

08 - Concurrency

Gaétan Richard
gaetan.richard@unicaen.fr

L2 – S4 2011/2012

I. Parallélisme

”Faux parallélisme”

Principe : Le système d'exploitation donne l'impression que les programmes s'exécutent en parallèle en alternant suffisamment rapidement sur une unité de calcul.

Utilisation : En général efficace pour une utilisation personnelle.

Principe : Certains calculs demandent une très forte puissance de calcul (ex : prévisions météorologique, simulation de phénomènes physiques, ...)

Solution : On utilise un grand nombre d'unités de calculs.

Problème : Il faut souvent échanger des informations, se synchroniser entre les unités.

Alternatives : Les unités de calcul peuvent être câblées :

- ▶ En clique ;
- ▶ En anneaux ;
- ▶ En grille (bi ou tri dimensionnelle) ;
- ▶ En hypercube ;
- ▶ ...

À chaque fois, il s'agit d'un compromis entre le coût (matériel et au niveau du calcul) du câblage et la facilité de programmation.

Quelques “grosses” machines

Top 10 : (issu du top 500, novembre 2011)

n°	Pays	Fabriquant	nb de cœurs	Rmax (PFlop)	date
1	Japan	K computer	705 024	10 510.00	2011
2	China	NUDT	186 368	2 566.00	2010
3	United States	Cray Inc.	224 162	1 759.00	2009
4	China	Dawning	120 640	1 271.00	2010
5	Japan	NEC/HP	73 278	1192.00	2010
6	United States	Cray Inc.	153 408	1 054.00	2011
7	United States	SGI ALix	111 104	1 088.00	2011
8	United States	Cray	153 408	1 054.00	2010
9	France	Bull SA	138 368	1050.00	2010
10	United States	Blade Center	122 400	1 042.00	2009

Problème : Pour utiliser de telles machines, il faut séparer les calculs en blocs “le plus indépendant” possibles et qui tiennent compte de la structure de la machine.

Recherche : Ces questions relèvent du domaine de l’**algorithmique parallèle**.

À l’avenir : Pour le moment, ces questions sont réservées à des machines “d’exception” mais la multiplication des cœurs en fait un domaine émergeant dans les machines grand publique.

Performance : Il est quasi impossible de rendre parallèle un code initialement conçu en séquentiel.

Programmation : Si vous programmez un programme ayant besoin de puissance de calcul, il faut réfléchir à l'avance à la séparation du calcul en tâches indépendantes et parallélisables.

2. Synchronisation

Threads

Principe : À l'opposé des processus qui sont indépendants, nous avons vu qu'il existe un moyen d'introduire du parallélisme à l'intérieur d'un même processus à l'aide de threads.

Avantage : Les threads partagent le même espace mémoire d'où une communication triviale.

Inconvénient : Les threads partagent le même espace mémoire d'où des problèmes de **concurrency**.

Démonstration

Idée : Utiliser des primitives de synchronisation.

Principe : Les primitives permettent un accès exclusif à une valeur qui servira de barrière.

Bonus : Ces primitives mettront également en œuvre un mécanisme d'attente.

Verrou : (**lock** en anglais) Une valeur booléenne qui peut être prise ou relâchée de façon atomique. Trois opérations :

- ▶ Création ;
- ▶ Acquisition (de façon bloquante ou non) ;
- ▶ Libération (doit être fait par celui ayant pris le verrou).

Si l'acquisition est bloquante, le thread est endormi. Il sera réveillé lorsque le verrou sera libre.

Le verrou sert à protéger des **sections critiques**

- ▶ Création : `threading.Lock()`
- ▶ Acquisition : `Lock.acquire([blocking=1])`
- ▶ Libération : `Lock.release()`

Note : Il existe également une notion de *reentrant lock* (Rlock) qui est lié à un thread.

Principe : Une **sémaphore** est un entier qui peut être incrémenté / décrétementé de manière atomique. Si celui-ci est à 0, la décrémentation est bloquante.

Il existe 3 opérations principales :

- ▶ Création à une valeur donnée ;
- ▶ Incrémentation (**V**, *Verhogen*, incrémenter) ;
- ▶ Décrémentation (**P**, *Proberen*, tester).

Elles ont été formalisées par *Edsger Dijkstra*.

Primitives :

- ▶ Création : `class threading.Semaphore([value]) ;`
- ▶ Décrément : `acquire([blocking]) ;`
- ▶ Incrément : `release()`.

Principe : Les conditions servent à synchroniser des threads : l'envoi d'une condition réveille tous les threads qui attendaient sur cette condition.

4 primitives :

- ▶ Création ;
- ▶ Attendre une condition ;
- ▶ Réveiller un thread en attente de cette condition ;
- ▶ Réveiller tous les threads en attente de cette condition.

Note : En python, une condition combine également les fonctions d'un verrou.

Primitives :

- ▶ Création : **`class threading.Condition([lock]) ;`**
- ▶ Acquisition : **`acquire(*args) ;`**
- ▶ Libération : **`release() ;`**
- ▶ Attente : **`wait([timeout]) ;`**
- ▶ Réveil unique : **`notify() ;`**
- ▶ Réveil de tous : **`notify_all() ;`**

Section critique

La principale utilisation des verrous est d'empêcher la concurrence dans des **sections critiques**. Le code est alors assuré d'être exécuté par un seul thread à la fois.

Exemple :

...

```
lock.acquire()  
# section critique  
lock.release()
```

...

Deadlock

Il est possible (et même courant) d'avoir plusieurs lock différents protégeant l'accès à des ressources. Dans ce cas, il peut surgir le problème de **deadlock** (*inter-blocage* en français).

Thread 1

```
lock1.acquire()  
lock2.acquire()  
# du code  
lock2.release()  
lock1.release()
```

Thread 2

```
lock2.acquire()  
lock1.acquire()  
# encore du code  
lock1.release()  
lock2.release()
```

Remarque : Dans certains cas, la présence de lock et de sémaphore peut faire en sorte qu'un ou plusieurs threads n'aient jamais accès à l'unité de calcul. On parle alors de **famine**.

À propos de ces problèmes

Reproduction : Ces problèmes étant liés à de la concurrence, il sont très difficiles à reproduire et peuvent rester ignorés pendant de très longue périodes.

Détection : Il existe quelques outils permettant de détecter de façon statique des problèmes potentiels ou de reconnaître à l'exécution lors de l'apparition d'un deadlock.

Solution : Il faut être prudent et bien réfléchir avant de mettre en place des systèmes multiples de locks.

3. Problèmes classiques

Principe : L'utilisation des verrous et sémaphores fait l'objet de nombreux exemples. On distingue cependant trois exemples classiques qui se retrouvent partout dans la littérature.

L'accès à une ressource partagée

Au tableau.

Au tableau.

Au tableau.

4. Mise en œuvre

Processeurs : Dans les processeurs, il existe des instructions d'échange qui s'effectuent de façon atomique.

Multi-core : Dans le cas du multicore, ces instructions sont étendues pour rester efficace.

Mise en œuvre : les verrous et sémaphores sont mises en place à l'aide d'un jeton et de ces opérations d'échange.