

Architecture et Systèmes

Stefan Schwoon

Cours L3, 2025/2026, ENS Paris-Saclay

Programmation concurrente

Motivation :

séparation des tâches

meilleure efficacité (si le CPU dispose de plusieurs cœurs)

Dispositif principal : les processus

sûre, puissant, mais lourd (mémoire propre)

communication entre processus par pipe/signaux

Alternative : les *thread* (ou *processus légers*)

Les threads

Un **thread** est un fil d'exécution *à l'intérieur d'un processus*.

Normalement, un processus ne possède qu'un seul thread.

Rappel: Les processus sont des unités d'exécution avec leurs propres ressources (mémoire, signaux, . . .), entièrement indépendants l'un de l'autre.

Par contre, les threads d'un processus se *partagent* la plupart de leurs ressources.

Ressources privés et partagés

Ressources propres d'un thread :

son propre compteur de programme, son jeu de registres et sa propre pile
ses variables locales (non `static`), allouées sur la pile
code de retour (un pointeur `void*`)

Ressources partagés :

le reste de la mémoire (code et tas)
les fichiers ouverts
les signaux

Travailler avec les threads

Librairie standard : Posix threads (Pthreads)

Pour compiler, inclure `pthreads.h` et utiliser `gcc -pthread`.

Voir `pthreads(7)` pour un survol de la thématique.

Remarques

Tout processus démarre avec un thread qui peut en créer d'autres.

Mais il n'existe aucune hiérarchie entre les threads d'un même processus !

Deux méthodes pour l'ordonnancement :

Kernel threads: Les threads sont connus au noyau qui leur accorde les créneaux de calcul.

User threads: (disponible dans certains version de Linux)

Le noyau ne connaît que les processus ;
les threads sont réalisés par un ordonneur au niveau d'un processus
(donc à l'extérieur du noyau, en mode utilisateur).

Un thread possède un identifiant (type `pthread_t`).

Cet identifiant peut être utilisé avec les fonctions de la famille `pthread`.

Création d'un thread

N'importe quel thread peut en créer un autre avec `pthread_create`.

Le nouveau thread a comme paramètre une fonction de départ.

Cette fonction de départ prend un argument de type `void*` et renvoie un `void*`.

Terminaison d'un thread

Un thread termine . . .

à la fin de sa fonction de départ;

avec un appel `pthread_exit`;

si un autre thread appelle `pthread_cancel`.

Code de sortie:

Sur termination, le noyau enregistre un code de sortie.

Comme pour les processus, ce code peut être récupéré par un autre thread (`pthread_join`).

`pthread_detach` rend un thread “non-joignable” :
pas de code de sortie, ni de zombie.

Vie et mort d'un processus avec threads

Un processus est vivant lorsqu'il possède au moins un thread vivant.

Les actions suivantes tuent un processus avec tous ses threads :

appel d'`exit` (par n'importe quel thread);

le thread principal termine la fonction `main`
(appelle `exit implicit`) ;

le processus reçoit un signal terminant.

Threads vs processus

Avantages des threads : plus efficace

Communication entre threads plus facile (par mémoire partagée)

Création des threads moins couteux pour le noyau.

Inconvénients : moins sûre

Une erreur dans un seul thread peut tuer le processus entier.

Certains appels système ne sont pas **thread-safe**, deux threads ne peuvent pas s'en servir simultanément (voir *pthreads(7)* pour une liste).

Attention aux accès mémoire (*situations de compétition*) !

Problèmes de programmation concurrente

Compétition pour les ressources (accès/modif de données, périphériques)

→ problème d'exclusion mutuelle

Coordination: établir un processus distinct parmi des pairs

→ élection d'un leader

Signaler la présence / absence de données:

→ problème de producteur / consommateur

Programmation concurrente

Il existe beaucoup de solutions à ces problèmes en fonction du contexte :

Concurrence entrelacée ou vraie (calcul multi-cœur ou distribué)

Mémoire partagée ou pas

Accès mémoire en écriture/lecture seulement

Moyens de communication (synchrone/asynchrone/délai borné)

Existence d'une autorité centrale qui peut résoudre des conflits (p.ex. noyau, serveur).

Exclusion mutuelle

Modèle abstract :

On a un ensemble de processus/threads qui possède tous des **sections critiques** (une partie du code).

On doit assurer qu'au plus un seul processus est dans une section critique en même temps.

On souhaite une structure de données (on l'appelle **mutex**) qui permet au moins les opérations suivantes:

acquérir : si plusieurs processus essayent à obtenir le mutex, un seul réussira.

relâcher : un processus qui détient le mutex le rend accessible aux autres.

Propriétés intéressantes : correction, absence de blocages, justice

Propriétés d'un mutex

Correction: Un seul processus/thread peut détenir le mutex en même temps.

Absence de blocages: Si plusieurs processus/threads tentent d'obtenir le mutex, au moins un réussira.

Justice: Si un processus tente d'obtenir un mutex, il réussira à un moment donné.

Algorithme de Peterson

Solution pour deux processus avec mémoire partagé (trois bits)

On suppose que la lecture/écriture d'un bit est atomique.

Variables:

`flag[0]`: premier processus veut entrer dans une section critique

`flag[1]`: deuxième processus veut entrer dans une section critique

`victim`: pour résoudre des conflits

Algorithme de Peterson

Au départ : flag[0] = flag[1] = 0;

Code du processus **i=0,1** (autour de la section critique) :

```
autre = 1-i;  
flag[i] = 1;  
victim = i;  
while (victim == i && flag[autre]);  
... critical section ...  
flag[i] = 0;
```

Remarque: La conjonction (`&&`) peut être non-atomique et évaluée dans n'importe quel ordre.

En supposant que les processus terminent toujours leurs section critiques, l'algorithme de Peterson est ...

correct (un seul processus peut être critique à la fois) ;

juste (tout processus réussit finalement à entrer dans sa section critique);

libre de blocages.

Il est possible de généraliser le principe à n participants qui font $n - 1$ tours d'élimination.

Problèmes

Un algorithme tel que Peterson résout le problème en absence d'autorité centrale, mais présente des inconvénients:

Du code compliqué à écrire autour de chaque accès.

Nécessite la mémoire partagée.

Assez lourd pour plusieurs processus.

Facile de se tromper.

Attention aux réordonnancements dans le processeur !

Avec le noyau comme autorité centrale, POSIX propose plusieurs solutions (sémaphores, spinlocks).

Sémaphores

Un **sémaphore** est une structure de donnée gérée par le noyau qui offre une solution si tous les processus sont dans un même ordinateur.

Gère un compteur de *créneaux* disponibles, avec les opérations suivantes :

Init(*n*), où *n* est un nombre de *créneaux* initiaux

Wait: si un créneau est disponible, l'obtenir; sinon on attend

Post: libérer un créneau

Implémentation d'un sémafore

Naïvement :

```
Init(n) { ctr = n; }
```

```
Wait() { while (ctr == 0); ctr = ctr-1; }
```

```
Post() { ctr = ctr+1; }
```

Notes :

Les opérations sont “atomiques” (les bibliothèques se chargent de l’assurer).

lors d'un appel de `Wait`, lorsque le sémafore n'est pas disponible, le thread/processus concerné sera mis en sommeil (pas d'attente active).

Cas d'usage typique pour sections critiques

```
Init(1);  
  
while (1) {           while (1) {  
    ...;  
    Wait();  
    Critical1();  
    Post();  
    ...;  
}  
}
```

Mettre **Wait** et **Post** autour des zones critiques.

Problème de consommateur-producteur

Deux threads, un **producteur** (à gauche) et un **consommateur** (à droite).

Le consommateur utilise ce que le producteur crée (données, requêtes, ...).

On écrira `put` et `get` pour insérer des objets dans une zone mémoire partagée de taille **N** (sans préciser le détail technique).

Solution I: Attente active

Init: counter = 0;

```
while (1) {  
    produce(&object);  
    while (counter == N);  
    put(object);  
    counter = counter+1;  
}
```

```
while (1) {  
    while (counter == 0);  
    counter = counter-1;  
    get(&object);  
    consume(object);  
}
```

Attention, cette solution nécessite des incrément/decrément atomiques !

Producer/consumer avec sémaphores

```
Init(empty,N); Init(full,0);
```

```
while (1) {  
    produce(&object);  
    Wait(empty);  
    put(object);  
    Post(full);  
}
```

```
while (1) {  
    Wait(full);  
    get(&object);  
    Post(empty);  
    consume(object);  
}
```

On utilise deux sempaphore afin de signaler combien de créneaux sont libres resp. occupés.

Sémaphores dans Unix

Fournis par le noyau, voir `sem_overview(7)`:

Sémaphores **anonymes** (entre threads/processus père et fils):

`sem_init`, `sem_wait`, `sem_post`

Sémaphores **nommés** (dans tout le système):

`sem_open`, `sem_unlink`

Alternatives : Mutex et Spinlock

Mutex: Optimisé pour le cas d'un seul créneau, plus efficace dans ce cas-là.

Voir : pthread_mutex_lock

Spinlock: un seul créneau + attente active

peut être efficace dans un contexte de vraie concurrence quand les attentes sont courtes.

ne jamais utiliser dans un contexte de concurrence entrelacée !

Voir : pthread_spin_lock