# Programmation parallèle sur mémoire distribuée 2ème partie

## – MASTER MIHPS –

Camille Coti[1]
camille.coti@lipn.univ-paris13.fr

[1]Université de Paris XIII, CNRS UMR 7030, France

# Plan du cours

## Exemples d'applications MPI

- Anneau à jeton
- Décomposition de domaine

## Fonctionnalités avancées de MPI

- Datatypes
- Réductions

## Profiling et déboggage d'applications MPI

# Circulation d'un anneau à jeton

## Algorithme

Un anneau tourne entre les processus

- Le processus de rang 0 envoie le premier jeton
- Les autres processus attendent de recevoir le jeton
  - Quand ils le reçoivent : incrémentation
  - Ils l'envoient au voisin

  On arrête au bout de `NB_TOURS` tours

## Mise en œuvre

Utilisation de MPI_Send, MPI_Recv

- Variation de la taille du token
- Et si un processus ne fait rien ?

## Travaux pratiques 1

Implémentation d'un anneau à jeton

```
mpiexec --machinefile machinefile -n 12 ./tokenring 1024
```

## Maître-esclave

### Distribution des données

Le maître distribue le travail aux esclaves

- Le maître démultiplexe les données, multiplexe les résultats
- Les esclaves ne entre eux

### Efficacité

Files d'attentes de données et résultats au niveau du maître

- On retrouve la partie séquentielle de la loi d'Amdahl
- Communications : maître $\leftrightarrow$ esclaves
- Les esclaves ne travaillent que quand ils attendent des données ou qu'ils envoient leurs résultats

Seuls les esclaves participent effectivement au calcul

- Possibilité d'un bon speedup à grande échelle (esclaves $>>$ maître)

- Peu rentable pour quelques processus
- Attention au bottleneck au niveau du maître

# Maître-esclave

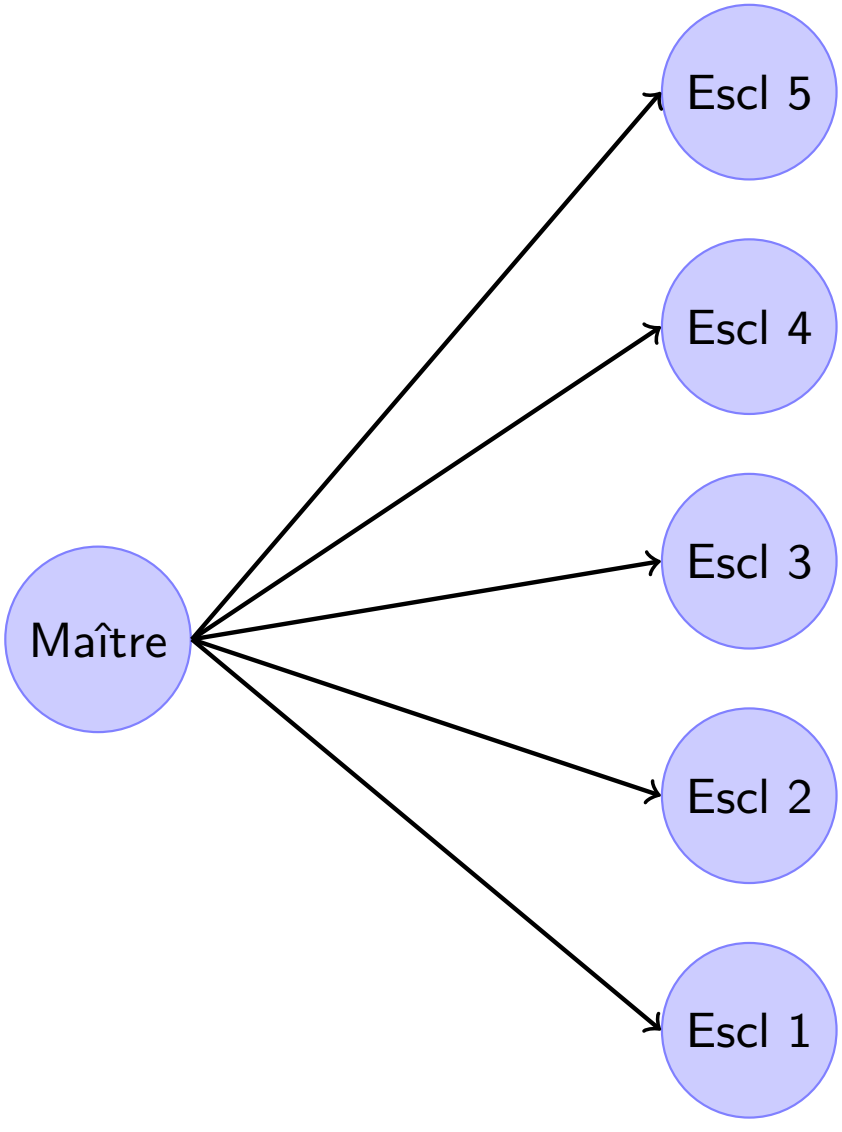


## Équilibrage de charge

Statique :

- Utilisation de `MPI_Scatter` pour distribuer les données
- `MPI_Gather` pour récupérer les résultats

Dynamique :

- Mode *pull* : les esclaves demandent du travail
- Le maître envoie les chunks 1 par 1

## Travaux pratiques 2

Implémenter un squelette de maitre-esclave utilisant les deux méthodes. Avantages et inconvénients ?

# Découpage en grille

## Grille de processus

On découpe les données et on attribue un processus à chaque sous-domaine

## Décomposition 1D

Découpage en bandes

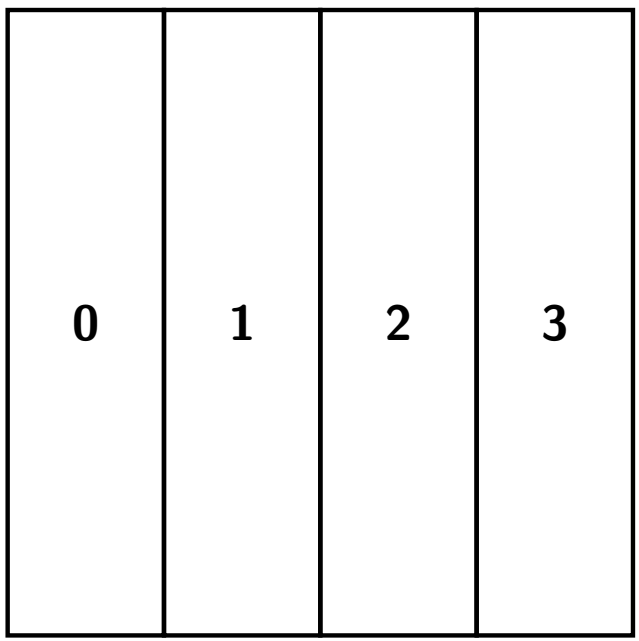


## Décomposition 2D

Découpage en rectangles, plus scalable

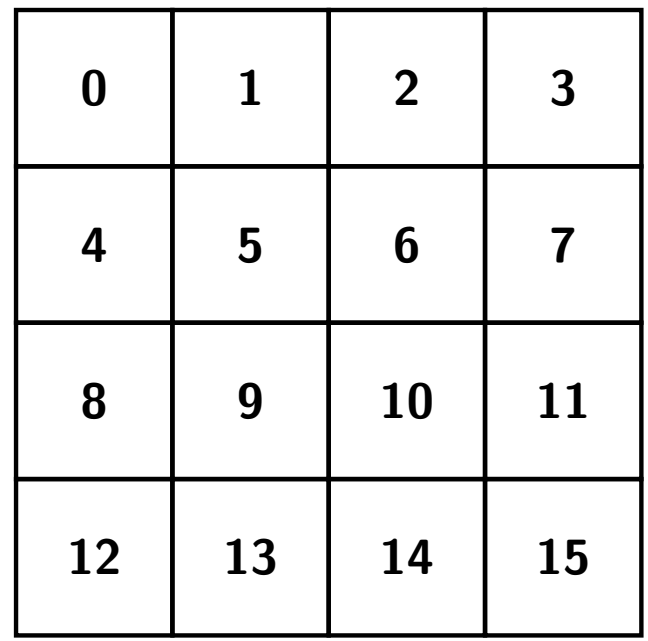

# Ghost region

## Frontières entre les sous-domaines

Un algorithme peut avoir besoin des valeurs des points voisins pour calculer la valeur d'un point

- Traitement d'images (détection de contours...), automates cellulaires...

Réplication des données situées à la frontière

- Chaque processus dispose d'un peu des données des processus voisins
- Mise à jour à la fin d'une étape de calcul

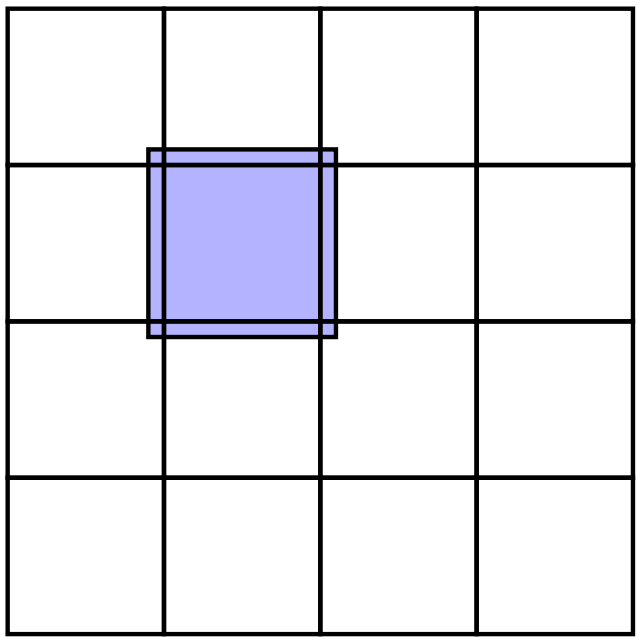

## Travaux pratiques 3

Utilisation d'une ghost region dans le maître-esclave dynamique en utilisant une décomposition 1D.

## Décomposition en structure géométrique

On transpose un communicateur sur une topologie cartésienne

- `int MPI_Cart_create ( MPI_Comm comm_old, int ndims, int *dims, int *periods, int reorder, MPI_Comm *comm_cart );`

| | | | |
|---|---|---|---|
| **0** | **1** | **2** | **3** |
| **4** | **5** | **6** | **7** |
| **8** | **9** | **10** | **11** |
| **12** | **13** | **14** | **15** |

### En 2D

- `comm_old` : le communicateur de départ
- `ndims` : ici 2
- `dims` : nombre de processus dans chaque dimension (ici $\{4, 4\}$)
- `periods` : les dimensions sont-elles périodiques
- `reorder` : autoriser ou non de modifier les rangs des processus
- `comm_cart` : nouveau communicateur

## Extraction de sous-communicateurs

Communicateur de colonnes, de rangées...

- `int MPI_Cart_sub( MPI_Comm comm_old, int *remain_dims, MPI_Comm *comm_new );`

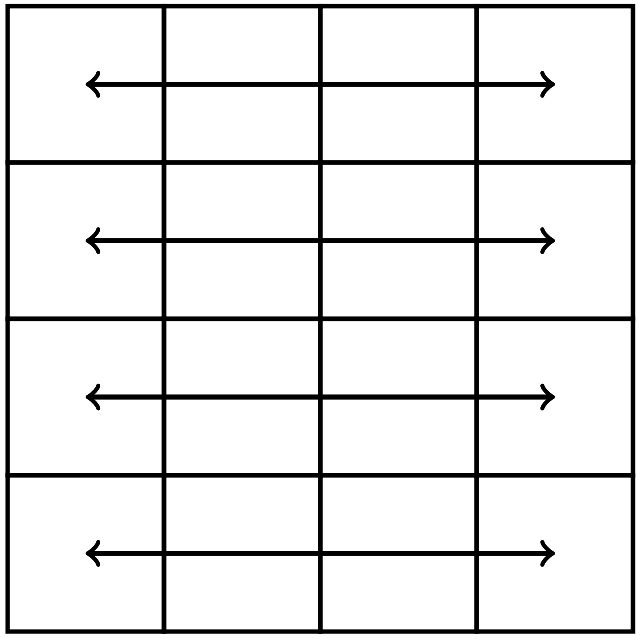

## Communicateurs de lignes

- `comm_old` : le communicateur de départ
- `remain_dims` : quelles dimensions sont dans le communicateur ou non
- `comm_new` : le nouveau communicateur

## Travaux pratiques 4

Implémenter la grille 2D de gauche et faire un broadcast sur chaque rangée.

# Utilisation des datatypes MPI

## Principe

- On définit le datatype
  - `MPI_Type_contiguous`, `MPI_Type_vector`, `MPI_Type_hvector`, `MPI_Type_indexed`, `MPI_Type_hindexed`, `MPI_Type_struct`
- On le commit
  - `MPI_Type_commit`
- On le libère à la fin
  - `MPI_Type_free`

## Combinaison des types de base

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

## Données contigües

On crée un block d'éléments :

- `int MPI_Type_contiguous( int count, MPI_Datatype oldtype, MPI_Datatype *newtype );`

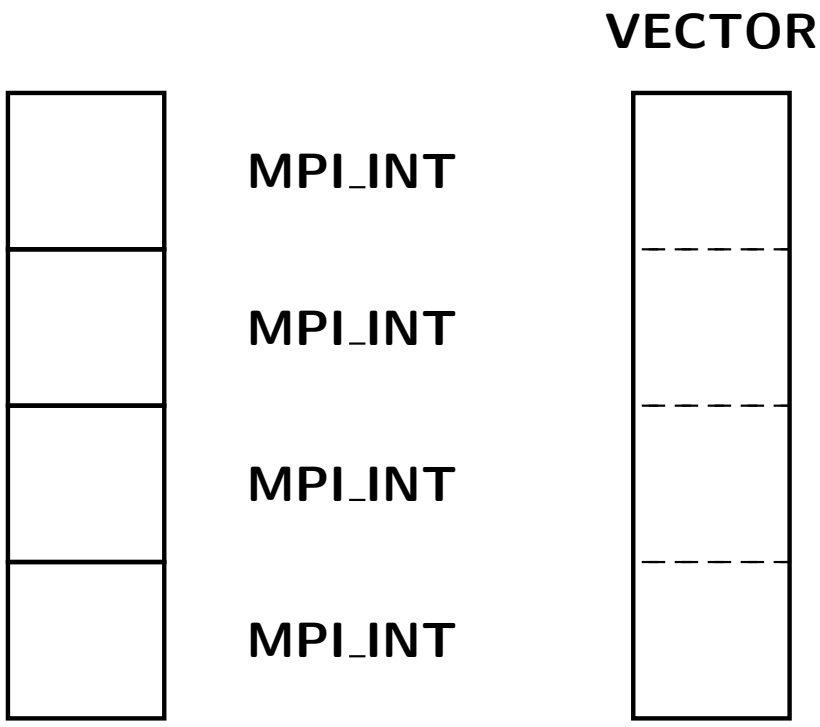


## Travaux pratiques 5

Implémenter l'anneau à jeton en faisant circuler des vecteurs en utilisant un MPI_Datatype (un seul élément sera envoyé à chaque communication, quel que soit la taille des données envoyées).

# Construction de datatypes MPI

## Vecteur de données

On crée un vecteur d'éléments :

- `int MPI_Type_vector( int count, int blocklength, int stride MPI_Datatype oldtype, MPI_Datatype *newtype );`

On aggrège des blocs de *blocklength* éléments séparés par un vide de *stride* éléments.

## Structure générale

On donne les éléments, leur nombre et l'offset auquel ils sont positionnés.

- `int MPI_Type_struct( int count, int *array_of_blocklengths, MPI_Aint *array_of_displacements, MPI_Datatype *array_of_types, MPI_Datatype *newtype);`

## Exemple

On veut créer une structure MPI avec un entier et deux flottants à double précision

- count = 2 : on a deux éléments
- array_of_blocklengths = 1, 2 : on a 1 entier et 2 doubles
- array_of_displacements = 0, sizeof( int), sizeof( int ) + sizeof( double ) (ou utilisation de MPI_Address sur une instance de cette structure)
- array_of_types = MPI_INT, MPI_DOUBLE

## La FFT 3D

Calcul de la transformée de Fourier 3D d'une matrice 3D

- FFT dans une dimension
- FFT dans la deuxième dimension
- FFT dans la troisième dimension

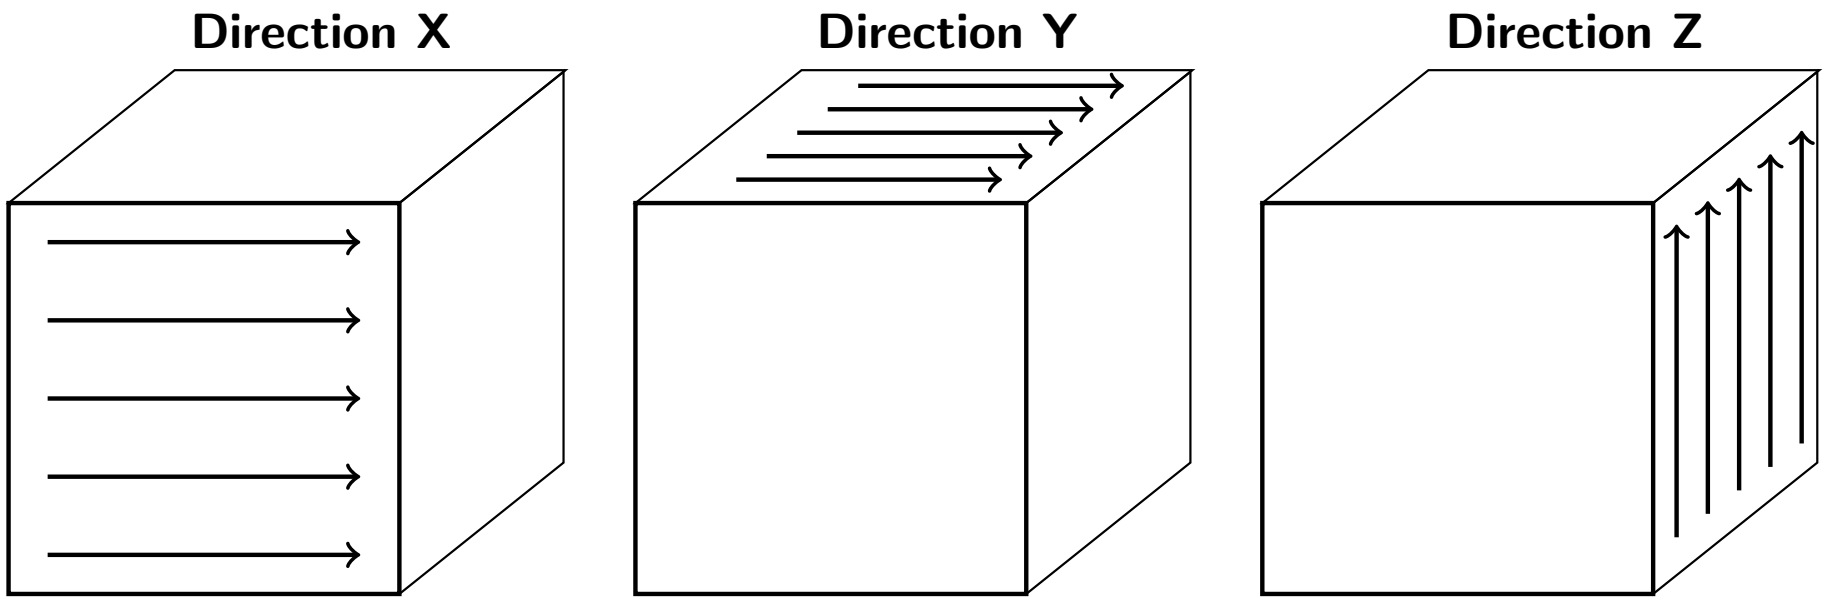

# Parallélisation de la FFT 3D

## Noyau de calcul : la FFT 1D

La FFT 1D est parallélisable

- Chaque vecteur peut être calculé indépendamment des autres

On veut calculer chaque vecteur *séquentiellement* sur *un seul processus*

- Direct pour la 1ere dimension
- Nécessite une transposition pour les dimensions suivantes

## Transposition de la matrice

On effectue une rotation de la matrice

- Redistribution des vecteurs
  - All to All
- Rotation des points (opération locale)

# Rotation des points

## Algorithme

```
MPI_Alltoall(tab 2 dans tab 1 )
for( i = 0 ; i < c ; ++i ) {
  for( j = 0 ; j < b ; ++j ) {
    for( k = 0 ; k < a ; ++k ) {
      tab2[i][j][k] = tab2[i][k][j];
    }
  }
}
```

## Complexité

- Le Alltoall coûte cher
- La rotation locale est en $O(n^3)$

# Dataypes non-contigüs

## Sérialisation des données en mémoire

La matrice est sérialisée en mémoire

- Vecteur$[0][0]$, Vecteur$[0][1]$, Vecteur$[0][2]$... Vecteur$[1][0]$, etc

## Rotation des données sérialisées

| | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| x | x | x | x | $\rightarrow$ | x | o | o | o |
| o | o | o | o | | x | o | o | o |
| o | o | o | o | | x | o | o | o |
| o | o | o | o | | x | o | o | o |

## Utilisation d'un datatype MPI

C'est l'écart entre les points des vecteur qui change avant et après la rotation $\rightarrow$ on définit un dataype différent en envoi et en réception.

Avantages :

- La rotation est faite par la bibliothèque MPI
- Gain d'une copie (buffer) au moment de l'envoi / réception des éléments (un seul élément au lieu de plusieurs)

## Performances

### FFT 2D sur Jaguar

*Parallel Zero-Copy Algorithms for Fast Fourier Transform and Conjugate Gradient using MPI Datatypes, Torsten Hoefler, Steven Gottlieb, EuroMPI'10*

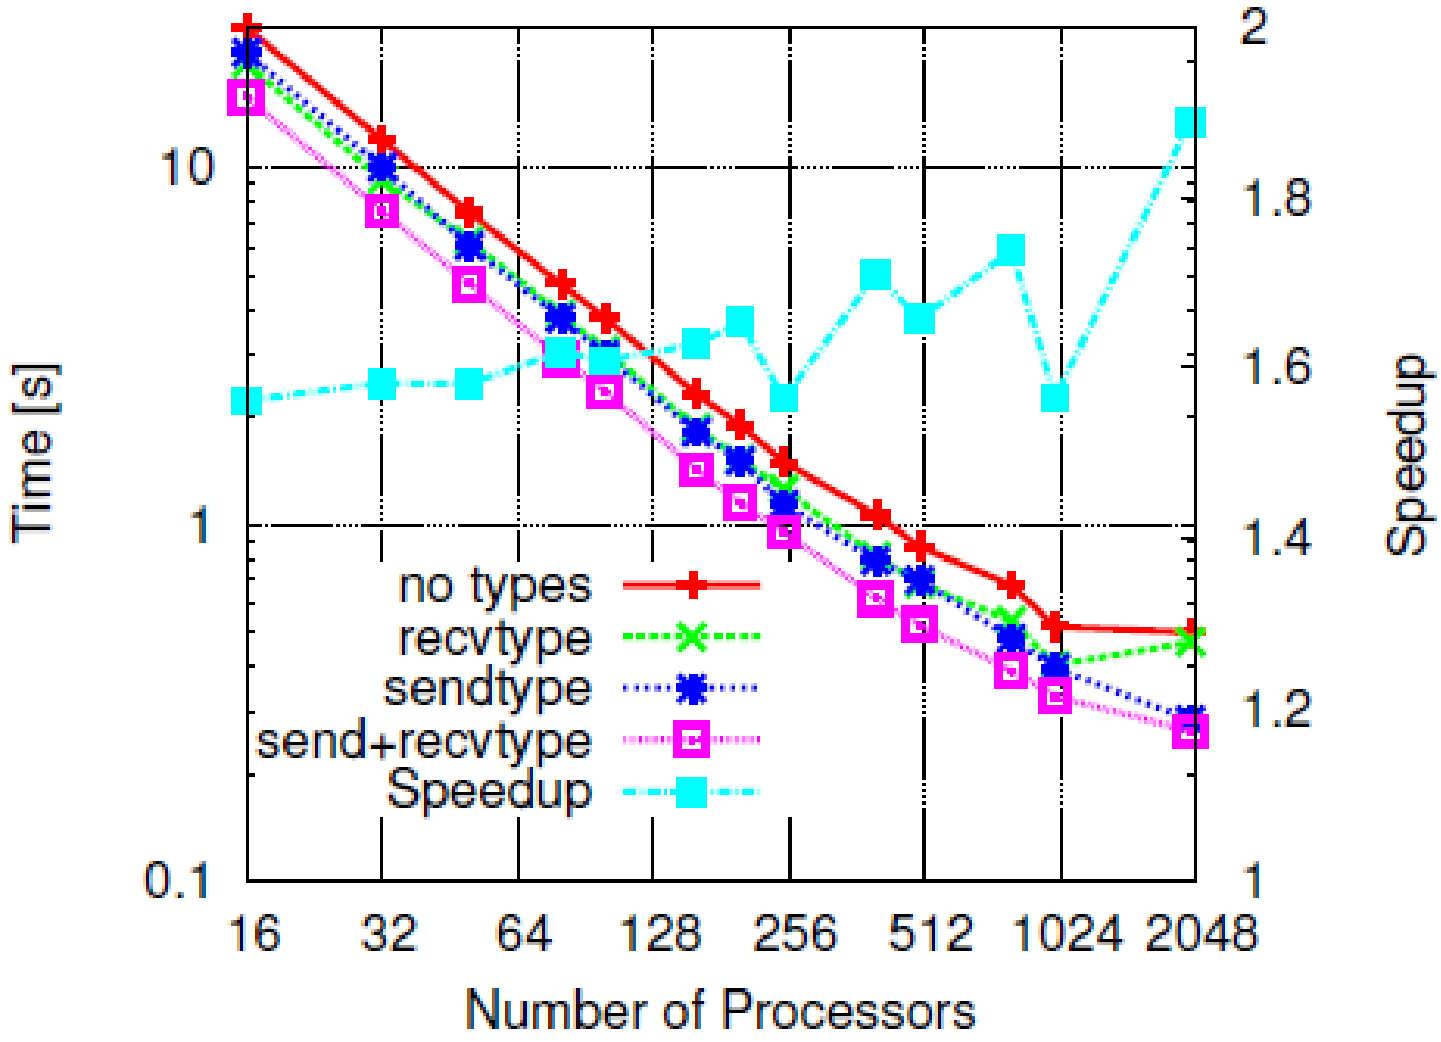

## Définition d'opérations

### Syntaxe

- `int MPI_Op_create( MPI_User_function *function, int commute, MPI_Op *op );`

On fournit un pointeur sur fonction. La fonction doit être associative et peut être commutative ou pas. Elle a un prototype défini.

### Exemple

- Définition d'une fonction :

```
void addem( int *, int *, int *, MPI_Datatype * );
void addem( int *invec, int *inoutvec, int *len, MPI_Datatype
*dtype ){
  int i;
  for ( i = 0 ; i < *len ; i++ )
    inoutvec[i] += invec[i];
}
```

- Déclaration de l'opération MPI :

```
MPI_Op_create( (MPI_User_function *)addem, 1, &op );
```

# Exemple d'utilisation : TSQR

## Definition

La *décomposition QR* d'une matrice A est une décomposition de la forme

$$A = QR$$

Où $Q$ est une matrice orthogonale ($QQ^T = I$)
et $R$ est une matrice triangulaire supérieure.

## TSQR basé sur CAQR

Algorithme à évitement de communications pour matrices "tall and skinny" (hauteur $>>$ largeur)

- On calcule plus pour communiquer moins (optimal en nombre de communications)
  - Les communications coûtent cher, pas les flops
- Calcul de facto QR partielle sur des sous-domaines (en parallèle), recomposition 2 à 2, facto QR, etc

# Algorithme TSQR

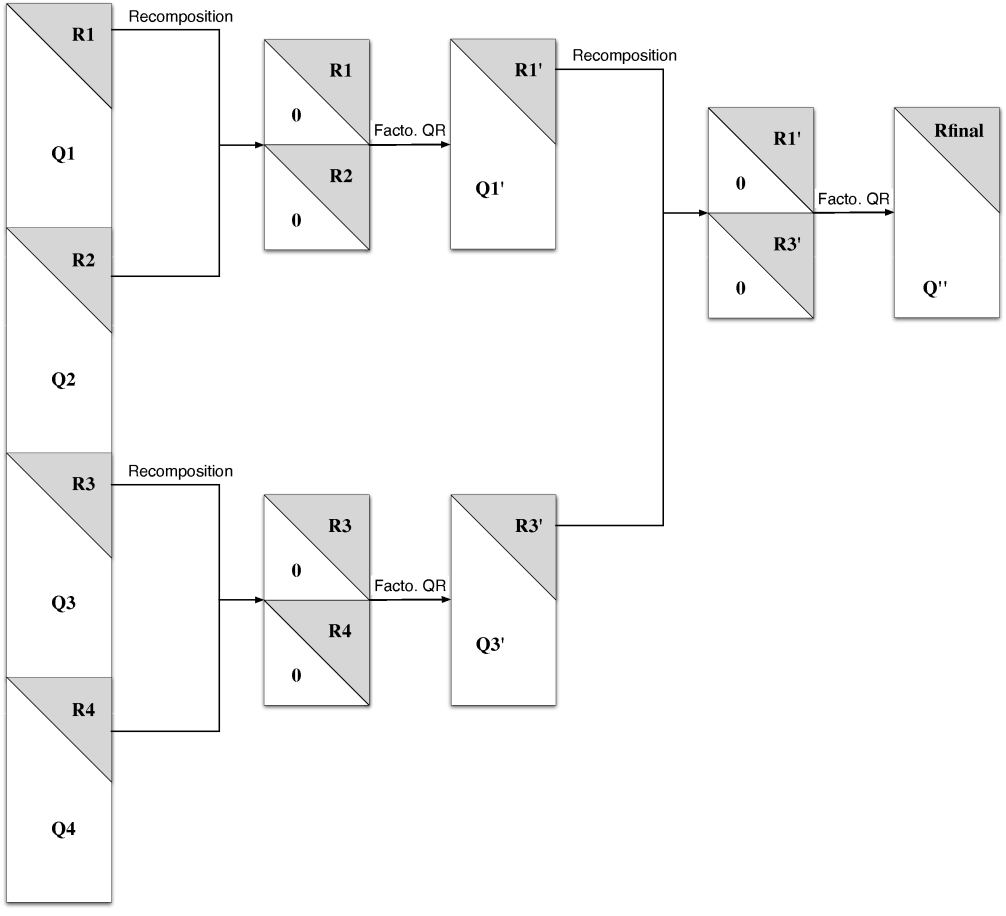


## Algorithme

Sur un arbre binaire :

- QR sur sa sous-matrice
- Communication avec le voisin
  - Si rang pair : réception de $r+1$
  - Si rank impair : envoi à $r-1$
- Si rang impair : fin

## Opération effectuée

On effectue à chaque étape de la réduction une factorisation QR des deux facteurs R mis l'un au-dessus de l'autre :

$$R = QR(R_1, R_2)$$

- C'est une opération binaire
  - Deux matrices triangulaires en entrée, une matrice triangulaire en sortie
- Elle est associative

$$QR(R_1, QR(R_2, R_3)) = QR(QR(R_1, R_2), R_3)$$

- Elle est commutative

$$QR(R_1, R_2) = QR(R_2, R_1)$$

## Utilisation de MPI_Reduce

L'opération remplit les conditions pour être une MPI_Op dans un MPI_Reduce

- Définition d'un datatype pour les facteurs triangulaires supérieurs $R$
- Utilisation de ce datatype et de l'opération QR dans un MPI_Reduce

## Performances de TSQR

Performance en MFlops/sec/proc sur une matrice de dimensions m = 1.000.000 et n = 50 (scalabilité forte).

| # of processors | 32 | 64 | 128 | 256 |
|---|---|---|---|---|
| 1. TSQR | 690 | 666 | 662 | 610 |
| 2. TSQR with MPI_Reduce | 420 | 411 | 414 | 392 |
| 3. ScaLAPACK Householder QR | 193 | 190 | 206 | 184 |

## Référence

*Computing the R of the QR factorization of tall and skinny matrices using MPI_Reduce, Julien Langou, arXiv:1002.4250v1 [math.NA]*

# Profiling

## Profiler une application parallèle ?

- Pas de notion de temps absolu !
- Système asynchrone !