

Université Gaston Berger de Saint-Louis

Programmation concurrente

Pr. Ousmane THIARE

M2RSD [www.ousmanethiare.com]

10 mai 2024

Introduction

Programmation concurrente

Programmation parallèle

Types et catégories de parallélisme

Les différents types de parallélisme

Les différentes catégories de parallélisme

Programmation concurrente

Communication et synchronisation de processus

Synchronisation

Un exemple de synchronisation pour la coopération

Un exemple de synchronisation pour la compétition

Accès mutuellement exclusif à une ressource partagée

Mécanisme de synchronisation

Mutex : exclusion mutuelle

Exemple de l'utilisation de mutex avec Ruby

Sémaphores

Implantation

Problème

Exclusion mutuelle

Limiter les accès

Avantages

Inconvénients

Exemple

Opérations d'attente et de libération

Moniteurs

Thread et modèles de threads

Threads ou fils d'exécution

Modèles de thread

Introduction

Programmation concurrente

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

- Exécution "simultanée" de plusieurs parties d'un programme ;
- Exécution sur la même machine ou sur des machines différentes.

- Type de concurrence :
 - □ Pseudo-parallélisme : un seul processus s'exécute à la fois ;
 - Quasi-parallélisme : du pseudo parallélisme avec commutation à la charge du processus en exécution;
 - □ Parallélisme réel : plusieurs processus en même temps.
- Distinguer entre la programmation concurrente, parallèle, et distribuée.

- Programmation parallèle :
 - □ Exécution d'un programme sur plusieurs unités
 - Cores, processeurs, ordinateurs
- Programmation distribuée ou répartie :
 - Répartir l'exécution d'un programme sur plusieurs machines distinctes
 - Programmation parallèle sur plusieurs machines
- Programmation parallèle sur plusieurs machines
 - Style de programmation prenant en compte les différentes unités d'exécution offertes : threads, processus, ...

Introduction

Programmation parallèle

Types et catégories de parallélisme Les différents types de parallélisme Les différentes catégories de parallélisme

Programmation concurrente

Synchronisation

- Niveau instructions machine : exécutant plusieurs instructions machine simultanément;
- □ Niveau instructions de code : exécutant plusieurs instructions de code source simultanément ;
- Niveau unités : exécutant plusieurs unités (routines ou sous programmes) simultanément.
- □ Niveau programmes : exécutant plusieurs programmes simultanément.

Introduction

Programmation parallèle

Types et catégories de parallélisme Les différents types de parallélisme Les différentes catégories de parallélisme

Programmation concurrente

Synchronisation

- Le parallélisme Physique : plusieurs unités appartenant au même programme sont exécutées littéralement en parallèle sur différents processeurs;
- Le parallélisme Logique: plusieurs unités appartenant au même programme semblent (au programmeur et à l'application) être exécutées en parallèle sur différents processeurs. En fait, l'exécution réelle des programmes à lieu de manière intercalée sur un seul processeur;
- Pour le programmeur et le créateur de langage, les deux types de parallélisme sont les mêmes.

Problèmes

- □ Partitionnement :
 - Décomposer le programme en unités de bases (threads, processus, ...)
- □ Communication :
 - Échanger les données
- □ Synchronisation :
 - Ce sont les feux de signalisation pour l'exécution des tâches
 - Faire en sorte de ne pas se marcher dessus.

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Communication et synchronisation de processus

Synchronisation

- Mémoire partagée :
 - □ La communication est implicite
 - □ Accès mutuel aux données des autres
- Echange de messages :
 - Échanger les données
 - □ Chaque processus à son propre espace mémoire
 - □ Envoi de messages entre processus : synchrone ou asynchrone

Types de concurrence

- □ Disjointe : pas de communication entre les entités concurrentes
- Compétitive : compétition pour l'accès à des ressources (CPU, entrées/sorties, mémoire, ...)
- □ Coopérative : coopération pour atteindre un objectif commun

Introduction

Programmation parallèle

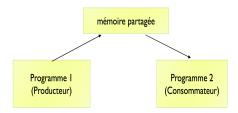
Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Un exemple de synchronisation pour la coopération Un exemple de synchronisation pour la compétition Accès mutuellement exclusif à une ressource partagée

Le Problème Du Producteur et du Consommateur



- Le programme 1 produit des données; Le programme 2 utilise ces données
- La synchronisation est nécessaire :
 - □ L'unité du consommateur ne doit pas prendre des données si la mémoire partagée (mémoire tampon) est vide;
 - ☐ L'unité du producteur ne peut pas placer de nouvelles données dans la mémoire partagée si elle n'est pas vide.

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Un exemple de synchronisation pour la coopération Un exemple de synchronisation pour la compétition Accès mutuellement exclusif à une ressource partagée

- Nous avons deux tâches (A et B) et une variable partagée (TOTAL)
- La tâche A doit additionner 1 à TOTAL
- La tâche B doit multiplier TOTAL par 2
- Chaque tâche accomplit son opération en utilisant le processus suivant :
 - Chercher la valeur dans TOTAL
 - □ Effectuer l'opération arithmétique
 - □ Remettre la nouvelle valeur dans TOTAL
- TOTAL a une valeur originale de 3

- Sans synchronisation, 4 valeurs peuvent résulter de l'exécution des deux tâches :
 - \square Si A s'accomplit avant que B ne commence \Rightarrow TOTAL=8
 - Si A et B cherchent leTOTAL avant que l'un ou l'autre remette la nouvelle valeur, alors :
 - Si A remet la nouvelle valeur dans TOTAL en premier ⇒ TOTAL=6
 - Si B remet la nouvelle valeur dans TOTAL en premier ⇒ TOTAL=4
 - \square Si B s'accomplit avant que A ne commence \Rightarrow TOTAL=7
- Ce genre de situation s'appelle un état de course parce plusieurs tâches font la course pour utiliser les ressources partagées et le résultat dépend de l'ordre de l'exécution des tâches.

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Un exemple de synchronisation pour la coopération Un exemple de synchronisation pour la compétition Accès mutuellement exclusif à une ressource partagée

- Une méthode générale consiste à monopoliser l'accès à une ressource
- Quand une tâche a fini d'utiliser une ressource partagée, elle doit l'abandonner de manière à ce que la ressource soit rendue disponible à d'autres tâches.

- Nous discutons maintenant de trois méthodes qui permettent l'accès mutuellement exclusif aux ressources :
 - Les Mutex
 - ☐ Les Sémaphores
 - Les Moniteurs

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

Mutex: exclusion mutuelle

Exemple de l'utilisation de mutex avec Ruby

- Un mutex est un verrou autour d'un bout de code
- Il a deux états :
 - Ouvert
 - □ Fermé
- Avant d'accéder à un code "critique", la tâche essaie de verrouiller le mutex (fermer)
 - S'il est déjà fermé : une autre tâche est dans la section critique, la tâche courante se met en attente
 - □ S'il est ouvert, la tâche courante ferme le mutex et passe à l'exécution de la section critique
- Après la fin de l'exécution de la section critique, la tâche courante ouvre le mutex et une des tâches en attente est réveillée.

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

Mutex: exclusion mutuelle

Exemple de l'utilisation de mutex avec Ruby

```
require 'thread'
mutex I = Mutex.new
var = 1
a = Thread.new {
  mutex I.synchronize {
   □ var = var + 10
b = Thread.new {
  mutex I .synchronize {
   \square var = var + 10
```

- Problème possible avec les mutex :
 - Interblocage
- Comment se produit l'interblocage?
 - □ Soient deux processus T1 et T2 et deux ressource R1 et R2
 - Un processus T1 ayant l'accès à la ressource R1
 - □ Un processus T2 ayant l'accès à la ressource R2
 - □ T1 demande l'accès à une ressource R2
 - □ T2 demande l'accès à une ressource R1
 - □ T1 et T2 sont bloqués :
 - Chacun attend l'autre pour libérer la ressource qu'il veut utiliser

$$x=5$$
 $y=2$

Fermer Mutex1 Fermer Mutex2 x = x + y Ouvrir Mutex2 Ouvrir Mutex1

Fermer Mutex1
x = x * y
Ouvrir Mutex1
Ouvrir Mutex2

Fermer Mutex2

- Introduits par Dijkstra dans les années 60
- Un sémaphore est une variable entière sur laquelle on définit deux opérations atomiques : P (wait) et V (signal)
- Un sémaphore peut être initialisé à une valeur $n \ge 0$.

- Soit un sémaphore S
- P(S) bloque le processus appelant jusqu'à ce que S > 0
- Une file d'attente est associée à chaque sémaphore pour contenir les processus bloqués.
- V(S) débloque le 1^{er} processus en attente s'il y en a un, sinon les signaux s'accumulent

Sémaphores

```
class semaphore {
     int valeur;
     listeDePcs liste;
   public:
     void P();
     void V();
```

```
semaphore::void P()
{ valeur--;
   if (valeur < 0)
        état du processus courant = bloqué;
        liste.ajoute(processus courant);
semaphore::void V()
{ process processus;
   valeur++;
   if (valeur <= 0)
       processus = liste.retire();
       processus.etat = prêt;
```

```
semaphore::void P()
{ if (valeur = 0)
        état du processus courant = bloqué;
        liste.ajoute(processus courant);
   else valeur--:
semaphore::void V()
  process processus;
   if (!liste.vide())
      processus = liste.retire();
       processus.etat = prêt;
   else valeur++;
```

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

Sémaphores

- Fil d'attente :
 - □ on l'implante où et comment?
 - son implantation assure ou non l'équité...
- Atomicité :
 - □ les opérations P et V doivent être atomiques (sections critiques)
 - comment y parvenir (mono et multi processeur)?

Introduction

Programmation parallèle

Types et catégories de parallélisme

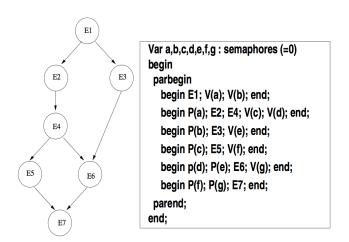
Programmation concurrente

Synchronisation

Mécanisme de synchronisation

```
semaphore mutex;
mutex.init(1);
   repeat
      P(mutex)
   ....section critique
      V(mutex)
   ....section non-critique
   forever
```

```
semaphore cond;
cond.init(0);
P1:
                         P2:
     S1;
                              P(cond);
     V(cond);
                               S2;
```



Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

- Soit un tampon contenant n espaces
- On peut initialiser un sémaphore à n pour détecter que le tampon est plein
- Utilisé dans le problème des producteurs/consommateurs

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

- Assurent l'exclusion mutuelle avec facilité
- Evitent l'interblocage
- Sont-ils équitables?

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

- connaissance des compétiteurs
- opérations toujours difficiles à utiliser
- on peut oublier de mettre des éléments en section critique
- les mêmes primitives assurent l'exclusion mutuelle et la synchronisation conditionnelle
- les opérations P et V ne donnent aucune idée sur la ressource visée

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

- On possède un tampon contenant n éléments chacun contenant un item
- Pour la synchronisation on utilise 3 sémaphores
 - mutex (exclusion mutuelle)
 - plein et vide (synchronisation conditionnelle)

```
type
        item : ...
        plein, vide, mutex : semaphore;
var
        tampon: array[0..n-1] of item;
        nextp, nextc : item;
```

```
begin
   plein := n; vide := 0; mutex := 1;
   parbegin
        producteur:
                            repeat
                               produire un "item" dans nextp;
                               P(plein); P(mutex);
                               dépose nextp dans tampon;
                               V(mutex); V(vide);
                            forever:
        consommateur:
                            repeat
                               P(vide); P(mutex);
                               lire nextc de tampon;
                               V(mutex); V(plein);
                               traite nextc;
                            forever:
   parend
end;
```

```
Program OPSYS;
      in_mutex, out_mutex : semaphore initial (1,1);
var
      nun_in, num_out : semaphore initial (0,0);
      free_in, free_out : semaphore initial (n,n);
      tampon_in : array[0..n-1] of entree;
      tampon_out : array[0..n-1] of sortie;
process lecteur;
      var ligne : entree;
      loop
            lecture ligne;
            P(free_in); P(in_mutex);
            dépose ligne dans tampon_in;
            V(in_mutex); V(num_in);
      end:
end process;
```

```
Process traitement;
       var
             ligne : entree;
                             resultat : sortie :
       loop
             P(num_in); P(in_mutex);
             lecture ligne de tampon_in;
             V(in_mutex); V(free_in);
              traitement de ligne et génération de resultat;
             P(free_out); P(out_mutex);
             dépose resultat dans tampon_out :
             V(out_mutex); V(num_out);
       end:
end process:
Process imprimante;
       var resultat : sortie ;
       loop
             P(num_out); P(out_mutex);
             lecture resultat de tampon_out :
             V(out_mutex); V(free_out);
             impression de resultat;
       end:
end process;
```

- Un objet peut être partagé par plusieurs processus
- Certains peuvent faire des lectures et d'autres des mises à jour
- Cette distinction est importante :
 - \square lectures simultanées seulement \rightarrow pas de problème.
 - □ écritures simultanées → risque d'incohérences
 - □ lectures et écriture simultanées → risque d'incohérences

Exemple

- Compte en banque A contient \$500
- Transaction B ajoute \$10 sur A
- Transaction C ajout \$1000 sur A
- Séquence :
 - □ B lit A (\$500)
 - □ C lit A (\$500)
 - C ajoute \$1000
 - C écrit A (\$1500)
 - B ajoute \$10
 - □ B écrit A (\$510) \Rightarrow A contient à la fin \$510

Solutions:

- Permet plusieurs lecteurs simultanées
- Accès exclusif aux écrivains
- Variations :
 - on ne fait attendre aucun lecteur
 - on ne fait attendre aucun écrivain
 - □ autres???

Exemple de solution

- 2 sémaphores : mutex (1) et wrt (1)
- 1 entier (nblecteur)

Exemple de solution

```
Lecteur : P(mutex)
             nblecteur++
             if (nblecteur=1) P(wrt)
          V(mutex)
         .... lecture....
          P(mutex)
             nblecteur--
             if (nblecteur=0) V(wrt)
          V(mutex)
Écrivain: P(wrt)
         .... écriture ....
          V(wrt)
```

Philosophes

- Introduit par Dijkstra (1965)
- 5 philosophes passent leur vie à penser et manger
- Ils partagent une table circulaire, 5 chaises, 5 plats de riz et 5 baguettes
- Pour manger il doit prendre 2 baguettes (les plus rapprochées)
- Si une des baguettes n'est pas disponible, il attend

Philosophes

```
Var baguette : array[0..4] of semaphore;
Procedure phil(i:integer)
begin
   repeat
      P(baguette[i])
      P(baguette[i+1mod5])
     ...mange ...
      V(baguette[i]
      V(baguette[i+1mod5])
     ... pense ...
  forever
end
begin
   baguette[0..4] := 1
   cobegin
      phil(0); phil(1); phil(2); phil(3); phil(4)
   coend
end
```

- Un sémaphore est une structure de données se composant d'un nombre entier et d'une file d'attente qui stocke des descripteurs de tâches
- Un sémaphore est une généralisation des mutex :
 - □ Un mutex est donc un sémaphore avec un nombre entier initialisé à 1 (sémaphore binaire)

- Le compteur d'un sémaphore permet d'indiguer le nombre de ressources encore disponibles ou le nombre de processus qui peuvent entrer en section critique
 - Dans les mutex, un seul processus peut entrer en section critique
- Il y a deux opérations liées à un sémaphore : attendre et libérer

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

Attendre(Sem)

- Si compteur de Sem > 0
 - Décrémente le compteur de Sem (une ressource en moins)
 - Exécuter la section critique
- Sinon
 - Mettre l'appelant dans la file d'attente de Sem

Libérer(Sem)

- Incrémenter le compteur de Sem (libérer une place pour l'accès à la ressource)
- ▶ Si la file de Sem n'est pas vide
 - Réveiller un processus en attente dans la file d'attente de Sem

Le problème du producteur consommateur résolu avec les sémaphores

```
Sémaphores : articledisponible, placedisponible; articledisponible.compteur = 0 placedisponible.compteur = BUFLEN
```

Producteur do
loop
Produire: valeur;
Attendre(placedisponible);
DEPOSER(valeur);
Libérer(articledisponible);
end loop
end producteur

Consommateur do
loop
Attendre(articledisponible);
Récupérer (valeur);
Libérer(placedisponible);
Consommer(valeur);
end loop
end consommateur

- Les moniteurs est un mécanisme de haut niveau de synchronisation
- Dans les moniteurs, les structures de données partagées avec leurs opérations sont encapsulées
- Fonctionnement :
 - Un seul processus peut être actif à un moment donné à l'intérieur du moniteur
 - □ Toutes les autres demandes d'exécution de primitives du moniteur sont bloquées tant qu'il y aura un processus actif à l'intérieur du moniteur
 - □ Cela produit une exclusion mutuelle garantie

- Quel est la différence entre les moniteurs et les sémaphores?
 - Un processus en section critique ne peut se bloquer qu'une fois la ressource est libérée
 - Le moniteur se charge de réveiller un processus en attente d'une ressource : ce n'est plus les processus qui s'occupent de gérer la file d'attente
 - □ Dans le cas des moniteurs on dispose de deux primitives : Attendre et Signaler

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

- Les threads partagent souvent les même variables
- Un thread peut être bloqué :
 - Une application se subdivise en processus et un processus peut être composé de plusieurs threads
 - Les processus sont généralement créés lors de la conception de l'architecture alors que les threads sont créés lors de la phase de programmation/exécution.

Introduction

Programmation parallèle

Types et catégories de parallélisme

Programmation concurrente

Synchronisation

Mécanisme de synchronisation

- Il existe différents modèles de thread
- Chaque modèle a ses avantages et inconvénients
- Chaque langage de programmation supporte un ou plusieurs modèles de thread.

- Il existe différents modèles de thread
- Chaque langage de programmation supporte un ou plusieurs modèles de thread
- Chaque modèle a ses avantages et inconvénients.

Modèles existants :

- Modèle 1:1
- Modèle 1 :N
- Modèle M:N.

- Dans ce modèle un thread utilisateur (du programme) est associé à un thread système
- C'est le modèle le plus répondu (surtout sous linux)
- On l'appelle souvent "threads natifs"

- Avantages :
 - Les threads peuvent être exécutés dans différentes CPUs
 - Vrai parallélisme
 - □ Les threads ne se bloquent pas mutuellement
 - □ Le scheduler système s'occupe de la gestion de chaque thread

- Inconvénients :
 - Difficultés de mise en place et de configuration
 - À chaque fois qu'un thread utilisateur est créé, il faudra notifier le système (OS) pour créer un état système à ce thread
 - □ Avec beaucoup de threads, le noyau de Linux bug
 - □ Limitation du nombre de threads qui peuvent être créés

- Dans ce modèle un thread système est associé à plusieurs thread utilisateur (du programme)
- On les appelles les "thread verts" (green threads)
 - □ Car ils sont légers, économique ... et écologique

- Avantages :
 - La création, exécution et arrêt de threads est facile et n'est pas couteuse
 - Beaucoup de threads peuvent être créés
 - Des dizaines de milliers et plus

Inconvénients:

- Le scheduler système n'a pas connaissance des threads en exécution
 - Exemple
 - le scheduler voit un thread, alors que côté utilisateur il y a y thread s'exécutant dans ce même thread
- Les opérations d'entrée/sortie peuvent bloquer tous les autres threads utilisateur qui s'exécutent à l'intérieur du même thread système

Inconvénients:

- Tous les threads utilisateur s'exécutent sur la même CPU
 - □ Pas de vrai parallélisme

Modèle M:N

- Dans ce modèle M threads système sont associés à plusieurs thread utilisateur (du programme)
- C'est un modèle hybride
 - □ Combinant les deux modèles précédents

Modèle M:N

- Avantages :
 - Les threads peuvent être exécutés dans différentes CPUs
 - Seulement quelques threads peuvent être bloqués par des appels système (I/O)
 - La création, exécution et arrêt de threads est facile et n'est pas couteuse
 - Beaucoup de threads peuvent être créés
 - Des dizaines de milliers et plus

Modèle M:N

- Inconvénients :
 - Le scheduler système et le scheduler utilisateur ont besoin de collaboration étroitement
 - □ Les threads utilisateur associés à un même thread système se bloquent si un d'eux effectue des opérations d'entrée/sortie (I/O)
 - □ Difficulté à écrire, maintenir et déboguer du code basé sur ce modèle

- Erlang
 - □ M :N
- Java,Ruby1.9,Python
 - □ 1:1
- Anciennes version de Java et Ruby
 - □ 1:N
- Le modèle 1 :1 est actuellement le plus efficace et le plus répandu