CentraleSupélec

SG6: High Performance Computing

Distributed application deployment with MPI

Stéphane Vialle

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

CentraleSupélec

Distributed application deployment with MPI

- **Déploiement sur cluster de multicoeurs et mécanismes de MPI**
- Exercices
- Modélisation de performances

Problématique et possibilités de MPI

Ressources matérielles:

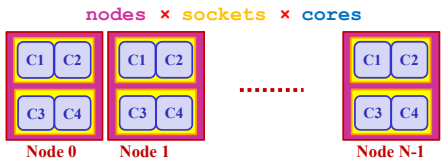

Topologie des processus (ex : anneau)

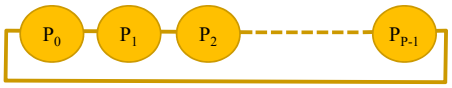

→ Quel *mapping* de la topologie virtuelle sur les rsrcs matérielles ?
→ Quel *ranking* des processus MPI sur la topologie matérielle ?
→ Quel *binding* d'un process sur les rsrcs matérielles locales ?

(voir les exemples)

Problématique et possibilités de MPI

Ressources matérielles:

nodes × sockets × cores

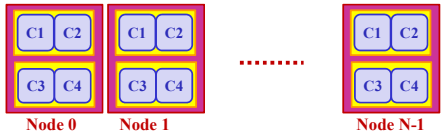

Topologie des processus (ex : anneau)

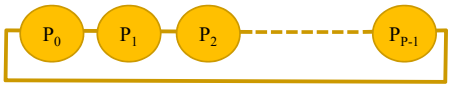


```
mpirun -np #P -machinefile machines.txt
              -map-by  <node|socket|core…>
              -rank-by <node|socket|core…>
              -bind-to <none|socket|core…>
              --report-bindings .....
```


Problématique et possibilités de MPI

Ressources matérielles:

nodes × sockets × cores

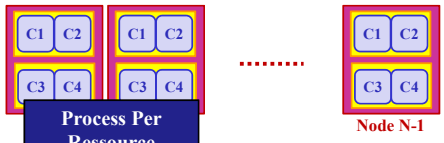

Topologie des processus (ex : anneau)


```
mpirun -np #P -machinefile machines.txt
              -map-by  ppr:N:<node|socket|core…>
              -rank-by <node|socket|core…>
              -bind-to <none|socket|core…>
              --report-bindings .....
```


Exemple de déploiement: sol 1

Sol 1 : un processus MPI par nœud

- Chaque machine présente une fois dans le fichier des machines ciblées
- Nbr de machines listées ≥ P (P : nbr de processus a créer)
- Utile si un processus nécessite tout le cache ou toute la RAM d'un nœud / d'un socket

  → Reste un mode « luxueux » !

machines.txt

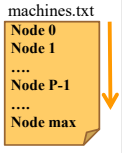

Attention : le binding d'un process peut être limité à un socket…

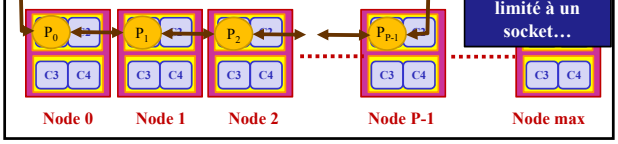

Exemple de déploiement: sol 1

Sol 1 : un processus MPI par nœud

- Chaque machine présente une fois dans le fichier des machines ciblées
- Nbr de machines listées ≥ P
  (P : nbr de processus a créer)

machines.txt

Node 0
Node 1
....
Node P-1
....
Node max

```
mpirun -np #P -machinefile machines.txt
              -map-by ppr:1:node
              -rank-by node
              -bind-to none|socket .....
```

Attention : le binding d'un process peut être limité à un socket…

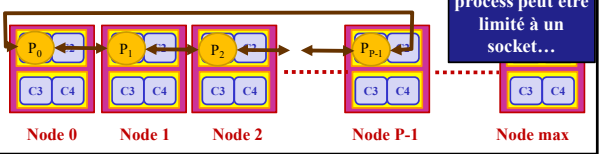

Exemple de déploiement: sol 2

Sol 2 : un processus MPI par cœur en « mode compact »

- Nbr de machines nécessaires = P / C
  (P : nbr de processus à créer, C : nb de cœurs/nœud)
- Un maximum de communications se font au sein d'un même nœud : plus efficace!

*Ce déploiement dépend de la topologie virtuelle **et** de l'architecture réelle.*

machines.txt

Node 0
Node 1
....
Node P/C-1
....
Node max

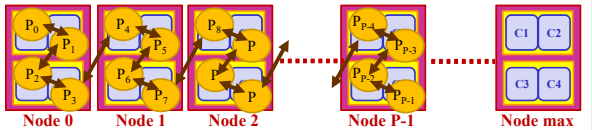

Exemple de déploiement: sol 2

Sol 2 : un processus MPI par cœur en « mode compact »

- Nbr de machines nécessaires = P / C
  (P : nbr de processus à créer, C : nb de cœurs/nœud)

machines.txt

Node 0
Node 1
....
Node P/C-1
....
Node max

```
mpirun -np #P -machinefile machines.txt
              -map-by ppr:1:core
              -rank-by core
              -bind-to core .....
```

Provoque un déploiement « compact »

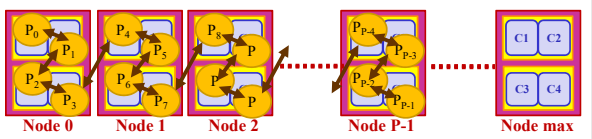

Exemple de déploiement: sol 2

Sol 2 : un processus MPI par cœur en « mode compact »

- Nbr de machines nécessaires = P / C
  (P : nbr de processus à créer, C : nb de cœurs/nœud)

```
mpirun -np #P -machinefile machines.txt
              -map-by ppr:#C:node
              -rank-by core
              -bind-to core .....
```

machines.txt
Node 0
Node 1
....
Node P/C-1
....
Node max

Provoque un déploiement « compact »

Simple variante : pas d'impact

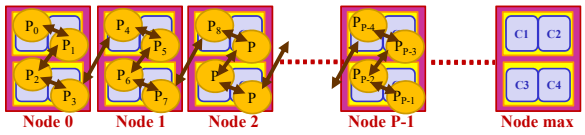

Exemple de déploiement: sol 3

Sol 3 : un processus MPI par cœur en « round robin »

- Nbr de machines nécessaires = P / C
  (P : nbr de processus à créer, C : nb de cœurs/nœud)
- Simple, mais toutes les communications se font à travers le réseau... Pas le plus efficace!!

machines.txt
Node 0
Node 1
....
Node P/C-1

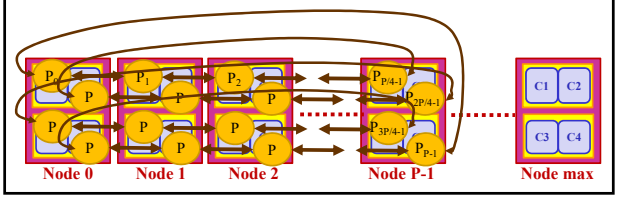

Exemple de déploiement: sol 3

Sol 3 : un processus MPI par cœur en « round robin »

- Nbr de machines nécessaires = P / C
  (P : nbr de processus à créer, C : nb de cœurs/nœud)

```
mpirun -np #P -machinefile machines.txt
              -map-by ppr:1:core
              -rank-by node
              -bind-to core .....
```

machines.txt
Node 0
Node 1
....
Node P/C-1

Provoque un déploiement « round robin »

Le fichier des machines doit avoir exactement la bonne taille

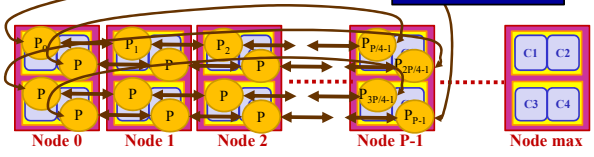

Exemple de déploiement: sol 4

Sol 4 : un processus MPI par node et C threads/process

- Nbr de machines listées ≥ P
  (P : nbr de processus à créer, C : nb de cœurs/nœud)
- Un processus/nœud, puis chaque processus créera C threads

machines.txt
Node 0
Node 1
....
Node P-1
....
Node max

```
mpirun -np #P -machinefile machines.txt
              -map-by ppr:1:node
              -rank-by node
              -bind-to none .....
```

Refuse parfois de *binder* sur le nœud entier : threads sur un seul socket !

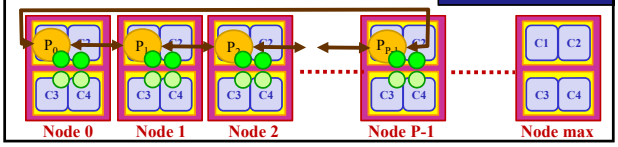

Exemple de déploiement: sol 4'

Sol 4' : un processus MPI par socket et Cs threads/process

- Nbr de machines listées ≥ P / S
  (P : nbr de processus à créer,
  S sockets/nœud, Cs : nb de cœurs/socket)
- Un processus/socket, puis chaque processus créera Cs threads

machines.txt
Node 0
Node 1
....
Node P/S-1
....
Node max

```
mpirun -np #P -machinefile machines.txt
              -map-by ppr:1:socket
              -rank-by socket
              -bind-to socket .....
```

Solution plus efficace sur nœuds NUMA (nœuds modernes)

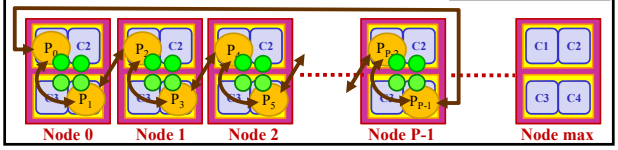

Options de *binding* de MPI

Options pour contrôler les ressources accessibles à un processus :

```
mpirun --bind-to < none     | hwthread | core   |
                   socket   | numa     | board  |
                   l1cache  | l2cache  | l3cache >
```

Toutes ne fonctionnent pas sur tous les systèmes!

Rapport de *binding* de MPI

```
mpirun -np 4 -machinefile machsar.txt
             -map-by ppr:1:socket -rank-by socket -bind-to socket
             --report-bindings
             ./MatrixProduct -k 1 -klc 4 -nt 4
```

32 nodes × 2 sockets × 4 cores × hyperthreading

```
[sar01:85379] MCW rank 0 bound to
  socket 0[core 0[hwt 0-1]], socket 0[core 1[hwt 0-1]],
  socket 0[core 2[hwt 0-1]], socket 0[core 3[hwt 0-1]]:
  [BB/BB/BB/BB][../../../..]
[sar01:85379] MCW rank 1 bound to
  socket 1[core 4[hwt 0-1]], socket 1[core 5[hwt 0-1]],
  socket 1[core 6[hwt 0-1]], socket 1[core 7[hwt 0-1]]:
  [../../../..][BB/BB/BB/BB]
[sar02:78868] MCW rank 3 bound to
  socket 1[core 4[hwt 0-1]], socket 1[core 5[hwt 0-1]],
  socket 1[core 6[hwt 0-1]], socket 1[core 7[hwt 0-1]]:
  [../../../..][BB/BB/BB/BB]
[sar02:78868] MCW rank 2 bound to
  socket 0[core 0[hwt 0-1]], socket 0[core 1[hwt 0-1]],
  socket 0[core 2[hwt 0-1]], socket 0[core 3[hwt 0-1]]:
  [BB/BB/BB/BB][../../../..]
```


Meilleur déploiement ?

La performance du déploiement dépend de plusieurs facteurs :

- L'occupation des ressources de calcul disponibles
  - → *Déployer une tâche (processus ou thread) par ressource :*
    - *au moins une tâche par cœur physique*
    - *ou une tâche par cœur logique (selon le noyau de calcul utilisé)*
- Le schéma de communication obtenu
  - → *Minimiser les communications inter-nœuds*
- Le respect de l'architecture NUMA des nœuds
  - → *Au moins un processus par sous-nœud NUMA (en général par socket)*

Rmq : quand on travaille toujours sur un même cluster on finit par savoir ce qui est le plus efficace sur lui !

Distributed application deployment with MPI

- Déploiement sur cluster de multicoeurs et mécanismes de MPI
- **Exercices**
- Modélisation de performances

Exercices

Déploiement 1

Cluster : 16 nœuds ×
4 sockets (processeurs) ×
16 cœurs physiques ×
2 threads (hyperthreading)

Règles :
- On alloue *n* nœuds ($1 \leq n \leq 16$)
- On cherche toujours à utiliser tous les cœurs des nœuds alloués

Pb 1 :
- Ressources allouées : 8 nœuds
- Stratégie de déploiement de l'application *myAppli* :
  - un processus MPI par cœur physique,
  - processus de numéros consécutifs sur un même nœud
  - un thread par cœur logique (hyp : option *–nt* de l'application)

Question 1 : combien de processus doit-on créer (option *–np* de *mpirun*) ?

→ 8 × 4 x 16 = **512** processus MPI

Question 2 : combien de *threads* doit créer chaque processus (option *–nt*) ?

→ **2** threads

Exercices

Déploiement 1

Cluster : 16 nœuds ×
4 sockets (processeurs) ×
16 cœurs physiques ×
2 threads (hyperthreading)

Règles :
- On alloue *n* nœuds ($1 \leq n \leq 16$)
- On cherche toujours à utiliser tous les cœurs des nœuds alloués

Pb 1 :
- Ressources allouées : 8 nœuds
- Stratégie de déploiement de l'application *myAppli* :
  - un processus MPI par cœur physique,
  - processus de numéros consécutifs sur un même nœud
  - un thread par cœur logique (hyp : option *–nt* de l'application)

Question 3 : quelle commande *mpirun* doit-on entrer ?

→ mpirun –np 512 –machinefile machines.txt
–map-by ppr:1:core –rank-by core –bind-to core
myAppli –nt 2

Exercices

Déploiement 2

Cluster : 16 nœuds ×
4 sockets (processeurs) ×
16 cœurs physiques ×
2 threads (hyperthreading)

Règles :
- On alloue *n* nœuds ($1 \leq n \leq 16$)
- On cherche toujours à utiliser tous les cœurs des nœuds alloués

Pb 2 :
- Ressources allouées : 16 nœuds
- Stratégie de déploiement de l'application *myAppliOptim* :
  - un processus MPI par socket,
  - processus de numéros consécutifs sur un même nœud
  - un thread par cœur physique (hyp : option *–nt* de l'application)

Question 1 : combien de processus doit-on créer (option *–np* de *mpirun*) ?

→ 16 × 4 = **64** processus MPI

Question 2 : combien de *threads* doit créer chaque processus (option *–nt*) ?

→ **16** threads

Exercices

Déploiement 2

Cluster : 16 nœuds ×
4 sockets (processeurs) ×
16 cœurs physiques ×
2 threads (hyperthreading)

Règles :
- On alloue *n* nœuds ($1 \leq n \leq 16$)
- On cherche toujours à utiliser tous les cœurs des nœuds alloués

Pb 2 :
- Ressources allouées : 16 nœuds
- Stratégie de déploiement de l'application *myAppliOptim* :
  - un processus MPI par socket,
  - processus de numéros consécutifs sur un même nœud
  - un thread par cœur physique (hyp : option *–nt* de l'application)

Question 3 : quelle commande *mpirun* doit-on entrer ?

→ mpirun –np 64 –machinefile machines.txt
–map-by ppr:1:socket –rank-by socket –bind-to socket
myAppliOptim –nt 16

Exercices

Déploiement 3

Cluster : 16 nœuds ×
4 sockets (processeurs) ×
16 cœurs physiques ×
2 threads (hyperthreading)

Règles :
- On alloue *n* nœuds ($1 \leq n \leq 16$)
- On cherche toujours à utiliser tous les cœurs des nœuds alloués

Pb 3 :
- Ressources allouées : 16 nœuds
- Stratégie de déploiement de l'application *myAppliOptim* :
  - 4 processus MPI par socket,
  - processus de numéros consécutifs sur des nœuds différents
  - un thread par cœur physique (hyp : option *–nt* de l'application)

Question 1 : combien de processus doit-on créer (option *–np* de *mpirun*) ?

→ 16 × 4 × 4 = **256** processus MPI

Question 2 : combien de *threads* doit créer chaque processus (option *–nt*) ?

→ **4** threads

Exercices

Déploiement 3

Cluster : 16 nœuds ×
4 sockets (processeurs) ×
16 cœurs physiques ×
2 threads (hyperthreading)

Règles :
- On alloue *n* nœuds ($1 \leq n \leq 16$)
- On cherche toujours à utiliser tous les cœurs des nœuds alloués

Pb 3 :
- Ressources allouées : 16 nœuds
- Stratégie de déploiement de l'application *myAppliOptim* :
  - 4 processus MPI par socket,
  - processus de numéros consécutifs sur des nœuds différents
  - un thread par cœur physique (hyp : option –

Sur chaque socket l'OS répartit 4×4 threads sur 16 cœurs

Question 3 : quelle commande *mpirun* doit-on entrer ?

→ mpirun –np 256 –machinefile machines.txt
–map-by ppr:4:socket –rank-by node –bind-to socket
myAppliOptim –nt 4

Distributed application deployment with MPI

- Déploiement sur cluster de multicoeurs et mécanismes de MPI
- Exercices
- **Modélisation de performances**
  - **volume de communication en fonction du déploiement**
  - temps d'exécution pour un déploiement donné

Cas d'un pgm en anneau (de processus)

Produit de matrices denses en anneau:

Anneau de processus

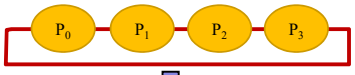

Déploiement visé :
- *1 process/machine*
- *processus k voisin des processus k-1 et k+1*

Réseau réel de machines & 1 processeur par machine

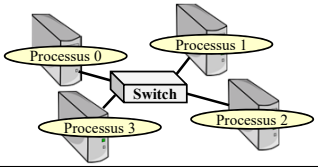

Cas d'un pgm en anneau (de processus)

Algorithme distribué sur un anneau de processus

Implantation MPI avec choix des communications

Déploiement MPI sur un cluster de PC multi-coeurs

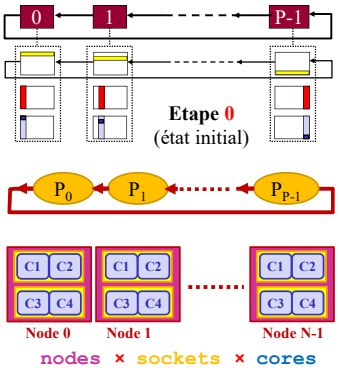

Modélisation des communications

2 types de comms. :

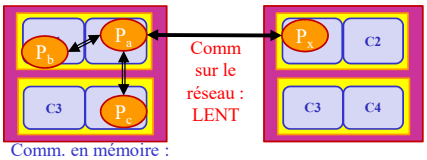

Comm. en mémoire : TRES RAPIDE

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**

Volume des comms. du 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

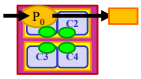

Au final :

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 :
$\boldsymbol{Q_A/N_n}$

Volume des comms. du 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

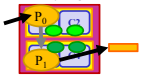

Au final :

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 de performances

Volume des comms. du 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

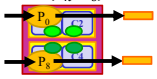

Au final :

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 !**

Distributed application deployment with MPI

- Déploiement sur cluster de multicoeurs et mécanismes de MPI
- Exercices
- **Modélisation de performances**
  - volume de communication en fonction du déploiement
  - **temps d'exécution pour un déploiement donné**

Modélisation de performances

Configuration logicielle et matérielle

Déploiement : un processus MPI par node et C threads/process

- P nœuds (machines), avec C cœurs par nœud
- Un réseau architecturé autour d'un switch
- P processus dans le programme, les processus sont multithreadés
- Communication des processus en anneau
- Un processus/nœud, puis chaque processus crée C threads
- C : nb de cœurs/nœud
- Hypothèse : pas de limitation du *binding*

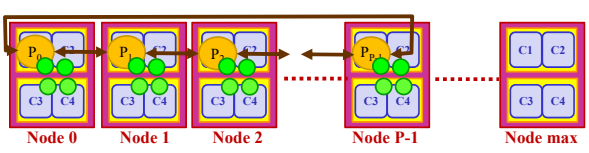

Modélisation du temps d'exécution

Performances sans recouvrement :

• Temps mono-noeud :

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

t_{flop} tient compte du multithreading sur C coeurs

• Temps parallèle :

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

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

$$t_{1-circ} = t_s + \sqrt{N}.\frac{\sqrt{N}}{P}t_w$$
$$t_{1-circ} \approx \frac{N}{P}t_w$$

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

• 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 :

$$T^{calc}_{par} \approx 2.\frac{N^{3/2}}{P}t_{flop}$$
$$P \text{ fixé} \Rightarrow O(T^{calc}_{par}) = O(N^{3/2})$$

• Circulation :

$$T^{circ}_{par} \approx Nt_w$$
$$O(T^{circ}_{par}) = O(N)$$

$$O(T^{calc}_{par}) > O(T^{circ}_{par})$$

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 !

Distributed application deployment with MPI

Questions ?