

Algorithmique et techniques de base du calcul parallèle

Important. L'examen est composé de deux problèmes indépendants. Tous les documents sont autorisés.

Exercice A - Ordonnancement glouton

On considère une machine parallèle comportant p processeurs P_i ($0 \leq i < p$). Chaque processeur connaît son indice $i \in 0, \dots, p-1$.

De plus, le tableau de booléens `EstInactif[0 .. p-1]` donne l'état de chaque processeur: `EstInactif[i]` vaut 1 (respectivement 0) si le processeur i est inactif (respectivement actif).

Sur cette machine, on cherche à construire un algorithme parallèle de grain fin pour implanter un ordonnancement de type vol de travail.

1. On suppose que l'on a k tâches prêtes J_1, \dots, J_k qui peuvent être volées; ces tâches sont stockées dans une mémoire partagée accessible par tous les processeurs. On désire affecter à chaque processeur inactif j une tâche parmi J_1, \dots, J_k tel que deux processeurs inactifs différents aient deux tâches différentes. On calcule pour cela un tableau d'indices `JobCible[0 .. p-1]` tel que si le processeur j est inactif, alors il vole la tâche $J_{\text{JobCible}[j]}$.

Donner un algorithme parallèle de coût $T_\infty = O(\log p)$ et $T_1 = O(p)$ qui calcule le tableau `JobCible`. **Indication:** on pourra utiliser un algorithme de calcul de préfixes.

2. On suppose maintenant que chaque processeur possède localement les tâches qu'il a créées. Le tableau en mémoire partagée `NbJobsLocaux[0 .. p-1]` donne le nombre de tâches prêtes sur chaque processeur. À un top t donné, pour $0 \leq i < p$, `NbJobsLocaux[i]` donne le nombre de tâches sur le processeur i :

- si `NbJobsLocaux[i] = 0`, le processeur i est inactif;
- si `NbJobsLocaux[i] ≥ 1`, le processeur i est actif; il possède alors `NbJobsLocaux[i]-1` tâches qui peuvent être volées par des processeurs inactifs.

On désire calculer un tableau `IdentiteCible[0 .. p-1]` tel que si le processeur j est inactif, alors `IdentiteCible[j]` contient l'indice du processeur à qui il va voler une tâche. Deux processeurs inactifs peuvent voler un même processeur actif; mais un processeur actif ne doit pas être la cible de plus de processeurs qu'il n'a de jobs, i.e.

$$\forall 0 \leq i < p : \quad \text{Card} \{ j = 0, \dots, p-1 / \text{IdentiteCible}[j] = i \} \leq \text{NbJobsLocaux}[i] - 1$$

Donner un algorithme parallèle de coût $T_\infty = O(\log p)$ et $T_1 = O(p)$ qui calcule le tableau `JobCible`. **Indication:** on pourra utiliser, outre des calculs de préfixes comme précédemment, des recherches dichotomiques.

3. Votre algorithme est-il EREW, CREW ou CRCW ? A quelle classe de complexité NC^k appartient ce problème d'allocation de tâches aux processeurs inactifs ?
-

Problème . Construction et analyse de programmes parallèles

On considère un programme dont le graphe de précédence est le graphe Diamant $n \times m$; on suppose $n \leq m$. Le schéma de calcul est décrit dans la figure 1.

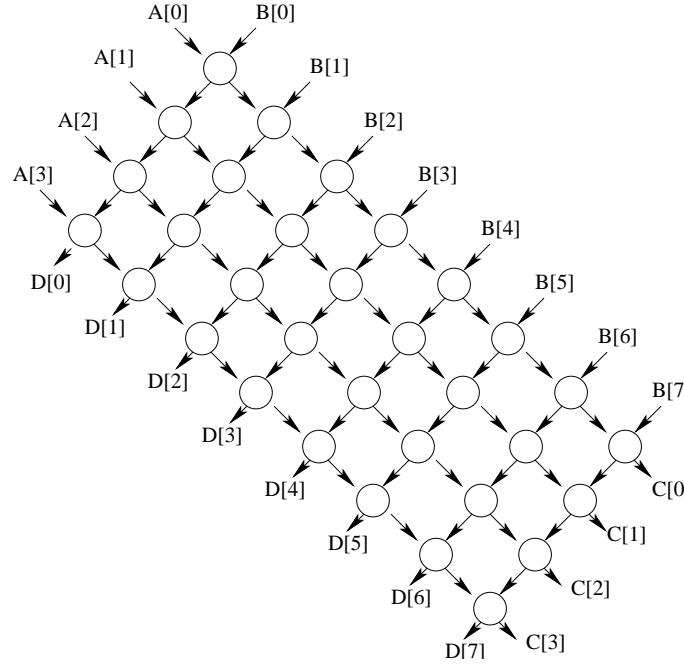


Figure 1: Graphe de précédence Diamant avec $n = 4$ et $m = 8$.

La procédure séquentielle de base est la suivante:

```
void DiamantSeq(int n, int m, IN Elt A[0 .. n-1], IN Elt B[0 .. m-1],
                 OUT Elt C[0 .. n-1], OUT Elt D[0 .. m-1] ) {

    Elt oldtmpA[0 .. n-1] ; // zone de memoire pour calcul intermédiaire;
    Elt newtmpC[0 .. n-1] ; // zone de memoire pour calcul intermédiaire;

    for (int k=0; k<n; k++) oldtmpA[k] = A[k] ;

    // Boucle de calcul
    for (int i=0; i<m; i++) {
        newtmpC[0] = localcompute ( oldtmpA[0], B[i] ) ;
        for (int j=1; j<n; j++) {
            newtmpC[j] = localcompute ( oldtmpA[j], newtmpC[j-1] ) ;
        }
        D[i] = newtmpC[ n-1 ] ;
        for (int k=0; k<n; k++) oldtmpA[k] = newtmpC[k] ;
    }
    for (int k=0; k<n; k++) C[k] = newtmpC[k] ;
}
```

Dans toute la suite, on suppose que le coût de l'opération élémentaire `localcompute` est une constante τ ; on ne s'intéresse qu'au coût de ces opérations `localcompute`.

Analyse de l'algorithme séquentiel

On considère une machine SMP : on ne prend pas ici en compte le coût des communications.

Question I.

1. Calculer le coût T_1 en nombre d'opérations `localcompute` du graphe Diamant $n \times m$.
2. Calculer le chemin critique T_∞ du graphe Diamant.
3. Montrer que n processeurs suffisent pour atteindre ce temps T_∞ . Dessiner sur le graphe un placement possible des calculs sur les processeurs.
4. On considère maintenant qu'on a p processeurs identiques avec n multiple de p . Comment regroupez-vous les calculs sur p processeurs ?
5. On considère maintenant qu'on a p processeurs différents mais ayant des vitesses proportionnelles; le processeur P_i a une vitesse v_i . Comment adaptez-vous le placement précédent ?

Prise en compte des communications

On s'intéresse maintenant au coût des communications. On suppose qu'un processeur ne peut émettre qu'un message à la fois; par contre, il peut calculer et recevoir un message pendant qu'il en émet un autre. On suppose que le délai de la communication d'une donnée de type Elt est α ; i.e. lorsqu'un processeur P émet au top t une donnée de type Elt vers un processeur P' , le processeur reçoit la donnée au top $t + \alpha$.

Question II.

1. Quels sont les volumes de communications C_1 et C_∞ dans le graphe Diamant ?
 2. On suppose que l'on a n processeurs. Comment regrouperiez-vous les calculs ? Donner le coût d'exécution de ce placement en fonction de α , τ , n et m .
-

Algorithme parallèle par bloc

Dans toute la suite on suppose que $n = m$ et on s'intéresse maintenant à la prise en compte du coût de description du parallélisme (i.e. la description du graphe) sur machine SMP. On suppose que le coût de création d'un processus qui prend en entrée μ paramètres est μ .

Pour prendre en compte le surcoût induit par la génération du parallélisme (i.e. la description du graphe), on considère un algorithme `DiamantPar` basé sur un regroupement par blocs bidimensionnels des tâches. Pour cela, les tableaux A , B , C et D sont découpés en K blocs de (n/K) éléments; chaque calcul sur un bloc de taille n/K est effectué en séquentiel par l'algorithme `DiamantSeq`. La figure 2 illustre cette découpe pour $K = 2$.

Question III. Algorithme par blocs sans coût de communication.

On ne prend pas ici en compte les coûts de communication.

1. Décrire (en pseudo-code) le schéma de l'algorithme par bloc; on précisera les paramètres de chaque processus.
2. Calculer le coût T'_1 de ce programme en fonction de K , n , τ et μ .

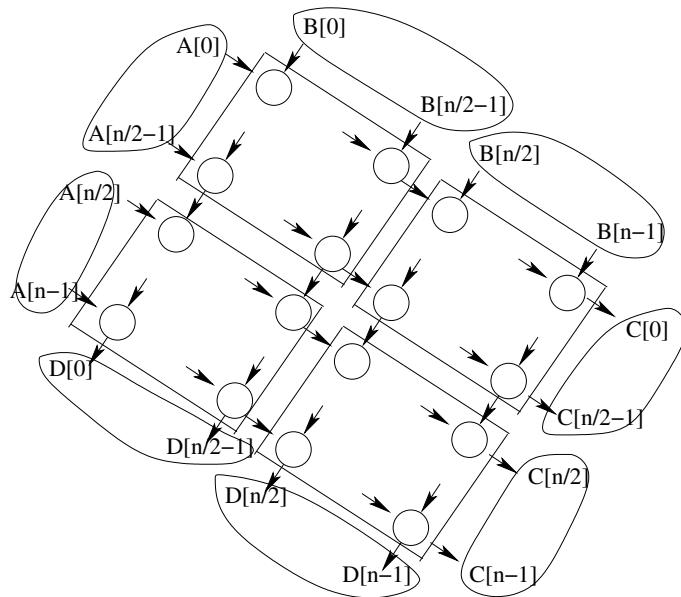


Figure 2: Diamant avec découpe des tableaux A, B, C, D en $K = 2$ blocs de taille $n/2$.

3. Calculer le temps T'_∞ de ce programme en fonction de K et n .
4. Quelle valeur choisissez-vous pour K ? Expliquez votre choix.

Question IV. Algorithme par blocs avec coût de communication. On considère toujours que $n = m$ et on désire programmer l'algorithme par bloc de la question III sur une architecture distribuée avec des processeurs identiques. Afin de regrouper les communications, on ne communique un tableau résultat que lorsque le calcul de tous ses éléments est terminé. Le délai de la communication d'un bloc de n/K éléments est alors $\alpha + \beta \cdot \frac{n}{K}$ et on suppose $\alpha \geq \beta$.

1. Donner le coût C_1 et C_∞ de l'algorithme par bloc en fonction de n, K, α et β .
 2. En déduire le coût T_1 et T_∞ de l'algorithme par bloc en fonction de n, τ, α et β . Ce coût inclue les coûts de description du parallélisme et de communication
 3. Comment choisissez-vous K pour minimiser le temps d'exécution ?
 4. On suppose que le K optimal est K_{opt} , et on veut exécuter l'algorithme avec $p = K_{opt}$ processeurs. Comment placez-vous les tâches sur les processeurs ?
-

Exercice B

On se place dans les conditions du cours sur les communications collectives. Soit $p = 2^k$ processeurs. On considère que le coût de transmission d'un message de taille n entre deux processeurs est $t(n) = \alpha + n/\beta$. Un processeur ne peut émettre qu'un message à la fois. Par contre il peut émettre un message pendant qu'il reçoit un autre message.

1. Donner un algorithme de communication collective lorsque deux processeurs distincts doivent émettre chacun leur message vers tous les autres processeurs (2 broadcasts en parallèle).
2. Donner le coût de cet algorithme.

3. Reprendre les deux questions précédentes mais cette fois avec un algorithme adapté aux messages longs.
4. Justifier pourquoi ce second algorithme est plus performant que le précédent pour les messages longs (lorsque p est grand).