

Introduction à MPI

Message Passing Interface

Christophe PERA

Informatique scientifique pour le calcul
Ecole doctorale 2012/2013


Basé sur les cours de l'IDRIS
[http : //www.idris.fr/data/cours/parallel/mpi/](http://www.idris.fr/data/cours/parallel/mpi/)

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 Environnement
 - Description
 - Exemple
- 3 Communications point à point
 - Notions
 - Différent types de transfert/communication point à point
 - Types de données de base
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées
- 6 Conclusion


Lignes directrices

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 Environnement
 - Description
 - Exemple
- 3 Communications point à point
 - Notions
 - Différent types de transfert/communication point à point
 - Types de données de base
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées

- Le modèle de programmation séquentiel :
 - le programme est exécuté par un et un seul processus ;
 - toutes les variables et constantes du programme sont allouées dans la mémoire allouée au processus ;
 - un processus s'exécute sur un processeur physique de la machine .




- Dans le modèle de programmation par échange de messages :
 - le programme est écrit dans un langage classique (Fortran , C , C++ , python, ...) ;
 - chaque processus exécute éventuellement des parties différentes d'un programme ;
 - toutes les variables du programme sont privées et résident dans la mémoire locale allouée à chaque processus ;
 - une donnée est échangée entre deux ou plusieurs processus via un appel, dans le programme, à des sous-programmes particuliers.



- Le modèle d'exécution SPMD :

- Single Program , Multiple Data ;
- le même programme est exécuté par tous les processus ;
- toutes les machines supportent ce modèle de programmation et certaines ne supportent que celui-là ;
- c'est un cas particulier du modèle plus général MPMD (Multiple Program , Multiple Data), qu'il peut d'ailleurs émuler.



Lignes directrices

1 Introduction

- Définitions
- L'échange de message
- Historique

2 Environnement

- Description
- Exemple

3 Communications point à point


- Notions
- Différent types de transfert/communication point à point
- Types de données de base

4 Communications collectives

- notions
- Cas particulier des réductions

5 Types de données dérivées

- Si un message est envoyé à un processus, celui-ci doit ensuite le recevoir



- Un message est constitué de paquets de données transitant du processus émetteur au(x) processus récepteur(s)
- En plus des données (variables scalaires, tableaux, etc.) à transmettre, un message doit contenir les informations suivantes :
 - l'identificateur du processus émetteur ;
 - le type de la donnée ;
 - sa longueur ;
 - l'identificateur du processus récepteur.




FIGURE 5 – Constitution d'un message

- Les messages échangés sont interprétés et gérés par un environnement qui peut être comparé à la téléphonie, à la télécopie, au courrier postal, à la messagerie électronique, etc.
- Le message est envoyé à une adresse déterminée Le processus récepteur doit pouvoir classer et interpréter les messages qui lui ont été adressés.
- L'environnement en question est MPI (Message Passing Interface).
- Une application MPI est un ensemble de processus autonomes exécutant chacun leur propre code et communiquant via des appels à des sous-programmes de la bibliothèque MPI.

Lignes directrices

1 Introduction

- Définitions
- L'échange de message
- Historique

2 Environnement

- Description
- Exemple

3 Communications point à point

- Notions
- Différent types de transfert/communication point à point
- Types de données de base

4 Communications collectives

- notions
- Cas particulier des réductions

5 Types de données dérivées

- Version 1.0 : en juin 1994, le forum MPI (Message Passing Interface Forum), avec la participation d'une quarantaine d'organisations, abouti à la définition d'un ensemble de sous-programmes concernant la bibliothèque d'échanges de messages MPI.
- Version 1.1 : juin 1995, avec seulement des changements mineurs.
- Version 1.2 : en 1997, avec des changements mineurs pour une meilleure cohérence des dénominations de certains sous-programmes.
- Version 1.3 : septembre 2008, avec des clarifications dans MPI 1.2, en fonction des clarifications elles-mêmes apportées par MPI-2.1.
- Version 2.0 : apparue en juillet 1997, cette version apportait des compléments essentiels volontairement non intégrés dans MPI 1.0 (gestion dynamique de processus, copies mémoire à mémoire, entrées-sorties parallèles, etc.).
- Version 2.1 : juin 2008, avec seulement des clarifications dans MPI 2.0 mais aucun changement.
- Version 2.2 : septembre 2009, avec seulement de « petites » additions.

- Version 3.0

- changements et ajouts importants par rapport à la version 2.2 ;
- pour un meilleur support des applications actuelles et futures, notamment sur les machines massivement parallèles et many cores ;
- principaux changements actuellement envisagés :
 - communications collectives non bloquantes ;
 - révision de l'implémentation des copies mémoire à mémoire ;
 - tolérance aux pannes ;
 - Fortran (2003-2008) bindings ;
 - interfaçage d'outils externes (pour le débogage et les mesures de performance) ;
- voir :
 - http://meetings.mpi-forum.org/MPI_3.0_main_page.php.
 - <https://svn.mpi-forum.org/trac/mpi-forum-web/wiki>.

Lignes directrices

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 **Environnement**
 - Description
 - Exemple
- 3 Communications point à point
 - Notions
 - Différent types de transfert/communication point à point
 - Types de données de base
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées

- Environnement MPI Linux langage C/C++
 - openmpi.
 - mpich.
 - lam.
- Environnement MPI python
 - mpi4py.
 - pypmi.


OpenMPI

- Standard MPI version 2, une partie de la version 3.
- Thread safe.
- Gestion dynamique des processus.
- Tolérance aux pannes réseau et système.
- Multiplateformes.

MPI4PY

- Projet initié en 2006 par Lissandro Dalcin.
- Interfaçage de la bibliothèque MPI-1/2 avec Swig (version < 1).
- Interfaçage de la bibliothèque MPI-1/2 avec Cython (version ≥ 1).
- Ce module gère toutes les fonctionnalités que l'on peut trouver dans MPI-1/2.

- Toutes les opérations effectuées par MPI portent sur des communicateurs. Le communicateur par défaut est `MPI_COMM_WORLD` qui comprend tous les processus actifs.



- On peut connaître le nombre de processus gérés par un communicateur donné par le sous-programme `MPI_COMM_SIZE()` et `MPI_COMM_RANK()` permet d'obtenir le rang d'un processus (i.e. son numéro d'instance, qui est un nombre compris entre 0 et la valeur renvoyée par `MPI_COMM_SIZE() - 1`) :

```
#include <stdio.h>
#include "mpi.h"
main(int argc, char *argv[])
{
    int my_rank; /* Rang du processus */
    int p; /* Nombre de processus */
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &my_rank);
    MPI_Comm_size(MPI_COMM_WORLD, &p);
    MPI_Finalize();
} /* main */
```

```
from mpi4py import MPI
# MPI Init
comm = MPI.COMM_WORLD # mon communicateur
mpi_size = comm.Get_size() # le nombre de processus
mpi_rank = comm.Get_rank() # le rang du processus
#
print "Process %d of %d on %s\n" %(mpi_rank, mpi_size, mpi_name)
```

Lignes directrices


- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 **Environnement**
 - Description
 - **Exemple**
- 3 Communications point à point
 - Notions
 - Différent types de transfert/communication point à point
 - Types de données de base
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées

- Exemple C
- Exemple python

Lignes directrices

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 Environnement
 - Description
 - Exemple
- 3 **Communications point à point**
 - **Notions**
 - Différent types de transfert/communication point à point
 - Types de données de base
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées

- Une communication dite point à point a lieu entre deux processus, l'un appelé processus émetteur et l'autre processus récepteur (ou destinataire).



- L'émetteur et le récepteur sont identifiés par leur rang dans le communicateur.
- Ce que l'on appelle l'enveloppe d'un message est constituée :
 - 1 du rang du processus émetteur ;
 - 2 du rang du processus récepteur ;
 - 3 de l'étiquette (tag) du message ;
 - 4 du communicateur qui définit le groupe de processus et le contexte de communication.
- Les données échangées sont typées (entiers, réels, etc ou types dérivés personnels).
- Il existe dans chaque cas plusieurs modes de transfert, faisant appel à des protocoles différents.

Lignes directrices

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 Environnement
 - Description
 - Exemple
- 3 **Communications point à point**
 - Notions
 - **Différent types de transfert/communication point à point**
 - Types de données de base
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées

- Fonctions d'envoi/réception de messages standard :
MPI_Send / MPI_Recv
 - Utile pour les envois de message de base.
 - Fonction d'envoi bloquante (le retour de l'appel n'est fait que lorsque l'espace mémoire des données est disponible).
- Fonctions non bloquante
 - Initialisent l'envoi / la réception des données et retourne une valeur 'status' immédiatement, on peut ensuite interroger ou attendre la réalisation des opérations.
 - L'espace mémoire des données n'est pas 'accessible' tant que les opérations ne sont pas finies.
 - MPI_Probe() or MPI_Wait() renvoie les infos sur l'état de l'échange non bloquant.
- Fonction d'échange 'Synchronous' et 'Buffered' ...

```
#include "mpi.h"
#include <stdio.h>

int main(argc,argv){
    int numtasks, rank, dest, source, rc, count, tag=1;
    char inmsg, outmsg='x';
    MPI_Status Stat;
    MPI_Init(&argc,&argv);
    MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    if (rank == 0) {
        dest = 1;
        source = 1;
        rc = MPI_Send(&outmsg, 1, MPI_CHAR, dest, tag, MPI_COMM_WORLD);
        rc = MPI_Recv(&inmsg, 1, MPI_CHAR, source, tag, MPI_COMM_WORLD, &
            Stat);
    } else if (rank == 1) {
        dest = 0;
        source = 0;
        rc = MPI_Recv(&inmsg, 1, MPI_CHAR, source, tag, MPI_COMM_WORLD, &
            Stat);
        rc = MPI_Send(&outmsg, 1, MPI_CHAR, dest, tag, MPI_COMM_WORLD);
    }

    rc = MPI_Get_count(&Stat, MPI_CHAR, &count);
    printf("Task %d : Received %d char(s) from task %d with tag %d\n",
        rank, count, Stat.MPI_SOURCE, Stat.MPI_TAG);
    MPI_Finalize();
}
```

```
from mpi4py import MPI
comm = MPI.COMM_WORLD
rank = comm.Get_rank()
if rank == 0:
    data = {'a':7, 'b':3.14}
    comm.send(data, dest=1, tag=11)
    print "Message sent, data is:", data
elif rank == 1:
    data = comm.recv(source=0, tag=11)
    print "Message Received, data is:", data
```

Lignes directrices

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 Environnement
 - Description
 - Exemple
- 3 **Communications point à point**
 - Notions
 - Différent types de transfert/communication point à point
 - **Types de données de base**
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées

Types C

Types MPI	Type C
MPI_CHAR	signed char
MPI_SHORT	signed short
MPI_INT	signed int
MPI_LONG	signed long int
MPI_UNSIGNED_CHAR	unsigned char
MPI_UNSIGNED_SHORT	unsigned short
MPI_UNSIGNED	unsigned int
MPI_UNSIGNED_LONG	unsigned long int
MPI_FLOAT	float
MPI_DOUBLE	double
MPI_LONG_DOUBLE	long double

Type python

- Classe Datatype dans le module mpi4py.
- Politique de type implicite python 'mappé' de manière transparente en mpi avec le module numpy !
- Dépend de l'implémentation mpi wrappé sur le système (openmpi/C, openmpi/fortran, mpich/C,...).

Types MPI	type python
MPI.BOOL	bool
MPI.CHAR	char
MPI.FLOAT	float
MPI.INT	int
MPI.DOUBLE	double

```
from mpi4py import MPI
import numpy









comm = MPI.COMM_WORLD
rank = comm.Get_rank()
# pass explicit MPI datatypes
if rank == 0:
    data = numpy.arange(1000, dtype='i')
    comm.Send([data, MPI.INT], dest=1, tag=77)
elif rank == 1:
    data = numpy.empty(1000, dtype='i')
    comm.Recv([data, MPI.INT], source=0, tag=77)
# automatic MPI datatype discovery
if rank == 0:
    data = numpy.arange(100, dtype=numpy.float64)
    comm.Send(data, dest=1, tag=13)
elif rank == 1:
    data = numpy.empty(100, dtype=numpy.float64)
    comm.Recv(data, source=0, tag=13)
```

Lignes directrices

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 Environnement
 - Description
 - Exemple
- 3 Communications point à point
 - Notions
 - Différent types de transfert/communication point à point
 - Types de données de base
- 4 **Communications collectives**
 - **notions**
 - Cas particulier des réductions
- 5 Types de données dérivées

- Les communications collectives permettent de faire en une seule opération une série de communications point à point.
- Une communication collective concerne toujours tous les processus du communicateur indiqué.
- Pour chacun des processus, l'appel se termine lorsque la participation de celui-ci à l'opération collective est achevée, au sens des communications point-à-point (donc quand la zone mémoire concernée peut être modifiée).
- Il est inutile d'ajouter une synchronisation globale (barrière) après une opération collective.
- La gestion des étiquettes dans ces communications est transparente et à la charge du système. Elles ne sont donc jamais définies explicitement lors de l'appel à ces sous-programmes. Cela a entre autres pour avantage que les communications collectives n'interfèrent jamais avec les communications point à point.

- Il y a trois types de sous-programmes (fonctions) :
 - ❶ celui qui assure les synchronisations globales : `MPI_BARRIER()`.
 - ❷ ceux qui ne font que transférer des données :
 - diffusion globale de données : `MPI_BCAST()` ;
 - diffusion sélective de données : `MPI_SCATTER()` ;
 - collecte de données réparties : `MPI_GATHER()` ;
 - collecte par tous les processus de données réparties : `MPI_ALLGATHER()` ;
 - diffusion sélective, par tous les processus, de données réparties : `MPI_ALLTOALL()`.
 - ❸ ceux qui, en plus de la gestion des communications, effectuent des opérations sur les données transférées :
 - opérations de réduction (somme, produit, maximum, minimum, etc.), qu'elles soient d'un type prédéfini ou d'un type personnel : `MPI_REDUCE()` ;
 - opérations de réduction avec diffusion du résultat (équivalent à un `MPI_REDUCE()` suivi d'un `MPI_BCAST()`) : `MPI_ALLREDUCE()`.



exemple bcast C

```
#include <stdio.h>
#include <stdlib.h>
#include <mpi.h>
#include <math.h>
int main( argc , argv ){
    int i , myid , numprocs , source , count ;
    int buffer [ 4 ] ;
    MPI_Status status ; MPI_Request request ;

    MPI_Init( &argc , &argv ) ;
    MPI_Comm_size( MPI_COMM_WORLD , &numprocs ) ;
    MPI_Comm_rank( MPI_COMM_WORLD , &myid ) ;
    source = 0 ; count = 4 ;
    if ( myid == source ){
        for ( i = 0 ; i < count ; i ++ )
            buffer [ i ] = i ;
    }
    MPI_Bcast( buffer , count , MPI_INT , source , MPI_COMM_WORLD ) ;
    for ( i = 0 ; i < count ; i ++ )
        printf ( "%d_\n" , buffer [ i ] ) ;
    printf ( "\n" ) ;
    MPI_Finalize ( ) ;
}
```

exemple bcast python

```
from mpi4py import MPI

comm = MPI.COMM_WORLD
rank = comm.Get_rank()

if rank == 0:
    data = { 'key1' : [7, 2.72, 2+3j],
             'key2' : ( 'abc', 'xyz' ) }
else:
    data = None
data = comm.bcast(data, root=0)
```

Lignes directrices

- 1 Introduction
 - Définitions
 - L'échange de message
 - Historique
- 2 Environnement
 - Description
 - Exemple
- 3 Communications point à point
 - Notions
 - Différent types de transfert/communication point à point
 - Types de données de base
- 4 Communications collectives
 - notions
 - Cas particulier des réductions
- 5 Types de données dérivées

- Une réduction est une opération appliquée à un ensemble d'éléments pour en obtenir une seule valeur. Des exemples typiques sont la somme des éléments d'un vecteur $SUM(A(:))$ ou la recherche de l'élément de valeur maximum dans un vecteur $MAX(V(:))$.
- MPI propose des sous-programmes de haut-niveau pour opérer des réductions sur des données réparties sur un ensemble de processus. Le résultat est obtenu sur un seul processus ($MPI_REDUCE()$) ou bien sur tous ($MPI_ALLREDUCE()$, qui est en fait équivalent à un $MPI_REDUCE()$ suivi d'un $MPI_BCAST()$).
- Si plusieurs éléments sont concernés par processus, la fonction de réduction est appliquée à chacun d'entre eux.
- Le sous-programme $MPI_SCAN()$ permet en plus d'effectuer des réductions partielles en considérant, pour chaque processus, les processus précédents du communicateur et lui-même.
- Les sous-programmes $MPI_OP_CREATE()$ et $MPI_OP_FREE()$ permettent de définir des opérations de réduction personnelles.

Nom	opération
MPI_SUM	Somme des éléments
MPI_PROD	Produit des éléments
MPI_MIN	Recherche du maximum
MPI_MAX	Recherche du minimum
MPI_MAXLOC	Recherche de l'indice du maximum
MPI_MINLOC	Recherche de l'indice du minimum
MPI_LAND	ET logique
MPI_LOR	OU logique
MPI_LXOR	OU exclusif logique

Exemple Scatter C

```
#include "mpi.h"
#include <stdio.h>
#define SIZE 4
int main(argc, argv){
    int numtasks, rank, sendcount, recvcnt, source;
    float sendbuf[SIZE][SIZE] = {
        {1.0, 2.0, 3.0, 4.0}, {5.0, 6.0, 7.0, 8.0},
        {9.0, 10.0, 11.0, 12.0}, {13.0, 14.0, 15.0, 16.0}
    };
    float recvbuf[SIZE];
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
    if (numtasks == SIZE) {
        source = 1;
        sendcount = SIZE;
        recvcnt = SIZE;
        MPI_Scatter(sendbuf, sendcount, MPI_FLOAT, recvbuf, recvcnt,
            MPI_FLOAT, source, MPI_COMM_WORLD);
        printf("rank=%d Results: %f %f %f %f\n", rank, recvbuf[0],
            recvbuf[1], recvbuf[2], recvbuf[3]);
    }
    else printf("Must specify %d processors. Terminating.\n", SIZE);
    MPI_Finalize();
}
```


Exemple Scatter python

```
from mpi4py import MPI

comm = MPI.COMM_WORLD
size = comm.Get_size()
rank = comm.Get_rank()

if rank == 0:
    data = [(i+1)**2 for i in range(size)]
else:
    data = None
data = comm.scatter(data, root=0)
assert data == (rank+1)**2
```

- Dans les communications, les données échangées sont typées : `MPI_INTEGER`, `MPI_REAL`, `MPI_COMPLEX`, etc.
- On peut créer des structures de données plus complexes à l'aide de sous-programmes tels que `MPI_TYPE_CONTIGUOUS()`, `MPI_TYPE_VECTOR()`, `MPI_TYPE_CREATE_HVECTOR()`.
- A chaque fois que l'on crée un type de données, il faut le valider à l'aide du sous-programme `MPI_TYPE_COMMIT()`.
- Si on souhaite réutiliser le même nom pour définir un autre type dérivé, on doit au préalable le libérer avec le sous-programme `MPI_TYPE_FREE()` .



- Pour compléter :
 - Copies de mémoire à mémoire.
 - Types de données dérivés.
 - Optimisations.
 - Communicateurs.
 - MPI-IO.
 - Gestion dynamique de processus.

Ressources

- Message Passing Interface Forum, MPI : A Message-Passing Interface Standard, Version 2.2, High Performance Computing Center Stuttgart (HLRS), 2009
<https://fs.hlr.de/projects/par/mpi/mpi22/>
- William Gropp, Ewing Lusk et Anthony Skjellum : Using MPI : Portable Parallel Programming with the Message Passing Interface, second edition, MIT Press, 1999
- William Gropp, Ewing Lusk et Rajeev Thakur : Using MPI-2, MIT Press, 1999
- Peter S. Pacheco : Parallel Programming with MPI, Morgan Kaufman Ed., 1997
- Ian Foster, Designing and Building Parallel Programs :
<http://www.mcs.anl.gov/itf/dbpp/>

Ressources

- Lawrence Livermore National Laboratory :
<https://computing.llnl.gov/tutorials/mpi>
- Documentations complémentaires :
 - <http://www.mpi-forum.org/docs/>
 - http://www.mpi-forum.org/mpi2_1/index.htm
 - <http://www.mcs.anl.gov/research/projects/mpi/learning.html>
 - <http://www.mpi-forum.org/archives/notes/notes.html>
- MPICH2 :
<http://www.mcs.anl.gov/research/projects/mpich2/>
- Open MPI : <http://www.open-mpi.org/>