INTRODUCTION AUX SYSTEMES D'EXPLOITATION

TD2
Exclusion mutuelle / Sémaphores

S O M M A I R E

1.Généralités sur les sémaphores

1.1. Présentation

Un sémaphore est un mécanisme empêchant deux processus ou plus d'accéder simultanément à une ressource partagée. Sur les voies ferrées, un sémaphore empêche deux trains d'entrer en collision sur un tronçon de voie commun.

Sur les voies ferrées comme dans les ordinateurs, les sémaphores ne sont qu'indicatifs :
- Si un machiniste ne voit pas le signal ou ne s'y conforme pas, le sémaphore ne pourra éviter la collision.
- De même si un processus ne teste pas un sémaphore avant d'accéder à une ressource partagée, le chaos peut en résulter.

Un sémaphore binaire n'a que deux états :
- 0 verrouillé (ou occupé),
- 1 déverrouillé (ou libre).

Un sémaphore général peut avoir un très grand nombre d'états car il s'agit d'un compteur dont la valeur initiale peut être assimilée au nombre de ressources disponibles.
Par exemple, si le sémaphore compte le nombre d'emplacements libres dans un tampon et qu'il y en ait initialement 5 on doit créer un sémaphore général dont la valeur initiale sera 5. Ce compteur :
- Décroît d'une unité quand il est acquis (" verrouillé ").
- Croît d'une unité quand il est libéré (" déverrouillé ").

Quand il vaut zéro, un processus tentant de l'acquérir doit attendre qu'un autre processus ait augmenté sa valeur car il ne peut jamais devenir négatif.
L'accès à un sémaphore se fait généralement par deux opérations :

P : pour l'acquisition
V : pour la libération

Un moyen mnémotechnique pour mémoriser le P et le V est le suivant :
- **P**(uis-je) accéder à une ressource.
- **V**(as-y) la ressource est disponible.

Si nous devions écrire en C ces deux primitives nous aurions le résultat suivant.

P	V

void P(int* sem)
{
while (*sem <=0);
(*sem)--;
}
	void V(int *sem)
	{
	(*sem)++
	}

Les deux fonctions C précédentes pour les opérations P et V ne fonctionnent pas :
- La variable sémaphore sur laquelle pointe *sem* ne peut être partagée entre plusieurs processus, car ils ont des segments de données distinctes.
- Ces fonctions ne s'exécutent pas de manière indivisible, le noyau pouvant interrompre à tout moment un processus. On peut imaginer le scénario suivant :
  - Un processus N_1 termine la boucle *while* dans P et est interrompu avant de pouvoir décrémenter le sémaphore.
  - Un processus N_2 entre dans P, trouve que le sémaphore est égal à 1, parcourt sa boucle *while* et décrémente le sémaphore à 0.
  - Le processus N_1 reprend et décrémente le sémaphore à -1 qui est une valeur illégale.
  - Si *sem* vaut 0, P réalise une attente active qui n'est pas très judicieux pour utiliser au mieux l'unité centrale.

Pour toutes ces raisons, P et V ne peuvent tout simplement pas être programmées dans l'espace utilisateur.

Les sémaphores doivent être fournis par le noyau qui, lui, peut :
- Partager des données entre les processus.
- Exécuter des opérations indivisibles (ou atomiques).
- Allouer l'unité centrale à un processus prêt quand un autre processus se bloque.

1.2. Un mécanisme fourni par le noyau

La notion de sémaphore est implémentée dans la plupart des systèmes d'exploitation. Il s'agit d'un concept fondamental car il permet une solution à la plupart des problèmes d'exclusion.
Ce concept nécessite la mise en œuvre d'une variable, le sémaphore, et de deux opérations atomiques associées P et V.
Soit séma la variable, elle caractérise les ressources et permet de les gérer. Lorsqu'on désire effectuer un exclusion mutuelle entre tous les processus par exemple, il n'y a virtuellement qu'une seule ressource et on donnera à séma la valeur initiale de 1.
P(séma) correspond à une prise de ressource et V(séma) à une libération de ressource.

Lorsqu'un processus effectue l'opération P(séma) :
- si la valeur de séma est supérieure à 0, il y a alors des ressources disponibles, P(séma) décrémente séma et le processus poursuit son exécution,
- sinon ce processus sera mis dans une file d'attente jusqu'à la libération d'une ressource.

Lorsqu'un processus effectue l'opération V(séma) :
- si il n'y a pas de processus dans la file d'attente, V(séma) incrémente la valeur de séma,
- sinon un processus en attente est débloqué.

2.Exercices sur les sémaphores

2.1. Exercice N°1: problème de circulation

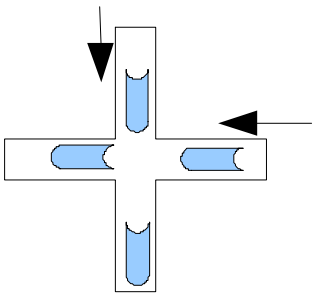

1. Nous somme sur une intersection où les routes sont en sens unique comme le montre le schéma ci-dessus.
   - Modéliser le problème sous forme de processus et de ressources
   - Quel problème peut se produire ?
   - Donnez une solution au problème en pseudo code en utilisant des/un sémaphore(s).
2. On suppose maintenant l'intersection (sur la page) suivante:
   - Que peut-il se produire ?
   - Donnez une solution au problème en pseudo code en utilisant des sémaphores.

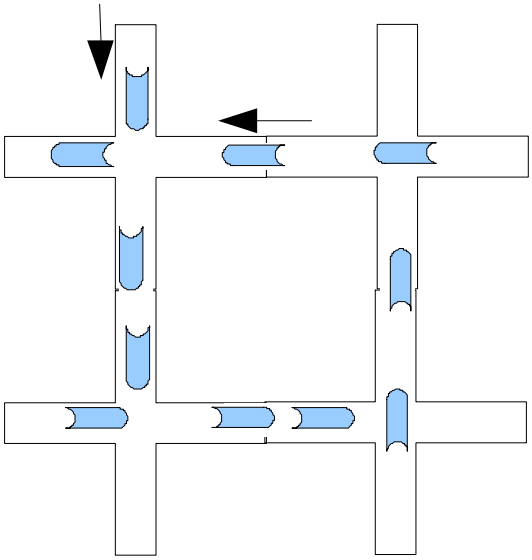

2.2. Exercice N°2

Deux processus (P1 et P2) souhaitent établir un rendez-vous avant l'exécution de la fonction RDV1() pour l'un et RDV2() pour l'autre. En utilisant les sémaphores, écrire la séquence de pseudo-code de P1 et P2 permettant d'établir ce rendez-vous.
Décrire le comportement des deux processus à partir d'un diagramme temporel.

2.3. Exercice N°3

Effectuer un rendez-vous entre 3 processus P1, P2 et P3.

2.4. Exercice N°4

Généraliser le rendez-vous précédent entre N processus avec un ensemble de sémaphores initialisés à 0 : sema [i] désigne le sémaphore i.
Ecrire le code du processus Pi permettant d'établir ce rendez-vous.

2.5. Exercice N°5

On est toujours dans le cas d'un rendez-vous de N processus mais avec les contraintes suivantes :

1. Tous les processus ont le même code.
2. Il y a une variable globale qui compte le nombre de processus arrivés au rendez-vous. Soit cette variable shm.nbArrivés stockée dans un segment de mémoire partagée shm et initialement positionnée à la valeur 0.
3. C'est le dernier processus arrivé qui libère tous les autres.

La solution proposée est la suivante :

```
#define N 10 /* Nombre de processus */
```

```
int sema [N] /* un semaphore par processus initialisé à 0 au départ */
void Processus (int i)
{
      int k ;
      if shm.nbArrivés != N-1 {
            shm.nbArrivés ++ ;
            P (sema [i]);
      }
      else {
            for (k=0 ;k<N ;k++) {
                  if (k != i) V(sema[k]) ;
            }
      }
}
```

Expliquer les principes de fonctionnement de l'algorithme proposé. La solution proposée est-elle correcte ? Sinon corrigez.

3. Lecteur/Rédacteur

3.1. Présentation

- Soit la variable tour, qui a initialement la valeur 1 et dont le contenu permettra de savoir qui peut rentrer en section critique
  - 1 : le processus 1 peut rentrer en section critique
- Soit une donnée partageable par plusieurs processus :
  - Un rédacteur qui met à jour la donnée et qui y accède en lecture/écriture.
  - Plusieurs lecteurs qui consultent la donnée en lecture uniquement.

- On souhaite obtenir un maximum de parallélisme tout en conservant une information cohérente :
  - Pas de lecteur et rédacteur en //.
  - Pas 2 rédacteurs en //.

  Le début de solution proposée est la suivante :
  - Un rédacteur demande toujours l'autorisation d'utiliser la donnée.
  - Un lecteur ne demande l'autorisation d'utiliser la ressource que s'il est le 1er lecteur.

  Soit donnée le sémaphore d'accès à la donnée et dont la valeur initiale est 1.

```
Processus REDACTEUR
Processus LECTEUR
Redacteur () {
      P(donnee) ;
      ecrire (donnee) ;
      V(donnee) ;
}
Lecteur () {
      if pas-de-lecteur-en-cours {
            P(donnee) ;
      }
      lire (donnee);
      if dernier-lecteur {
            V(donnee) ;
      }
}
```

3.2. Exercice

A l'aide d'une variable *nbLecteur* stockée dans un segment de mémoire partagée, et d'un sémaphore *mutex_ l* de protection associé à cette variable, écrire le code du processus LECTEUR.

4. Pour aller plus loin

4.1. Présentation

Dans l'exercice proposé, il n'existe pas de priorité entre les différents processus. On souhaite à présent changer cela.

4.2. Exercices

Répondez aux questions suivantes :

1. Quel est le risque pour les rédacteurs dans la situation actuelle ?
2. Comment garantir que si un rédacteur et un premier lecteur sont simultanément candidats, le rédacteur sera prioritaire ?
3. Comment garantir qu'un rédacteur est prioritaire sur les lecteurs (c'est-à-dire que si un rédacteur est bloqué, plus aucun lecteur ne peut accéder à la ressource) ?