CentraleSupélec

Mineure CalHau1

MPI : produit de matrices denses en anneau

Stéphane Vialle

CentraleSupélec université PARIS-SACLAY ÉCOLE DOCTORALE Sciences et technologies de l'information et de la communication (STIC) RISEGrid Région lorraine Grand Est ALSACE CHAMPAGNE-ARDENNE LORRAINE

Stephane.Vialle@centralesupelec.fr
http://www.metz.supelec.fr/~vialle

CentraleSupélec

Produit de matrices denses en anneau

- **Algorithme distribué en « anneau de processus »**
- Modélisation de performances sur un anneau théorique
- Topologie de processus *vs* réseau réels
- Modélisation des comms. selon déploiement

Produit de matrices denses sur anneau

Algorithme distribué

Problème à résoudre :

A, B, C : n x n = N éléments

C = A . B $\quad c_{ij} = \sum_{k=1}^{n} (a_{ik} b_{kj})$ $\quad$ O(Nbr d'opérations) = $O(N^{3/2})$

Comment répartir les données ?

Pb du **partitionnement**

Calculs déterministes localisés :
- Partitionnement statique

Calculs déterministes NON localisés :
- Duplication ?
- **Circulation** ?

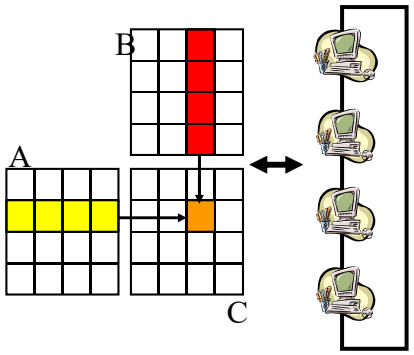

Produit de matrices denses sur anneau

Algorithme distribué

Partitionnement sur un anneau de processeurs :

- A partitionnée en blocs de lignes
- B et C partitionnées en blocs de colonnes
- **Circulation de A**
- B et C statiques

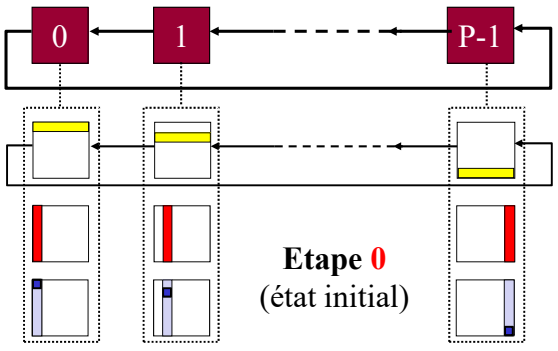

Etape 0
(état initial)

Topologie

Partitionnement et circulation de A

Partitionnement statique de B

Partitionnement statique de C

CentraleSupélec

Produit de matrices denses sur anneau

Algorithme distribué

Partitionnement sur un anneau de processeurs :

- A partitionnée en blocs de lignes
- B et C partitionnées en blocs de colonnes
- **Circulation de A**
- B et C statiques

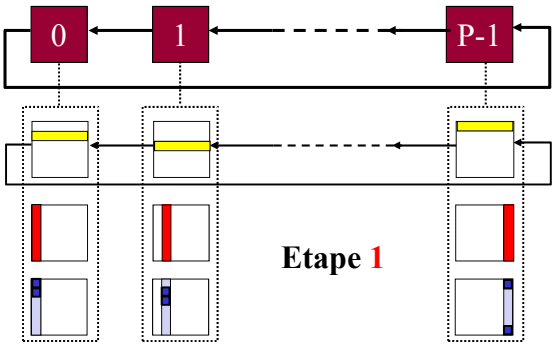

Topologie

Partitionnement et circulation de A

Partitionnement statique de B

Partitionnement statique de C

CentraleSupélec

Produit de matrices denses sur anneau

Algorithme distribué

Partitionnement sur un anneau de processeurs :

- A partitionnée en blocs de lignes
- B et C partitionnées en blocs de colonnes
- Circulation de A
- B et C statiques

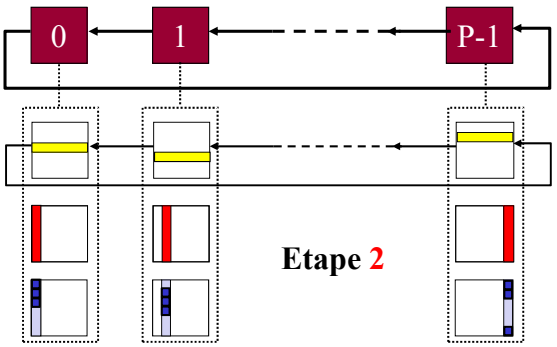

Topologie

Partitionnement et circulation de A

Partitionnement statique de B

Partitionnement statique de C

Produit de matrices denses sur anneau

Algorithme distribué

Partitionnement sur un anneau de processeurs :

- A partitionnée en blocs de lignes
- B et C partitionnées en blocs de colonnes
- **Circulation de A**
- B et C statiques

Résultats à la fin des P étapes :

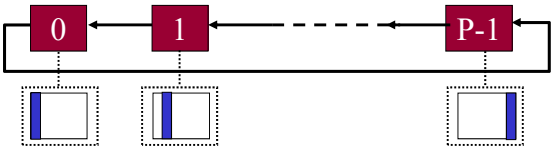

Topologie

Partitionnement statique de C

Bilan :

- Chaque PC a calculé un bloc de colonnes de C
- Les *P* PC ont travaillé en parallèle

→ **Calcul de tous les blocs de colonnes en parallèle**, en *P* étapes

Produit de matrices denses sur anneau

Algorithme distribué

Partitionnement sur un anneau de processeurs :

- A partitionnée en blocs de lignes
- B et C partitionnées en blocs de colonnes
- **Circulation de A**
- B et C statiques

Déroulement de l'algorithme sur PE-2, avec *P* = *4* :

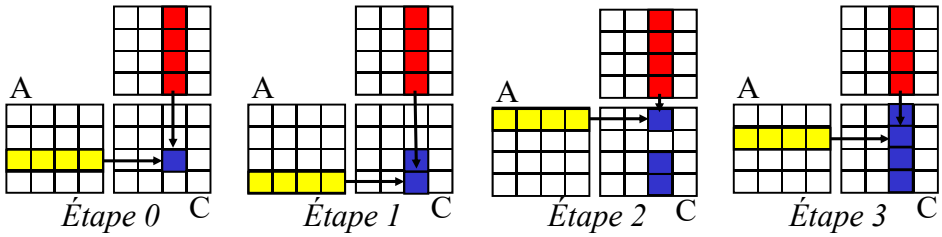

Produit de matrices denses sur anneau

Algorithme distribué

Stratégies d'implantation sur un anneau de P processeurs :

```
// Sans recouvrement
for (step=0; step<P; step++)
  calcul();
  barrier();    // si besoin
  circulation();
  barrier();    // si besoin
}
```

```
// Avec recouvrement
for (step=0; step<P; step++)
   thread{ calcul(); }
   thread{ circulation(); }
   joinThreads();
   permutBuff();
}
```

- Concevoir l'algorithme avec des barrières de (re)synchronisation potentielles
- Selon le mécanisme de communication utilisé :
  - Implanter des barrières explicites : synchronisation forte

  ou bien
  - Se contenter de la synchro des comms : synchronisation relaxée

Produit de matrices denses sur anneau

Algorithme distribué

Stratégies d'implantation sur un anneau de P processeurs :

```
// Sans recouvrement
for (step=0; step<P; step++)
  calcul();
  barrier();    // si besoin
  circulation();
  barrier();    // si besoin
}
```

```
// Avec recouvrement
for (step=0; step<P; step++)
   thread{ calcul(); }
   thread{ circulation(); }
   joinThreads(); // barrier
   permutBuff();
}
```

- Concevoir l'algorithme avec une barrière de (re)synchronisation et implanter la barrière de (re)synchronisation !
- Permuter les buffers de calcul et de communication (quasi-obligatoire)

→ Voir chapitre de programmation asynchrone

CentraleSupélec

Produit de matrices denses sur anneau

Algorithme distribué

→ TP

CentraleSupélec

Produit de matrices denses en anneau

- Algorithme distribué en « anneau de processus »
- **Modélisation de performances sur un anneau théorique**
- Topologie de processus *vs* réseau réels
- Modélisation des comms. selon déploiement

Modélisation de perfs sur anneau théorique

On suppose que l'on a un « anneau de processeurs »

Anneau de processus

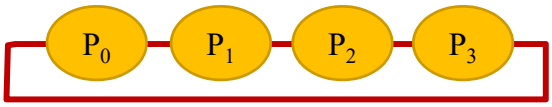

Déploiement *bijectif :*
- *1 process/machine*
- *processus k voisin des processus k-1 et k+1*

Anneau théorique de machines & 1 processeur par machine

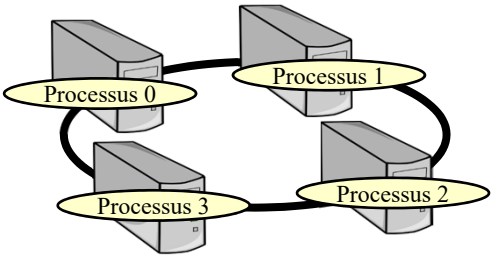

Produit de matrices denses sur anneau

Modélisation de perfs sur anneau théorique

Performances sans recouvrement :

• Temps séquentiel :

$$T_{seq} = N.(2.\sqrt{N} - 1)t_{flop}$$
$$T_{seq} \approx 2.N.\sqrt{N}\,t_{flop}$$

• Temps parallèle :

$$t_{1-calc} = \frac{\sqrt{N}}{P}.\frac{\sqrt{N}}{P}.(2.\sqrt{N} - 1)t_{flop}$$
$$t_{1-calc} \approx 2.\frac{N\sqrt{N}}{P^2}t_{flop}$$
$$t_{1-circ} = t_s + \sqrt{N}.\frac{\sqrt{N}}{P}t_w$$
$$t_{1-circ} \approx \frac{N}{P}t_w$$

Modèle de comm :
- $t_{com}(q) = t_s + q.t_w$
- *toutes les comms en parallèles*

$$T^{no}_{par} \approx P.(t_{1-calc} + t_{1-circ})$$
$$T^{no}_{par} \approx 2.\frac{N.\sqrt{N}}{P}t_{flop} + Nt_w$$

• Speed up :

$$S^{no} = \frac{T_{seq}}{T^{no}_{par}} \approx P.\frac{1}{1 + \frac{Pt_w}{2.\sqrt{N}t_{flop}}}$$

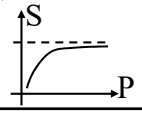

Modélisation de perfs sur anneau théorique

Comparaison calculs-communications (sans recouvrement) :

- Calculs :

$$T_{par}^{calc} \approx 2.\frac{N^{3/2}}{P} t_{flop}$$

$$P \text{ fixé} \Rightarrow O(T_{par}^{calc}) = O(N^{3/2})$$

- Circulation :

$$T_{par}^{circ} \approx N t_w$$

$$O(T_{par}^{circ}) = O(N)$$

$$O(T_{par}^{calc}) > O(T_{par}^{circ})$$

Avec P fixé, quand $N \uparrow$: les calculs deviennent prépondérants
→ le surcoût des comms devient négligeable

Et le speedup devient parfait :

$$S^{no} \approx P.\frac{1}{1+\frac{P.t_w}{2.\sqrt{N}.t_{flop}}} \xrightarrow[N\to\infty]{} P$$

« Bon » problème pour un TP !

Ex. de performances expérimentales

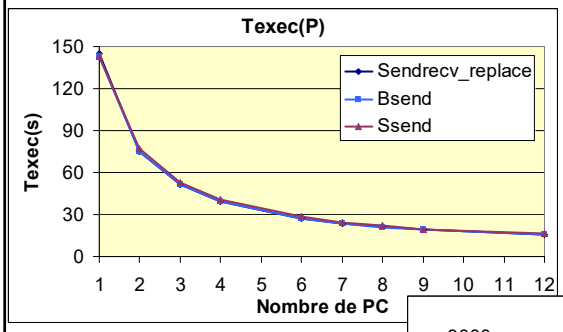

- 12 PC à 1 CPU à 1 cœur (P4- 3GHz)
- 1 Gbit Eth - 3 switchs (pas un vrai anneau)

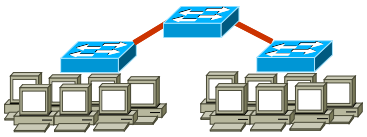

Communications bloquantes :

- Peu de différences
- La plus simple est aussi la plus efficace! (MPI_Sendrecv_replace)

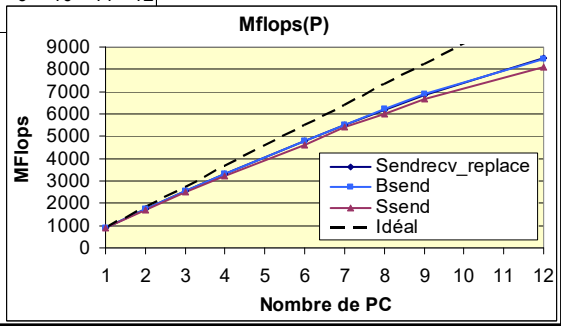

CentraleSupélec

Produit de matrices denses sur anneau

Ex. de performances expérimentales

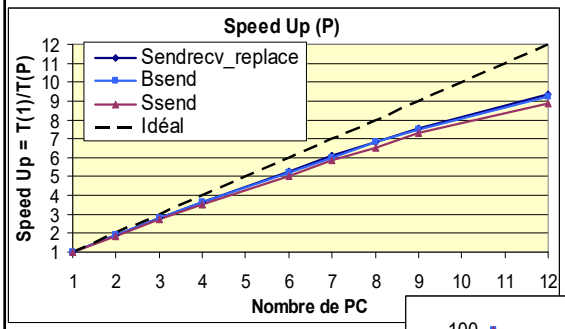

- 12 PC à 1 CPU à 1 cœur (P4- 3GHz)
- 1 Gbit Eth - 3 switchs

(pas un vrai anneau)

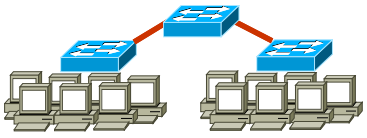

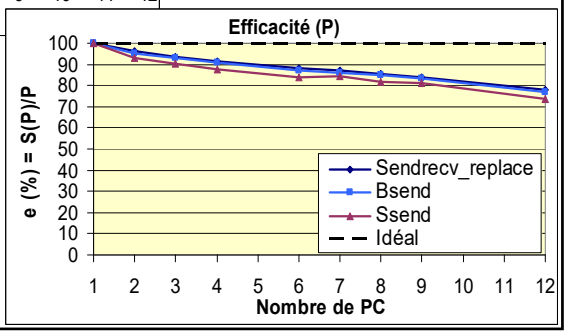

On s'éloigne lentement de l'asymptote :

- Coût des communications,
- Loi de Amdahl,
- Calculs locaux de – en – rentables.

CentraleSupélec

Produit de matrices denses en anneau

- Algorithme distribué en « anneau de processus »
- Modélisation de performances sur un anneau théorique
- **Topologie de processus *vs* réseau réels**
- Modélisation des comms. selon déploiement

Topologie de processus *vs* réseau réels

Principe du produit de matrices denses sur cluster :

1. Partitionnement initial des matrices A et B
2. Boucle de calcul et de circulation des données :
   - Sans recouvrement des calculs et des communications :
     `Loop {calcul ; circulation}`
   - Avec recouvrement des calculs et des communications :
     `Loop {par{calcul; circulation}}`
3. Sauvegarde des résultats ou suite des calculs

Différents algorithmes de circulation de données existent :

Ex : circulation de données sur un anneau
circulation de données sur un tore

→ Quelle topologie virtuelle est supportable par le cluster réel ?

Produit de matrices denses sur anneau

Topologie de processus *vs* réseau réels

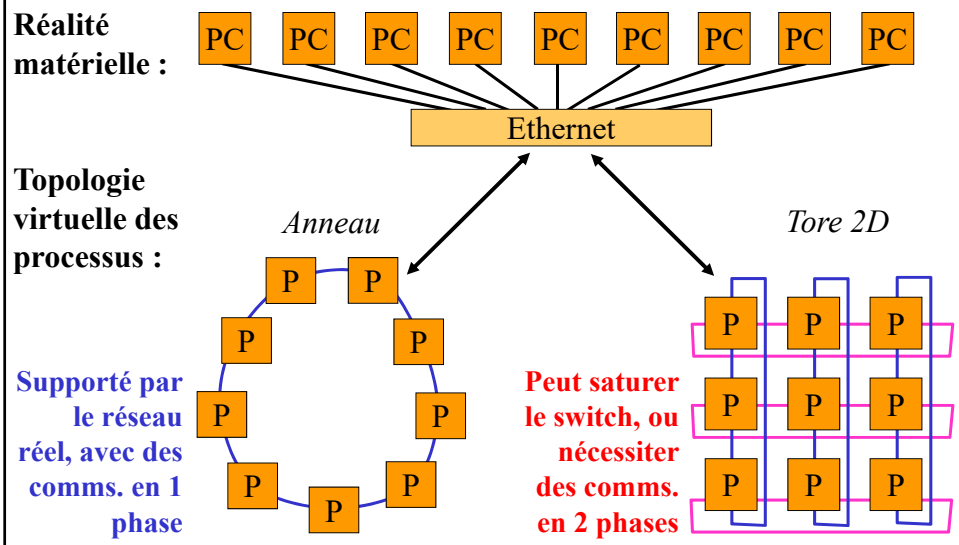

CentraleSupélec

Topologie de processus *vs* réseau réels

Circulation en anneau :

Implantation **`Bsend/Recv`** ou **`Sendrecv_replace`** :

- Comms. en une seule phase : toutes les comms lancées en parallèle
- Supportable par le switch ethernet : toutes les comms faites en parallèle

Circulation en tore 2D :

Implantation **`Bsend/Recv`** ou **`Sendrecv_replace`** :

- Comms. en **2 phases** : comms horizontales lancées en parallèle
  PUIS comms verticales lancées en parallèles
- Supportable par le switch ethernet : comms faites en **2 phases**

Implantation en **comm. asynchrones** :

- Comms. en une seule phase : toutes les comms lancées en parallèle
- **Non** supportable par le switch ethernet : comms **étalées dans le temps**

→ Quelle sera l'algorithme de circulation le plus efficace sur la plateforme réelle ?

CentraleSupélec

Produit de matrices denses en anneau

- Algorithme distribué en « anneau de processus »
- Modélisation de performances sur un anneau théorique
- Topologie de processus *vs* réseau réels
- **Modélisation des comms. selon déploiement**

Modélisation des comms. selon déploiement

Algorithme distribué sur un anneau de processus

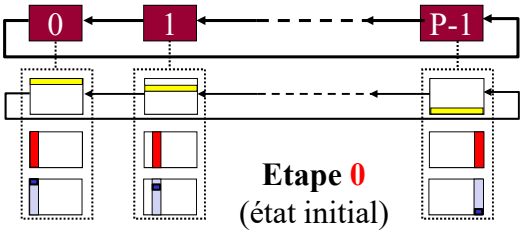

Implantation MPI avec organisation des comms.

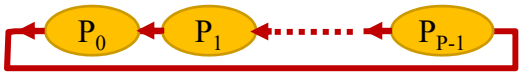

Déploiement MPI sur un cluster de PC multi-coeurs

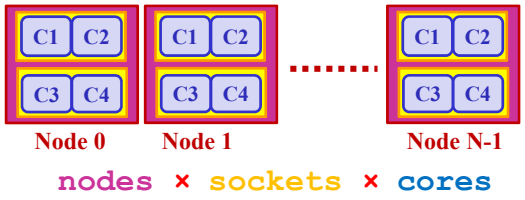

Produit de matrices denses sur anneau

Modélisation des comms. selon déploiement

2 types de comms. :

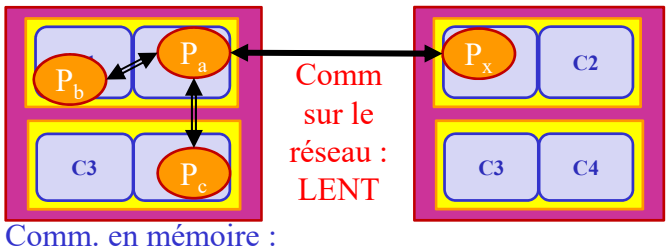

Comm. en mémoire : TRES RAPIDE

Modélisation :

Comm sur le réseau :

- modélisée en : $t_{comm}(q) = (t_s) + q.t_w$
- exécutées en parallèle : - si le réseau réel n'est pas saturé
  - et si elles ont été lancées en parallèle

Comm au sein d'un nœud :

- considérées instantanées : $t_{comm}(q) = 0$

→ **comparer les déploiements selon leurs comms. sur le réseau**

Modélisation des comms. selon déploiement

Volume de communications sur le réseau d'interconnexion :

Cluster : $N_{nodes} \times N_{socket/node} \times N_{coeurs/socket} = N_n \times N_s \times N_c$

Déploiement : 1 processus/nœud et $N_s \times N_c$ threads par processus

- N_n processus et étapes
- Volume d'une tranche de matrice A : $Q_{slice} = Q_s = {}^{Q_A}/_{N_n}$

A chaque étape : - chaque processus émet Q_s data
- chaque nœud émet Q_s data vers un autre nœud

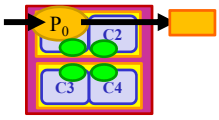

Au final :

Volume total de données traversant le réseau durant tout le calcul :

$N_n \times (N_n \times Q_s) = N_n \times \boldsymbol{Q_A}$

Taille de chaque message :

$\boldsymbol{Q_A/N_n}$

Produit de matrices denses sur anneau

Modélisation des comms. selon déploiement

Volume de communications sur le réseau d'interconnexion :

Cluster : $N_{nodes} \times N_{socket/node} \times N_{coeurs/socket} = N_n \times N_s \times N_c$

Déploiement : 1 processus/socket et N_c threads par processus et numérotation selon les sockets

- $N_n \times N_s$ processus et étapes
- Volume d'une tranche de matrice A : $Q_{slice} = Q_s = {}^{Q_A}/_{(N_n \times N_s)}$

A chaque étape : - chaque processus émet Q_s data
- chaque nœud émet Q_s data vers un autre nœud

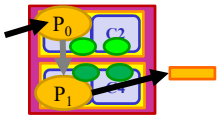

Au final :

Volume total de données traversant le réseau durant tout le calcul :

$(N_n \times N_s) \times (N_n \times Q_s) = \boldsymbol{N_n \times Q_A}$

Taille de chaque message :

$\boldsymbol{Q_A/(N_n \times N_s)}$

Plus de plus petits msg, mais même volume total

Modélisation des comms. selon déploiement

Volume de communications sur le réseau d'interconnexion :

Cluster : $N_{nodes} \times N_{socket/node} \times N_{coeurs/socket} = N_n \times N_s \times N_c$

Déploiement : 1 processus/socket et N_c threads par processus
et numérotation selon les nœuds

- $N_n \times N_s$ processus et étapes
- Volume d'une tranche de matrice A : $Q_{slice} = Q_s = {}^{Q_A}/_{(N_n \times N_s)}$

A chaque étape : - chaque processus émet Q_s data
- chaque nœud émet $N_s \times Q_s$ data vers d'autres nœuds

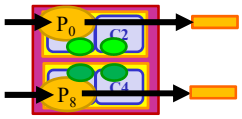

Au final :

Volume total de données traversant le réseau durant tout le calcul :

$(N_n \times N_s) \times (N_n \times (N_s \times Q_s)) = \boldsymbol{N_n \times N_s \times Q_A}$

Taille de chaque message :

$\boldsymbol{Q_A/(N_n \times N_s)}$

Bcp plus de plus petits msg, et volume total plus important !
→ **Plus lent !**

L'essentiel de MPI-1

Questions ?