Programmation Parallèle

Le calcul haute performance
Architecture mémoire distribuée
Paradigme de programmation par passage de messages

Sophie Robert

UFR ST Département info

Modèle de programmation par passage de messages

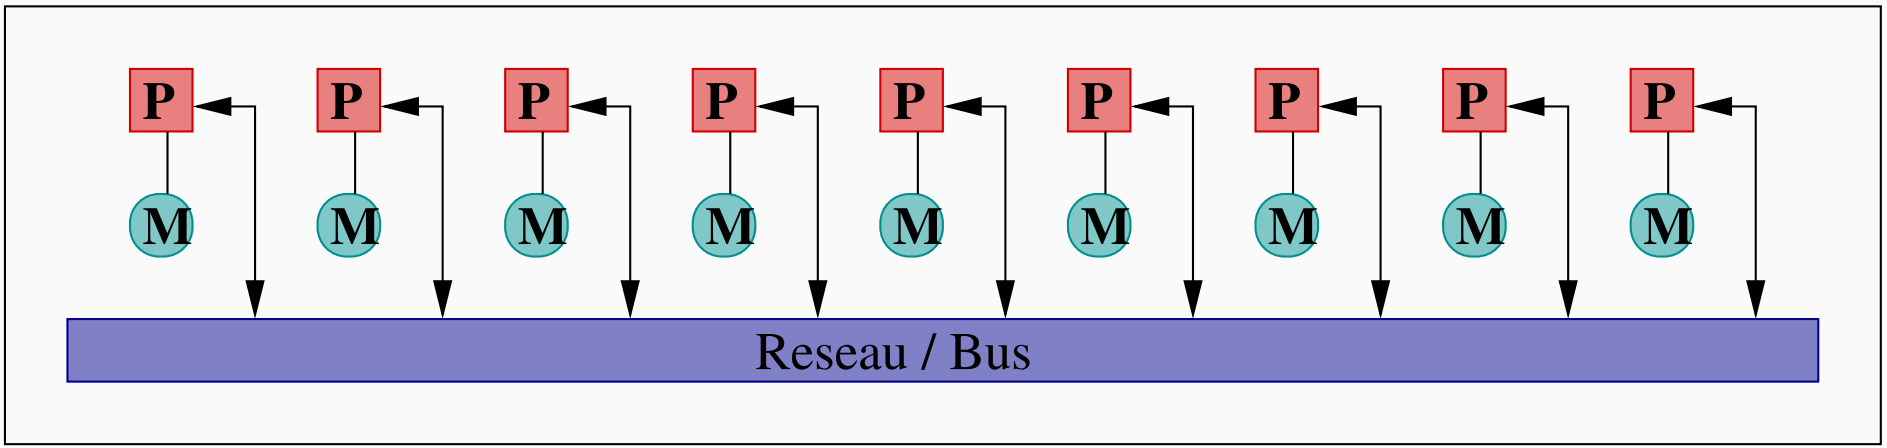

Il nécessite de la parallélisation explicite

- L'utilisateur doit coder le parallélisme dans son programme.
- L'accès aux données doit être exprimé dans le programme.
  - Pour exprimer le rôle de chaque processus dans les phases de lecture ou de lecture/écriture de données distribuées.

Modèle de programmation par passage de messages

asynchrone ou faiblement synchrone

- Il est adapté pour des programmes asynchrones
  * Tous les processus effectuent des tâches concurrentes sans s'occuper des autres participants
- ou **faiblement synchrones**
  * Les étapes de lecture/écriture des données synchronisent les processus mais sinon les tâches s'effectuent de manière asynchrone.

Modèle de programmation par passage de messages

Single Program Multiple Data

Les programmes respectent l'approche SPMD (Single Program Multiple Data) où le plus grand nombre de processus effectue les mêmes tâches sur des données différentes.

- Le programme unique utilise l'identifiant des processus pour différentier les instructions exécutées par chacun.

SPMD exemple

```
\\je connais mon identifiant pid
\\je connais le nombre total de processus nprocs
int a[5] = {0,1,2,3,4};
for (int i=0; i<5; i++)
    a[i]+=pid;
```

Sur 3 processus

P_0

0	1	2	3	4
?	?	?	?	?

P_1

0	1	2	3	4
?	?	?	?	?

P_2

0	1	2	3	4
?	?	?	?	?

SPMD exemple

```
\\je connais mon identifiant pid
\\je connais le nombre total de processus nprocs
int a[5] = {0,1,2,3,4};
if (pid==0)
    for (int i=0; i<5; i++)
        a[i]=0;
else
    for (int i=0; i<5; i++)
        a[i]+=pid;
```

Sur 3 processus

P_0

0	1	2	3	4
?	?	?	?	?

P_1

0	1	2	3	4
?	?	?	?	?

P_2

0	1	2	3	4
?	?	?	?	?

Les échanges de messages

Les opérations Send/Receive

- Les opérations de lecture/écriture nécessitent un moyen d'accéder aux données distribuées.
- La base de ce modèle de programmation s'appuie sur les opérations élémentaires
  * d'envoi de messages : send(void *sendbuf, int size, int dest)
  * de réception de messages : receive(void *recvbuf, int size, int source)

La sémantique des opérations send/recv

La garantie des données 

P0	P1
a=100 send(&a,sizeof(int),1) a=0;	receive(&a,sizeof(int),0) printf("%d",a);

Le processus P1 reçoit 0 ou 100 ?

Les opérations send/receive bloquant

Caractéristiques

- Négociation entre l'émetteur et le récepteur avant la transmission
- Reprise des tâches à la fin de la transmission (fin envoi / fin réception)

Inconvénients

- Un taux d'attente important pour l'émetteur ou le récepteur.
- Des situations d'interblocage entre processus

P0	P1
send(&a,sizeof(int),1) receive(&b,sizeof(int),1)	send(&a,sizeof(int),0) receive(&b, sizeof(int), 0)

Les opérations send/receive bloquant

Déroulement

- Cas symétrique récepteur en avance
- – Temps d'attente -> perte de performances
- \+ Les processus sont équilibrés en charge de travail
- \+ Peut constituer une forme de synchronisation

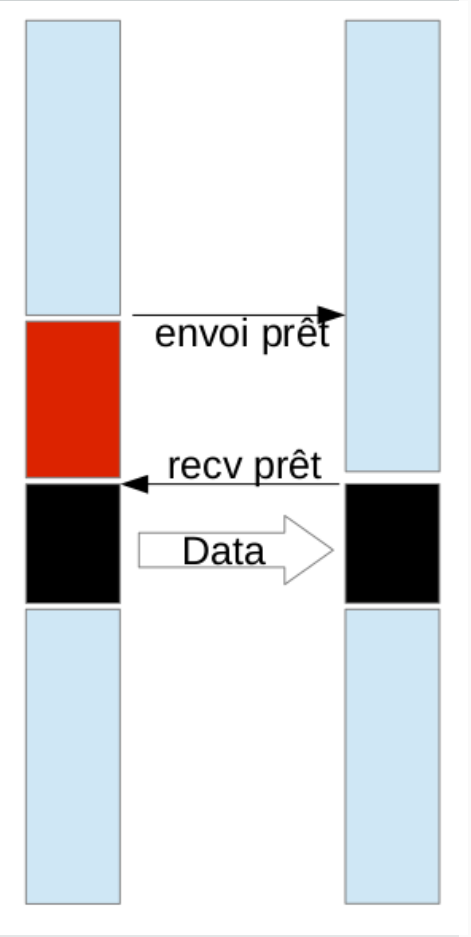

Avec ou sans support hardware

L'interface réseau contient (ou pas)

- un processeur pour réaliser la communication indépendamment du CPU.
- un espace mémoire pour stocker les messages
- un composant DMA (Direct Memory Access) pour lire et écrire directement dans la mémoire centrale

-> **Meilleures performances avec du recouvrement calculs/communications.**

Les opérations send/receive avec bufferisation

Caractéristiques

- L'émetteur et le récepteur disposent d'un buffer pour stocker le message
- Une opération send est décomposée en
  1. une bufferisation du message à transmettre (les données peuvent être modifiées sans altérer la transmission)
  2. un envoi du buffer de manière asynchrone ou non selon le mode de communication sous jacent
- Une opération receive ne copie pas directement le message mais utilise également une bufferisation et
  1. elle vérifie si le buffer contient le message à lire
  2. ou **attend** jusqu'à réception du message dans ce buffer

Les opérations send/receive avec bufferisation

Avec support hardware

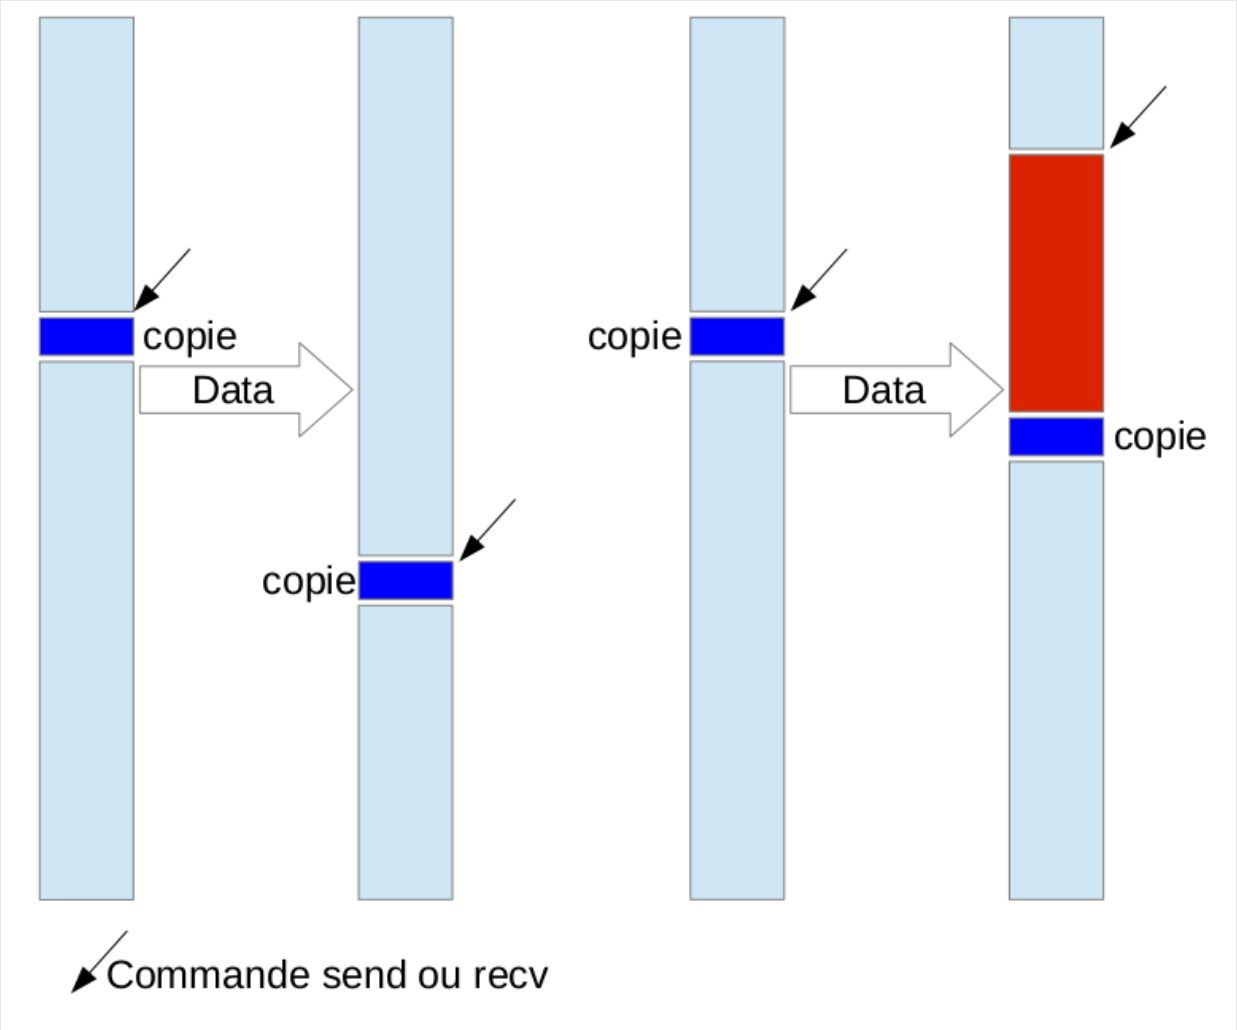

Les opérations send/receive avec bufferisation

Sans support hardware

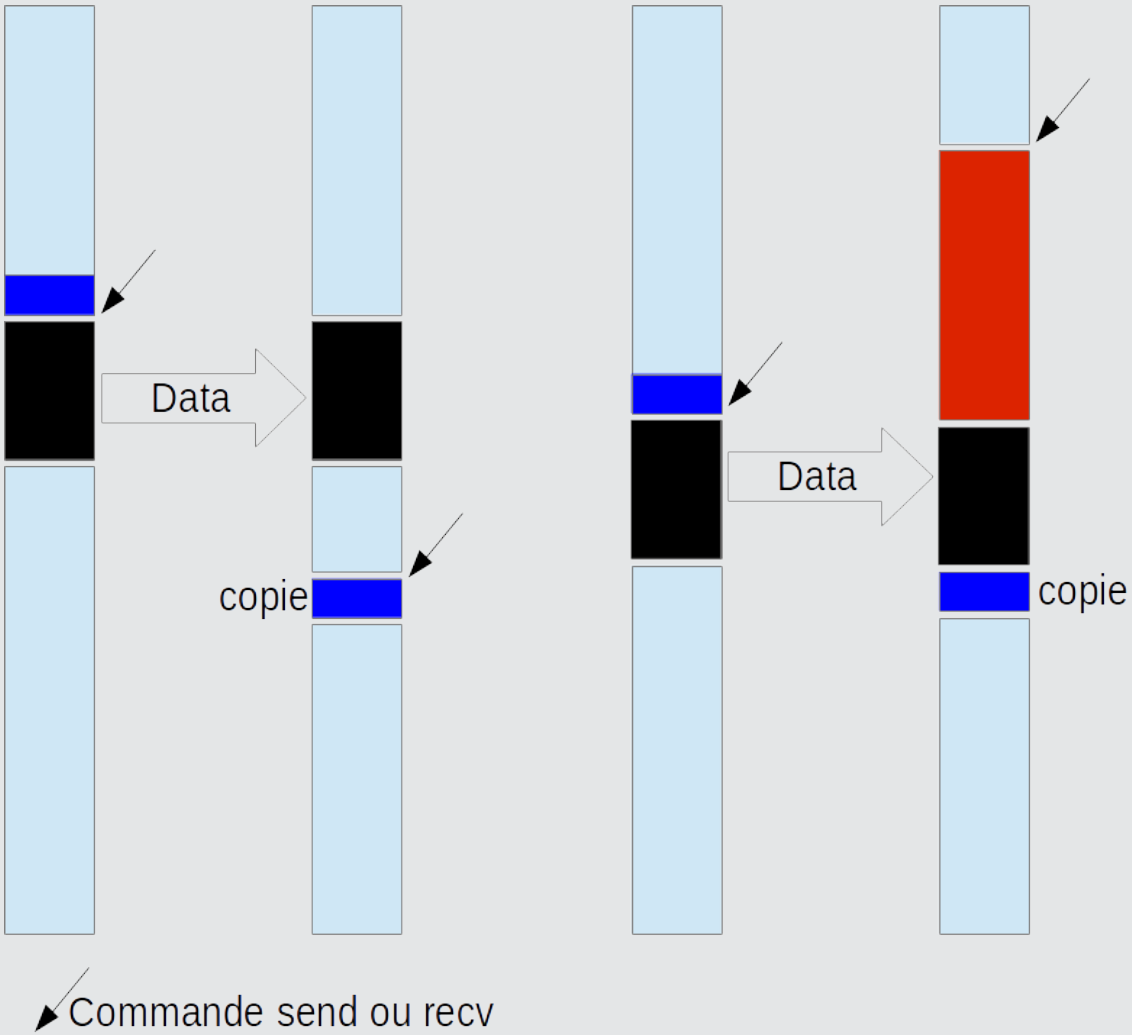

La bufferisation à un côté ?

Du côté émetteur

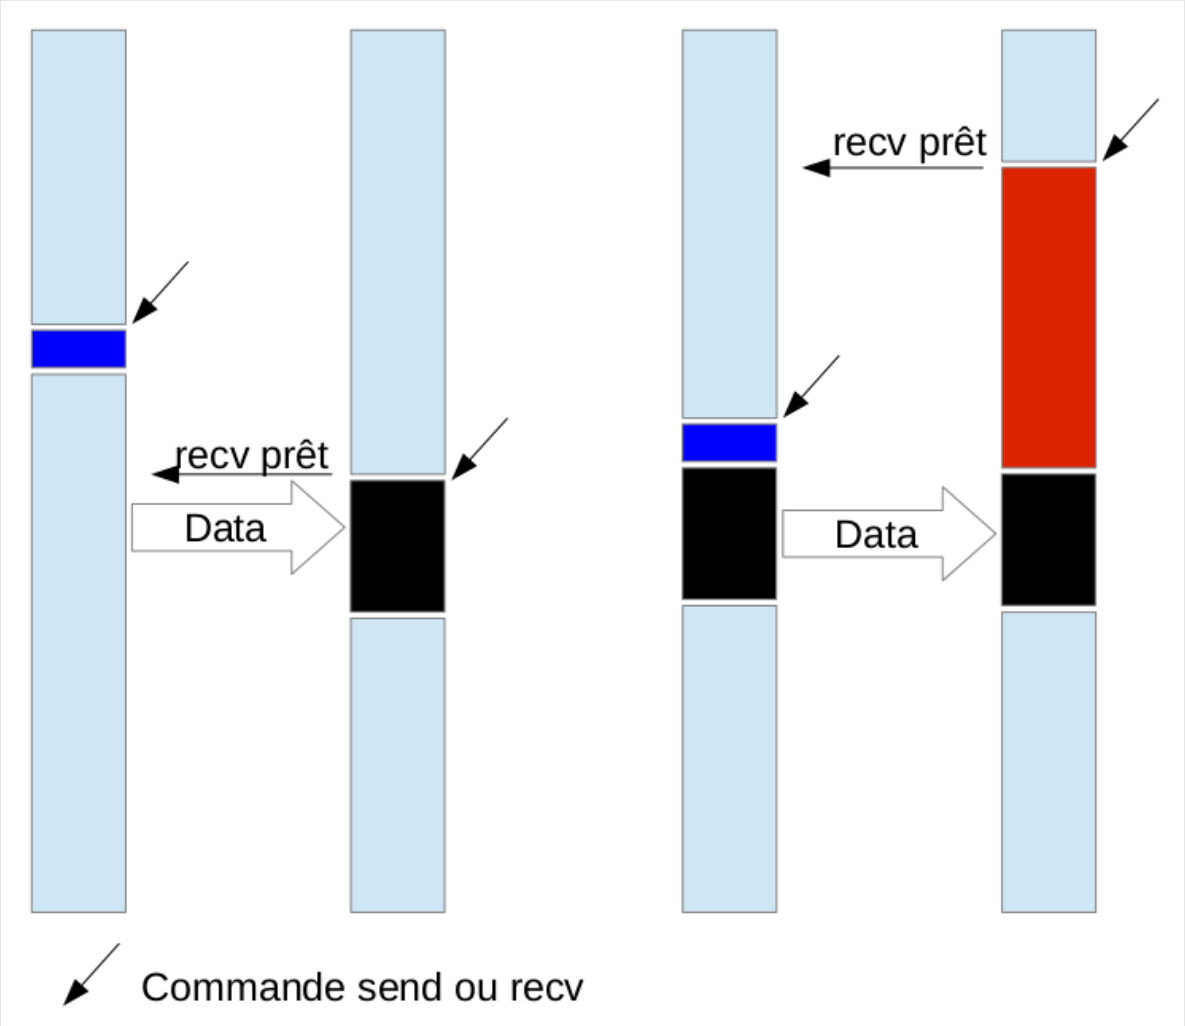

Bufferisation ou pas ?

Avantages/Inconvénients

- La bufferisation peut régler des temps d'attente et certains interblocages.
- Elle génère également un coût supplémentaire
  - compensable par du recouvrement calcul/communication,
- Si la taille des buffers n'est pas suffisante, des coûts supplémentaires d'attente vont diminuer les performances
- Et il reste des cas d'interblocage !!

P0	P1
receive(&a,sizeof(int),1) send(&b,sizeof(int),1)	receive(&a, sizeof(int), 0) send(&b,sizeof(int),0)

Bufferisation ou pas ?

Si le programme est très synchrone

Si les opérations lecture/écriture ont lieu au même moment, on peut se passer du coût de la bufferisation

Les opérations send/receive non bloquant

Altération des données

- Comment gérer la partie où l'altération de la donnée peut modifier le comportement du programme.

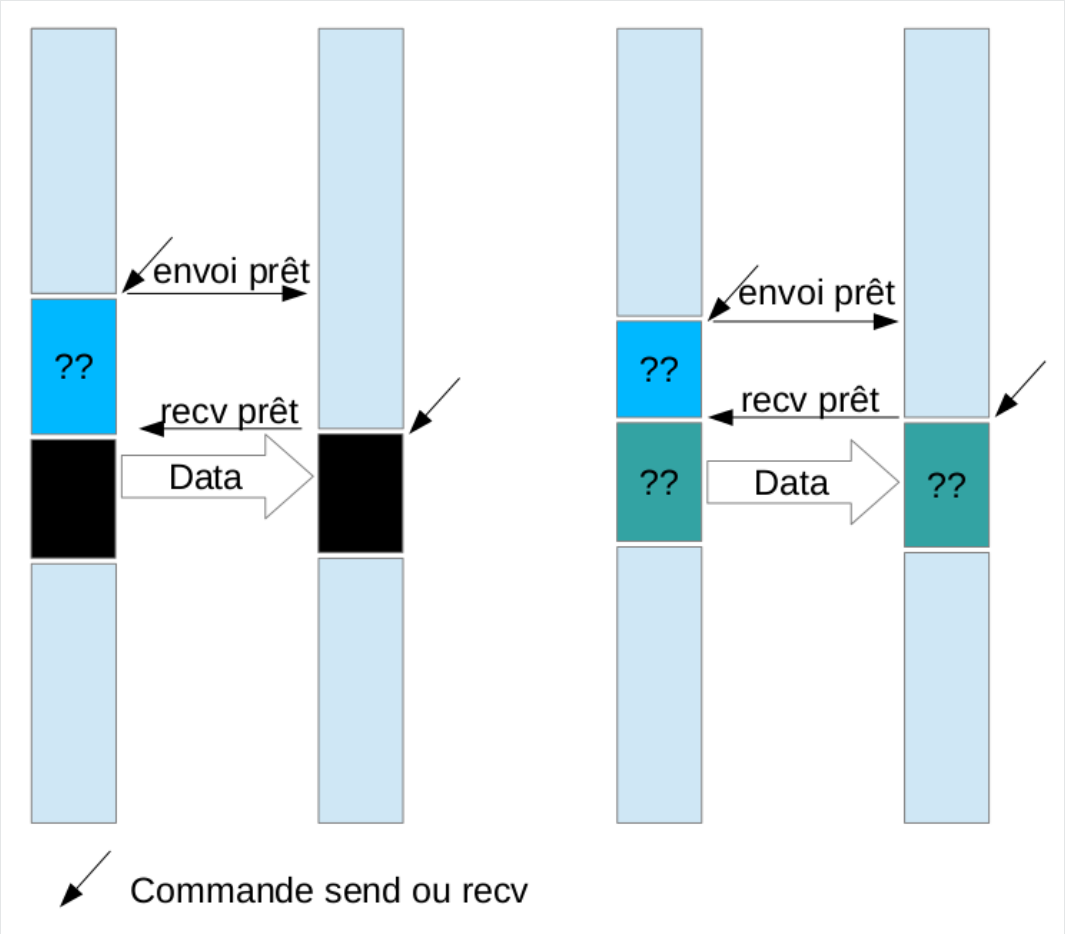

MPI - Message Passing Interface

- MPI est une spécification et un standard
  - Les implémentations de MPI sont fournies sous forme de bibliothèques libres ou commerciales
  - Les deux principales: MPICH2, OpenMPI
- Langages supportés: C/C++, Fortran (python, java, perl ...)

MPI permet de gérer

- l'environnement d'exécution
- les communications point à point (Send, Recv)
- les communications collectives (Bcast, Reduce, Scatter,...)
- les groupes de processus et les communicateurs
- la topologie d'inter-connexion des processus(grilles, arbres,...)

Quelques liens

Distributions

- https://www.open-mpi.org/
- https://www.mpich.org/

Documentation

- https://www.mpi-forum.org/
- https://www-unix.mcs.anl.gov/mpi/tutorial

MPI en C

Fichier mpi.h

Il doit être inclus en entête de tous les programmes MPI.

- Déclaration des prototypes de toutes les routines MPI
- Déclaration de l'ensemble des constantes MPI
- Déclaration de toutes les structures de données

Routines MPI

- Les routines MPI (en C) sont sous deux formes
  1. **MPI_Xxxx()**,
  2. **MPI_Xxxx_xxx()**.

MPI en C

4 routines MPI de base

- pour initialiser et terminer un programme SPMD parallèle
  1. MPI_Init,
  2. MPI_Finalize,
- pour identifier l'équipe de processus
  1. MPI_Comm_size,
  2. MPI_Comm_rank,

MPI sous langage C (2)

La structure d'un programme MPI

```
Inclure le fichier mpi.h

Initialiser l'environnement MPI
    ..........................
    ..........................
    Faire des calculs
    Appeler des routines MPI :
        - communiquer
        - synchroniser
    ..........................
    ..........................
Terminer l'environnement MPI
```

Initialisation et terminaison de MPI

```c
int MPI_Init(int* argc, char*** argv);
```

- C'est la première routine MPI exécutée par tous les processus
- Elle permet de débuter l'exécution parallèle
- Elle permet de diffuser les arguments donnés en ligne de commande
- Elle renvoie MPI_SUCCESS si l'appel n'a eu aucun problème

```c
int MPI_Finalize(void);
```

- Elle termine proprement l'exécution parallèle et doit être appelée par tous les processus

Les domaines de communication

Les communications MPI travaillent dans un communicateur soit un ensemble de processus pouvant communiquer entre eux.

MPI_Init initialise **le communicateur par défaut** MPI_COMM_WORLD qui comprend tous les processus impliqués dans l'exécution parallèle

- Il est possible de construire d'autres communicateurs comme un sous groupe de MPI_COMM_WORLD
- Le type d'un communicateur est `MPI_Comm`

Les domaines de communication

Taille du communicateur et identifiant du processus

```
int MPI_Comm_size(MPI_Comm comm, int* nprocs);
```

- Cette routine retourne dans `nprocs` le nombre total de processus du communicateur `comm`

```
int MPI_Comm_rank(MPI_Comm comm, int* pid);
```

- Cette routine initialise `pid` l'identifiant relatif au communicateur `comm` du processus appelant
- `pid` est un nombre entier unique dans le communicateur `comm`
- Initialement, chaque processus a un identifiant unique $pid \in [0, nprocs - 1]$ dans MPI_COMM_WORLD.

Programme MPI en C

Premier programme

```c
#include <mpi.h>
#include <stdio.h>
int main(int argc, char** argv)
{
  int pid, nprocs;

  MPI_Init(&argc, &argv);
  MPI_Comm_rank(MPI_COMM_WORLD, &pid);
  MPI_Comm_size(MPI_COMM_WORLD, &nprocs);
  printf("Process %d/%d\n", pid, nprocs);
  MPI_Finalize();

  return 0;
}
```

Installation et compilation d'un programme MPI

Installation Ubunbtu - Package

```
$ sudo apt-get install openmpi
                       openmpi-common
                       libopenmpi-dev
```

Compilation habituelle mais avec mpicxx

```
mpicxx -c exemple.c
mpicxx -o exemple exemple.o
```

Exécution en local (sans hostfile)

mpirun pour lancer l'exécution parallèle

```
mpirun -np 4 ./exemple
```

Résultat

```
Process 3/4
Process 0/4
Process 2/4
Process 1/4
```

Exécution sur une machine parallèle

Définir les différents hôtes des processus dans un fichier *hostfile*

```
machine_1 slots=1
machine_2 slots=2
.........
machine_n slots=1
```

Exécution

```
mpirun --hostfile hostfile ./exemple1
```

Résultat sur chaque hôte 

```
Process 3/4
```

MPI : Librairie de fonctions de communications

Les communications

- point-à-point : communications entre 2 processus dans un communicateur
- collectives : communications impliquant tous les processus d'un communicateur.

Conseil

Toujours utiliser les fonctions fournies par MPI. Elles sont souvent plus performantes que des versions "maison".

Communications point-à-point

Modes de communication

- bloquant
- non-bloquant

Types de communication

- standard
- synchrone
- bufferisé
- ready

Résumé

Types/Modes	Bloquant	Non bloquant
Envoi standard	MPI_Send	MPI_Isend
Envoi synchrone	MPI_Ssend	MPI_Issend
Envoi bufferisé	MPI_Bsend	MPI_Ibsend
Envoi ready	MPI_Rsend	MPI_Irsend
Réception	MPI_Recv	MPI_Irecv

Routine de réception bloquante MPI_Recv

```
int MPI_Recv(void *buf, int count, MPI_Datatype dtype,
             int src, int tag, MPI_Comm comm,
             MPI_Status *status)
```

Paramètres

1. void ***buff**: Adresse du tampon de reception
2. int **count**: Nombre d'éléments dans le tampon de données
3. MPI_Datatype **dtype**: Type de chaque élément envoyé
4. int **src**: Identifiant du processus émetteur,
5. int **tag**: Étiquette de message
6. MPI_Comm **comm**: Communicateur,
7. MPI_Status ***status**

Types de données en MPI

Type MPI	Type C
MPI_CHAR	signed char
MPI_SHORT	signed short int
MPI_INT	signed int
MPI_2INT	pair of int
MPI_LONG	signed long int
MPI_UNSIGNED_CHAR	unsigned char
MPI_UNSIGNED_SHORT	unsigned short int
MPI_UNSIGNED	unsigned int
MPI_UNSIGNED_LONG	unsigned long int
MPI_FLOAT	float
MPI_DOUBLE	double
MPI_LONG_DOUBLE	long double
MPI_BYTE	octet par octet

Les étiquettes

- Elles permettent de distinguer les messages au niveau du récepteur pour recevoir les messages dans le bon ordre,
- S'il n'y a pas d'ambiguïté on peut utiliser MPI_ANY_TAG pour accepter tous les messages.

Les informations sur la réception

MPI_Status

- C'est une structure de données pré-définie par MPI,
- Elle nous permet d'obtenir des informations supplémentaires sur le message reçu.
- MPI_STATUS_IGNORE

Structure MPI_Status

```
typedef struct MPI_Status
    {
        int MPI_SOURCE;
        int MPI_TAG;
        int MPI_ERROR;
    };
```

Envoi bloquant standard

Envoi avec la routine MPI_Send

- Deux types de communications sont gérées
  1. Bufferisé
  2. Synchrone
- Le choix automatique dépend de
  - La taille du message à échanger,
  - L'implémentation de MPI.

Réception avec la routine MPI_Recv

La transmission se termine lorsque le message est arrivé

Routine MPI_Send

```
int MPI_Send(void *buf, int count,MPI_Datatype dtype,
    int dest,int tag, MPI_Comm comm);
```

Paramètres

1. void ***buff**: Adresse du tampon de données à envoyer
2. int **count**: Nombre d'éléments dans le tampon de données
3. MPI_Datatype **dtype**: Type de chaque élément envoyé
4. int **dest**: Identifiant du processus de destination
5. int **tag**: Étiquette de message
6. MPI_Comm **comm**: Communicateur

Exemple Send/Recv

$P_0 \rightarrow P_1$

```
int pid, nprocs, i;
int buff[10];
MPI_Comm_rank(MPI_COMM_WORLD, &pid);
MPI_Comm_size(MPI_COMM_WORLD, &nprocs);
.....
.....
if (pid == 0){
  for(i=0;i<10;i++)
    buff[i]=i;
  MPI_Send(buff, 10, MPI_INT, 1, 9, MPI_COMM_WORLD);
}
if (pid ==1)
  MPI_Recv(buff, 10, MPI_INT, 0, 9, MPI_COMM_WORLD,
           MPI_STATUS_IGNORE);
.....
.....
```

Envoi bloquant : Synchrone

Envoi avec la routine MPI_Ssend

- L'émetteur se signale d'abord au récepteur
- Il attend la réponse du récepteur
- Le transfert de données est réalisé
- L'appel de cette routine retourne au programme appelant lorsque le récepteur a bien reçu tout le message

Réception avec la routine MPI_Recv

- Le récepteur répond à l'émetteur
- Il provoque le transfert de données
- L'appel de cette routine retourne au programme appelant lorsque tout le message a bien été reçu

Routine MPI_Ssend

Prototype

```
int MPI_Ssend(void *buf, int count,MPI_Datatype dtype,
    int dest,int tag,MPI_Comm comm);
```

Paramètres

1. void *buf : Adresse initiale du buffer d'envoi
2. int count : Nombre d'éléments envoyés
3. MPI_Datatype dtype : Type de chaque élément envoyé
4. int dest : Identifiant du processus récepteur
5. int tag : Étiquette du message
6. MPI_Comm **comm**: Communicateur

Exemple Send/Recv

$P_0 \rightarrow P_1$

```
int pid, nprocs, i;
int buff[10];
MPI_Comm_rank(MPI_COMM_WORLD, &pid);
MPI_Comm_size(MPI_COMM_WORLD, &nprocs);
.....
.....
if (pid == 0){
  for(i=0;i<10;i++)
    buff[i]=i;
  MPI_Ssend(buff, 10, MPI_INT, 1, 9, MPI_COMM_WORLD);
}
if (pid ==1)
  MPI_Recv(buff, 10, MPI_INT, 0, 9, MPI_COMM_WORLD,
           MPI_STATUS_IGNORE);
.....
.....
```

MPI_Send ou MPI_Ssend 

Conseil

Pour contrôler son programme préférer MPI_Ssend à MPI_Send

Envoi bloquant : bufferisé

Envoi avec la routine MPI_Bsend

- L'émetteur copie d'abord les données dans un buffer local,
- Cette routine retourne immédiatement au programme appelant après la copie des données.

Réception avec la routine MPI_Recv (Pas de MPI_Brecv)

- Le récepteur se signale à l'émetteur
- Il provoque le transfert de données
- Cette routine retourne au programme appelant à la fin du transfert.

Envoi avec la routine MPI_Bsend

Au niveau de l'émetteur

```
MPI_Pack_size(XXX)  //Calcul de la taille du tampon
.....
.....
malloc ou calloc(XXX) //Allocation la memoire du tampon
    .....
    .....
MPI_Buffer_attach(XXX)  //Attachement du tampon
.....
.....
MPI_Bsend(XXX)  //Envoi du message
.....
.....
MPI_Buffer_detach(XXX)  //Detachement du tampon
free(XXX)  //liberation du tampon
.....
```

Association d'un buffer local pour un processus

Calcul de la taille du buffer

1. Taille d'un message MPI_Pack_size
2. Plus le surcoût de taille pour chaque message : MPI_BSEND_OVERHEAD

MPI_Pack_size

```
int MPI_Pack_size(int incount,MPI_Datatype dtype,
    MPI_Comm comm,int *size);
```

1. int incount: Nombre d'éléments du paquet
2. MPI_Datatype dtype: Type en MPI d'un élément
3. MPI_Comm comm : Communicateur
4. int *size: La taille du message en octets

Attacher le buffer: Routine MPI_Buffer_attach

Prototype

```
int MPI_Buffer_attach(void *buffer, int size);
```

1. void *buffer: Adresse du tampon à attacher
2. int size: Taille du tampon en octets

- Cette routine fournit au système un tampon afin de copier le message avant son envoi
- Le tampon est utilisé uniquement par les messages envoyés par MPI_Bsend
- Un seul tampon peut être attaché à un processus à la fois

Réception avec la routine MPI_Bsend

Prototype

```
int MPI_Bsend(void *buf, int count,MPI_Datatype dtype,
    int dest,int tag,MPI_Comm comm);
```

Paramètres

1. void *buf: Adresse du tampon d'envoi
2. int count: Nombre d'éléments à envoyer dans le tampon
3. MPI_Datatype dtype : Type de chaque élément envoyé
4. int dest: Identifiant du processus récepteur
5. int tag: Étiquette du message
6. MPI_Comm comm: Communicateur

Détacher un buffer: Routine MPI_Buffer_Detach

Prototype

```
int MPI_Buffer_detach(void *buffer, int *size);
```

Paramètres

1. void *buffer: Adresse du tampon à détacher
2. int *size: Taille du tampon en octets

- Cette routine détache le tampon actuel associé à MPI_Bsend
- L'appel à cette routine permet de bloquer le programme appelant jusqu'à ce que tous les messages dans ce tampon aient été transmis.
- L'utilisateur peut réutiliser ou désallouer l'espace occupé par le tampon

Envoi bloquant : bufferisé

Conclusion

- Ce mode est parfois plus efficace
- Mais il reste des situations de blocage 
- et attention aux temps de recopies 

Exemple 1

Schéma de communications

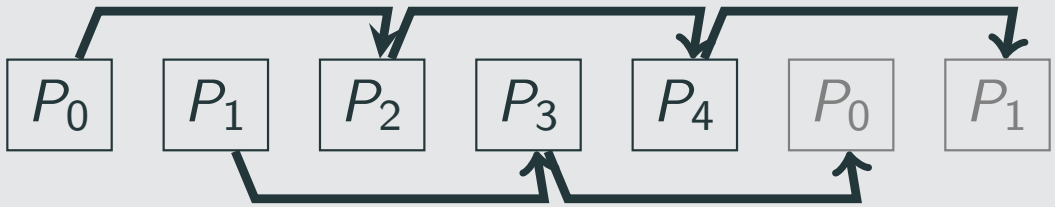

Exemple 1

```
int size_tab = atoi(argv[1]);
int* tab = new int[size_tab];
for (int i=0; i<size_tab; i++)
    tab[i] = i+pid;
int size = size_tab;
MPI_Pack_size(size_tab,MPI_INT,MPI_COMM_WORLD,&size);
size += MPI_BSEND_OVERHEAD;
int *buffer = new int[size];
MPI_Buffer_attach(buffer, size);
int to = (pid + 2) % nprocs;
int from = ((pid - 2) + nprocs) % nprocs;
MPI_Bsend(tab, size_tab, MPI_INT, to, 34,
  MPI_COMM_WORLD);
MPI_Recv(tab, size_tab, MPI_INT, from, 34,
  MPI_COMM_WORLD, &status);
MPI_Buffer_detach(buffer, &size);
```

Exemple 2

Distribution d'un tableau

Un processus accède à un ensemble de *nglobal* entiers (calcul, lecture fichier, etc) et souhaite les distribuer à l'ensemble des processus de MPI_COMM_WORLD ?

Par exemple

$$nglobal = 20$$

$$nlocal = ?$$

avec *nglobal* non divisible par le nombre de processus ($nprocs = 6$).

Combinaison de l'envoi et la réception

Routine MPI_Sendrecv

- L'échange combine :
  - l'envoi d'un message vers un processus
  - la réception d'un message venant du même processus ou d'un autre
- Les buffers et les types peuvent être différents
- C'est une routine très utile pour des opérations dans une chaîne de processus
- Elle est pratique et efficace

Routine MPI_Sendrecv_replace

- Le même buffer est utilisé pour l'envoi et la réception,
- L'implémentation gère le stockage intermédiaire additionnel

Routine MPI_Sendrecv

Prototype

```
int MPI_Sendrecv(void *sendbuf, int sendcount,
    MPI_Datatype sendtype,int dest,int sendtag,void *
    recvbuf,int recvcount,MPI_Datatype recvtype,int
    source,int recvtag,MPI_Comm comm,MPI_Status *status
    )
```

Paramètres

1. void *sendbuf : Adresse du tampon d'envoi
2. int sendcount : Nombre d'éléments envoyés
3. MPI_Datatype sendtype : Type de chaque élément envoyé
4. int dest : Identifiant du processus récepteur
5. int sendtag : Étiquette du message envoyé

Routine MPI_Sendrecv

Paramètres

6. void *recvbuf : Adresse initiale du tampon de réception
7. int recvcount : Nombre d'éléments de réception
8. MPI_Datatype recvtype, Type de chaque élément de réception
9. int source : Identifiant du processus émetteur
10. int recvtag : Étiquette du message de réception
11. MPI_Comm comm : Communicateur
12. MPI_Status *status : État du message de réception

Routine : MPI_Sendrecv

Exemple

- Chaque processus a deux buffers:
  1. `buffer1` pour l'envoi
  2. `buffer2` pour la réception
- Le processus d'identifiant `i`
  1. envoie les données du `buffer1` au processus `i-1`
  2. reçoit les données du processus `i+1`, et les met dans `buffer2`.

Routine : MPI_Sendrecv

Extrait du code

```
MPI_Comm_size(MPI_COMM_WORLD, &nprocs);
MPI_Comm_rank(MPI_COMM_WORLD, &pid);

to = (pid + 2) % numprocs;
from = (pid - 2 + numprocs) % numprocs;

MPI_Sendrecv(buffer1, 10, MPI_INT, to, 123, buffer2,
    10, MPI_INT, from, 123,
                MPI_COMM_WORLD, &status);
```

Routine MPI_Sendrecv_replace

Prototype

```
int MPI_Sendrecv_replace(void *buf, int count,
                         MPI_Datatype datatype,
                         int dest,int sendtag,
                         int source,int recvtag,
                         MPI_Comm comm,
                         MPI_Status *status)
```

Paramètres

1. void *buf : Adresse initiale du tampon d'envoi et de réception
2. int count : Nombre d'éléments envoyés et de réception
3. MPI_Datatype datatype : Type de chaque élément

Routine MPI_Sendrecv_replace

Prototype

```
int MPI_Sendrecv_replace(void *buf, int count,
                         MPI_Datatype datatype,
                         int dest,int sendtag,
                         int source,int recvtag,
                         MPI_Comm comm,
                         MPI_Status *status)
```

Paramètres

4. int dest : Identifiant de processus récepteur
5. int sendtag : Étiquette du message envoyé
6. int source : Identifiant du processus émetteur

Routine MPI_Sendrecv_replace

Prototype

```
int MPI_Sendrecv_replace(void *buf, int count,
                         MPI_Datatype datatype,
                         int dest,int sendtag,
                         int source,int recvtag,
                         MPI_Comm comm,
                         MPI_Status *status)
```

Paramètres

7. int recvtag : Étiquette du message de réception
8. MPI_Comm comm : Communicateur
9. MPI_Status *status : État du message de réception

Exemple 1 : nouvelle version

Extrait du code

```
// tab un tableau de n entiers sur chaque processus
MPI_Comm_size(MPI_COMM_WORLD, &nprocs);
MPI_Comm_rank(MPI_COMM_WORLD, &pid);

to = (pid + 2) % nprocs;
from = (pid - 2 + nprocs) % nprocs;

MPI_Sendrecv_replace(tab, 10, MPI_INT,
                     to, 123,
                     from, 123,
                     MPI_COMM_WORLD, &status);
```

Communication non-bloquante

 Une communication non bloquante rend la main avant que la communication ne soit terminée. Il faut être très prudent dans son utilisation mais elle peut permettre d'optimiser son programme.

Principe

- Ce type de communications est moins coûteux (pas de messages au préalable, moins de synchronisation)
- Il faut utiliser du recouvrement calcul communication avant de modifier la donnée
  1. Initier la communication non-bloquante dès que la donnée à envoyer est disponible
  2. Lancer des calculs n'ayant pas besoin de cette donnée
  3. Vérifier l'état de la communication avant d'accéder à la donnée

Communications non-bloquantes

Type de communication

- standard : MPI_Isend - MPI_Irecv
- synchrone : MPI_Issend - MPI_Irecv
- bufférisation: MPI_Ibsend - MPI_Irecv
- ready : MPI_Irsend - MPI_Irecv

L'utilisateur doit lui-même s'assurer que

Le message a bien été envoyé ou reçu avec

- MPI_Test pour tester si l'opération de communication est terminée
- MPI_Wait pour attendre que l'opération de communication se termine

Le mode non-bloquant Standard ou Synchrone

Envoi par MPI_Isend/MPI_Issend Réception par MPI_Irecv

- Le processus émetteur (resp. récepteur)
  - initialise l'opération d'envoi (resp. de réception)
  - mais rend la main avant sa réalisation
- L'appel sera terminé avant que le message ne soit parti (resp. reçu)
- Après l'initialisation et avant l'envoi (resp. avant la réception), d'autres calculs peuvent être faits

MPI_Irecv

Prototype

```
int MPI_Irecv(void *buf, int count,
              MPI_Datatype datatype,
              int source,int tag,
              MPI_Comm comm, MPI_Request *request)
```

Paramètres

1. void ***buff**: Adresse initiale du tampon de données
2. int **count**: Nombre d'éléments dans le tampon de données
3. MPI_Datatype **datatype**: Type de chaque élément envoyé
4. int **src**: Identifiant du processus émetteur
5. int **tag**: Étiquette de message
6. MPI_Comm **comm**: Communicateur
7. MPI_Request ***request**: Requête de communication

Envoi non-bloquant standard MPI_Isend

Prototype

```
int MPI_Isend(void *buf, int count,
              MPI_Datatype datatype,int dest, int tag,
              MPI_Comm comm, MPI_Request *request)
```

Paramètres

1. void ***buff**: Adresse initiale du tampon de données,
2. int **count**: Nombre d'éléments dans le tampon de données,
3. MPI_Datatype **datatype**: Type de chaque élément envoyé,
4. int **dest**: Identifiant du processus de destination,
5. int **tag**: Étiquette de message,
6. MPI_Comm **comm**: Communicateur
7. MPI_Request *request : Requête de communication

Envoi non-bloquant synchrone MPI_Issend

Prototype

```
int MPI_Issend(void *buf, int count,
               MPI_Datatype datatype,
               int dest, int tag,
               MPI_Comm comm, MPI_Request *request)
```

Principe

Aucune bufferisation et on ne doit modifier la donnée que lorsqu'elle a été envoyée entièrement.

Envoi non-bloquant bufferisé MPI_Ibsend

Prototype

```
int MPI_Ibsend(void *buf, int count,
               MPI_Datatype datatype,
               int dest, int tag,
               MPI_Comm comm, MPI_Request *request)
```

Principe

Le buffer n'est pas géré par l'utilisateur. On peut modifier la donnée dès la fin de la bufferisation.

MPI_Isend : MPI_Issend ou MPI_Ibsend

Que signifie Standard ?

Bufferisation ou pas et c'est le choix de l'implémentation

Les routines de complétion

Test

- MPI_Test
- MPI_Testall
- MPI_Testany

Attente

- MPI_Wait
- MPI_Waitall
- MPI_Waitany

Routine MPI_Test

Prototype

```
int MPI_Test(MPI_Request *req,
             int *flag, MPI_Status *status)
```

Principe

- Elle vérifie l'achèvement d'une opération associée à `request`
- Elle donne flag=true si l'opération (send/recv) identifiée par `request` est terminée
- `request` est alors libérée et mis à MPI_REQUEST_NULL
- `status` contient des informations sur l'opération terminée

Une parmi plusieurs ou toutes

```
int MPI_Testany(int count, MPI_Request *array_of_req,
                int *index, int *flag, MPI_Status *status)
```

```
int MPI_Testall(int count, MPI_Request *array_of_req,
                int *flag, MPI_Status *array_of_status)
```

Routine MPI_Test

```
.....................................
.....................................
MPI_Irecv(buffer, 10, MPI_INT,
          left, 123, MPI_COMM_WORLD,
          &request);

MPI_Test(&request, &flag, &status);
while (!flag)
{
    /* Do some work ... */
    .....................................
    .....................................
    MPI_Test(&request, &flag, &status);
}
.....................................
.....................................
```

Routine MPI_Wait

Prototype

```
int MPI_Wait(MPI_Request *request, MPI_Status *status)
```

Principe

- Cette routine retourne au programme appelant lorsque l'opération identifiée par `request` est complète.
- `request` est alors libérée et mis à MPI_REQUEST_NULL par cet appel.
- `status` contient des informations sur la communication lorsque l'opération est terminée

Au moins une ou toutes

```
int MPI_Waitany(int count, MPI_Request *array_of_req,
    int *index, MPI_Status *status)
```

```
int MPI_Waitall(int count, MPI_Request *array_of_req,
    MPI_Status *array_of_status)
```

Routine MPI_Wait

Utilisation de MPI_Wait

```
.....................................
.....................................
MPI_Irecv(buffer, 10, MPI_INT,
          left, 123, MPI_COMM_WORLD,
          &request);
/* Do some work ... */
.....................................
MPI_Wait(&request, &status);
/* Do some work ... */
.....................................
```

Routine MPI_Waitall

Utilisation de MPI_Wait

```
.....
.....
MPI_Irecv(buffer, 10, MPI_INT,
          left, 123, MPI_COMM_WORLD,
          request);
MPI_Isend(buffer2, 10, MPI_INT,
          right, 123, MPI_COMM_WORLD,
          request+1);
.....
.....
MPI_Waitall(2,request, status);
.....
.....
```