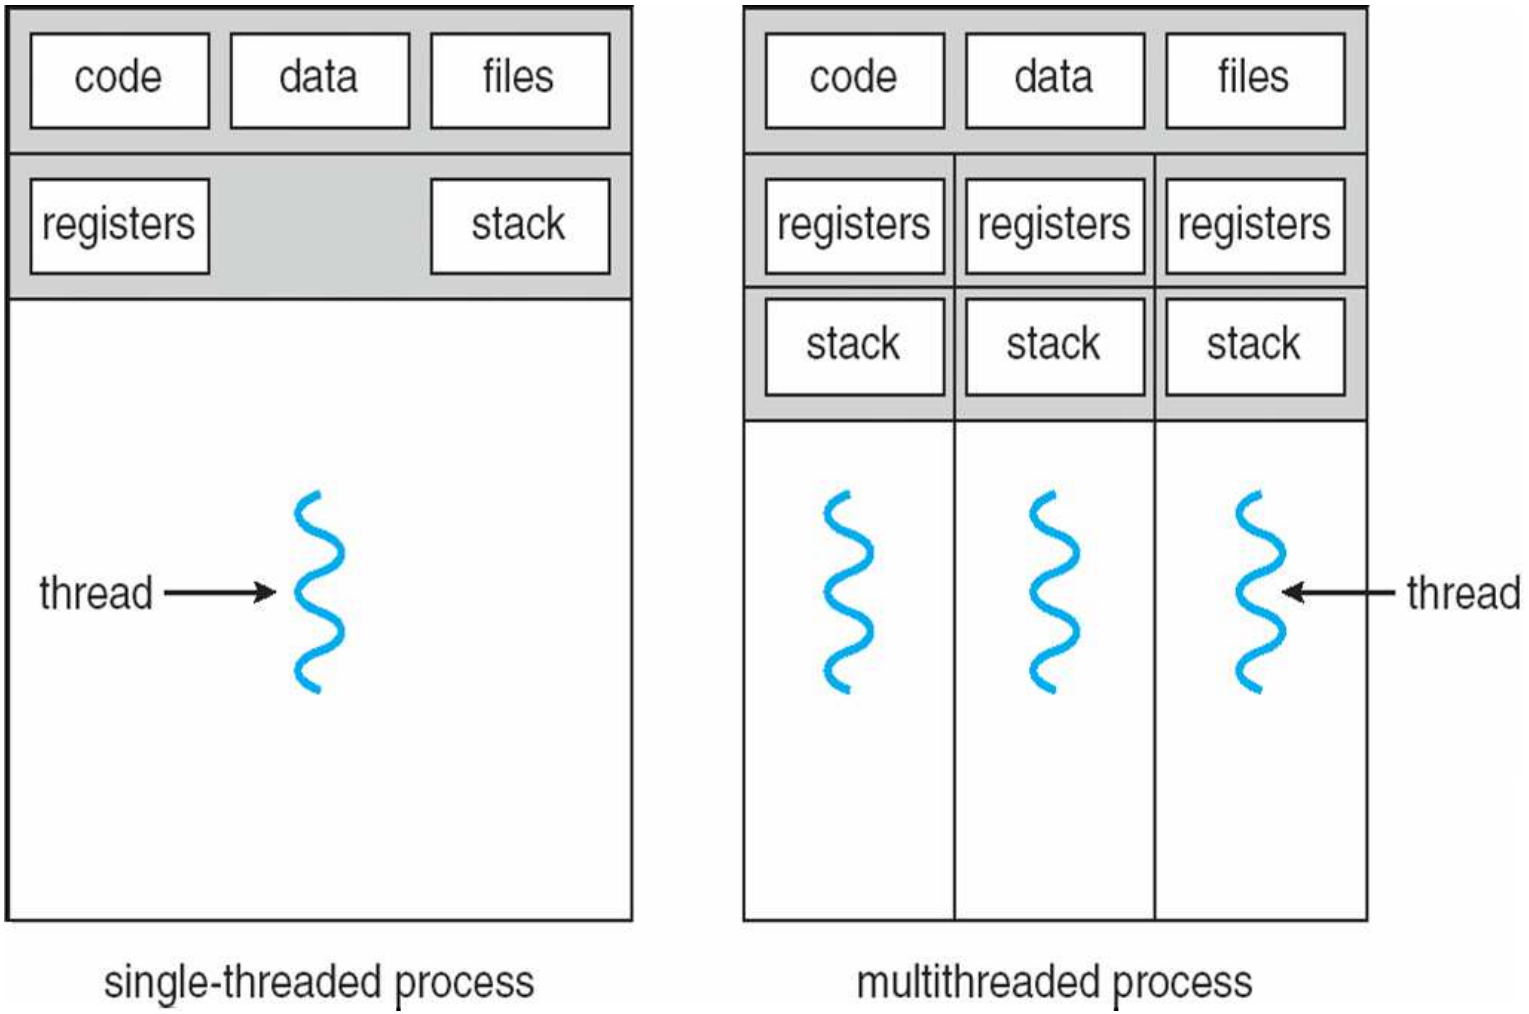

Du fil d'exécution au processus

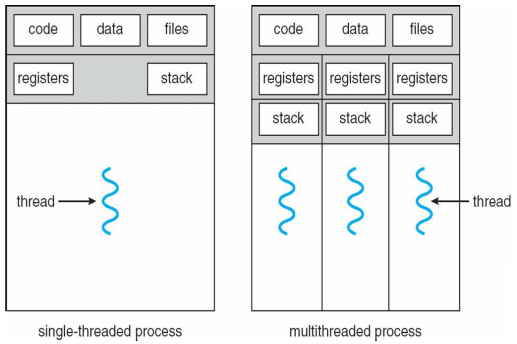

- fil d'exécution ou *thread*
  - contexte d'exécution de code utilisateur
  - « unité de traitement » ordonnancée par le noyau
- processus = thread(s) + espace d'adressage
  - protection mémoire entre processus
  - un processus peut contenir plusieurs *threads*
  - même environnement pour tous les threads d'un processus
    - même espace d'adressage (mémoire partagée)
    - mêmes descripteurs de fichiers

Choisir entre fil d'exécution et processus

- protection mémoire
  - les processus sont protégés entre eux, pas les *threads*
  - pour un langage à gestion automatique de la mémoire, cet argument est peu pertinent...
- performance
  - création de *threads* moins coûteuse que création de *processus*
  - communication entre *threads* moins coûteuse, plus simple
  - changement de contexte entre *threads* moins coûteux
- passage à l'échelle
  - plusieurs *threads* pour un programme permettent d'utiliser plusieurs cœurs
  - ex. : parallélisation des algorithmes internes au programme

Entrelacement de l'exécution des fils/processus

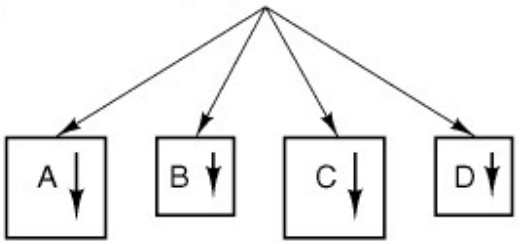

- conceptuellement : 4 programmes s'exécutent « en même temps »
  - 4 pointeurs d'instruction (ou *program counters*)
  - 4 piles, 4 jeux de registres, etc.
- en pratique : exécution entrelacée
  - le noyau/ordonnanceur reprend la main
  - installe la pile du fil/processus suivant
  - lui passe la main : changement de contexte

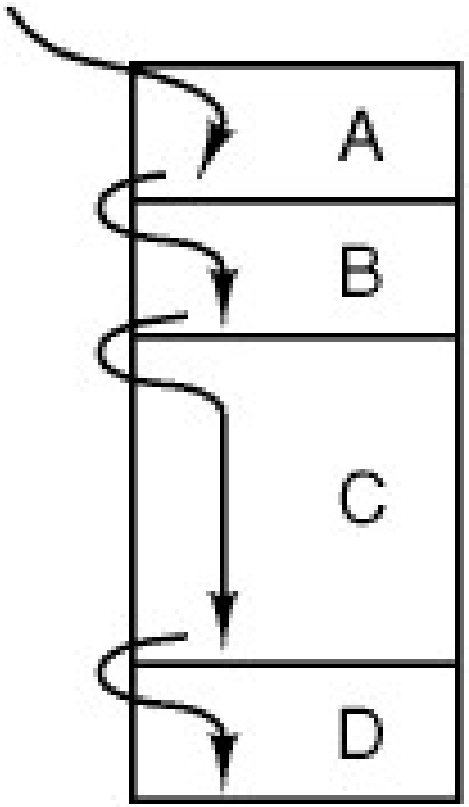

Concurrence vs. parallélisme

- concurrence
  - plusieurs fils d'exécution *progressent* en même temps
  - éventuellement exécution entrelacée, chacun son tour
- parallélisme
  - plusieurs fils d'exécution *s'exécutent* en même temps
  - exemple : sur un processeur multi-cœur
- en pratique :
  - les CPU modernes ont plusieurs cœurs
  - donc « vrai » parallélisme *et* concurrence

Avantages potentiels pour la performance

- améliore l'utilisation du CPU
  - recouvrement des attentes d'un processus par le calcul d'un autre
- réduit la latence
  - exécuter A puis B prend 100s

  - exécuter A et B de manière concurrente finit plus tôt

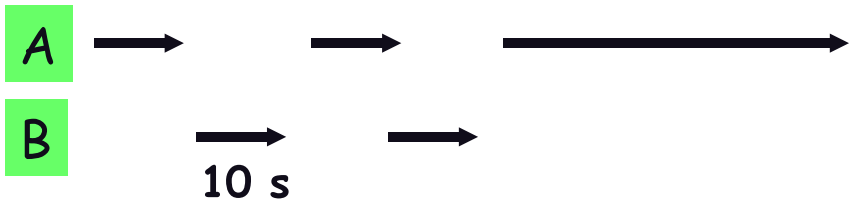

  - à supposer que A et B ne fassent pas que des calculs
  - ralentissement engendré par les changements de contexte quasi-négligeable

Interface POSIX pour manipuler les *threads*

- `int pthread_create (pthread_t *fil, pthread_attr_t *attr, void *(*entrée) (void *), void *arg)`
  - créée un nouveau fil d'exécution dans le processus courant
  - le nouveau fil a une nouvelle pile, mais le même environnement que le reste du processus
  - retourne 0 et renvoie son identifiant dans `fil`
  - l'exécution commence par l'appel `entrée (arg)`
- `int pthread_join (pthread_t fil, void **valeur_retour)`
  - attend la terminaison de `fil`
  - retourne dans `*valeur_retour` sa valeur de retour (pointeur)
- `void pthread_exit (void *valeur_retour)`
  - termine le fil courant avec `valeur_retour`

Exemple : Création et attente d'un fil d'exécution

```
#include <pthread.h>
static void *code_du_fil (void *arg) {
  static int result = 2;
  result += *(int *) arg;
  return &result;
}
int main (int argc, char *argv[]) {
  pthread_t fil; int x = 3; int *resultat;
  pthread_create (&fil, NULL, code_du_fil, &x);
  pthread_join (fil, &resultat);
  printf ("resultat : %i\n", *resultat); /* 5 */
  return *resultat;
}
```

Ce que voit un processus

- chaque processus a sa vue de la machine
  - son propre espace d'adressage
    - `(char *) 0x1234` différent dans chaque proc.
  - ses propres descripteurs de fichiers (fichiers ouverts, etc.)
    - descripteur de fichier 7 différent dans chaque processus
  - son « CPU à lui » (via le multitâche préemptif)
- modèle de programmation simple
  - gcc ne se soucie pas que `firefox` tourne

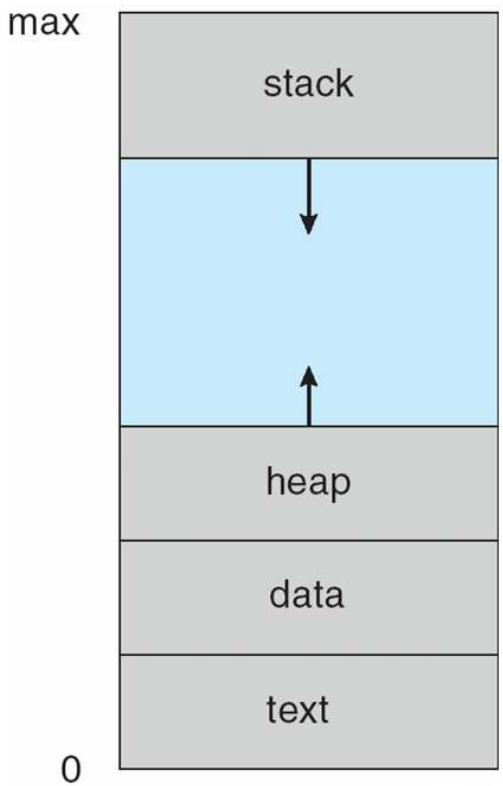

Interface Unix/POSIX pour manipuler les processus

- chaque processus identifié par un entier, le PID
- `pid_t fork (void)` : création de processus fils
  - créée un processus fils copie conforme du parent
  - le fils hérite des projections mémoire, mais *copy-on-write*
  - le fils hérite des descripteurs de fichier, etc.
  - le fils a un PID différent (`fork` retourne le PID du fils dans le parent, `0` dans le fils)
- `pid_t waitpid (pid_t pid, int *stat, int opt)` : attend la fin d'un processus
  - attend la fin du fils `pid`, ou de tous les fils si `pid = -1=`
  - retourne dans `stat` le statut de terminaison
  - retourne `0` si succès, `-1` si erreur
- `pid_t getpid (void)` : renvoie le PID de l'appelant
- `pid_t getppid (void)` : renvoie le PID du parent

Terminaison de processus

- `void exit (int statut)` : termine le processus courant
  - termine le processus courant avec `statut`
  - par convention, `statut = 0` signifie « succès »
- `int kill (pid_t pid, int signal)` : termine ou envoie un signal à `pid`
  - si `signal = SIGKILL`, le noyau termine `pid` sans préavis
  - si `signal = SIGTERM`, le noyau notifie `pid` de sa fin prochaine
    - le processus peut p. ex. sauvegarder ses données puis `exit`
  - les autres signaux peuvent aussi être « attrapés » par le destinataire, comportement par défaut sinon

Terminaison de processus

folklore Unix/POSIX

- quand un processus se termine
  - les ressources du processus sont libérées par le système
  - le signal `SIGCHLD` est envoyé au parent
  - le parent doit l'attendre avec `waitpid` ou `wait`
    - sinon le fils devient *zombie* après sa terminaison
- quand un parent se termine avant son fils
  - le fils est adopté par le processus `1` (`init`)

Exécution de programme

- `int execve (const char *chemin, char *argv[], char *env[])`
  - remplace l'image du processus courant par le programme à `chemin` (p. ex. `/bin/date`)
  - programme lancé avec les arguments `argv`
  - ... et les variables d'environnement `env`
  - les descripteurs de fichier ouverts sont conservés
- interfaces de plus haut niveau
  - `int execvp (const char *nom, char *argv[])` cherche `nom` dans `$PATH`, utilise l'environnement courant
  - `int execlp (const char *nom, char *argv, ...)` idem, mais arguments listés

Exemple : lancer /bin/date

```
#include <unistd.h>
#include <sys/types.h>
#include <sys/wait.h>
int main (int argc, char *argv[]) {
  pid_t enfant;
  switch ((enfant = fork ())) {
  case -1: return 1; /* erreur */
  case 0: execlp ("date", "date program", NULL);  /* enfant
  default: { int statut; /* parent */
    waitpid (enfant, &statut, 0);
    if (WIFEXITED (statut))
      printf ("OK: %i\n", WEXITSTATUS (statut)); }
  }
  return 0;
}
```

Interaction et coopération entre processus

- à travers l'environnement initial
  - mémoire, desc. de fichier ouverts, var. d'environnement, etc.
- à travers des fichiers
  - `emacs` écrit un fichier, `gcc` le lit et le compile
- par communication inter-processus
  - appel système `pipe` pour créer un canal de communication entre processus parent et fils
  - appels système `socket`, `connect`, etc. pour ouvrir une connexion
  - appel système `kill` pour envoyer un signal
- par transfert de descripteur de fichier (`sendmsg`)
- par mémoire partagée (`shmctl`, etc.)

Communication inter-processus par tube

```
#include <unistd.h>
#include <sys/types.h>
#include <sys/wait.h>

int main (int argc, char *argv[]) {
  int enfant, tube[2];
  pipe (tube);  /* créée un tube */
  switch ((enfant = fork ())) {
  case -1: return 1;
  case 0:       /* le fils écrit dans 1 */
    write (tube[1], "Salut !", 8);
    return 0;
  default: {    /* le parent lit dans 0 */
    char buf[8]; int statut;
    read (tube[0], buf, sizeof (buf));
    printf ("message : %s\n", buf);
    waitpid (enfant, &statut, 0);
    return WEXITSTATUS (statut); }
  }
}
```

Plan

Concurrence, entrelacement et synchronisation

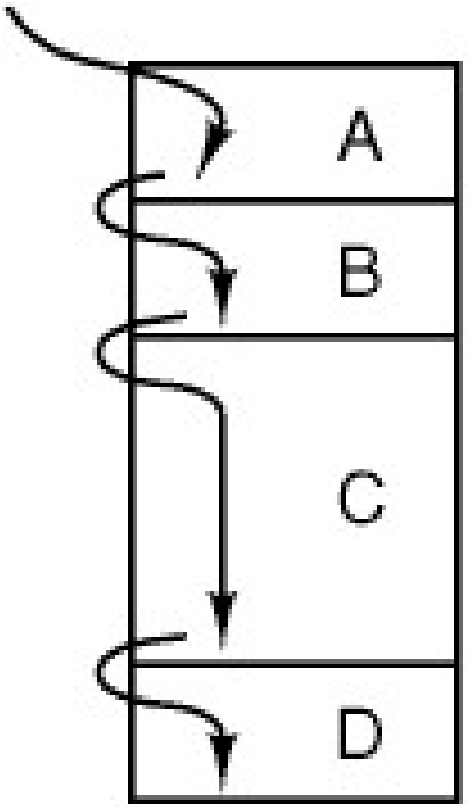

Accès à l'état partagé

Quelle est la sortie de ce programme ?

```
#include <stdlib.h>
int count = 0; /* modifié par différents fils */
void *loop (void *ignored) {
  int i;
  for (i = 0 ; i < 100000 ; i++)
     count++;
  return NULL;
}
int main () {
  pthread_t tid;
  pthread_create (&tid, NULL, loop, NULL);
  loop (NULL);
  pthread_join (tid, NULL);
  printf("%d\n",count);
}
```

Accès à l'état partagé

Quelle est la sortie de ce programme ?

```
#include <stdlib.h>
int count = 0; /* modifié par différents fils */
void *loop (void *ignored) {
  int i;
  for (i = 0 ; i < 100000 ; i++)
     count++;
  return NULL;
}
int main () {
  pthread_t tid;
  pthread_create (&tid, NULL, loop, NULL);
  loop (NULL);
  pthread_join (tid, NULL);
  printf("%d\n",count);
}
```

- une valeur entre 100000 et 2e6
  - count++ peut devenir :

```
reg1 <- count
reg1 <- reg1 + 1
count <- reg1
```

Accès à l'état partagé

Est-ce que les 2 sections critiques vont être appelées ?

```
int flag1 = 0, flag2 = 0;
void *p1 (void *ignored) {
  flag1 = 1;
  if (!flag2) { section_critique_1 (); }
}
void *p2 (void *ignored) {
  flag2 = 1;
  if (!flag1) { section_critique_2 (); }
}
int main () {
  pthread_t tid1;
  pthread_create (&tid1, NULL, p1, NULL);
  p2 ();
  pthread_join (tid1, NULL);
}
```

Accès à l'état partagé

Est-ce que les 2 sections critiques vont être appelées ?

```
int flag1 = 0, flag2 = 0;
void *p1 (void *ignored) {
  flag1 = 1;
  if (!flag2) { section_critique_1 (); }
}
void *p2 (void *ignored) {
  flag2 = 1;
  if (!flag1) { section_critique_2 (); }
}
int main () {
  pthread_t tid1;
  pthread_create (&tid1, NULL, p1, NULL);
  p2 ();
  pthread_join (tid1, NULL);
}
```

- on ne sait pas !

Besoin de synchronisation

- ordre des instructions produites par le compilateur ?
- entrelacement/ordonnancement des *threads* imprévisible
- non-atomicité des opérations
  - même `count++` peut correspondre à plusieurs instructions
- cohérence cache/mémoire sur systèmes SMP ou multi-cœurs ?
  - sur x86, préfixe `lock` pour verrouiller le bus mémoire
  - mais très coûteux, et pas généré par le compilateur C

Exclusion mutuelle

les *mutexes*

- fourni par les bibliothèques de *threads* (ex. : `pthread`)
  - `void pthread_mutex_init (pthread_mutex_t *)`
  - `int pthread_mutex_lock (pthread_mutex_t *m)` bloque jusqu'à acquisition de `m`
  - `int pthread_mutex_trylock (pthread_mutex_t *m)` retourne 0 si `m` acquise
  - `int pthread_mutex_unlock (pthread_mutex_t *m)`
- toute donnée globale partagée doit être protégée par une mutexe !

Analogie des mutexes avec les verrous

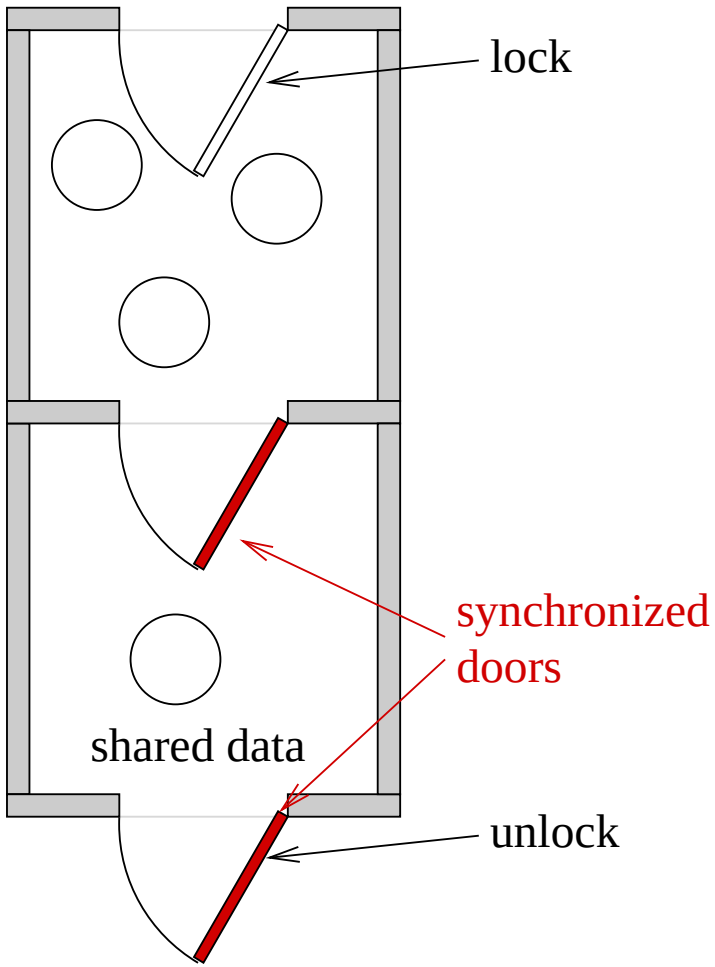

Exemple du compteur avec mutexe

```
pthread_mutex_t count_lock = PTHREAD_MUTEX_INITIALIZER;
int count = 0; /* modifié par différents fils */

void *loop (void *ignored) {
  for (int i = 0 ; i < 10 ; i++) {
    pthread_mutex_lock (&count_lock); /* inefficace... */
    count++;
    pthread_mutex_unlock (&count_lock);
  }
  return NULL;
}
int main () {
  pthread_t tid;
  pthread_create (&tid, NULL, loop, NULL);
  loop (NULL);
  pthread_join (tid, NULL);
  printf("%d\n",count);
}
```

Exemple producteur/consommateur

```
mutex_t mutex = MUTEX_INITIALIZER;

void producer (void *ignored) {
  for (;;) {
    /* produce an item and put in
       nextProduced */


    while (count == BUFFER_SIZE) {

      /* Do nothing */

    }

    buffer[in] = nextProduced;
    in = (in + 1) % BUFFER_SIZE;
    count++;

  }
}
```

```
void consumer (void *ignored) {
  for (;;) {

    while (count == 0) {

      /* Do nothing */

    }

    nextConsumed =  buffer[out];
    out = (out + 1) % BUFFER_SIZE;
    count--;


    /* consume the item in
       nextConsumed */
  }
}
```

Exemple producteur/consommateur

```
mutex_t mutex = MUTEX_INITIALIZER;

void producer (void *ignored) {
  for (;;) {
    /* produce an item and put in
       nextProduced */

    mutex_lock (&mutex);
    while (count == BUFFER_SIZE) {

      thread_yield ();

    }

    buffer[in] = nextProduced;
    in = (in + 1) % BUFFER_SIZE;
    count++;
    mutex_unlock (&mutex);
  }
}
```

```
void consumer (void *ignored) {
  for (;;) {
    mutex_lock (&mutex);
    while (count == 0) {

      thread_yield ();

    }

    nextConsumed =  buffer[out];
    out = (out + 1) % BUFFER_SIZE;
    count--;
    mutex_unlock (&mutex);

    /* consume the item in
       nextConsumed */
  }
}
```

Exemple producteur/consommateur

```
mutex_t mutex = MUTEX_INITIALIZER;

void producer (void *ignored) {
  for (;;) {
    /* produce an item and put in
       nextProduced */

    mutex_lock (&mutex);
    while (count == BUFFER_SIZE) {
      mutex_unlock (&mutex);
      thread_yield ();
      mutex_lock (&mutex);
    }

    buffer[in] = nextProduced;
    in = (in + 1) % BUFFER_SIZE;
    count++;
    mutex_unlock (&mutex);
  }
}
```

```
void consumer (void *ignored) {
  for (;;) {
    mutex_lock (&mutex);
    while (count == 0) {
      mutex_unlock (&mutex);
      thread_yield ();
      mutex_lock (&mutex);
    }

    nextConsumed =  buffer[out];
    out = (out + 1) % BUFFER_SIZE;
    count--;
    mutex_unlock (&mutex);

    /* consume the item in
       nextConsumed */
  }
}
```

Exemple producteur/consommateur

problèmes et solution

- attente active dans l'application : mauvaise idée
  - le `while` consomme du CPU, même quand on ne peut pas progresser
- mieux : informer l'ordonnanceur de quand on peut travailler
- utilisation de variables de condition
- `cond_init (cond_t *c, ...)`
- `cond_wait (cond_t *c, mutex_t *m)`
  - atomiquement déverrouille `m` et dort jusqu'à `c` signalée
  - puis ré-acquiert `m` et poursuit
- `cond_signal (cond_t *c)`
  `cond_broadcast (cond_t *c)`
  - réveille un/tous les *threads* en attente
- structure de synchronization associée à une condition logique

Producteur/consommateur avec variables de condition

```
mutex_t mutex = MUTEX_INITIALIZER;
cond_t nonempty = COND_INITIALIZER;
cond_t nonfull = COND_INITIALIZER;

void producer (void *ignored) {
  for (;;) {
    /* produce an item and
       put in nextProduced */

    mutex_lock (&mutex);
    if (count == BUFFER_SIZE)
      cond_wait (&nonfull, &mutex);

    buffer[in] = nextProduced;
    in = (in + 1) % BUFFER_SIZE;
    count++;
    cond_signal (&nonempty);
    mutex_unlock (&mutex);
  }
}
```

```
void consumer (void *ignored) {
  for (;;) {
    mutex_lock (&mutex);
    if (count == 0)
      cond_wait (&nonempty, &mutex);

    nextConsumed =  buffer[out];
    out = (out + 1) % BUFFER_SIZE;
    count--;
    cond_signal (&nonfull);
    mutex_unlock (&mutex);

    /* consume the item
       in nextConsumed */
  }
}
```

Et avec plusieurs lecteurs/écrivains ?

Producteur/consommateur avec variables de condition

```
mutex_t mutex = MUTEX_INITIALIZER;
cond_t nonempty = COND_INITIALIZER;
cond_t nonfull = COND_INITIALIZER;

void producer (void *ignored) {
  for (;;) {
    /* produce an item and
       put in nextProduced */

    mutex_lock (&mutex);
    while (count == BUFFER_SIZE)
      cond_wait (&nonfull, &mutex);

    buffer[in] = nextProduced;
    in = (in + 1) % BUFFER_SIZE;
    count++;
    cond_signal (&nonempty);
    mutex_unlock (&mutex);
  }
}
```

```
void consumer (void *ignored) {
  for (;;) {
    mutex_lock (&mutex);
    while (count == 0)
      cond_wait (&nonempty, &mutex);

    nextConsumed =  buffer[out];
    out = (out + 1) % BUFFER_SIZE;
    count--;
    cond_signal (&nonfull);
    mutex_unlock (&mutex);

    /* consume the item
       in nextConsumed */
  }
}
```

Mettre un `while` autour du `cond_wait`.

Producteur/consommateur avec variables de condition

```
mutex_t mutex = MUTEX_INITIALIZER;
cond_t nonempty = COND_INITIALIZER;
cond_t nonfull = COND_INITIALIZER;

void producer (void *ignored) {
  for (;;) {
    /* produce an item and
       put in nextProduced */

    mutex_lock (&mutex);
    while (count == BUFFER_SIZE)
      cond_wait (&nonfull, &mutex);

    buffer[in] = nextProduced;
    in = (in + 1) % BUFFER_SIZE;
    count++;
    cond_signal (&nonempty);
    mutex_unlock (&mutex);
  }
}
```

```
void consumer (void *ignored) {
  for (;;) {
    mutex_lock (&mutex);
    while (count == 0)
      cond_wait (&nonempty, &mutex);

    nextConsumed =  buffer[out];
    out = (out + 1) % BUFFER_SIZE;
    count--;
    cond_signal (&nonfull);
    mutex_unlock (&mutex);

    /* consume the item
       in nextConsumed */
  }
}
```

Attention : pas de garantie premier arrivé premier servi

Variables de condition

- pourquoi `cond_wait` doit à la fois relâcher la mutex et dormir ? pourquoi ne pas séparer ?

```
while (count == BUFFER_SIZE) {
  mutex_unlock (&m);
  cond_wait_hypothétique (&nonfull);
  mutex_lock (&m);
}
```

- parce qu'on pourrait avoir un mauvais entrelacement
  - p. ex. le producteur manquerait le signal :

```
/* producteur */                    |  /* consommateur */
while (count == BUFFER_SIZE) {      |
  mutex_unlock (&m);                |
  | mutex_lock (&m);
  | /* ... */
  | count--;
  | cond_signal_hypo (&nonfull);
  cond_wait (&nonfull);             |
```

Autres problèmes courants de synchronisation

- interblocage (*deadlock*)
  - P_0 et P_1 veulent accéder à R et S protégées par un verrou

P_0	P_1
lock(S)	lock(R)
lock(R)	lock(S)
...	...
unlock(R)	unlock(S)
unlock(S)	unlock(R)

- famine (*starvation*)
  - un des *threads* n'acquiert jamais la ressource
  - p. ex. à cause de l'ordre dans lequel on sert les *threads*

Alternatives à la concurrence avec mémoire partagée

- la programmation parallèle n'implique pas *forcément* la mémoire partagée !
- passage de messages
  - MPI (*Message Passing Interface*) sur grappes de calcul
  - langage Erlang
- programmation fonctionnelle (Scheme, OCaml, Haskell, etc.)
  - passage de valeurs (constantes) entre fonctions
  - pas d'accès globaux à synchroniser

Plan

Mise en œuvre des fils d'exécution et processus par le noyau

- le SE garde une structure pour chaque fil ou proc.
  - *Thread/Process Control Block* (TCB/PCB)
  - PCB appelé `task_struct` dans Linux
- contient l'état du fil/processus
  - en cours d'exécution, prêt, bloqué, etc.
- inclus l'info nécessaire pour le faire tourner
  - registres (dont pointeurs de pile et de programme)
  - pour un processus : projections mémoire, desc. de fichier
- d'autres informations
  - ID utilisateur/groupe, masque de signal, terminal de contrôle, stats de conso. de ressources, etc.

Process state
Process ID
User id, etc.
Program counter
Registers
Address space (VM data structs)
Open files

`fork` et `exec`

- `fork` créée une copie du PCB
  - descripteurs de fichier hérités
  - fichiers ouverts à la fois par le parent et le fils (chacun doit les fermer)
  - pages mémoires partagées (`text`, `rodata`, etc.)
- `exec` remplace tout
  - registres (dont pointeur d'instruction), espace d'adressage
  - mais descripteurs de fichier conservés

État des processus et fils

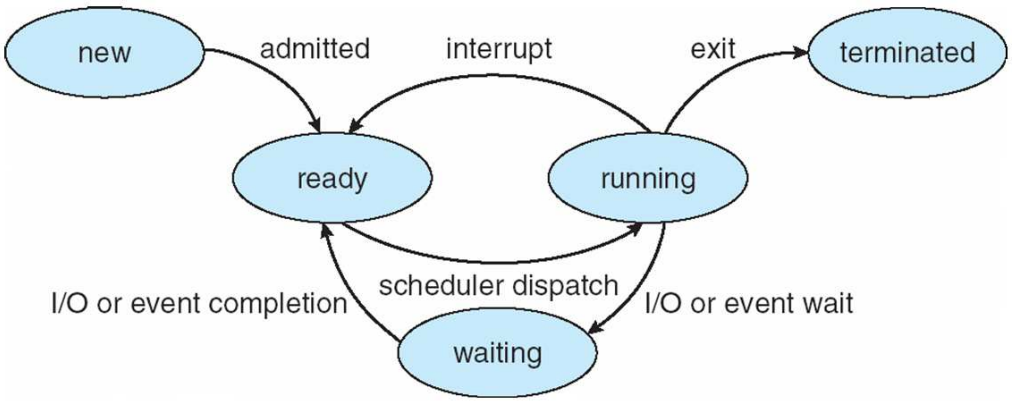

- fils et processus dans un état
  - *nouveau* ou *terminé* au début/fin
  - en cours d'exécution (*running*)
  - *prêt* – pourrait s'exécuter, mais CPU occupé
  - *en attente* – attend la complétion d'entrée/sortie, verrou libéré, etc.
- que processus/fil le noyau choisit-il d'exécuter ?
  - si 0 prêt, on attend ; si 1 prêt, on l'exécute
  - si > 1 prêt, il faut faire un choix d'ordonnancement

Ordonnancement de processus/fils

Quel processus/thread exécuter ?

- parcourir la table des processus pour en trouver un prêt ?
  - coûteux, effets douteux (ex. : triés par PID)
  - séparer les *prêts* et les autres
- FIFO ?
  - processus ajoutés en fin de file
  - retirés en tête de file
- priorité ?
  - donner plus de chance à CPU

Politique d'ordonnancement

- équilibre entre plusieurs objectifs
  - *équité* – éviter la famine de certains processus/fils
  - *priorité* – prendre en compte l'importance relative
  - *échéances* – doit faire x d'ici t (ex. : audio/vidéo)
  - *débit* – bonne performance globale
  - *réactivité* – minimiser le temps de réponse (ex. : GUI)
  - *efficacité* – minimiser le surcoût engendré par l'ordonnanceur
- pas de politique universelle
  - beaucoup de critères, conflictuels
- ordonnancement mémoire et CPU intimement liés
  - ex. : un processus avec mémoire et sans CPU ne peut pas progresser, donc la mémoire est gâchée

Préemption

- processus/fil effectivement préempté quand le noyau prend la main
- un processus peut passer la main au noyau
  - appel système, défaut de page, instruction invalide, division flottante par zéro, etc.
  - peut s'endormir — p. ex. en initiant des E/S
  - peut réveiller d'autres — p. ex. `fork`, écriture dans un tube
- la minuterie donne la main au noyau périodiquement
  - si le processus courant a assez tourné, ordonnance un autre
- interruption matérielle
  - requête disque servie, paquet arrivé sur le réseau, etc.
  - peut rendre des processus *prêts*
  - peut mener à l'ordonnancement d'un autre proc. avec plus haute priorité
- changement de contexte

Changement de contexte (*context switch*)

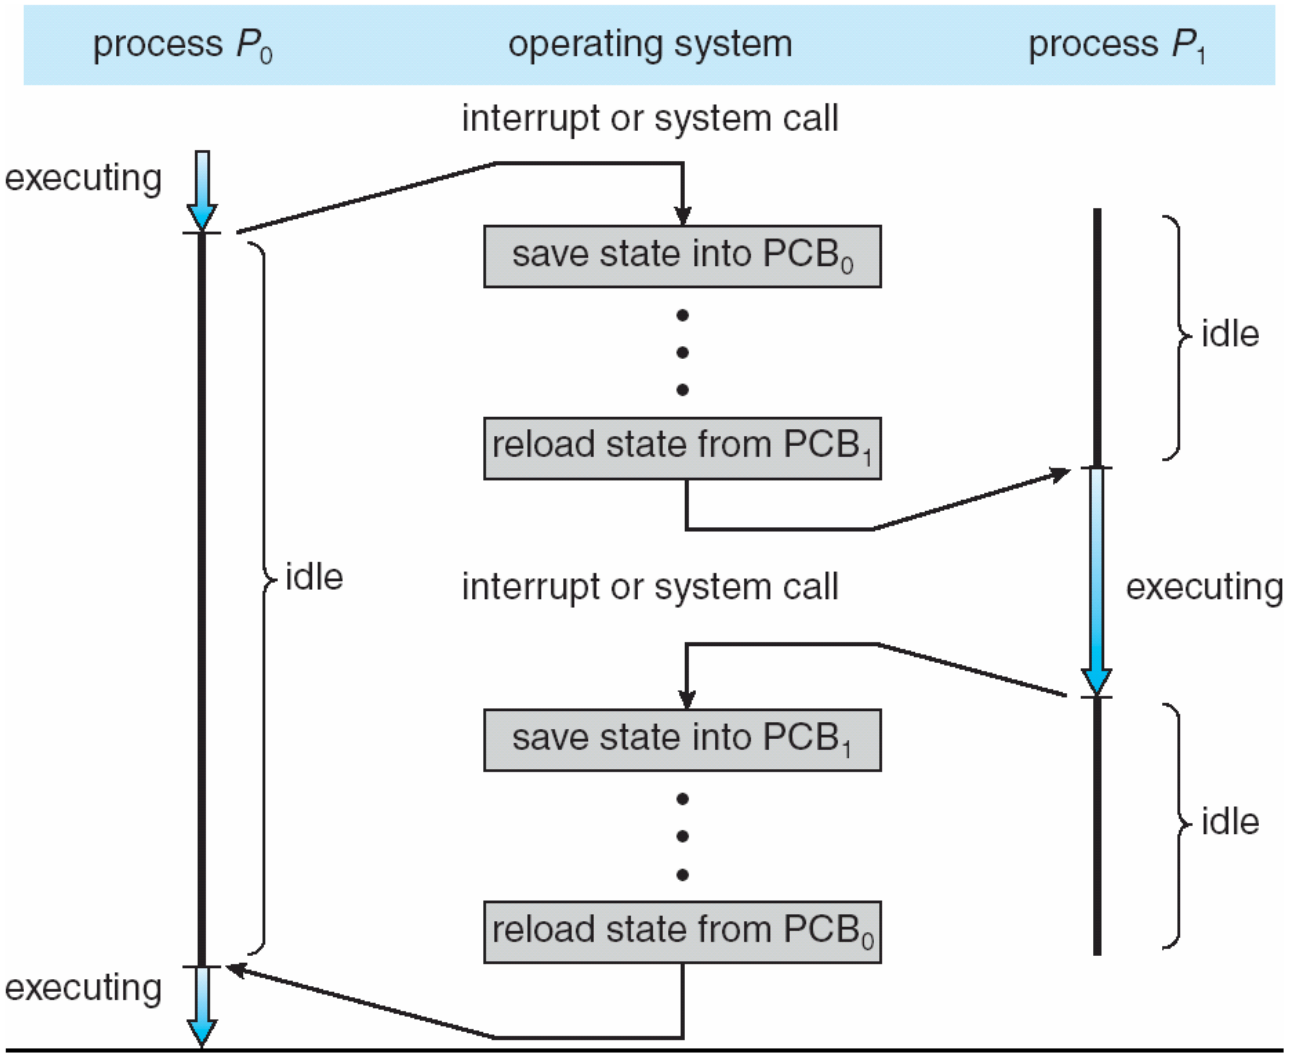

Détails du changement de contexte

- dépendant de l'architecture :
  - sauvegarde du pointeur d'instruction + registres entiers
  - sauvegarde des registres virgule flottante
  - si changement de processus, changement de traductions d'adresses virtuelles
- coûts non négligeables
  - sauvegarde/restauration des registres flottants
    - optimisation : que si ils ont été utilisés
  - peut nécessiter de vider le TLB (traduction d'adresses matérielle)
    - optimisation : conserver les données du noyau dans le TLB
  - entraîne des défauts de cache

Limitations des *threads* mis en œuvre par le noyau

- chaque opération sur les *threads* passe par le noyau
  - un appel système prend ~50x plus de temps qu'un appel de fonction
- une implémentation des *threads* pour plaire à tous (`pthread`)
  - répond à beaucoup de besoins
  - mais chacun paye pour des fonctionnalités parfois superflues (priorités, etc.)
- demande mémoire lourde
  - allocation des structures de données du noyau à la création, etc.

Mise en œuvre des *threads* en espace utilisateur

- utilise un seul *thread* noyau : n : 1
- exemple : bibliothèque GNU Pth, `http://gnu.org/software/pth`
- ordonnanceur en espace utilisateur
  - file de *threads* utilisateur prêts, en attente, etc.
  - TCB avec contexte d'exécution de chaque *thread*
  - éventuellement préemption avec minuterie (`setitimer`)
- remplace les appels bloquants : `read` vs. `pth_read`, etc.
  - si l'opération peut bloquer, ordonnance un autre *thread*
- avantage : création et changement de contextes légers
- inconvénient : pas de parallélisme (un seul cœur de CPU)
- cf. fonctions `getcontext` et `swapcontext` de la libc

Mise en œuvre des *threads* en espace utilisateur (n : m)

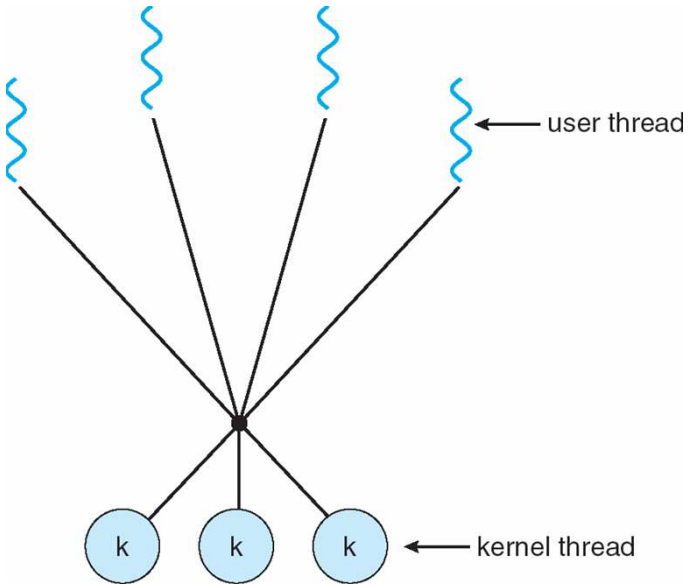

- *n threads* utilisateurs sur *m threads* noyau : n : m
- exemple : bibliothèque Marcel, `http://runtime.bordeaux.inria.fr/marcel/`
- avantages : *threads* légers, parallélisme
- inconvénients : le noyau ne dévoile pas tout, implémentation compliquée

Micro-noyaux et ordonnancement en espace utilisateur

micro-noyau L4 — `http://l4ka.org`

- *thread* associé à sa création à un thread d'ordonnancement (`ThreadControl`)
- chaque *thread* a 3 attributs d'ordonnancement :
  - priorité, durée des intervalles (*timeslice*), temps total (*total quantum*)
- protocole de préemption
  - quand un *thread* est préempté ou passe explicitement la main (*yields*)
  - message de préemption envoyé au *thread* d'ordonnancement
  - le *thread* d'ordonnancement peut changer la priorité, le temps imparti au *thread*, etc. (`Schedule`)
- avantage : ordonnancement des ressources de l'appli par l'appli, meilleure connaissance des besoins

Plan

Plan

On veut que les processus puissent co-exister

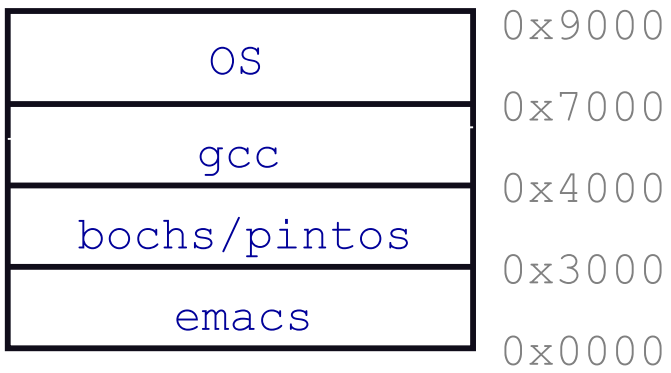

- imaginons le multi-tâche sur mémoire physique
  - qu'est-ce qui se passe si `pintos` a besoin de plus de mémoire ?
  - si `emacs` a besoin de plus de mémoire que disponible sur la machine ?
  - si `pintos` a un bug et écrit à `0x7100` ?
  - quand `gcc` a-t-il besoin de savoir qu'il tourne à `0x4000` ?
  - et si `emacs` n'utilise pas sa mémoire ?

Problèmes avec le partage de la mémoire physique

- protection
  - un bug dans un processus peut corrompre un autre
  - empêcher que A puisse corrompre la mémoire de B
  - empêcher que A puisse observer la mémoire de B
- transparence
  - un processus ne devrait pas requérir des adresses spécifiques
  - les processus ont souvent besoin de larges zones contiguës (pile, grosses structures de données, etc.)
- épuisement des ressources
  - le programmeur suppose que la machine a « assez » de mémoire
  - somme des tailles des processus souvent supérieure à la mémoire physique

Buts de la mémoire virtuelle

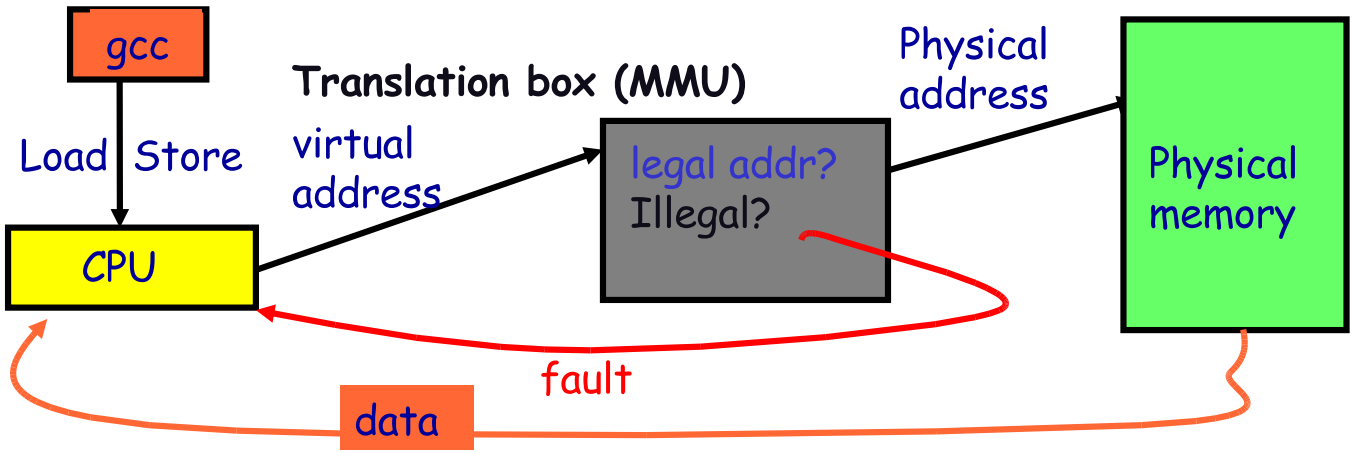

- donner à chaque programme son espace d'adressage
  - convertir chaque accès mémoire virtuelle en un accès mémoire physique
  - l'appli ne se soucie pas de quelle mémoire physique elle utilise
- garantir la protection
  - empêche une appli de toucher à la mémoire d'une autre
- permettre aux programmes de voir plus de mémoire qu'il n'en existe (*swap* sur disque)

Avantages de la mémoire virtuelle

- peut reloger un programme pendant qu'il tourne
  - partiellement en mémoire physique, partiellement sur disque
- l'essentiel de la mémoire d'un processus est inutilisée (règle du 80/20)

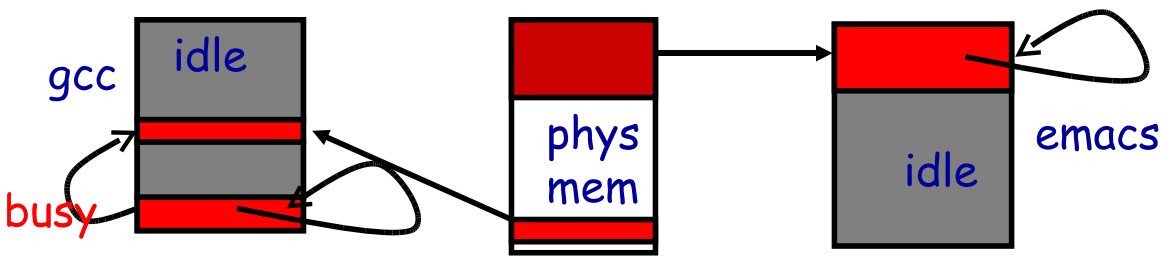

  - écrire les parties actuellement inutilisées sur disque
  - laisse la mémoire physique libérée aux autres processus
  - similaire au démultiplexage/virtualisation du CPU
    - quand un processus n'utilise pas le CPU, on le passe à un autre
    - quand un processus n'utilise pas une page mémoire, on la passe à un autre
- défi : une indirection en plus, pourrait être lent

Définitions

- les programmes chargent/écrivent à des adresses virtuelles (ou logiques)
- la mémoire vive est désignée avec des adresses physiques (ou réelles)
  - adresses physiques inaccessibles et inconnues de l'espace utilisateur
- unité matérielle de gestion de la mémoire (MMU, *memory management unit*)
  -
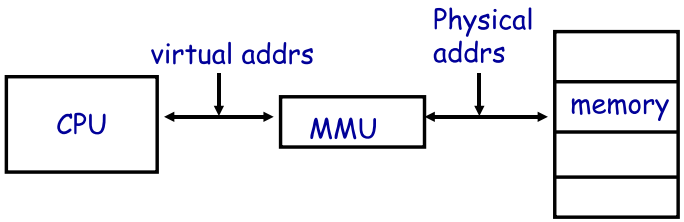

  - fait typiquement partie du CPU
  - accès avec des instructions privilégiées
- traduit les adresses virtuelles en adresses physiques

Espace d'adressage

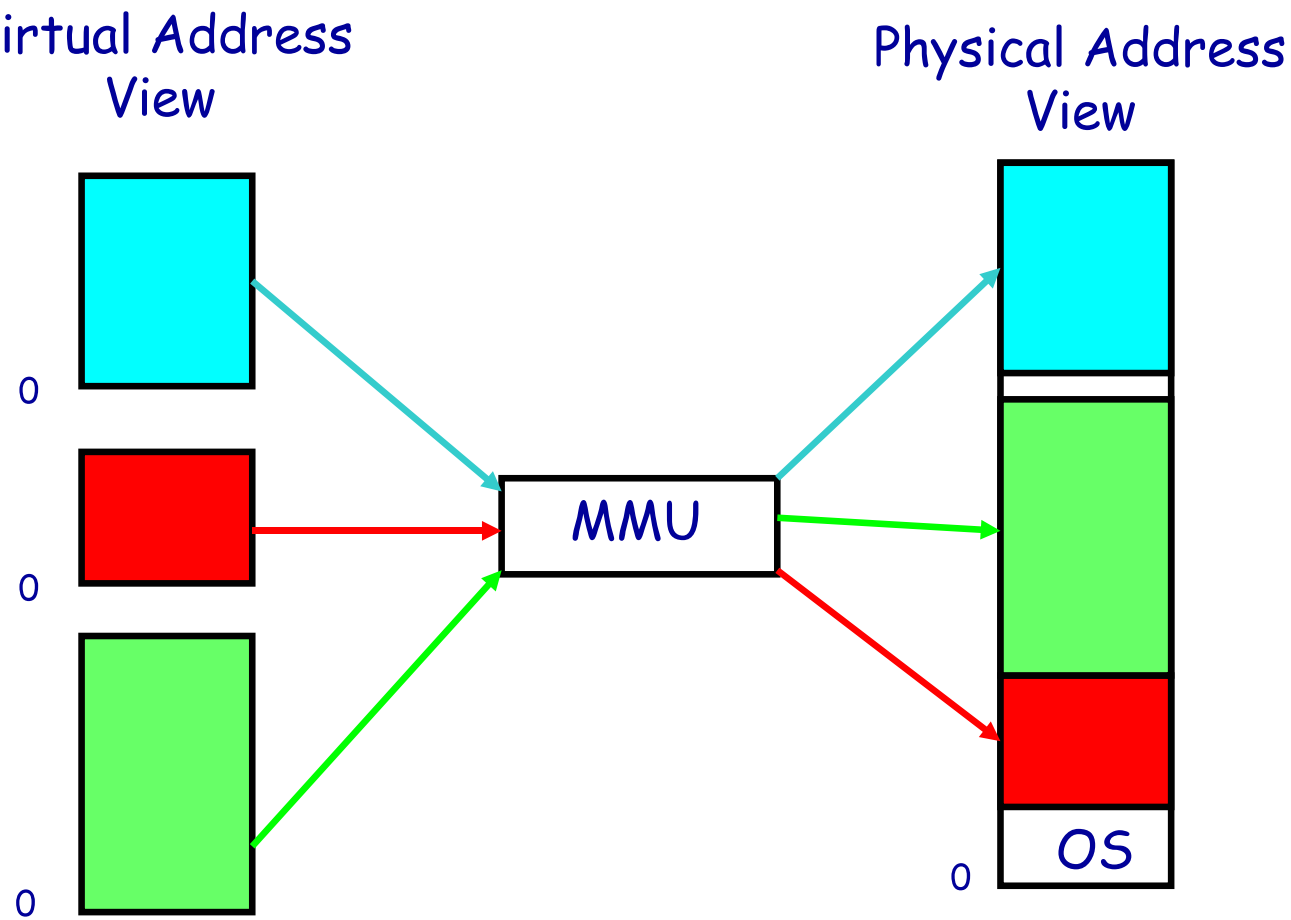

Plan

Ce que voit un processus

- chaque processus a son propre espace d'adressage
  - `(char *) 0x1234` différent dans chaque proc.
- zones mémoires typiques
  - pile d'appel (*stack*) : variables automatiquement allouées/déallouées (r/w)
  - tas (*heap*) : mém. allouée/déallouée dynamiquement, p. ex. `malloc` (r/w)
  - données (*data*) : variables globales initialisées (r/w)
  - BSS : variables globales non-initialisées, zéros (r/w)
  - texte (*text*) : code binaire (r/x)

Ce que voit un processus

exemple avec le noyau Linux

```
$ cat /proc/2459/maps
00400000-004af000 r-xp          /bin/bash
006ae000-006b3000 rw-p          /bin/bash
006b3000-006bc000 rw-p
012c3000-0141f000 rw-p          [heap]
7fbcba0b9000-7fbcba21a000 r-xp  /lib/libc-2.12.1.so
7fbcba21a000-7fbcba41a000 ---p  /lib/libc-2.12.1.so
[...]
7fbcbaac2000-7fbcbacc1000 ---p  /lib/libreadline.so.6.1
7fbcbacc1000-7fbcbacc9000 rw-p  /lib/libreadline.so.6.1
[...]
7fbcbaee9000-7fbcbaeea000 rw-p  /lib/ld-2.12.1.so
7fff51274000-7fff5128a000 rw-p  [stack]
7fff513a1000-7fff513a2000 r-xp  [vdso]
```

Principe de la pagination

- mémoire divisées en pages
- correspondance pages virtuelles → pages physiques
  - projection virtuelle → physique propre à chaque processus
- permet au SE d'avoir le contrôle sur certaines opérations
  - pages en lecture seule : le SE est consulté si accès en écriture
  - accès invalides en lecture ou écriture : le SE est notifié
  - le SE peut changer la projection et faire reprendre l'exécution du processus
- autres fonctionnalités
  - le matériel peut maintenir des bits « accédé » ou « modifié » pour chaque page
  - avoir des droits « exécution », en plus de lecture/écriture
    - p. ex. : pile non exécutable pour éviter les attaques par débordement de tampon (*buffer overflow*)

Allocation des pages

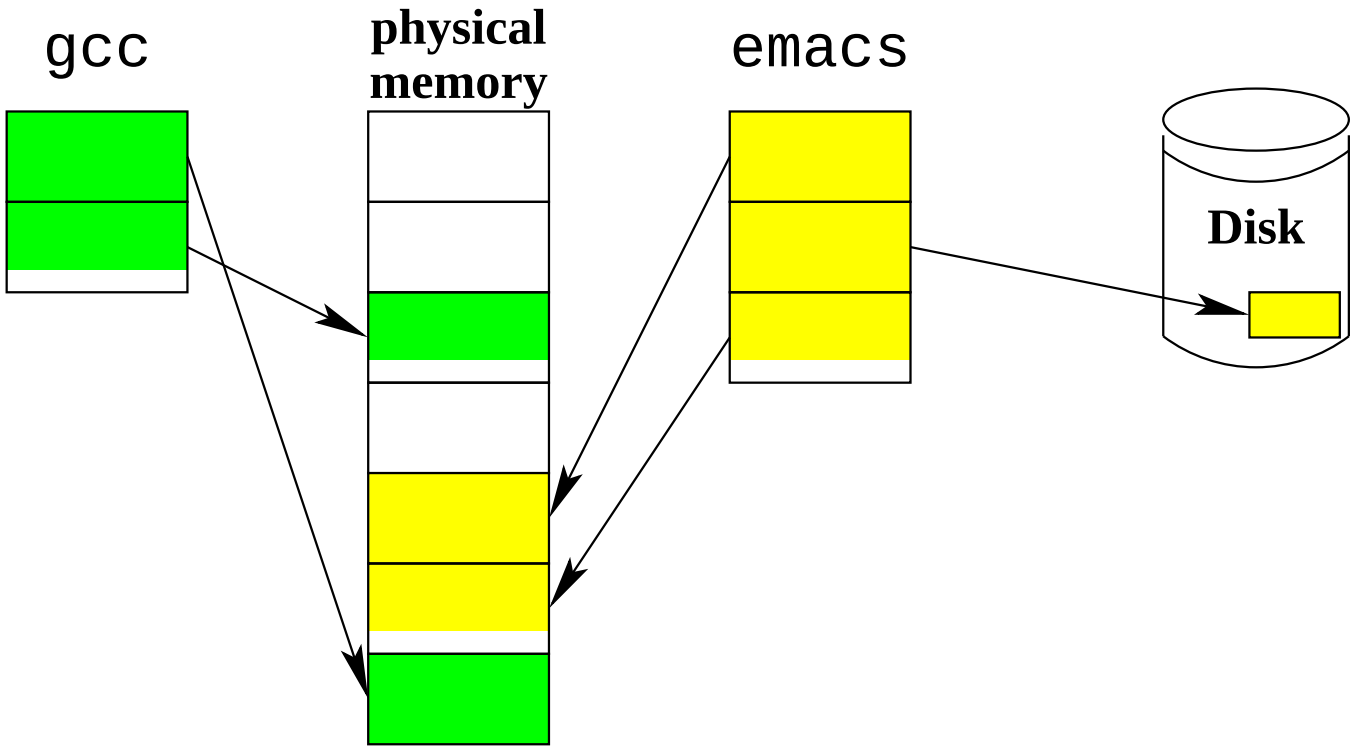

- n'importe quelle page physique allouée à n'importe quel processus
- les pages inutilisées peuvent être envoyées sur disque (*swap*)

Structures de données pour la pagination

- les pages ont une taille fixe, p. ex. 4 Kio
  - 12 bits de poids faible : décalage dans la page (*page offset*)
  - bits de poids fort : numéro de page
- une table de pages associée à chaque processus
  - n° de page virtuelle (VPN) → n° de page physique (PPN)
  - inclue l'information concernant la protection (r/w/x), la validité, etc.
- à chaque accès : traduction VPN → PPN + décalage

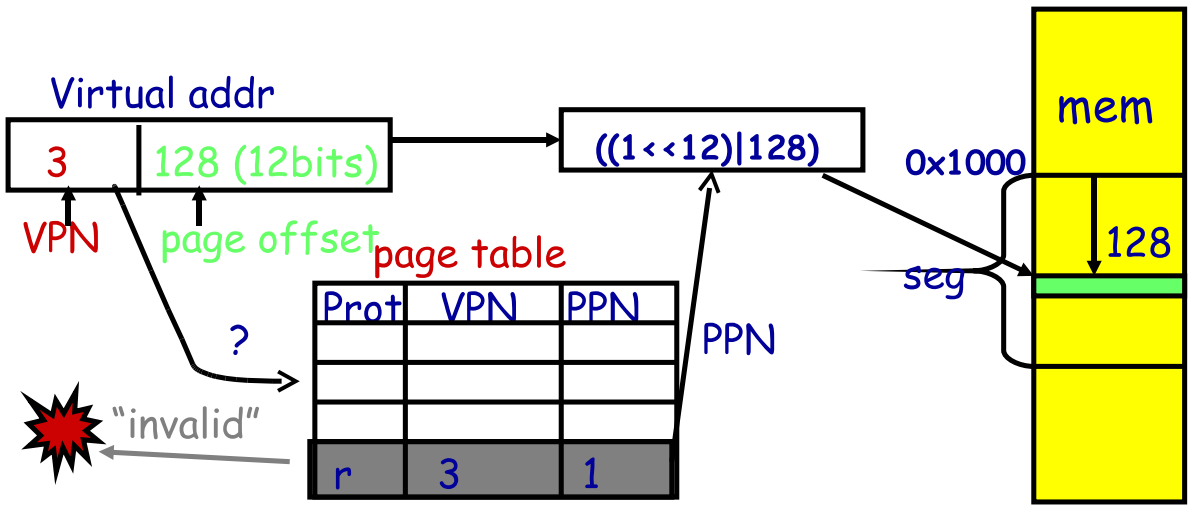

Gestion de la mémoire sur architecture Intel x86 (aka. IA32)

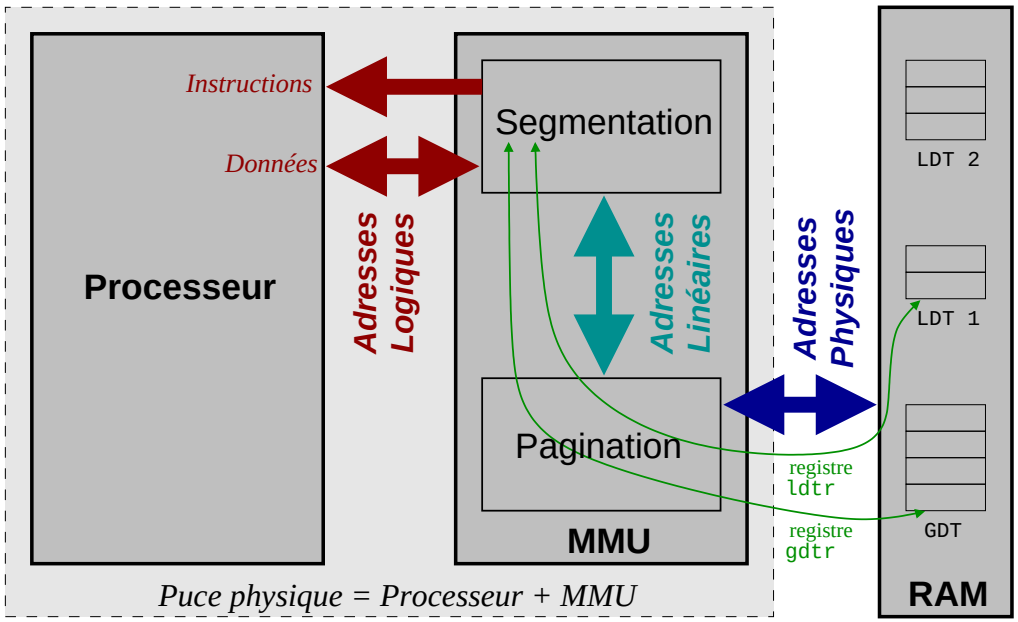

- 2 traductions d'adresses successives
  - adresses virtuelles/logiques → linéaires → physiques
- le cœur du CPU ne perçoit pas les adresses physiques
  - traduction entièrement déléguée à la MMU

Pagination sur architecture Intel x86 (aka. IA32)
traduction adresse linéaire → physique

- activée par des bits dans le registre de contrôle `%cr0`
  - privilégié : seul le noyau peut y toucher
- pages de 4 Kio (par défaut)
  - mots de 32 bits sur IA32 → 4 Gio de mémoire adressable
  - 12 bits pour le décalage, 20 bits pour le n° de page
- le registre `%cr3` pointe sur un répertoire de pages
  - 1 répertoire de pages par processus
  - 1024 entrées (*page directory entries*, PDE)
    - chaque entrée contient l'adr. physique d'une table des pages
    - indice de table sur 10 bits
- table des pages : 1024 entrées (*page table entries*, PTE)
  - chaque PTE contient l'adr. physique d'une page virtuelle
  - la table des pages couvre 4 Mio de mémoire virtuelle
  - indice de page sur 10 bits

Pagination sur architecture Intel x86 (aka. IA32) illustration

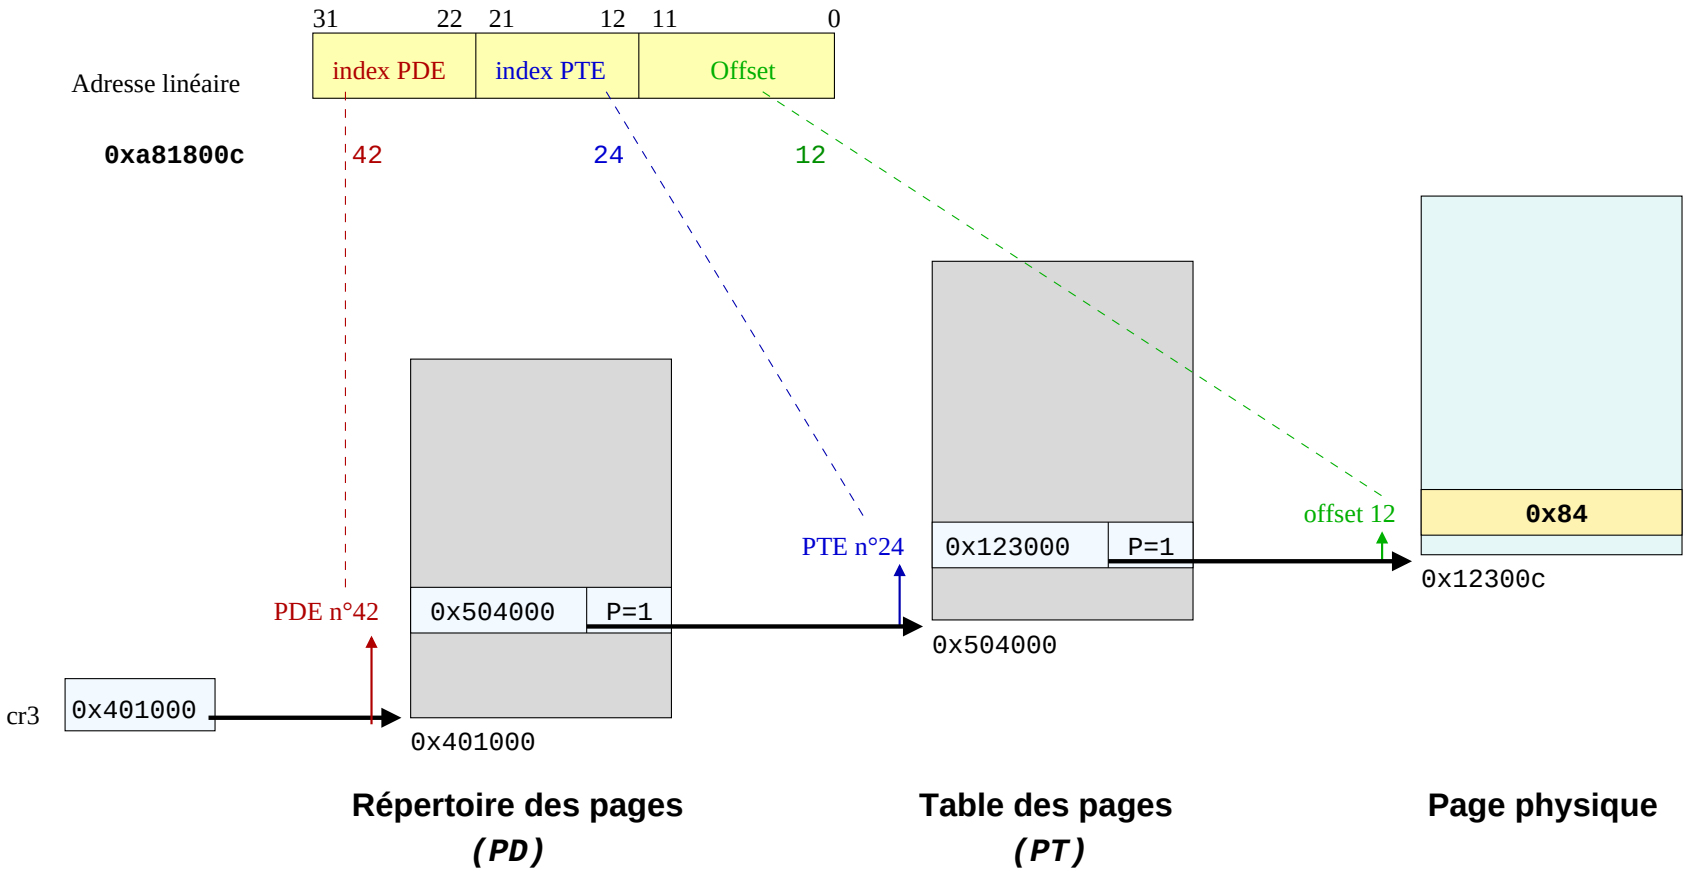

Besoin d'un cache de traduction d'adresses

- la traduction adr. linéaire → physique implique 3 accès en RAM
  1. répertoire des pages
  2. table des pages
  3. donnée demandée
- problème : la mémoire vive est lente

stockage →	registre	cache L1	cache L2	RAM	swap
nb cycles →	1	≈ 3	≈ 14	≈ 240	$\approx 10^7$
géographie →	Pessac	Talence	Cestas	Toulouse	Mars

Un cache de traduction d'adresses : le TLB

- la MMU dispose d'un cache : le TLB (*translation lookaside buffer*)
  - conserve les traductions les plus récentes
- le noyau est responsable de garder le TLB valide
  - chaque traduction peut être invalidée (instruction `invlpg`)
  - et lors d'un changement de contexte ?
    - typiquement, vide le TLB (moins vrai sur x86-64 récent)

Le TLB illustré

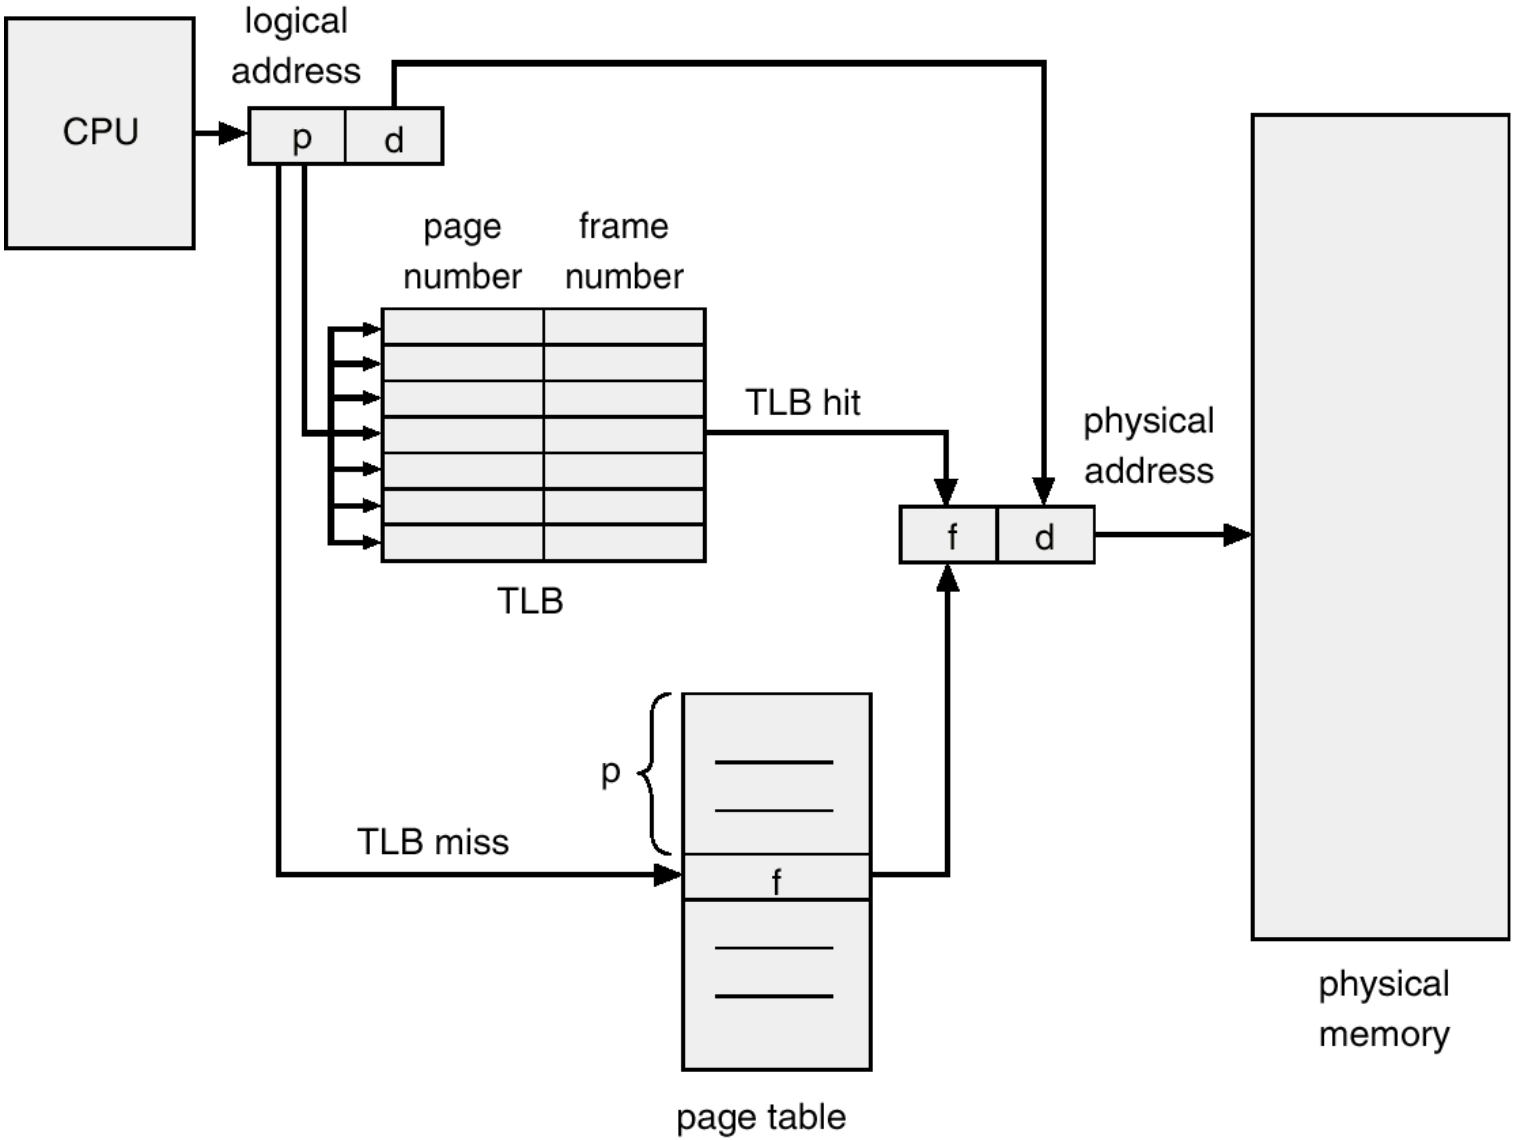

Défauts de page : le film

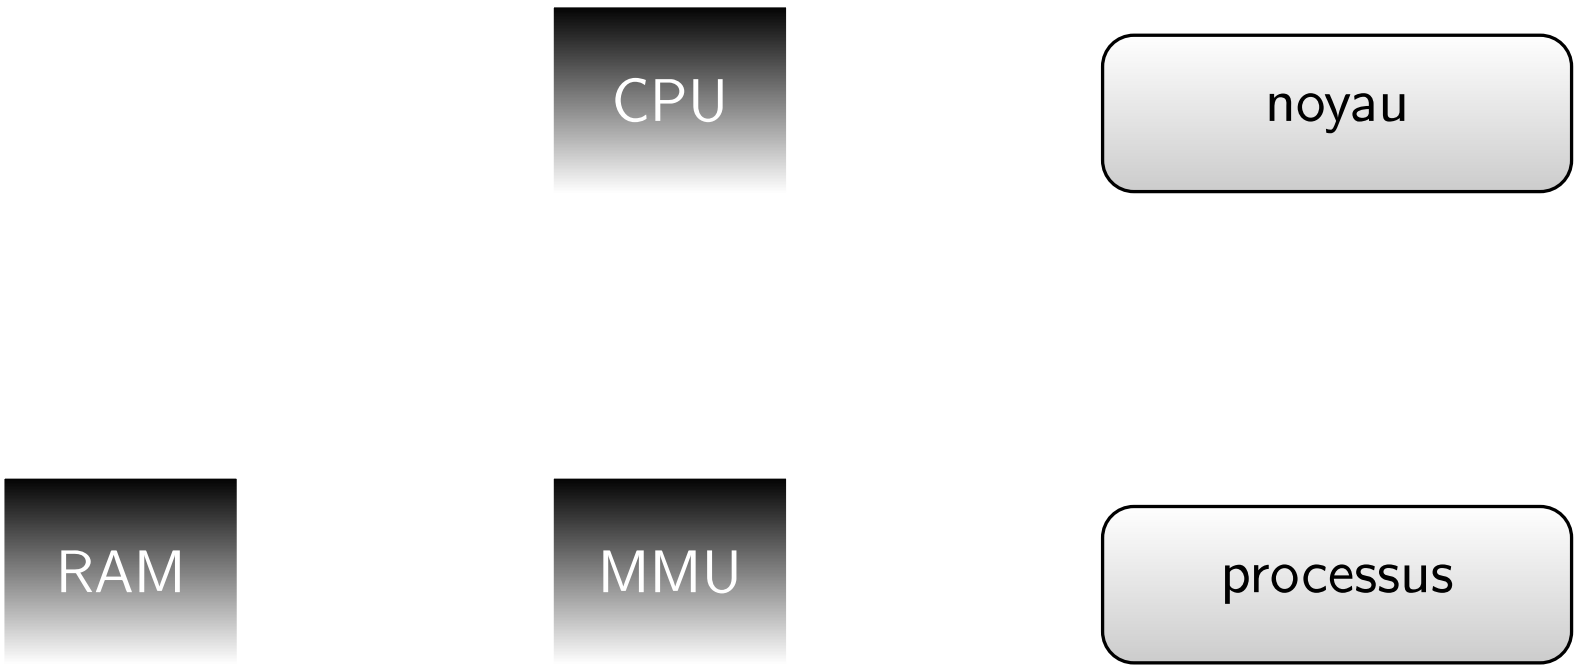

- accès mémoire virtuelle quand tout va bien : pas d'intervention du noyau

Défauts de page : le film

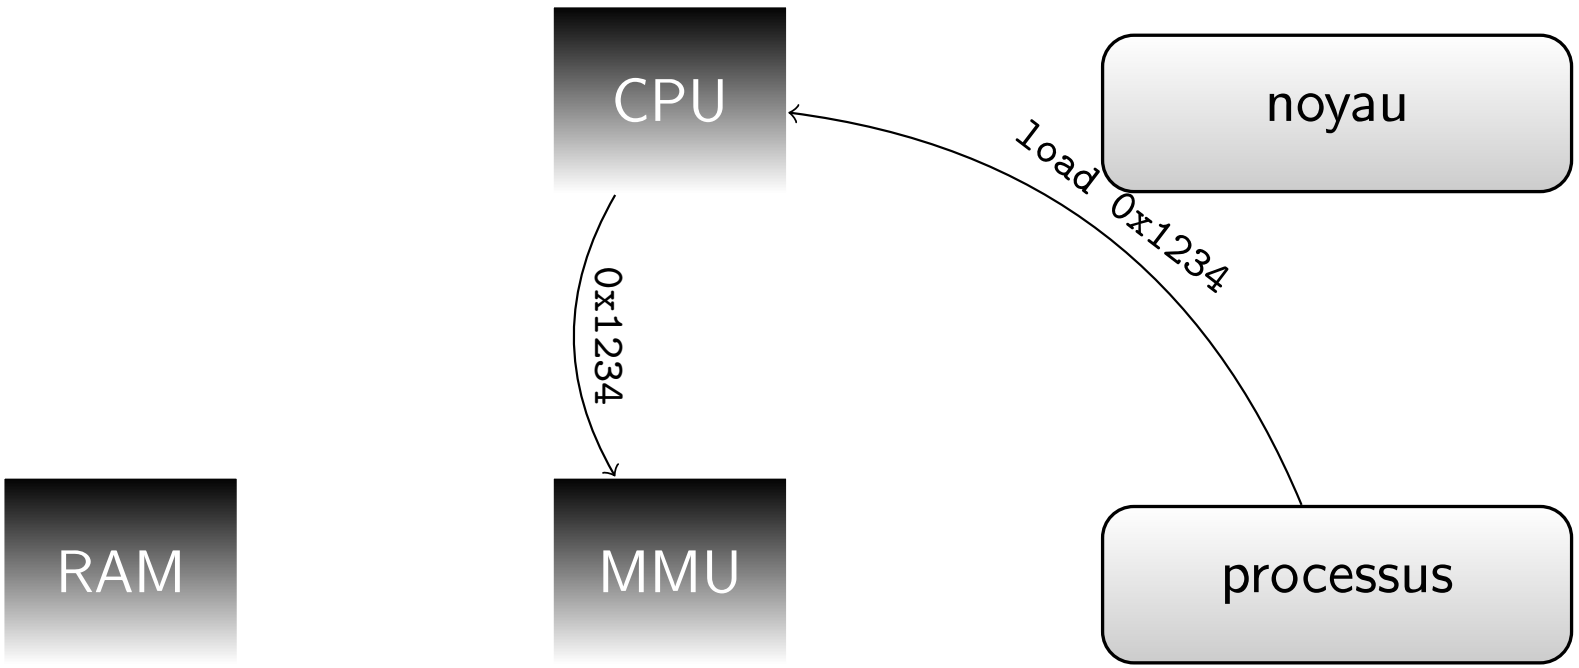

- accès mémoire virtuelle quand tout va bien : pas d'intervention du noyau

Défauts de page : le film

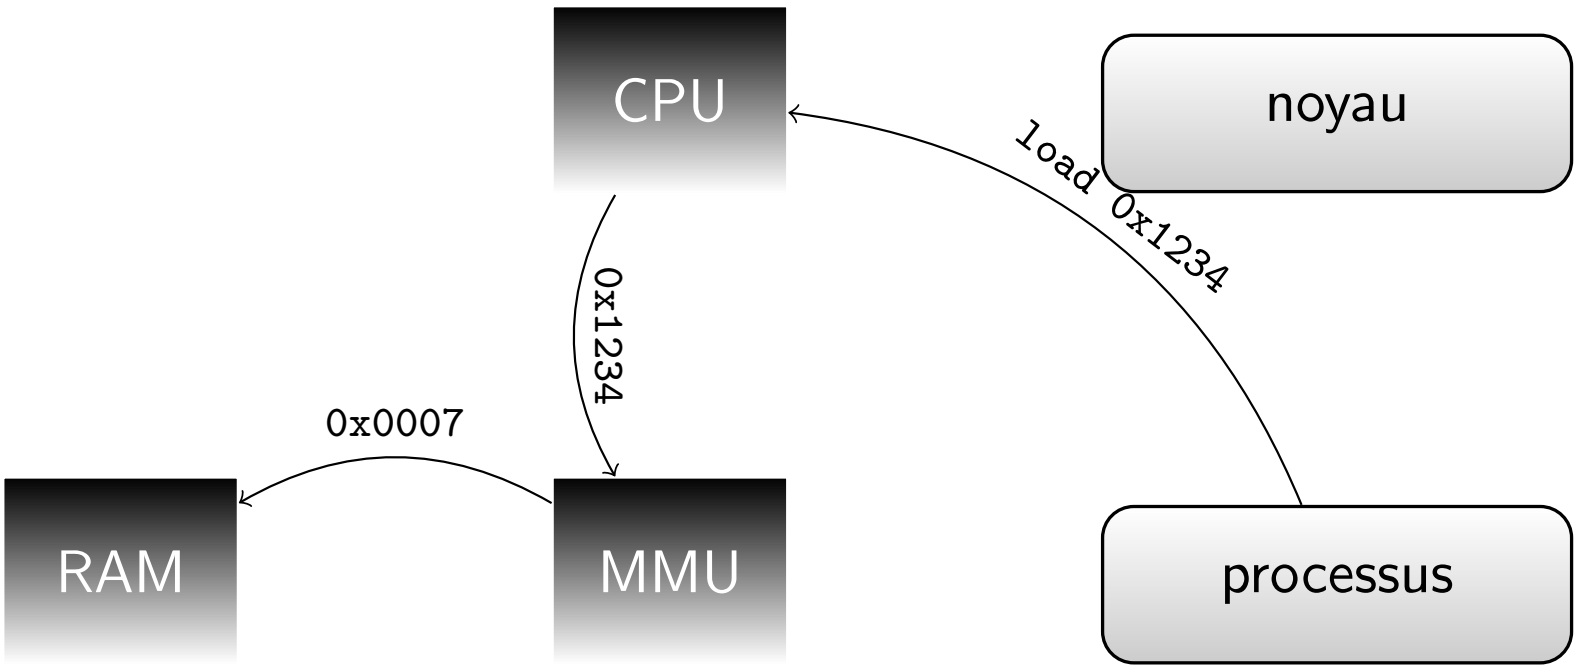

- accès mémoire virtuelle quand tout va bien : pas d'intervention du noyau

Défauts de page : le film

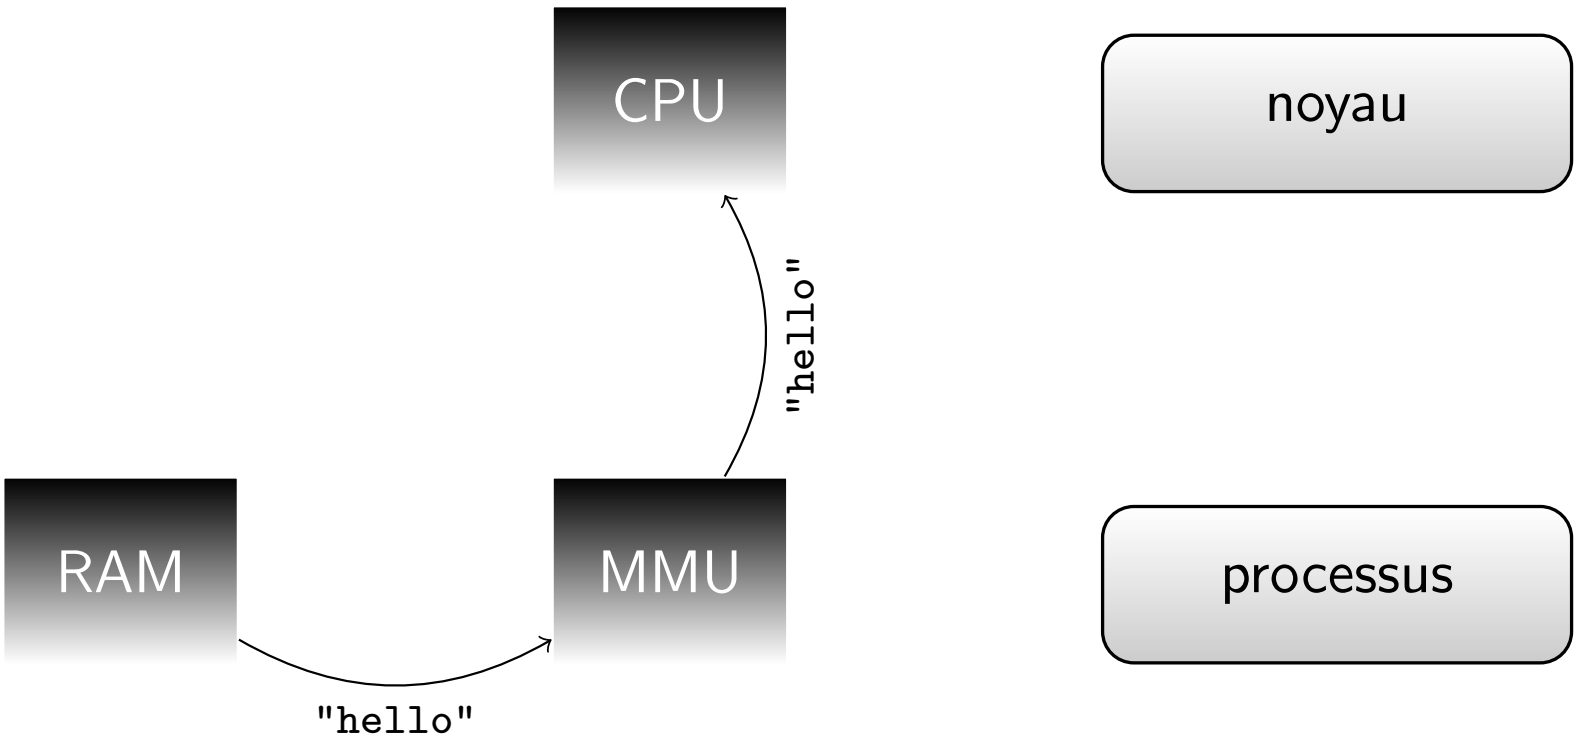

- accès mémoire virtuelle quand tout va bien : pas d'intervention du noyau

Défauts de page : le film

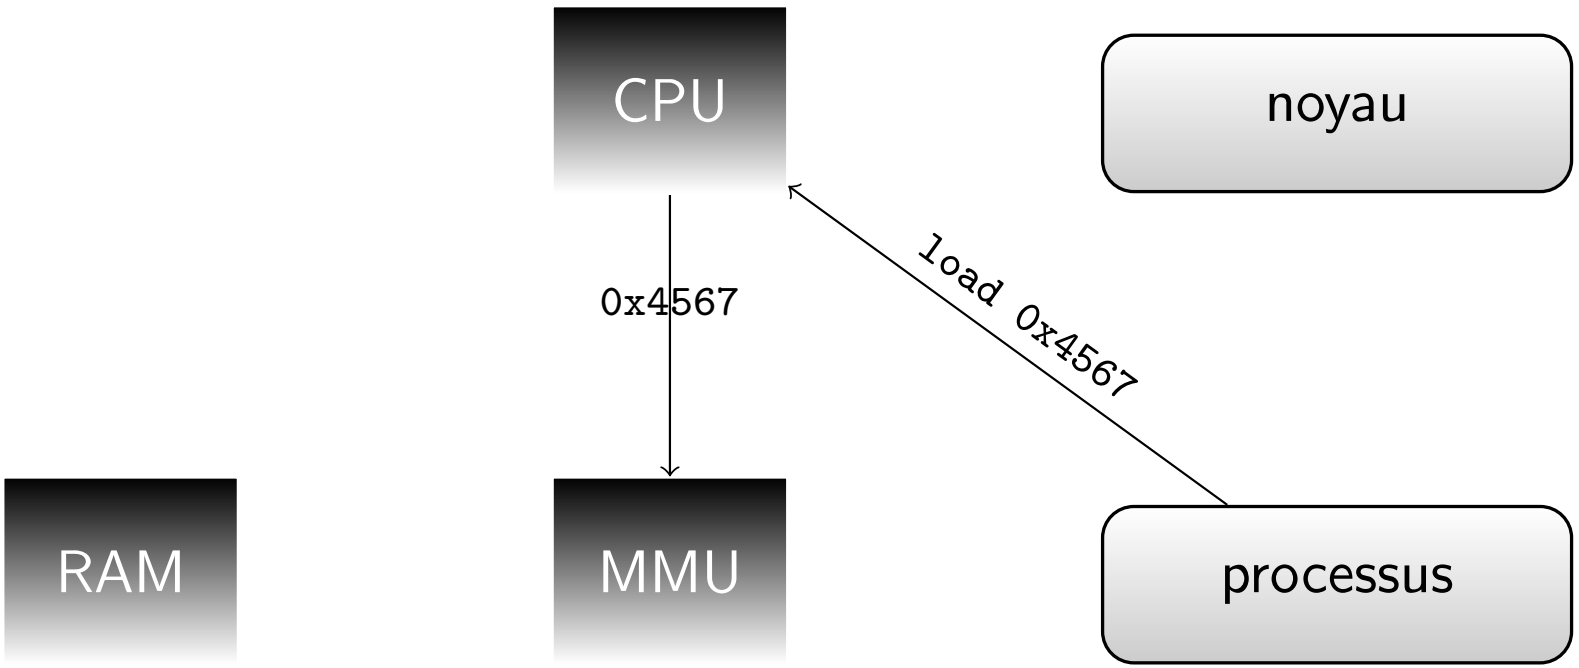

- accès à une adresse virtuelle pas encore projetée dans l'E.A. du processus, absente de la table des pages

Défauts de page : le film

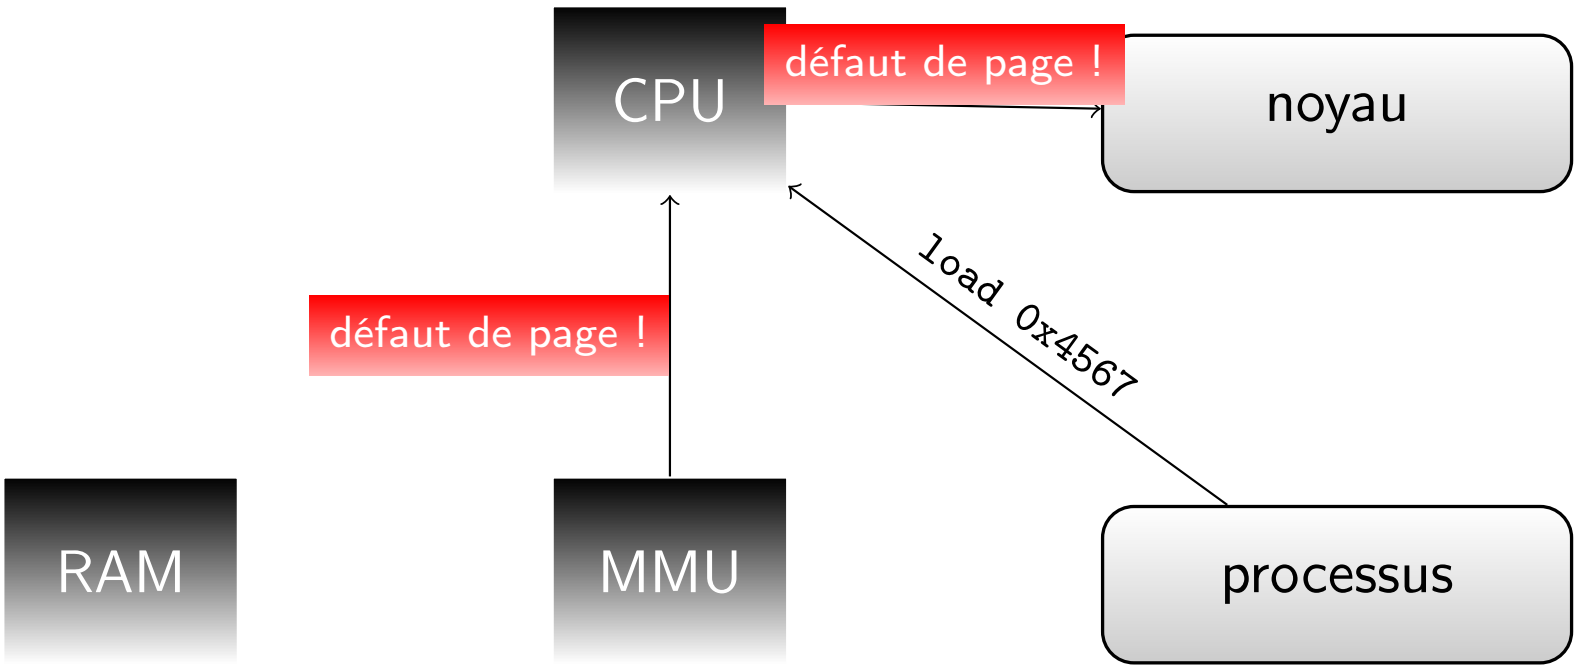

- la MMU lève une exception matérielle **défaut de page** (*page fault*), traitée par le noyau

Défauts de page : le film

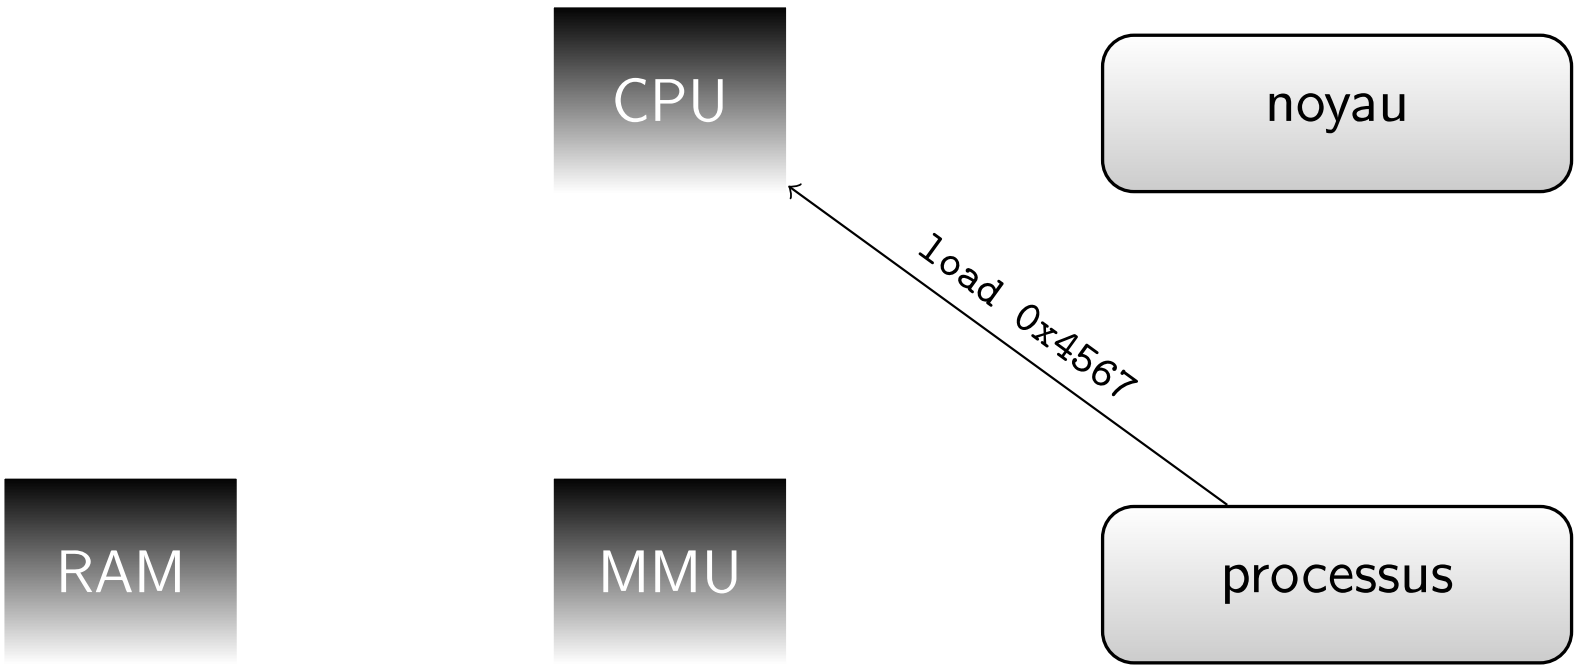

- le noyau cherche dans la table de pages de ce processus à quoi est associée la page virtuelle fautive

Défauts de page : le film

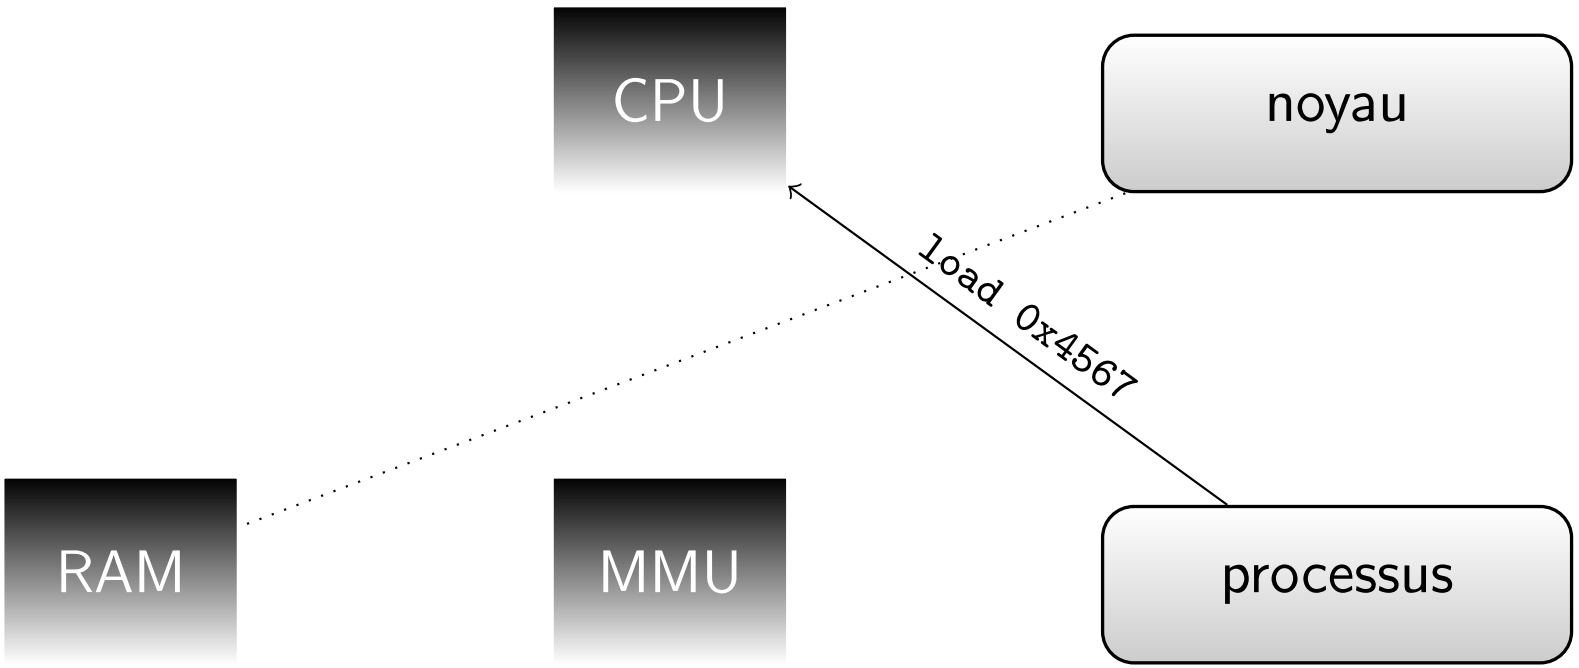

- si c'est une **adresse valide** : le noyau alloue une page physique...

Défauts de page : le film

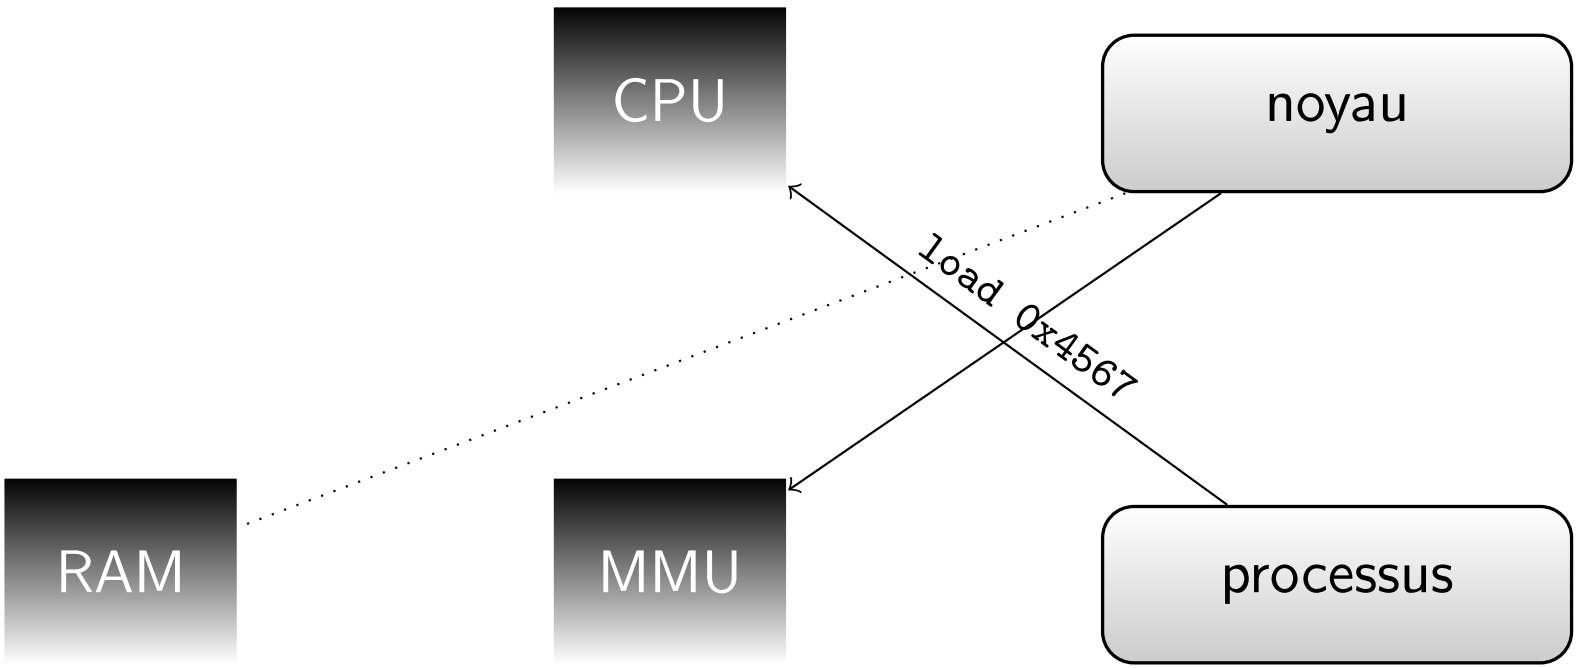

- ... projette la page physique dans l'E.A. du processus, met à jour la table des pages dans la MMU

Défauts de page : le film

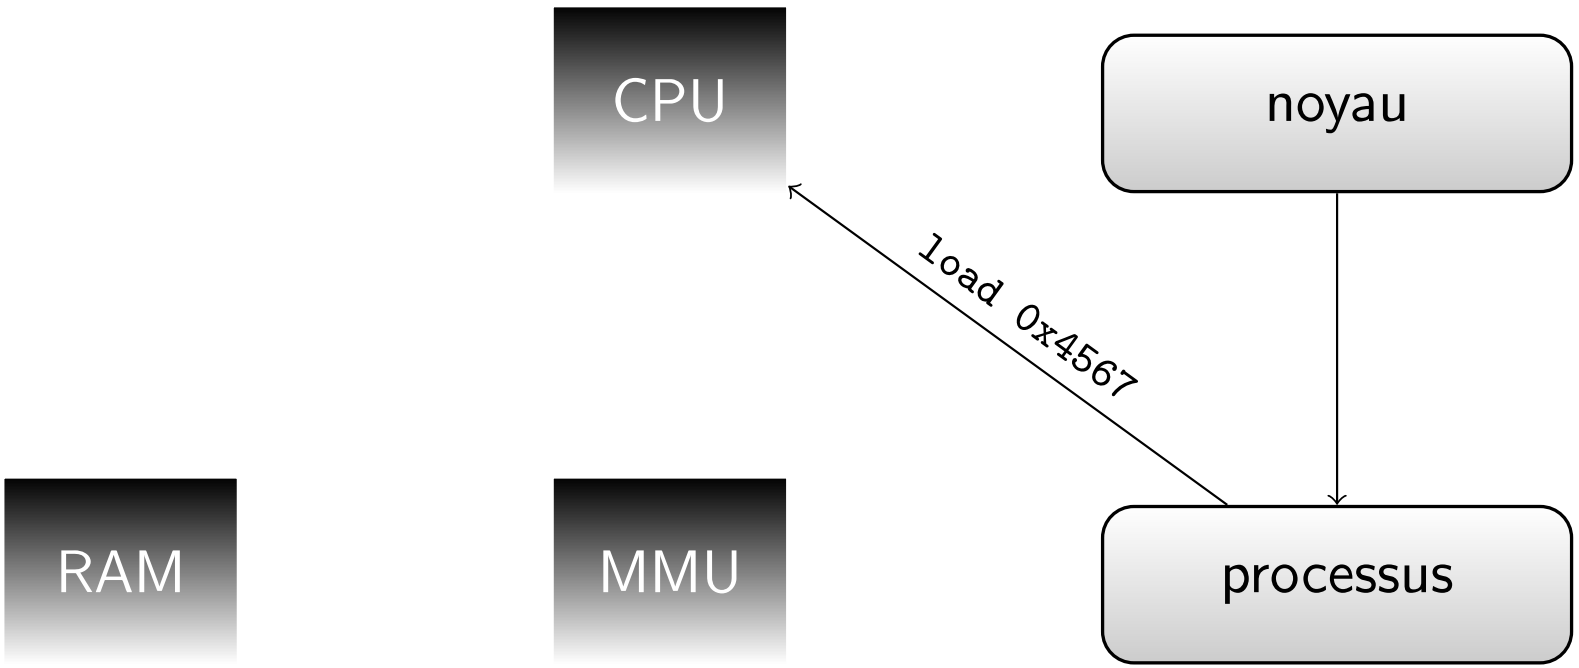

- … puis repasse la main au processus, qui poursuit son exécution

Défauts de page : le film

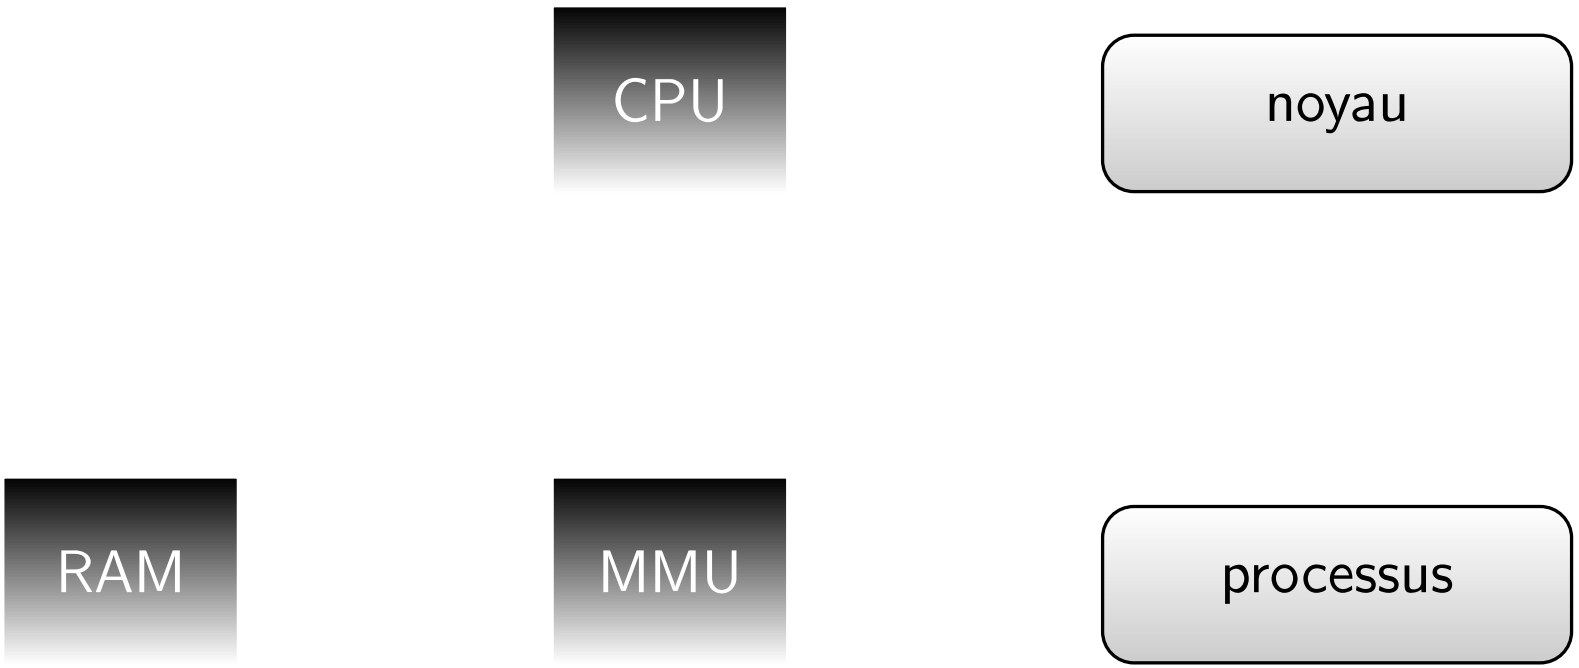

- … puis repasse la main au processus, qui poursuit son exécution

Défauts de page : le film

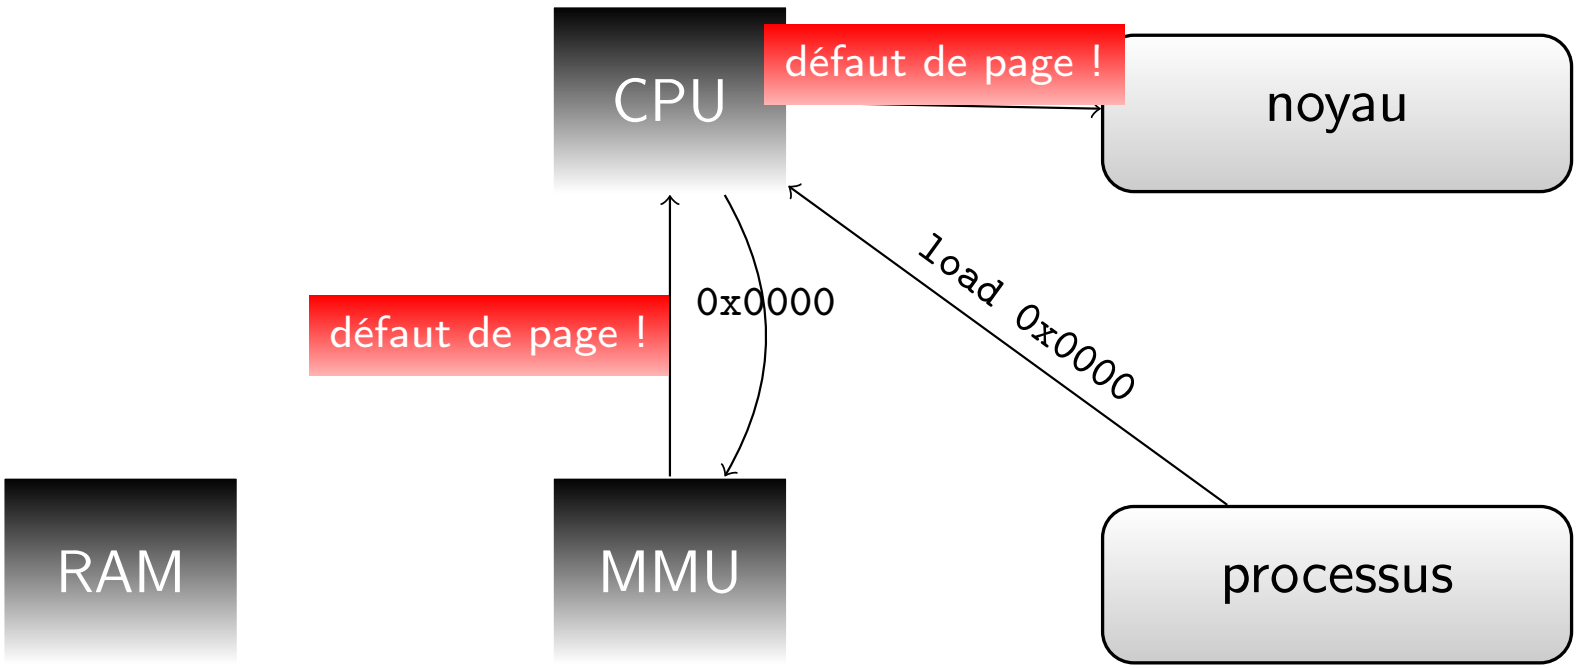

- accès à une **adresse virtuelle invalide**

Défauts de page : le film

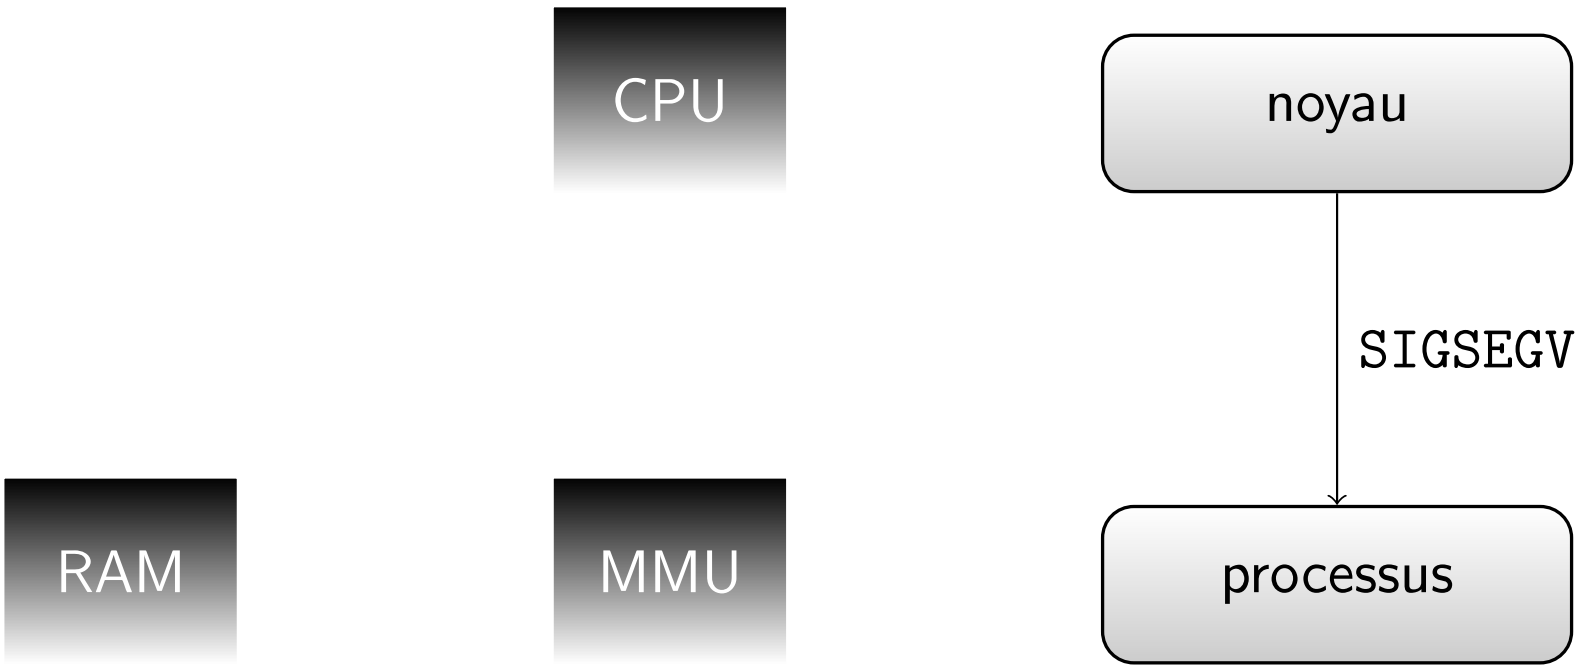

- le noyau constate l'accès invalide, envoie le signal `SIGSEGV` (*segmentation fault*) au processus...

Défauts de page : le film

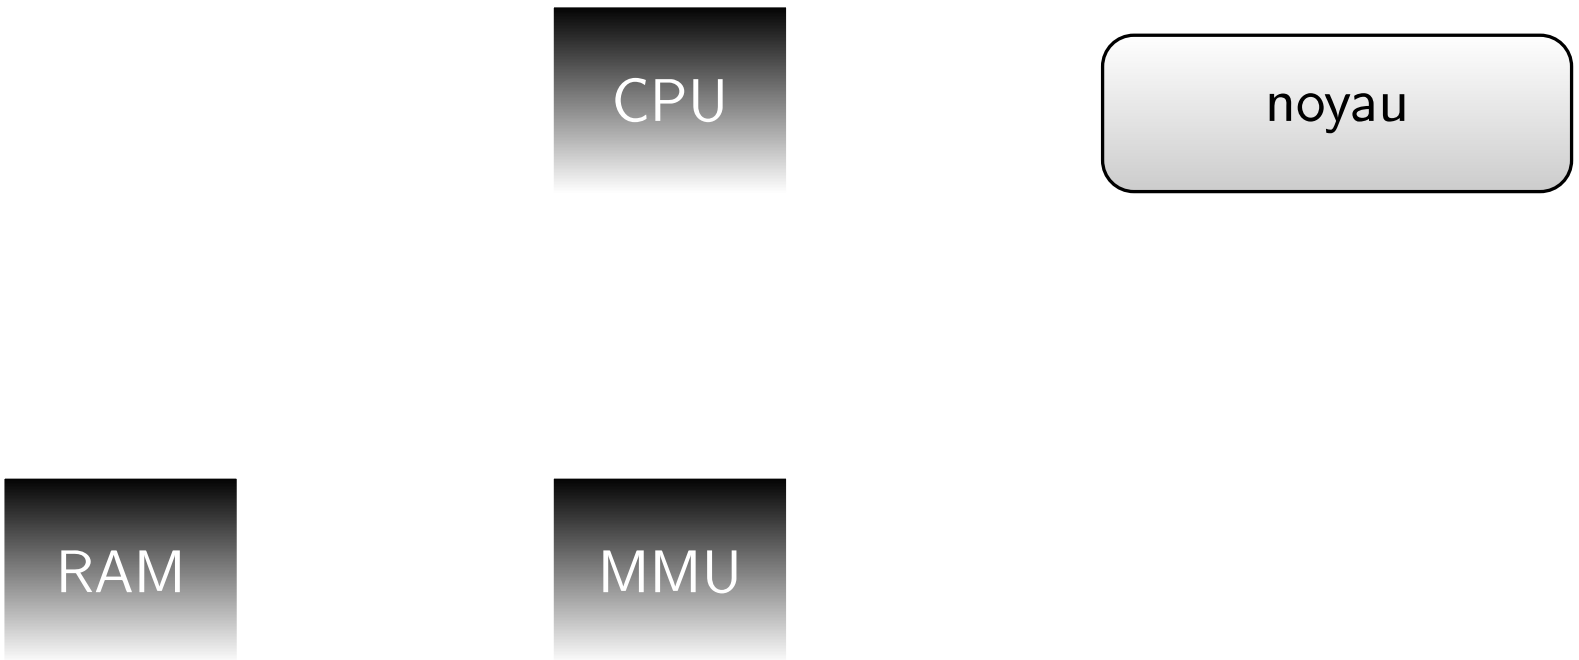

- ... et termine le processus (par défaut)

La pagination au quotidien

- pagination à la demande, quand l'appli touche une page
  - agrandissement de la pile d'appel
  - allocation du BSS (données non initialisées)
  - chargement du `text` (code)
  - chargement des bibliothèques partagées (`.so` sous GNU/Linux, DLL sous Windows, etc.)
  - projection du contenu de fichiers en mémoires
- pagination vers le disque (*swap*)
  - donner l'impression d'avoir plus de mémoire qu'en réalité
- copie sur écriture (*copy-on-write*, COW)
  - copier paresseusement les pages physiques
  - utilisé par `fork`, `mmap`, etc.
- ...

Exemple : la copie sur écriture et `fork`

- `fork` créée un processus fils copie conforme du père
  - initialement : données du fils 100% identiques au père
  - puis divergence progressive
- optimisation : la copie sur écriture (*copy-on-write*)
  - au lieu de copier les pages physiques du père au fils, projetter les pages du père chez le fils en lecture seule
  - lorsque le fils écrit, défaut de page :
    - le SE copie la page physique
    - met à jour la projetion dans le fils
    - redémarre le fils, qui utilise maintenant une copie

Exemple : la copie sur écriture et `fork`

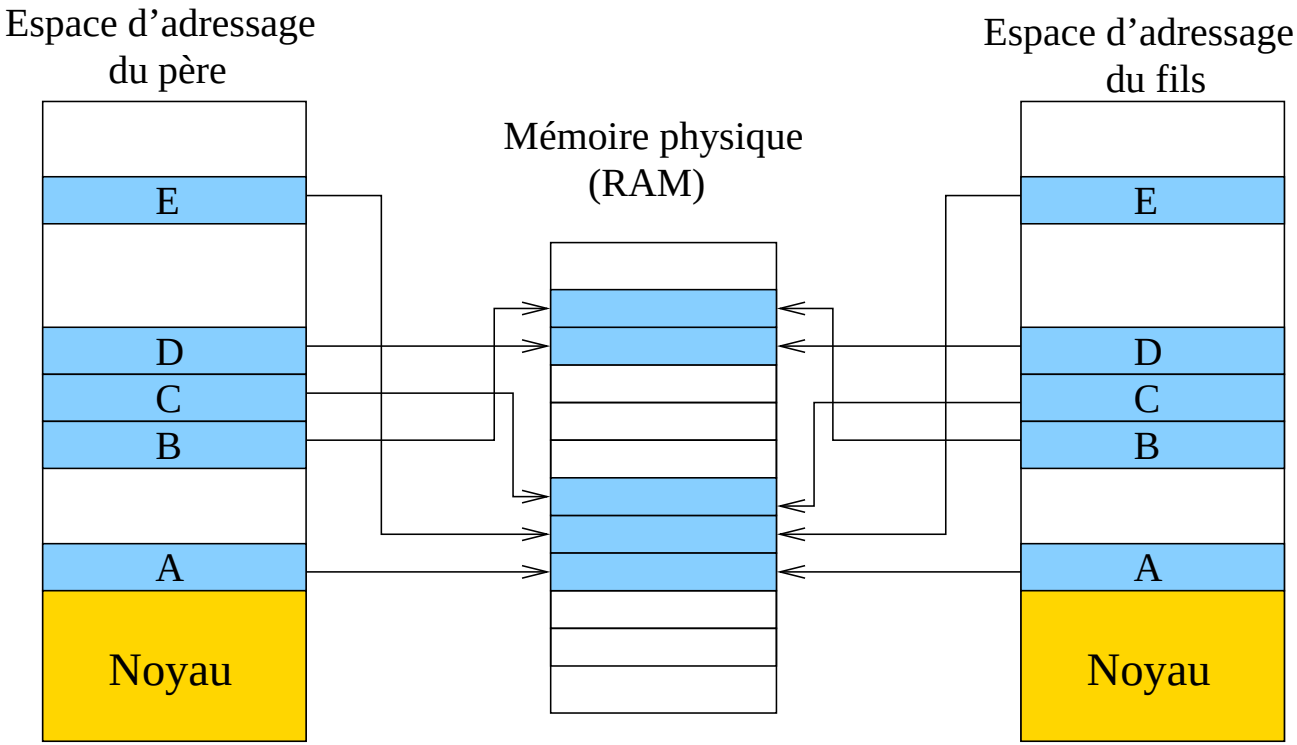

- juste après le `fork` : copies conformes, pages physiques partagées

Exemple : la copie sur écriture et `fork`

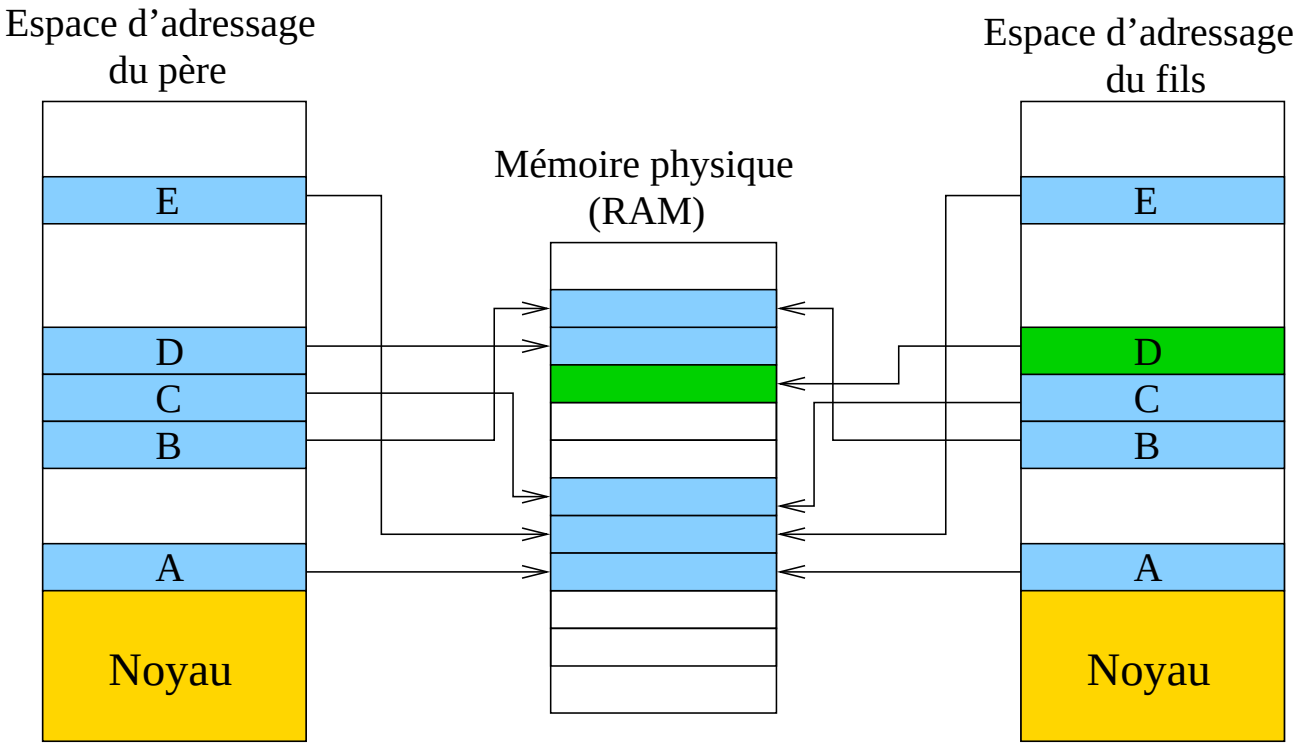

- plus tard : le fils a modifié la page D $\rightarrow$ **défaut de page** $\rightarrow$ copie de D $\rightarrow$ **projection de la copie** dans le fils

Exemple : projection d'un fichier en mémoire

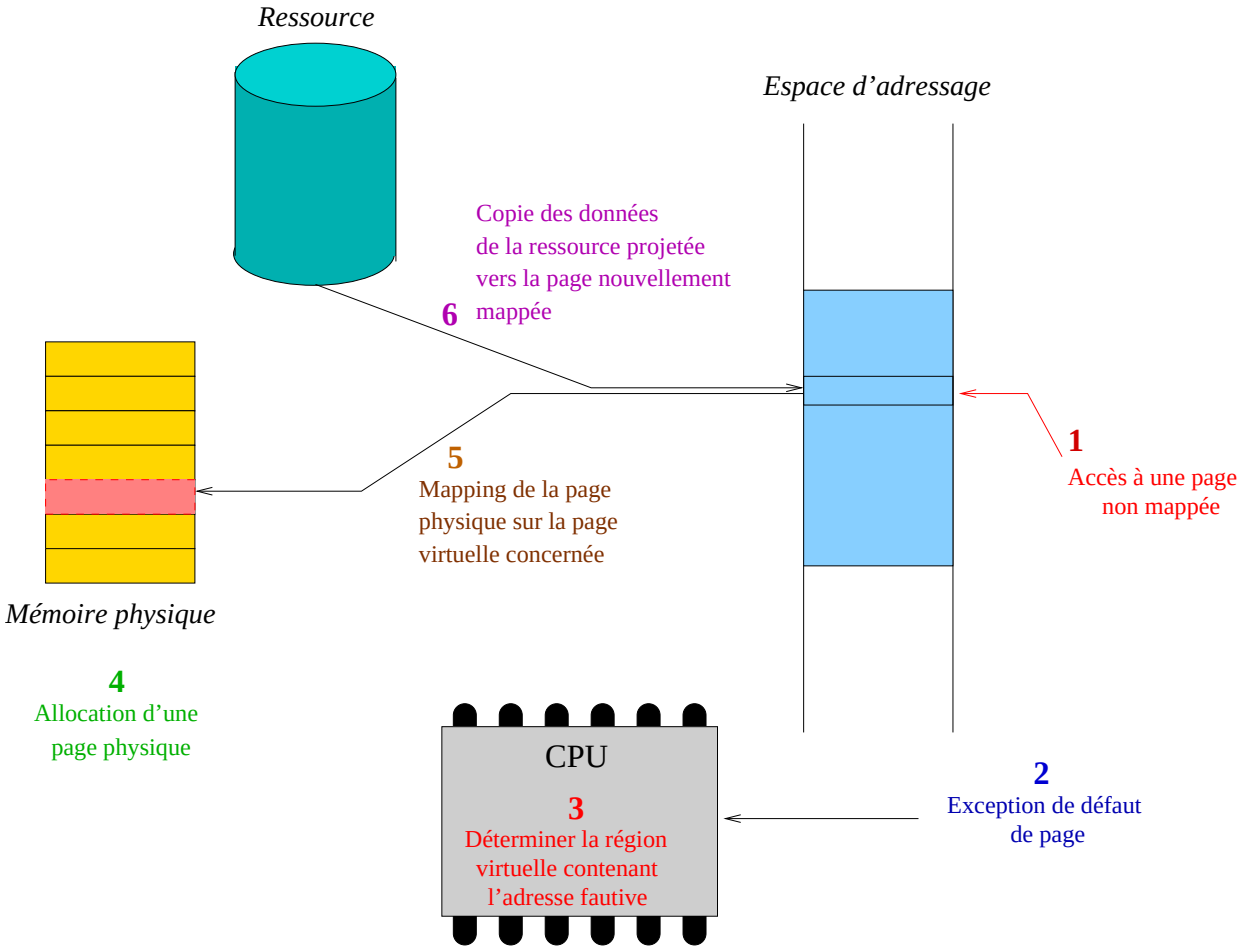

- fichier projeté en mémoire, p. ex. avec `mmap` (voir plus loin)

Exemple : pagination sur disque (*swap*)

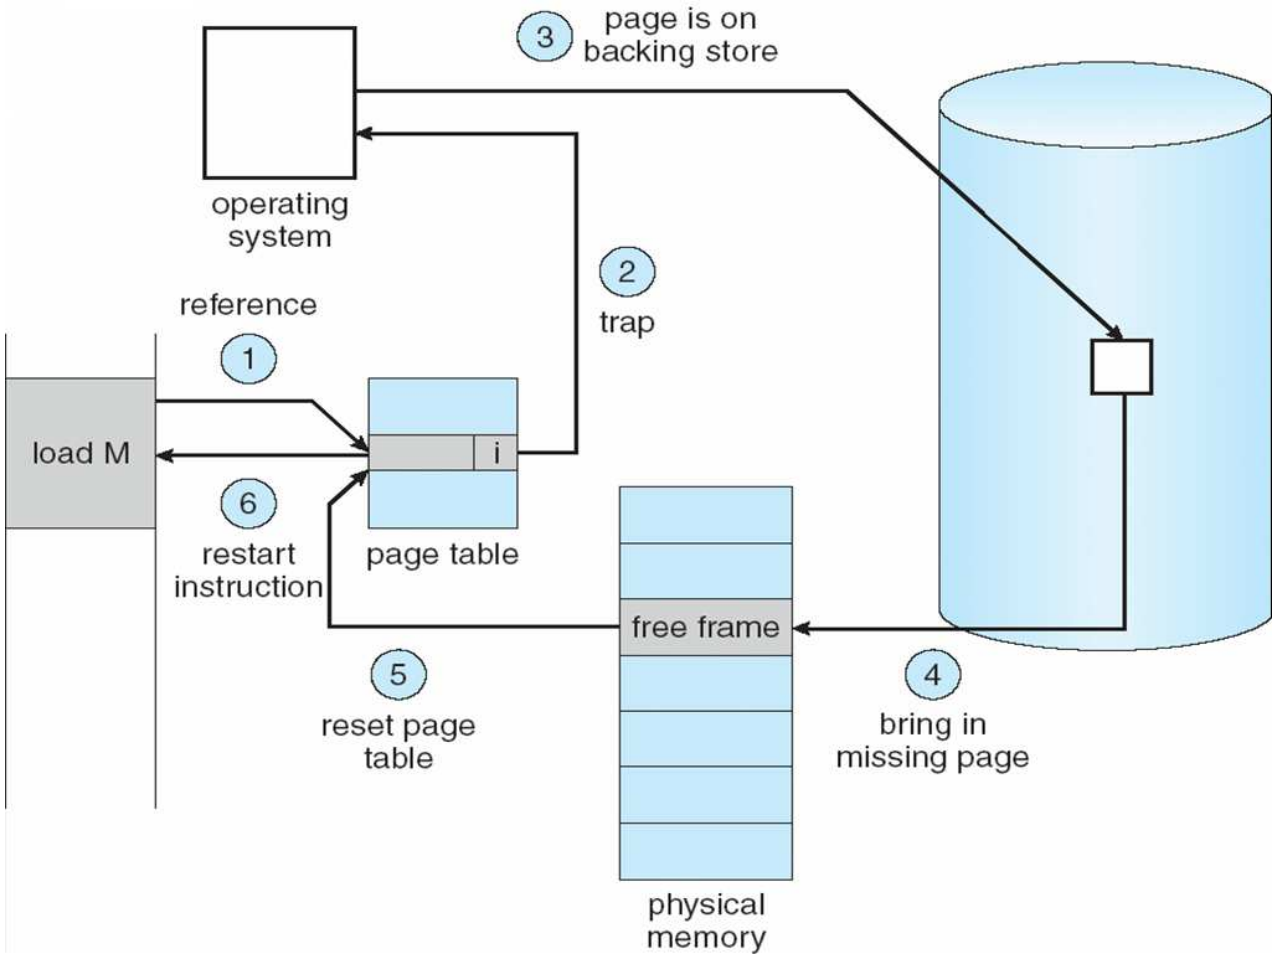

- la RAM est un « cache du disque dur »

Exemple : pagination sur disque (*swap*)

1. gcc a besoin d'une nouvelle page
2. le SE récupère une page inutilisée de `emacs`
   - si la page est propre (stockée sur disque à l'identique)
     - p. ex. le code binaire de `emacs`
     - peut toujours relire cette page depuis le fichier `/bin/emacs`
     - donc peut donner la page physique à `gcc`
   - si la page est sale (càd., pas d'exemplaire à jour sur disque)
     - doit écrire la page sur disque avant de la donner à `gcc`
3. marque la page virtuelle comme invalide dans `emacs`
   - au prochain accès à la page, `emacs` fera un *défaut de page*
   - alors le SE lira la page depuis le disque, la projettera dans l'E.A. de `emacs`, et poursuivra son exécution

Pagination sur disque : comment choisir ?

- quand la mémoire vive est pleine, il faut évincer des pages
  - càd. libérer des pages physiques en les envoyant sur disque
- politique d'éviction des pages : quelle page envoyer sur disque ?
  - typiquement implémentée dans le noyau (monolithique)
  - sans connaissance du sens des données contenues dans la page, sans informations du processus, etc.
  - càd. devinnette
- problème : envoyer sur disque peut être une mauvaise idée
  - ex. : un cache de rendu de fichier PDF
  - plus performant de détruire la page et de la reconstruire plus tard si besoin
  - cf. `madvise VOLATILE` and `vmpressure_fd`
- solution (?) : coopérer avec l'application
  - la notifier de la « pression mémoire »
  - lui permettre d'avoir sa politique d'éviction

Auto-pagination des applications sur micro-noyau
micro-noyau L4

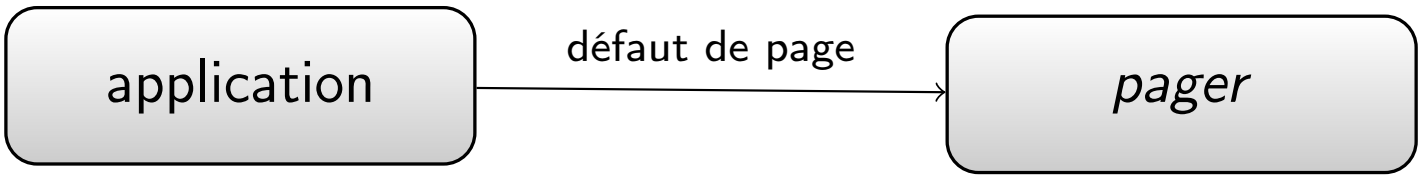

- chaque processus a un *thread* dédié : le *paginateur* (*pager*)
  - défaut de page → message envoyé au *pager*
  - le *pager* envoie un message « projection » au *thread* fautif
  - le *thread* fautif reprend son exécution
- hiérarchie de paginateurs
  - le paginateur racine a toute la mémoire physique projetée
  - peut en déléguer aux processus fils

Auto-pagination des applications sur micro-noyau
micro-noyau L4

- chaque processus a un *thread* dédié : le *paginateur* (*pager*)
  - défaut de page → message envoyé au *pager*
  - le *pager* envoie un message « projection » au *thread* fautif
  - le *thread* fautif reprend son exécution
- hiérarchie de paginateurs
  - le paginateur racine a toute la mémoire physique projetée
  - peut en déléguer aux processus fils

Interface POSIX pour manipuler les projections

- permet à un processus utilisateur de demander une projection ou d'en annuler une
- `void *mmap (void *addr, size_t length, int prot, int flags, int fd, off_t offset)`
  - retourne un pointeur (adresse virtuelle) de la projection, peut-être `addr`
  - `prot` définit les droits : `PROT_READ`, `PROT_WRITE`, `PROT_EXEC`
  - `flags` définit le type de projection
    - `MAP_ANONYMOUS` : mémoire physique (« anonyme »), `fd` ignoré
    - sinon projette le fichier pointé par `fd` (desc. de fichier)
    - `MAP_SHARED` → changements écrits dans le fichier
    - `MAP_PRIVATE` → changements privés au processus (COW)
- `int munmap(void *addr, size_t length)`

Exemple d'utilisation de mmap

```
#include <sys/mman.h>
#include <fcntl.h>
#include <unistd.h>

int main (int argc, char *argv[]) {
  int fd; char *projection;
  fd = open ("/dev/zero", O_RDONLY);
  projection = mmap (NULL, 123, PROT_READ,
     MAP_PRIVATE, fd, 0);
  printf ("%02x %02x %02x...\n",
  projection[0], projection[1],
  projection[2]); /* 00 00 00... */
  projection[0] = 1;       /* défaut de page -> SIGSEGV */
  return 0;
}
```

Plan

Quelle est la difficulté ?

- permettre d'allouer des blocs de n'importe quelle taille
- serait facile sans `free`

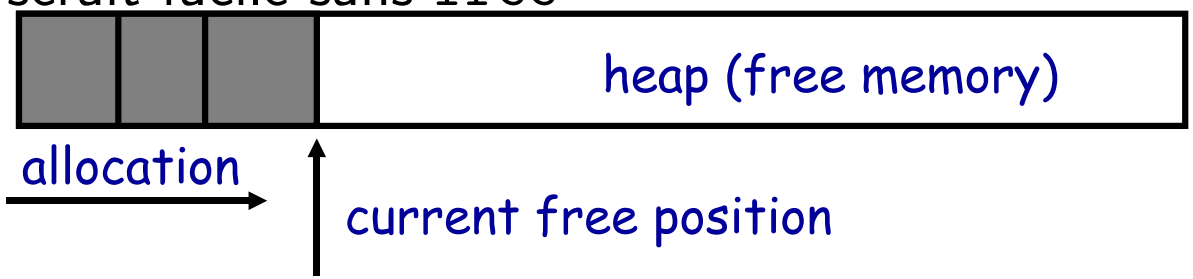

  - on ne ferait que agrandir le tas (`sbrk`)
- problèmes de fragmentation
  - plein de trous peuvent apparaître

  - mémoire libre mais requêtes non satisfaites !

Comment malloc s'y prend

- maintient une liste chaînée des zones libres

freelist

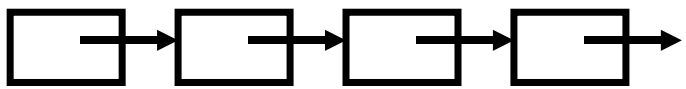

  - au début, un seul élément : le tas
  - puis un élément par intervalle libre
- si allocation >= 4 Kio → mmap (anonyme)
- sinon
  - cherche un intervalle libre de taille suffisante
  - ou agrandit le tas (sbrk)

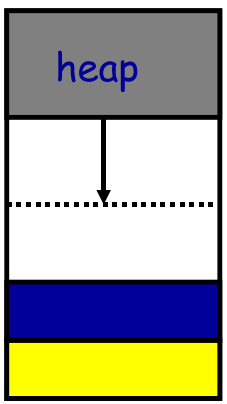

sbrk(4096)

```
/* add nbytes of valid virtual address space */
void *get_free_space(unsigned nbytes) {
  void *p;
  if(!(p = sbrk(nbytes)))
        error("virtual memory exhausted");
  return p;
}
```

Résumé

- la mémoire virtuelle, c'est bien
  - permet la répartition de la mémoire physique entre processus
  - permet l'isolation entre processus
- pagination gérée par le matériel et le système d'exploitation
  - unité matérielle de gestion de la mémoire virtuelle : la MMU
  - traduction d'adresses virtuelles $\rightarrow$ physiques par la MMU
  - guidées par le noyau (table des pages)
- bénéfices
  - économie de la mémoire physique
  - allocation à la demande des pages physiques
  - permet le *swap*, la projection de fichiers, etc.

Plan

Plan

Matrice de contrôle d'accès
Unix/POSIX, etc.

Objects

Subjects

	File 1	File 2	File 3	…	File n
User 1	read	write	-	-	read
User 2	write	write	write	-	-
User 3	-	-	-	read	read
…					
User m	read	write	read	write	read

- des sujets accèdent à des objets
  - sujet = processus/utilisateur
  - object = fichier

Utilisateurs Unix

- chaque utilisateur a un nom symbolique et un UID (entier)
  - exemples : `bob` → `101` ; `root` → `0`
- mots de passe et autres infos stockés dans `/etc`
  - `/etc/passwd` contient les noms/UID
  - `/etc/shadow` idem + un condensé des mots de passe
    - condensé = résultat d'une fonction de hachage à sens unique

Droits d'accès spécifiés par rôle/groupe

- chaque fichier Unix a un propriétaire et un groupe
  - droits *read*, *write*, *execute*
  - `chown -R ludo $HOME ; chgrp -R prof $HOME`
  - `chmod -R u+rw,g-w,o-rw $HOME`
- optionnellement une liste de contrôle d'accès (ACL)
- matrice de contrôle d'accès découpée par colonne :
  - à un objet est associé une série de paires sujets/permissions
- exemples
  - `$ ls -l examen.lout`
    `-rw-r--r-- 1 ludo users ... examen.lout`
  - `$ ls -l /bin/sh`
    `-r-xr-xr-x 1 root root ... /bin/sh`

Droits d'accès Unix

- les répertoires ont des droits aussi
  - droit en écriture requis pour pouvoir ajouter/effacer un fichier
- Le super-utilisateur `root` (UID 0) a tous les privilèges
  - peut lire/écrire tous les fichiers, changer leur propriétaire, etc.
  - nécessaire pour l'administration (ajout d'utilisateurs, sauvegarde, etc.)

Droits d'accès Unix hors système de fichiers

- certains périphériques vus comme des fichiers
  - `$ ls -l /dev/tty1`
    `crw------- 1 root root 4, 1 ... /dev/tty1`
- autres ressources traitées différement :
  - changement du propriétaire d'un fichier
  - changement de l'utilisateur/groupe du processus courant
  - montage/démontage de systèmes de fichiers
  - création de nœuds de périphériques (comme `/dev/tty1`)
  - ports TCP/UDP < 1024
  - `reboot`, `halt`, etc.

Trous de sécurité
bugs time-of-check-to-time-of-use (TOCTTOU)

- `find /tmp -exec rm -f -- {} \;`

find/rm	**Attacker**
	creat ("/tmp/badetc/passwd")
readddir ("/tmp") → "badetc"	
lstat ("/tmp/badetc") → directory	
readddir ("/tmp/badetc") → "passwd"	
	rename ("/tmp/badetc" → "/tmp/x")
	symlink ("/etc", "/tmp/badetc")
unlink ("/tmp/badetc/passwd")	

- `find` trouve que `/tmp/badetc` n'est pas un lien symbolique
- ... mais le fichier avec ce nom change entre temps !

Programmes `setuid`

- certaines actions légitimes demandent davantage de privilège
  - ex. : comment changer un mot de passe ?
  - mots de passe stockés dans `/etc/shadow` propriété de `root`
- « solution » : programmes setuid/setgid
  - s'exécute avec les privilège du propriétaire/groupe du fichier
  - chaque processus a un UID/GID *réel* et *effectif*
    - *réel* est celui qui a lancé le programme
    - *effectif* est le propriétaire/groupe du fichier — utilisé dans les vérifications de droits d'accès
- vu comme `s` dans la sortie de `ls`
  - `ls -l /bin/passwd`
    `-r-s--x--x 1 root root ... /bin/passwd`
  - `passwd`, `su`, `ping`, `netstat`, etc.

Problèmes des programmes `setuid`

- l'utilisateur contrôle l'environnement du programme
  - peut interférer sur son fonctionnement
  - changer `$PATH` si le programme utilise `execlp` & co.
  - fermer le descripteur de fichier 2 pour pousser le prog. a écrire un message d'erreur dans un fichier protégé
  - ...

Problèmes des droits Unix

- gestion des droits hétérogène
  - tout n'est pas vu comme un fichier
- un processus a plus de droits que nécessaire
  - tous les droits de l'utilisateur
  - accès à toute l'aborescence, au réseau, etc.
- noms de ressources symboliques découplés des droits afférents
  - on peut nommer un fichier même sans y avoir accès
  - solution : lier désignation et autorité (*capabilities*)
    - possibilité de désigner = possibilité d'accéder
    - matrice découpée par ligne
    - exemple : descripteurs de fichier ; pointeur Java

Sources
Merci à eux !

- cours de David Mazières (Stanford), `http://www.scs.stanford.edu/10wi-cs140/`
- cours d'Arnaud Legrand (IMAG), `http://mescal.imag.fr/membres/arnaud.legrand/teaching/20`
- illustrations supplémentaires par A. Tanenbaum, E. Skoglund, R. Javaux (Wikipédia), T. Petazzoni & D. Decotigny (Éditions Diamond), L. Courtès

Références

- *Simple Operating System*, articles dans GNU/Linux Magazine France, Diamond Éditions, T. Petazzoni et D. Decotigny, 2004–2007, `http://sos.enix.org/`
- *Modern Operating Systems*, Andrew Tanenbaum
- *Towards a New Strategy of OS Design*, Thomas Bushnell, 1994, `http://www.gnu.org/software/hurd/hurd-paper.html`
- Manuels des processeurs Intel, `http://www.intel.com/products/processor/manuals/`