



INSTITUT DU
DÉVELOPPEMENT ET DES
RESSOURCES EN
INFORMATIQUE
SCIENTIFIQUE

MPI

Dimitri Lecas - Rémi Lacroix - Serge Van Criekingen - Myriam Peyrounette

CNRS — IDRIS

v5.2 22 septembre 2022

Plan I

Introduction

- A propos
- Introduction
- Concepts de l'échange de messages
- Mémoire distribuée
- Historique
- Bibliographie

Environnement

Communications point à point

- Notions générales
- Opérations d'envoi et de réception bloquantes
- Types de données de base
- Autres possibilités

Communications collectives

- Notions générales
- Synchronisation globale : `MPI_Barrier()`
- Diffusion générale : `MPI_Bcast()`
- Diffusion sélective : `MPI_Scatter()`
- Collecte : `MPI_Gather()`
- Collecte générale : `MPI_Allgather()`
- Collecte : `MPI_Gatherv()`

Plan II

- Collectes et diffusions sélectives : `MPI_Alltoall()`
- Réductions réparties
- Compléments

Modèles de communication

- Modes d'envoi point à point
- Appels bloquants
 - Envois synchrones
 - Envois *bufferisés*
 - Envois standards
- Appels non bloquants
- Nombre d'éléments reçus
- Communications mémoire à mémoire (RMA)

Types de données dérivés

- Introduction
- Types contigus
- Types avec un pas constant
- Validation des types de données dérivés
- Exemples
 - Type « colonne d'une matrice »
 - Type « ligne d'une matrice »
 - Type « bloc d'une matrice »
- Types homogènes à pas variable

Plan III

- Taille des types de données
- Types hétérogènes
- Conclusion

Communicateurs

- Introduction
- Exemple
- Communicateur par défaut
- Groupes et communicateurs
- Partitionnement d'un communicateur
- Communicateur construit à partir d'un groupe
- Topologies
 - Topologies cartésiennes
 - Subdiviser une topologie cartésienne

MPI-IO

- Introduction
- Ouverture et fermeture d'un fichier
- Lectures/écritures : généralités
- Lectures/écritures individuelles
 - Via des déplacements explicites
 - Via des déplacements implicites individuels
 - Via des déplacements implicites partagés
- Lectures/écritures collectives

Plan IV

- Via des déplacements explicites
- Via des déplacements implicites individuels
- Via des déplacements implicites partagés

Positionnement explicite des pointeurs dans un fichier

Lectures/écritures non bloquantes

- Via des déplacements explicites
- Via des déplacements implicites individuels
- Lectures/écritures collectives et non bloquantes

MPI 3.x

MPI 4.x

MPI-IO Vues

- Définition des vues
- Construction de sous-tableaux
- Lecture d'un fichier par blocs de deux éléments
- Utilisation successive de plusieurs vues
- Gestion des trous dans les types de données
- Conseils

Conclusion

Introduction

A propos

Ce document est mis à jour régulièrement. La version la plus récente est disponible sur le site Web de l'IDRIS : <http://www.idris.fr/formations/mpi/>

- IDRIS
Institut du développement et des ressources en informatique scientifique
Rue John Von Neumann
Bâtiment 506
BP 167
91403 ORSAY CEDEX
France
<http://www.idris.fr>

Introduction

Parallélisme

L'intérêt de faire de la programmation parallèle est :

- De réduire le temps de restitution ;
- D'effectuer de plus gros calculs ;
- D'exploiter le parallélisme des processeurs modernes (multi-coeurs, multithreading).

Mais pour travailler à plusieurs, la coordination est nécessaire. [MPI](#) est une bibliothèque permettant de coordonner des processus en utilisant le paradigme de l'échange de messages.

Introduction

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.

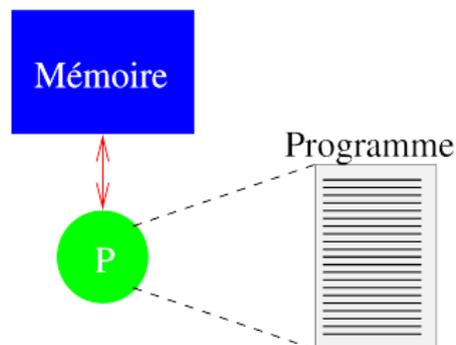


Figure 1 – Modèle de programmation séquentiel

Introduction

Modèle de programmation par échange de messages

- le programme est écrit dans un langage classique ([Fortran](#), [C](#), [C++](#), etc.);
- toutes les variables du programme sont privées et résident dans la mémoire locale allouée à chaque processus ;
- chaque processus exécute éventuellement des parties différentes d'un programme ;
- une donnée est échangée entre deux ou plusieurs processus via un appel, dans le programme, à des sous-programmes particuliers.

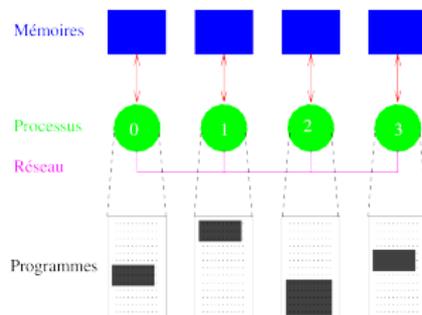


Figure 2 – Modèle de programmation par échange de messages

Introduction

Concepts de l'échange de messages

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

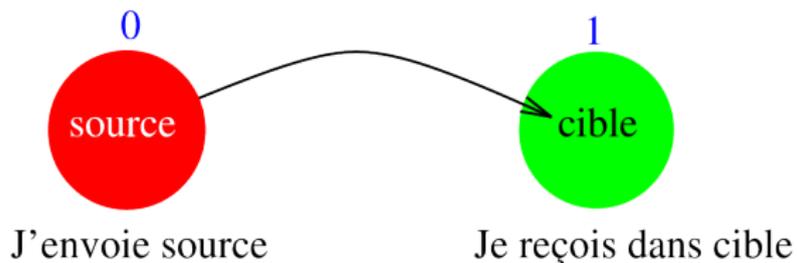


Figure 3 – échange d'un message

Introduction

Constitution d'un message

- 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.

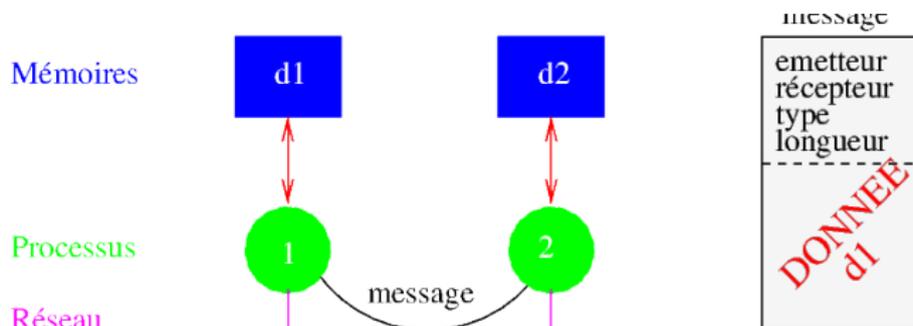


Figure 4 – Constitution d'un message

Introduction

Environnement

- Les messages échangés sont interprétés et gérés par un environnement qui peut être comparé à la téléphonie, 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

Introduction

Architecture des supercalculateurs

La plupart des supercalculateurs sont des machines à mémoire distribuée. Ils sont composés d'un ensemble de nœud, à l'intérieur d'un nœud la mémoire est partagée.

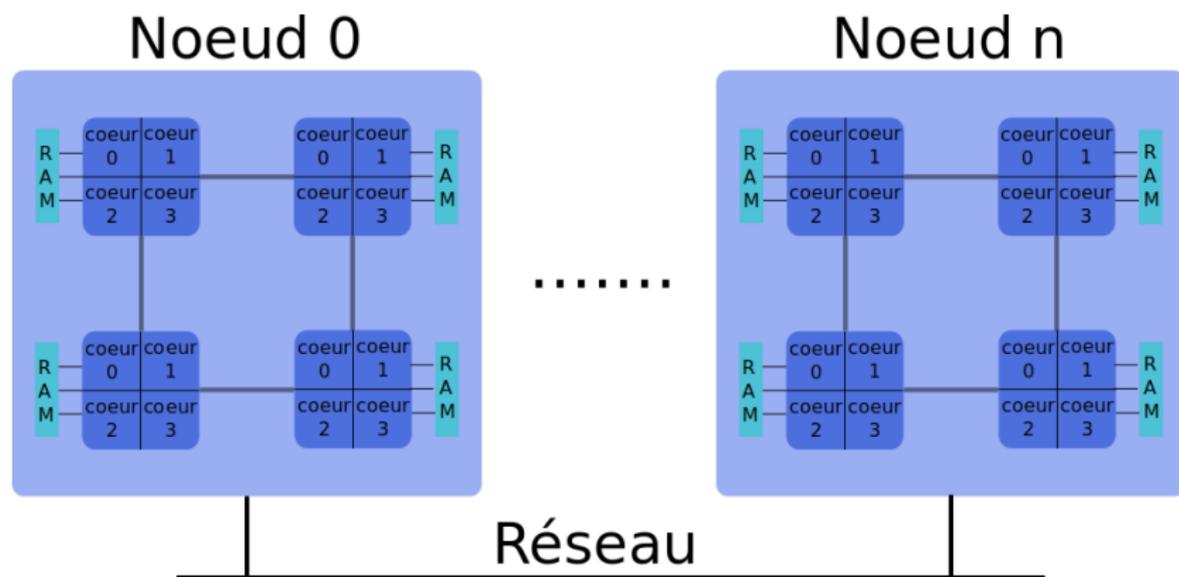


Figure 5 – Architecture des supercalculateurs

Introduction

Jean Zay

- 2 140 nœuds
- 2 processeurs Intel Cascade Lake (20 cœurs) à 2,5 Ghz par nœud
- 4 GPU Nvidia V100 par nœud (sur 612 nœud)
- 85 600 cœurs
- 410 To (192 Go par nœud)
- 26 Pflop/s crête
- 15,6 Pflop/s (linpack)



Introduction

MPI vs OpenMP

OpenMP utilise un schéma à mémoire partagée, tandis que pour MPI la mémoire est distribuée.

Processus 0 Processus n

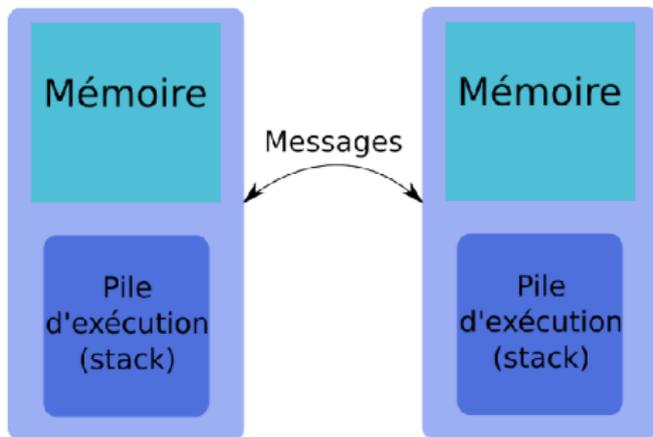


Figure 6 – Schéma MPI

Processus

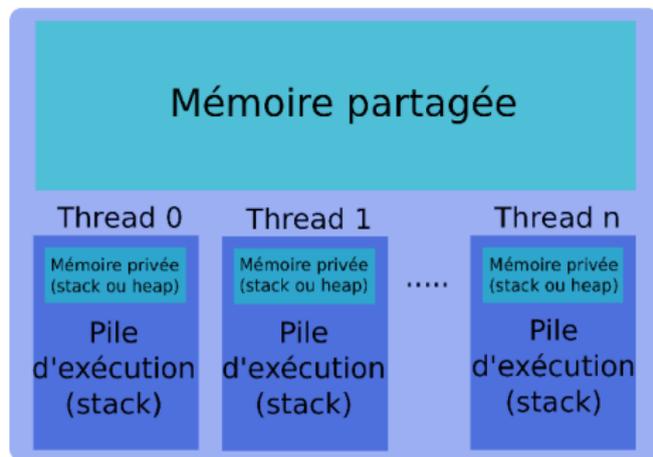


Figure 7 – Schéma OpenMP

Introduction

Décomposition de domaine

Un schéma que l'on rencontre très souvent avec **MPI** est la décomposition de domaine. Chaque processus possède une partie du domaine global, et effectue principalement des échanges avec ses processus voisins.

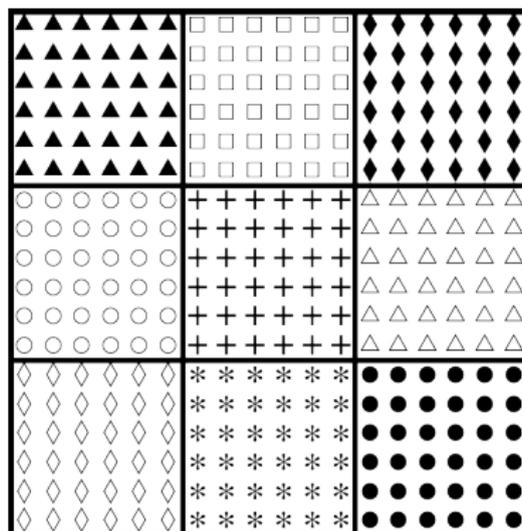


Figure 8 – Découpage en sous-domaines

Historique

- **Version 1.0** : en juin 1994, le forum MPI, avec la participation d'une quarantaine d'organisations, aboutit 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 importants 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

Introduction

MPI 3.0

- **Version 3.0** : septembre 2012 changements et ajouts importants par rapport à la version 2.2 ;
 - communications collectives non bloquantes ;
 - révision de l'implémentation des copies mémoire à mémoire ;
 - Fortran (2003-2008) interface ;
 - suppression de l'interface C++ ;
 - interfaçage d'outils externes (pour le débogage et les mesures de performance) ;
 - etc.
- **Version 3.1** : juin 2015
 - Correction de l'interface Fortran (2003-2008) ;
 - Nouvelles fonctions pour les écritures collectives non bloquantes ;

MPI 4.0

Version 4.0 : juin 2021

- Grand nombre
- Communication par morceaux
- MPI Session

Bibliographie

- Message Passing Interface Forum, *MPI : A Message-Passing Interface Standard, Version 3.1*, High Performance Computing Center Stuttgart (HLRS), 2015
<https://fs.hlrs.de/projects/par/mpi/mpi31/>
- William Gropp, Ewing Lusk et Anthony Skjellum : *Using MPI, third edition Portable Parallel Programming with the Message-Passing Interface*, MIT Press, 2014.
- William Gropp, Torsten Hoefler, Rajeev Thakur et Erwing Lusk : *Using Advanced MPI Modern Features of the Message-Passing Interface*, MIT Press, 2014.
- Documentations complémentaires : <http://www.mpi-forum.org/docs/>
<http://www.mcs.anl.gov/research/projects/mpi/learning.html>

Introduction

Implémentations MPI *open source*

Elles peuvent être installées sur un grand nombre d'architectures mais leurs performances sont en général en dessous de celles des implémentations constructeurs

- **MPICH** : <http://www.mpich.org>
- **Open MPI** : <http://www.open-mpi.org>

Introduction

Outils

- Débugueurs
 - Totalview
<https://totalview.io>
 - DDT
<https://www.arm.com/products/development-tools/server-and-hpc/forge/ddt>
- Outils de mesure de performances
 - FPMPI : *FPMPI*
<http://www.mcs.anl.gov/research/projects/fpmapi/WWW/>
 - Scalasca : *Scalable Performance Analysis of Large-Scale Applications*
<http://www.scalasca.org>
 - MUST : *MPI Runtime Correctness Analysis*
<https://itc.rwth-aachen.de/must/>

Bibliothèques scientifiques parallèles *open source*

- **ScaLAPACK** : résolution de problèmes d'algèbre linéaire par des méthodes directes.
<http://www.netlib.org/scalapack/>
- **PETSc** : résolution de problèmes d'algèbre linéaire et non-linéaire par des méthodes itératives.
<https://www.mcs.anl.gov/petsc/>
- **PaStiX** : résolution de grands systèmes linéaires creux.
<http://pastix.gforge.inria.fr/files/README-txt.html>
- **FFTW** : transformées de Fourier rapides.
<http://www.fftw.org>

Environnement

Environnement

Description

- Tout unité de programme appelant des fonctions MPI doit inclure le fichier d'en-têtes `mpi.h`.
- Le sous-programme `MPI_Init()` permet d'initialiser l'environnement nécessaire :

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

- Réciproquement, le sous-programme `MPI_Finalize()` désactive cet environnement :

```
int MPI_Finalize(void)
```

Environnement

Communicateurs

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

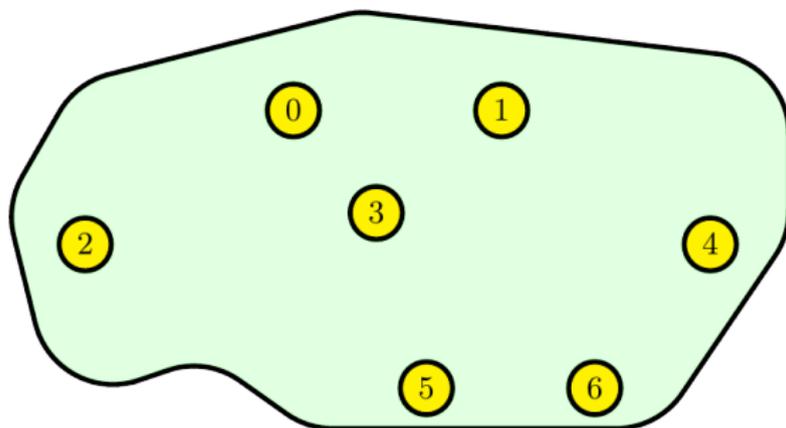


Figure 9 – Communicateur MPI_COMM_WORLD

Arrêt d'un programme

Parfois un programme se trouve dans une situation où il doit s'arrêter sans attendre la fin normale. C'est typiquement le cas si un des processus ne peut pas allouer la mémoire nécessaire à son calcul. Dans ce cas il faut utiliser le sous-programme `MPI_Abort()` et non l'instruction Fortran `stop` (Ou `exit` in C).

```
int MPI_Abort(MPI_Comm comm, int erreur)
```

- `comm` : tous les processus appartenant à ce communicateur seront stoppés, il est donc conseillé d'utiliser `MPI_COMM_WORLD` ;
- `erreur` : numéro d'erreur retourné à l'environnement UNIX.

Code

Il n'est pas nécessaire de tester la valeur de `code` (valeur de retour en C) après des appels aux routines MPI. Par défaut, lorsque MPI rencontre un problème, le programme s'arrête comme lors d'un appel à `MPI_Abort()`.

Rang et nombre de processus

- À tout instant, on peut connaître le nombre de processus gérés par un communicateur en appelant le sous-programme `MPI_Comm_size()` :

```
int MPI_Comm_size (MPI_Comm comm, int *nb_procs)
```

- De même, le sous-programme `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) :

```
int MPI_Comm_rank (MPI_Comm comm, int *rang)
```

Environnement

Exemple

```
1 /* qui_je_suis */
2 #include <mpi.h>
3 #include <stdio.h>
4
5 int main(int argc, char *argv[]) {
6     int nb_procs, rang;
7
8     MPI_Init(&argc, &argv);
9
10    MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
11    MPI_Comm_rank(MPI_COMM_WORLD, &rang);
12
13    printf("Je suis le processus %d parmi %d\n", rang, nb_procs);
14
15    MPI_Finalize();
16 }
```

```
> mpiexec -n 7 qui_je_suis
```

```
Je suis le processus 3 parmi 7
Je suis le processus 0 parmi 7
Je suis le processus 4 parmi 7
Je suis le processus 1 parmi 7
Je suis le processus 5 parmi 7
Je suis le processus 2 parmi 7
Je suis le processus 6 parmi 7
```

Compilation et exécution d'un code MPI

- Pour **compiler** un code MPI, on utilise un enrobeur (*wrapper*) de compilateur qui fait le lien avec la librairie MPI utilisée.
- Cet enrobeur diffère selon le langage de programmation, le compilateur et la librairie MPI utilisés. Par exemple : `mpif90`, `mpifort`, `mpicc`, ...

```
> mpif90 <options> -c source.f90  
> mpif90 source.o -o mon_executable
```

- Pour **exécuter** un code MPI, on utilise un lanceur d'application MPI qui ordonne le lancement de l'exécution sur un nombre de processus choisi.
- Le lanceur défini par la norme MPI est `mpiexec`. Il existe également des lanceurs non standards, comme `mpirun`.

```
> mpiexec -n <nombre de processus> mon_executable
```

Travaux pratiques MPI – Exercice 1 : Environnement MPI

- Implémenter un programme MPI dans lequel chaque processus affiche un message indiquant si son rang est **pair** ou **impair**. Par exemple :

```
> mpiexec -n 4 ./pair_impair
Moi, processus 0, je suis de rang pair
Moi, processus 2, je suis de rang pair
Moi, processus 3, je suis de rang impair
Moi, processus 1, je suis de rang impair
```

- Pour tester la parité, la fonction intrinsèque Fortran correspondant à l'opération *modulo* est **mod** :

```
mod(a, b)
```

(en C, utilisez le symbole **%** : `a%b`)

- Pour compiler votre programme, utilisez la commande **make**
- Pour exécuter votre programme, utilisez la commande **make exe**
- Pour être reconnu par le Makefile, le programme doit se nommer `pair_impair.f90` (ou `pair_impair.c`)

Communications point à point

Communications point à point

Notions générales

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

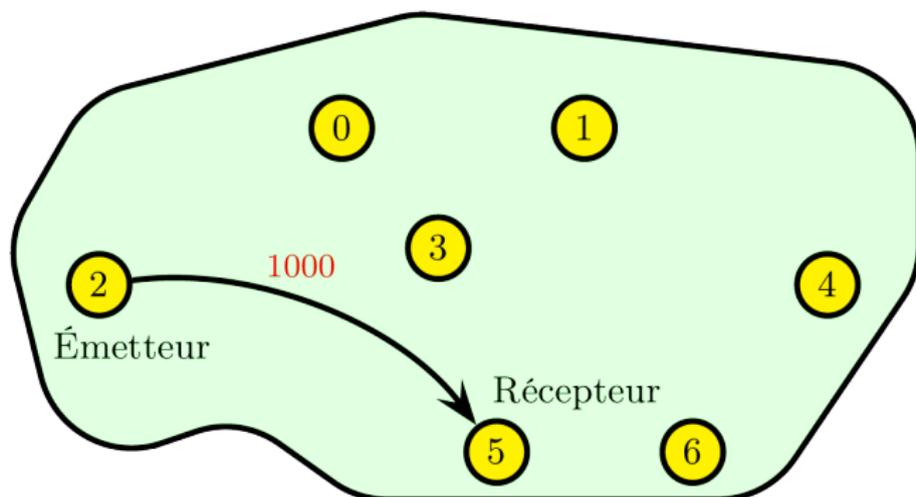


Figure 10 – Communication point à point

Communications point à point

Notions générales

- L'émetteur et le récepteur sont identifiés par leur **rang** dans le communicateur.
- L'entité transmise entre deux processus est appelée **message**.
- Un message est caractérisé par son **enveloppe**. Celle-ci est constituée :
 - du rang du processus émetteur ;
 - du rang du processus récepteur ;
 - de l'étiquette (*tag*) du message ;
 - 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.

Communications point à point

Opération d'envoi `MPI_Send`

```
int MPI_Send(const void *message, int longueur, MPI_Datatype type_message,  
            int rang_dest, int etiquette, MPI_Comm comm)
```

Envoi, à partir de l'adresse `message`, d'un message de taille `longueur`, de type `type_message`, étiqueté `etiquette`, au processus `rang_dest` dans le communicateur `comm`.

Remarque :

Cette opération est bloquante : l'exécution reste bloquée jusqu'à ce que le contenu de `message` puisse être réécrit sans risque d'écraser la valeur qui devait être envoyée.

Communications point à point

Opération de réception `MPI_Recv`

```
int MPI_Recv(void *message, int longueur, MPI_Datatype type_message,  
            int rang_source, int etiquette, MPI_Comm comm, MPI_Status *status)
```

Réception, à partir de l'adresse `message`, d'un message de taille `longueur`, de type `type_message`, étiqueté `etiquette`, du processus `rang_source`.

Remarques :

- `statut` stocke des informations sur la communication : `rang_source`, `etiquette`, `code`,...
- L'appel `MPI_Recv` ne pourra fonctionner avec une opération `MPI_Send` que si ces deux appels ont la même enveloppe (`rang_source`, `rang_dest`, `etiquette`, `comm`).
- Cette opération est bloquante : l'exécution reste bloquée jusqu'à ce que le contenu de `message` corresponde au message reçu.

Communications point à point

Exemple (voir Fig. 10)

```
1  /* point_a_point */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, valeur;
7      int etiquette=100;
8      MPI_Status statut;
9
10     MPI_Init (&argc, &argv);
11
12     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
13
14     if (rang == 2) {
15         valeur = 1000;
16         MPI_Send (&valeur, 1, MPI_INT, 5, etiquette, MPI_COMM_WORLD);
17     } else if (rang == 5) {
18         MPI_Recv (&valeur, 1, MPI_INT, 2, etiquette, MPI_COMM_WORLD, &statut);
19         printf("Moi, processus 5, ai recu %d du processus 2.\n", valeur);
20     }
21
22     MPI_Finalize ();
23 }
```

```
> mpiexec -n 7 point_a_point
```

```
Moi, processus 5, ai recu 1000 du processus 2
```

Communications point à point

Types de données de base C

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

Communications point à point

Autres possibilités

- À la réception d'un message, le rang de l'émetteur et l'étiquette peuvent être des « *jokers* », respectivement `MPI_ANY_SOURCE` et `MPI_ANY_TAG`.
- Une communication impliquant le processus « fictif » de rang `MPI_PROC_NULL` n'a aucun effet.
- `MPI_STATUS_IGNORE` est une constante prédéfinie qui peut être utilisée à la place de la variable `statut`.
- On peut communiquer des structures de données plus complexes en créant ses propres types dérivés.
- Il existe d'autres opérations qui effectuent **simultanément** un envoi et une réception : `MPI_Sendrecv()` et `MPI_Sendrecv_replace()`.

Communications point à point

Opération d'envoi et de réception simultanés `MPI_Sendrecv`

```
int MPI_Sendrecv(const void *message_emis, int longueur_message_emis,
                 MPI_Datatype type_message_emis, int rang_dest, int etiq_message_emis,
                 void *message_recu, int longueur_message_recu,
                 MPI_Datatype type_message_recu, int rang_source, int etiq_message_recu,
                 MPI_Comm comm, MPI_Status *status)
```

- Envoi, à partir de l'adresse `message_emis`, d'un message de taille `longueur_message_emis`, de type `type_message_emis`, étiqueté `etiq_message_emis`, au processus `rang_dest` dans le communicateur `comm` ;
- Réception, à partir de l'adresse `message_recu`, d'un message de taille `longueur_message_recu`, de type `type_message_recu`, étiqueté `etiq_message_recu`, du processus `rang_source` dans le communicateur `comm`.

Remarque :

- La zone de réception `message_recu` doit différer de la zone d'envoi `message_emis`.

Communications point à point

Opération d'envoi et de réception simultanés `MPI_Sendrecv`

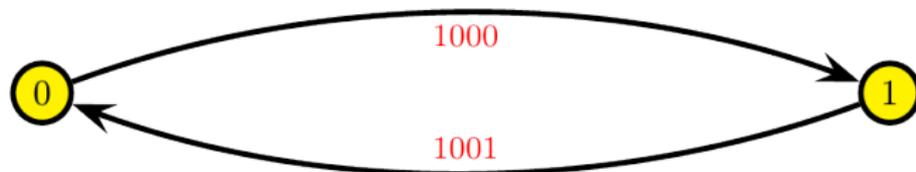


Figure 11 – Communication `sendrecv` entre les processus 0 et 1

Communications point à point

Exemple (voir Fig. 11)

```
1  /* sendrecv */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, valeur, num_proc, message;
7      int etiquette=110;
8
9      MPI_Init (&argc, &argv);
10     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
11
12     num_proc=(rang+1)%2;
13     message = rang+1000;
14     MPI_Sendrecv (&message, 1, MPI_INT, num_proc, etiquette, &valeur, 1, MPI_INT,
15                 num_proc, etiquette, MPI_COMM_WORLD, MPI_STATUS_IGNORE);
16
17     printf("Moi, processus %d, ai reçu %d du processus %d.\n", rang, valeur, num_proc);
18
19     MPI_Finalize ();
20 }
```

```
> mpiexec -n 2 sendrecv
```

```
Moi, processus 1, ai reçu 1000 du processus 0
Moi, processus 0, ai reçu 1001 du processus 1
```

Communications point à point

Attention !

Dans le cas d'une implémentation **synchrone** de `MPI_Send()`, l'exemple précédent serait en situation de verrouillage si l'appel à `MPI_Sendrecv()` était remplacé par un `MPI_Send()` suivi d'un `MPI_Recv()`. En effet, chacun des deux processus attendrait un ordre de réception qui ne viendrait jamais, puisque les deux envois resteraient en suspens.

```
val = rang+1000;
MPI_Send (&val,1,MPI_INT,num_proc,etiquette,MPI_COMM_WORLD);
MPI_Recv (valeur,1,MPI_INT,num_proc,etiquette,MPI_COMM_WORLD,&statut);
```

Communications point à point

Opération d'envoi et de réception simultanés `MPI_Sendrecv_replace`

```
int MPI_Sendrecv_replace(void * message, int longueur, MPI_Datatype type_message,  
                        int rang_dest, int etiq_message_emis,  
                        int rang_source, int etiq_message_recu, MPI_Comm comm,  
                        MPI_Status *statut)
```

- Envoi, à partir de l'adresse `message`, d'un message de taille `longueur`, de type `type_message`, étiqueté `etiq_message_emis`, au processus `rang_dest` dans le communicateur `comm` ;
- Réception d'un message à la même adresse, d'une taille et d'un type identique, étiqueté `etiq_message_recu`, du processus `rang_source` dans le communicateur `comm`.

Remarque :

- Contrairement à l'usage imposée par `MPI_Sendrecv()`, la zone de réception coïncide ici avec la zone d'envoi `message`.

Communications point à point

Exemple

```
1  /* joker */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int nb_procs, rang;
7      int m=4, etiquette=11;
8      int A[m][m];
9      MPI_Status statut;
10
11     MPI_Init (&argc, &argv);
12     MPI_Comm_size (MPI_COMM_WORLD, &nb_procs);
13     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
14
15     if (rang == 0) {
16         A[0][0]=1;A[0][1]=2;A[0][2]=3;A[0][3]=4;A[1][0]=5;A[1][1]=6;A[1][2]=7;
17         A[1][3]=8;A[2][0]=9;A[2][1]=10;A[2][2]=11;A[2][3]=12;A[3][0]=13;
18         A[3][1]=14;A[3][2]=15;A[3][3]=16;
19         MPI_Send (A, 3, MPI_INT, 1, etiquette, MPI_COMM_WORLD);
20     } else {
21         MPI_Recv (&(A[0][1]), 3, MPI_INT, MPI_ANY_SOURCE, MPI_ANY_TAG,
22                 MPI_COMM_WORLD, &statut);
23         printf("Moi processus %d, ai reçu 3 elements du processus %d avec comme "
24              "etiquette %d les elements sont %d %d %d.\n",
25              rang, statut.MPI_SOURCE, statut.MPI_TAG, A[0][1], A[0][2], A[0][3]);
26     }
27     MPI_Finalize ();
28 }
```

Communications point à point

```
> mpiexec -n 2 joker  
Moi processus 1, ai reçu 3 elements du processus 0  
avec comme etiquette 11 les elements sont 1 2 3.
```

Travaux pratiques MPI – Exercice 2 : Ping-pong

- Communications point à point : *Ping-Pong* entre deux processus
- L'exercice 2 est décomposé en 3 étapes :
 1. *Ping* : compléter le script `ping_pong_1.c` de manière à ce que le processus de rang 0 **envoie** un message contenant une série aléatoire de 1000 réels au rang 1.
 2. *Ping-Pong* : compléter le script `ping_pong_2.c` de manière à ce que le processus de rang 1 **renvoie** le message vers le processus de rang 0, et mesurer le temps pris par la communication à l'aide de la fonction `MPI_Wtime()`.
 3. *Match de Ping-Pong* : compléter le script `ping_pong_3.c` de manière à enchaîner 9 *Ping-Pong*, **en faisant varier la taille du message**, et mesurer les temps pris par chaque échange. Les débits correspondants seront affichés.

Travaux pratiques MPI – Exercice 2 : Ping-pong

Remarques :

- Pour compiler la première étape : `make ping_pong_1`
- Pour exécuter la première étape : `make exe1`
- Pour compiler la seconde étape : `make ping_pong_2`
- Pour exécuter la seconde étape : `make exe2`
- Pour compiler la dernière étape : `make ping_pong_3`
- Pour exécuter la dernière étape : `make exe3`

- La génération de nombres réels pseudo-aléatoires uniformément répartis dans l'intervalle $[0,1[$ se fait en C par un appel au sous-programme `rand` :

```
rand() / (RAND_MAX+1.);
```

- Les mesures de temps peuvent s'effectuer de la façon suivante :

```
temps_debut=MPI_Wtime();  
.....  
temps_fin=MPI_Wtime();  
printf("... en %f secondes.\n",temps_fin-temps_debut);
```

Communications collectives

Communications collectives

Notions générales

- 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).
- 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.

Communications collectives

Types de communications collectives

Il y a trois types de sous-programmes :

1. celui qui assure les synchronisations globales : `MPI_Barrier()`.
2. 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()` ;
 - collecte et diffusion sélective, par tous les processus, de données réparties : `MPI_Alltoall()`.
3. 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()`.

Communications collectives

Synchronisation globale : `MPI_Barrier()`

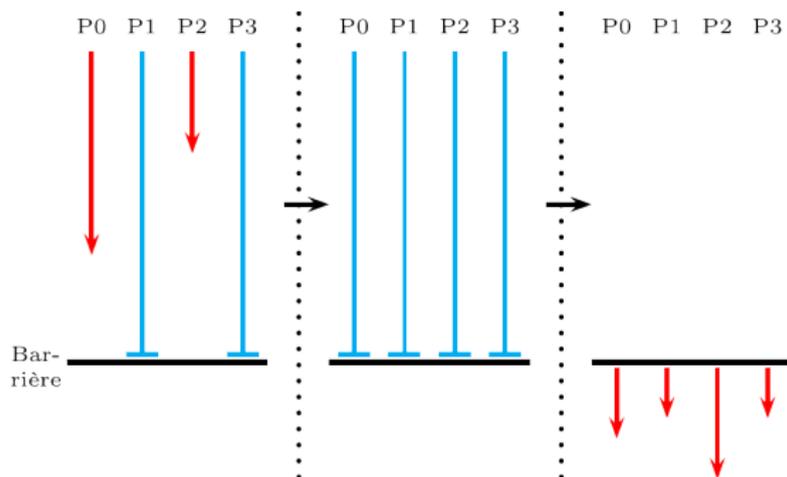


Figure 12 – Synchronisation globale : `MPI_Barrier()`

```
int MPI_Barrier(MPI_Comm MPI_COMM_WORLD)
```

Communications collectives

Diffusion générale : `MPI_Bcast()`

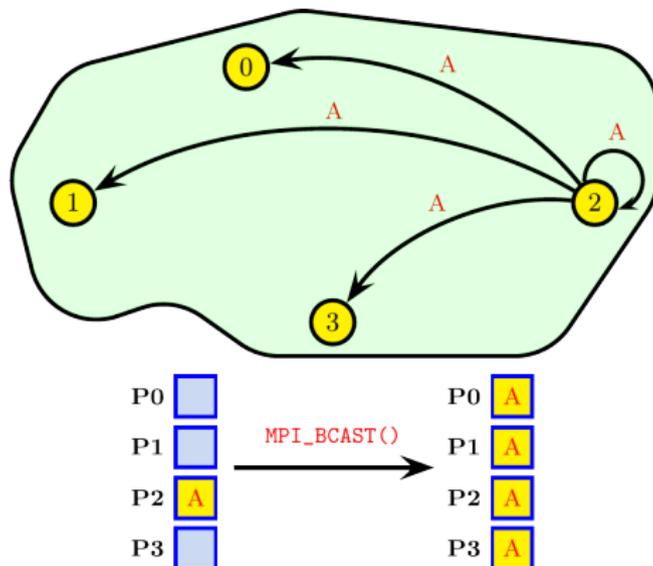


Figure 13 – Diffusion générale : `MPI_Bcast()`

Diffusion générale : `MPI_Bcast()`

```
int MPI_Bcast(void *message, int longueur, MPI_Datatype type_message,  
             int rang_source, MPI_Comm comm)
```

1. Envoi, à partir de l'adresse `message`, d'un message constitué de `longueur` élément de type `type_message`, par le processus `rang_source`, à tous les autres processus du communicateur `comm`.
2. Réception de ce message à l'adresse `message` pour les processus autre que `rang_source`.

Communications collectives

Exemple de `MPI_Bcast()`

```
1  /* bcast */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, valeur;
7
8      MPI_Init (&argc, &argv);
9      MPI_Comm_rank (MPI_COMM_WORLD, &rang);
10
11     if (rang == 2) valeur = rang+1000;
12
13     MPI_Bcast (&valeur, 1, MPI_INT, 2, MPI_COMM_WORLD);
14
15     printf("Moi, processus %d, ai recu %d du processus 2\n",
16           rang, valeur);
17
18     MPI_Finalize ();
19 }
```

```
> mpiexec -n 4 bcast
```

```
Moi, processus 2, ai recu 1002 du processus 2
Moi, processus 0, ai recu 1002 du processus 2
Moi, processus 1, ai recu 1002 du processus 2
Moi, processus 3, ai recu 1002 du processus 2
```

Communications collectives

Diffusion sélective : `MPI_Scatter()`

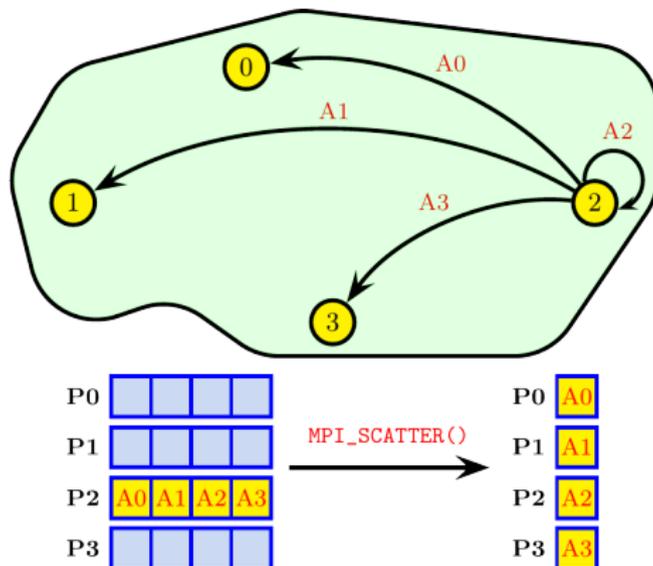


Figure 14 – Diffusion sélective : `MPI_Scatter()`

Diffusion sélective : `MPI_Scatter()`

```
int MPI_Scatter(const void *message_a_repartir, int longueur_message_emis,  
               MPI_Datatype type_message_emis, void *message_recu,  
               int longueur_message_recu, MPI_Datatype type_message_recu,  
               int rang_source, MPI_Comm comm)
```

1. Distribution, par le processus `rang_source`, à partir de l'adresse `message_a_repartir`, d'un message de taille `longueur_message_emis`, de type `type_message_emis`, à tous les processus du communicateur `comm` ;
2. réception du message à l'adresse `message_recu`, de longueur `longueur_message_recu` et de type `type_message_recu` par tous les processus du communicateur `comm`.

Remarques :

- Les couples (`longueur_message_emis`, `type_message_emis`) et (`longueur_message_recu`, `type_message_recu`) doivent être tels que les quantités de données envoyées et reçues soient égales.
- Les données sont distribuées en tranches égales, une tranche étant constituée de `longueur_message_emis` éléments du type `type_message_emis`.
- La *i*ème tranche est envoyée au *i*ème processus.

Communications collectives

Exemple de `MPI_Scatter()`

```
1  /* scatter */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5  int main(int argc, char *argv[]) {
6      int nb_valeurs=8, rang, nb_procs, longueur_tranche, i;
7      float *valeurs, *donnees;
8      MPI_Init(&argc, &argv);
9      MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
10     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
11     longueur_tranche = nb_valeurs/nb_procs;
12     donnees = (float *) malloc(longueur_tranche*sizeof(float));
13     if (rang == 2) {
14         valeurs = (float *) malloc(nb_valeurs*sizeof(float));
15         for (i=0; i<nb_valeurs;i++) valeurs[i]=1000.+i;
16         printf("Moi, processus %d envoie mon tableau valeurs : ", rang);
17         for (i=0; i<nb_valeurs;i++) {printf("%f ", valeurs[i]);} printf("\n"); }
18     MPI_Scatter(valeurs, longueur_tranche, MPI_FLOAT,
19               donnees, longueur_tranche, MPI_FLOAT, 2, MPI_COMM_WORLD);
20     printf("Moi, processus %d, ai recu ", rang);
21     for (i=0; i<longueur_tranche; i++) printf("%f ", donnees[i]);
22     printf("du processus 2\n");
23     MPI_Finalize(); }
```

```
> mpiexec -n 4 scatter
Moi, processus 2 envoie mon tableau valeurs :
1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008.

Moi, processus 0, ai recu 1001. 1002. du processus 2
Moi, processus 1, ai recu 1003. 1004. du processus 2
Moi, processus 3, ai recu 1007. 1008. du processus 2
Moi, processus 2, ai recu 1005. 1006. du processus 2
```

Communications collectives

Collecte : `MPI_Gather()`

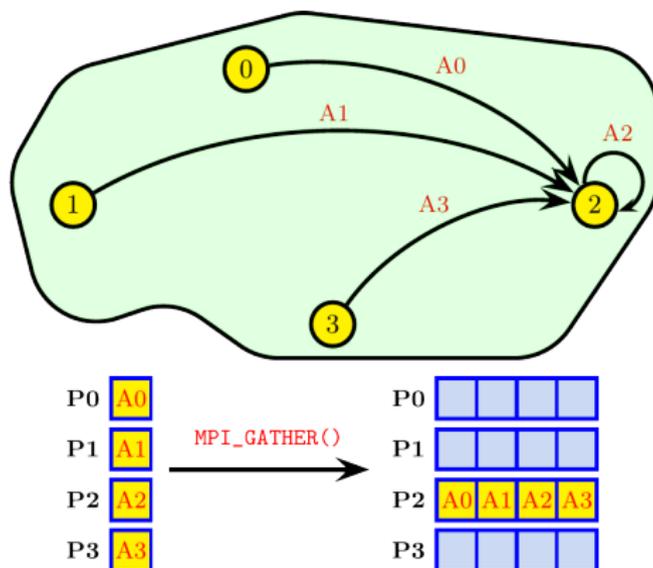


Figure 15 – Collecte : `MPI_Gather()`

Communications collectives

Collecte : `MPI_Gather()`

```
int MPI_Gather(const void*message_emis,int longueur_message_emis,  
MPI_Datatype type_message_emis,void *message_recu,  
int longueur_message_recu,MPI_Datatype type_message_recu,  
int rang_dest,MPI_Comm comm)
```

1. Envoi de chacun des processus du communicateur `comm`, d'un message `message_emis`, de taille `longueur_message_emis` et de type `type_message_emis`.
2. Collecte de chacun de ces messages, par le processus `rang_dest`, à partir l'adresse `message_recu`, sur une longueur `longueur_message_recu` et avec le type `type_message_recu`.

Remarques :

- Les couples (`longueur_message_emis`, `type_message_emis`) et (`longueur_message_recu`, `type_message_recu`) doivent être tels que les quantités de données envoyées et reçues soient égales.
- Les données sont collectées dans l'ordre des rangs des processus.

Communications collectives

Collecte : `MPI_Gather()`

```
1  /* Gather */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5  int main(int argc, char *argv[]) {
6      int nb_valeurs=8, rang, nb_procs, longueur_tranche, i;
7      float donnees[nb_valeurs], *valeurs;
8      MPI_Init(&argc, &argv);
9      MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
10     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
11     longueur_tranche = nb_valeurs/nb_procs;
12     valeurs = (float *) malloc(longueur_tranche*sizeof(float));
13     for (i=0; i<longueur_tranche; i++) valeurs[i]=1000.+rang*longueur_tranche+i;
14     printf("Moi, processus %d envoie mon tableau valeurs : ", rang);
15     for (i=0; i<longueur_tranche; i++) {printf("%f ", valeurs[i]);} printf("\n");
16     MPI_Gather(valeurs, longueur_tranche, MPI_FLOAT,
17              donnees, longueur_tranche, MPI_FLOAT, 2, MPI_COMM_WORLD);
18     if (rang==2) {
19         printf("Moi, processus %d, ai recu ", rang);
20         for (i=0; i<nb_valeurs; i++) { printf("%f ", donnees[i]); } printf("\n"); }
21     MPI_Finalize(); }
```

```
> mpiexec -n 4 gather
Moi, processus 1 envoie mon tableau valeurs :1003. 1004.
Moi, processus 0 envoie mon tableau valeurs :1001. 1002.
Moi, processus 2 envoie mon tableau valeurs :1005. 1006.
Moi, processus 3 envoie mon tableau valeurs :1007. 1008.

Moi, processus 2, ai recu 1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008.
```

Communications collectives

Collecte générale : `MPI_Allgather()`

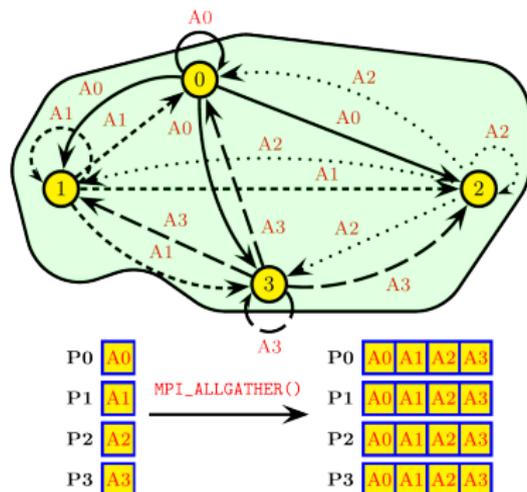


Figure 16 – Collecte générale : `MPI_Allgather()`

Communications collectives

Collecte générale : `MPI_Allgather()`

Correspond à un `MPI_Gather()` suivi d'un `MPI_Bcast()` :

```
int MPI_Allgather(const void *message_emis, int longueur_message_emis,  
                 MPI_Datatype type_message_emis, void *message_recu,  
                 int longueur_message_recu, MPI_Datatype type_message_recu,  
                 MPI_Comm comm)
```

1. Envoi de chacun des processus du communicateur `comm`, d'un message `message_emis`, de taille `longueur_message_emis` et de type `type_message_emis`.
2. Collecte de chacun de ces messages, par tous les processus, à partir l'adresse `message_recu`, sur une longueur `longueur_message_recu` et avec le type `type_message_recu`.

Remarques :

- Les couples (`longueur_message_emis`, `type_message_emis`) et (`longueur_message_recu`, `type_message_recu`) doivent être tels que les quantités de données envoyées et reçues soient égales.
- Les données sont collectées dans l'ordre des rangs des processus.

Communications collectives

Exemple de `MPI_Allgather()`

```
1  /* allgather */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5  int main(int argc, char *argv[]) {
6      int nb_valeurs=8, rang, nb_procs, longueur_tranche, i;
7      float donnees[nb_valeurs], *valeurs;
8
9      MPI_Init(&argc, &argv);
10     MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
11     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
12     longueur_tranche = nb_valeurs/nb_procs;
13     valeurs = (float *) malloc(longueur_tranche*sizeof(float));
14     for (i=0; i<longueur_tranche; i++) valeurs[i]=1000.+rang*longueur_tranche+i;
15     MPI_Allgather(valeurs, longueur_tranche, MPI_FLOAT,
16                 donnees, longueur_tranche, MPI_FLOAT, MPI_COMM_WORLD);
17     printf("Moi, processus %d, ai recu ", rang);
18     for (i=0; i<nb_valeurs; i++) {printf("%f ", donnees[i]);} printf("\n");
19     MPI_Finalize(); }
```

```
> mpiexec -n 4 allgather
```

```
Moi, processus 1, ai recu 1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008.
Moi, processus 3, ai recu 1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008.
Moi, processus 2, ai recu 1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008.
Moi, processus 0, ai recu 1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008.
```

Communications collectives

Collecte "variable" : `MPI_Gatherv()`

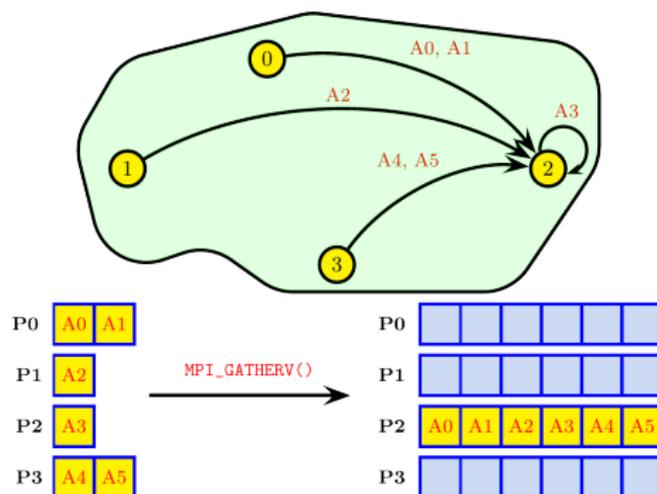


Figure 17 – Collecte : `MPI_Gatherv()`

Communications collectives

Collecte "variable" : `MPI_Gatherv()`

Correspond à un `MPI_Gather()` pour lequel la taille des messages varie :

```
int MPI_Gatherv(const void *message_emis, int longueur_message_emis,  
               MPI_Datatype type_message_emis, void *message_recu,  
               const int *nb_elts_recus, const int *deplts,  
               MPI_Datatype type_message_recu, int rang_dest, MPI_Comm comm)
```

Le i ème processus du communicateur `comm` envoie au processus `rang_dest`, un message depuis l'adresse `message_emis`, de taille `longueur_message_emis`, de type `type_message_emis`, avec réception du message à l'adresse `message_recu`, de type `type_message_recu`, de taille `nb_elts_recus(i)` avec un déplacement de `deplts(i)`.

Remarques :

- Les couples (`longueur_message_emis`, `type_message_emis`) du i ème processus et (`nb_elts_recus(i)`, `type_message_recu`) du processus `rang_dest` doivent être tels que les quantités de données envoyées et reçues soient égales.

Communications collectives

Exemple de `MPI_Gatherv()`

```
1  /* gatherv */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int nb_valeurs=8, rang, nb_procs, longueur_tranche, reste, i;
8      float donnees[nb_valeurs];
9      float *valeurs;
10     int *nb_elements_recus, *deplacements;
11
12     MPI_Init(&argc, &argv);
13     MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
14     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
15     longueur_tranche = nb_valeurs/nb_procs;
16     reste = nb_valeurs%nb_procs;
17     if (rang < reste) longueur_tranche = longueur_tranche+1;
18     valeurs = (float *) malloc(longueur_tranche*sizeof(float));
19     for (i=0; i<longueur_tranche; i++)
20         valeurs[i]=1000.+rang*longueur_tranche+(rang<reste?rang:reste)+i;
21     printf("Moi, processus %d envoie mon tableau valeurs : ", rang);
22     for (i=0; i<longueur_tranche; i++) {printf("%f ", valeurs[i]); }printf("\n");
23     if (rang == 2) {
24         nb_elements_recus = (int *) malloc(nb_procs*sizeof(int));
25         deplacements = (int *) malloc(nb_procs*sizeof(int));
26         nb_elements_recus[0] = nb_valeurs/nb_procs;
27         if (reste > 0) nb_elements_recus[0] = nb_elements_recus[0]+1;
28         deplacements[0] = 0;
29         for (i=1; i<nb_procs; i++) {
30             deplacements[i] = deplacements[i-1]+nb_elements_recus[i-1];
31             nb_elements_recus[i] = nb_valeurs/nb_procs;
32             if (i < reste) nb_elements_recus[i] = nb_elements_recus[i]+1;
33         } }
```

Communications collectives

Exemple de `MPI_Gatherv()` (suite)

```
MPI_Gatherv(valeurs, longueur_tranche, MPI_FLOAT,
            donnees, nb_elements_recus, deplacements, MPI_FLOAT, 2, MPI_COMM_WORLD);
if (rang==2) {
    printf("Moi, processus %d, ai recu ", rang);
    for (i=0; i<nb_valeurs; i++) printf("%f ", donnees[i]);
    printf("\n"); }
MPI_Finalize();
}
```

```
> mpiexec -n 4 gatherv
```

```
Moi, processus 0 envoie mon tableau valeurs : 1001. 1002. 1003.
Moi, processus 2 envoie mon tableau valeurs : 1007. 1008.
Moi, processus 3 envoie mon tableau valeurs : 1009. 1010.
Moi, processus 1 envoie mon tableau valeurs : 1004. 1005. 1006.

Moi, processus 2 ai recu 1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008. 1009. 1010.
```

Communications collectives

Collectes et diffusions sélectives : `MPI_Alltoall()`

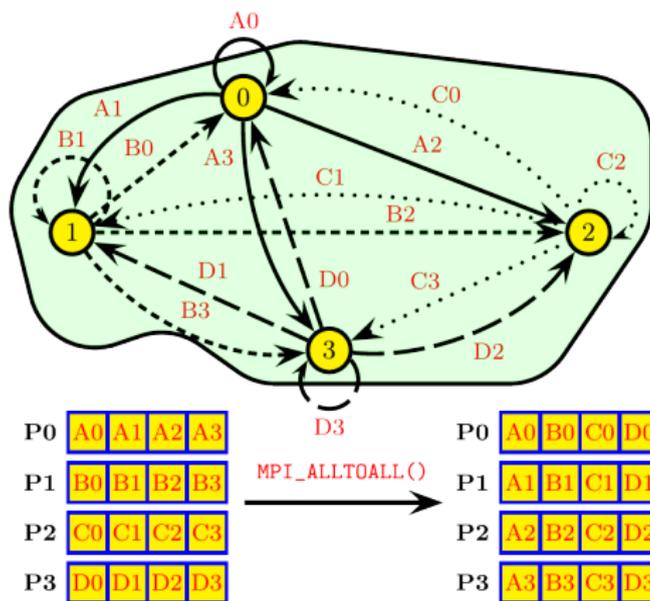


Figure 18 – Collecte et diffusion sélectives : `MPI_Alltoall()`

Collectes et diffusions sélectives : `MPI_Alltoall()`

```
int MPI_Alltoall(const void *message_emis, int longueur_message_emis,  
                MPI_Datatype type_message_emis, void *message_recu,  
                int longueur_message_recu, MPI_Datatype type_message_recu,  
                MPI_Comm comm)
```

Ici, le *i*ème processus envoie la *j*ème tranche au *j*ème processus qui le place à l'emplacement de la *i*ème tranche.

Remarque :

- Les couples (`longueur_message_emis`, `type_message_emis`) et (`longueur_message_recu`, `type_message_recu`) doivent être tels que les quantités de données envoyées et reçues soient égales.

Communications collectives

Exemple de `MPI_Alltoall()`

```
1  /* alltoall */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int nb_valeurs=8;
8      int rang, nb_procs, longueur_tranche, i;
9      float donnees[nb_valeurs], valeurs[nb_valeurs];
10
11
12      MPI_Init(&argc, &argv);
13      MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
14      MPI_Comm_rank(MPI_COMM_WORLD, &rang);
15
16      for (i=0; i<nb_valeurs; i++) valeurs[i]=1000.+rang*nb_valeurs+i;
17      longueur_tranche = nb_valeurs/nb_procs;
18
19      printf("Moi, processus %d envoie mon tableau valeurs : ", rang);
20      for (i=0; i<nb_valeurs; i++) printf("%f ", valeurs[i]);
21      printf("\n");
22
23      MPI_Alltoall(valeurs, longueur_tranche, MPI_FLOAT,
24                  donnees, longueur_tranche, MPI_FLOAT, MPI_COMM_WORLD);
25
26      printf("Moi, processus %d, ai recu ", rang);
27      for (i=0; i<nb_valeurs; i++) printf("%f ", donnees[i]);
28      printf("\n");
29      MPI_Finalize();
30 }
```

Exemple de `MPI_Alltoall()` (suite)

```
> mpiexec -n 4 alltoall
Moi, processus 1 envoie mon tableau valeurs :
1009. 1010. 1011. 1012. 1013. 1014. 1015. 1016.
Moi, processus 0 envoie mon tableau valeurs :
1001. 1002. 1003. 1004. 1005. 1006. 1007. 1008.
Moi, processus 2 envoie mon tableau valeurs :
1017. 1018. 1019. 1020. 1021. 1022. 1023. 1024.
Moi, processus 3 envoie mon tableau valeurs :
1025. 1026. 1027. 1028. 1029. 1030. 1031. 1032.

Moi, processus 0, ai recu 1001. 1002. 1009. 1010. 1017. 1018. 1025. 1026.
Moi, processus 2, ai recu 1005. 1006. 1013. 1014. 1021. 1022. 1029. 1030.
Moi, processus 1, ai recu 1003. 1004. 1011. 1012. 1019. 1020. 1027. 1028.
Moi, processus 3, ai recu 1007. 1008. 1015. 1016. 1023. 1024. 1031. 1032.
```

Réductions réparties

- 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 (par exemple à tous les éléments d'un vecteur).

Communications collectives

Réductions réparties : `MPI_Reduce()`

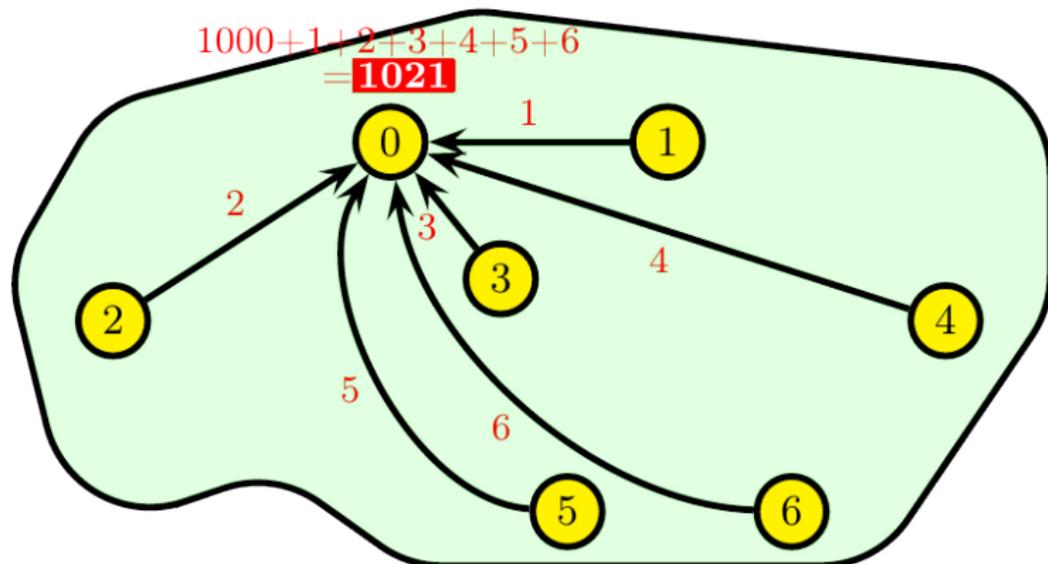


Figure 19 – Réduction répartie : `MPI_Reduce()` avec l'opérateur somme

Opérations pour réductions réparties

Nom	Opération
<code>MPI_SUM</code>	Somme des éléments
<code>MPI_PROD</code>	Produit des éléments
<code>MPI_MAX</code>	Recherche du maximum
<code>MPI_MIN</code>	Recherche du minimum
<code>MPI_MAXLOC</code>	Recherche de l'indice du maximum
<code>MPI_MINLOC</code>	Recherche de l'indice du minimum
<code>MPI_BAND</code>	ET logique
<code>MPI_BOR</code>	OU logique
<code>MPI_BXOR</code>	OU exclusif logique

Réductions réparties : `MPI_Reduce()`

```
int MPI_Reduce(const void*message_emis,void *message_recu,int longueur,  
              MPI_Datatype type_message,MPI_Op operation,int rang_dest,  
              MPI_Comm comm)
```

1. Réduction répartie des éléments situés à partir de l'adresse `message_emis`, de taille `longueur`, de type `type_message`, pour les processus du communicateur `comm`,
2. Écrit le résultat à l'adresse `message_recu` pour le processus de rang `rang_dest`.

Communications collectives

Exemple de `MPI_Reduce()` (voir Fig.19)

```
1  /* reduce */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, nb_procs, valeur, somme, i;
7
8      MPI_Init(&argc, &argv);
9      MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
10     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
11
12     if (rang == 0)
13         valeur = 1000;
14     else
15         valeur = rang;
16
17     MPI_Reduce(&valeur, &somme, 1, MPI_INT, MPI_SUM, 0, MPI_COMM_WORLD);
18
19     if (rang == 0)
20         printf("Moi, processus 0, ma valeur de la somme globale est %d\n", somme);
21
22     MPI_Finalize();
23 }
```

```
> mpiexec -n 7 reduce
```

```
Moi, processus 0, ma valeur de la somme globale est 1021
```

Communications collectives

Réductions réparties avec diffusion du résultat : `MPI_Allreduce()`

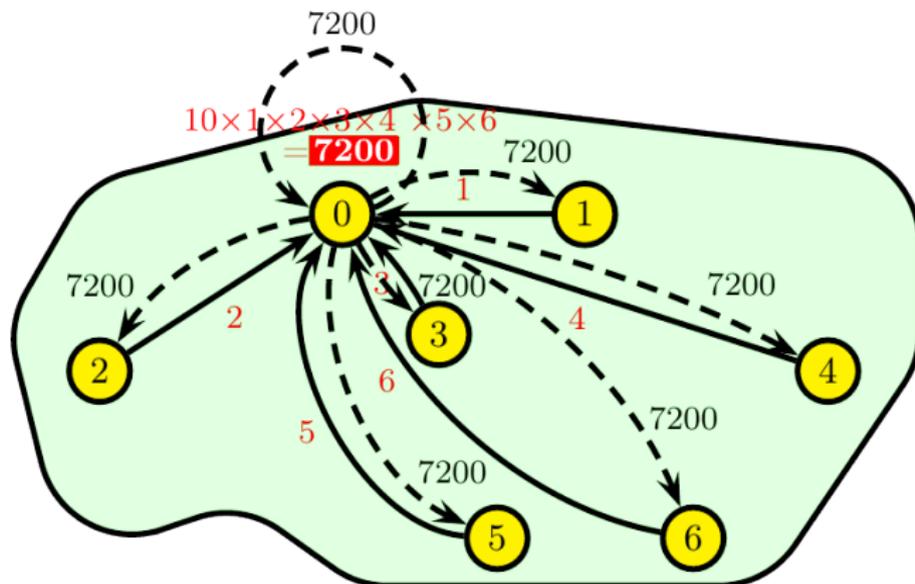


Figure 20 – Réduction répartie avec diffusion du résultat : `MPI_Allreduce` (utilisation de l'opérateur produit)

Réductions réparties avec diffusion du résultat : `MPI_Allreduce()`

```
int MPI_Allreduce(const void *message_emis, void *message_recu, int longueur,  
                 MPI_Datatype type_message, MPI_Op operation, MPI_Comm comm)
```

1. Réduction répartie des éléments situés à partir de l'adresse `message_emis`, de taille `longueur`, de type `type_message`, pour les processus du communicateur `comm`,
2. Écrit le résultat à l'adresse `message_recu` pour tous les processus du communicateur `comm`.

Exemple de `MPI_Allreduce()` (voir Fig.20)

```
1  /* allreduce */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, nb_procs, valeur, produit, i;
7
8      MPI_Init(&argc, &argv);
9      MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
10     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
11
12     if (rang == 0)
13         valeur = 10;
14     else
15         valeur = rang;
16
17     MPI_Allreduce(&valeur, &produit, 1, MPI_INT, MPI_PROD, MPI_COMM_WORLD);
18
19     printf("Moi, processus %d, ai reçu la valeur du produit globale %d\n",
20           rang, produit);
21
22     MPI_Finalize();
23 }
```

Exemple de `MPI_Allreduce()` (voir Fig.20) (suite)

```
> mpiexec -n 7 allreduce  
  
Moi, processus 6, ai recu la valeur du produit global 7200  
Moi, processus 2, ai recu la valeur du produit global 7200  
Moi, processus 0, ai recu la valeur du produit global 7200  
Moi, processus 4, ai recu la valeur du produit global 7200  
Moi, processus 5, ai recu la valeur du produit global 7200  
Moi, processus 3, ai recu la valeur du produit global 7200  
Moi, processus 1, ai recu la valeur du produit global 7200
```

Compléments

- Le sous-programme `MPI_Scan()` permet d'effectuer des réductions partielles en considérant, pour chaque processus, les processus précédents du communicateur et lui-même. `MPI_Exscan()` est la version *exclusive* de `MPI_Scan()`, qui elle est inclusive.
- Les sous-programmes `MPI_Op_create()` et `MPI_Op_free()` permettent de définir des opérations de réduction personnelles.
- Pour toutes les opérations de réduction, le mot-clé `MPI_IN_PLACE` peut être utilisé pour que les données et résultats de l'opération soient stockés au même endroit (mais uniquement pour le ou les processus qui reçoivent les résultats).
Exemple :

```
MPI_Allreduce (MPI_IN_PLACE, message_emis_et_recu, ...);
```

Compléments

- De même que ce qui a été vu pour `MPI_Gatherv()` vis-à-vis de `MPI_Gather()`, les sous-programmes `MPI_Scatterv()`, `MPI_Allgatherv()` et `MPI_Alltoallv()` étendent `MPI_Scatter()`, `MPI_Allgather()` et `MPI_Alltoall()` au cas où le nombre d'éléments à diffuser ou collecter est différent suivant les processus.
- `MPI_Alltoallw()` est la version de `MPI_Alltoallv()` permettant de traiter des éléments hétérogènes (en exprimant les déplacements en octets et non en éléments).

T.P. MPI – Exercice 3 : Communications collectives et réductions

- Il s'agit de calculer π par intégration numérique $\pi = \int_0^1 \frac{4}{1+x^2} dx$.
- On utilise la méthode des rectangles (point milieu).
- La fonction à intégrer est $f(x) = \frac{4}{1+x^2}$.
- *nbbloc* est le nombre de points.
- *largeur* = $\frac{1}{nbbloc}$ est le pas de discrétisation et la largeur de chaque rectangle.
- La version séquentielle est disponible dans le fichier `pi.c`.
- Il vous faut écrire la version parallélisée avec MPI dans ce fichier.

Modèles de communication

Modèles de communication

Modes d'envoi point à point

<i>Mode</i>	<i>Bloquant</i>	<i>Non bloquant</i>
Envoi standard	<code>MPI_Send()</code>	<code>MPI_Isend()</code>
Envoi synchrone	<code>MPI_Ssend()</code>	<code>MPI_Issend()</code>
Envoi <i>bufferisé</i>	<code>MPI_Bsend()</code>	<code>MPI_Ibsend()</code>
Réception	<code>MPI_Recv()</code>	<code>MPI_Irecv()</code>

Appels bloquants

- Un appel est **bloquant** si l'espace mémoire servant à la communication peut être réutilisé immédiatement après la sortie de l'appel.
- Les données envoyées peuvent être modifiées après l'appel bloquant.
- Les données reçues peuvent être lues après l'appel bloquant.

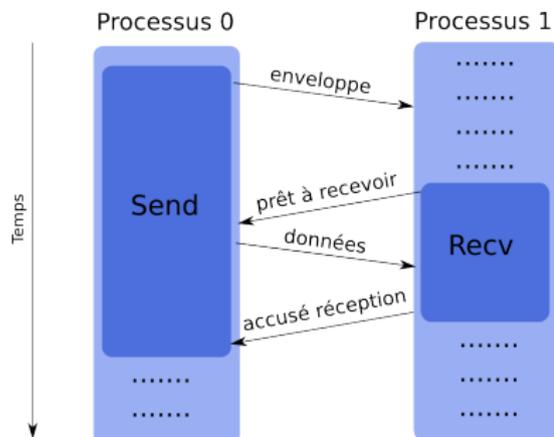
Modèles de communication

Envois synchrones

Un **envoi synchrone** implique une synchronisation entre les processus concernés. Un envoi ne pourra commencer que lorsque sa réception sera postée. Il ne peut y avoir de communication que si les deux processus sont prêts à communiquer.

Protocole de *rendez-vous*

Le protocole de *rendez-vous* est généralement celui employé pour les envois en mode synchrone (dépend de l'implémentation). L'accusé de réception est optionnel.



Modèles de communication

Interface de `MPI_Ssend()`

```
int MPI_Ssend(const void* valeurs, int taille, MPI_Datatype type_message,  
             int dest, int etiquette, MPI_Comm comm)
```

Avantages

- Consomment peu de ressources (pas de *buffer*)
- Rapides si le récepteur est prêt (pas de recopie dans un *buffer*)
- Connaissance de la réception grâce à la synchronisation

Inconvénients

- Temps d'attente si le récepteur n'est pas là/pas prêt
- Risques d'inter-blocage

Modèles de communication

Exemple d'inter-blocage

Dans l'exemple suivant, on a un inter-blocage, car on est en mode synchrone, les deux processus sont bloqués sur le `MPI_Ssend()` car ils attendent le `MPI_Recv()` de l'autre processus. Or ce `MPI_Recv()` ne pourra se faire qu'après le déblocage du `MPI_Ssend()`.

```
1  /* ssendrecv */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, num_proc, tmp, valeur;
7      int etiquette=110;
8
9      MPI_Init(&argc, &argv);
10     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
11
12     /* On suppose avoir exactement 2 processus */
13     num_proc = (rang+1)%2;
14
15     tmp = rang+1000;
16     MPI_Ssend(&tmp, 1, MPI_INT, num_proc, etiquette, MPI_COMM_WORLD);
17     MPI_Recv(&valeur, 1, MPI_INT, num_proc, etiquette, MPI_COMM_WORLD, MPI_STATUS_IGNORE);
18
19     printf("Moi, processus %d ai recu %d du processus %d\n", rang, valeur, num_proc);
20
21     MPI_Finalize();
22 }
```

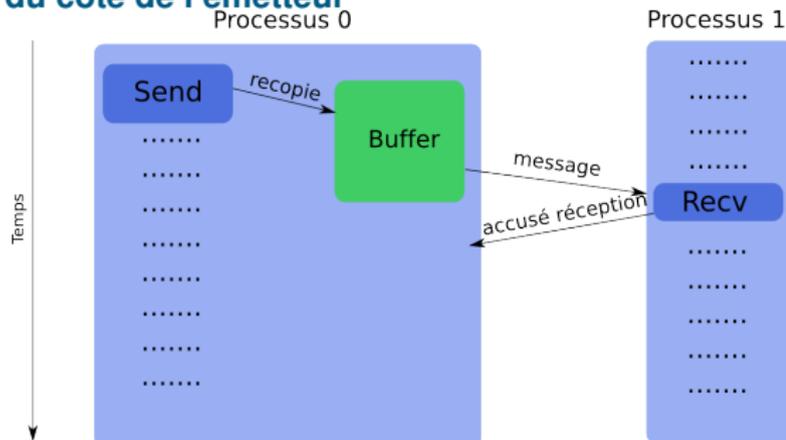
Modèles de communication

Envois *bufferisés*

Un *envoi bufferisé* implique la recopie des données dans un espace mémoire intermédiaire. Il n'y a alors pas de couplage entre les deux processus de la communication. La sortie de ce type d'envoi ne signifie donc pas que la réception a eu lieu.

Protocole avec *buffer* utilisateur du côté de l'émetteur

Dans cette approche, le *buffer* se trouve du côté de l'émetteur et est géré explicitement par l'application. Un *buffer* géré par MPI peut exister du côté du récepteur. De nombreuses variantes sont possibles. L'accusé de réception est optionnel.



Modèles de communication

Buffers

Les *buffers* doivent être gérés manuellement (avec appels à `MPI_Buffer_attach()` et `MPI_Buffer_detach()`). Ils doivent être alloués en tenant compte des surcoûts mémoire des messages (en ajoutant la constante `MPI_BSEND_OVERHEAD` pour chaque instance de message).

Interfaces

```
int MPI_Buffer_attach(void *buf, int taille_buf)
int MPI_Bsend(const void *valeurs, int taille, MPI_Datatype type_message,
              int dest, int etiquette, MPI_Comm comm)
int MPI_Buffer_detach(void *buf, int taille_buf)
```

Modèles de communication

Avantages du mode bufferisé

- Pas besoin d'attendre le récepteur (recopie dans un *buffer*)
- Pas de risque de blocage (*deadlocks*)

Inconvénients du mode bufferisé

- Consomment plus de ressources (occupation mémoire par les *buffers* avec risques de saturation)
- Les *buffers* d'envoi doivent être gérés manuellement (souvent délicat de choisir une taille adaptée)
- Un peu plus lent que les envois synchrones si le récepteur est prêt
- Pas de connaissance de la réception (découplage envoi-réception)
- Risque de gaspillage d'espace mémoire si les *buffers* sont trop sur-dimensionnés
- L'application plante si les *buffers* sont trop petits
- Il y a aussi souvent des *buffers* cachés gérés par l'implémentation MPI du côté de l'expéditeur et/ou du récepteur (et consommant des ressources mémoires)

Absence d'inter-blocage

Dans l'exemple suivant, on a pas d'inter-blocage, car on est en mode bufferisé. Une fois la copie faite dans le *buffer*, l'appel `MPI_Bsend()` retourne et on passe à l'appel `MPI_Recv()`.

```
1  /* bsendrecv */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, num_proc, tmp, valeur, taille, surcout, taille_buf;
8      int etiquette=110, nb_elt=1, nb_msg=1;
9      int * buffer;
10
11     MPI_Init (&argc, &argv);
12     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
13     MPI_Type_size (MPI_INT, &taille);
14     /* Convertir taille MPI_BSEND_OVERHEAD (octets) en nombre d'integer */
15     surcout = (int) (1+(MPI_BSEND_OVERHEAD*1.)/taille);
16     buffer = (int *) malloc (nb_msg*(nb_elt+surcout)*sizeof(int));
17     taille_buf = taille*nb_msg*(nb_elt+surcout);
18     MPI_Buffer_attach (buffer, taille_buf);
19     /* On suppose avoir exactement 2 processus */
20     num_proc = (rang+1)%2;
21     tmp = rang+1000;
22     MPI_Bsend (&tmp, nb_elt, MPI_INT, num_proc, etiquette, MPI_COMM_WORLD);
23     MPI_Recv (&valeur, nb_elt, MPI_INT, num_proc, etiquette, MPI_COMM_WORLD, MPI_STATUS_IGNORE);
24     printf("Moi, processus %d ai recu %d du processus %d\n", rang, valeur, num_proc);
25     MPI_Buffer_detach (buffer, &taille_buf);
26     MPI_Finalize (); }
```

Envois standards

Un envoi standard se fait en appelant le sous-programme `MPI_Send()`. Dans la plupart des implémentations, ce mode passe d'un mode *bufferisé* (*eager*) à un mode synchrone lorsque la taille des messages croît.

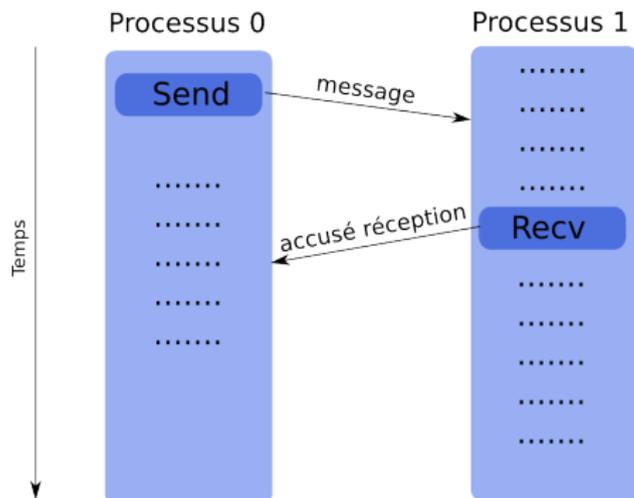
Interfaces

```
int MPI_Send(const void *valeurs, int taille, MPI_Datatype type_message,  
            int dest, int etiquette, MPI_Comm comm)
```

Modèles de communication

Protocole *eager*

Le protocole *eager* est souvent employé pour les envois en mode standard (`MPI_Send()`) pour les messages de petites tailles. Il peut aussi être utilisé pour les envois avec `MPI_Bsend()` avec des petits messages (dépend de l'implémentation) et en court-circuitant le *buffer* utilisateur du côté de l'émetteur. Dans cette approche, le *buffer* se trouve du côté du récepteur. L'accusé de réception est optionnel.



Modèles de communication

Avantages du mode standard

- Souvent le plus performant (choix du mode le plus adapté par le constructeur)

Inconvénients du mode standard

- Peu de contrôle sur le mode réellement utilisé (souvent accessible via des variables d'environnement)
- Risque de *deadlock* selon le mode réel
- Comportement pouvant varier selon l'architecture et la taille du problème

Modèles de communication

Présentation

Le recouvrement des communications par des calculs est une méthode permettant de réaliser des opérations de communications en arrière-plan pendant que le programme continue de s'exécuter. Sur Jean Zay, la latence d'une communication inter-nœud est de $1\mu s$ soit 2500 cycles processeur.

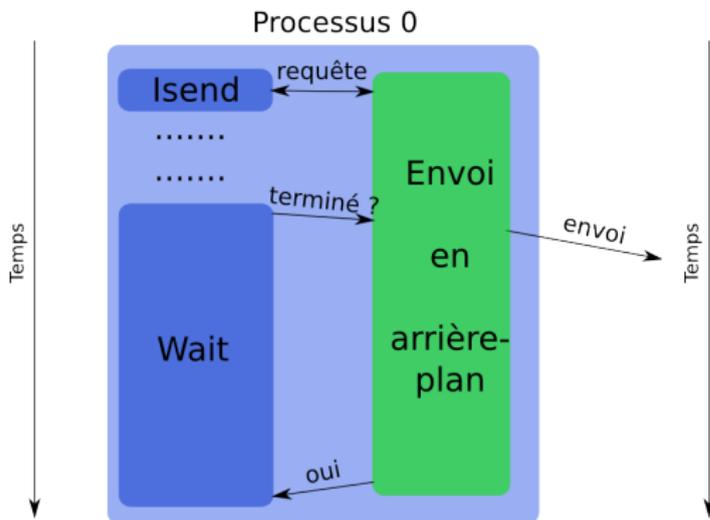
- Il est ainsi possible, si l'architecture matérielle et logicielle le permet, de masquer tout ou une partie des coûts de communications.
- Le recouvrement calculs-communications peut être vu comme un niveau supplémentaire de parallélisme.
- Cette approche s'utilise dans MPI par l'utilisation de sous-programmes non-bloquants (i.e. `MPI_Isend()`, `MPI_Irecv()` et `MPI_Wait()`).

Appels non bloquants

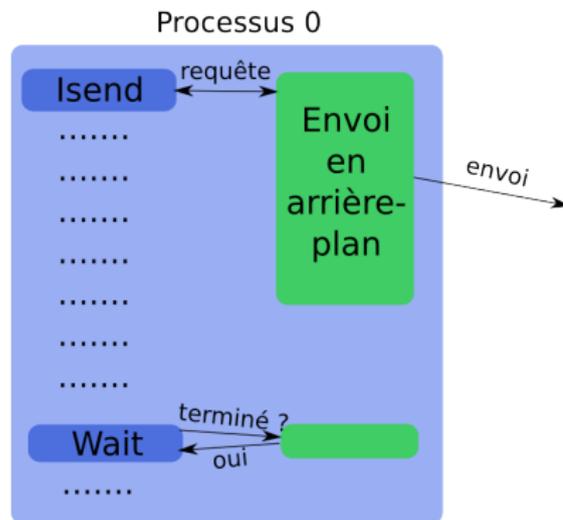
Un appel **non bloquant** rend la main très rapidement, mais n'autorise pas la réutilisation immédiate de l'espace mémoire utilisé dans la communication. Il est nécessaire de s'assurer que la communication est bien terminée (avec `MPI_Wait()` par exemple) avant de l'utiliser à nouveau.

Modèles de communication

Recouvrement partiel



Recouvrement total



Modèles de communication

Avantages des appels non bloquants

- Possibilité de masquer tout ou une partie des coûts des communications (si l'architecture le permet)
- Pas de risques de *deadlock*

Inconvénients des appels non bloquants

- Surcoûts plus importants (plusieurs appels pour un seul envoi ou réception, gestion des requêtes)
- Complexité plus élevée et maintenance plus compliquée
- Peu performant sur certaines machines (par exemple avec transfert commençant seulement à l'appel de `MPI_Wait()`)
- Risque de perte de performance sur les noyaux de calcul (par exemple gestion différenciée entre la zone proche de la frontière d'un domaine et la zone intérieure entraînant une moins bonne utilisation des caches mémoires)
- Limité aux communications point à point (a été étendu aux collectives dans MPI 3.0)

Interfaces

`MPI_Isend()` `MPI_Issend()` et `MPI_Ibsend()` pour les envois non bloquants

```
int MPI_Isend(const void*valeurs, int taille, MPI_Datatype type_message,
              int dest, int etiquette, MPI_Comm comm, MPI_Request *req)
int MPI_Issend(const void*valeurs, int taille, MPI_Datatype type_message,
               int dest, int etiquette, MPI_Comm comm, MPI_Request *req)
int MPI_Ibsend(const void*valeurs, int taille, MPI_Datatype type_message,
               int dest, int etiquette, MPI_Comm comm, MPI_Request *req)
```

`MPI_Irecv()` pour les réceptions non bloquantes.

```
int MPI_Irecv(void *valeurs, int taille, MPI_Datatype type_message, int source,
              int etiquette, MPI_Comm comm, MPI_Request *req)
```

Modèles de communication

Interfaces

`MPI_Wait()` attend la fin d'une communication. `MPI_Test()` est la version non bloquante.

```
int MPI_Wait(MPI_Request *req, MPI_Status *statut)
int MPI_Test(MPI_Request *req, int *flag, MPI_Status *statut)
```

`MPI_Waitall()` attend la fin de toutes les communications. `MPI_Testall()` est la version non bloquante.

```
int MPI_Waitall(int taille, MPI_Request reqs[], MPI_Status statuts[])
int MPI_Testall(int taille, MPI_Request reqs[], int *flag, MPI_Status statuts[])
```

Interfaces

`MPI_Waitany()` attend la fin d'une communication parmi plusieurs.

`MPI_Testany()` est la version non bloquante.

```
int MPI_Waitany(int taille, MPI_Request reqs[], int *indice, MPI_Status *statut)
int MPI_Testany(int taille, MPI_Request reqs[], int *indice, int *flag, MPI_Status *statut)
```

`MPI_Waitsome()` attend la fin d'une ou plusieurs communications.

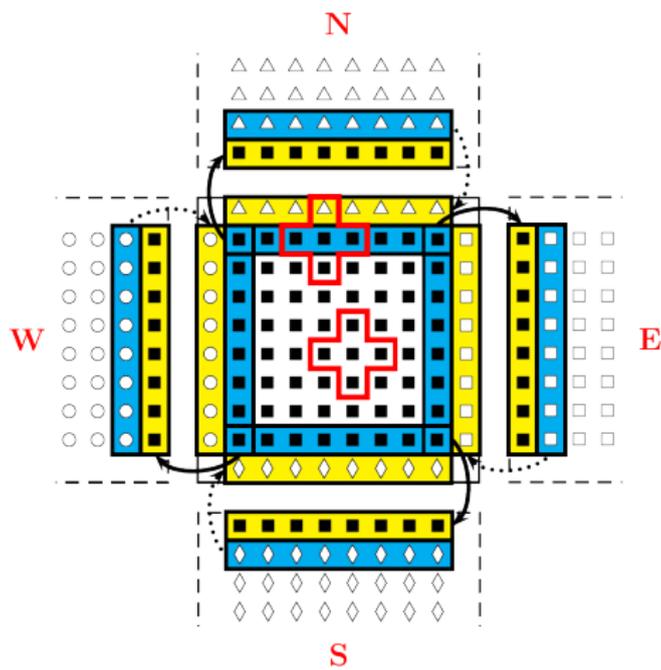
`MPI_Testsome()` est la version non bloquante.

```
int MPI_Waitsome(int taille, MPI_Request reqs[], int *nbfin, int *indices, MPI_Status *statuts)
int MPI_Testsome(int taille, MPI_Request reqs[], int *nbfin, int *indices, MPI_Status *statuts)
```

Gestion des requêtes

- Après un appel aux fonctions bloquantes d'attente (`MPI_Wait()`, `MPI_Waitall()`,...), la requête vaut `MPI_REQUEST_NULL`.
- De même après un appel aux fonctions non bloquantes d'attente lorsque le *flag* est à vrai.
- Une attente avec une requête qui vaut `MPI_REQUEST_NULL` ne fait rien.

Modèles de communication



Modèles de communication

```
1 void debut_communication(double *u) {
2     /* Envoi au voisin N et reception du voisin S */
3     MPI_Irecv(&(u[0]), 1, type_ligne, voisin[S], etiquette, comm2d, &(requete[0]));
4     MPI_Isend(&(u[0]), 1, type_ligne, voisin[N], etiquette, comm2d, &(requete[1]));
5
6     /* Envoi au voisin S et reception du voisin N */
7     MPI_Irecv(&(u[1]), 1, type_ligne, voisin[N], etiquette, comm2d, &(requete[2]));
8     MPI_Isend(&(u[1]), 1, type_ligne, voisin[S], etiquette, comm2d, &(requete[3]));
9
10    /* Envoi au voisin W et reception du voisin E */
11    MPI_Irecv(&(u[2]), 1, type_colonne, voisin[E], etiquette, comm2d, &(requete[4]));
12    MPI_Isend(&(u[2]), 1, type_colonne, voisin[W], etiquette, comm2d, &(requete[5]));
13
14    /* Envoi au voisin E et reception du voisin W */
15    MPI_Irecv(&(u[3]), 1, type_colonne, voisin[W], etiquette, comm2d, &(requete[6]));
16    MPI_Isend(&(u[3]), 1, type_colonne, voisin[E], etiquette, comm2d, &(requete[7]));
17 }
18 void fin_communication(double *u) {
19     MPI_Waitall(2*NB_VOISINS, requete, tab_statut);
20 }
```

Modèles de communication

```
1 while(!(convergence) && (it < it_max) ) {
2   it = it+1;
3   /* Echanges des pointeurs */
4   temp = u; u = u_nouveau; u_nouveau = temp;
5
6   debut_communication(u);
7   calcul(u,u_nouveau, sx+1, ex-1, sy+1, ey-1);
8   fin_communication(u);
9
10  /* Nord */
11  calcul(u,u_nouveau,sx,sx,sy,ey);
12  /* Sud */
13  calcul(u,u_nouveau,ex,ex,sy,ey);
14  /* Ouest */
15  calcul(u,u_nouveau,sx,ex,sy,sy);
16  /* Est */
17  calcul(u,u_nouveau,sx,ex,ey,ey);
18
19  /* Calcul de l'erreur globale */
20  diffnorm = erreur_globale (u, u_nouveau);
21
22  /* Arrêt du programme si on a atteint la precision machine obtenue */
23  convergence = (diffnorm < eps);
24 }
```

Modèles de communication

Niveau de recouvrement sur différentes machines

<i>Machine</i>	<i>Niveau</i>
Zay(IntelMPI)	43%
Zay(IntelMPI) I_MPI_ASYNC_PROGRESS=yes	95%

Mesures faites en recouvrant un noyau de calcul et un noyau de communication de mêmes durées.

Un recouvrement de 0% signifie que la durée totale d'exécution vaut 2x la durée d'un noyau de calcul (ou communication).

Un recouvrement de 100% signifie que la durée totale vaut 1x la durée d'un noyau de calcul (ou communication).

Nombre d'éléments reçus

```
int MPI_Recv(void *message, int longueur, MPI_Datatype type_message,  
            int rang_source, int etiquette, MPI_Comm comm, MPI_Status *statut)
```

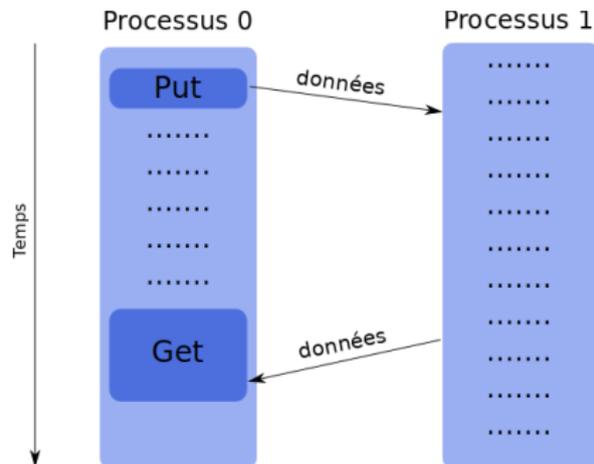
- Dans l'appel à `MPI_Recv()` ou `MPI_Irecv()`, l'argument `longueur` correspond dans la norme au nombre d'éléments dans le buffer `message`.
- Ce nombre doit être supérieur au nombre d'éléments à recevoir.
- Quand c'est possible, pour des raisons de lisibilité, il est conseillé de mettre le nombre d'éléments à recevoir.
- On peut connaître le nombre d'éléments reçus avec `MPI_Get_count()` et à l'aide de l'argument `statut` retourné par l'appel à `MPI_Recv()` ou `MPI_Wait()`.

```
int MPI_Get_count(MPI_Status *statut, MPI_Datatype type_message, int *longueur)
```

Modèles de communication

Communications mémoire à mémoire (RMA)

Les communications mémoire à mémoire (ou RMA pour *Remote Memory Access* ou *one sided communications*) consistent à accéder en écriture ou en lecture à la mémoire d'un processus distant sans que ce dernier doive gérer cet accès explicitement. Le processus cible n'intervient donc pas lors du transfert.



Modèles de communication

RMA - Approche générale

- Création d'une fenêtre mémoire avec `MPI_Win_create()` pour autoriser les transferts RMA dans cette zone.
- Accès distants en lecture ou écriture en appelant `MPI_Put()`, `MPI_Get()` ou `MPI_Accumulate()`.
- Libération de la fenêtre mémoire avec `MPI_Win_free()`.

RMA - Méthodes de synchronisation

Pour s'assurer d'un fonctionnement correct, il est obligatoire de réaliser certaines synchronisations. 3 méthodes sont disponibles :

- Communication à cible active avec synchronisation globale (`MPI_Win_fence()`);
- Communication à cible active avec synchronisation par paire (`MPI_Win_start()` et `MPI_Win_complete()` pour le processus origine; `MPI_Win_post()` et `MPI_Win_wait()` pour le processus cible);
- Communication à cible passive sans intervention de la cible (`MPI_Win_lock()` et `MPI_Win_unlock()`).

Modèles de communication

```
1  /* ex_fence */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, taille_reel, i;
8      int n=4, m=4, cible, nb_elements;
9      MPI_Aint dim_win, deplacement;
10     double *win_local, *tab, sum;
11     MPI_Win win;
12     int assert=0;
13
14     MPI_Init (&argc, &argv);
15     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
16     MPI_Type_size (MPI_DOUBLE, &taille_reel);
17
18     if (rang == 0 ) {
19         n = 0;
20         tab = (double *) malloc(m*sizeof(double)); }
21
22     win_local = (double *) malloc(n*sizeof(double));
23     dim_win = taille_reel*n;
24
25     MPI_Win_create (win_local, dim_win, taille_reel, MPI_INFO_NULL, MPI_COMM_WORLD, &win);
```

Modèles de communication

```
26  if (rang == 0) {
27      for(i=0;i<m;i++) tab[i]=i+1;
28  } else {
29      for(i=0;i<n;i++) win_local[i]=0.0;
30  }
31
32  MPI_Win_fence (assert,win);
33  if (rang == 0) {
34      cible = 1; nb_elements = 2; deplacement = 1;
35      MPI_Put (tab,nb_elements,MPI_DOUBLE,cible,
36              deplacement,nb_elements,MPI_DOUBLE,win);}
37
38  MPI_Win_fence (assert,win);
39  sum = 0.;
40  if (rang == 0) {
41      for (i=0;i<m-1;i++) sum=sum+tab[i];
42      tab[m-1] = sum;
43  } else {
44      for (i=0;i<n-1;i++) sum=sum+win_local[i];
45      win_local[n-1] = sum; }
46
47  MPI_Win_fence (assert,win);
48  if (rang == 0) {
49      nb_elements=1;deplacement=m-1;
50      MPI_Get (tab,nb_elements,MPI_DOUBLE,cible,
51              deplacement,nb_elements,MPI_DOUBLE,win);}

```

Modèles de communication

Avantages des RMA

- Permet de mettre en place plus efficacement certains algorithmes.
- Plus performant que les communications point à point sur certaines machines (utilisation de matériels spécialisés tels que moteur DMA, coprocesseur, mémoire spécialisée...).
- Possibilité pour l'implémentation de regrouper plusieurs opérations.

Inconvénients des RMA

- La gestion des synchronisations est délicate.
- Complexité et risques d'erreurs élevés.
- Pour les synchronisations cible passive, obligation d'allouer la mémoire avec `MPI_Alloc_mem()` qui ne respecte pas la norme Fortran (utilisation de pointeurs Cray non supportés par certains compilateurs).
- Moins performant que les communications point à point sur certaines machines.

Types de données dérivés

Types de données dérivés

Introduction

- 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_indexed()` ou `MPI_Type_create_struct()`.
- Les types dérivés permettent notamment l'échange de données non contiguës ou non homogènes en mémoire et de limiter le nombre d'appels aux sous-programmes de communications.

Types de données dérivés

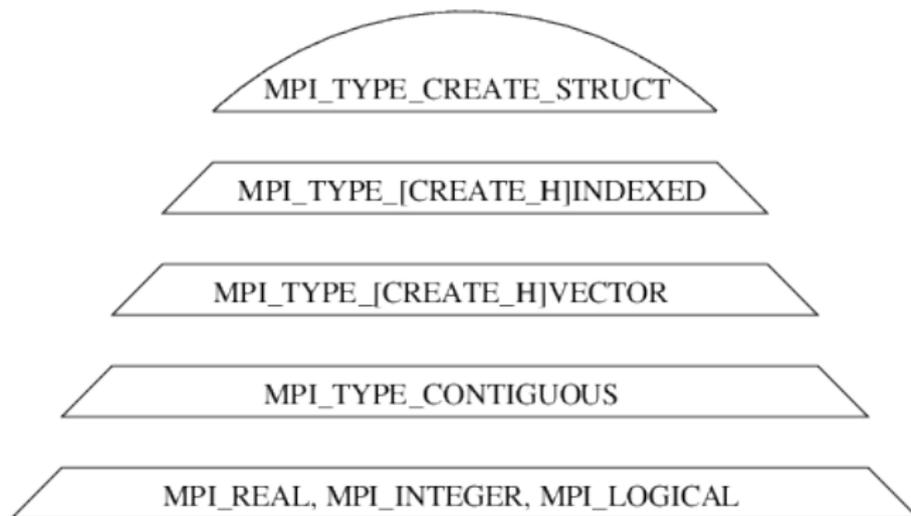


Figure 21 – Hiérarchie des constructeurs de type MPI

Types de données dérivés

Types contigus

- `MPI_Type_contiguous()` crée une structure de données à partir d'un ensemble homogène de type préexistant de données contiguës en mémoire.

1.	6.	11.	16.	21.	26.
2.	7.	12.	17.	22.	27.
3.	8.	13.	18.	23.	28.
4.	9.	14.	19.	24.	29.
5.	10.	15.	20.	25.	30.

```
MPI_Type_contiguous(6, MPI_FLOAT, &nouveau_type);
```

Figure 22 – Sous-programme `MPI_Type_contiguous`

```
int MPI_Type_contiguous(int nombre, MPI_Datatype ancien_type, MPI_Datatype *nouveau_type)
```

Types de données dérivés

Types avec un pas constant

- `MPI_Type_vector()` crée une structure de données à partir d'un ensemble homogène de type préexistant de données distantes d'un pas constant en mémoire. Le pas est donné en nombre d'éléments.

1.	6.	11.	16.	21.	26.
2.	7.	12.	17.	22.	27.
3.	8.	13.	18.	23.	28.
4.	9.	14.	19.	24.	29.
5.	10.	15.	20.	25.	30.

```
MPI_Type_vector(5,1,6,MPI_FLOAT,&nouveau_type);
```

Figure 23 – Sous-programme `MPI_Type_vector`

```
int MPI_Type_vector(int nombre,int nbr_elt_par_bloc,int pas,  
MPI_Datatype type_elt,MPI_Datatype *nouveau_type)
```

Types de données dérivés

Types avec un pas constant

- `MPI_Type_create_hvector()` crée une structure de données à partir d'un ensemble homogène de type préexistant de données distantes d'un pas constant en mémoire. Le pas est donné en nombre d'octets.
- Cette instruction est utile lorsque le type générique n'est plus un type de base (`MPI_INT`, `MPI_FLOAT`, ...) mais un type plus complexe construit à l'aide des sous-programmes MPI, parce qu'alors le pas ne peut plus être exprimé en nombre d'éléments du type générique.

```
int MPI_Type_create_hvector(int nombre_bloc, int nbr_elt_par_bloc, MPI_Aint pas,
                           MPI_Datatype type_elt, MPI_Datatype *nouveau_type)
```

Types de données dérivés

Validation des types de données dérivés

- Les types dérivés doivent être validés avant d'être utilisés dans une communication. La validation s'effectue à l'aide du sous-programme `MPI_Type_commit()`.

```
int MPI_Type_commit (MPI_Datatype *nouveau_type)
```

- Si on souhaite réutiliser le même nom pour définir un autre type dérivé, on doit au préalable le libérer en utilisant le sous-programme `MPI_Type_free()`.

```
int MPI_Type_free (MPI_Datatype *nouveau_type)
```

Types de données dérivés

```
1  /* ligne */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, i, j;
8      int nb_lignes=5, nb_colonnes=6, etiquette=100;
9      float a[nb_lignes][nb_colonnes];
10     MPI_Datatype type_ligne;
11     MPI_Status statut;
12
13     MPI_Init (&argc, &argv);
14     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
15
16     /* Initialisation de la matrice sur chaque processus */
17     for (i=0; i<nb_lignes; i++)
18         for (j=0; j<nb_colonnes; j++)
19             a[i][j]=rang;
20
21     /* Definition du type type_ligne */
22     MPI_Type_contiguous (nb_colonnes, MPI_FLOAT, &type_ligne);
23
24     /* Validation du type type_ligne */
25     MPI_Type_commit (&type_ligne);
```

Types de données dérivés

```
26  /* Envoi de la premiere colonne */
27  if (rang == 0) {
28      MPI_Send(a,1,type_ligne,1,etiquette,MPI_COMM_WORLD);
29  } else {
30      MPI_Recv(&a[nb_lignes-1][0],1,type_ligne,0,etiquette,
31              MPI_COMM_WORLD,&statut); }
32
33  /* Libere le type */
34  MPI_Type_free(&type_ligne);
35
36  MPI_Finalize();
37  }
```

Types de données dérivés

```
1  /* colonne */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, i, j;
8      int nb_lignes=5, nb_colonnes=6, etiquette=100;
9      float a[nb_lignes][nb_colonnes];
10     MPI_Datatype type_colonne;
11     MPI_Status statut;
12
13     MPI_Init(&argc, &argv);
14     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
15
16     /* Initialisation de la matrice sur chaque processus */
17     for(i=0; i<nb_lignes; i++)
18         for(j=0; j<nb_colonnes; j++)
19             a[i][j]=rang;
20
21     /* Definition du type type_colonne */
22     MPI_Type_vector(nb_lignes, 1, nb_colonnes, MPI_FLOAT, &type_colonne);
23
24     /* Validation du type type_colonne */
25     MPI_Type_commit(&type_colonne);
```

Types de données dérivés

```
26  /* Envoi de la premiere colonne */
27  if (rang == 0) {
28      MPI_Send (&a[1][0], 1, type_colonne, 1, etiquette, MPI_COMM_WORLD);
29  } else {
30      MPI_Recv (&a[nb_lignes-2][0], 1, type_colonne, 0, etiquette,
31              MPI_COMM_WORLD, &statut); }
32
33  /* Libere le type type_colonne */
34  MPI_Type_free (&type_colonne);
35
36  MPI_Finalize ();
37  }
```

Types de données dérivés

```
1  /* bloc */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, i, j;
8      int nb_lignes=5, nb_colonnes=6, etiquette=100;
9      int nb_lignes_bloc=2, nb_colonnes_bloc=3;
10     float a[nb_lignes][nb_colonnes];
11     MPI_Datatype type_bloc;
12     MPI_Status statut;
13
14     MPI_Init(&argc, &argv);
15     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
16
17     /* Initialisation de la matrice sur chaque processus */
18     for(i=0; i<nb_lignes; i++)
19         for(j=0; j<nb_colonnes; j++)
20             a[i][j]=rang;
21
22     /* Definition du type type_bloc */
23     MPI_Type_vector(nb_lignes_bloc, nb_colonnes_bloc, nb_colonnes,
24                   MPI_FLOAT, &type_bloc);
25
26     /* Validation du type type_bloc */
27     MPI_Type_commit(&type_bloc);
```

Types de données dérivés

```
28  /* Envoi d'un bloc */
29  if (rang == 0) {
30      MPI_Send(a,1,type_bloc,1,etiquette,MPI_COMM_WORLD);
31  } else {
32      MPI_Recv(&a[nb_lignes-2][nb_colonnes-3],1,type_bloc,0,etiquette,
33              MPI_COMM_WORLD,&statut); }
34
35  /* Libere du type type_bloc */
36  MPI_Type_free(&type_bloc);
37
38  MPI_Finalize();
39  }
```

Types de données dérivés

Types homogènes à pas variable

- `MPI_Type_indexed()` permet de créer une structure de données composée d'une séquence de blocs contenant un nombre variable d'éléments et séparés par un pas variable en mémoire. Ce dernier est exprimé en `éléments`.
- `MPI_Type_create_hindexed()` a la même fonctionnalité que `MPI_Type_indexed()` sauf que le pas séparant deux blocs de données est exprimé en `octets`.
Cette instruction est utile lorsque le type générique n'est pas un type de base MPI (`MPI_INT`, `MPI_FLOAT`, ...) mais un type plus complexe construit avec les sous-programmes MPI vus précédemment. On ne peut exprimer alors le pas en nombre d'éléments du type générique d'où le recours à `MPI_Type_create_hindexed()`.
- Pour `MPI_Type_create_hindexed()`, comme pour `MPI_Type_create_hvector()`, utilisez `MPI_Type_size()` ou `MPI_Type_get_extent()` pour obtenir de façon portable la taille du pas en nombre d'octets.

Types de données dérivés

nb=3, longueurs_blocs=(2,1,3), déplacements=(0,3,7)

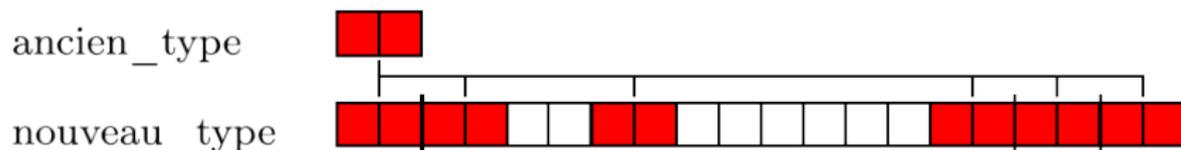


Figure 24 – Le constructeur `MPI_Type_indexed`

```
int MPI_Type_indexed(int nb, const int longueurs_blocs[], const int déplacements[],  
                    MPI_Datatype ancien_type, MPI_Datatype *nouveau_type)
```

Types de données dérivés

nb=4, longueurs_blocs=(2,1,2,1), déplacements=(2,10,14,24)

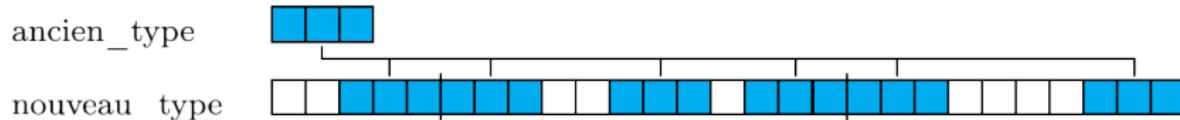


Figure 25 – Le constructeur `MPI_Type_create_hindexed`

```
int MPI_Type_create_hindexed(int nb, const int longueurs_blocs[],  
                             const MPI_Aint déplacements,  
                             MPI_Datatype ancien_type,  
                             MPI_Datatype *nouveau_type)
```

Types de données dérivés

Exemple : matrice triangulaire

Dans l'exemple suivant, chacun des deux processus :

1. initialise sa matrice (nombres croissants positifs sur le processus 0 et négatifs décroissants sur le processus 1) ;
2. construit son type de données (*datatype*) : matrice triangulaire (supérieure pour le processus 0 et inférieure pour le processus 1) ;
3. envoie sa matrice triangulaire à l'autre et reçoit une matrice triangulaire qu'il stocke à la place de celle qu'il a envoyée. Cela se fait avec l'instruction `MPI_Sendrecv_replace()` ;
4. libère ses ressources et quitte MPI.

Types de données dérivés

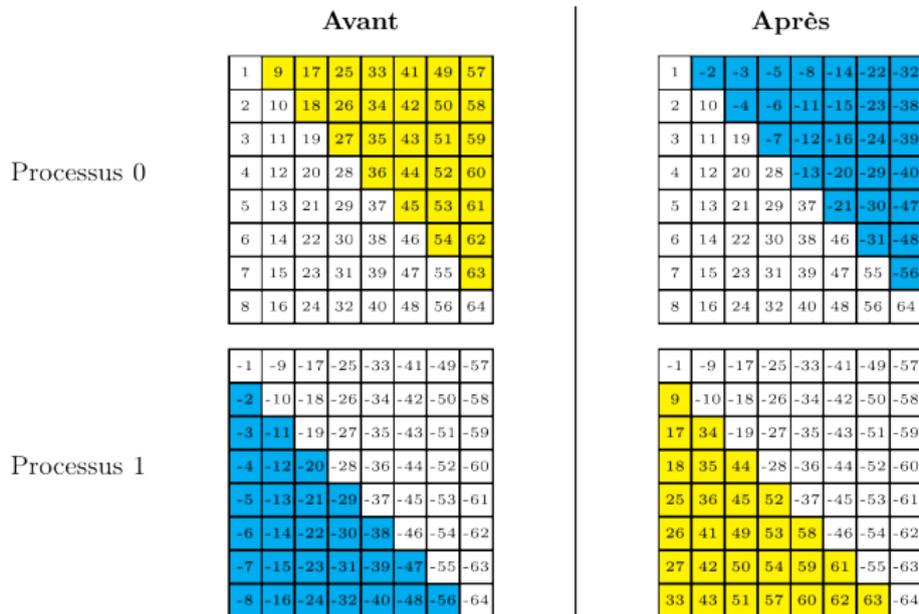


Figure 26 – Échanges entre les 2 processus

Types de données dérivés

```
1  /* triangle */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, i, j;
8      int n=8, etiquette=100, sign=1;
9      float a[n][n];
10     MPI_Datatype type_triangle;
11     MPI_Status statut;
12     int longueurs_blocs[n], deplacements[n];
13
14     MPI_Init(&argc, &argv);
15     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
16
17     /* Initialisation de la matrice sur chaque processus */
18     if (rang == 1) sign=-1;
19     for (i=0; i<n; i++)
20         for (j=0; j<n; j++)
21             a[i][j]=sign*(1+i+n*j);
22
23     /* Creation du type matrice triangulaire sup pour le processus 0
24     et du type matrice triangulaire inferieure pour le processus 1 */
25     if (rang == 0) {
26         for (i=0; i<n; i++) longueurs_blocs[i] = n-i-1;
27         for (i=0; i<n; i++) deplacements[i] = (n+1)*i+1;
28     } else {
29         for (i=0; i<n; i++) longueurs_blocs[i] = i;
30         for (i=0; i<n; i++) deplacements[i] = n*i;
31     }
32
33     MPI_Type_indexed(n, longueurs_blocs, deplacements, MPI_FLOAT, &type_triangle);
34     MPI_Type_commit(&type_triangle);
35
36     /* Permutation des matrices triangulaires superieure et inferieure */
37     MPI_Sendrecv_replace(a, 1, type_triangle, (rang+1)%2, etiquette,
38                         (rang+1)%2, etiquette, MPI_COMM_WORLD, &statut);
39
40     /* Liberation du type triangle */
41     MPI_Type_free(&type_triangle);
42     MPI_Finalize();
43 }
```

Types de données dérivés

Taille des types de données

- `MPI_Type_size()` retourne le nombre d'octets nécessaire pour envoyer un type de données. Cette valeur ne tient pas compte des *trous* présents dans le type de données.

```
int MPI_Type_size(MPI_Datatype type_message, int *taille)
```

- L'étendue d'un type est l'espace mémoire occupé par le type (en octets). Cette valeur intervient directement pour calculer la position du prochain élément en mémoire (c'est-à-dire le **pas** entre des éléments successifs).

```
int MPI_Type_get_extent(MPI_Datatype type_message, MPI_Aint *borne_inf,  
                        MPI_Aint *etendue)
```

Types de données dérivés

Exemple 1 : `MPI_Type_indexed`(2, {2, 1}, {1, 4}, `MPI_INT`, &type)

Type dérivé :



Deux éléments successifs :

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

taille = 12 (3 entiers); borne_inf = 4 (1 entier); etendue = 16 (4 entiers)

Exemple 2 : `MPI_Type_vector`(3, 1, nb_colonnes, `MPI_INT`, &type_demi_colonne)

Vue 2D :

1	6	11	16	21	26
2	7	12	17	22	27
3	8	13	18	23	28
4	9	14	19	24	29
5	10	15	20	25	30

Vue 1D :

1	6	11	16	21	26	2	7	12	17	22	27	3	8
---	---	----	----	----	----	---	---	----	----	----	----	---	---

taille = 12 (3 entiers); borne_inf = 0; etendue = 44 (11 entiers)

Types de données dérivés

Changer l'étendue

- L'étendue est un paramètre du type de données. Par défaut, c'est généralement l'intervalle en mémoire entre le premier et le dernier composant du type (bornes incluses et en tenant compte de l'alignement mémoire). On peut modifier l'étendue d'un type pour créer un nouveau type adapté du précédent avec `MPI_Type_create_resized()`. Cela permet de choisir le pas entre des éléments successifs.

```
int MPI_Type_create_resized(MPI_Datatype ancien_type, MPI_Aint nouvelle_borne_inf,  
                           MPI_Aint nouvelle_etendue, MPI_Datatype *nouveau_type)
```

Types de données dérivés

```
1  /* demi_colonne */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, i, j, taille_integer;
8      int nb_lignes=5, nb_colonnes=6, etiquette=100, sign=1;
9      int taille_demi_colonne=nb_lignes/2;
10     int a[nb_lignes][nb_colonnes];
11     MPI_Datatype type_demi_colonne1, type_demi_colonne2;
12     MPI_Status statut;
13     MPI_Aint borne_inf1, etendue1, borne_inf2, etendue2;
14
15     MPI_Init (&argc, &argv);
16     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
17
18     /* Initialisation de la matrice sur chaque processus */
19     if (rang == 1) sign=-1;
20     for (i=0; i<nb_lignes; i++)
21         for (j=0; j<nb_colonnes; j++)
22             a[i][j]=sign*(1+i+nb_lignes*j);
23
24     /* Construction du type derive type_demi_colonne1 */
25     MPI_Type_vector (taille_demi_colonne, 1, nb_colonnes, MPI_INT, &type_demi_colonne1);
26
27     /* Connaître la taille du type de base MPI_INT */
28     MPI_Type_size (MPI_INT, &taille_integer);
29
30     /* Informations sur le type type_demi_colonne1 */
31     MPI_Type_get_extent (type_demi_colonne1, &borne_inf1, &etendue1);
32     if (rang == 0) printf("Type_demi_colonne1: borne_inf=%d etendue %d\n",
33                          borne_inf1, etendue1);
34
35     /* Construction du type type_demi_colonne2 */
36     borne_inf2 = 0;
37     etendue2 = taille_integer;
38     MPI_Type_create_resized (type_demi_colonne1, borne_inf2, etendue2,
39                             &type_demi_colonne2);
```

Types de données dérivés

```
40 /* Information sur le type type_demi_colonne2 */
41 MPI_Type_get_extent (type_demi_colonne2, &borne_inf2, &etendue2);
42 if (rang == 0) printf("Type_demi_colonne2: borne_inf=%d etendue %d\n",
43                     borne_inf2, etendue2);
44
45 /* Validation du type */
46 MPI_Type_commit (&type_demi_colonne2);
47
48 if (rang == 0) {
49     /* Envoi de la matrice a au processus 1 avec le type demi_colonne2 */
50     MPI_Send (a, 2, type_demi_colonne2, 1, etiquette, MPI_COMM_WORLD);
51 } else {
52     /* Reception pour le processus 1 dans la matrice a */
53     MPI_Recv (&(a[nb_lignes-2][1]), 4, MPI_INT, 0, etiquette, MPI_COMM_WORLD, &statut);
54     printf("Matrice A sur le processus 1\n");
55     for(i=0; i<nb_lignes; i++) {
56         for(j=0; j<nb_colonnes; j++)
57             printf("%d ", a[i][j]);
58         printf("\n"); } }
59
60 MPI_Finalize ();
61 }
```

```
> mpiexec -n 2 demi_ligne
type_demi_ligne1: borne_inf=0, etendue=28
type_demi_ligne2: borne_inf=0, etendue=4
```

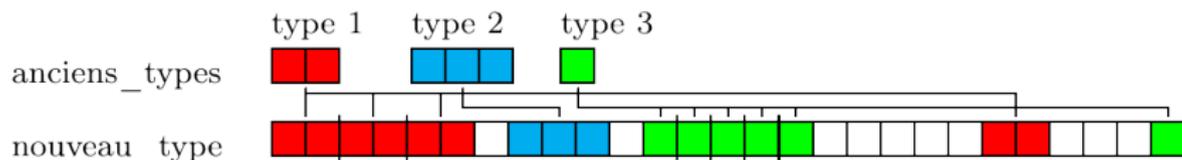
```
Matrice A sur le processus 1
-1 -6 -11 -16 -21 -26
-2 -7 -12 -17 -22 -27
-3 -8 -13 -18 -23 -28
-4 1 2 6 7 -29
-5 -10 -15 -20 -25 -30
```

Types de données dérivés

Types hétérogènes

- Le sous-programme `MPI_Type_create_struct()` permet de créer une séquence de blocs de données en précisant le **type**, le **nombre d'éléments** et le **pas** de chaque bloc.
- Il s'agit du constructeur de types le plus complet. Il généralise `MPI_Type_indexed()` en permettant de définir un **type** différent pour chaque bloc.

`nb=5`, `longueurs_blocs=(3,1,5,1,1)`, `déplacements=(0,7,11,21,26)`,
`anciens_types=(type1,type2,type3,type1,type3)`



```
int MPI_Type_create_struct(int nb, const int longueurs_blocs[], const MPI_Aint déplacements[],  
                          const MPI_Datatype anciens_types[], MPI_Datatype *nouveau_type)
```

Types de données dérivés

Calcul des déplacements

- `MPI_Type_create_struct()` est utile notamment pour créer des types MPI correspondant à des types dérivés Fortran ou à des structures C.
- L'alignement en mémoire des structures de données hétérogènes dépend de l'architecture et du compilateur.
- Le déplacement entre deux composants d'un type dérivé Fortran ou d'une structure C peut-être obtenu en calculant la différence entre leurs adresses mémoires.
- Le sous-programme `MPI_Get_address()` permet de récupérer l'adresse d'une variable. C'est l'équivalent de l'opérateur de référencement (&) du C.
- Attention, même en C, il est préférable d'utiliser ce sous-programme MPI pour des raisons de portabilité.
- Attention, il faut corriger l'étendue du type MPI obtenu.

```
int MPI_Get_address(const void *variable, MPI_Aint *adresse_variable)
```

Types de données dérivés

```
1  /* Interaction_Particules */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5  #include <stdbool.h>
6
7  struct Particule {
8      char categorie[5];
9      int masse;
10     float coords[3];
11     bool classe;
12 };
13
14 int main(int argc, char *argv[]) {
15     int rang, i;
16     int n=1000, etiquette=100;
17     int longueurs_blocs[4];
18     MPI_Datatype types[4], type_particule, temp;
19     MPI_Status statut;
20     MPI_Aint adresses[5], deplacements[5], lb, extent;
21     struct Particule p[n], temp_p[n];
22
23     MPI_Init(&argc, &argv);
24     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
25
26     /* Construction du type de donnees */
27     types[0] = MPI_CHARACTER; types[1] = MPI_INT;
28     types[2] = MPI_FLOAT; types[3] = MPI_LOGICAL;
29     longueurs_blocs[0]=5; longueurs_blocs[1]=1;
30     longueurs_blocs[2]=3; longueurs_blocs[3]=1;
```

Types de données dérivés

```
31 MPI_Get_address (&(p[0].categorie), &(adresses[0]));
32 MPI_Get_address (&(p[0].masse), &(adresses[1]));
33 MPI_Get_address (&(p[0].coords), &(adresses[2]));
34 MPI_Get_address (&(p[0].classe), &(adresses[3]));
35 /* Calcul des déplacements relatifs a l'adresse de depart */
36 for (i=0;i<4;i++) déplacements[i] = adresses[i]-adresses[0];
37 MPI_Type_create_struct (4, longueurs_blocs, déplacements, types, &temp);
38 MPI_Get_address (&(p[1].categorie), &(adresses[4]));
39 lb=0;
40 extent = adresses[4]-adresses[0];
41 MPI_Type_create_resized (temp, lb, extent, &type_particule);
42 /* Validation du type structure */
43 MPI_Type_commit (&type_particule);
44
45 /* Initialisation des particules pour chaque processus */
46
47 /* Envoi des particules de 0 vers 1 */
48 if (rang == 0) {
49     MPI_Send (&(p[0].categorie), n, type_particule, 1, etiquette, MPI_COMM_WORLD);
50 } else {
51     MPI_Recv (&(temp_p[0].categorie), n, type_particule, 0, etiquette,
52             MPI_COMM_WORLD, &statut);
53 }
54
55 /* Liberation du type */
56 MPI_Type_free (&type_particule);
57 MPI_Finalize ();
58 }
```

Types de données dérivés

Conclusion

- Les types dérivés MPI sont de puissants mécanismes portables de description de données.
- Ils permettent, lorsqu'ils sont associés à des instructions comme `MPI_Sendrecv()`, de simplifier l'écriture de sous-programmes d'échanges interprocessus.
- L'association des types dérivés et des topologies (décrites dans l'un des prochains chapitres) fait de MPI l'outil idéal pour tous les problèmes de décomposition de domaine avec des maillages réguliers ou irréguliers.

Travaux pratiques MPI – Exercice 4 : Transposée d'une matrice

- Dans cet exercice, on se propose de se familiariser avec les types dérivés
- On se donne une matrice A de 5 lignes et 4 colonnes sur le processus 0
- Il s'agit pour le processus 0 d'envoyer au processus 1 cette matrice mais d'en faire automatiquement la transposition au cours de l'envoi

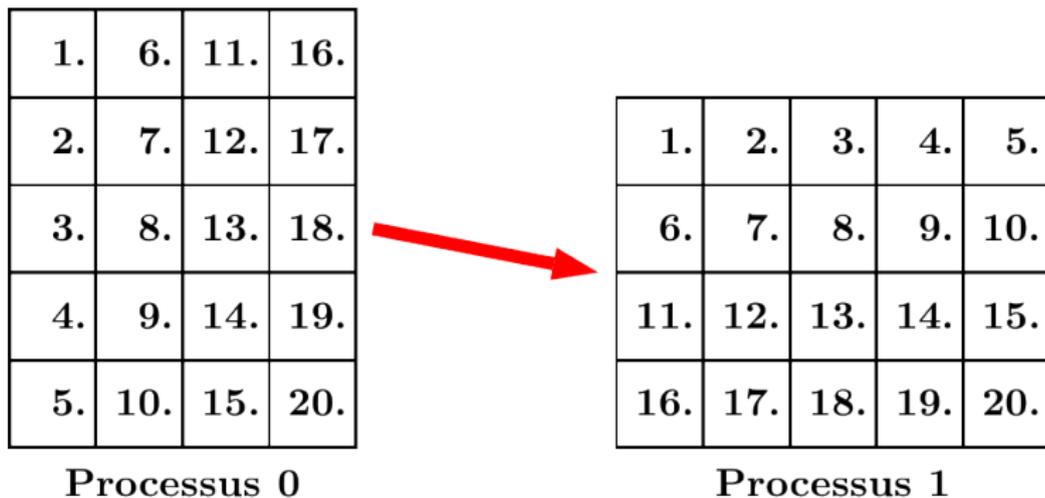


Figure 27 – Transposée d'une matrice

- Pour ce faire, on va devoir se construire deux types dérivés, un type `type_colonne` et un type `type_transpose`

Travaux pratiques MPI – Exercice 5 : Produit réparti de matrices

- Communications collectives et réductions : produit de matrices $C = A \times B$
 - On se limite au cas de matrices carrées dont l'ordre est un multiple du nombre de processus
 - Les matrices A et B sont sur le processus 0. Celui-ci distribue une tranche horizontale de la matrice A et une tranche verticale de la matrice B à chacun des processus. Chacun calcule alors un bloc diagonal de la matrice résultante C .
 - Pour calculer les blocs non diagonaux, chaque processus doit envoyer aux autres processus la tranche de A qu'il possède
 - Après quoi le processus 0 peut collecter les résultats et vérifier les résultats

Travaux pratiques MPI – Exercice 5 : Produit réparti de matrices

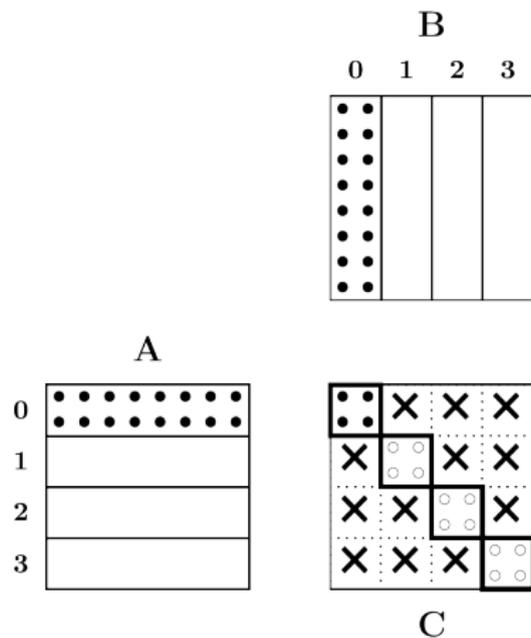


Figure 28 – Produit parallèle de matrices

Travaux pratiques MPI – Exercice 5 : Produit réparti de matrices

- Toutefois, l'algorithme qui peut sembler le plus immédiat, et qui est le plus simple à programmer, consistant à faire envoyer par chaque processus sa tranche de la matrice A à chacun des autres, n'est pas performant parce que le schéma de communication n'est pas du tout équilibré. C'est très facile à voir en faisant des mesures de performances et en représentant graphiquement les traces collectées.



Figure 29 – Produit parallèle de matrices sur 16 processus, pour une taille de matrice de 1024 (premier algorithme)

Travaux pratiques MPI – Exercice 5 : Produit réparti de matrices

- Mais en changeant l'algorithme pour faire *glisser* le contenu des tranches de processus à processus, on peut obtenir un équilibre parfait des calculs et des communications, et gagner ainsi un facteur 2.



Figure 30 – Produit parallèle de matrices sur 16 processus, pour une taille de matrice de 1024 (second algorithme)

Communicateurs

Communicateurs

Introduction

Il s'agit de créer des sous-ensembles de processus sur lesquels on peut effectuer des opérations telles que des communications point à point, collectives, etc. Chaque sous-ensemble aura son propre espace de communication.

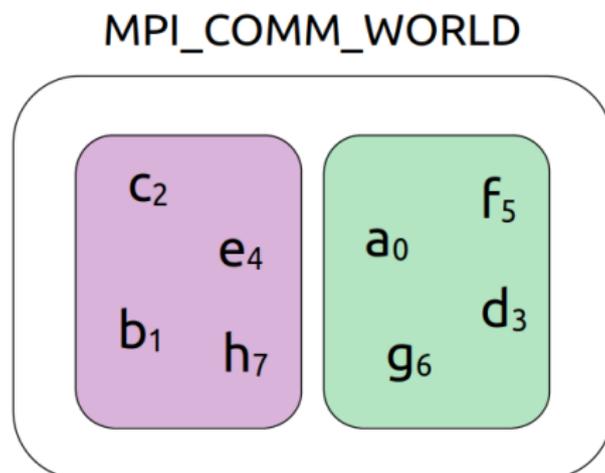


Figure 31 – Partitionnement d'un communicateur

Exemple

Par exemple, on veut diffuser un message collectif aux processus de rang pair et un autre aux processus de rang impair.

- Boucler sur des *send/recv* peut être très pénalisant surtout si le nombre de processus est élevé. De plus un test serait obligatoire dans la boucle pour savoir si le rang du processus auquel le processus émetteur doit envoyer le message est pair ou impair.
- Une solution est de créer un communicateur regroupant les processus pairs et un autre regroupant les processus impairs, puis d'initier les communications collectives à l'intérieur de ces groupes.

Communicateurs

Communicateur par défaut

- On ne peut créer un communicateur qu'à partir d'un autre communicateur. Le premier sera créé à partir de `MPI_COMM_WORLD`.
- En effet, suite à l'appel à `MPI_Init()`, un communicateur est créé pour toute la durée d'exécution du programme.
- Son identificateur `MPI_COMM_WORLD` est un entier défini dans les fichiers d'en-tête.
- Il ne peut être détruit que via l'appel à `MPI_Finalize()`
- Par défaut, il fixe donc la portée des communications point à point et collectives à tous les processus de l'application

Groupes et communicateurs

- Un communicateur est constitué :
 - d'un **groupe**, qui est un ensemble ordonné de processus ;
 - d'un **contexte** de communication mis en place à l'appel du sous-programme de construction du communicateur, qui permet de délimiter l'espace de communication.
- Les contextes de communication sont gérés par MPI (le programmeur n'a aucune action sur eux) : c'est un attribut « caché »
- Dans la bibliothèque MPI, divers sous-programmes existent pour construire des communicateurs : `MPI_Comm_create()`, `MPI_Comm_dup()`, `MPI_Comm_split()`
- Les **constructeurs de communicateurs** sont des **opérateurs collectifs** (qui engendrent des communications entre les processus)
- Les communicateurs que le programmeur crée peuvent être gérés dynamiquement et, de même qu'il est possible d'en créer, il est possible d'en détruire en utilisant le sous-programme `MPI_Comm_free()`

Communicateurs

Partitionnement d'un communicateur

Pour résoudre le problème de l'exemple, nous allons :

- partitionner le communicateur en processus de rang pair et d'autre part en processus de rang impair ;
- ne diffuser un message collectif qu'aux processus de rang pair et un autre qu'aux processus de rang impair.

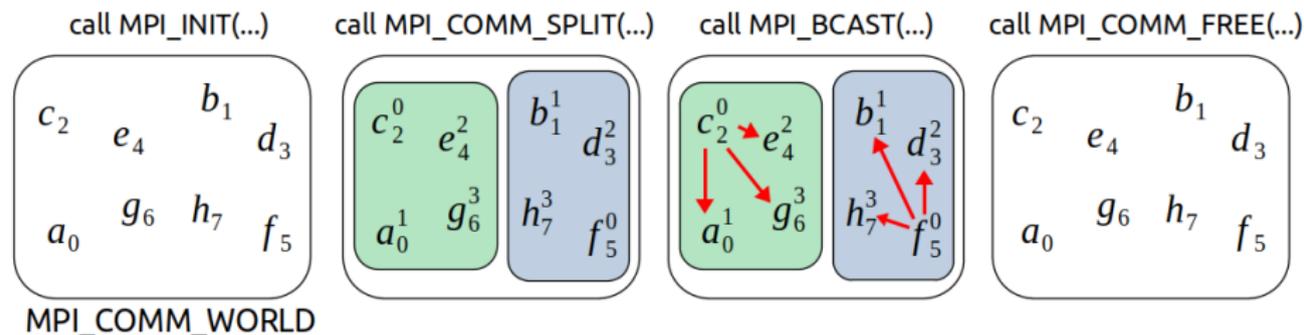


Figure 32 – Création/destruction d'un communicateur

Communicateurs

Partitionnement d'un communicateur avec `MPI_Comm_split()`

Le sous-programme `MPI_Comm_split()` permet de :

- partitionner un communicateur donné en autant de communicateurs que l'on veut
- donner le même nom à tous ces communicateurs : il aura la valeur du communicateur dans lequel se trouve le processus courant
- Méthode :
 1. définir une valeur couleur associant à chaque processus le numéro du communicateur auquel il appartiendra
 2. définir une valeur clef permettant de numéroter les processus dans chaque communicateur
 3. créer la partition où chaque communicateur s'appelle `nouveau_comm`

```
int MPI_Comm_split (MPI_Comm comm, int couleur, int clef, MPI_Comm *nouveau_comm)
```

Un processus qui s'attribue une couleur égale à la valeur `MPI_UNDEFINED` aura pour `nouveau_com` le communicateur invalide `MPI_COMM_NULL`.

Communicateurs

Exemple

Voyons comment procéder pour construire le communicateur qui va subdiviser l'espace de communication entre processus de rangs pairs et impairs, via le constructeur `MPI_Comm_split()`.

processus	a	b	c	d	e	f	g	h
rang_monde	0	1	2	3	4	5	6	7
couleur	0	1	0	1	0	1	0	1
clef	0	1	-1	3	4	-1	6	7
rang_paires_imp	1	1	0	2	2	0	3	3

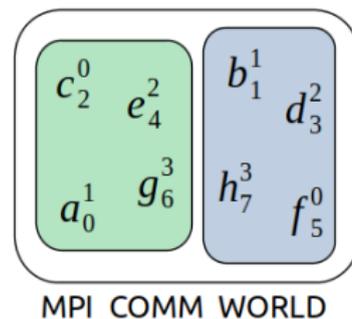
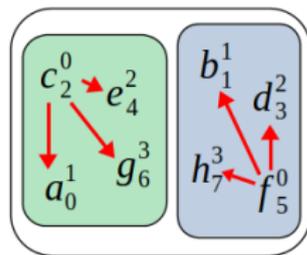


Figure 33 – Construction du communicateur `CommPairsImpairs` avec `MPI_Comm_split()`

Communicateurs

```
1  /* PairsImpairs */
2  #include <mpi.h>
3  #include <stdlib.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, clef, rang_dans_monde;
7      int m=16;
8      float a[16];
9      MPI_Comm CommPairsImpairs;
10
11     MPI_Init (&argc, &argv);
12     MPI_Comm_rank (MPI_COMM_WORLD, &rang_dans_monde);
13
14     for (i=0; i<m; i++) a[i]=0.;
15     if (rang_dans_monde == 2) {for (i=0; i<m; i++) a[i]=2.;}
16     if (rang_dans_monde == 5) {for (i=0; i<m; i++) a[i]=5.;}
17
18     clef = rang_dans_monde;
19     if ((rang_dans_monde == 2) || (rang_dans_monde == 5)) {
20         clef = -1; }
21
22     /* Creation des communicateurs pair et impair en leur donnant une meme denomination */
23     MPI_Comm_split (MPI_COMM_WORLD, rang_dans_monde%2, clef, &CommPairsImpairs);
24
25     /* Diffusion du message par le processus 0 de chaque communicateur aux processus
26        de son groupe */
27     MPI_Bcast (a, m, MPI_FLOAT, 0, CommPairsImpairs);
28
29     /* Destruction des communicateurs */
30     MPI_Comm_free (&CommPairsImpairs);
31     MPI_Finalize ();
32 }
```



Communicateurs

Communicateur construit à partir d'un groupe

- On peut aussi construire un communicateur en définissant un groupe de processus, grâce à la sous-routine `MPI_Comm_create()` :

```
1  /* CommCreation */
2  #include <mpi.h>
3  #include <stdlib.h>
4
5  int main(int argc, char *argv[]) {
6      int taille_nouveau_comm=2;
7      int proc_nouveau_comm[2] = { 1,3};
8      MPI_Group groupe_monde, nouveau_groupe;
9      MPI_Comm nouveau_comm;
10
11     MPI_Init (&argc, &argv);
12
13     /* Recuperation du groupe de processus du communicateur MPI_COMM_WORLD */
14     MPI_Comm_group (MPI_COMM_WORLD, &groupe_monde);
15
16     /* Creation d'un sous-groupe de processus */
17     MPI_Group_incl (groupe_monde, taille_nouveau_comm, proc_nouveau_comm, &nouveau_groupe);
18
19     /* Creation d'un nouveau communicateur a partir du sous-groupe de processus */
20     MPI_Comm_create (MPI_COMM_WORLD, nouveau_groupe, &nouveau_comm);
21
22     /* Destruction du sous-groupe et du nouveau communicateur */
23     MPI_Group_free (&nouveau_groupe);
24
25     MPI_Finalize ();
26 }
```

- Cette méthode est néanmoins nettement plus fastidieuse que d'utiliser `MPI_Comm_split()` lorsque c'est possible.

Communicateurs

Topologies

- Dans la plupart des applications, plus particulièrement dans les méthodes de décomposition de domaine où l'on fait correspondre le domaine de calcul à la grille de processus, il est intéressant de pouvoir disposer les processus suivant une topologie régulière
- MPI permet de définir des topologies virtuelles du type cartésien ou graphe
 - Topologies de type cartésien
 - ▶ chaque processus est défini dans une grille de processus ;
 - ▶ chaque processus a un voisin dans la grille ;
 - ▶ la grille peut être périodique ou non ;
 - ▶ les processus sont identifiés par leurs coordonnées dans la grille.
 - Topologies de type graphe
 - ▶ généralisation à des topologies plus complexes.

1	3	5	7
0	2	4	6

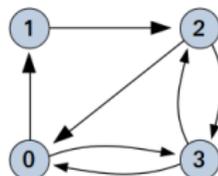


Figure 34 – Topologie cartésienne 2D (gauche) et topologie de type graphe (droite)

Topologies cartésiennes

- Une topologie cartésienne est définie à partir d'un communicateur donné `comm_ancien`, en appelant le sous-programme `MPI_Cart_create()`.
- On définit :
 - un entier `ndims` représentant le nombre de dimensions de la grille
 - un tableau d'entiers `dims` de dimension `ndims` indiquant le nombre de processus dans chaque dimension
 - un tableau de logiques de dimension `ndims` indiquant la périodicité dans chaque dimension
 - un logique `reorganisation` indiquant si la numérotation des processus peut être changé par MPI

```
int MPI_Cart_create(MPI_Comm comm_ancien, int ndims, const int *dims, const int *periods,  
int reorganisation, MPI_Comm *comm_nouveau)
```

Exemple

Exemple sur une grille comportant 4 domaines suivant x et 2 suivant y, périodique en y.

```
int ndims=2, reorganisation;
int dims[ndims], periods[ndims];
MPI_Comm comm_2D;

dims[0]=4; dims[1]=2;
periods[0]=false; periods[1]=true;
reorganisation=false;

MPI_Cart_create (MPI_COMM_WORLD, ndims, dims, periods, reorganisation, &comm_2D);
```

Si `reorganisation = false` alors le rang des processus dans le nouveau communicateur (`comm_2D`) est le même que dans l'ancien communicateur (`MPI_COMM_WORLD`).

Si `reorganisation = true`, l'implémentation MPI choisit l'ordre des processus.

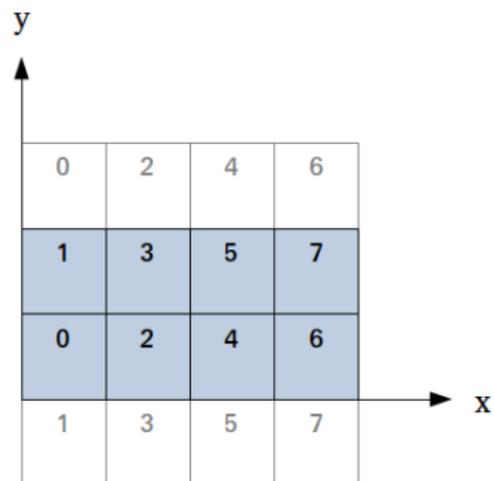


Figure 35 – Topologie cartésienne 2D périodique en y

Exemple 3D

Exemple sur une grille 3D comportant 4 domaines suivant x, 2 suivant y et 2 suivant z, non périodique.

```
int ndims=3, reorganisation;  
int dims[ndims], periods[ndims];  
MPI_Comm comm_3D;  
  
dims[0]=4; dims[1]=2; dims[2]=2;  
periods[0]=false; periods[1]=false; periods[2]=false;  
reorganisation=false;  
  
MPI_Cart_create (MPI_COMM_WORLD, ndims, dims, periods, reorganisation, &comm_3D);
```

Communicateurs

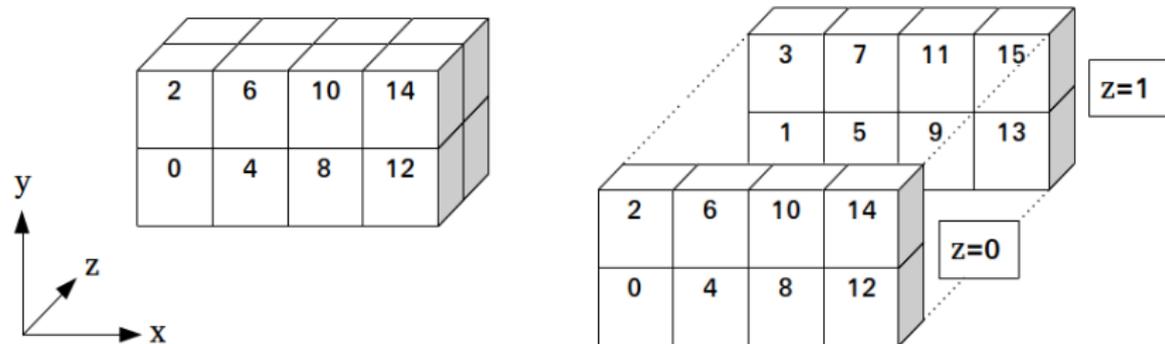


Figure 36 – Topologie cartésienne 3D non périodique

Distribution des processus

Le sous-programme `MPI_Dims_create()` retourne le nombre de processus dans chaque dimension de la grille en fonction du nombre total de processus.

```
int MPI_Dims_create(int nb_procs, int ndims, int *dims)
```

Remarque : si les valeurs de `dims` en entrée valent toutes 0, cela signifie qu'on laisse à MPI le choix du nombre de processus dans chaque direction en fonction du nombre total de processus.

dims en entrée	<code>MPI_Dims_create</code>	dims en sortie
(0,0)	(8,2,dims,code)	(4,2)
(0,0,0)	(16,3,dims,code)	(4,2,2)
(0,4,0)	(16,3,dims,code)	(2,4,2)
(0,3,0)	(16,3,dims,code)	error

Communicateurs

Rang et coordonnées d'un processus

Dans une topologie cartésienne, le rang de chaque processus est associé à ses coordonnées dans la grille.

0 (0,0)	2 (1,0)	4 (2,0)	6 (3,0)
1 (0,1)	3 (1,1)	5 (2,1)	7 (3,1)
0 (0,0)	2 (1,0)	4 (2,0)	6 (3,0)
1 (0,1)	3 (1,1)	5 (2,1)	7 (3,1)

Figure 37 – Topologie cartésienne 2D périodique en y

Rang d'un processus connaissant ses coordonnées

Dans une topologie cartésienne, le sous-programme `MPI_Cart_rank()` retourne le rang du processus associé aux coordonnées dans la grille.

```
int MPI_Cart_rank(MPI_Comm comm, const int coords[], int *rang)
```

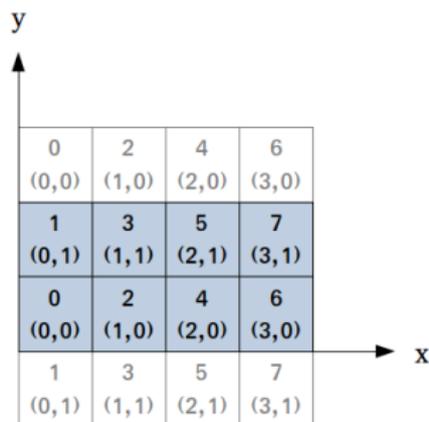


Figure 38 – Topologie cartésienne 2D périodique en y

```
coords[0]=dims[0]-1;
for(i=0;i<dims[1];i++) {
  coords[1]=i;
  MPI_Cart_rank(comm_2D,coords,&(rang[i]));
}
.....
i=0,en entree coords=[3,0],en sortie rang[0]=6.
i=1,en entree coords=[3,1],en sortie rang[1]=7.
```

Coordonnées d'un processus connaissant son rang

Dans une topologie cartésienne, le sous-programme `MPI_Cart_coords()` retourne les coordonnées d'un processus de rang donné dans la grille.

```
int MPI_Cart_coords(MPI_Comm comm, int rang, int ndims, int *coords)
```

Communicateurs

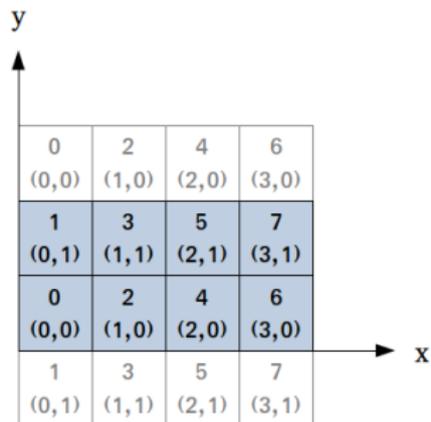


Figure 39 – Topologie cartésienne 2D périodique en y

```
if (rang%2 == 0)
    MPI_Cart_coords (comm_2D, rang, 2, &coords);
.....
En entree, les valeurs de rang sont : 0,2,4,6.
En sortie, les valeurs de coords sont :
(0,0), (1,0), (2,0), (3,0).
```

Rang des voisins

Dans une topologie cartésienne, un processus appelant le sous-programme `MPI_Cart_Shift()` se voit retourner le rang de ses processus voisins dans une direction donnée.

```
int MPI_Cart_shift(MPI_Comm comm, int direction, int pas, int *rang_precedent, int *rang_suivant)
```

- Le paramètre `direction` correspond à l'axe du déplacement (xyz).
- Le paramètre `pas` correspond au pas du déplacement.
- Si un rang n'a pas de voisin précédent (resp. suivant) dans la direction demandée, alors la valeur du rang précédent (resp. suivant) sera `MPI_PROC_NULL`.

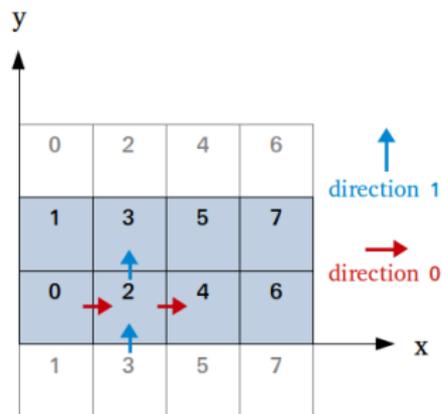


Figure 40 – Appel du sous-programme MPI_Cart_shift()

```
MPI_Cart_shift(comm_2D,0,1,&rang_gauche,&rang_droit);
```

```
.....
```

```
Pour le processus 2, rang_gauche=0, rang_droit=4
```

```
MPI_Cart_shift(comm_2D,1,1,&rang_bas,&rang_haut);
```

```
.....
```

```
Pour le processus 2, rang_bas=3, rang_haut=3
```

Communicateurs

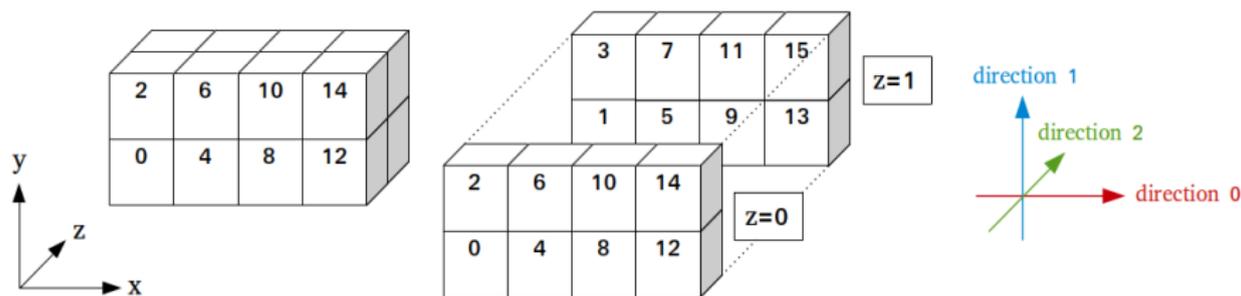


Figure 41 – Appel du sous-programme MPI_Cart_shift()

```
MPI_Cart_shift(comm_3D,0,1,&rang_gauche,&rang_droit)
.....
Pour le processus 0, rang_gauche=-1, rang_droit=4
```

```
MPI_Cart_shift(comm_3D,1,1,&rang_bas,&rang_haut)
.....
Pour le processus 0, rang_bas=-1, rang_haut=2
```

```
MPI_Cart_shift(comm_3D,2,1,&rang_avant,&rang_arriere)
.....
Pour le processus 0, rang_avant=-1, rang_arriere=1
```

Exemple

- création d'une grille cartésienne 2D périodique en y
- récupération des coordonnées de chaque processus
- récupération des rangs voisins pour chaque processus

```
1  /* decomposition */
2  #include <mpi.h>
3  #include <stdlib.h>
4
5  int main(int argc, char *argv[]) {
6      int nb_procs, rang_ds_topo;
7      int ndims=2, N=1, E=2, S=3, W=4;
8      int dims[ndims], coords[ndims], voisin[4];
9      int periods[ndims], reorganisation;
10     MPI_Comm comm_2D;
11
12     MPI_Init(&argc, &argv);
13
14     MPI_Comm_size(MPI_COMM_WORLD, &nb_procs);
15
16     /* Connaître le nombre de processus suivant x et y */
17     dims[0] = dims[1] = 0;
18
19     MPI_Dims_create(nb_procs, ndims, dims);
```

Communicateurs

```
20  /* Creation grille 2D periodique en y */
21  periods[0] = 0;
22  periods[1] = 1;
23  reorganisation = 0;
24
25  MPI_Cart_create (MPI_COMM_WORLD, ndims, dims, periods, reorganisation, &comm_2D);
26
27  /* Connaître mes coordonnees dans la topologie */
28  MPI_Comm_rank (comm_2D, &rang_ds_topo);
29  MPI_Cart_coords (comm_2D, rang_ds_topo, ndims, coords);
30
31  /* Recherche de mes voisins Ouest et Est */
32  MPI_Cart_shift (comm_2D, 0, 1, &(voisin[W]), &(voisin[E]));
33
34  /* Recherche des mes voisins Sud et Nord */
35  MPI_Cart_shift (comm_2D, 1, 1, &(voisin[S]), &(voisin[N]));
36
37  MPI_Finalize ();
38 }
```

Subdiviser une topologie cartésienne

- La question est de savoir comment dégénérer une topologie cartésienne de processus 2D ou 3D en une topologie cartésienne respectivement 1D ou 2D.
- Pour MPI, dégénérer une topologie cartésienne 2D (ou 3D) revient à créer autant de communicateurs qu'il y a de lignes ou de colonnes (resp. de plans) dans la grille cartésienne initiale.
- L'intérêt majeur est de pouvoir effectuer des opérations collectives restreintes à un sous-ensemble de processus appartenant à :
 - une même ligne (ou colonne), si la topologie initiale est 2D ;
 - un même plan, si la topologie initiale est 3D.

Communicateurs

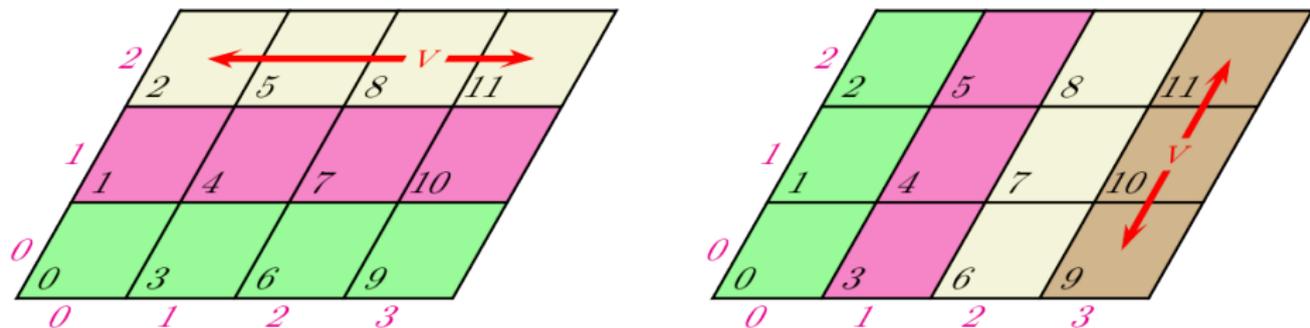


Figure 42 – Deux exemples de distribution de données dans une topologie 2D dégénérée

Communicateurs

Subdiviser une topologie cartésienne

Il existe deux façons de faire pour dégénérer une topologie :

- en utilisant le sous-programme général `MPI_Comm_split()` ;
- en utilisant le sous-programme `MPI_Cart_sub()` prévu à cet effet.

```
int MPI_Cart_sub(MPI_Comm CommCart, const int conserve_dims[], MPI_Comm *CommCartD)
```

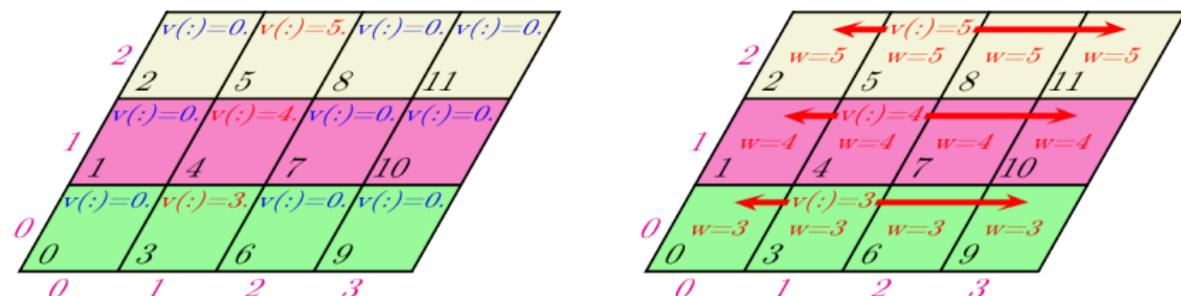


Figure 43 – Distribution d'un tableau V sur la grille 2D dégénérée

Communicateurs

```
1  /* CommCartSub */
2  #include <mpi.h>
3  #include <stdlib.h>
4  #include <stdio.h>
5
6  int main(int argc, char *argv[]) {
7      int NDim2D=2, m=4;
8      int Dim2D[NDim2D], Periode[NDim2D], Coord2D[NDim2D], conserve_dims[NDim2D];
9      int ReOrdonne, rang, i;
10     MPI_Comm Comm2D, Comm1D;
11     float V[m], W;
12
13
14     MPI_Init(&argc, &argv);
15
16     /* Creation de la grille 2D initiale */
17     Dim2D[0] = 4;
18     Dim2D[1] = 3;
19     Periode[0] = 0; Periode[1] = 0;
20     ReOrdonne = 0;
21     MPI_Cart_create (MPI_COMM_WORLD, NDim2D, Dim2D, Periode, ReOrdonne, &Comm2D);
22     MPI_Comm_rank (Comm2D, &rang);
23     MPI_Cart_coords (Comm2D, rang, NDim2D, Coord2D);
```

Communicateurs

```
24  /* Initialisation du vecteur V */
25  if (Coord2D[0] == 1) {for(i=0;i<m;i++) V[i]=rang; }
26
27  /* Chaque ligne de la grille doit etre une topologie cartesienne 1D */
28  conserve_dims[0] = 1;
29  conserve_dims[1] = 0;
30  /* Subdivision de la grille cartesienne 2D */
31  MPI_Cart_sub (Comm2D, conserve_dims, &Comm1D);
32
33  /* Les processus de la colonne 2 distribuent le vecteur V aux processus de leur ligne */
34  MPI_Scatter (V, 1, MPI_FLOAT, &W, 1, MPI_FLOAT, 1, Comm1D);
35
36  printf("Rang : %d ; Coordonnees : ( %d,%d); W = %f\n",
37        rang, Coord2D[0], Coord2D[1], W);
38
39  MPI_Finalize ();
40 }
```

Communicateurs

```
> mpiexec -n 12 CommCartSub
```

```
Rang : 0 ; Coordonnees : (0,0) ; W = 3.  
Rang : 1 ; Coordonnees : (0,1) ; W = 4.  
Rang : 3 ; Coordonnees : (1,0) ; W = 3.  
Rang : 8 ; Coordonnees : (2,2) ; W = 5.  
Rang : 4 ; Coordonnees : (1,1) ; W = 4.  
Rang : 5 ; Coordonnees : (1,2) ; W = 5.  
Rang : 6 ; Coordonnees : (2,0) ; W = 3.  
Rang : 10 ; Coordonnees : (3,1) ; W = 4.  
Rang : 11 ; Coordonnees : (3,2) ; W = 5.  
Rang : 9 ; Coordonnees : (3,0) ; W = 3.  
Rang : 2 ; Coordonnees : (0,2) ; W = 5.  
Rang : 7 ; Coordonnees : (2,1) ; W = 4.
```

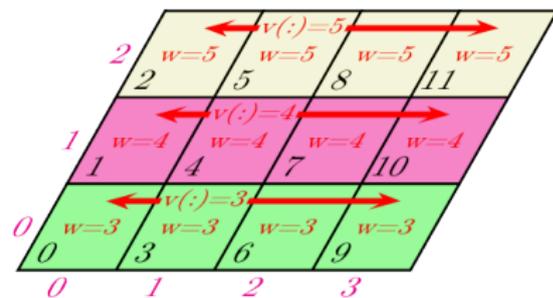
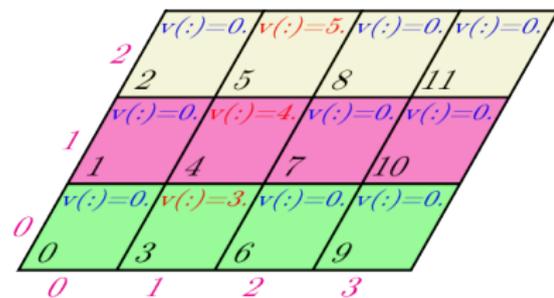


Figure 44 – Distribution d'un tableau V sur la grille 2D dégénérée

Travaux pratiques MPI – Exercice 6 : Communicateurs

- En partant de la topologie cartésienne définie ci-dessous, subdiviser en 2 communicateurs suivant les lignes via `MPI_Comm_split()`

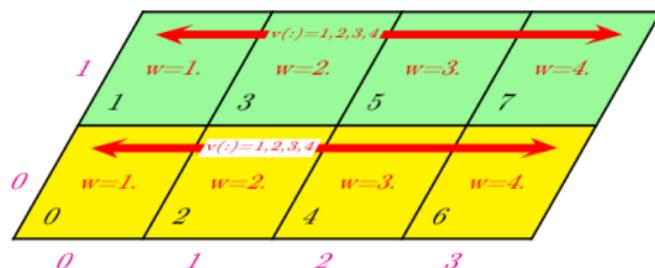


Figure 45 – Subdivision d'une topologie 2D et communication suivant la topologie 1D obtenue

- Contrainte : définir les couleurs de chaque processus sans utiliser l'opération *modulo*.

MPI-IO

Optimisation des entrées-sorties

- Très logiquement, les applications qui font des calculs volumineux manipulent également des quantités importantes de données externes, et génèrent donc un nombre conséquent d'entrées-sorties.
- Le traitement efficace de celles-ci influe donc parfois très fortement sur les performances globales des applications.
- L'optimisation des entrées-sorties de codes parallèles se fait par la combinaison :
 - de leur **parallélisation**, pour éviter de créer un goulet d'étranglement en raison de leur sérialisation ;
 - de techniques mises en œuvre **explicitement** au niveau de la programmation (lectures / écritures non-bloquantes) ;
 - d'opérations spécifiques prises en charge par le **système d'exploitation** (regroupement des requêtes, gestion des tampons d'entrées-sorties, etc.).
- L'utilisation d'une bibliothèque facilite l'optimisation des entrées-sorties.

L'interface MPI-IO

- La norme MPI-2 définit un ensemble de fonctions permettant de réaliser des entrées-sorties parallèles.
- L'interface est calquée sur celle utilisée pour l'échange de messages MPI. Par exemple, les **opérations collectives** et **non-bloquantes** sur les fichiers sont gérées de façon similaire à ce que propose **MPI** pour les messages entre processus. La définition des données accédées suivant les processus se fait par l'utilisation de **types de données** (de base ou bien dérivés).
- Bien sûr, de nombreux éléments (descripteurs de fichiers, attributs . . .) rappellent les interfaces d'entrées-sorties natives des langages de programmation.

MPI-IO

Exemple d'optimisation séquentielle implémentée par les bibliothèques

- Pour obtenir de bonnes performances, il est préférable de limiter le nombre de requêtes (latence) et de lire de larges blocs de données.
- Lorsqu'un seul processus accède à de nombreux petits blocs discontinus, il est possible de regrouper les requêtes pour plus de performances.
- Une bibliothèque MPI-IO peut implémenter cette optimisation de manière transparente.

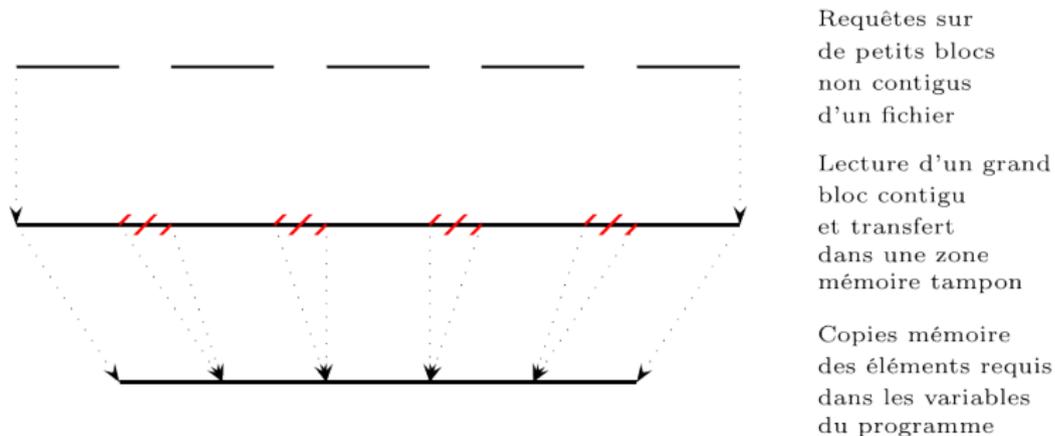


Figure 46 – Mécanisme de *passoire* (*data sieving*) dans le cas d'accès nombreux, par un seul processus, à de petits blocs discontinus

Exemple d'optimisation parallèle

Lorsqu'un ensemble de processus accède à des blocs discontinus (cas des tableaux distribués, par exemple), la bibliothèque d'I/O peut optimiser l'opération en maximisant l'accès aux données contiguës et en utilisant des communications collectives de redistribution.

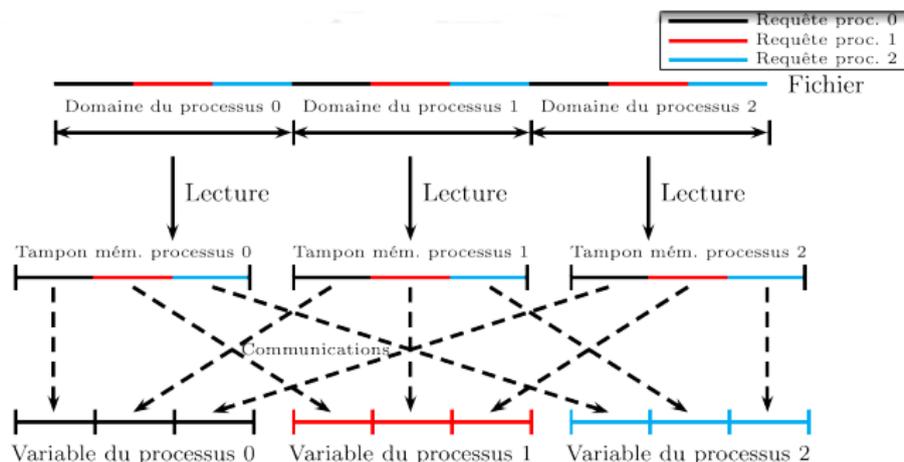


Figure 47 – Lecture en deux phases, par un ensemble de processus

Ouverture et fermeture d'un fichier

- L'ouverture et la fermeture d'un fichier sont des opérations *collectives*.
- Tous les processus du communicateur au sein duquel un fichier est ouvert participeront aux opérations collectives ultérieures d'accès aux données.
- L'ouverture d'un fichier renvoie un **descripteur**. C'est un objet opaque qui est ensuite utilisé comme référence dans toutes les opérations portant sur le fichier.
- A l'ouverture, les attributs décrivent les droits d'accès, le mode d'ouverture, la destruction éventuelle à la fermeture, etc. Les attributs doivent être précisés en utilisant des constantes prédéfinies et peuvent être combinés entre eux.
- Nous ne décrivons ici que les sous-programmes d'ouverture et de fermeture mais d'autres sous-programme de gestion de fichiers sont disponibles (obtention des caractéristiques, suppression, pré-allocation, etc.). Par exemple, le sous-programme `MPI_File_get_info()` permet d'obtenir des informations sur un fichier ouvert (les informations disponibles varient d'une implémentation à l'autre).

MPI-IO

```
1  /* open01 */
2  #include <mpi.h>
3  #include <stdlib.h>
4  #include <stdio.h>
5
6  int main(int argc, char *argv[]) {
7      MPI_File descripteur;
8      int code, texte_longueur;
9      char texte_erreur[MPI_MAX_ERROR_STRING];
10
11     MPI_Init(&argc, &argv);
12
13     code = MPI_File_open(MPI_COMM_WORLD, "fichier.txt",
14                         MPI_MODE_RDWR + MPI_MODE_CREATE, MPI_INFO_NULL, &descripteur);
15     if (code != MPI_SUCCESS) {
16         MPI_Error_string(code, texte_erreur, &texte_longueur);
17         printf("%s\n", texte_erreur);
18         MPI_Abort(MPI_COMM_WORLD, 42);
19     }
20
21     code = MPI_File_close(&descripteur);
22     if (code != MPI_SUCCESS) {
23         printf("Erreur fermeture fichier\n");
24         MPI_Abort(MPI_COMM_WORLD, 2);
25     }
26
27     MPI_Finalize();
28 }
```

```
> ls -l fichier.txt
-rw-----  1 nom      grp    0 Feb 08 12:13 fichier.txt
```

Attribut	Signification
<code>MPI_MODE_RDONLY</code>	seulement en lecture
<code>MPI_MODE_RDWR</code>	en lecture et écriture
<code>MPI_MODE_WRONLY</code>	seulement en écriture
<code>MPI_MODE_CREATE</code>	création du fichier s'il n'existe pas
<code>MPI_MODE_EXCL</code>	erreur si le fichier existe
<code>MPI_MODE_UNIQUE_OPEN</code>	erreur si le fichier est déjà ouvert
<code>MPI_MODE_SEQUENTIAL</code>	accès séquentiel
<code>MPI_MODE_APPEND</code>	pointeurs en fin de fichier (mode ajout)
<code>MPI_MODE_DELETE_ON_CLOSE</code>	destruction après la fermeture

Gestion des erreurs

- Le comportement concernant l'argument code est différent pour la partie IO de MPI;
- Il est nécessaire de tester la valeur de cet argument ;
- Il est possible de changer ce comportement avec `MPI_File_set_errhandler()` ;
- Deux gestionnaires d'erreurs sont disponibles : `MPI_ERRORS_ARE_FATAL` et `MPI_ERRORS_RETURN` ;
- `MPI_Comm_set_errhandler()` permet de changer la gestion des erreurs pour les communications.

```
int MPI_File_set_errhandler(MPI_File descripteur, MPI_Errhandler gestionnaire)
```

Pour changer le comportement par défaut, il faut utiliser `MPI_FILE_NULL` comme descripteur.

Généralités

- Les transferts de données entre fichiers et zones mémoire des processus se font via des appels explicites à des sous-programmes de lecture et d'écriture.
- On distingue trois propriétés des accès aux fichiers :
 - le **positionnement**, qui peut être explicite (en spécifiant un déplacement par rapport au début du fichier) ou implicite, via des pointeurs gérés par le système (ces pointeurs peuvent être de deux types : soit **individuels** à chaque processus, soit **partagés** par tous les processus) ;
 - la **synchronisation**, les accès pouvant être de type bloquants ou non bloquants ;
 - le **regroupement**, les accès pouvant être collectifs (c'est-à-dire effectués par tous les processus du communicateur au sein duquel le fichier a été ouvert) ou propres seulement à un ou plusieurs processus.
- Il est possible de mélanger les types d'accès effectués à un même fichier au sein d'une application.

Positionnement	Synchronisation	individuel	collectif
adresses explicites	bloquantes	MPI_File_read_at MPI_File_write_at	MPI_File_read_at_all MPI_File_write_at_all
	non bloquantes	MPI_File_iread_at MPI_File_iwrite_at	MPI_File_read_at_all_begin MPI_File_read_at_all_end MPI_File_write_at_all_begin MPI_File_write_at_all_end
pointeurs implicites individuels	bloquantes	MPI_File_read MPI_File_write MPI_File_iread	MPI_File_read_all MPI_File_write_all MPI_File_read_all_begin MPI_Filre_read_all_end MPI_File_write_all_begin MPI_File_write_all_end
	non bloquantes	MPI_File_iwrite	MPI_File_read_ordered MPI_File_write_ordered MPI_File_read_ordered_begin MPI_File_read_ordered_end MPI_File_write_ordered_begin MPI_File_write_ordered_end
pointeurs implicites partagés	bloquantes	MPI_File_read_shared MPI_File_write_shared	MPI_File_read_ordered MPI_File_write_ordered
	non bloquantes	MPI_File_iread_shared MPI_File_iwrite_shared	MPI_File_read_ordered_begin MPI_File_read_ordered_end MPI_File_write_ordered_begin MPI_File_write_ordered_end

Le mécanisme de vue

- Par défaut, les fichiers sont lus comme une simple suite d'octets mais MPI-IO dispose d'un mécanisme permettant une abstraction de plus haut niveau du contenu des fichiers : il est possible de décrire des structures de données complexes et de s'en servir comme gabarit lors de l'accès aux fichiers.
- Pour l'instant, il faut seulement savoir qu'un type élémentaire de données sert d'unité de base à ces constructions et que, par défaut, le type élémentaire est l'octet.
- Ce mécanisme de **vue** sera décrit en détail plus tard.

Déplacements explicites

- Le déplacement est explicite lorsque la `position` à partir de laquelle on travaille sur le fichier est définie explicitement lors de l'opération de lecture ou d'écriture.
- La position dans un fichier s'exprime toujours comme un multiple du type élémentaire de la vue courante. Par défaut, la position s'exprime donc en octets.
- La taille de la zone de lecture/écriture est exprimée en nombre d'occurrences d'un type de donnée (ex : `MPI_INT`). La taille du type doit être un multiple du type élémentaire.

```
1  /* write_at */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_octets_entier, nb_valeurs=10, code;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Offset position_fichier;
10     MPI_Status statut;
11
12     MPI_Init(&argc, &argv);
13     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
14     for(i=0; i<nb_valeurs; i++) {valeurs[i] = i+rang*100;}
15     printf("Ecriture processus %d :", rang);
16     for(i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);}
17     printf("\n");
18
19     code = MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
20                        MPI_MODE_WRONLY+MPI_MODE_CREATE, MPI_INFO_NULL, &descripteur);
21     if (code != MPI_SUCCESS) {
22         printf("Erreur ouverture fichier\n");
23         MPI_Abort(MPI_COMM_WORLD, 42); }
24     MPI_Type_size(MPI_INT, &nb_octets_entier);
25     position_fichier = rang*nb_valeurs*nb_octets_entier;
26
27     MPI_File_set_errhandler(descripteur, MPI_ERRORS_ARE_FATAL);
28     MPI_File_write_at(descripteur, position_fichier, valeurs, nb_valeurs, MPI_INT,
29                      &statut);
30     MPI_File_close(&descripteur);
31     MPI_Finalize();
32 }
```

MPI-IO

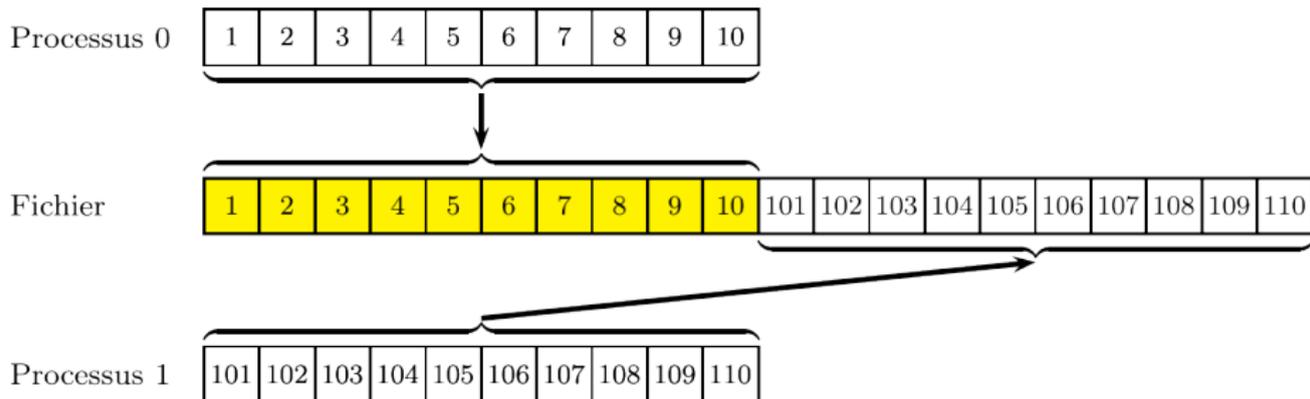


Figure 48 – Exemple d'utilisation de `MPI_File_write_at()`

```
> mpiexec -n 2 write_at
```

```
Ecriture processus 0 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10  
Ecriture processus 1 : 101, 102, 103, 104, 105, 106, 107, 108, 109, 110
```

```
1  /* read_at */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_octets_entier, nb_valeurs=10, code;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Offset position_fichier;
10     MPI_Status statut;
11
12     MPI_Init(&argc, &argv);
13     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
14     code = MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
15                         MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
16     MPI_Type_size(MPI_INT, &nb_octets_entier);
17     position_fichier = rang*nb_valeurs*nb_octets_entier;
18     MPI_File_read_at(descripteur, position_fichier, valeurs, nb_valeurs, MPI_INT,
19                    &statut);
20     printf("Lecture processus %d : ", rang);
21     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
22     MPI_File_close(&descripteur);
23     MPI_Finalize();
24 }
```

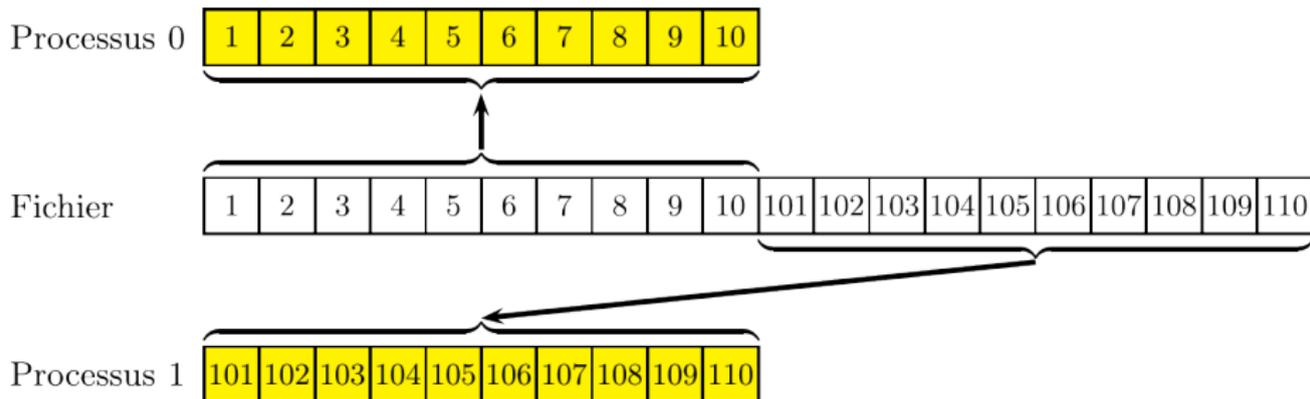


Figure 49 – Exemple d'utilisation de `MPI_File_read_at()`

```
> mpiexec -n 2 read_at
```

```
Lecture processus 0 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10  
Lecture processus 1 : 101, 102, 103, 104, 105, 106, 107, 108, 109, 110
```

Déplacements implicites individuels

- Un pointeur individuel est géré par le système, et ceci **par fichier** et **par processus**.
- Pour un processus donné, deux accès successifs au même fichier permettent donc d'accéder automatiquement aux éléments consécutifs de celui-ci.
- Dans tous ces sous-programmes, les pointeurs partagés ne sont jamais accédés ou modifiés explicitement.
- Après chaque accès, le pointeur est positionné sur l'élément suivant.

```
1  /* read01 */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_valeurs=10;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init (&argc, &argv);
12     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
13     MPI_File_open (MPI_COMM_WORLD, "donnees.dat",
14                  MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15     MPI_File_read (descripteur, valeurs, 6, MPI_INT, &statut);
16     MPI_File_read (descripteur, &(valeurs[6]), 4, MPI_INT, &statut);
17     printf("Lecture processus %d : ", rang);
18     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
19     MPI_File_close (&descripteur);
20     MPI_Finalize ();
21 }
```

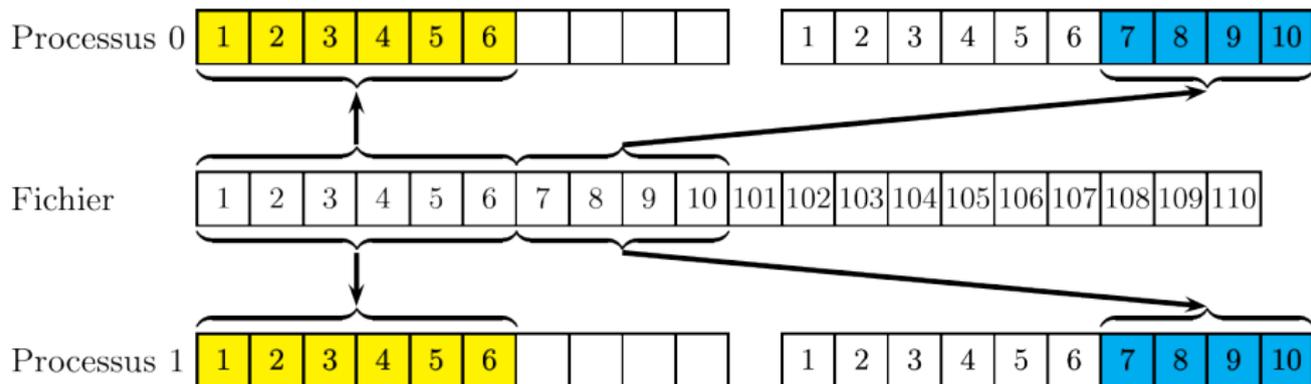


Figure 50 – Exemple 1 d'utilisation de `MPI_File_read()`

```
> mpiexec -n 2 read01
Lecture processus 1 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
Lecture processus 0 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
```

```
1  /* read02 */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_valeurs=10;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init(&argc, &argv);
12     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
13     MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
14                 MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15     if (rang == 0) {
16         MPI_File_read(descripteur, valeurs, 6, MPI_INT, &statut);
17     } else {
18         MPI_File_read(descripteur, valeurs, 8, MPI_INT, &statut);
19         MPI_File_read(descripteur, valeurs, 5, MPI_INT, &statut);
20     }
21     printf("Lecture processus %d : ", rang);
22     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
23     MPI_File_close(&descripteur);
24     MPI_Finalize();
25 }
```

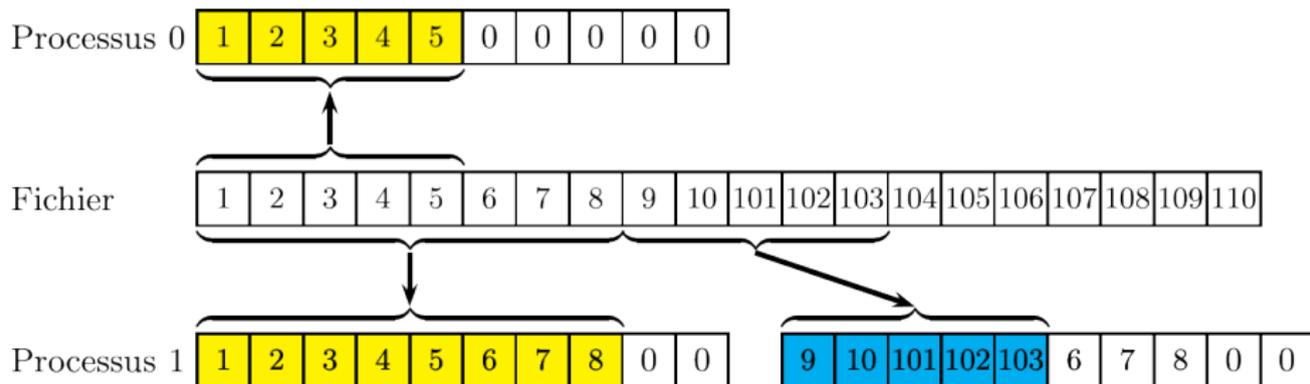


Figure 51 – Exemple 2 d'utilisation de `MPI_File_read()`

```
> mpiexec -n 2 read02
```

```
Lecture processus 0 : 1, 2, 3, 4, 5, 0, 0, 0  
Lecture processus 1 : 9, 10, 101, 102, 103, 6, 7, 8
```

Déplacements implicites partagés

- Il existe **un et un seul** pointeur partagé par fichier, commun à tous les processus du communicateur dans lequel le fichier a été ouvert.
- Tous les processus qui font une opération d'entrée-sortie utilisant le pointeur partagé doivent employer **la même vue** du fichier.
- Si on utilise les variantes non collectives des sous-programmes, l'ordre de lecture **n'est pas déterministe**. Si le traitement doit être déterministe, il faut explicitement gérer l'ordonnancement des processus ou utiliser les variantes collectives.
- Après chaque accès, le pointeur est positionné sur l'élément suivant.
- Dans tous ces sous-programmes, les pointeurs individuels ne sont jamais accédés ou modifiés.

```
1  /* read_shared01 */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_valeurs=10;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init (&argc, &argv);
12     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
13     MPI_File_open (MPI_COMM_WORLD, "donnees.dat",
14                  MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15     MPI_File_read_shared (descripteur, valeurs, 4, MPI_INT, &statut);
16     MPI_File_read_shared (descripteur, &(valeurs[4]), 6, MPI_INT, &statut);
17     printf("Lecture processus %d : ", rang);
18     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
19     MPI_File_close (&descripteur);
20     MPI_Finalize ();
21 }
```

MPI-IO

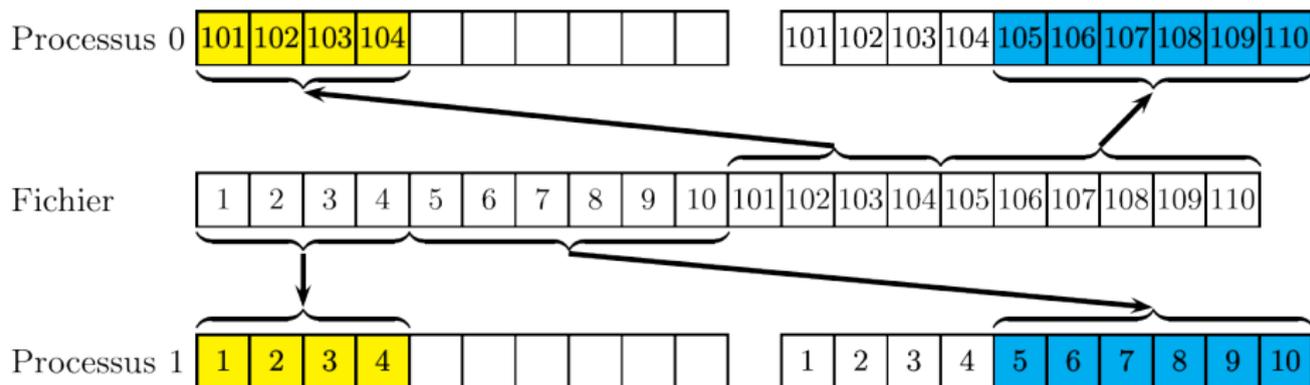


Figure 52 – Exemple 2 d'utilisation de `MPI_File_read_shared()`

```
> mpiexec -n 2 read_shared01
```

```
Lecture processus 1 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
```

```
Lecture processus 0 : 101, 102, 103, 104, 105, 106, 107, 108, 109, 110
```

Lectures/écritures collectives

- Tous les processus du **communicateur** au sein duquel un fichier est ouvert participent aux opérations collectives d'accès aux données.
- Les opérations collectives sont généralement **plus performantes** que les opérations individuelles, parce qu'elles autorisent davantage de techniques d'optimisation mises en œuvre automatiquement ;
- Les accès sont effectués **dans l'ordre** des rangs des processus : le traitement est donc ici **déterministe**.

```
1  /* read_at_all */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_octets_entier, nb_valeurs=10, code;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Offset position_fichier;
10     MPI_Status statut;
11
12     MPI_Init(&argc, &argv);
13     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
14     code = MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
15                         MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
16     MPI_Type_size(MPI_INT, &nb_octets_entier);
17     position_fichier = rang*nb_valeurs*nb_octets_entier;
18     MPI_File_read_at_all(descripteur, position_fichier,
19                         valeurs, nb_valeurs, MPI_INT, &statut);
20     printf("Lecture processus %d : ", rang);
21     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
22     MPI_File_close(&descripteur);
23     MPI_Finalize();
24 }
```

MPI-IO

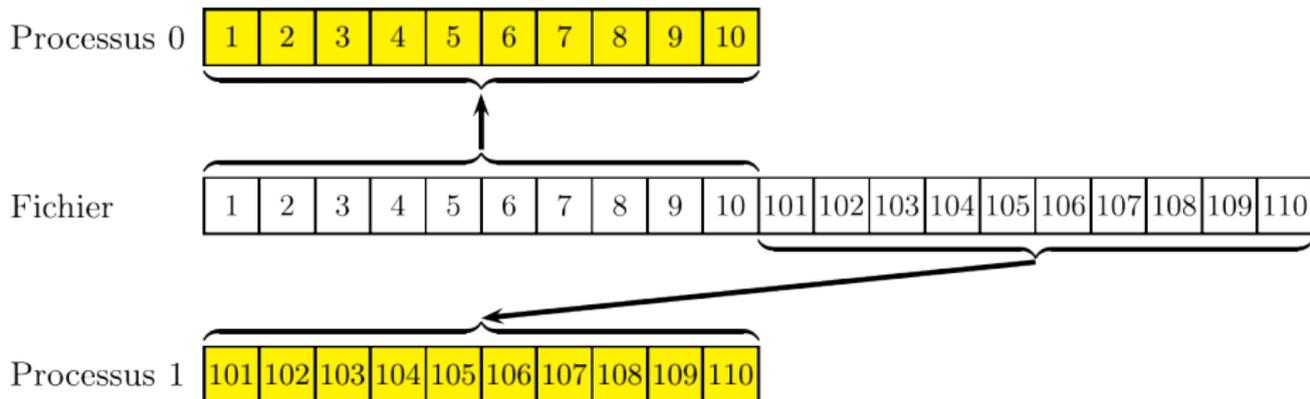


Figure 53 – Exemple d'utilisation de `MPI_File_read_at_all()`

```
> mpiexec -n 2 read_at_all
```

```
Lecture processus 0 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10  
Lecture processus 1 : 101, 102, 103, 104, 105, 106, 107, 108, 109, 110
```

```
1  /* read_all01 */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_valeurs=10;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init (&argc, &argv);
12     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
13     MPI_File_open (MPI_COMM_WORLD, "donnees.dat",
14                  MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15     MPI_File_read_all (descripteur, valeurs, 4, MPI_INT, &statut);
16     MPI_File_read_all (descripteur, &(valeurs[4]), 6, MPI_INT, &statut);
17     printf("Lecture processus %d : ", rang);
18     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
19     MPI_File_close (&descripteur);
20     MPI_Finalize ();
21 }
```

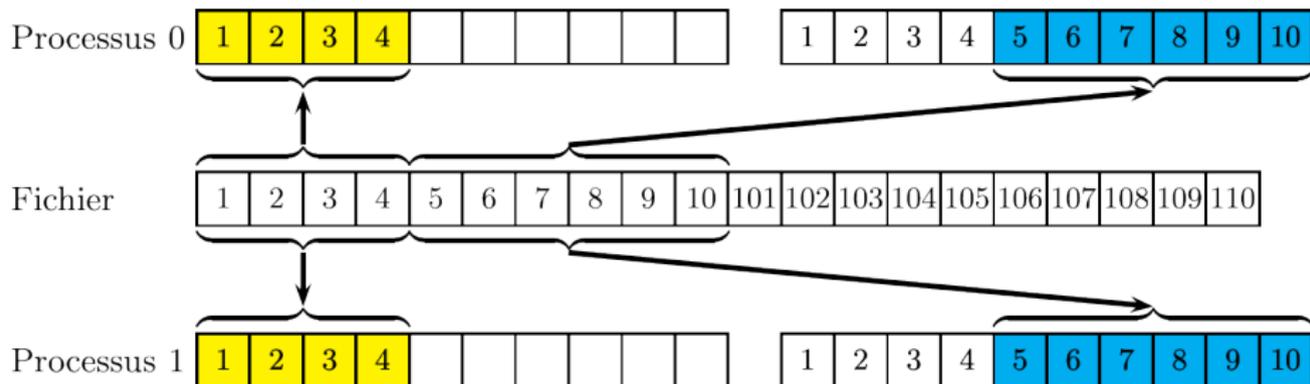


Figure 54 – Exemple 1 d'utilisation de `MPI_File_read_all()`

```
> mpiexec -n 2 read_all01
```

```
Lecture processus 0 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
```

```
Lecture processus 1 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
```

```
1  /* read_all102 */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_valeurs=10, indicel, indice2;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init(&argc, &argv);
12     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
13     MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
14                 MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15
16     if (rang == 0) {
17         indicel=2;
18         indice2=5;
19     } else {
20         indicel=4;
21         indice2=8;
22     }
23     MPI_File_read_all(descripteur, &(valeurs[indicel]),
24                     indice2-indicel+1, MPI_INT, &statut);
25     printf("Lecture processus %d : ", rang);
26     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
27     MPI_File_close(&descripteur);
28     MPI_Finalize();
29 }
```

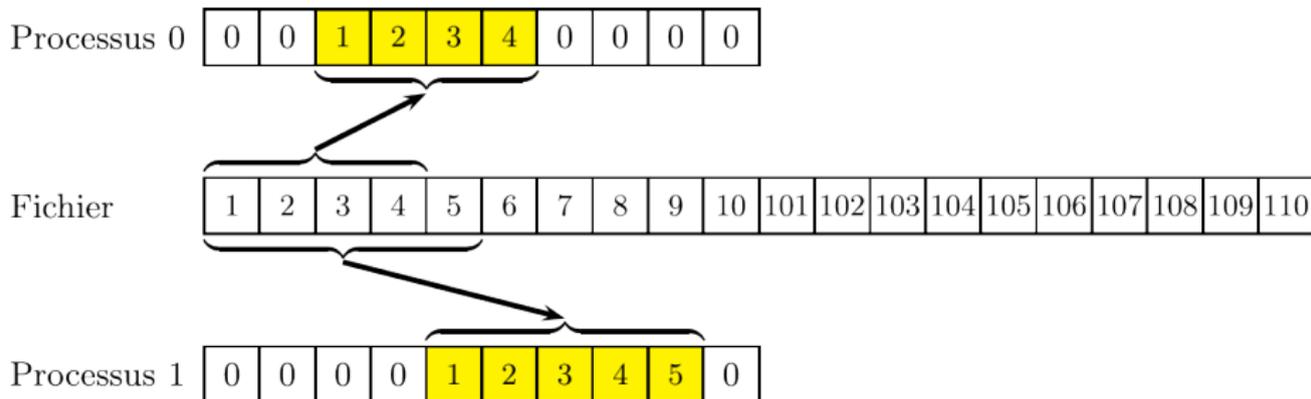


Figure 55 – Exemple 2 d'utilisation de `MPI_File_read_all()`

```
> mpiexec -n 2 read_all02
```

```
Lecture processus 1 : 0, 0, 0, 0, 1, 2, 3, 4, 5, 0
```

```
Lecture processus 0 : 0, 0, 1, 2, 3, 4, 0, 0, 0, 0
```

```
1  /* read_all03 */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_valeurs=10, indic1, indice2;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init(&argc, &argv);
12     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
13     MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
14                 MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15     if (rang == 0) {
16         MPI_File_read_all(descripteur, &(valeurs[2]), 4, MPI_INT, &statut);
17     } else {
18         MPI_File_read_all(descripteur, &(valeurs[4]), 5, MPI_INT, &statut);
19     }
20     printf("Lecture processus %d : ", rang);
21     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
22     MPI_File_close(&descripteur);
23     MPI_Finalize();
24 }
```

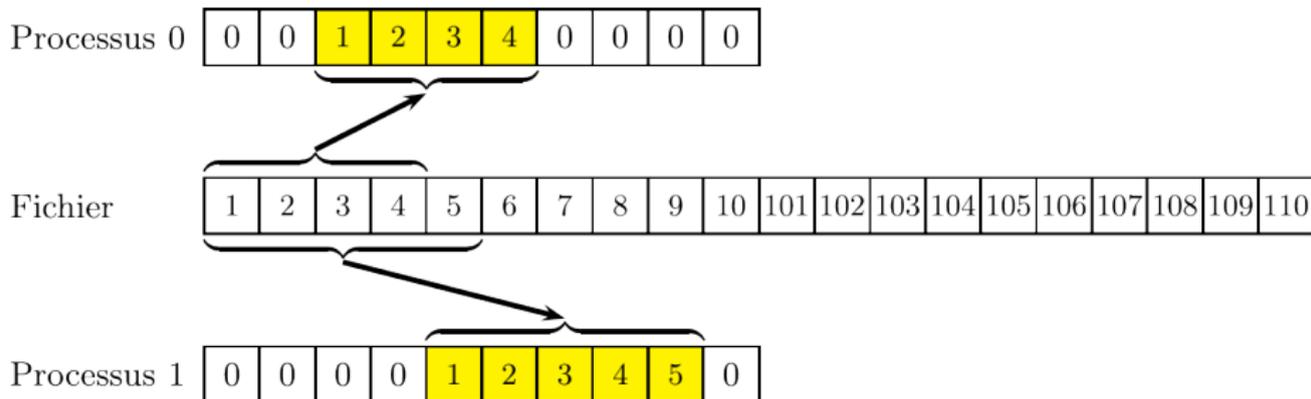


Figure 56 – Exemple 3 d'utilisation de `MPI_File_read_all()`

```
> mpiexec -n 2 read_all03
```

```
Lecture processus 1 : 0, 0, 0, 0, 1, 2, 3, 4, 5, 0
```

```
Lecture processus 0 : 0, 0, 1, 2, 3, 4, 0, 0, 0, 0
```

```
1  /* read_ordered */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_valeurs=10;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init (&argc, &argv);
12     MPI_Comm_rank (MPI_COMM_WORLD, &rang);
13     MPI_File_open (MPI_COMM_WORLD, "donnees.dat",
14                   MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15     MPI_File_read_ordered (descripteur, valeurs, 4, MPI_INQ, &statut);
16     MPI_File_read_ordered (descripteur, &(valeurs[4]), 6, MPI_INQ, &statut);
17     printf("Lecture processus %d : ", rang);
18     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
19     MPI_File_close (&descripteur);
20     MPI_Finalize ();
21 }
```

MPI-IO

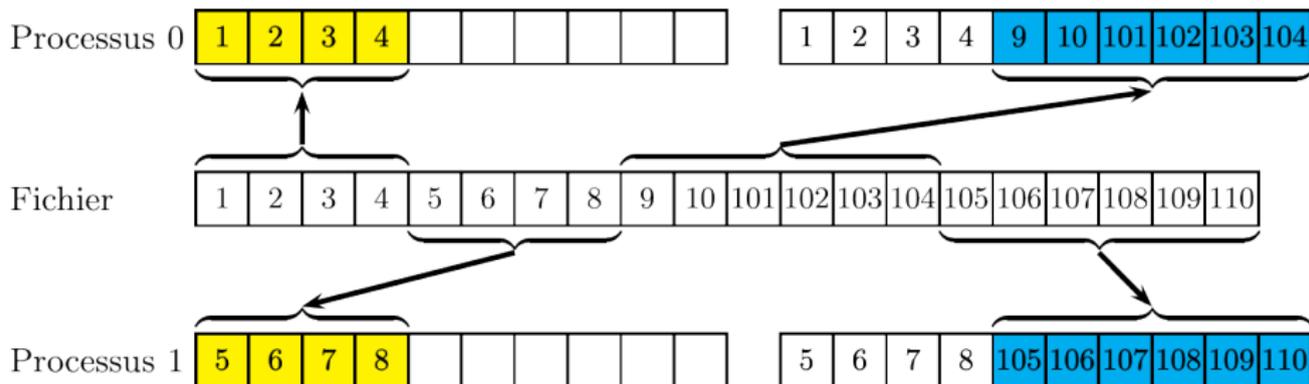


Figure 57 – Exemple d'utilisation de `MPI_File_ordered()`

```
> mpiexec -n 2 read_ordered
```

```
Lecture processus 1 : 5, 6, 7, 8, 105, 106, 107, 108, 109, 110
```

```
Lecture processus 0 : 1, 2, 3, 4, 9, 10, 101, 102, 103, 104
```

Positionnement explicite des pointeurs dans un fichier

- Les sous-programmes `MPI_File_get_position()` et `MPI_File_get_position_shared()` permettent de connaître respectivement la valeur courante des pointeurs individuels et celle du pointeur partagé.
- Il est possible de **positionner explicitement** les pointeurs individuels à l'aide du sous-programme `MPI_File_seek()`, et de même le pointeur partagé avec le sous-programme `MPI_File_seek_shared()`.
- Il y a **trois modes** possibles pour modifier la valeur d'un pointeur :
 - `MPI_SEEK_SET` permet de définir un déplacement absolu ;
 - `MPI_SEEK_CUR` permet un déplacement relativement à la position courante ;
 - `MPI_SEEK_END` positionne le pointeur à la fin du fichier, à laquelle un déplacement éventuel est ajouté.
- Avec `MPI_SEEK_CUR` et `MPI_SEEK_END`, on peut spécifier une valeur négative, ce qui permet de revenir **en arrière** dans le fichier.

```
1  /* seek */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_octets_entier, nb_valeurs=10;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10     MPI_Offset position_fichier;
11
12     MPI_Init(&argc, &argv);
13     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
14     MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
15                 MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
16     MPI_File_read(descripteur, valeurs, 3, MPI_INT, &statut);
17     MPI_Type_size(MPI_INT, &nb_octets_entier);
18     position_fichier = 8*nb_octets_entier;
19     MPI_File_seek(descripteur, position_fichier, MPI_SEEK_CUR);
20     MPI_File_read(descripteur, &(valeurs[3]), 3, MPI_INT, &statut);
21     position_fichier = 4*nb_octets_entier;
22     MPI_File_seek(descripteur, position_fichier, MPI_SEEK_SET);
23     MPI_File_read(descripteur, &(valeurs[6]), 4, MPI_INT, &statut);
24     printf("Lecture processus %d : ", rang);
25     for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
26     MPI_File_close(&descripteur);
27     MPI_Finalize();
28 }
```

MPI-IO

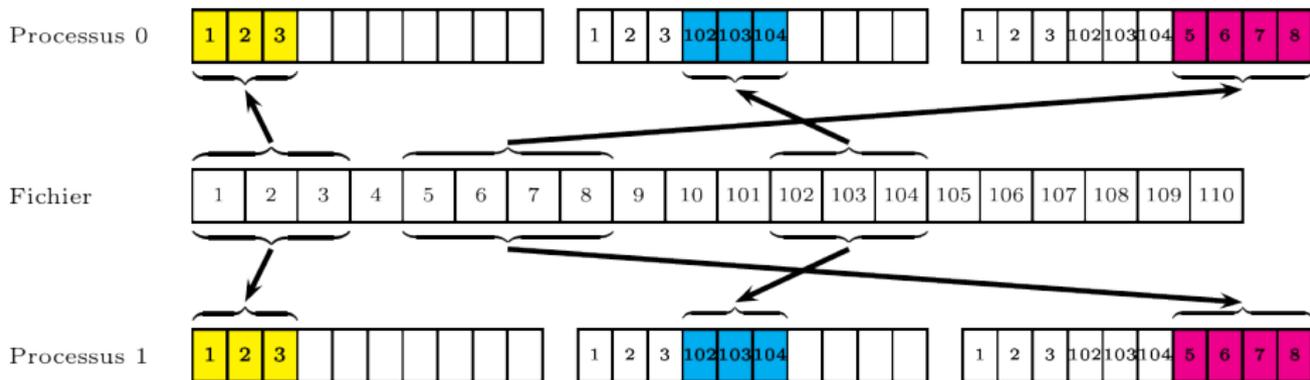


Figure 58 – Exemple d'utilisation de `MPI_File_seek()`

```
> mpiexec -n 2 seek  
Lecture processus 1 : 1, 2, 3, 102, 103, 104, 5, 6, 7, 8  
Lecture processus 0 : 1, 2, 3, 102, 103, 104, 5, 6, 7, 8
```

Lectures/écritures non bloquantes

- L'intérêt est de faire un recouvrement entre les calculs et les entrées-sorties.
- Les entrées-sorties non bloquantes sont implémentées suivant le modèle utilisé pour les communications non bloquantes entre processus.
- Un accès non-bloquant doit donner lieu ultérieurement à un test explicite de complétude ou à une mise en attente (via `MPI_Test()`, `MPI_Wait()`, etc.)

```
1  /* iread_at */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, nb_octets_entier, termine, nb_valeurs=10, nb_iterations=0;
7      int valeurs[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10     MPI_Offset position_fichier;
11     MPI_Request requete;
12
13     MPI_Init(&argc, &argv);
14     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
```

```
15 MPI_File_open (MPI_COMM_WORLD, "donnees.dat",
16 MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
17 MPI_Type_size (MPI_INT, &nb_octets_entier);
18 position_fichier = rang*nb_valeurs*nb_octets_entier;
19 MPI_File_iread_at (descripteur, position_fichier,
20 valeurs, nb_valeurs, MPI_INT, &requete);
21 while( nb_iterations < 5000) {
22     nb_iterations = nb_iterations+1;
23     /* Calculs recouvrant le temps demande par l'operation de lecture */
24     /* */
25     MPI_Test (&requete, &termine, &statut);
26     if (termine) break;
27 }
28 if ( !termine) MPI_Wait (&requete, &statut);
29 printf("Apres %d iterations, lecture processus %d : ", nb_iterations, rang);
30 for (i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]); printf("\n");}
31 MPI_File_close (&descripteur);
32 MPI_Finalize ();
33 }
```

MPI-IO

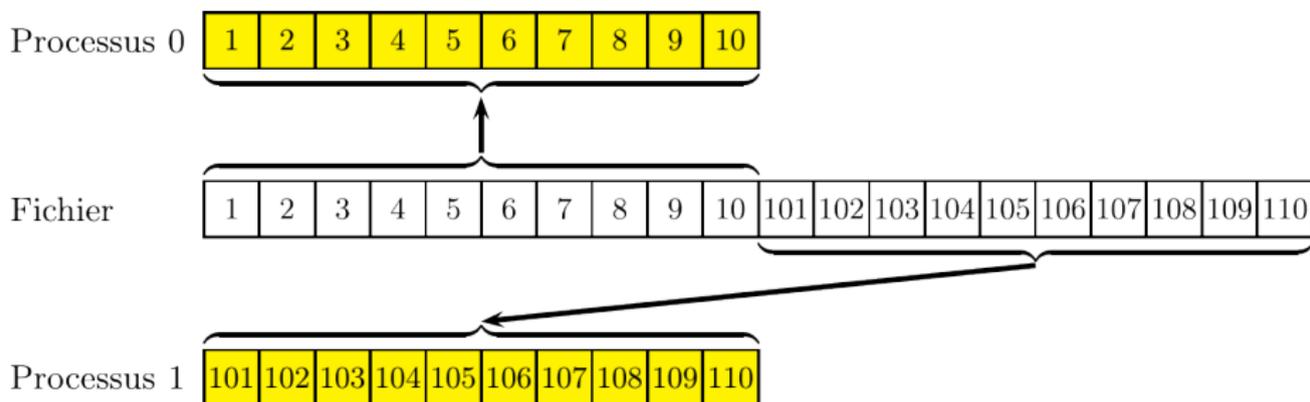


Figure 59 – Exemple d'utilisation de `MPI_File_iread_at()`

```
> mpiexec -n 2 iread_at
```

```
Après 1 iterations, lecture processus 0 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
```

```
Après 1 iterations, lecture processus 1 : 101, 102, 103, 104, 105, 106, 107, 108, 109, 110
```

```
1  /* iwrite */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, termine, nb_valeurs=10, nb_iterations=0;
7      int valeurs[nb_valeurs], temp[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Request requete;
10
11     MPI_Init (&argc, &argv);
12     MPI_File_open (MPI_COMM_WORLD, "donnees.dat",
13                  MPI_MODE_WRONLY+MPI_MODE_CREATE, MPI_INFO_NULL, &descripteur);
14     for(i=0; i<nb_valeurs; i++) temp[i]=valeurs[i];
15     MPI_File_seek (descripteur, deplacement, MPI_SEEK_SET);
16     MPI_File_irewrite (descripteur, temp, nb_valeurs, MPI_INI, &requete);
17     while( nb_iterations < 5000) {
18         nb_iterations = nb_iterations+1;
19         /* Calculs recouvrant le temps demande par l'operation de lecture */
20         /* */
21         MPI_Test (&requete, &termine, MPI_STATUS_IGNORE);
22         if (termine) {
23             for(i=0; i<nb_valeurs; i++) temp[i]=valeurs[i];
24             MPI_File_seek (descripteur, deplacement, MPI_SEEK_SET);
25             MPI_File_irewrite (descripteur, temp, nb_valeurs, MPI_INI, &requete); }
26     }
27     MPI_Wait (&requete, MPI_STATUS_IGNORE);
28     MPI_File_close (&descripteur);
29     MPI_Finalize ();
30 }
```

Lectures/écritures collectives et non bloquantes

- Il est possible d'effectuer des opérations qui soient à la fois **collectives** et **non bloquantes**.
- Celles-ci nécessitent un appel à deux sous-programmes distincts, l'un pour déclencher l'opération et l'autre pour la terminer.
- Il ne peut y avoir qu'une seule opération collective non bloquante en cours à la fois par processus.
- Entre les deux phases de l'opération collective non-bloquante, il est possible de faire des opérations non collectives sur le fichier, mais la zone mémoire concernée par l'opération collective ne peut être modifiée.

```
1  /* read_ordered_begin_end */
2  #include <mpi.h>
3  #include <stdio.h>
4
5  int main(int argc, char *argv[]) {
6      int rang, i, termine, nb_valeurs=10, nb_iterations=0;
7      int valeurs[nb_valeurs], temp[nb_valeurs];
8      MPI_File descripteur;
9      MPI_Status statut;
10
11     MPI_Init(&argc, &argv);
12     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
13     MPI_File_open(MPI_COMM_WORLD, "donnees.dat",
14                 MPI_MODE_RDONLY, MPI_INFO_NULL, &descripteur);
15     MPI_File_read_ordered_begin(descripteur, valeurs, 4, MPI_INFO);
16     printf("Processus numero : %d\n", rang);
17     MPI_File_read_ordered_end(descripteur, valeurs, &statut);
18     printf("Lecture processus %d : %d %d %d %d\n",
19           rang, valeurs[0], valeurs[1], valeurs[2], valeurs[3]);
20     MPI_File_close(&descripteur);
21     MPI_Finalize();
22 }
```


T.P. MPI – Exercice 7 : Lecture d'un fichier en mode parallèle

- On dispose du fichier binaire `donnees.dat`, constitué d'une suite de 484 valeurs entières
- En considérant un programme parallèle mettant en œuvre 4 processus, il s'agit de lire les 121 premières valeurs sur le processus 0, les 121 suivantes sur le processus 1, etc. et d'écrire celles-ci dans quatre fois quatre fichiers appelés `fichier_XXX0.dat` . . . `fichier_XXX3.dat`
- On emploiera pour ce faire 4 méthodes différentes, parmi celles présentées :
 - lecture via des déplacements explicites, en mode individuel ;
 - lecture via les pointeurs partagés, en mode collectif ;
 - lecture via les pointeurs individuels, en mode individuel ;
 - lecture via les pointeurs partagés, en mode individuel.
- Pour compiler utilisez la commande `make`, pour exécuter le code utilisez la commande `make exe` et pour vérifier les résultats utilisez la commande `make verification` qui génère des fichiers images correspondant aux quatre cas à traiter.

MPI 3.x

Ajout

- Communications collectives non bloquantes
- Communications collectives entre voisins
- Interface Fortran 2008
- Suppression de l'interface C++
- Extension des copies mémoire à mémoire

Communications collectives non bloquantes

- Version non bloquante des communications collectives
- Avec un I (*immediate*) devant : `MPI_Ireduce()`, `MPI_Ibcast()`, ...
- Attente avec les appels `MPI_Wait()`, `MPI_Test()` et leurs variantes
- Pas de correspondance bloquant et non bloquant
- Le *status* récupéré par `MPI_Wait()` contient une valeur non définie pour `MPI_SOURCE` et `MPI_TAG`
- Pour les processus d'un communicateur donné, l'ordre des appels doit être le même (comme en version bloquante)

```
int MPI_Ibarrier(MPI_Comm comm, MPI_Request *request)
```

Communications collectives entre voisins

- `MPI_Neighbor_allgather()` et la variante `V`, `MPI_Neighbor_alltoall()` et les variantes `V` et `W`
- Plus les versions non-bloquantes

```
MPI_Neighbor_allgather (u, 1, MPI_INT, v, 1, MPI_INT, comm2d);
```

MPI 3.x

Module mpi_f08

- Utilisation via le module `mpi_f08`
- Avec ce module, le dernier argument (*code*) est *optional*
- Les objets MPI ont un type particulier et ne sont plus des `INTEGER`
- C'est le module à privilégier désormais

Par exemple pour `MPI_RECV()` on a comme interface avec le module classique :

```
<type> buf(*)  
INTEGER :: count, datatype, source, tag, comm, ierror  
INTEGER, DIMENSION(MPI_STATUS_SIZE) :: statut
```

Avec le module `mpi_f08` :

```
TYPE(*), DIMENSION(..) :: buf  
INTEGER :: count, source, tag  
TYPE(MPI_DATATYPE) :: datatype  
TYPE(MPI_COMM) :: comm  
TYPE(MPI_STATUS) :: statut  
INTEGER, optional :: ierror
```

MPI 3.x

Module mpi_f08

Ces nouveaux types sont en fait des encapsulations d'INTEGER

```
TYPE, BIND(C) :: MPI_COMM
  INTEGER :: MPI_VAL
END TYPE MPI_COMM
```

Module mpi_f08, fonctionnalités facultatives

- Si `MPI_SUBARRAYS_SUPPORTED` est à *true*, il est possible d'utiliser des sections de tableaux pour les appels non bloquants.
- Si `MPI_ASYNC_PROTECTS_NONBLOCKING` est à *true*, les arguments d'envoi et/ou de réception sont *asynchronous* pour les interfaces des appels non bloquants.

```
call MPI_ISEND(buf,...,req)
...
call MPI_WAIT(req,...)
if (.not. MPI_ASYNC_PROTECTS_NONBLOCKING) call MPI_F_SYNC_REG(buf)
buf = val2
```

Suppression de l'interface C++

À remplacer soit par l'interface C, soit par l'interface *Boost.MPI*

Extension des copies mémoire à mémoire

- Ajout de l'opération `MPI_Get_accumulate()`
- de l'opération `MPI_Fetch_and_op()` un `MPI_Get_accumulate()` qui fonctionne sur un seul élément
- et de l'opération `MPI_Compare_and_swap()`
- Ajout de la fonction `MPI_Win_allocate()` pour allouer et créer la fenêtre en même temps
- Ajout de la fonction `MPI_Win_allocate_shared()` pour créer la fenêtre en mémoire partagée

```
MPI_Comm_split_type(MPI_COMM_WORLD, MPI_COMM_TYPE_SHARED, cle, MPI_INFO_NULL, &commnoeud);  
MPI_Win_allocate_shared(taille, deplacement, MPI_INFO_NULL, commnoeud, &ptr, &win);  
MPI_Win_shared_query(win, rang, &taille_distant, &disp, &ptr_distant);
```

MPI 3.x

MPI 3.1

- Ajout de `MPI_Aint_add()` et `MPI_Aint_diff()` pour les manipulations d'adresses.
- Ajout de `MPI_File_iread_at_all()` `MPI_File_iread_all()` `MPI_File_iwrite_all()` et `MPI_File_iwrite_at_all()`

MPI 4.x

Ajout

- Grand nombre
- Communication par morceaux
- MPI Session
- Autres

Grand nombre

- Les nombres d'éléments étaient en `integer` ou `int`.
- MPI 4.0 ajoute des fonctions avec `MPI_Count` à la place.
- En C ces nouvelles fonctions contiennent en plus `_c` à la fin de la fonction.

```
int MPI_Send(const void * buf, int count, MPI_Datatype datatype, int dest, int tag, MPI_Comm comm);
int MPI_Send_c(const void * buf, MPI_Count count, MPI_Datatype datatype, int dest, int tag, MPI_Comm comm);
```

- En *Fortran* les nombres en `integer` peuvent être remplacés par

```
integer(kind=MPI_COUNT_KIND).
```

- Uniquement disponible avec le module `mpi_f08`.
- Pas de changement de nom grâce au polymorphisme.

```
MPI_Send(buf, count, datatype, dest, tag, comm, ierror)
TYPE(*), DIMENSION(..), INTENT(IN) :: buf
INTEGER, INTENT(IN) :: count, dest, tag
TYPE(MPI_Datatype), INTENT(IN) :: datatype
TYPE(MPI_Comm), INTENT(IN) :: comm
INTEGER, OPTIONAL, INTENT(OUT) :: ierror
```

```
MPI_Send(buf, count, datatype, dest, tag, comm, ierror)
TYPE(*), DIMENSION(..), INTENT(IN) :: buf
INTEGER(KIND=MPI_COUNT_KIND), INTENT(IN) :: count
TYPE(MPI_Datatype), INTENT(IN) :: datatype
INTEGER, INTENT(IN) :: dest, tag
TYPE(MPI_Comm), INTENT(IN) :: comm
INTEGER, OPTIONAL, INTENT(OUT) :: ierror
```

Communication par morceaux

- Contribution multiple à une communication.
- Utile pour l'hybride.
- Initialisation avec `MPI_Psend_init()` ou `MPI_Precv_init()` en fournissant le nombre d'éléments par partition et le nombre de partitions.
- `MPI_Start()` pour démarrer la communication.
- `MPI_Pready()` pour signaler qu'une partition est prête.
- Il n'est pas possible de faire un `MPI_Recv()` d'un `MPI_Psend_init()`
- `MPI_Wait()` pour terminer la communication
- `MPI_Parrived()` permet de savoir si une partition a été reçue

Sessions

- Permettre de faire plusieurs `MPI_Init()`/`MPI_Finalize()`.
- `MPI_Session_init()` pour lancer une session.
- `MPI_Session_finalize()` pour terminer la session.
- Plus de notion de `MPI_COMM_WORLD`.
- Notion de *Process Sets* : `mpi://WORLD` et `mpi://SELF`.
- `MPI_Group_from_session_pset()` pour faire un groupe à partir d'un *pset*.
- `MPI_Comm_create_from_group()` pour faire un communicateur à partir d'un groupe.
- `MPI_Session_get_num_psets()` permet d'obtenir le nombre de *pset* disponible.
- `MPI_Session_get_nth_pset()` permet d'avoir le nom d'un *pset* disponible.

Autres

- Ajout de `MPI_Isendrecv` et `MPI_Isendrecv_replace`.
- Ajout des communications collectives persistentes.
- Ajout de l'option `mpi_initial_errhandler` pour `mpiexec` afin de spécifier le gestionnaire d'erreur par défaut.

MPI-IO Vues

MPI-IO Vues

Définition des vues

- C'est un mécanisme permettant de décrire un schéma d'accès aux fichiers.
- Une vue est définie par trois variables : un **déplacement initial**, un **type élémentaire de données** et un **motif**.
- L'accès aux fichiers s'effectue par répétition du motif, une fois le positionnement initial effectué.

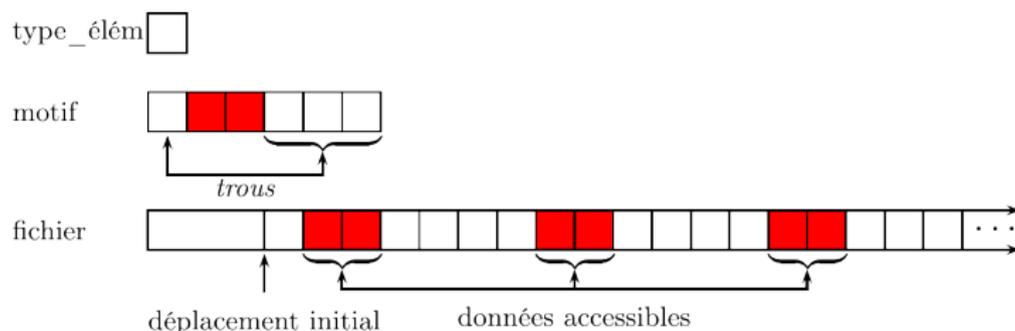


Figure 61 – Type élémentaire de donnée et motif

Définition des vues

- Les vues sont construites à l'aide de **types dérivés** MPI.
- Il est possible de définir des **trous** dans une vue, de façon à ne pas tenir compte de certaines parties des données.
- La vue par défaut consiste en une simple suite d'octets (déplacement initial nul, **type_élé**m et motif égal à `MPI_BYTE`).

Vues multiples

- Un processus donné peut définir et utiliser successivement **plusieurs vues** d'un même fichier.
- Les processus peuvent avoir des **vues différentes** du fichier, de façon à accéder à des parties complémentaires de celui-ci.

MPI-IO Vues

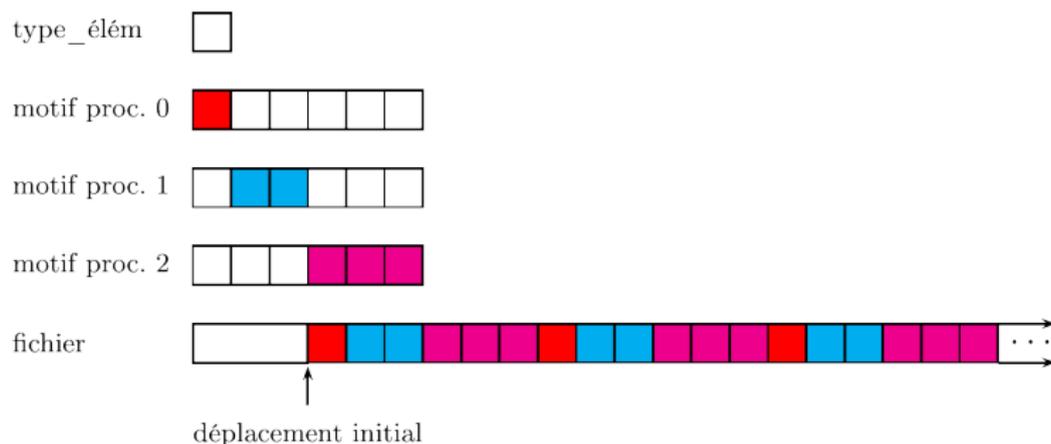


Figure 62 – Exemple de définition de motifs différents selon les processus

Remarques :

- Un pointeur partagé n'est utilisable avec une vue que si tous les processus ont la même vue.
- Si le fichier est ouvert en écriture, les zones décrites par les différentes vues ne peuvent se recouvrir, même partiellement.

Changement de la vue sur un fichier : `MPI_File_set_view()`

```
int MPI_File_set_view(MPI_File descripteur, MPI_Offset deplacement_initial, MPI_Datatype type_elem, MPI_Datatype motif, char *mode, MPI_Info info)
```

- C'est une **opération collective** à l'ensemble des processus impliqués dans l'accès au fichier. Chaque processus peut définir **un déplacement initial et un motif différent**. L'étendue du type élémentaire doit être identique.
- Les pointeurs individuels et le pointeur partagé **sont réinitialisés au début de la vue**.

Notes :

- Les types dérivés utilisés dans la vue doivent avoir été validés au préalable à l'aide du sous-programme `MPI_Type_commit()`.
- Il y a trois représentations possibles des données (mode) : "native", "internal" ou "external32".

Construction de sous-tableaux

Un type dérivé utile pour créer un motif est le type “subarray”, qu’on introduit ici. Ce type permet de créer un sous-tableau à partir d’un tableau et se définit via le sous-programme `MPI_Type_create_subarray()`.

Le **profil** d’un tableau est un vecteur dont chaque élément est le nombre d’éléments dans chaque dimension. Soit par exemple le tableau $T(10, 0:5, -10:10)$ (ou $T[10][6][21]$), son profil est le vecteur **(10,6,21)**.

MPI-IO Vues / Types de données dérivés

```
int MPI_Type_create_subarray(int nb_dims, const int profil_tab[], const int profil_sous_tab[],  
                             const int coord_debut[], int ordre, MPI_Datatype ancien_type,  
                             MPI_Datatype *nouveau_type)
```

Description des arguments

- `nb_dims` : nombre de dimension du tableau
- `profil_tab` : profil du tableau à partir duquel on va extraire un sous-tableau
- `profil_sous_tab` : profil du sous-tableau
- `coord_debut` : coordonnées de départ du sous-tableau dans le tableau, les indices du tableau commençant à 0. Par exemple, si on veut que les coordonnées de départ du sous-tableau soient `tab(2, 3)`, il faut que `coord_debut(:) = (/ 1, 2 /)`
- `ordre` : ordre de stockage des éléments
 - `MPI_ORDER_FORTRAN` spécifie le mode de stockage en Fortran, c.-à-d. suivant les colonnes
 - `MPI_ORDER_C` spécifie le mode de stockage en C, c.-à-d. suivant les lignes

Échanges entre 2 processus avec subarray

AVANT			APRES		
1	5	9	1	5	9
2	6	10	-7	-11	10
3	7	11	-8	-12	11
4	8	12	4	8	12
Processus 0			Processus 0		
-1	-5	-9	-1	-5	-9
-2	-6	-10	-2	-6	-10
-3	-7	-11	-3	2	6
-4	-8	-12	-4	3	7
Processus 1			Processus 1		

Figure 63 – Échanges entre les 2 processus

Échanges entre 2 processus avec subarray : code

```
1  /* subarray */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, i, j;
8      int nb_lignes=4, nb_colonnes=3, sign=1, nb_dims=2, etiquette=1000;
9      int tab[nb_lignes][nb_colonnes], profil_tab[nb_dims];
10     int profil_sous_tab[nb_dims], coord_debut[nb_dims];
11     MPI_Datatype type_sous_tab;
12     MPI_Status statut;
13
14     MPI_Init(&argc, &argv);
15     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
16
17     /* Initialisation du tableau tab sur chaque processus */
18     if (rang == 1) sign=-1;
19     for(i=0; i<nb_lignes; i++) {
20         for(j=0; j<nb_colonnes; j++) {
21             tab[i][j] = sign*(1+i+nb_lignes*j); } }
```

Échanges entre 2 processus avec subarray : code (suite)

```
22  /* Profil du tableau tab a partir duquel on va extraire un sous tableau */
23  profil_tab[0] = nb_lignes; profil_tab[1] = nb_colonnes;
24  /* Profil du sous tableau */
25  profil_sous_tab[0] = 2; profil_sous_tab[1] = 2;
26  /* Coordonnees de depart du sous tableau */
27  coord_debut[0]= rang+1; coord_debut[1]= rang;
28  /* Creation du type type_sous_tab */
29  MPI_Type_create_subarray (nb_dims,profil_tab,profil_sous_tab,coord_debut,
30                          MPI_ORDER_C, MPI_INT, &type_sous_tab);
31  MPI_Type_commit (&type_sous_tab);
32
33  /* Permutation du sous-tableau */
34  MPI_Sendrecv_replace (tab,1,type_sous_tab,(rang+1)%2,etiquette,
35                       (rang+1)%2,etiquette,MPI_COMM_WORLD,&statut);
36
37  MPI_Type_free (&type_sous_tab);
38  MPI_Finalize ();
39 }
```

MPI-IO Vues

Exemple 1 : lecture d'un fichier par blocs de deux éléments

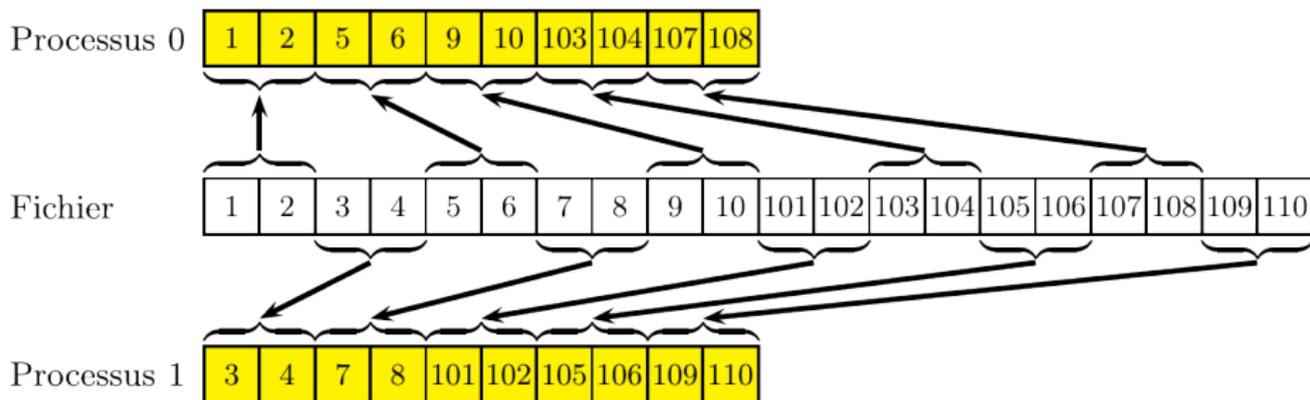


Figure 64 – Exemple 1 : lecture d'un fichier par blocs de deux éléments

```
> mpiexec -n 2 read_view01
```

```
Lecture processus 1 : 3, 4, 7, 8, 101, 102, 105, 106, 109, 110  
Lecture processus 0 : 1, 2, 5, 6, 9, 10, 103, 104, 107, 108
```

Exemple 1 (suite)

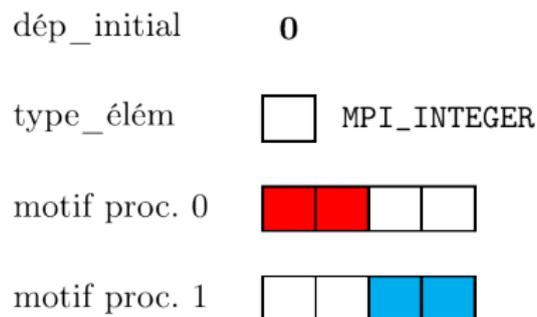


Figure 65 – Exemple 1 (suite) : création des vues sur le fichier

```
1 profil_tab[0] = 4;profil_sous_tab[0] = 2;  
2 if (rang == 0) coord[0]=0;  
3 if (rang == 1) coord[0]=2;  
4 MPI_Type_create_subarray(1,profil_tab,profil_sous_tab,coord,MPI_ORDER_C,MPI_INT,&motif);  
5 MPI_Type_commit(&motif);  
6 deplacement_initial=0  
7 MPI_File_set_view(descriptor,deplacement_initial,MPI_INT,motif,"native",MPI_INFO_NULL);
```

Exemple 1 : code complet

```
1  /* read_view01 */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, i, coord, n1=4, n2=2, nb_valeurs=10;
8      int valeurs[nb_valeurs];
9      MPI_Datatype motif;
10     MPI_File descripteur;
11     MPI_Offset deplacement_initial;
12     MPI_Status statut;
13     MPI_Init(&argc, &argv);
14     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
15     if (rang == 0) coord=0;
16     if (rang == 1) coord=2;
17     MPI_Type_create_subarray(1, &n1, &n2, &coord, MPI_ORDER_C, MPI_INT, &motif);
18     MPI_Type_commit(&motif);
19
20     MPI_File_open(MPI_COMM_WORLD, "donnees.dat", MPI_MODE_RDONLY, MPI_INFO_NULL,
21                 &descripteur);
22     deplacement_initial=0;
23     MPI_File_set_view(descripteur, deplacement_initial, MPI_INT, motif,
24                     "native", MPI_INFO_NULL);
25     MPI_File_read(descripteur, valeurs, nb_valeurs, MPI_INT, &statut);
26     printf("Lecture processus %d :", rang);
27     for(i=0; i<nb_valeurs; i++) {printf("%d ", valeurs[i]);} printf("\n");
28     MPI_File_close(&descripteur);
29     MPI_Finalize();
30 }
```

MPI-IO Vues

Exemple 2 : utilisation successive de plusieurs vues

dép_initial 0

type_élément  MPI_INTEGER

motif_1 

dép_initial 2 entiers

type_élément  MPI_INTEGER

motif_2 

Figure 66 – Exemple 2 : utilisation successive de plusieurs vues

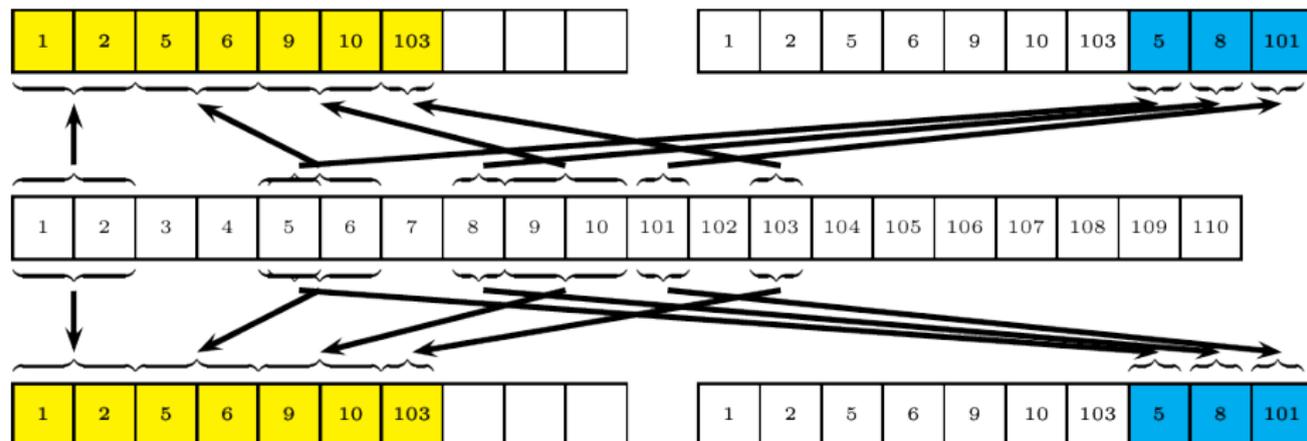
```
1  /* read_view02 */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, n1, n2, coord, nb_octets_entier, nb_valeurs=10, valeurs[nb_valeurs], i;
8      MPI_Datatype motif_1, motif_2;
9      MPI_File descripteur;
10     MPI_Offset deplacement_initial;
11     MPI_Status statut;
12
13     MPI_Init(&argc, &argv);
14     MPI_Comm_rank(MPI_COMM_WORLD, &rang);
```

Exemple 2 (suite du code)

```
15  nl=4;n2=2;coord=0;
16  MPI_Type_create_subarray(1,&nl,&n2,&coord,MPI_ORDER_C,MPI_INT,&motif_1);
17  MPI_Type_commit(&motif_1);
18  nl=3;n2=1;coord=2;
19  MPI_Type_create_subarray(1,&nl,&n2,&coord,MPI_ORDER_C,MPI_INT,&motif_2);
20  MPI_Type_commit(&motif_2);
21
22  MPI_File_open(MPI_COMM_WORLD,"donnees.dat",MPI_MODE_RDONLY,MPI_INFO_NULL,
23               &descripteur);
24
25  /* Lecture en utilisant la premiere vue */
26  deplacement_initial=0;
27  MPI_File_set_view(descripteur,deplacement_initial,MPI_INT,motif_1,
28                  "native",MPI_INFO_NULL);
29  MPI_File_read(descripteur,valeurs,4,MPI_INT,&statut);
30  MPI_File_read(descripteur,&(valeurs[4]),3,MPI_INT,&statut);
31
32  /* Lecture en utilisant la seconde vue */
33  MPI_Type_size(MPI_INT,&nb_octets_entier);
34  deplacement_initial=2*nb_octets_entier;
35  MPI_File_set_view(descripteur,deplacement_initial,MPI_INT,motif_2,
36                  "native",MPI_INFO_NULL);
37  MPI_File_read(descripteur,&(valeurs[7]),3,MPI_INT,&statut);
38  printf("Lecture processus %d :",rang);
39  for(i=0;i<nb_valeurs;i++) {printf("%d ", valeurs[i]);} printf("\n");
40  MPI_File_close(&descripteur);
41  MPI_Finalize();
42 }
```

MPI-IO Vues

Exemple 2 : illustration



```
> mpiexec -n 2 read_view02
```

```
Lecture processus 1 : 1, 2, 5, 6, 9, 10, 103, 5, 8, 101
```

```
Lecture processus 0 : 1, 2, 5, 6, 9, 10, 103, 5, 8, 101
```

MPI-IO Vues

Exemple 3 : gestion des trous dans les types de données

dép_initial 0 entiers

type_élément  MPI_INTEGER

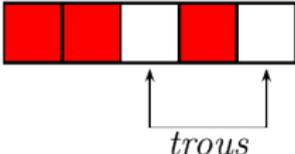
motif 

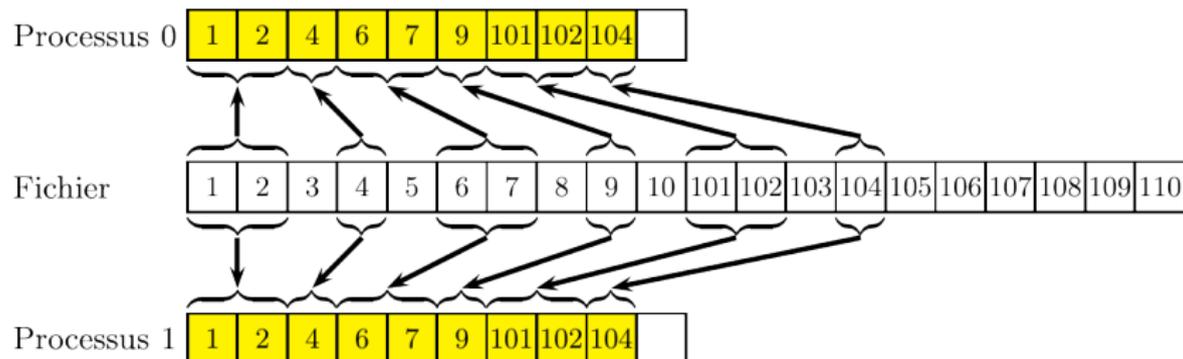
Figure 67 – Exemple 3 : gestion des trous dans les types de données

```
1  /* read_view03_indexed */
2  #include <mpi.h>
3  #include <stdio.h>
4  #include <stdlib.h>
5
6  int main(int argc, char *argv[]) {
7      int rang, nb_octets_entier, nb_valeurs=9, valeurs[nb_valeurs], i;
8      int longueurs[2], deplacements[2];
9      MPI_Datatype motif_temp, motif;
10     MPI_Aint borne_inf, etendue;
11     MPI_File descripteur;
12     MPI_Offset deplacement_initial;
13     MPI_Status statut;
```

Exemple 3 (suite du code)

```
14 MPI_Init(&argc,&argv);
15 MPI_Comm_rank(MPI_COMM_WORLD,&rang);
16
17 deplacements[0]=0; deplacements[1]=3;longueurs[0]=2;longueurs[1]=1;
18 MPI_Type_indexed(2,longueurs,deplacements,MPI_INT,&motif_temp);
19
20 /* Motif : type MPI d'etendu 5*MPI_INT */
21 MPI_Type_size(MPI_INT,&nb_octets_entier);
22 MPI_Type_get_extent(motif_temp,&borne_inf,&etendue);
23 etendue = etendue+nb_octets_entier;
24 MPI_Type_create_resized(motif_temp,borne_inf,etendue+borne_inf,&motif);
25 MPI_Type_commit(&motif);
26
27 MPI_File_open(MPI_COMM_WORLD,"donnees.dat",MPI_MODE_RDONLY,MPI_INFO_NULL,
28             &descripteur);
29
30 deplacement_initial=0;
31 MPI_File_set_view(descripteur,deplacement_initial,MPI_INT,motif,
32                 "native",MPI_INFO_NULL);
33 MPI_File_read(descripteur,valeurs,9,MPI_INT,&statut);
34
35 printf("Lecture processus %d :",rang);
36 for(i=0;i<nb_valeurs;i++) {printf("%d ",valeurs[i]);} printf("\n");
37 MPI_File_close(&descripteur);
38 MPI_Finalize();
39 }
```

Exemple 3 : illustration



```
> mpiexec -n 2 read_view03
```

```
Lecture, processus 0 : 1, 2, 4, 6, 7, 9, 101, 102, 104
```

```
Lecture, processus 1 : 1, 2, 4, 6, 7, 9, 101, 102, 104
```

Exemple 3 : implémentation alternative utilisant un type structure

```
1  /* read_view03_struct */
2
3  profil_tab=3;profil_sous_tab=2;coord=0;
4  MPI_Type_create_subarray(1,&profil_tab,&profil_sous_tab,&coord,MPI_ORDER_C,MPI_INT,&temp_motif1);
5  profil_tab=2;profil_sous_tab=1;
6  MPI_Type_create_subarray(1,&profil_tab,&profil_sous_tab,&coord,MPI_ORDER_C,MPI_INT,&temp_motif2);
7  MPI_Type_size(MPI_INT,&nb_octets_entier);
8  déplacements[0]=0;déplacements[1]=3*nb_octets_entier;
9  bloc[0]=1;bloc[1]=1;type[0]=temp_motif1;type[1]=temp_motif2;
10 MPI_Type_create_struct(2,bloc,déplacements,type,&motif);
11 MPI_Type_commit(motif);
```

Conclusion

MPI-IO offre une interface de haut niveau et un ensemble de fonctionnalités très riche. Il est possible de réaliser des opérations complexes et de tirer parti des optimisations implémentées dans la bibliothèque. MPI-IO offre aussi une bonne portabilité.

Conseils

- L'utilisation des sous-programmes à positionnement explicite dans les fichiers doit être réservée à des cas particuliers, l'utilisation **implicite** de pointeurs individuels avec des vues offrant une interface de plus haut niveau.
- Lorsque les opérations font intervenir l'ensemble des processus (ou un sous-ensemble identifiable par un sous-communicateur MPI), il faut généralement privilégier la forme **collective** des opérations.
- Exactement comme pour le traitement des messages lorsque ceux-ci représentent une part importante de l'application, le **non-bloquant** est une voie privilégiée d'optimisation à mettre en œuvre par les programmeurs, mais ceci ne doit être implémenté qu'**après** qu'on se soit assuré du comportement correct de l'application en mode bloquant.

Conclusion

Conclusion

- Utiliser les communications point-à-point bloquantes, ceci avant de passer aux communications non-bloquantes. Il faudra alors essayer de faire du recouvrement calcul/communications.
- Utiliser les fonctions d'entrées-sorties bloquantes, ceci avant de passer aux entrées-sorties non-bloquantes. De même, il faudra alors faire du recouvrement calcul/entrées-sorties.
- Écrire les communications comme si les envois étaient synchrones (`MPI_Ssend()`).
- Éviter les barrières de synchronisation (`MPI_Barrier()`), surtout sur les fonctions collectives qui sont bloquantes.
- La programmation mixte MPI/OpenMP peut apporter des gains d'extensibilité, mais pour que cette approche fonctionne bien, il est évidemment nécessaire d'avoir de bonnes performances OpenMP à l'intérieur de chaque processus MPI. Un cours est dispensé à l'IDRIS (<https://cours.idris.fr>).

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

On considère l'équation de Poisson suivante :

$$\begin{cases} \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} = f(x, y) & \text{dans } [0, 1] \times [0, 1] \\ u(x, y) = 0 & \text{sur les frontières} \\ f(x, y) = 2 \cdot (x^2 - x + y^2 - y) \end{cases}$$

On va résoudre cette équation avec une méthode de décomposition de domaine :

- L'équation est discretisée sur le domaine via la méthode des différences finies.
- Le système obtenu est résolu avec un solveur suivant la méthode de Jacobi.
- Le domaine global est découpé en sous domaines.

La solution exacte est connue et est $u_{exacte}(x, y) = xy(x - 1)(y - 1)$

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

Pour discrétiser l'équation, on définit une grille constituée d'un ensemble de points (x_i, y_j)

$$x_i = i h_x \quad \text{pour } i = 0, \dots, ntx + 1$$

$$y_j = j h_y \quad \text{pour } j = 0, \dots, nty + 1$$

$$h_x = \frac{1}{(ntx + 1)}$$

$$h_y = \frac{1}{(nty + 1)}$$

h_x : pas suivant x

h_y : pas suivant y

ntx : nombre de points intérieurs suivant x

nty : nombre de points intérieurs suivant y

Il y a au total $ntx+2$ points suivant x et $nty+2$ points suivant y

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

- Soit u_{ij} l'estimation de la solution à la position $x_i = ih_x$ et $x_j = jh_y$.
- La méthode de Jacobi consiste à calculer :

$$u_{ij}^{n+1} = c_0(c_1(u_{i+1j}^n + u_{i-1j}^n) + c_2(u_{ij+1}^n + u_{ij-1}^n) - f_{ij})$$

$$\text{avec : } c_0 = \frac{1}{2} \frac{h_x^2 h_y^2}{h_x^2 + h_y^2}$$

$$c_1 = \frac{1}{h_x^2}$$

$$c_2 = \frac{1}{h_y^2}$$

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

- En parallèle, les valeurs aux interfaces des sous-domaines doivent être échangées entre les voisins.
- On utilise des cellules fantômes, ces cellules servent de buffer de réception pour les échanges entre voisins.

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

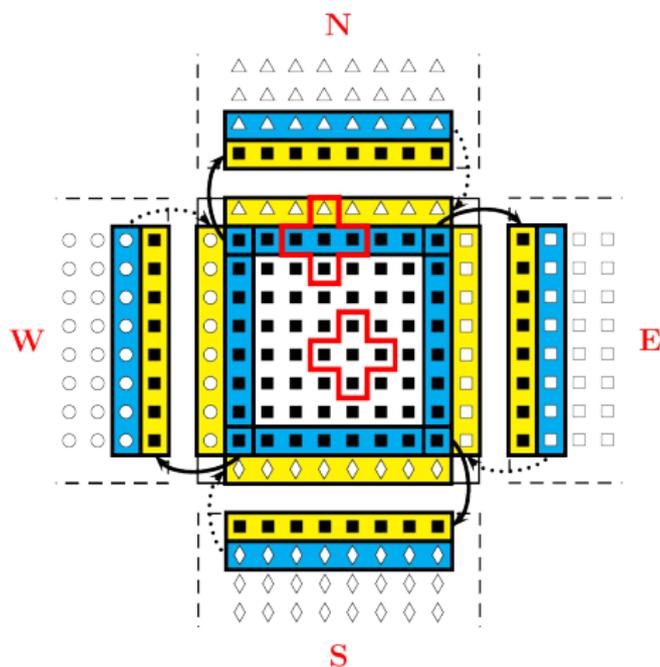


Figure 68 – Échange de points aux interfaces

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

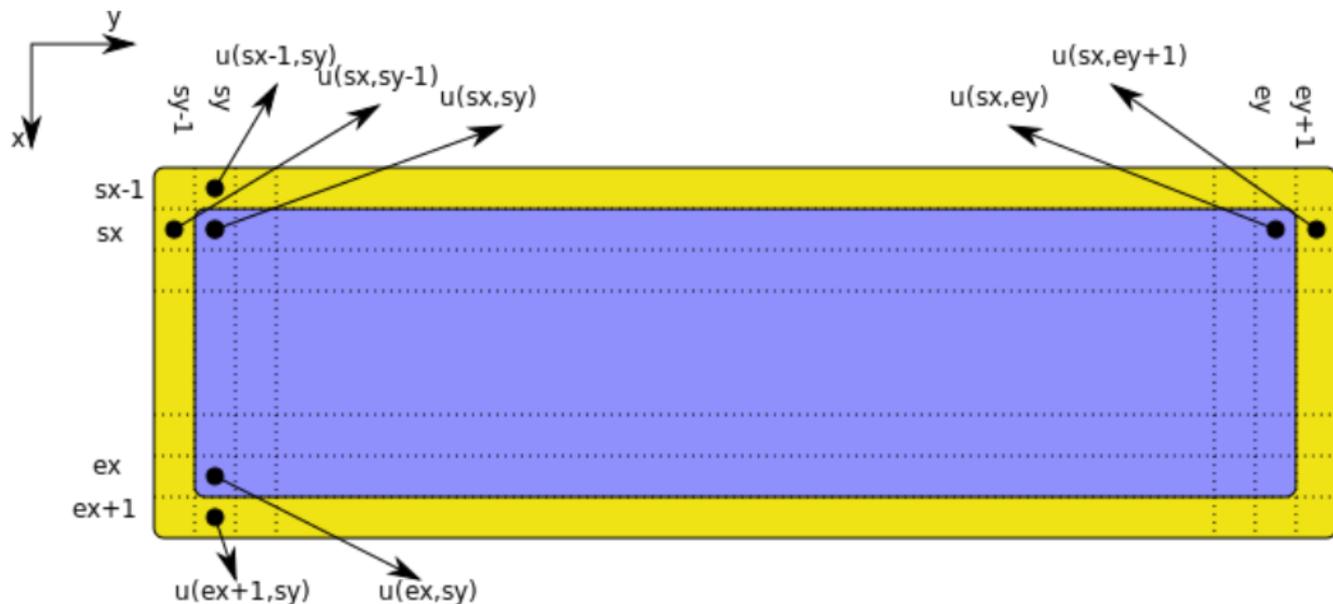


Figure 69 – Numérotation des points dans les différents sous-domaines

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

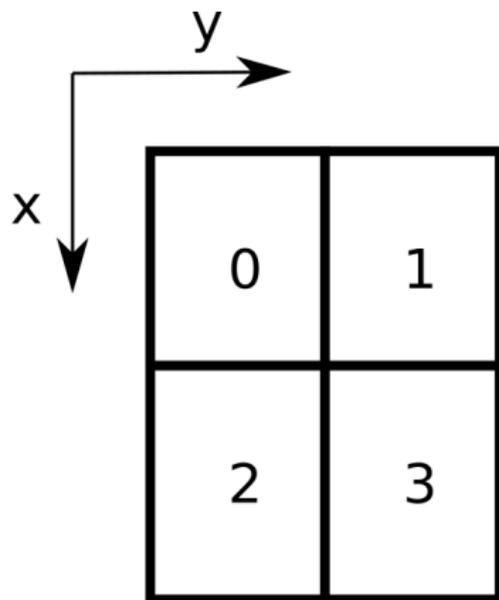


Figure 70 – Rang correspondant aux différents sous-domaines

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

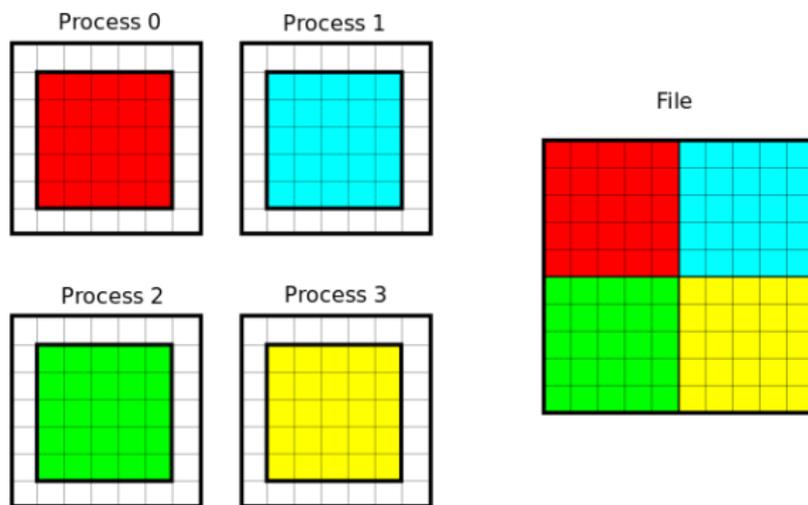


Figure 71 – Ecriture de la matrice u globale dans un fichier

Il s'agit de définir :

- Une vue, pour ne voir dans le fichier que la partie de la matrice u globale que l'on possède ;
- Un type afin d'écrire la matrice u locale (sans les cellules fantômes) ;
- Appliquer la vue au fichier ;
- Faire l'écriture en une fois.

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

- initialiser l'environnement MPI ;
- créer la topologie cartésienne 2D ;
- déterminer les indices de tableau pour chaque sous-domaine ;
- déterminer les 4 processus voisins d'un processus traitant un sous-domaine donné ;
- créer deux types dérivés *type_ligne* et *type_colonne* ;
- échanger les valeurs aux interfaces avec les autres sous-domaines ;
- calculer l'erreur globale. Lorsque l'erreur globale sera inférieure à une valeur donnée (précision machine par exemple), alors on considérera qu'on a atteint la solution ;
- reformer la matrice *u* globale (identique à celle obtenue avec la version monoprocesseur) dans un fichier `donnees.dat`.

Travaux pratiques MPI – Exercice 8 : Équation de Poisson

- Un squelette de la version parallèle est proposé : il s'agit d'un programme principal (`poisson.c`) et de plusieurs sous-programmes. Les modifications sont à effectuer dans le fichier `parallel.c`.
- Pour compiler utilisez la commande `make`, pour exécuter le code utilisez la commande `make exe`. Pour vérifier les résultats, utilisez la commande `make verification` qui exécute un programme de relecture du fichier `donnees.dat` puis le compare avec la version monoprocasseur.