CentraleSupélec

Mineure CalHau1

MPI : l'essentiel

Stéphane Vialle

CentraleSupélec université PARIS-SACLAY — École doctorale Sciences et technologies de l'information et de la communication (STIC) — RISEGrid — Grand Est

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

CentraleSupélec

L'essentiel de MPI-1

CentraleSupélec

1 – Principes de base

Principes de bases

Fait pour des archi. distribuées (ou pas)

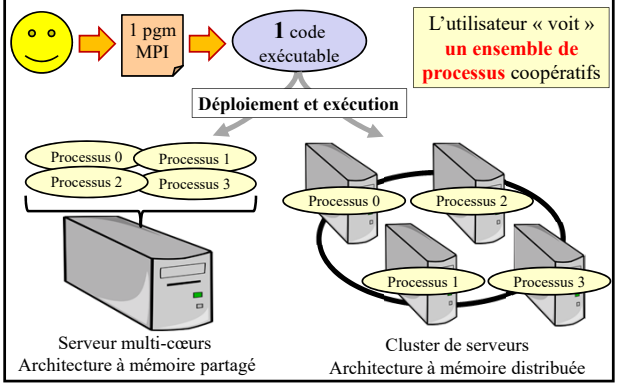

Serveur multi-cœurs
Architecture à mémoire partagé

Cluster de serveurs
Architecture à mémoire distribuée

Principes de bases

« Hello World »

Programme source :

```
#include <stdio.h>
#include "mpi.h"
main(int argc, char **argv) {
  int Me, NbPE;
  MPI_Init(&argc,&argv);
  MPI_Comm_size(MPI_COMM_WORLD,&NbPE);
  MPI_Comm_rank(MPI_COMM_WORLD,&Me);
  printf("Hello World from process %d/%d\n",Me,NbPE);
  fflush(stdout);
  MPI_Barrier(MPI_COMM_WORLD);
  MPI_Finalize();
}
```

Le « groupe » de tous les process du pgm MPI

Pour afficher tous les msgs avant la fin du pgm

Exemple d'exécution avec 3 processus :

```
Hello World from process 0/3
Hello World from process 2/3
Hello World from process 1/3
```

Pas d'hypothèse sur l'ordre d'exécution ni d'affichage !

Principes de bases

Principales instructions d'un code MPI

Instructions incontournables d'un programme MPI :

Inclusion du fichier d'entête MPI
```
#include "mpi.h"
```

Première instruction MPI du `main(int argc, char **argv)`
```
MPI_Init(&argc,&argv);
```

Pour connaître le nombre de processus lancés
```
MPI_Comm_size(MPI_COMM_WORLD,&NbPE);
```

Pour connaître le numéro du processus
```
MPI_Comm_rank(MPI_COMM_WORLD,&Me);
```

Dernière instruction MPI du `main`
```
MPI_Finalize();
```

Instructions de communication entre processus :

Comms. point-à-point
```
Ex : ...
  MPI_Send(...);
  MPI_Recv(...);
```

Comms. de groupe
```
Ex: ...
  MPI_Bcast(...);
  ...
```

Le parallélisme est très explicite en MPI !

Principes de bases

Difficultés de développement en MPI

Objectifs :

Concevoir un code MPI qui fonctionne (!) et qui soit efficace (!)

Difficultés :

- **Deux processus ne possèdent pas d'espace mémoire partagé**

  Accéder à des données stockés/générées par un autre processus impose des échanges de messages avec lui

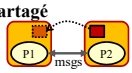

- **Concevoir des schémas d'échange de données entre les processus**

  Ex : topologie virtuelle en anneau de processus
  topologie virtuelle en tore 2D de processus
  ……

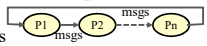

- **Fonctionner avec un nombre de processus le moins contraint possible**

  Ex : topologie virtuelle en anneau (1D)
  - fonctionner pour 1, 2, 3, 4, 5 … processus : **TB**
  - fonctionner pour 2, 4, 6, 8… processus : **inconfortable**

  Fonctionner aussi avec un seul processus (très pratique!)

Principes de bases

Difficultés de développement en MPI

Objectifs :

Concevoir un code qui fonctionne (!) et qui soit efficace (!)

Difficultés :

- **Eviter les inter-blocages**

  Ex : tous les processus bloqués en attente de réception de données

  → **Séquencer/Planifier** les operations Send et Recv

- **Diminuer l'impact des temps de latence**

  Envoyer 1 msg de 1000 données, plutôt que1000 msg de 1 donnée.

  → Sur chaque processus **regrouper** les communications à destination de la même cible

- **Diminuer l'impact des temps de communication**

  Réaliser les communications dans des threads en parallèle des calculs (*la carte réseau n'utilise pas le CPU*)

  → **Recouvrir** les communications par les calculs

Principes de bases

Compilation d'une application MPI

Compilation MPI :

- **MPI est perçu comme une simple bibliothèque**

```
cc -I…/include -L…/libs
   -O3 -o myAppli XXX.c YYY.c …
   -lmpi
```

ou bien :

```
mpicc -O3 -o myAppli XXX.c YYY.c …
```

→ On obtient un seul fichier exécutable (comme en séquentiel)

- **MPI est compatible avec le multithreading**
  - Notamment compatible avec OpenMP (`mpicc -O3 -fopenmp …`)
  - SI les appels à MPI sont toujours faits par un seul thread à la fois *(pas de parallélisation des appels)*

    ALORS : aucun problème *(prêt à l'emploi)*

    SINON : installer MPI en mode multithreads/thread safe.

Principes de bases

Déploiement et exécution d'une appli. MPI

Déploiement de l'application :
déployer *p* processus sur *m* machines,
et exécuter l'ensemble des processus :
→ tout se fait avec la commande « **`mpirun`** »

`mpirun -np <#P>`	Nb total de processus à créer
`-machinefile <FileName>`	Liste des machines disponibles
`-mab-by … -rank-by … -bind-to …`	Contrôle du déploiement (voir plus loin - important)
`<Path/ExecName> [args]`	Exécutable et ses arguments

Ex minimaliste : **`mpirun -np 3 ./HelloWorld`**
→ lance 3 processus "HelloWorld" sur la machine courante

Principes de bases

Démarche complète de parallélisation MPI

1. **Algorithmique parallèle** (optimisée)
2. **Programmation parallèle** (optimisée)
   → code src avec : envoi de message + multithreading + vectorisation
   ex : MPI + OpenMP + noyaux de calculs vectorisés
3. **Compilation**
   → Production d'UN binaire (**`mpicc`**)
4. **Stratégie de déploiement**
   → étude des caractéristiques des machines disponibles
   → choix d'options de déploiement (**`-map-by / -rank-by / -bind-to`**)
5. **Déploiement et exécution**
   → Copie du binaire sur chaque nœud ou montage d'un répertoire partagé
   → Lancement du programme MPI suivant le déploiement prévu
   `mpirun -np <#P> -machinefile machines.txt` ……

L'essentiel de MPI-1

2 – Communications point à point

- Communications disponibles
- Principes du Bsend/Recv
- Principes du Ssend/Recv
- Principes du Isend/Irecv
- Principes du Sendrecv
- Principes du Sendrecv_replace

Communications disponibles

Communications point-à-point disponibles :

Mode\Type	Not specified	Buffered	Synchronous	Ready
Bloquantes	`MPI_Send` `MPI_Recv`	`MPI_Bsend` `MPI_Recv`	`MPI_Ssend` `MPI_Recv`	`MPI_Rsend` `MPI_Recv`
Non - bloquantes	***`MPI_Ibsend`*** ***`MPI_Irecv`***	***`MPI_Ibsend`*** ***`MPI_Irecv`***	***`MPI_Issend`*** ***`MPI_Irecv`***	***`MPI_Irsend`*** ***`MPI_Irecv`***

+ `MPI_Sendrecv`
  `MPI_Sendrecv_replace`

Communications pt-à-pt combinées et bloquantes

Communications disponibles

Les types des données sont spécifiés dans les communications :

Ex : `MPI_Send(…, n, MPI_DOUBLE, …);`

Type pré-existants :

Utilisé en TP

`MPI_CHAR`	`MPI_SHORT`	`MPI_FLOAT`	`MPI_UNSIGNED_CHAR`
`MPI_BYTE`	`MPI_INT`	`MPI_DOUBLE`	`MPI_UNSIGNED_SHORT`
	`MPI_LONG`	`MPI_LONG_DOUBLE`	`MPI_UNSIGNED`
			`MPI_UNSIGNED_LONG`

Définition possible de nouveaux types :

- des **tableaux** à une dimension :
  `MPI_Type_contiguous(count,old_type,new_type)`
- des ***vecteurs* extraits de tableaux** plus complexes :
  `MPI_Type_vector(count,blocklen,stride,old_t,new_t)`
- des **structures** de données :
  `MPI_Type_struct(count,blocklens,indices,old_t,new_t)`

Puis allocation du nouveau type avant usage :
`MPI_Type_commit(datatype)`

Principes du Bsend/Recv

Echanges de messages en mode *bloquant* et *bufferisé* : Bsend/Recv

Bsend(…) :

- rend la main dès que les données à expédier sont sauvegardées,
- on peut modifier sans délai les zones de données émises,
- la transmission réelle se fera plus tard (quand le dest. le demandera)

Recv(…) :

- demande la transmission et la réception des données
- rend la main seulement lorsque les données sont toutes arrivées
- les réceptions de données servent aussi à resynchroniser les processus

Ex. sur un anneau de processus :

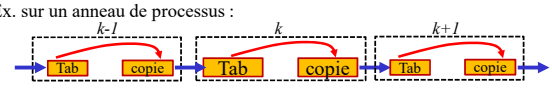

Même code dans tous les processus :

```
……
Bsend(Tab,Me+1);
Recv(Tab,Me-1);
……
```

Principes du Bsend/Recv

Echanges de messages en mode *bloquant* et *bufferisé* : Bsend/Recv

Bsend(…) / Recv(…) :

Quelle que soit la topologie des processus (anneau, tore, hypercube…)
→ **un même code de communication pour tous les processus**

1. Exécuter tous les Bsend(…) de l'étape (dans n'importe quel ordre)
2. Exécuter tous les Recv(…) de l'étape (dans n'importe quel ordre)

Ex. sur un anneau de processus :

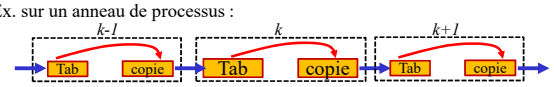

Même code dans tous les processus :

```
.....
Bsend(Tab,Me+1);
Recv(Tab,Me-1);
.....
```


Principes du Bsend/Recv

Mode *bloquant* et *bufferisé* : `MPI_Bsend` / `MPI_Recv`

- *Bsend* : copie les données dans le buffer et rend la main
- *Recv* : se signale à l'émetteur, provoque le transfert des données, rend la main à la fin du transfert

```
MPI_Bsend(data_adr,count,datatype,destproc,tag,comm)
MPI_Recv(data_adr,count,datatype,srcproc,tag,comm,stts_adr)
```

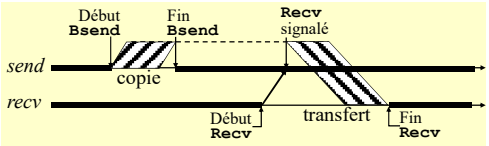

Mode menant à des parallélisations simples à concevoir.
Parfois les plus efficaces, malgré les temps de recopie !

Principes du Bsend/Recv

Mode *bloquant* et *bufferisé* : `MPI_Bsend` / `MPI_Recv`

Le développeur doit *allouer*, *attacher*, *détacher* et *libérer* son buffer :

```
                                        // Buffer size comput
MPI_Pack_size(n,MPI_DOUBLE,MPI_COMM_WORLD,&size1Msg);
sizeBuff = m*(size1Msg + MPI_BSEND_OVERHEAD);
ptBuff = (double *) malloc(sizeBuff);// Buffer allocation
MPI_Buffer_attach(ptBuff,sizeBuff);  // Buffer attachement
for (i=0; i<m; i++) {                // Message sending
  tab = …;                                 // - tab update
  MPI_Bsend(tab,n,MPI_DOUBLE,suivant,…);  // - msg passing
  MPI_Recv(tab,n,MPI_DOUBLE,precedent,…);
}
MPI_Buffer_detach(&ptBuff,&sizeBuff);// Buffer detachement
free(ptBuff);                        // Buffer dealloc.
```

Bloque jusqu'à ce que tous les msgs stockés dans le buffer soient délivrés

Un *overhead* par msg stocké dans le buffer

Principes du Bsend/Recv

Mode *bloquant* et *bufferisé* : `MPI_Bsend` / `MPI_Recv`

Le développeur doit *allouer*, *attacher*, *détacher* et *libérer* son buffer :

```
                                        // Buffer size comput
MPI_Pack_size(n,MPI_DOUBLE,MPI_COMM_WORLD,&size1Msg);
sizeBuff = 1*(size1Msg + MPI_BSEND_OVERHEAD);
ptBuff = (double *) malloc(sizeBuff);// Buffer allocation
for (i=0; i<m; i++) {                   // Message sending
  MPI_Buffer_attach(ptBuff,sizeBuff);      // - attachement
  tab = …;                                 // - tab update
  MPI_Bsend(tab,n,MPI_DOUBLE,suivant,…);   // - msg passing
  MPI_Recv(tab,n,MPI_DOUBLE,precedent,…);
  MPI_Buffer_detach(&ptBuff,&sizeBuff);    // - detachement
}
free(ptBuff);                           // Buffer dealloc.
```

Bloque jusqu'à ce que tous les msgs stockés dans le buffer soient délivrés

Un *overhead* par msg stocké dans le buffer

Principes du Ssend/Recv

Mode *bloquant* et *synchrone* : Ssend/Recv

Ssend(…) :

- rend la main seulement lorsque les données sont toutes parties
- on ne doit PAS modifier les zones de données en cours d'émission

Recv(…) :

- demande la transmission et la réception des données
- rend la main seulement lorsque les données sont toutes arrivées

→ **A chaque étape un Recv(…) doit correspondre à un Ssend(…)**

Car les communications forment des ***Rendez-Vous*** entre processus

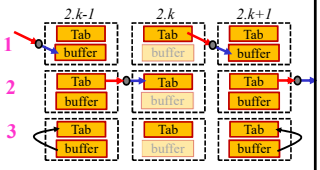

Certains buffers sont encore nécessaires pour éviter d'écraser des données

Principes du Ssend/Recv

Mode *bloquant* et *synchrone* : Ssend/Recv

Ssend(…) / Recv(…) :

Quelle que soit la topologie des processus (anneau, tore, hypercube…)

→ **il faut planifier précisément toute la séquence des Ssend et des Recv sur chaque processus (le *plan de communication*)**

Ex. sur un anneau de processus :

```
.....
if (processId %2 == 0)
  1 : Ssend(Tab,Me+1);
  2 : Recv(Tab,Me-1);
else
  1 : Recv(buffer,Me-1);
  2 : Ssend(Tab,Me+1);
  3 : permut(buffer,Tab);
.....
```

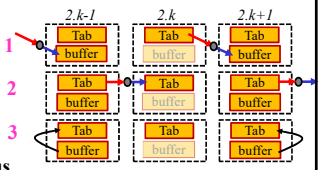

Le plan de communication sera plus long qu'avec Bsend(…)/Recv(…) !!

Ex : exécution de la moitié des comms (1), puis de l'autre moitié (2)

Principes du Ssend/Recv

Mode *bloquant* et *synchrone* : `MPI_Ssend` / `MPI_Recv`

- *Ssend* : se signale au récepteur, attend son ack., puis ne rend la main qu'à la fin de l'émission des données
- *Recv* : répond à l'émetteur et provoque le transfert, puis rend la main à la fin de la réception des données

```
MPI_Ssend(data_adr,count,datatype,destproc,tag,comm)
MPI_Recv(data_adr,count,datatype,srcproc,tag,comm,stts_adr)
```

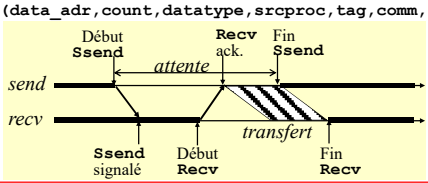

Mode rappelant les *rendez-vous* de CSP/Occam
Pbs de *dead-lock* si tous les processus émettent puis reçoivent

Principes du Send/Recv

Originalité du mode *bloquant* et *standard* `MPI_Send/MPI_Recv`

Non spécifié en détail et optimisable par chaque constructeur pour :
- obtenir de bonnes perfs. sur ses machines
- être simple d'emploi sur ses machines

Mais fonctionnement non portable !

Ex, par le passé :
- MPICH : *send* bufferisé (similaire Bsend)
- IBM SP : < seuil : *send* bufferisé (similaire Bsend)
  > seuil : *send* synchrone (similaire Ssend)

2 approches opposées :

- Un pgm MPI ne doit pas utiliser de comms. *bloquantes-standard* : objectif de portabilité ! — Cluster de PC
- Un pgm MPI doit utiliser des comms. *bloquantes-standards* optimisées par le constructeur : objectif de performances ! — Super-calculateurs

Principes du Rsend/Recv

Mode *bloquant* et *ready* : `MPI_Rsend` – `MPI_Recv`

- *Rsend* : recherche un récepteur signalé, si oui : débute le transfert et rend la main à la fin de l'émission, sinon ? (erreur ? recopie ?)
- *Recv* : se signale à l'émetteur (*ready*), et ne rend la main qu'à la fin de la réception des données

```
MPI_Rsend(data_adr,count,datatype,destproc,tag,comm)
MPI_Recv(data_adr,count,datatype,srcproc,tag,comm,stts_adr)
```

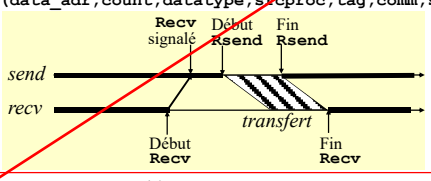

Mode sensé être très rapide
Mais demande des « garantis » de synchro « impossibles » !

Communications disponibles

Communications point-à-point fiables et portables :

Mode\Type	Not specified	Buffered	Synchronous	Ready
Bloquantes	`MPI_Send` `MPI_Recv`	`MPI_Bsend` `MPI_Recv`	`MPI_Ssend` `MPI_Recv`	`MPI_Rsend` `MPI_Recv`
Non - bloquantes	`MPI_Ibsend` `MPI_Irecv`	`MPI_Ibsend` `MPI_Irecv`	`MPI_Issend` `MPI_Irecv`	`MPI_Irsend` `MPI_Irecv`

+ `MPI_Sendrecv`
`MPI_Sendrecv_replace`

Communications pt-à-pt combinées et bloquantes

Principes

Echanges de messages en mode *non-bloquant (asynchrone)*

- **Isend(…)** "lance un thread d'envoi de message" et rend la main
- **Irecv(…)** "lance un thread de réception de message" et rend la main
- Un **recouvrement** des comms avec la **suite des calculs** est alors possible
  → mais on ne doit plus utiliser les zones de stockage des données avant la fin des communications en cours
- **Wait(…)** resynchronise ensuite les calculs avec la fin des comms.
  → On peut alors réutiliser/exploiter les zones de stockage

```
// Ex de code d'UN process avec comm asynchrone
..... // calcul
1 : Isend(myTab,dest,&Srq);  // lance thread de comm
2 : Irecv(otherTab,src,&Rrq);// lance thread de comm
3 : suite_calcul(…)          // recouvrement calcul-comms
4 : Wait(&Srq); Wait(&Rrq);  // resynchro calcul-comm
..... // fin des calculs
```

La programmation avec recouvrement se révèle toujours plus complexe...

Principes

Echanges de messages en mode *non-bloquant (asynchrone)*

- Parfois **Isend(…)** / **Irecv(…)** créent des threads qui restent inactifs
  → **le recouvrement calcul-comm ne se produit pas !**

Autre solution :

- Créer des threads traditionnels (Posix, OpenMP…)
- Leur faire exécuter des comms bloquantes → comms non bloquantes
- Resynchroniser les calculs et les comms avec une barrière sur la mort des threads de comm.

```
// Ex de code d'UN process avec comm asynchrone
..... // calcul
1 : tidS = thread{Send(myTab,dest)};   // Thread de comm
2 : tidR = thread{Recv(otherTab,src)}; // Thread de comm
3 : suite_calcul(…)          // recouvrement calcul-comms
4 : threadJoin(tidS, tidR);  // resynchro calcul-comm
..... // fin des calculs
```

La programmation avec recouvrement se révèle toujours plus complexe...

Communications point-à-point

Communications disponibles

Communications point-à-point fiables et portables :

Mode\Type	Not specified	Buffered	Synchronous	Ready
Bloquantes	`MPI_Send` `MPI_Recv`	`MPI_Bsend` `MPI_Recv`	`MPI_Ssend` `MPI_Recv`	`MPI_Rsend` `MPI_Recv`
Non - bloquantes	*`MPI_Ibsend` `MPI_Irecv`*	*`MPI_Ibsend` `MPI_Irecv`*	*`MPI_Issend` `MPI_Irecv`*	*`MPI_Irsend` `MPI_Irecv`*

+ Communications bloquantes dans des threads explicites, pour réaliser des comms. non-bloquantes

+ `MPI_Sendrecv` `MPI_Sendrecv_replace` — Communications pt-à-pt combinées et bloquantes

Communications point-à-point

Sendrecv

Communications *bloquantes combinées* : `MPI_Sendrecv`

- Adapté à des *échanges de frontières* dans une topologie
- Communications bloquantes
- Pas de Dead-Lock possible (gérés par le système)
- Compatible avec Send et Recv aux extrémités

```
MPI_Sendrecv(send_adr,sendcount,sendtype,destproc,sendtag,
             recv_adr,recvcount,recvtype,srcproc,recvtag,
             comm,status_adr)
```

Ex : échange de frontières avec `MPI_Sendrecv`

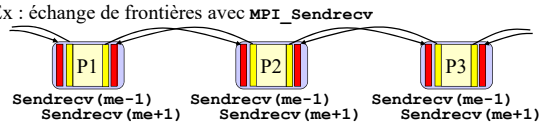

→ Très pratique et très efficace ! Mais besoin de planifier le plan de comm. sur des topologies complexes

Communications point-à-point

Sendrecv_replace

Communications *bloquantes combinées* : `MPI_Sendrecv_replace`

- Adapté à des *circulation de données* dans une topologie
- Communications bloquantes
- Pas de Dead-Lock possible (gérés par le système)
- Pas d'écrasement de données (géré par le système)

```
MPI_Sendrecv_replace(data_adr,count,datatype,
                     destproc,sendtag,srcproc,recvtag,
                     comm,status_adr)
```

Ex : circulation avec `MPI_Sendrecv_replace` et **1 (seul)** buffer par proc

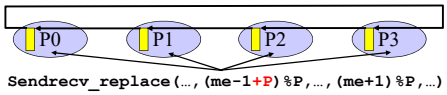

Pb avec opérateur *modulo*

→ Très pratique et très efficace ! Mais besoin de planifier le plan de comm. sur des topologies complexes

Communications disponibles

Communications point-à-point fiables et portables :

Mode\Type	Not specified	Buffered	Synchronous	Ready
Bloquantes	`MPI_Send` `MPI_Recv`	**`MPI_Bsend`** **`MPI_Recv`**	**`MPI_Ssend`** **`MPI_Recv`**	`MPI_Rsend` `MPI_Recv`
Non - bloquantes	*`MPI_Ibsend`* *`MPI_Irecv`*	*`MPI_Ibsend`* *`MPI_Irecv`*	*`MPI_Issend`* *`MPI_Irecv`*	*`MPI_Irsend`* *`MPI_Irecv`*

+ Communications bloquantes dans des threads explicites, pour réaliser des comms. non-bloquantes

+ **`MPI_Sendrecv`** **`MPI_Sendrecv_replace`**
Communications pt-à-pt combinées et bloquantes

L'essentiel de MPI-1

3 – Exemple de programmation MPI

- Communications Send/Recv
- Communications Bsend/Recv
- Communications Ssend/Recv
- Communications Sendrecv

Relaxation de Jacobi parallèle

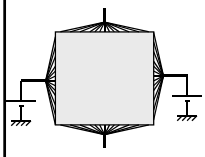

Calcul des lignes de potentiel dans une plaque diélectrique :

$$\frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} = 0$$

• Discrétisation et équation aux différences
• Itération jusqu'à la convergence ($V^{n+1}_{i,j} - V^{n}_{i,j} < \varepsilon$)

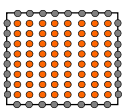

- Condition aux limites : V fixé
- $V^{n+1}_{i,j} = \frac{V^{n}_{i-1,j} + V^{n}_{i+1,j} + V^{n}_{i,j-1} + V^{n}_{i,j+1}}{4}$

Exemple de programmation MPI

Relaxation de Jacobi parallèle

Parallélisation par envoi de messages:

- **Partitionnement spatial des données**
- Ex : avec 4 *processus* de calcul

- 2 extraits des tables V^n et V^{n+1} dans chaque mémoire locale + les frontières
- **Parallélisation de la boucle principale**
- 1 barrière (implicite sur comm bloquantes)

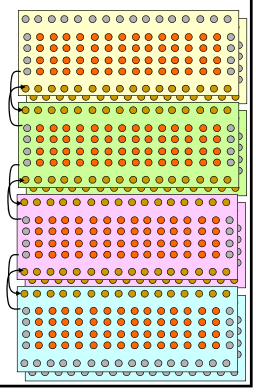

Exemple de programmation MPI

Implantation des initialisations

```
// Static parallelization: size and partitioning fixed
#define side       112        // Side of the Jacobi grid
#define small       28        // Need side = NbPE*small

int Me;                       // Processor number
int NbPE;                     // Number of processors

double V[2][small+2][side+2];// Jacobi grids
int NI, OI;                   // Indexes of new & old grids

main(int argc, char **argv) {




  ..... // Jacobi grid initialization and relaxation loop


}
```

Exemple de programmation MPI

Implantation des initialisations

```
// Static parallelization: size and partitioning fixed
#define side       112        // Side of the Jacobi grid
#define small       28        // Need side = NbPE*small

int Me;                       // Processor number
int NbPE;                     // Number of processors

double V[2][small+2][side+2];// Jacobi grids
int NI, OI;                   // Indexes of new & old grids

main(int argc, char **argv) {
  MPI_Init(&argc,&argv);      // MPI initializations
  MPI_Comm_rank(MPI_COMM_WORLD,&Me);
  MPI_Comm_size(MPI_COMM_WORLD,&NbPE);
  printf("Hello from PE%d/%d\n",Me,NbPE);
  ..... // Jacobi grid initialization and relaxation loop
  MPI_Finalize();             // End of MPI calls
}
```

Exemple de programmation MPI

Implantation en Send-Recv

```
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  for (i = 1; i <= small; i++) {
    for (j = 1; j <= side; j ++) {
      V[NI][i][j] =
          (V[OI][i-1][j]+
           V[OI][i+1][j]+
           V[OI][i][j-1]+
           V[OI][i][j+1])/4.0;
    }
  }
  // - Frontier exchange
  if (NbPE > 1) {
    ........
  }
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
```

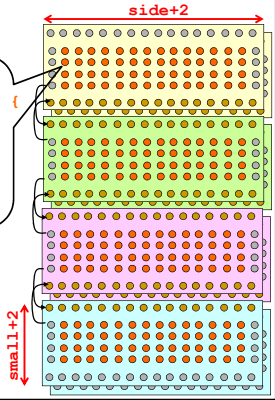

Exemple de programmation MPI

Implantation en Send-Recv

```
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  ........
  // - Frontier exchange
  if (NbPE > 1) {
    ........
  }
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
```

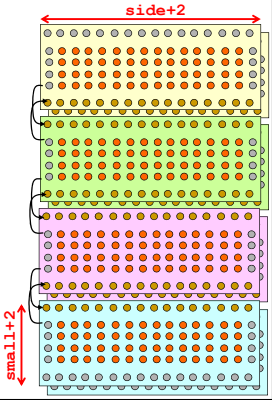

Exemple de programmation MPI

Implantation en Send-Recv

```
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  ........
  // - Frontier exchange
  if (NbPE > 1) {
    if (Me == 0) {
      MPI_Send(&V[NI][small][1],side,MPI_DOUBLE,
               Me+1,cycle,MPI_COMM_WORLD);
      MPI_Recv(&V[NI][small+1][1],side,MPI_DOUBLE,
               Me+1,cycle,MPI_COMM_WORLD,&status);
    } else if (Me == NbPE - 1) {

    } else {

    }
  }
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
```

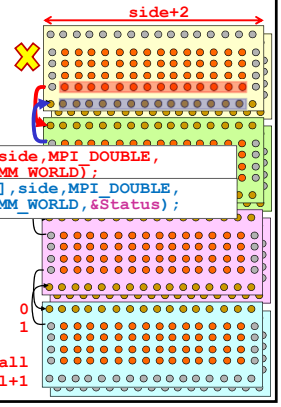

Exemple de programmation MPI

Implantation en Send-Recv

```
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  .....
  // - Frontier exchange
  if (NbPE > 1) {
    if (Me == 0) {
      MPI_Send(&V[NI][small][1],…,Me+1,…);
      MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
    } else if (Me == NbPE - 1) {
      MPI_Send(&V[NI][1][1],…,Me-1,…);
      MPI_Recv(&V[NI][0][1],…,Me-1,…);
    } else {
    }
  }
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
```

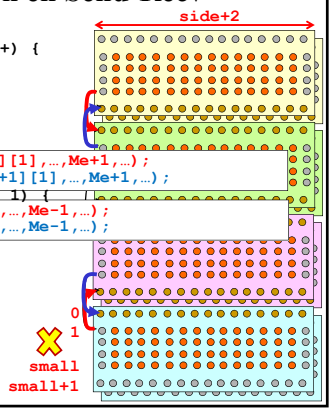

Exemple de programmation MPI

Implantation en Send-Recv

```
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  .....
  // - Frontier exchange
  if (NbPE > 1) {
    if (Me == 0) {
      MPI_Send(&V[NI][small][1],…,Me+1,…);
      MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
    } else if (Me == NbPE - 1) {
      MPI_Send(&V[NI][1][1],…,Me-1,…);
      MPI_Recv(&V[NI][0][1],…,Me-1,…);
    } else {
      MPI_Send(&V[NI][small][1],…,Me+1,…);
      MPI_Send(&V[NI][1][1],…,Me-1,…);
      MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
      MPI_Recv(&V[NI][0][1],…,Me-1,…);
    }
  }
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
```

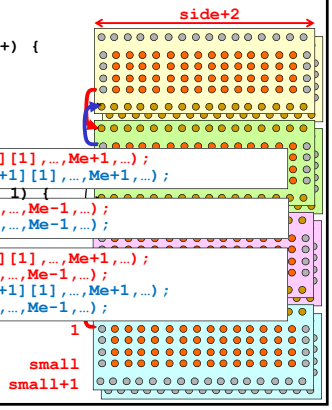

Exemple de programmation MPI

Implantation en Send-Recv

```
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  .....
  // - Frontier exchange
  if (NbPE > 1) {
    if (Me == 0) {
      MPI_Send(…);
      MPI_Recv(…);
    } else if (Me == NbPE - 1) {
      MPI_Send(…);
      MPI_Recv(…);
    } else {
      MPI_Send(…);
      MPI_Send(…);
      MPI_Recv(…);
      MPI_Recv(…);
    }
  }
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
```

MPI_Send / MPI_Recv : simple mais peu portable !

- Optimisé sur chaque supercalculateur
- Mais peut fonctionner différemment !

Rappel : 2 stratégies

- Pour des codes génériques sur « clusters de PC » : ne pas utiliser
- Sur super-calculateur propriétaire : utiliser + portage du code à chaque changement de machine

Exemple de programmation MPI

Implantation en Bsend-Recv

```
// Buffer size and pointer declaration
int size1Msg, sizeBuff;
void *PtBuff;
// Buffer size computation and allocation
MPI_Pack_size(side,MPI_DOUBLE,MPI_COMM_WORLD,&size1Msg);
sizeBuff = 2*(size1Msg + MPI_BSEND_OVERHEAD);
PtBuff = (void *) malloc(sizeBuff);
if (PtBuff == NULL) ……
// Relaxation loop (with comms)
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  ……
  // - Frontier exchange
  ……
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
// Buffer free
free(PtBuff);
```

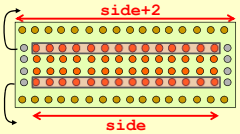

Exemple de programmation MPI

Implantation en Bsend-Recv

```
// Buffer size computation and allocation
……
// Relaxation loop (with comms)
OI = 0; NI = 1;
for (c = 0; c < NbCycle; c++) {
  // - Computation loop
  ……
  // - Frontier exchange
  if (NbPE > 1) {
    MPI_Buffer_attach(PtBuff,sizeBuff);
    if (Me == 0) {
      MPI_Bsend(…); MPI_Recv(…);
    } else if (Me == NbPE - 1) {
      MPI_Bsend(…); MPI_Recv(…);
    } else {
      MPI_Bsend(…); MPI_Bsend(…);
      MPI_Recv(…);  MPI_Recv(…);
    }
    MPI_Buffer_detach(&PtBuff,&sizeBuff);
  }
  // - Index switching
  OI = 1-OI; NI = 1-NI;
}
// Buffer free
……
```

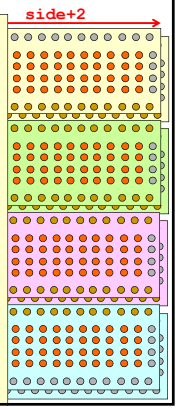

Exemple de programmation MPI

Implantation en Ssend-Recv

Avantage :
On évite une recopie mémoire

Inconvénient :
Il faut **planifier/séquencer** les comms, sinon il y aura interblocage!

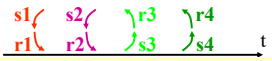

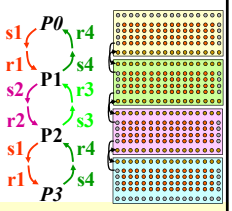


```
main(in argc, char ** argv) {
  ……   // MPI initialisations
  ……   // Non-MPI initialisations
  // RELAXATION LOOP
  for (cycle = 0; cycle < NbCycle; cycle++) {
    …… // - Computation loop
    …… // - Frontier exchange
    …… // - Index switching
  }
  // Print results and end of MPI calls
  ……
}
```

Exemple de programmation MPI

Implantation en Ssend-Recv

```
// - Frontier exchange
if (NbPE > 1) {
  if (Me == 0) {
    MPI_Ssend(&V[NI][small][1],…,Me+1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
  } else if (Me == NbPE - 1) {
    MPI_Recv(&V[NI][0][1],…,Me-1,…);
    MPI_Ssend(&V[NI][1][1],…,Me-1,…);
  } else if (Me%2 == 0) {
    MPI_Ssend(&V[NI][small][1],…,Me+1,…);
    MPI_Recv(&V[NI][0][1],…,Me-1,…);
    MPI_Ssend(&V[NI][1][1],…,Me-1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
  } else /* if (Me%2 == 1) */ {
    MPI_Recv(&V[NI][0][1],…,Me-1,…);
    MPI_Ssend(&V[NI][small][1],…,Me+1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
    MPI_Ssend(&V[NI][1][1],…,Me-1,…);
  }
}
```

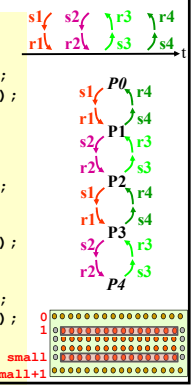

Exemple de programmation MPI

Implantation en Ssend-Recv

Autre séquencement possible :

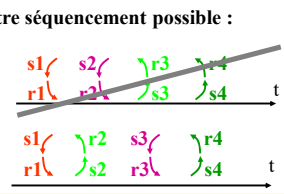

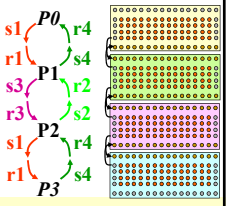


```
main(in argc, char ** argv) {
 ……   // MPI initialisations
 ……   // Non-MPI initialisations
 // RELAXATION LOOP
 for (cycle = 0; cycle < NbCycle; cycle++) {
   …… // - Computation loop
   …… // - Frontier exchange
   …… // - Index switching
 }
 // Print results and end of MPI calls
 ……
}
```

Exemple de programmation MPI

Implantation en Ssend-Recv

```
// - Frontier exchange
if (NbPE > 1) {
  if (Me == 0) {
    MPI_Ssend(&V[NI][small][1],…,Me+1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
  } else if (Me == NbPE - 1) {
    if (Me%2 == 0) {
      MPI_Ssend(&V[NI][1][1],…,Me-1,…);
      MPI_Recv(&V[NI][0][1],…,Me-1,…);
    } else {
      MPI_Recv(&V[NI][0][1],…,Me-1,…);
      MPI_Ssend(&V[NI][1][1],…,Me-1,…);
    }
  } else if (Me %2 == 0) {
    MPI_Ssend(&V[NI][small][1],…,Me+1,…);
    MPI_Ssend(&V[NI][1][1],…,Me-1,…);
    MPI_Recv(&V[NI][0][1],…,Me-1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
  } else {
    MPI_Recv(&V[NI][0][1],…,Me-1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
    MPI_Ssend(&V[NI][small][1],…,Me+1,…);
    MPI_Ssend(&V[NI][1][1],…,Me-1,…);
  }
}
```

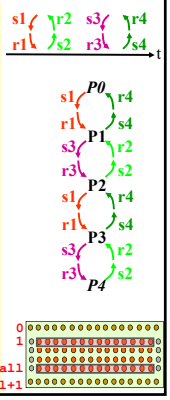

Exemple de programmation MPI

Implantation en Rsend-Recv

Avantage :

Pas de recopie mémoire

Emission rapide (suppression d'overhead)

Inconvénient :

Théoriquement : nécessite que le recv soit fait avant !

sinon : comportement non spécifié

Ne pas modifier la zone transmise avant fin de transmission

```
main(in argc, char ** argv) {
 ..... // MPI initialisations
 ..... // Non-MPI initialisations
 // RELAXATION LOOP
 for (cycle = 0; cycle < NbCycle; cycle++) {
   ..... // - Computation loop
   ..... // - Frontier exchange
   ..... // - Index switching
 }
 // Print results and end of MPI calls
 .....
}
```

Exemple de programmation MPI

Implantation en Rsend-Recv

```
// - Frontier exchange
if (NbPE > 1) {
  if (Me == 0) {
    MPI_Rsend(&V[NI][small][1],…,Me+1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
  } else if (Me == NbPE - 1) {
    MPI_Rsend(&V[NI][1][1],…,Me-1,…);
    MPI_Recv(&V[NI][0][1],…,Me-1,…);
  } else {
    MPI_Rsend(&V[NI][1][1],…,Me-1,…);
    MPI_Rsend(&V[NI][small][1],…,Me+1,…);
    MPI_Recv(&V[NI][0][1],…,Me-1,…);
    MPI_Recv(&V[NI][small+1][1],…,Me+1,…);
  }
}
```

Implantation « douteuse » :

fonctionne souvent correctement …

… mais sans garanti sur un simple cluster de PC !

Exemple de programmation MPI

Implantation en Sendrecv

Avantage :

Pas de gestion de buffer mémoire

Deux opérations en une !

Inconvénient :

Planifier/séquencer les Sendrecv

r1 ⟨⟩ s1 r2 ⟨⟩ s2

s1 ⟨⟩ r1 s2 ⟨⟩ r2 t

P0
s1 ⟨⟩ r1
r1 ⟨⟩ s1
P1
s2 ⟨⟩ r2
r2 ⟨⟩ s2
P2
s1 ⟨⟩ r1
r1 ⟨⟩ s1
P3

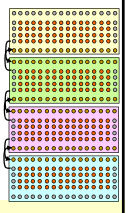

```
main(in argc, char ** argv) {
 ..... // MPI initialisations
 ..... // Non-MPI initialisations
 // RELAXATION LOOP
 for (cycle = 0; cycle < NbCycle; cycle++) {
   ..... // - Computation loop
   ..... // - Frontier exchange
   ..... // - Index switching
 }
 // Print results and end of MPI calls
 .....
}
```

Exemple de programmation MPI

Implantation en Sendrecv

```
// - Frontier exchange
if (NbPE > 1) {
  if (Me == 0) {
    MPI_Sendrecv(&V[NI][small][1],…,Me+1,…
                 &V[NI][small+1][1],…,Me+1,…);
  } else if (Me == NbPE - 1) {
    MPI_Sendrecv(&V[NI][1][1],…,Me-1,…
                 &V[NI][0][1],…,Me-1,…);
  } else if (Me % 2 == 0) {
    MPI_Sendrecv(&V[NI][small][1],…,Me+1,…
                 &V[NI][small+1][1],…,Me+1,…);
    MPI_Sendrecv(&V[NI][1][1],…,Me-1,…
                 &V[NI][0][1],…,Me-1,…);
  } else /* if (Me % 2 == 1) */ {
    MPI_Sendrecv(&V[NI][1][1],…,Me-1,…
                 &V[NI][0][1],…,Me-1,…);
    MPI_Sendrecv(&V[NI][small][1],…,Me+1,…
                 &V[NI][small+1][1],…,Me+1,…);
  }
}
```

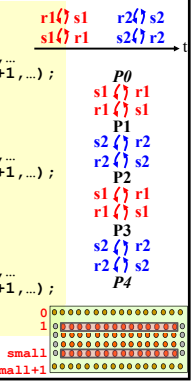

Exemple de programmation MPI

Implantation en Sendrecv

Autre séquencement possible :

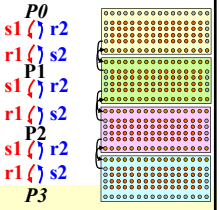


```
main(in argc, char ** argv) {
 ……   // MPI initialisations
 ……   // Non-MPI initialisations
 // RELAXATION LOOP
 for (cycle = 0; cycle < NbCycle; cycle++) {
   …… // - Computation loop
   …… // - Frontier exchange
   …… // - Index switching
 }
 // Print results and end of MPI calls
 ……
}
```

Exemple de programmation MPI

Implantation en Sendrecv

```
// - Frontier exchange
if (NbPE > 1) {
  if (Me == 0) {
    MPI_Sendrecv(&V[NI][small][1],…,Me+1,…
                 &V[NI][small+1][1],…,Me+1,…);
  } else if (Me == NbPE - 1) {
    MPI_Sendrecv(&V[NI][1][1],…,Me-1,…
                 &V[NI][0][1],…,Me-1,…);
  } else {
    MPI_Sendrecv(&V[NI][small][1],…,Me+1,…
                 &V[NI][0][1],…,Me-1,…);
    MPI_Sendrecv(&V[NI][1][1],…,Me-1,…
                 &V[NI][small+1][1],…,Me+1,…);
  }
}
```

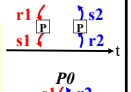

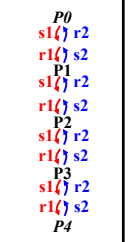

- Le séquencement des **`MPI_Sendrecv`** est plus simple (moins de cas à différencier)
- Le **`MPI_Sendrecv`** de chaque extrémité se conjugue avec deux autres **`MPI_Sendrecv`**

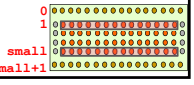

L'essentiel de MPI-1

4 – Communications de groupe

- Principes des communications de groupe
- Broadcast
- Scatter
- Gather
- Reduce

Principes des comm. de groupe

5 types principaux :

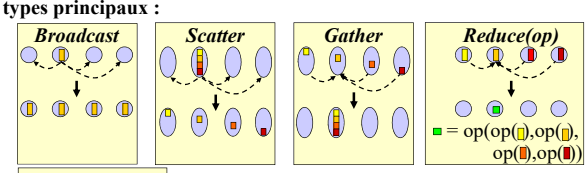

+ les barrières !

Principes :

- Utilisent les *communicator* et les groupes de processus
- Opérations bloquantes
- Des variantes existent : *all-reduce*, *all-to-all*, *scatterv*, …

Intérêt dans un supercalculateur :

Le routage est optimisé selon le réseau sous-jacent
(arborescent – linéaire – sur bus – …)

Broadcast

```
int MPI_Bcast(buffer,count,datatype,root,comm )
   void *buffer;  // Starting address of buffer
   int count;     // Number of elts in buffer (integer)
   MPI_Datatype datatype; // Data type of buffer
   int root;      //  Rank of broadcast root (integer)
   MPI_Comm comm; // Communicator
```

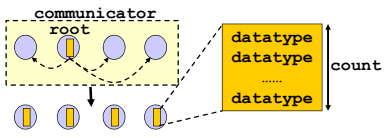

Chaque processus exécute `MPI_Bcast` (en émetteur ou récepteur)

Généralisation :

`MPI_Alltoall` et `MPI_Alltoallv`

Communications de groupe

Scatter

```
int MPI_Scatter(sendbuf,sendcnt,sendtype,
                recvbuf,recvcnt,recvtype, root,comm)
   void *sendbuf; // Address of send buffer
   int sendcnt;   // Nb of elements sent to each process
   MPI_Datatype sendtype; // Data type of elt to send
   void *recvbuf; // Address of receive buffer
   int recvcnt;   // Number of elements in receive buffer
   MPI_Datatype recvtype; // Data type of elt to receive
   int root;      // Rank of the sending process
   MPI_Comm comm; // Communicator
```

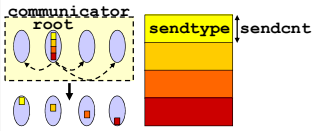

- Chaque processus exécute **MPI_Scatter** (en émetteur ou récepteur)
- Le buffer d'émission n'a de sens que sur le processus **root**

Généralisation :

MPI_Scatterv (avec partitionnement explicite des données)

Communications de groupe

Gather

```
int MPI_Gather(sendbuf,sendcnt,sendtype,
               recvbuf,recvcount,recvtype, root,comm)
   void *sendbuf; // Starting address of send buffer
   int sendcnt;   // Number of elements in send buffer
   MPI_Datatype sendtype; // Data type of elts to send
   void *recvbuf; // Address of receive buffer
   int recvcount; // Nb of elts to receive from each proc
   MPI_Datatype recvtype; // Data type of elt to recv
   int root;      // Rank of the receiving process
   MPI_Comm comm; // Communicator
```

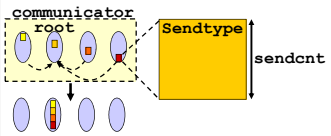

- Chaque processus exécute **MPI_Gather** (en émetteur ou récepteur)
- Le buffer de réception n'a de sens que sur le processus **root**

Généralisation :

MPI_Gatherv, **MPI_Allgather**, **MPI_Allgatherv**

Communications de groupe

Reduce

```
int MPI_Reduce(sendbuf,recvbuf,count,datatype,op,
               root,comm)
   void *sendbuf; // Address of send buffer
   void *recvbuf; // Address of receive buffer
   int count;     // Number of elts in send buffer
   MPI_Datatype datatype; // Data type of elts to send
   MPI_Op op;     // Reduce operation
   int root;      // Rank of the process hosting result
   MPI_Comm comm; // Communicator
```

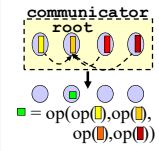

- Opérations de reduction disponibles :
  MPI_MAX, **MPI_MIN**, **MPI_SUM**, **MPI_PROD**
  MPI_LAND, **MPI_BAND**, **MPI_LOR**, **MPI_BOR**
  MPI_LXOR, **MPI_BXOR**, **MPI_MINLOC**
- Définition de nouvelles opérations avec **MPI_Op_create()**

Généralisation :

MPI_Allreduce, **MPI_Reduce_scatter** : les res sont redistribués

L'essentiel de MPI-1

5 – Stratégie de déploiement

- Placement de processus sur cluster de multi-cœurs
- Processus et threads sur clusters de multicoeurs
- Meilleur déploiement ?

Processus sur clusters de multicoeurs (1)

Ressources matérielles:

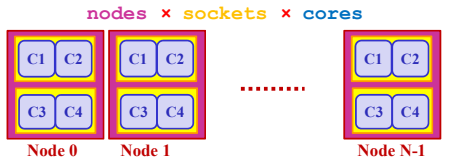

Topologie virtuelle de l'algorithme (ex : anneau)

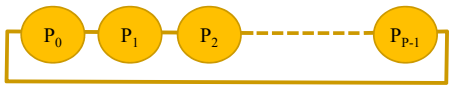

→ Quel *mapping* de la topologie virtuelle sur les rsrcs matérielles ?
→ Quel *ranking* des processus MPI sur la topologie matérielle ?
→ Quel *binding* d'un process sur les rsrcs matérielles locales ?

Stratégie de déploiement

Processus sur clusters de multicoeurs (1)

Ressources matérielles:

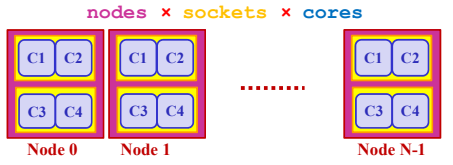

Topologie virtuelle de l'algorithme (ex : anneau)

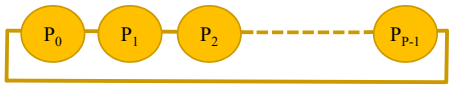


```
mpirun -np #P -machinefile machines.txt
              -map-by  <node|socket|core…>
              -rank-by <node|socket|core…>
              -bind-to <none|socket|core…>
              --report-bindings ……
```

Stratégie de déploiement

Processus sur clusters de multicoeurs (1)

Ressources matérielles:

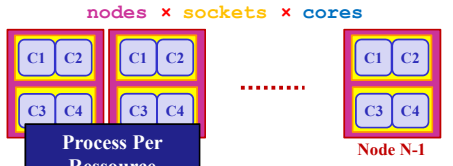

Topologie virtuelle de l'algorithme (ex : anneau)

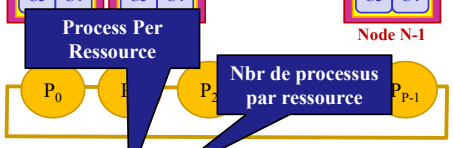


```
mpirun -np #P -machinefile machines.txt
              -map-by  ppr:N:<node|socket|core…>
              -rank-by <node|socket|core…>
              -bind-to <none|socket|core…>
              --report-bindings .....
```

Stratégie de déploiement

Processus sur clusters de multicoeurs (2)

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 toutes le cache ou toute la RAM d'un nœud / d'un socket

→ Reste un mode « luxueux »

machines.txt

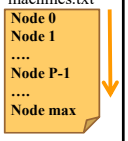

Attention : le binding d'un process peut être limité à un socket…

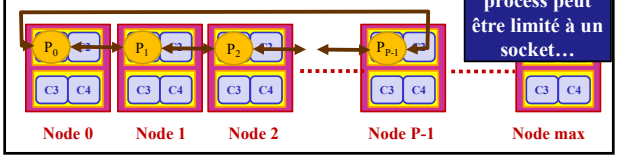

Stratégie de déploiement

Processus sur clusters de multicoeurs (2)

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

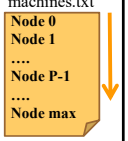


```
mpirun -np #P -machinefile machines.txt
              -map-by ppr:1:node
              -rank-by node
              -bind-to none|socket .....
```

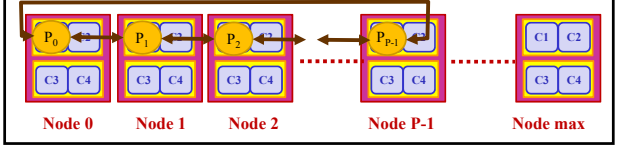

Stratégie de déploiement

Processus sur clusters de multicoeurs (3)

machines.txt

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

Sol 2 : 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.

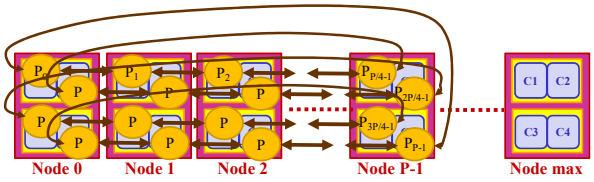

Stratégie de déploiement

Processus sur clusters de multicoeurs (3)

machines.txt

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

Sol 2 : 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:#C:node
              -rank-by node
              -bind-to core .....
```

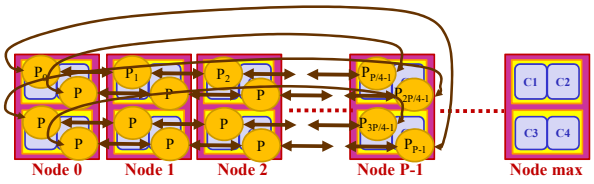

Stratégie de déploiement

Processus sur clusters de multicoeurs (4)

machines.txt

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

Sol 3 : 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.*

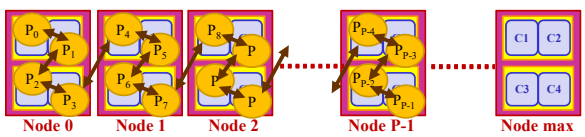

Stratégie de déploiement

Processus sur clusters de multicoeurs (4)

Sol 3 : 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

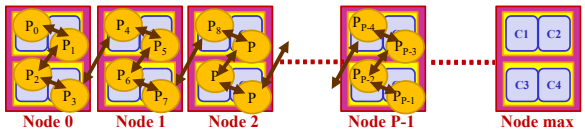

Stratégie de déploiement

Processus sur clusters de multicoeurs (4)

Sol 3 : 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:1:core
              -rank-by core
              -bind-to core .....
```

machines.txt

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

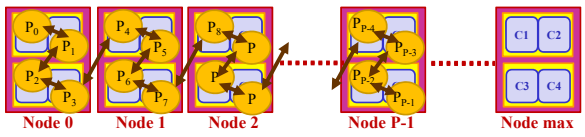

Stratégie de déploiement

Processus et threads sur clusters de multicoeurs

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

```
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

machines.txt

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

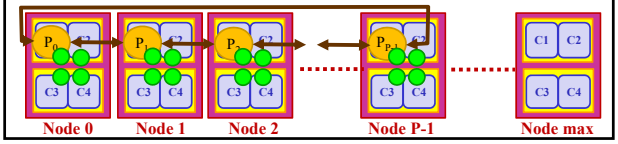

Stratégie de déploiement

Processus et threads sur clusters de multicoeurs

Sol 5 : un processus MPI par Socket et C 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 modernes/NUMA

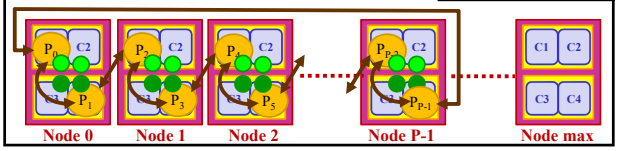

Stratégie de déploiement

Options de binding

Des options pour contrôler les ressources allouées à un processus multithreadé :

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

Stratégie de déploiement

Exemple de déploiement

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

Stratégie de déploiement

Exemple de déploiement

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

Stratégie de déploiement

Exemple de déploiement

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

Stratégie de déploiement

Exemple de déploiement

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

Stratégie de déploiement

Exemple de déploiement

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

Stratégie de déploiement

Exemple de déploiement

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

Stratégie de déploiement

Rapport de binding

```
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][../../../..]
```

Stratégie de déploiement

Meilleur déploiement ?

Dépend de plusieurs facteurs :

- Schéma de communication (topologie des processus MPI)
  → *Minimiser les communications inter-nœuds*
- Architecture NUMA des nœuds
  → *Au moins un processus par sous-nœud NUMA*
- Bibliothèque de multithreading et d'envoi de messages disponibles
  → *Toutes les implantations des bibliothèques de multithreading et de MPI ne sont pas équivalentes*

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

L'essentiel de MPI-1

6 – Ex. de mesure et d'analyse de performances

- Jacobi sur (tout) petits clusters
- Produit de matrices
- Ce qui compte ….

Analyse de performance en MPI

Jacobi - Fast Ethernet

Fast-Ethernet – 1 server + 2 nodes – PIII-1GHz-256KB (cache)

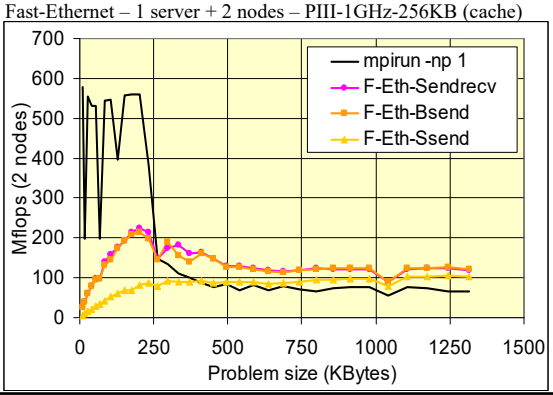

Jacobi - Fast Ethernet

Fast-Ethernet – 1 server + 2 nodes – PIII-1GHz-256KB (cache)

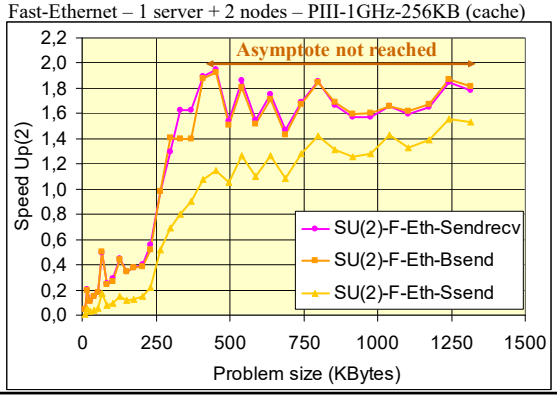

Jacobi - Gigabit Ethernet

Gigabit-Ethernet – 2 nodes – PIV-Xeon-1.4GHz-512KB (cache)

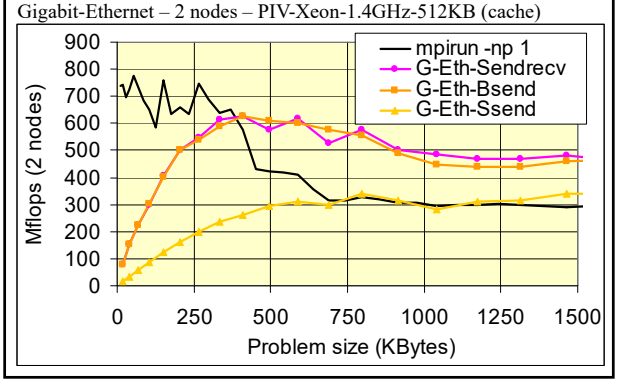

Jacobi - Gigabit Ethernet

Gigabit-Ethernet – 2 nodes – PIV-Xeon-1.4GHz-512KB (cache)

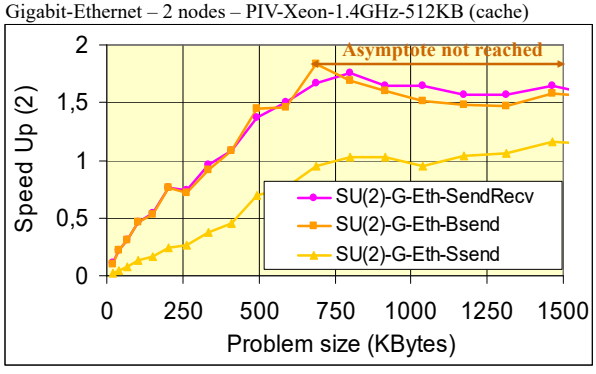

Jacobi - Myrinet

Myrinet – 1 server + 2 nodes – PIII-1GHz-256KB (cache)

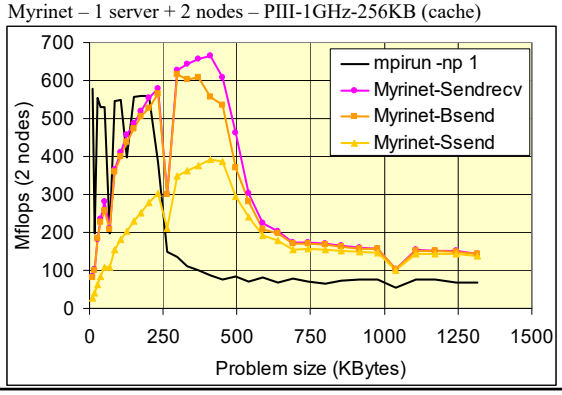

Jacobi - Myrinet

Myrinet – 1 server + 2 nodes – PIII-1GHz-256KB (cache)

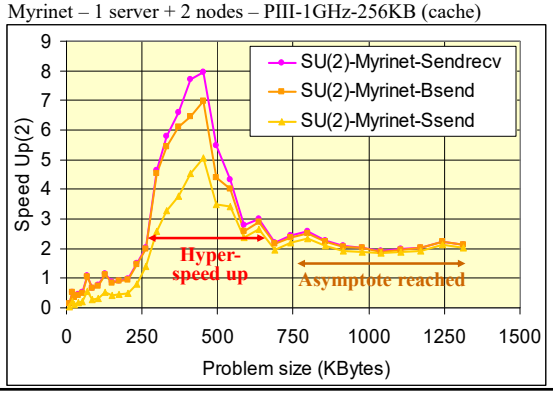

Produit de matrices sur anneau

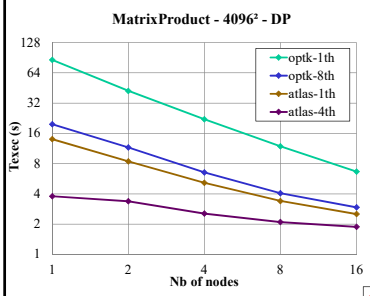

Cluster :

- 16 x 4-cores-ht 2.6GHz 8Go Ram
- 1 switch Gigabit Ethernet

Code :

- Optk: un peu optimisé
- Atlas : BLAS

Plus le noyau est optimisé, plus les calculs sont rapides, plus le *speedup* sera limité !

Analyse de performance en MPI

Produit de matrices sur anneau

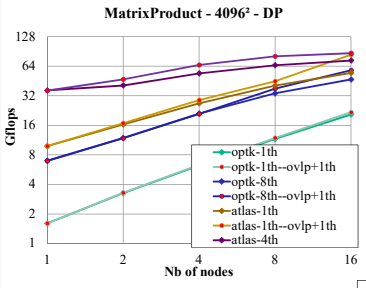

Cluster :

- 16 x 4-cores-ht 2.6GHz 8Go Ram
- 1 switch Gigabit Ethernet

Code :

- Optk: un peu optimisé
- Atlas : BLAS

Plus le noyau est optimisé, plus les calculs sont rapides, plus le *speedup* sera limité !

Analyse de performance en MPI

Il n'y a pas que le nbr de processeurs qui compte lors des choix

Mémoire et mémoire cache ….

- Optimisations sérielles ! (vaste)
- Statégie de blocage en cache
- Recherche d'hyper-accélération.

Processeurs

- Nombre de processeurs
- Puissance des procs.
- Consommation électrique

Réseau d'interconnexion

- Bw ?
- Latence ?
- Capacité d'extensibilité ?

Equilibrage des ressources :

- Mémoire *vs* processeur
- **Nbr de nœuds *vs* réseau**
- Performances calculatoires *vs* énergétiques

L'essentiel de MPI-1

Questions ?