Computación de alta performance

Sergio Nesmachnow (sergion@fing.edu.uy)
Universidad de la República, Uruguay

Message Passing Interface (MPI)

Sergio Nesmachnow (sergion@fing.edu.uy)
Universidad de la República, Uruguay

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

MPI (continuación)

Operaciones colectivas

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Las comunicaciones colectivas permiten la transferencia de datos entre todos los procesos que pertenecen a un grupo específico
- No se usan etiquetas para los mensajes, estas se sustituyen por identificadores de los grupos (comunicadores)

  Las operaciones colectivas comprenderán a todos los procesos en el alcance del comunicador
- Por defecto, todos los procesos se incluyen en el comunicador genérico MPI_COMM_WORLD
- Las operaciones colectivas son bloqueantes
- Las operaciones colectivas que involucran un subconjunto de procesos deben precederse de un particionamiento de los subconjuntos y relacionar los nuevos grupos con nuevos comunicadores

Operaciones colectivas

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Se clasifican en tres clases:

1. Sincronización (operaciones de barrera): procesos que esperan a que otros miembros del grupo alcancen el punto de sincronización
2. Movimiento (transferencia) de datos: operaciones para difundir, recolectar y esparcir datos entre procesos
3. Cálculos colectivos: operaciones para reducción global, tales como suma, máximo, mínimo o cualquier función definida por el usuario

Barrier

- MPI_Barrier (comm)

  Crea una barrera de sincronización en un grupo

  Al llegar a la invocación a la operación, cada tarea se bloquea hasta que todas las tareas del grupo alcancen la invocación de MPI_Barrier

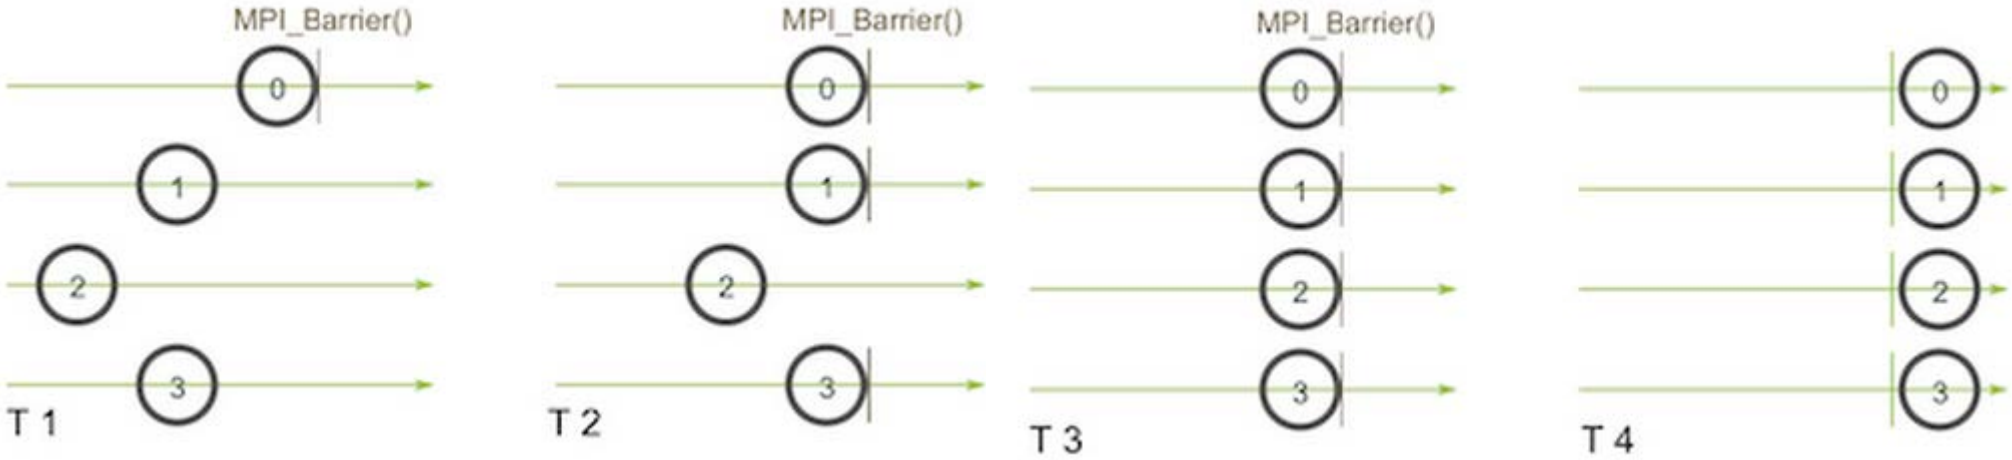

Barrier

- MPI_Barrier (comm)

  Crea una barrera de sincronización en un grupo

  Al llegar a la invocación a la operación, cada tarea se bloquea hasta que todas las tareas del grupo alcancen la invocación de MPI_Barrier

  Muy útil en procesamiento asincrónico

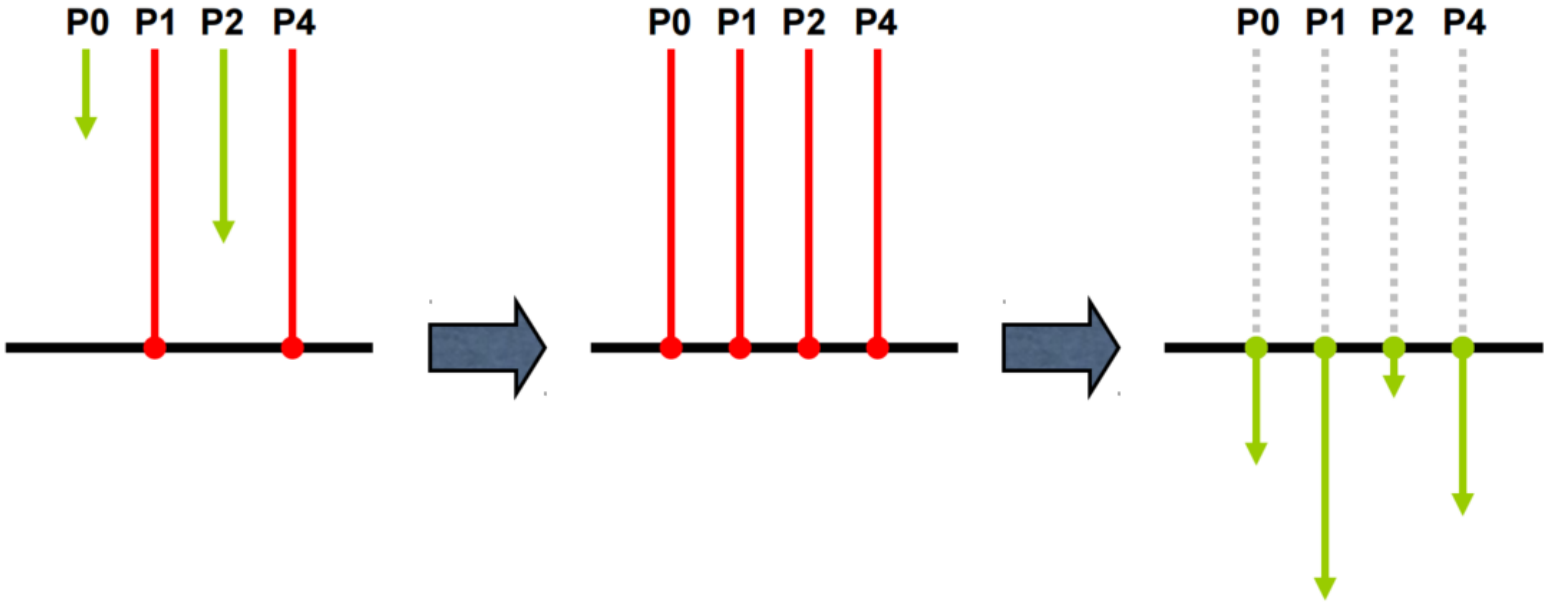

Broadcast

- MPI_Bcast (buffer, count, datatype, root, comm)

  Envía un mensaje desde el proceso con rango root a todos los demás procesos del communicador

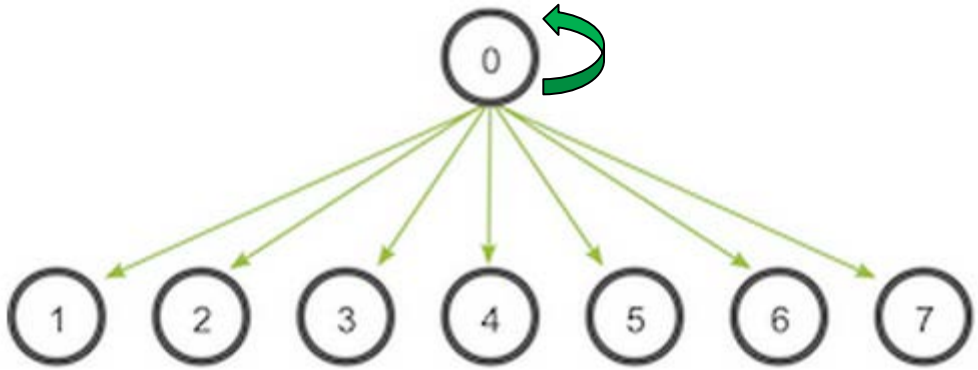

El broadcast también envía el mensaje al proceso root !!

Broadcast

- MPI_Bcast (buffer, count, datatype, root, comm)

  Envía un mensaje desde el proceso con rango root a todos los demás procesos del communicador

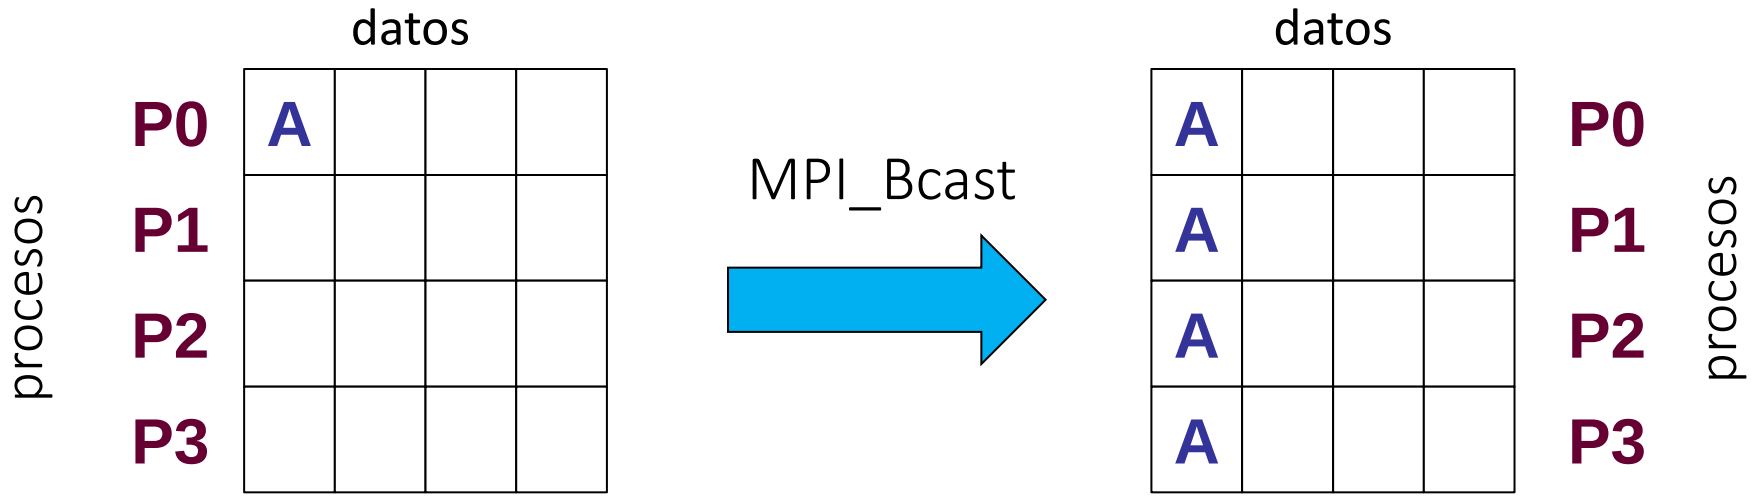

Broadcast

```
#include <stdio.h>
#include <stdlib.h>
#include <mpi.h>
#include <math.h>

int main(int argc, char *argv[]){
    int i,myid,numprocs,root,count;
    int buffer[4];

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

MPI_Bcast funciona “como send y receive” para el proceso root y como “receive” para el resto de los procesos

Scatter: esparcir/distribuir

- Un proceso distinguido (root) rompe un arreglo de datos y envía las partes a cada proceso

  MPI_Scatter (void* send_data, int send_count, MPI_Datatype send_datatype, void* recv_data, int recv_count, MPI_Datatype recv_datatype, int root, MPI_Comm communicator)

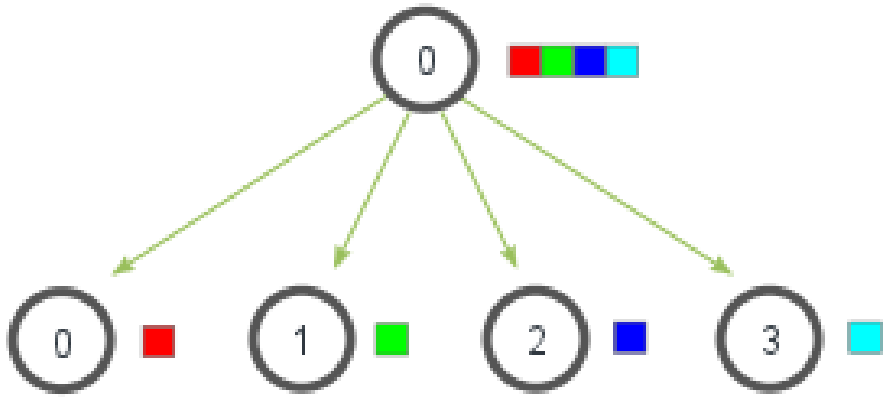

Scatter: esparcir/distribuir

- Un proceso distinguido (root) rompe un arreglo de datos y envía las partes a cada proceso

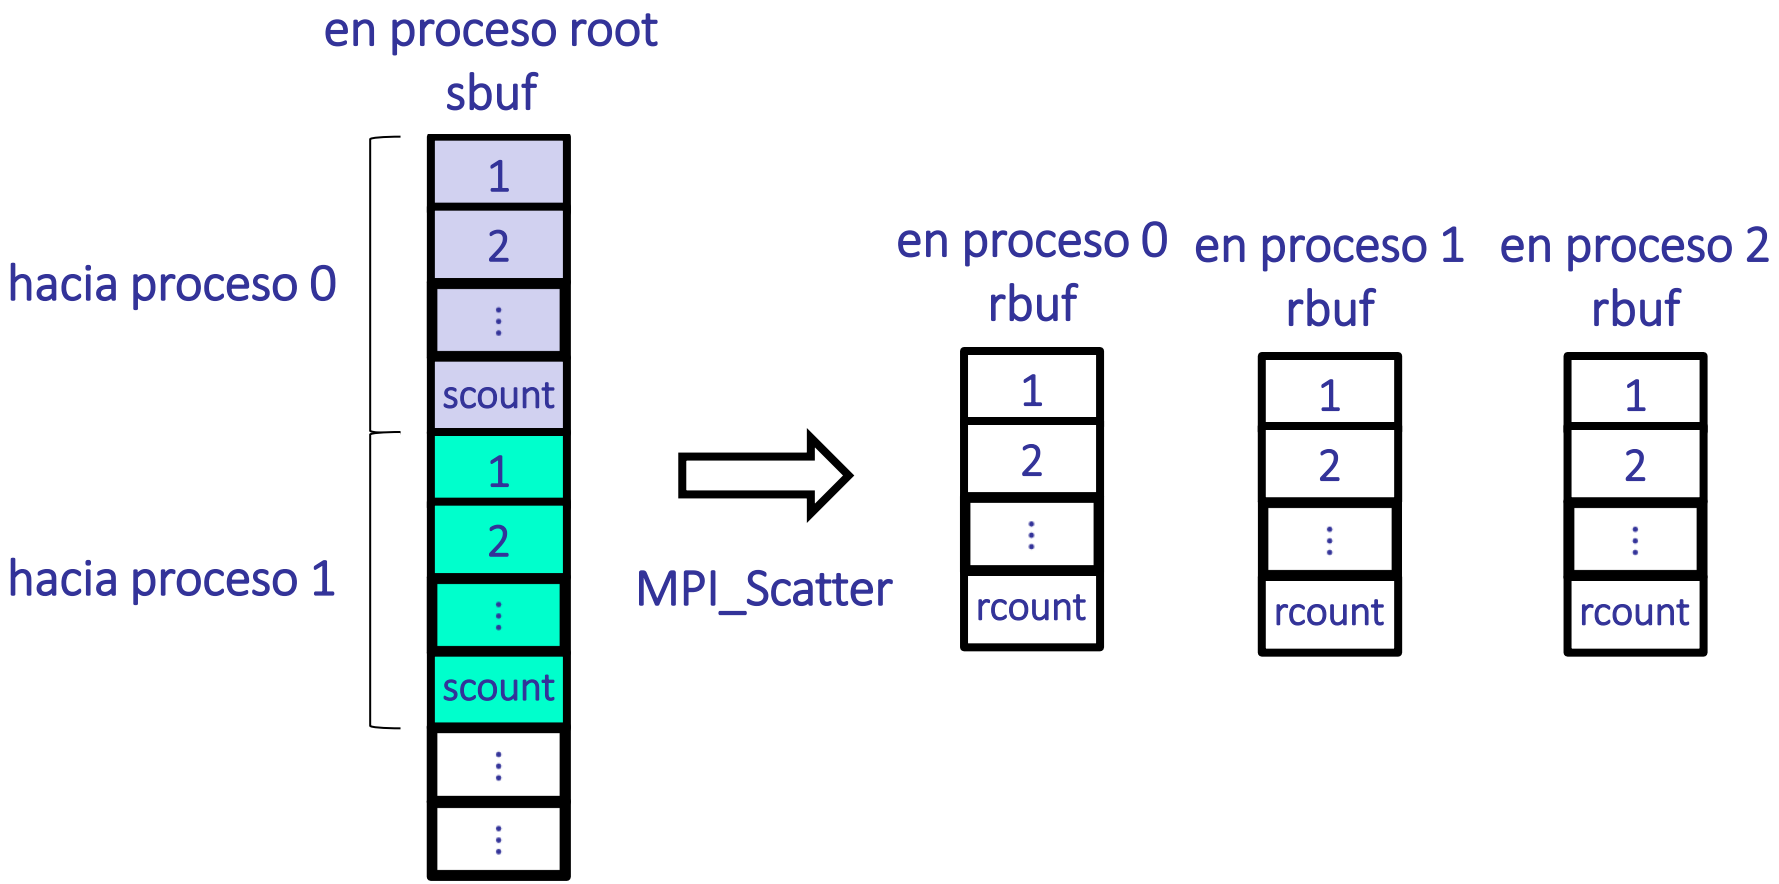

Gather: recolectar

- Cada proceso envía diferentes datos al proceso distinguido (root) y este los agrupa en un arreglo

  MPI_Gather (void* send_data, int send_count, MPI_Datatype send_datatype, void* recv_data, int recv_count, MPI_Datatype recv_datatype, int root, MPI_Comm communicator)

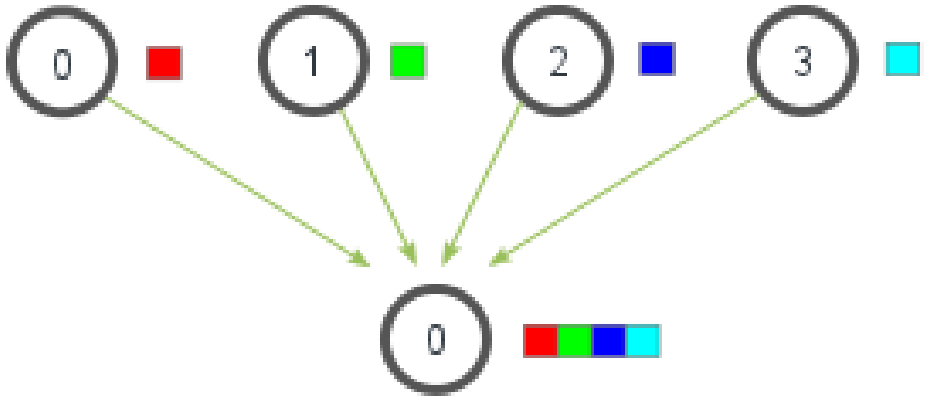

Gather: recolectar

- Cada proceso envía diferentes datos al proceso distinguido (root) y este los agrupa en un arreglo

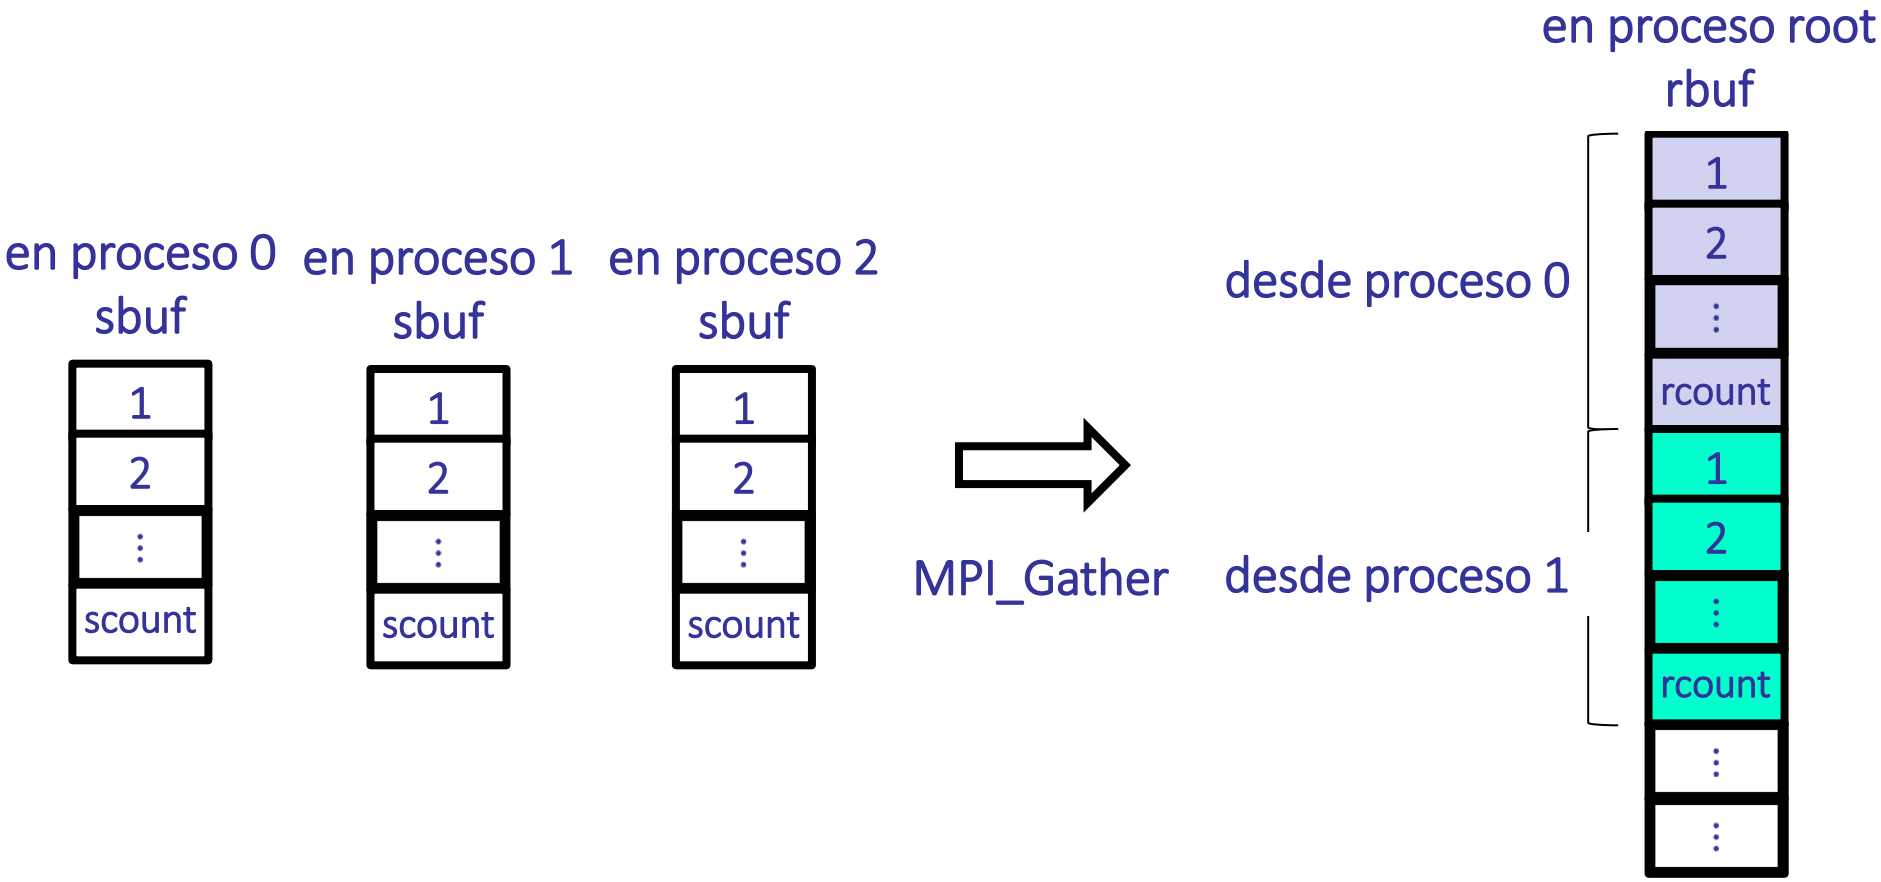

Allgather: recolectar y difundir

- Funciona como gather, pero TODOS los procesos reciben el resultado

MPI_Allgather (void* send_data, int send_count, MPI_Datatype send_datatype, void* recv_data, int recv_count, MPI_Datatype recv_datatype, MPI_Comm communicator)

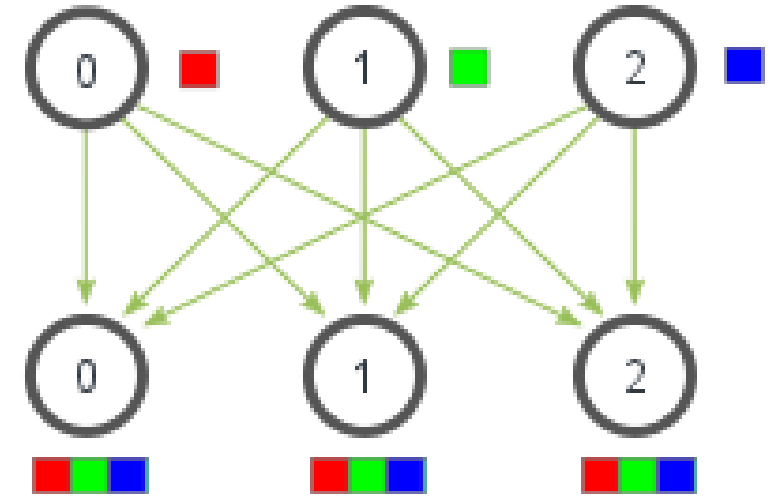

Allgather: recolectar y difundir

- Funciona como gather, pero todos los procesos reciben el resultado

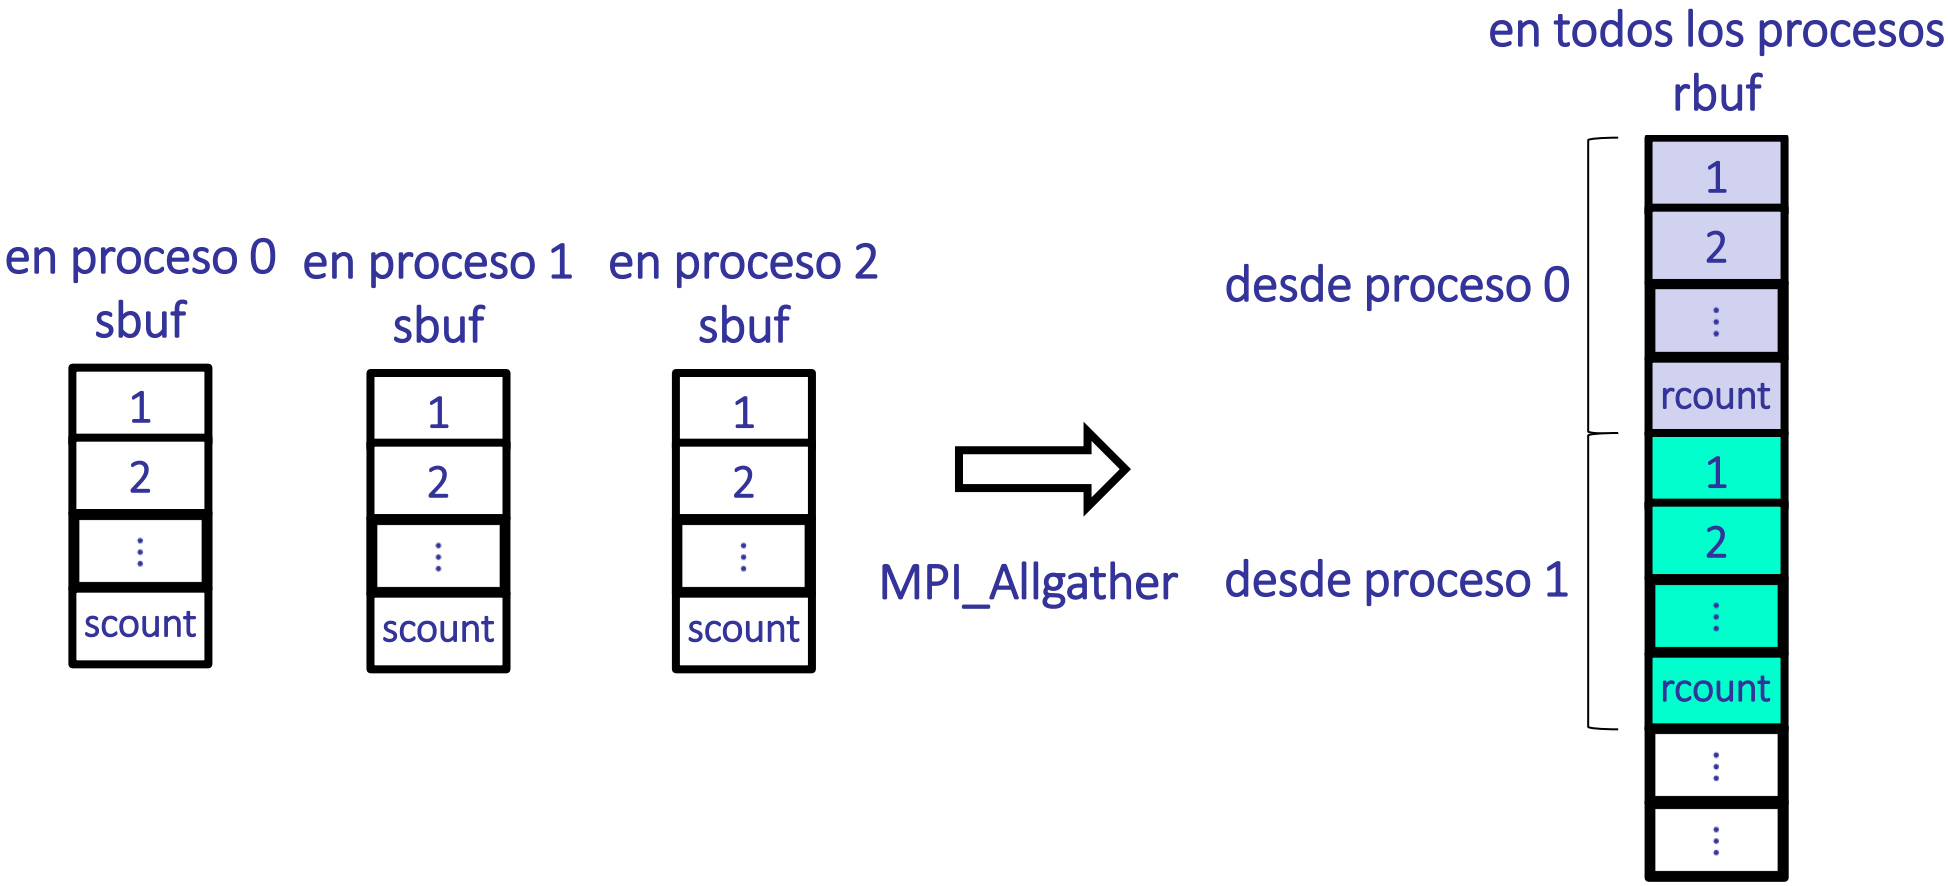

Difusión y recolección de datos

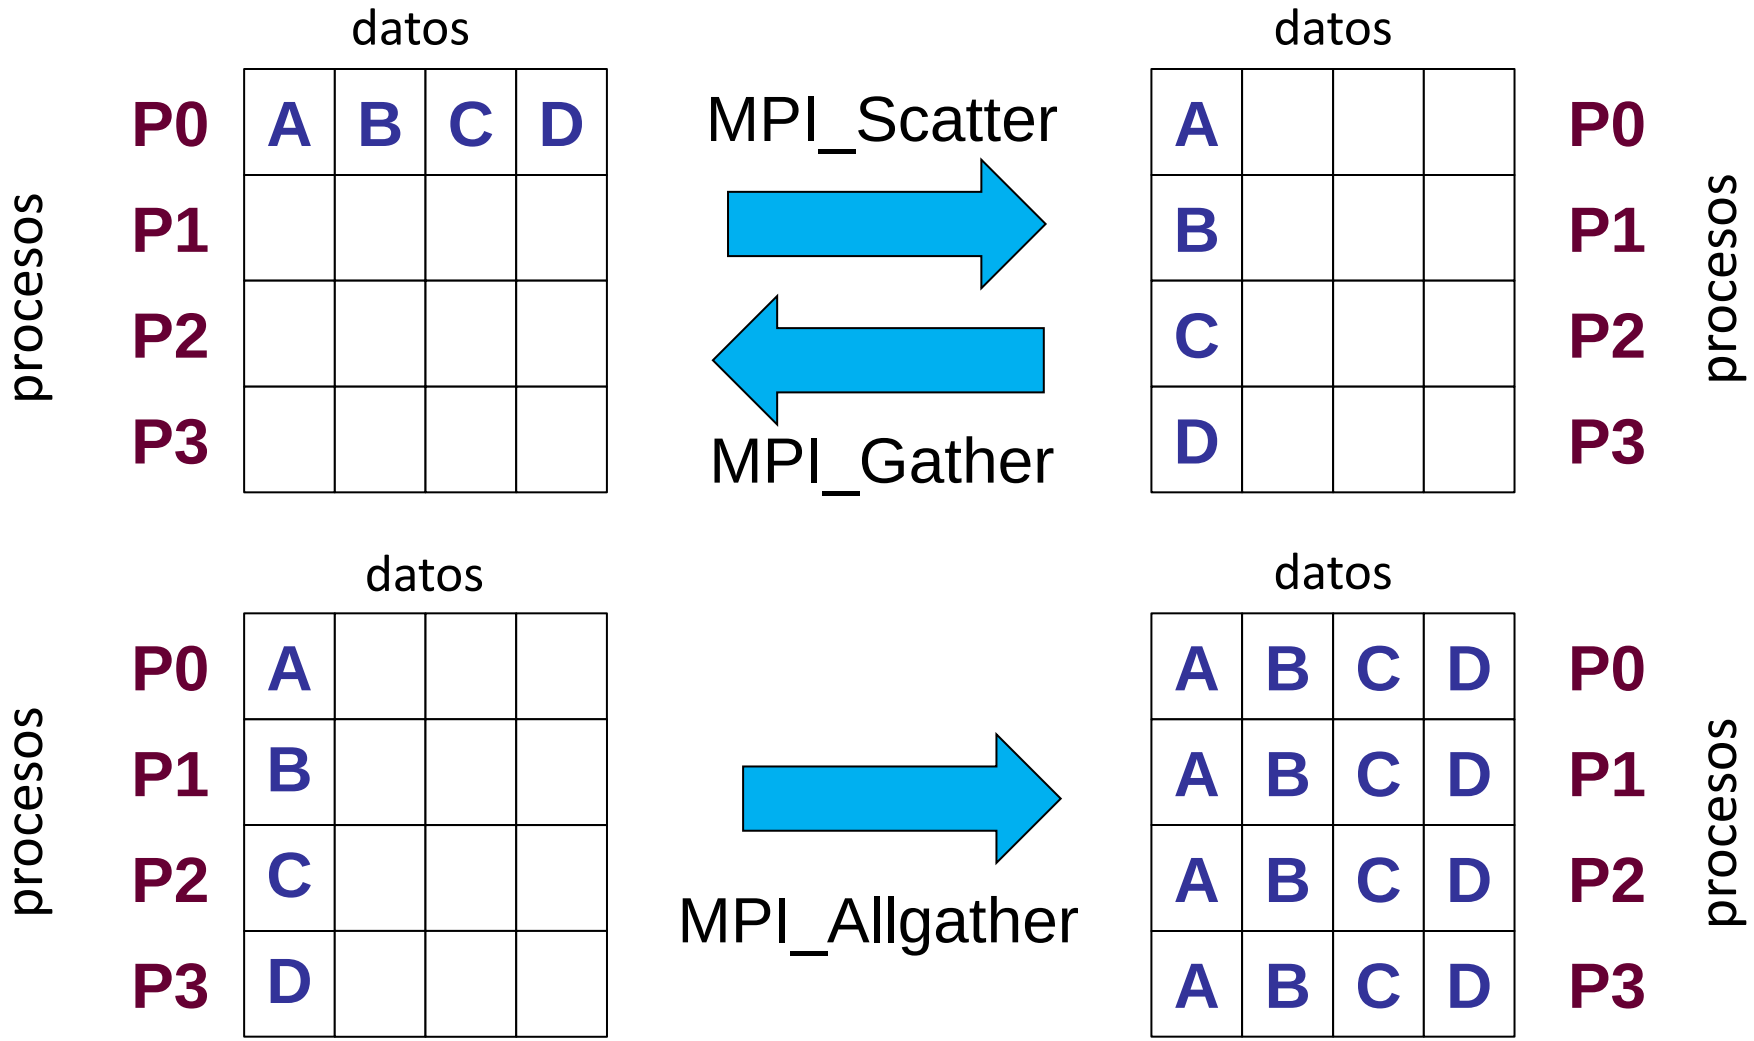

Ejemplo: operaciones colectivas

```
#include "mpi.h"
#include <stdio.h>
#define SIZE 4

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

Ejemplo: operaciones colectivas

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Scatter en las filas de una matriz

- Salida del programa

```
rank= 0  Results: 1.00000   2.00000  3.00000  4.00000
rank= 1  Results: 5.00000   6.00000  7.00000  8.00000
rank= 2  Results: 9.00000  10.00000 11.00000 12.00000
rank= 3  Results: 13.00000 14.00000 15.00000 16.00000
```

Ejemplo: MPI_Scatter y MPI_Gather

```
#include <stdio.h>
#include <stdlib.h>
#include <mpi.h>
int numnodes,myid,mpi_err; /* variables globales */
#define root 0

int main(int argc,char *argv[]){
   int *myray,*send_ray,*back_ray, int count,size,mysize,i,k,j,total;

   MPI_Init(argc,argv);
   MPI_Comm_size( MPI_COMM_WORLD, &numnodes );
   MPI_Comm_rank(MPI_COMM_WORLD, &myid);
   count=4; /* cada proceso recibe count elementos del root */

   myray=(int*)malloc(count*sizeof(int));
   if(myid == root){
      /* crear los datos a ser enviados por el root */
      size=count*numnodes;
      send_ray=(int*)malloc(size*sizeof(int));
      back_ray=(int*)malloc(numnodes*sizeof(int));
      for(i=0;i<size;i++)
        send_ray[i]=i;
   }
```

Ejemplo: MPI_Scatter y MPI_Gather

```
/* enviar los datos a cada proceso */
   mpi_err=MPI_Scatter(send_ray,count,MPI_INT,myray,count,MPI_INT,root,MPI_COMM_WOR
   LD);

/* cada proceso realiza una suma local */
   total=0;
   for(i=0;i<count;i++)
       total=total+myray[i];
   printf("myid= %d total= %d\n ",myid,total);

/* enviar las sumas locales al proceso root*/
    mpi_err = MPI_Gather(&total,1,MPI_INT,back_ray,1,MPI_INT,root,MPI_COMM_WORLD);

/* el root imprime la suma global */
   if(myid == root){
     total=0;
     for(i=0;i<numnodes;i++)
       total=total+back_ray[i];
     printf("results from all processors= %d \n ",total);
   }
   MPI_Finalize();
}
```

Fuente: http://geco.mines.edu/workshop/class2/examples/mpi/c_ex05.c

Cálculos colectivos

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- El usuario puede combinar cálculos parciales de todos los procesos
- Los resultados quedan disponibles en un proceso particular o en todos los procesos
- Permite la ejecución sincronizada
- Combinación de resultados parciales:
  - El proceso principal (root) recibe los cálculos parciales y los combina usando la operación indicada

```
ierr = MPI_Reduce(sbuf,rbuf,cont,datatype,op, root, comm)
```

- Todos los procesos pueden almacenan el resultado con:

  `MPI_Allreduce`

  - En este caso la rutina no requiere el parámetro root

Operaciones de reducción

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

Reducción	Operación	Tipos de datos
MPI_MAX	Máximo	integer, float
MPI_MIN	Mínimo	integer, float
MPI_SUM	Suma	integer, float
MPI_PROD	Producto	integer, float
MPI_LAND	And lógico	integer
MPI_BAND	And bit a bit	integer, MPI_BYTE
MPI_LOR	Or lógico	integer
MPI_BOR	Or bit a bit	integer, MPI_BYTE
MPI_LXOR	Xor lógico	integer
MPI_BXOR	Xor bit a bit	integer, MPI_BYTE
MPI_MAXLOC	Máx y loc	Par de integer
MPI_MINLOC	Mín y loc	Par de integer

Definición de operaciones

- El usuario puede definir sus propias operaciones
  - Por ejemplo, en C

```
void function(void *invec,void *inout,int *len,
  MPI_Datatype *datatype)
     { Cuerpo de la función }
...
int commute;
MPI_Op op;
...
ierr = MPI_Op_create(function,commute,&op);
   ...
ierr=MPI_Op_free(&op);    {op = MPI_OP_NULL}
```

Ejemplo de reducción

- El ejemplo previo de scatter/gather y cálculo colectivo puede implementarse con una operación de reducción
- En lugar de

```
/* enviar las sumas locales al proceso root */
mpi_err = MPI_Gather(&total,1,MPI_INT,back_ray,1,MPI_INT,root,MPI_COMM_WORLD);
/* el root imprime la suma global */
if(myid == root){
   total=0;
   for(i=0;i<numnodes;i++){total=total+back_ray[i];}
   printf("results from all processors= %d \n ",total);
}
```

- Simplemente sería

```
/* enviar las sumas locales al proceso root y reducir */
mpi_err = MPI_Reduce(&total,&gtotal,1,MPI_INT,MPI_SUM,root,MPI_COMM_WORLD);
/* el root imprime la suma global */
if(myid == root){
   printf("results from all processors= %d \n ",gtotal);
}
```

Manejo de grupos

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Organización de tareas en grupos
  - Permite comunicaciones y operaciones colectivas sobre un conjunto de tareas relacionadas
  - Provee la base para implementar topologías de procesos

- MPI provee rutinas para la manipulación de grupos:
  - Crear un grupo de procesos a partir de otros grupos de procesos
  - Crear un comunicador para el nuevo grupo
  - Realizar operaciones colectivas entre los procesos de un grupo
  - Organizar los grupos de procesos en topologías virtuales

- Todas las tareas que pertenezcan al grupo deben participar en la invocación de la creación del grupo

Manejo de grupos

- Definen un colección ordenada de procesos
- Cada proceso que pertenece a un grupo tiene un único identificador asociado (rank) en ese grupo
- Los procesos pueden pertenecer a más de un grupo a la vez
- El rank es siempre relativo a un grupo
- Tareas que no pertenezcan a un grupo no podrán participar en operaciones o comunicaciones colectivas que especifiquen ese grupo
- Un grupo se asocia con un comunicador, por defecto todas las tareas están en el grupo asociado con MPI_COMM_WORLD
- Existencia del grupo vacío: MPI_GROUP_EMPTY
- Los grupos son creados a partir de otro grupo
- El grupo base es el asociado al comunicador inicial MPI_COMM_WORLD

Manejo de grupos

- `MPI_Group_difference (group1,group2,*newgroup)`
  Crea un grupo diferencia de dos grupos
- `MPI_Group_incl (group,n,*ranks,*newgroup)`
  Crea un grupo con las tareas listadas de un grupo existente
- `MPI_Group_excl (group,n,*ranks,*newgroup)`
  Crea un grupo con las tareas no listadas de un grupo existente
- `MPI_Group_intersection (group1,group2,*newgroup)`
- `MPI_Group_union (group1,group2,*newgroup)`
- `MPI_Group_compare (group1,group2,*result)`
  Compara dos grupos y retorna:
  - `MPI_IDENT` si las tareas y su orden coinciden.
  - `MPI_SIMILAR` si solo las tareas son iguales.
  - `MPI_UNEQUAL` en otro caso.

Manejo de grupos

- `MPI_Group_rank (group,*rank)`
  Retorna el rango del proceso en el grupo (o `MPI_UNDEFINED` si el proceso no es miembro del grupo)
- `MPI_Group_size (group,*size)`
  Retorna el tamaño (#procesos) del grupo
- `MPI_Group_free (group)`
  Elimina un grupo
- `MPI_Comm_group (comm,*group)`
  Devuelve el grupo asociado a un comunicador
- `MPI_Comm_create (comm,group,*newcomm)`
  Crea un comunicador para un grupo a partir de un comunicador existente
- `MPI_Comm_dup (comm,*newcomm)`
  Duplica un comunicador existente (con toda su información)

Ejemplo: manejo de grupos

```
#include "mpi.h"
#include <stdio.h>
#define NPROCS 8
#define MASTER 0
#define MSGSIZE 7

int main(int argc, char *argv[]) {
   int rank, new_rank;
   int ranks1[4] = {0,1,2,3};
   int ranks2[4] = {4,5,6,7};
   char *msg;
   MPI_Group orig_group, new_group;
   MPI_Comm  new_comm;
   MPI_Init(&argc,&argv);
   MPI_Comm_rank(MPI_COMM_WORLD, &rank);
   /* Extraer la referencia del grupo original */
   MPI_Comm_group(MPI_COMM_WORLD, &orig_group);
```

Ejemplo: manejo de grupos

```
/* Dividir las tareas en dos grupos. Crear un nuevo grupo y un nuevo
   comunicador. Luego, hallar el nuevo rango en el nuevo comunicador y
   prepar el proceso maestro para la comunicación colectiva */
   if (rank < NPROCS/2) {
      MPI_Group_incl(orig_group, NPROCS/2, ranks1, &new_group);
      MPI_Comm_create(MPI_COMM_WORLD, new_group, &new_comm);
      MPI_Group_rank (new_group, &new_rank);
      if (new_rank == MASTER) msg="Group 1";
   } else {
      MPI_Group_incl(orig_group, NPROCS/2, ranks2, &new_group);
      MPI_Comm_create(MPI_COMM_WORLD, new_group, &new_comm);
      MPI_Group_rank (new_group, &new_rank);
      if (new_rank == MASTER) msg="Group 2";
   }
   MPI_Bcast(&msg,MSGSIZE,MPI_CHAR,MASTER,new_comm);
   printf("rank= %d newrank= %d msg= %s\n",rank,new_rank,msg);
   MPI_Finalize();
}
```

Ejemplo: manejo de grupos

Salida del ejemplo:

```
rank= 0 newrank= 0 msg= Group 1
rank= 1 newrank= 1 msg= Group 1
rank= 2 newrank= 2 msg= Group 1
rank= 3 newrank= 3 msg= Group 1
rank= 4 newrank= 0 msg= Group 2
rank= 5 newrank= 1 msg= Group 2
rank= 6 newrank= 2 msg= Group 2
rank= 7 newrank= 3 msg= Group 2
```

Topologías virtuales

- Definen un orden de los procesos MPI en una estructura geométrica.
- Las topologías son virtuales, no tienen ningún vínculo con la estructura física del multicomputador subyacente
- Se construyen sobre los comunicadores y los grupos de procesos
- Son aplicables para aplicaciones con patrones de comunicación específicos, con “vecinos” determinados

Topología cartesiana (grid)

MPI_Cart_create(comm, ndims, dims, periods, reorder, &cartcomm);

0 (0,0)	1 (0,1)	2 (0,2)	3 (0,3)
4 (1,0)	5 (1,1)	6 (1,2)	7 (1,3)
8 (2,0)	9 (2,1)	10 (2,2)	11 (2,3)
12 (3,0)	13 (3,1)	14 (3,2)	15 (3,3)

Topologías virtuales

- Definen un orden de los procesos MPI en una estructura geométrica.
- Las topologías son virtuales, no tienen ningún vínculo con la estructura física del multicomputador subyacente
- Se construyen sobre los comunicadores y los grupos de procesos
- Son aplicables para aplicaciones con patrones de comunicación específicos, con “vecinos” determinados

Topología cartesiana (grid)

MPI_Cart_create(comm, ndims, dims, periods, reorder, &cartcomm);

0 (0,0)	1 (0,1)	2 (0,2)	3 (0,3)
4 (1,0)	5 (1,1)	6 (1,2)	7 (1,3)
8 (2,0)	9 (2,1)	10 (2,2)	11 (2,3)
12 (3,0)	13 (3,1)	14 (3,2)	15 (3,3)

Topologías virtuales

MPI_Cart_create(MPI_Comm comm_old, int ndims, const int dims[],
const int periods[], int reorder, MPI_Comm *comm_cart)

- comm_old: comunicador base
- ndims: número de dimensiones de la grilla
- dims: dimensiones de la grilla
- periods: array de tamaño ndims, indica si la grilla es periódica (true) o no (false) en cada dimensión
- reorder: booleano, indica si los rangos pueden reordenarse o no
- comm_cart: comunicador de la grilla

MPI_Cart_create(com, 2, [4,4], [0,0], 0, &cartcom);

0 (0,0)	1 (0,1)	2 (0,2)	3 (0,3)
4 (1,0)	5 (1,1)	6 (1,2)	7 (1,3)
8 (2,0)	9 (2,1)	10 (2,2)	11 (2,3)
12 (3,0)	13 (3,1)	14 (3,2)	15 (3,3)

Topologías virtuales

MPI_Cart_coords(MPI_Comm comm, int rank, int maxdims, int *coords)

Retorna las coordenadas en una grilla cartesiana, el inverso es MPI_Cart_rank

- comm: comunicador de la grilla
- rank: rango del proceso
- maxdims: largo del vector coords
- coords: arreglo con las coordenadas del proceso en la grilla

MPI_Cart_shift(MPI_Comm comm, int dir, int disp, int *source, int *dest)

Obtiene los dos vecinos de un proceso en una dimensión

- comm: comunicador de la grilla
- dir: dimensión del desplazamiento (0: columna, 1: fila)
- disp: desplazamiento (> 0: arriba/derecha, < 0: abajo/izquierda)
- source: rango del vecino1
- dest: rango del vecino2

Ejemplo: topologías virtuales

```
#include "mpi.h"
#include <stdio.h>
#define SIZE 16
#define UP    0        // vecinos // vecinos
#define DOWN  1
#define LEFT  2
#define RIGHT 3

main(int argc, char *argv[])  {
int numtasks, rank, source, dest, outbuf, i, tag=1,
inbuf[4]={MPI_PROC_NULL,MPI_PROC_NULL,MPI_PROC_NULL,MPI_PROC_NULL,},
nbrs[4], dims[2]={4,4}, periods[2]={0,0}, reorder=0, coords[2];

MPI_Request reqs[8];
MPI_Status stats[8];
MPI_Comm cartcomm;   // comunicador para la grilla
```

Ejemplo: topologías virtuales

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

```
MPI_Init(&argc,&argv);
MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
if (numtasks == SIZE) {
   // crear topología virtual cartesiana
   MPI_Cart_create(MPI_COMM_WORLD, 2, dims, periods, reorder, &cartcomm);
   // obtener rango, coordenadas, rango de vecinos
   MPI_Comm_rank(cartcomm, &rank);
   MPI_Cart_coords(cartcomm, rank, 2, coords);
   MPI_Cart_shift(cartcomm, 0, 1, &nbrs[UP], &nbrs[DOWN]);
   MPI_Cart_shift(cartcomm, 1, 1, &nbrs[LEFT], &nbrs[RIGHT]);
   printf("rank: %d coords: %d %d neighbors(u,d,l,r): %d %d %d %d\n",
      rank,coords[0],coords[1],nbrs[UP],nbrs[DOWN],nbrs[LEFT],nbrs[RIGHT]);
   outbuf = rank;
```

Ejemplo: topologías virtuales

```
// intercambiar datos (rango) con los cuatro vecinos
   for (i=0; i<4; i++) {
     dest = nbrs[i];
     source = nbrs[i];
     MPI_Isend(&outbuf, 1, MPI_INT, dest, tag, MPI_COMM_WORLD, &reqs[i]);
     MPI_Irecv(&inbuf[i], 1, MPI_INT, source, tag, MPI_COMM_WORLD,&reqs[i+4]);
   }
   MPI_Waitall(8, reqs, stats);
   printf("rank= %d, inbuf(u,d,l,r)= %d %d %d %d\n",
         rank,inbuf[UP],inbuf[DOWN],inbuf[LEFT],inbuf[RIGHT]);
} else
   printf("Deben especificarse %d procesos.\n",SIZE);
MPI_Finalize();
}
```

Ejemplo: topologías virtuales

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

```
rank=    0 coords=  0 0 neighbors(u,d,l,r)=  -1  4 -1  1
rank=    0                  inbuf(u,d,l,r)=  -1  4 -1  1
rank=    8 coords=  2 0 neighbors(u,d,l,r)=   4 12 -1  9
rank=    8                  inbuf(u,d,l,r)=   4 12 -1  9
rank=    1 coords=  0 1 neighbors(u,d,l,r)=  -1  5  0  2
rank=    1                  inbuf(u,d,l,r)=  -1  5  0  2
rank=   13 coords=  3 1 neighbors(u,d,l,r)=   9 -1 12 14
rank=   13                  inbuf(u,d,l,r)=   9 -1 12 14
...
...
rank=    3 coords=  0 3 neighbors(u,d,l,r)=  -1  7  2 -1
rank=    3                  inbuf(u,d,l,r)=  -1  7  2 -1
rank=   11 coords=  2 3 neighbors(u,d,l,r)=   7 15 10 -1
rank=   11                  inbuf(u,d,l,r)=   7 15 10 -1
rank=   10 coords=  2 2 neighbors(u,d,l,r)=   6 14  9 11
rank=   10                  inbuf(u,d,l,r)=   6 14  9 11
rank=    9 coords=  2 1 neighbors(u,d,l,r)=   5 13  8 10
rank=    9                  inbuf(u,d,l,r)=   5 13  8 10
```

Definición de tipos de datos en MPI

- MPI permite al usuario construir nuevos tipos de datos en tiempo de ejecución
- Primitivas:
  - `MPI_Type_contiguous`
  - `MPI_Type_vector`
  - `MPI_Type_indexed`
  - `MPI_Type_struct`
- Tipos de datos predefinidos (para C):

```
MPI_CHAR, MPI_WCHAR          MPI_UNSIGNED_LONG
MPI_SHORT                    MPI_FLOAT
MPI_INT                      MPI_DOUBLE
MPI_LONG, MPI_LONG_LONG      MPI_LONG_DOUBLE
MPI_UNSIGNED_CHAR            MPI_BYTE
MPI_UNSIGNED_SHORT           MPI_PACKED
MPI_UNSIGNED_INT
```

Definición de tipos de datos en MPI

- `MPI_Type_contiguous (count,oldtype,*newtype)`

Produce un nuevo tipo de dato, formado por copias contiguas de un tipo existente

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

Similar al anterior, permite “saltos regulares” en los desplazamientos

- `MPI_Type_indexed (count,blocklens[],offsets[],old_type,*newtype)`

Crea un array “indexado” por los desplazamientos provistos

- `MPI_Type_hindexed`

Idéntica a MPI_Type_indexed, pero los offsets se especifican en bytes

- `MPI_Type_commit`

Finaliza la definición de tipo de datos, reserva memoria, etc.

- `MPI_Type_free`

Elimina el tipo de dato derivado, libera la memoria.

Definición de tipos de datos en MPI

`MPI_Type_contiguous(count,oldtype,*newtype)`

- Tipo de dato fila: count = 4, oldtype = MPI_FLOAT, newtype = rowtype
- MPI_Type_contiguous (4, MPI_FLOAT, & rowtype)

a[4][4]

1.0	2.0	3.0	4.0
5.0	6.0	7.0	8.0
9.0	10.0	11.0	12.0
13.0	14.0	15.0	16.0

MPI_send(&a[2][0],1, rowtype,dest,tag,comm)

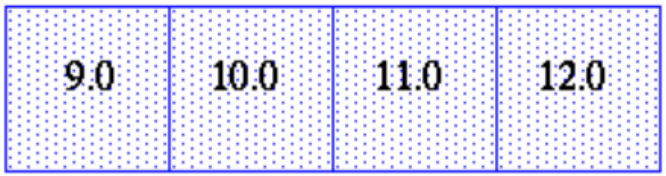

se envía un elemento de tipo rowtype

Definición de tipos de datos en MPI

`MPI_Type_vector(count,blocklength,stride,oldtype,*newtype)`

- Tipo de dato columna: count = 4, blocklength=1, stride=4
- MPI_Type_vector(4, 1, 4, MPI_FLOAT, & coltype)

a[4][4]

1.0	2.0	3.0	4.0
5.0	6.0	7.0	8.0
9.0	10.0	11.0	12.0
13.0	14.0	15.0	16.0

MPI_send(&a[0][1],1, coltype,dest,tag,comm)

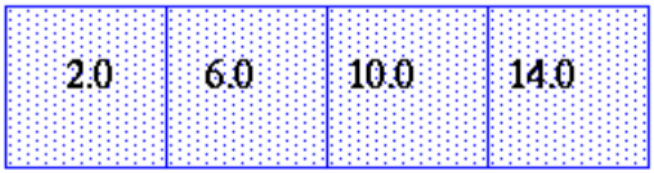

se envía un elemento de tipo coltype

Definición de tipos de datos en MPI

`MPI_Type_indexed(count,blocklens[],offsets[],oldtype,*newtype)`

- Tipo de dato de largo variable: count = 2, blocklens=[4,2], offsets=[5,12]
- MPI_Type_indexed(2, blocklens, offsets, MPI_FLOAT, &indextype)

a[16]

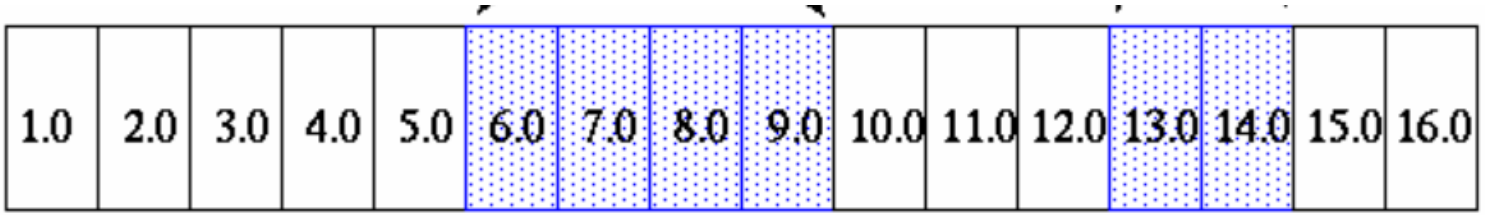

MPI_send(&a,1, indextype, dest,tag,comm)

se envía un elemento
de tipo indextype

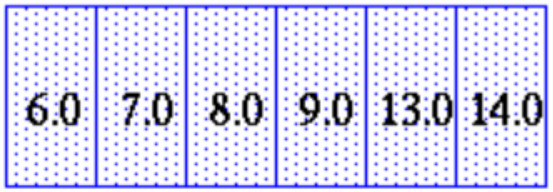

Ejemplo: definición de tipos de datos en MPI

- Matriz A (100x100):

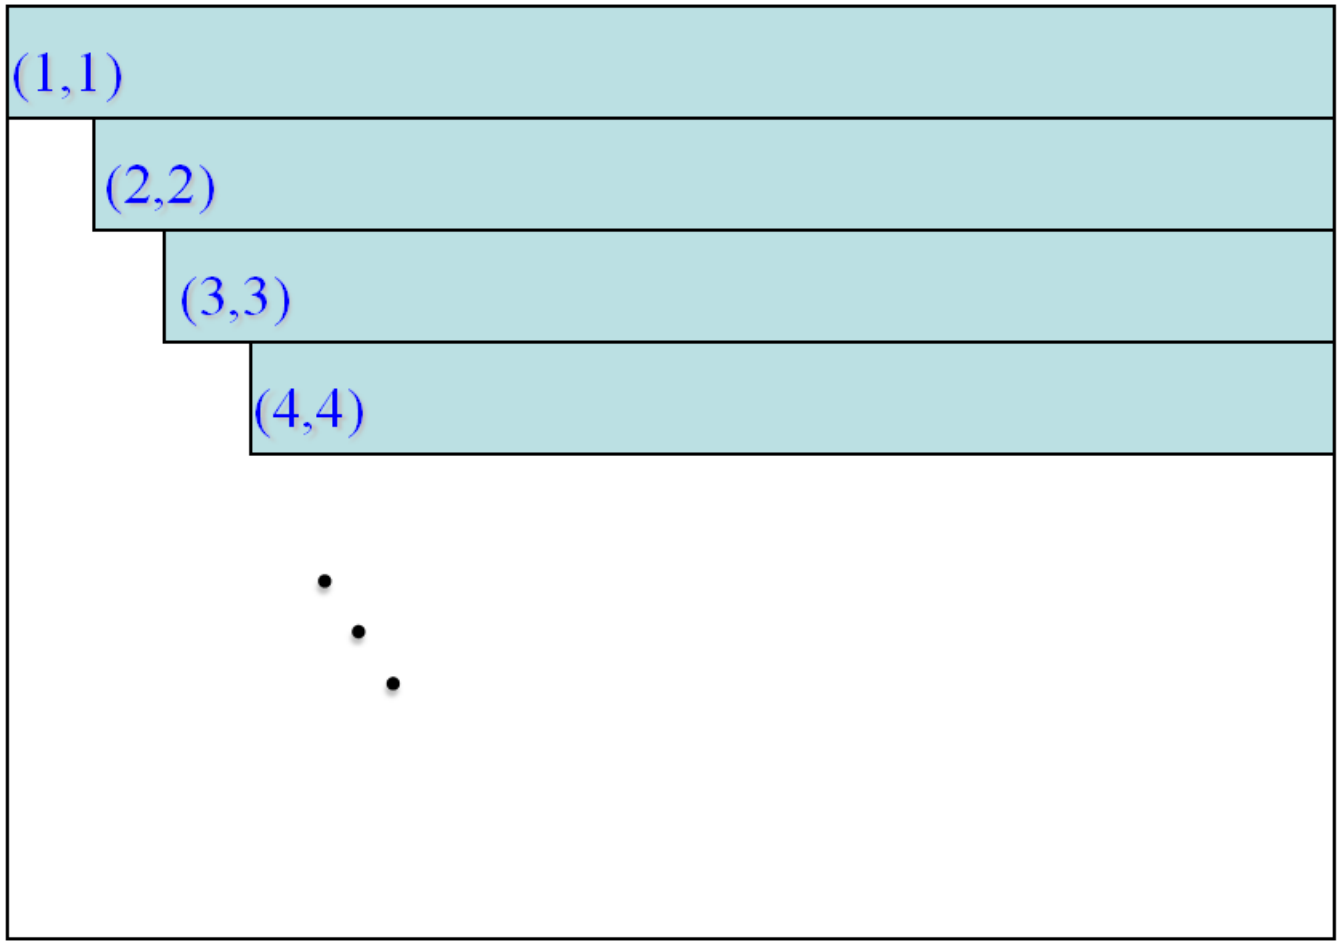

Ejemplo: definición de tipos de datos en MPI

```
double a[100][100];
int separacion[100],longbloqs[100],i;
MPI_Datatype superior;
....
 /* Cálculo del inicio y tamaño de cada fila    */
for (i=0;i<100;i++) {
   separacion[i] = 100*i + i;
   longbloqs[i] = 100 - i ;
}
/* Crear el tipo de dato para la parte triangular superior de la matriz*/
MPI_Type_indexed(100,longbloqs,separacion,MPI_DOUBLE,&superior);
MPI_Type_commit(&superior);

/* ... Enviar la parte superior ... */
MPI_Send(a,1,superior,dest,tag,MPI_COMM_WORLD);
```

Definición de tipos de datos en MPI

`MPI_Type_struct(count,blocklens[],offsets[],oldtypes,*newtype)`

typedef struct {float x,y,z,velocity; int type, cat;} particle
particle particles[NELEM]

- Tipo de dato estructurado: count = 2, blocklens=[4,2], offsets=[0,4*extent]
- MPI_Type_struct(2, blocklens, offsets, {MPI_FLOAT,MPI_INT}, &structtype)

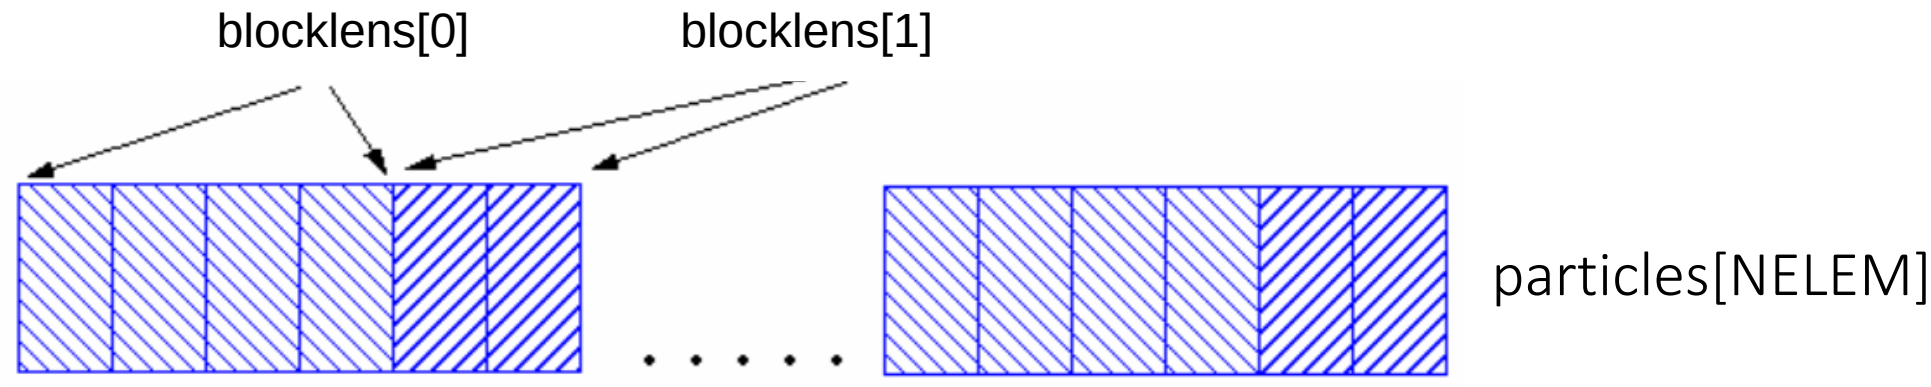

MPI_send(particles,NELEM, particletype, dest,tag,comm) envía un elemento de tipo particletype (array de NELEM elementos, cada uno formado por cuatro floats y dos enteros)

Definición de tipos de datos en MPI

```
MPI_Type_extent(MPI_Datatype datatype, MPI_Aint *extent)
MPI_Type_get_extent(MPI_Datatype datatype, MPI_Aint *lb,
                    MPI_Aint *extent)
```
(en MPI-3)

- Retorna el extent (tamaño) de un tipo de datos
- En el ejemplo previo: MPI_Type_extent(MPI_FLOAT, &extent)
- Proporciona una función que encapsula el uso de sizeof()

Ejemplo: definición de tipos de datos en MPI

- Considérense los tipos de datos

```
struct A {                    struct B {
        int f;                        struct A a;
        short p; };                   int pp, vp; };
```

- Construcción del tipo de datos derivado en MPI:

```
static const int blocklen[] = {1, 1, 1, 1};
static const MPI_Aint disp[] = { offsetof(struct B, a) +
offsetof(struct A, f), offsetof(struct B, a) + offsetof(struct A, p),
offsetof(struct B, pp), offsetof(struct B, vp) };

static MPI_Datatype type[] = {MPI_INT, MPI_SHORT, MPI_INT, MPI_INT};

MPI_Datatype newtype;
MPI_Type_create_struct(sizeof(type) / sizeof(*type), blocklen, disp,
type, &newtype);
MPI_Type_commit(&newtype);
```

Definición de tipos de datos en MPI

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Otras funciones para crear tipos de datos derivados:
- MPI_Type_hvector: Idéntica a MPI_Type_vector, pero el stride se especifica en bytes
- MPI_Type_hindexed: Idéntica a MPI_Type_indexed, pero los offsets se especifican en bytes
- MPI_Type_create_subarray: crea un array (n dimensional) que es parte de otro array (n dimensional)
- MPI_Type_create_darray: crea un array multidimensional distribuido

Ejemplo: tipos de datos derivados

- Intercambio de una estructura de partículas (dos floats, un int)

```
int nblocks = 2, blocklen[] = {2, 1}; oldtypes[] = {MPI_FLOAT, MPI_INT};
MPI_Aint displ[] = {0, 8};          // Seteo manual, no muy recomendado
Particle p;
...                                 // Inicializar MPI
MPI_Get_address(&(p.x),&displ[0]); // Obtener dirección y desplazamiento
MPI_Get_address(&(p.type),&displ[1]);
displ[1] -= displ[0];
displ[0] -= displ[0];
MPI_Type_create_struct(nblocks, blocklen, displ, oldtypes, &MPI_Particle);
MPI_Type_commit(&MPI_Particle);
p.x = ... // Inicializar partícula
int dst = 0, src = 1;
if (rank == src)
    MPI_Send(&p, 1, MPI_Particle, dst, 10, MPI_COMM_WORLD);
else
    MPI_Recv(&p, 1, MPI_Particle, src, 10, MPI_COMM_WORLD, MPI_STATUS_IGNORE);
```

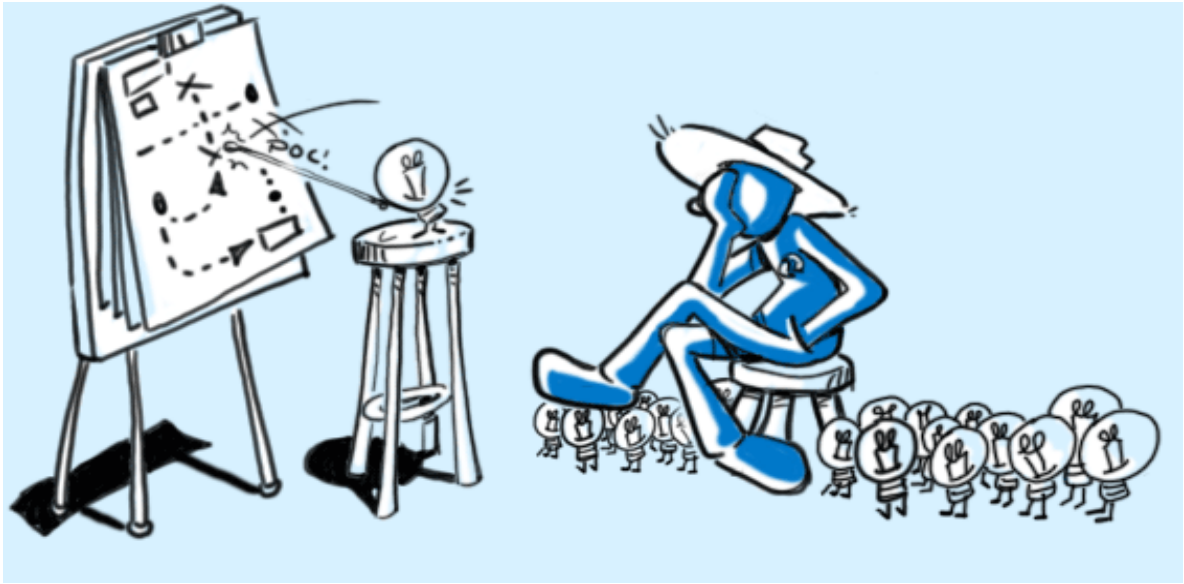

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

CASO DE ESTUDIO
Método de Jacobi paralelo

Caso de estudio

- Método de Jacobi para resolver sistemas de ecuaciones lineales: A x = b.
- Bajo ciertas condiciones, un sistema lineal puede resolverse mediante el método iterativo de Jacobi:

$$a_{ii}x_i^{(k+1)} = -\sum_{\substack{j=1 \\ j\neq i}}^{n} a_{ij}x_j^{(k)} + b_i \qquad x_i^{(k+1)} = \frac{-\sum_{\substack{j=1 \\ j\neq i}}^{n} a_{ij}x_j^{(k)} + b_i}{a_{ii}}$$

- Para calcular el paso k+1 solo se precisan datos del paso anterior k.
- El calculo puede paralelizarse realizando una división de dominio, con un modelo maestro-esclavo.

Caso de estudio

- Asumiendo el sistema de 3×3:

$$5x_1 - 2x_2 + 3x_3 = -1 \rightarrow P0$$
$$-3x_1 + 9x_2 + x_3 = 2 \rightarrow P1$$
$$2x_1 - x_2 - 7x_3 = 3 \rightarrow P2$$

- Se aplica una división del dominio en 3 procesos
- Cada proceso toma la fila i, y calcula el x_i correspondiente
- Cada proceso necesita la fila i de la matriz A, el b_i y la solución actual completa
- El algoritmo general tendrá el siguiente esquema:
  - Distribuir datos iniciales
  - Iterar hasta cierta condición esperada
    - Calcular x_i
    - Distribuir x_i a todos los procesos

Caso de estudio

- Fase de distribución inicial:
  - Se necesita transmitir una fila a cada proceso: se puede utilizar un scatter para la matriz A
  - La misma situación ocurre para el vector b
  - En cambio, es necesario transmitir la solución inicial a todos los procesos (broadcast)
- Fase de iteración:
  - Cada proceso calcula su parte del vector x
  - Para distribuir los valores calculados se puede utilizar un broadcast, o mejor un Allgather
- Ejemplo
  - Disponible en http://www.tezu.ernet.in/dcompsc/facility/HPCC/hypack/mpi-1x-hypack-2013/matrix-comp-solver-codes/jacobi-mpi-code-clang.c

Caso de estudio: Jacobi con MPI

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

```
#include <stdio.h>
#include <assert.h>
#include <mpi.h>
#define MAX_ITERATIONS 100
double Distance(double *X_Old, double *X_New, int n_size);

main(int argc, char** argv) {
/* ....... Inicialización de variables ......*/
MPI_Status status;
int n_size, NoofRows_Bloc, NoofRows, NoofCols;
int Numprocs, MyRank, Root=0;
int irow, jrow, icol, index, Iteration, GlobalRowNo;
double **Matrix_A, *Input_A, *Input_B, *ARecv, *BRecv;
double *X_New, *X_Old, *Bloc_X, tmp; FILE *fp;
/* ....... Inicialización de MPI .......*/
MPI_Init(&argc, &argv);
MPI_Comm_rank(MPI_COMM_WORLD, &MyRank);
MPI_Comm_size(MPI_COMM_WORLD, &Numprocs);
```

Caso de estudio: Jacobi con MPI

```
/* .......Leer archivo de entrada ......*/
if(MyRank == Root) {
   if ((fp = fopen ("./matrix-data-jacobi.inp", "r")) == NULL) {
     printf("Can't open input matrix file"); exit(-1);
   }
   fscanf(fp, "%d %d", &NoofRows,&NoofCols);
   n_size=NoofRows;
/* ... Reservar memoria y leer datos ....*/
     Matrix_A = (double **) malloc(n_size*sizeof(double *));
     for(irow = 0; irow < n_size; irow++){
        Matrix_A[irow] = (double *) malloc(n_size * sizeof(double));
        for(icol = 0; icol < n_size; icol++)
                fscanf(fp, "%lf", &Matrix_A[irow][icol]);
        }
        fclose(fp);
        if ((fp = fopen ("./vector-data-jacobi.inp", "r")) == NULL){
                printf("Can't open input vector file"); exit(-1);
     }
     fscanf(fp, "%d", &NoofRows);
```

Caso de estudio: Jacobi con MPI

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

```
      n_size=NoofRows;
      Input_B  = (double *)malloc(n_size*sizeof(double));
      for (irow = 0; irow<n_size; irow++)
         fscanf(fp, "%lf",&Input_B[irow]);
      fclose(fp);
/* ...Convertir Matrix_A en un array 1D Input_A ......*/
      Input_A  = (double *)malloc(n_size*n_size*sizeof(double));
      index = 0;
      for(irow=0; irow<n_size; irow++)
          for(icol=0; icol<n_size; icol++)
              Input_A[index++] = Matrix_A[irow][icol];
}
MPI_Bcast(&NoofRows, 1, MPI_INT, Root, MPI_COMM_WORLD);
MPI_Bcast(&NoofCols, 1, MPI_INT, Root, MPI_COMM_WORLD);
if(NoofRows != NoofCols) {
           MPI_Finalize();
           if(MyRank == 0) printf("Input Matrix Should Be Square.\n");
           exit(-1);
}
```

Caso de estudio: Jacobi con MPI

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

```
/* .... Broadcast del tamaño de la matriz ...*/
MPI_Bcast(&n_size, 1, MPI_INT, Root, MPI_COMM_WORLD);
if(n_size % Numprocs != 0) {
    MPI_Finalize();
    if(MyRank == 0) printf("Matrix Can not be Striped Evenly ..... \n");
    exit(-1);
}
NoofRows_Bloc = n_size/Numprocs;
/*..... Memoria para matriz de entrada y vector en cada proceso ....*/
ARecv = (double *) malloc (NoofRows_Bloc * n_size* sizeof(double));
BRecv = (double *) malloc (NoofRows_Bloc * sizeof(double));

/*..... Scatter de los datos de entrada a todos los procesos .....*/
MPI_Scatter (Input_A, NoofRows_Bloc * n_size, MPI_DOUBLE, ARecv, NoofRows_Bloc *
n_size, MPI_DOUBLE, 0, MPI_COMM_WORLD);
MPI_Scatter (Input_B, NoofRows_Bloc, MPI_DOUBLE, BRecv, NoofRows_Bloc,
MPI_DOUBLE, 0, MPI_COMM_WORLD);
```

Caso de estudio: Jacobi con MPI

```
X_New  = (double *) malloc (n_size * sizeof(double));
X_Old  = (double *) malloc (n_size * sizeof(double));
Bloc_X = (double *) malloc (NoofRows_Bloc * sizeof(double));
/* Inicializar X[i] = B[i] */
for(irow=0; irow<NoofRows_Bloc; irow++)
    Bloc_X[irow] = BRecv[irow];
MPI_Allgather(Bloc_X, NoofRows_Bloc, MPI_DOUBLE, X_New, NoofRows_Bloc,
                                          MPI_DOUBLE, MPI_COMM_WORLD);
Iteration = 0;
do {
       for(irow=0; irow<n_size; irow++)
           X_Old[irow] = X_New[irow];
       for(irow=0; irow<NoofRows_Bloc; irow++){
          GlobalRowNo = (MyRank * NoofRows_Bloc) + irow;
          Bloc_X[irow] = BRecv[irow];
          index = irow * n_size;
          for(icol=0; icol<GlobalRowNo; icol++){
                Bloc_X[irow] -= X_Old[icol] * ARecv[index + icol];
          }
```

Caso de estudio: Jacobi con MPI

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

```
            for(icol=GlobalRowNo+1; icol<n_size; icol++){
                Bloc_X[irow] -= X_Old[icol] * ARecv[index + icol];
            }
            Bloc_X[irow] = Bloc_X[irow] / ARecv[irow*n_size + GlobalRowNo];
        }
        MPI_Allgather(Bloc_X, NoofRows_Bloc, MPI_DOUBLE, X_New, NoofRows_Bloc,
                                             MPI_DOUBLE, MPI_COMM_WORLD);
        Iteration++;
    } while((Iteration < MAX_ITERATIONS)&&(Distance(X_Old,X_New,n_size)>=1.0E-24));

    /* ..... Imprimir vector resultado ....*/
    if (MyRank == 0) {
        printf("Results of Jacobi Method on processor %d: \n", MyRank);
        printf("Matrix Input_A \n");
        for (irow = 0; irow < n_size; irow++) {
            for (icol = 0; icol < n_size; icol++)
                printf("%.3lf  ", Matrix_A[irow][icol]);
            printf("\n");
        }
```

Caso de estudio: Jacobi con MPI

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

```
    printf("Matrix Input_B \n");
    for (irow = 0; irow < n_size; irow++) {
        printf("%.3lf\n", Input_B[irow]);
    }
    printf("Solution vector \n");
    printf("Number of iterations = %d\n",Iteration);
    for(irow = 0; irow < n_size; irow++)
        printf("%.12lf\n",X_New[irow]);
    }
MPI_Finalize();
}

double Distance(double *X_Old, double *X_New, int n_size){
   int  index;
   double Sum = 0.0;
   for(index=0; index<n_size; index++)
        Sum += (X_New[index]-X_Old[index])*(X_New[index]-X_Old[index]);
   return(Sum);
}
```

Caso de estudio

- Otros códigos de ejemplo para la resolución de sistemas de ecuaciones lineales con MPI
  - Disponibles en https://www.cdac.in/index.aspx?id=print_page&print=ev_hpc_hypack_matrix-comp-solver-mpi
  - Eliminación gaussiana
  - Gradiente conjugado
  - Método de Gauss Seidel

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

MPI-2 y MPI-3

Motivación

- MPI-1 fue liberado en 1994 como resultado de un trabajo en conjunto entre varios vendedores
- Se desarrollaron una gran cantidad de implementaciones propietarias y libres
- A su vez, se estaban desarrollando otros modelos de programación paralela que proveían otras funcionalidades
- Las funcionalidades más notables que no proveía MPI-1:
  - Creación dinámica de procesos
  - Entrada/salida paralela
  - Único modelo de comunicación: two-sided
- De forma de cubrir esas necesidades se elaboró un nuevo foro de discusión y una posterior nueva versión del estándar

Evolución del estándar

- MPI-1.0: Mayo, 1994
- MPI-1.1: Junio, 1995
- MPI-1.2: Julio, 1997
  - MPICH 1.2.7p1 (Noviembre, 2005)
- MPI-2.0: Julio, 1997
- MPI-1.3: Mayo, 2008
- MPI-2.1: Junio, 2008
- MPI-2.2: Setiembre, 2009
  - MPICH2 2.4.1 (Setiembre,2011)
- MPI-3.0: Setiembre, 2012

Entrada/salida paralela

- MPI-1 no proporcionó ningún soporte para operaciones de entrada/salida
- Los programadores se vieron obligados a diseñar sus propios mecanismos de E/S
- Las dos configuraciones más utilizadas son:
  - E/S secuencial: Un único proceso MPI centraliza la lectura/escritura en un archivo único
  - E/S Paralela con múltiples archivos: Cada proceso lee/escribe de un archivo distinto

Entrada/salida secuencial

- Un proceso es dedicado a concentrar todas las lecturas/escrituras
- Los demás procesos envían/reciben los mensajes a través de intercambio de mensajes
- Bajo desempeño

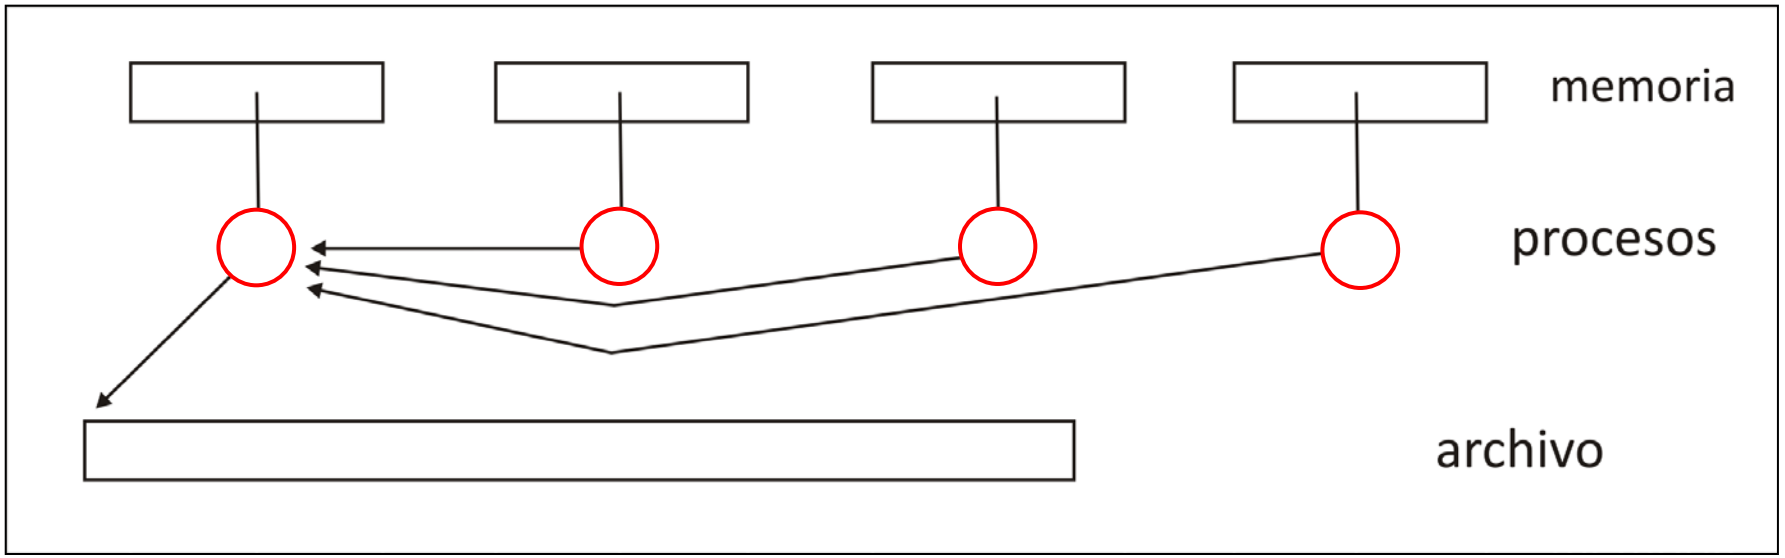

Entrada/salida paralela a múltiples archivos

- Cada proceso MPI lee/escribe de un archivo distinto
- No es necesario la sincronización por parte de los procesos
- El archivo debe ser unido posteriormente por fuera de MPI
- Mayor esfuerzo de gestión y overhead

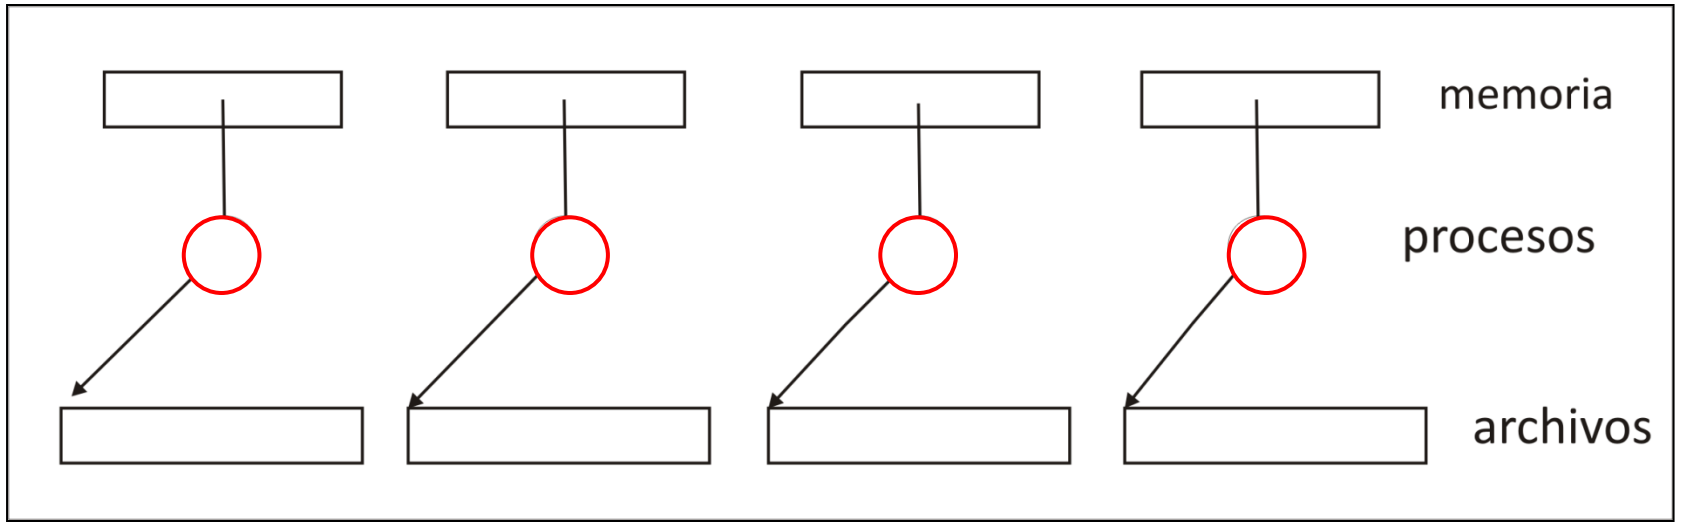

Entrada/salida en MPI-2

- El estandar MPI-2 introdujo un conjunto de primitivas específicas para el manejo de E/S
- Ventajas sobre E/S estándar (POSIX):
  - Performance/desempeño
  - Permite implementar E/S con archivo único (no se requiere un archivo por proceso)
- Los procesos MPI pueden acceder a una porción de un archivo común
- Se proponen primitivas similares a las ya establecidas para manipulación de archivos: open, close, read, write, seek, etc.
- Se proveen operaciones para acceso contiguo y no contiguo
- Se definen vistas del archivo (file view) para cada proceso de forma de lograr el acceso no contiguo

Entrada/salida paralela en MPI

- Cada proceso MPI lee/escribe de un único archivo
- Cada proceso tiene porciones/vistas del archivo
- Escribir es análogo a enviar (send) y leer es análogo a recibir (receive)
- Mayor desempeño, la gestión de vistas la realiza MPI

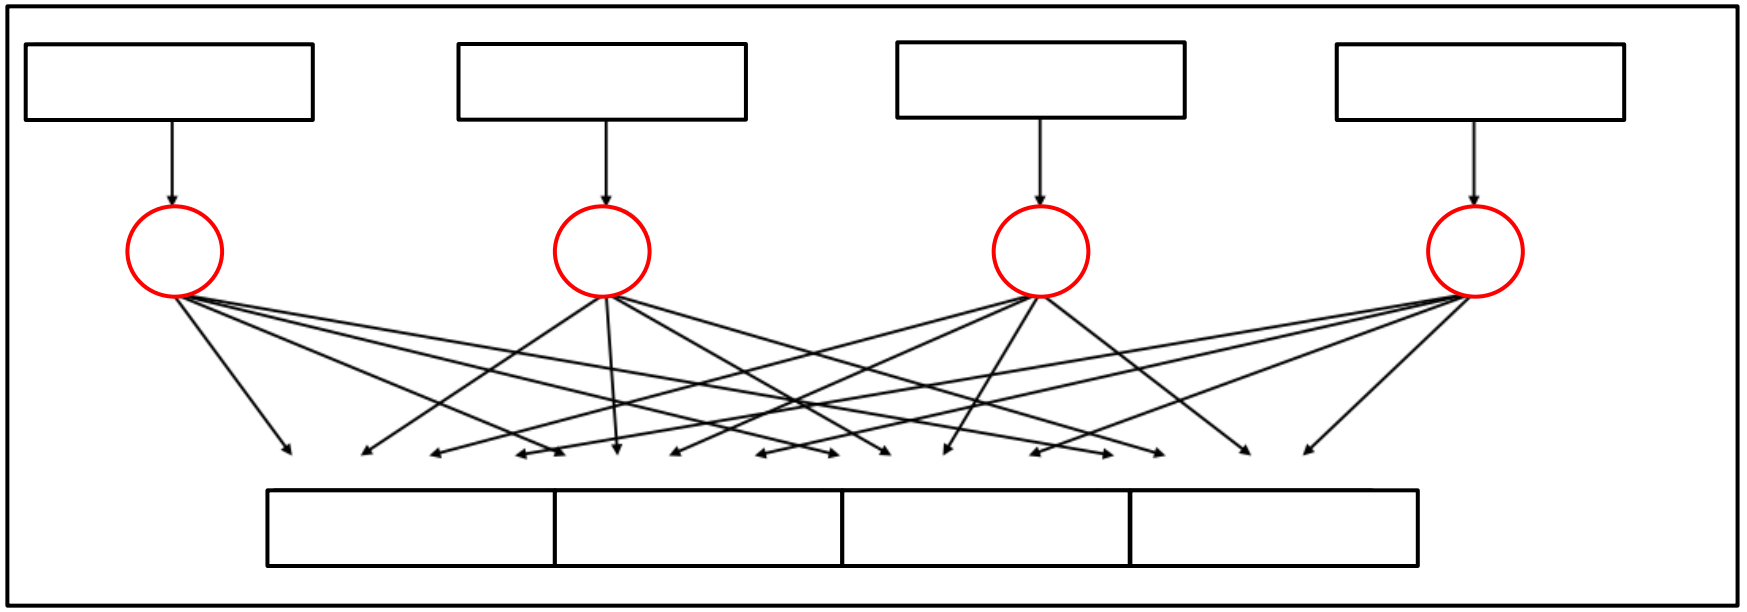

Entrada/salida en MPI-2

- Escribir es análogo a enviar (send) y leer es análogo a recibir (receive)
- El sistema de E/S paralela require:
  - Operaciones colectivas
  - Tipos de datos definidos por el usuario para especificar los datos a almacenar en memoria y en el archivo
  - Comunicaciones para separar el pasaje de mensajes de los procesos (nivel de aplicación) de los mensajes utilizados para E/S (nivel del sistema)
  - Operaciones no bloqueantes
- Al nivel de aplicación:
  - Lecturas y escrituras concurrentes de múltiples procesos a un único archivo
- Al nivel del sistema:
  - Un sistema de archivos paralelo y hardware que soporte el acceso concurrente

Abrir y cerrar archivos

- MPI-2 define el tipo **MPI_File** que proporciona punteros (*handlers*) a los archivos
- Las operaciones de apertura (MPI_File_open) y cierre (`MPI_File_close`) de archivo son operaciones colectivas

```
MPI_File_open(comm, filename, mode, info, fpointer)
```

  - **comm**: Comunicador asociado a la operación colectiva
  - **mode**: modo de apertura: MPI_MODE_RDONLY, MPI_MODE_WRONLY, MPI_MODE_CREATE, etc.
  - **info**: sugerencias para optimizar la implementación
  - **fpointer**: *handler* para acceso

```
MPI_File_close(fpointer)
```

Lectura/escritura

- Los archivos abiertos por un proceso tienen asociado un file pointer para acceso secuencial sobre una vista (file view) del archivo
- La vista por defecto es todo el archivo, pero se pueden definir porciones específicas según un formato dado a través de tipo de datos estándar o estructurados MPI
- Las operaciones no son colectivas
- Las operaciones son relativas al *file pointer* del archivo referenciado
- La funciones `MPI_File_read` y `MPI_File_write` no son *thread-safe*

Lectura

- La operación MPI_File_read utiliza el file pointer para acceder al archivo

```
MPI_File_read(MPI_File fp, void *buf, int count, MPI_Datatype
                datatype, MPI_Status *status)
```

  - **fp**: handler para acceso
  - **count**: número de elementos a escribir
  - **datatype**: tipo del dato a leer
  - **buf**: dirección del buffer de salida
  - **status**: información adicional

```
bufsize = FILESIZE/nprocs;
nints = bufsize/sizeof(int);

MPI_File_open(MPI_COMM_WORLD, ”archivo.txt”,
                MPI_MODE_RDONLY, MPI_INFO_NULL,&fh);
MPI_File_read(fh,buf,nints,MPI_INT,&status);
```

Lectura con posicionamiento previo

- Para ubicarse en una posición dentro del archivo se utiliza la función MPI_File_seek, que actualiza el file pointer del proceso

```
int MPI_File_seek(MPI_File fh, MPI_Offset offset, int update)
```

- Update tiene tres valores
  - MPI_SEEK_SET: el puntero se setea al offset
  - MPI_SEEK_CUR: el puntero se setea a la posición actual más el offset
  - MPI_SEEK_END: el puntero se setea al final del archivo más el offset

```
bufsize = FILESIZE/nprocs;
nints = bufsize/sizeof(int);

MPI_File_open(MPI_COMM_WORLD, ”archivo.txt”,
              MPI_MODE_RDONLY, MPI_INFO_NULL,&fh);
MPI_File_seek(fh, rank*buffsize, MPI_SEEK_SET);
MPI_File_read(fh,buf,nints,MPI_INT,&status);
```

Escritura

- MPI_File_write también utiliza el file pointer para el acceso

```
MPI_File_write(MPI_File fp, void *buf, int count,
  MPI_Datatype datatype, MPI_Status *status)
```

  - **fp**: handler para acceso
  - **count**: número de elementos a escribir
  - **datatype**: tipo del dato a leer
  - **buf**: dirección del buffer de la aplicación
  - **status**: información adicional

```
MPI_File_open(MPI_COMM_WORLD, ”archivo.txt”, MPI_MODE_CREATE
                  | MPI_MODE_WRONLY, MPI_INFO_NULL, &fh);
MPI_File_write(fh,buf,BUFSIZE,MPI_INT,MPI_STATUS_IGNORE);
```

- Pueden utilizarse tipos estructurados MPI
- Puede utilizarse MPI_File_seek para posicionamiento.
- Puede definirse una vista para escribir en una porción del archivo

Escritura: ejemplo

```
#include <stdio.h>
#include "mpi.h”
int main(int argc, char *argv[]){
MPI_File fh;
int buf[1000], rank;

MPI_Init(argc, argv);
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
MPI_File_open(MPI_COMM_WORLD,"test.out", MPI_MODE_CREATE |
              MPI_MODE_WRONLY, MPI_INFO_NULL, &fh);
if (rank == 0)
    MPI_File_write(fh, buf, 1000, MPI_INT, MPI_STATUS_IGNORE);
MPI_File_close(&fh);
MPI_Finalize();
return 0;
}
```

Lectura/escritura en MPI

- `MPI_File_open` es colectiva sobre el comunicador
  - Debe ser colectiva para proporcionar soporte a E/S colectiva, para mejorar el desempeño
  - Los modos de apertura son similares a los de Unix/Linux: MPI_MODE_WRONLY, MPI_MODE_RDWR, MPI_MODE_CREATE
  - Info prové información adicional para mejorar el desempeño
- `MPI_File_write` es independiente paa cada proceso (por este motive se chequea el rango del proceso que escribe)
- `MPI_File_close` es colectiva, su análogo es MPI_Comm_free
  - Libera los recursos utilizados para la gestión del archivo compartido

Lectura/escritura con posición

- Además de las operaciones básicas se proveen funciones para leer/escribir con posición explícita:
  - `MPI_File_read_at`
  - `MPI_File_write_at`
- Estas funciones son thread-safe y no modifican el file pointer
- Se utiliza un direccionamiento (posicionamiento explícito) que no modifica el estado interno (fp)
- Es útil cuando la sincronización de las operaciones colectivas no es natural para el esquema de paralelismo, o cuando el overhead al utilizar operaciones colectivas conspira contra el desempeño
  - Por ejemplo: E/S de pocos datos durante una lectura de inicialización

Lectura con posición: ejemplo

```
#include “mpi.h”
MPI_Status status;
MPI_File fh;
MPI_Offset offset;

MPI_File_open(MPI_COMM_WORLD, “/pfs/datafile”, MPI_MODE_RDONLY,
              MPI_INFO_NULL, &fh)
nints = FILESIZE / (nprocs*INTSIZE);
offset = rank * nints * INTSIZE;

MPI_File_read_at(fh, offset, buf, nints, MPI_INT, &status);
MPI_Get_count(&status, MPI_INT, &count);
printf(“process %d read %d ints\n”, rank, count);
MPI_File_close(&fh);
```

Lectura/escritura: acceso no contiguo

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Acceso no contiguo
  - Cuando un proceso abre un archivo tiene una visión total de su contenido
  - MPI proporciona vistas para describir la parte de un archivo que es responsabilidad de cada proceso
  - Las vistas se definen por un offset y un tipo de datos (MPI_Datatype)
  - Proveen una manera eficiente de implementar el acceso no contiguo
  - Luego de invocada/definida la vista, solo la parte definida (porción visible) es accessible al proceso MPI para E/S

Vistas

- MPI_File_set_view define una vista de un archivo

```
int MPI_File_set_view(MPI_File fp, MPI_Offset disp, MPI_Datatype
etype, MPI_Datatype filetype, char *datarep, MPI_Info info)
```

  - fp: handler para acceso
  - disp: offset de inicio de la vista (relativo al inicio del archivo)
  - etype: (elementary datatype) tipo de dato básico (o derivado) de la vista
  - filetype: tipo de dato, etype o derivado (a partir de etype)
  - datarep: representación de datos “native”, “internal” o “external32”
  - info: información adicional para mejorar el desempeño (MPI_INFO_NULL: sin información)

```
MPI_File_open(MPI_COMM_WORLD, ”archivo.txt”,  MPI_MODE_CREATE
                  | MPI_MODE_WRONLY, MPI_INFO_NULL, &fh);
MPI_File_set_view(fh,myrank * BUFSIZE * sizeof(int), MPI_INT,
                  MPI_INT, ”native”, MPI_INFO_NULL);
MPI_File_write(fh,buf,BUFSIZE,MPI_INT,MPI_STATUS_IGNORE);
```

Vistas

- Se espera que se invoque MPI_File_set_view inmediatamente después de MPI_File_open
- El acceso a los datos se realiza en etype unidades, para leer o escribir items (datos) de tipo etype. Los offsets se expresan en etypes y los file pointers apuntan al inicio de etypes.
- Inicialemnte, todos los procesos ven al archivo como un arreglo lineal de bytes (byte stream), etype y filetype son ambos MPI_BYTE.
- Si el archivo se abrió en el modo MPI_MODE_SEQUENTIAL, el desplazamiento especial MPI_DISPLACEMENT_CURRENT debe especificarse en disp, para setear el desplazamiento a la posición actual del file pointer compartido. MPI_DISPLACEMENT_CURRENT es inválido en otro caso.

Vistas

etype: MPI_DOUBLE

filetype: patrón (uno de cada cuatro doubles)

Inicio del archivo

desplazamiento

Vista: cada tarea repite el patrón, con diferentes desplazamientos

Vistas

etype: MPI_INT

filetype: patrón (dos enteros seguidos de un gap de cuatro enteros)

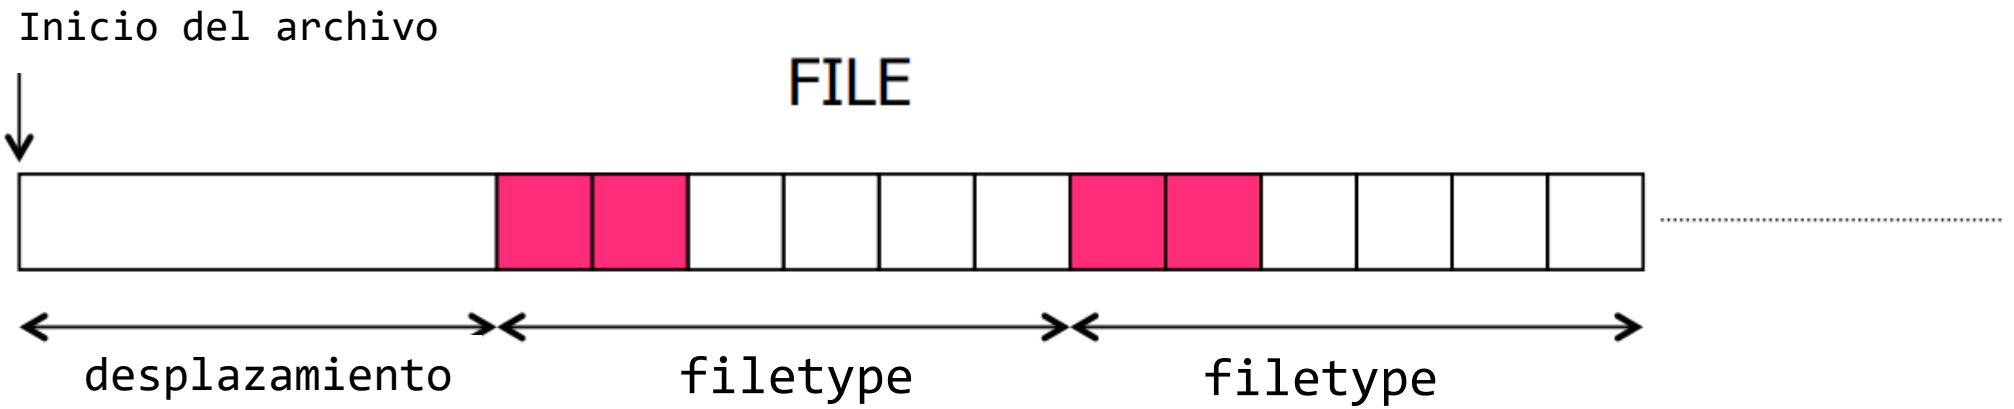

Vista: cada tarea repite el patrón, con diferentes desplazamientos

Vistas

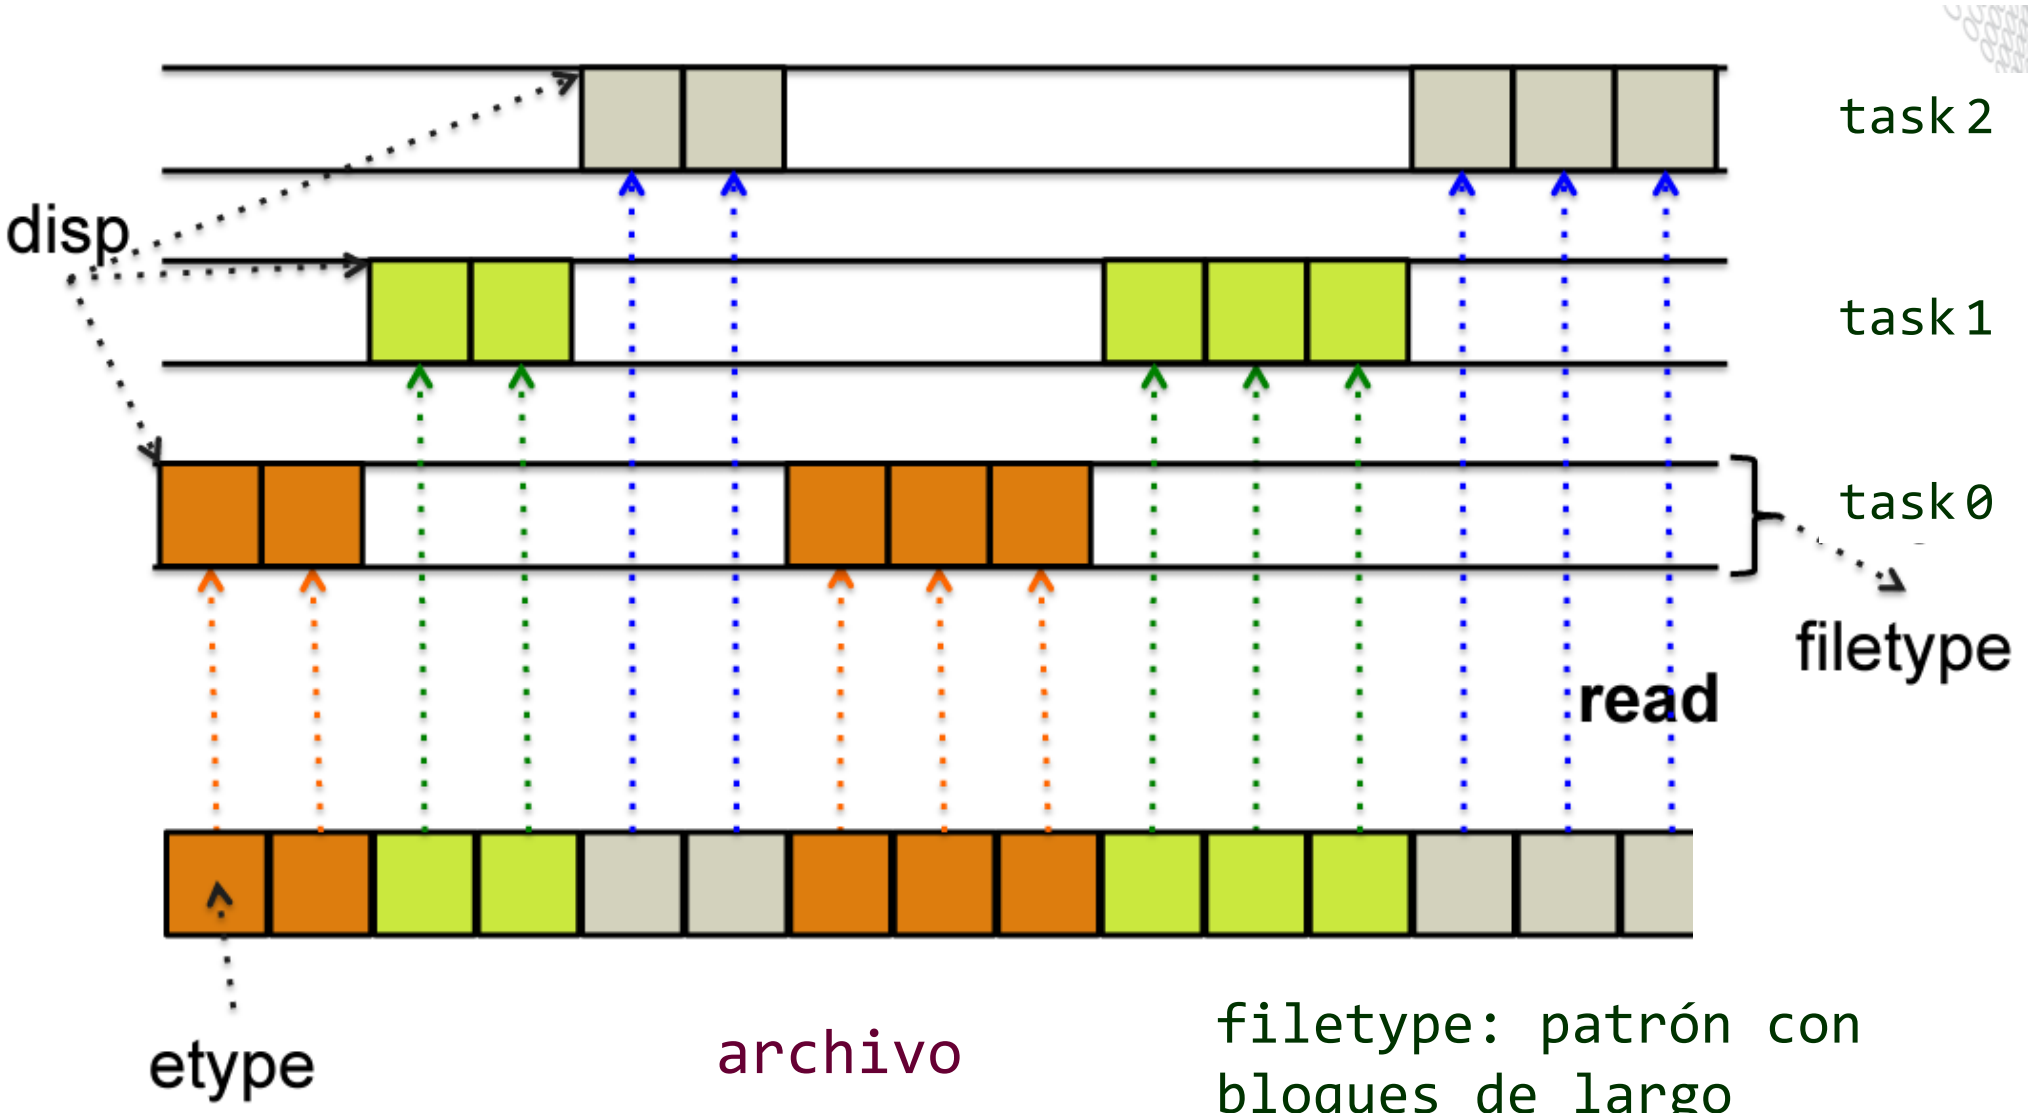

filetype: patrón con bloques de largo variable

Escritura sobre vistas

- Simplemente se invoca `MPI_File_write` con el file handler retornado en la creación de la vista

```
MPI_File_open(MPI_COMM_WORLD, ”archivo.txt”,  MPI_MODE_CREATE
                  | MPI_MODE_WRONLY, MPI_INFO_NULL, &fh);
MPI_File_set_view(fh,myrank * BUFSIZE * sizeof(int), MPI_INT,
                  MPI_INT, ”native”, MPI_INFO_NULL);
MPI_File_write(fh,buf,BUFSIZE,MPI_INT,MPI_STATUS_IGNORE);
```

- En el ejemplo el tipo de información del archivo es MPI_INT
- Se pueden utilizar tipos derivados de MPI

Vistas: ejemplo 1

- Escribir datos en bloques definidos por vistas

```
#define N 100
MPI_Datatype arraytype;
MPI_Offset disp;

disp = rank * sizeof(int) * N;
etype = MPI_INT;
MPI_Type_contiguous(N, MPI_INT
MPI_Type_commit(&arraytype);
```

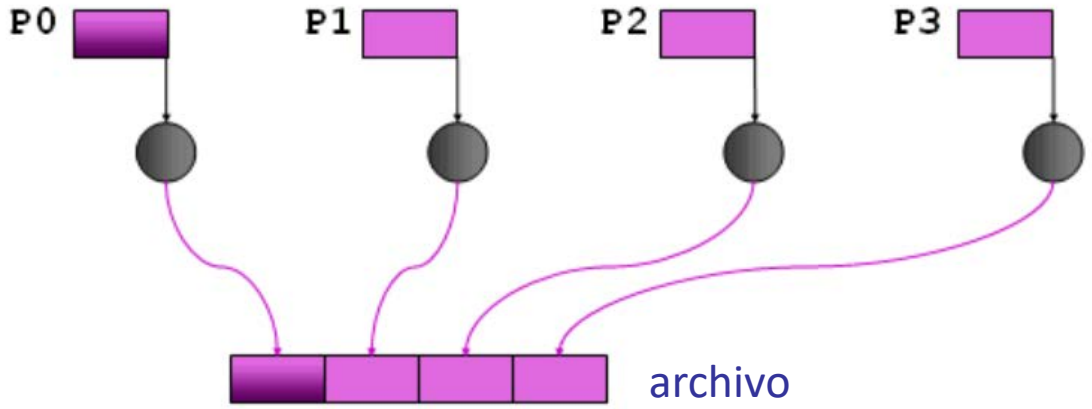


```
MPI_File_open(MPI_COMM_WORLD, “data1”, MPI_MODE_CREATE | MPI_MODE_RDWR,
              MPI_INFO_NULL, &fh);
MPI_File_set_view(fh, disp, etype, arraytype, "native", MPI_INFO_NULL);
MPI_File_write(fh, buf, N, etype, MPI_STATUS_IGNORE);
```

Vistas: ejemplo 2

```
int buf[NW*2];

MPI_File_open(MPI_COMM_WORLD,"data2",MPI_MODE_RDWR,MPI_INFO_NULL,&fh);
/* archivo: dos bloques de NW enteros, separados NW*nprocs */
MPI_Type_vector(2, NW, NW*nprocs, MPI_INT, &fileblk);
MPI_Type_commit(&fileblk);

disp = (MPI_Offset)rank*NW*sizeof(int);
MPI_File_set_view(fh, disp, MPI_INT, fileblk, "native", MPI_INFO_NULL);
/* escribir dos 'ablk', cada uno con NW enteros */
MPI_Type_contiguous(NW, MPI_INT, &ablk);
MPI_Type_commit(&ablk);
MPI_File_write(fh, (void *)buf, 2, ablk, &status);
```

- El tipo de dato en memoria es un arreglo (contíguo) de NW enteros.
- El tipo de la vista es fileblk, desplazado rank*NW*sizeof(int).
- Dos unidades del tipo de dato se escriben en el archivo sobre el que se definió la vista

Vistas: ejemplo 2

```
int buf[NW*2];

MPI_File_open(MPI_COMM_WORLD,"data2",MPI_MODE_RDWR,MPI_INFO_NULL,&fh);
/* archivo: dos bloques de NW enteros, separados NW*nprocs */
MPI_Type_vector(2, NW, NW*nprocs, MPI_INT, &fileblk);
MPI_Type_commit(&fileblk);

disp = (MPI_Offset)rank*NW*sizeof(int);
MPI_File_set_view(fh, disp, MPI_INT, fileblk, "native", MPI_INFO_NULL);
/* escribir dos 'ablk', cada uno con NW enteros */
MPI_Type_contiguous(NW, MPI_INT, &ablk);
MPI_Type_commit(&ablk);
MPI_File_write(fh, (void *)buf, 2, ablk, &status);
```

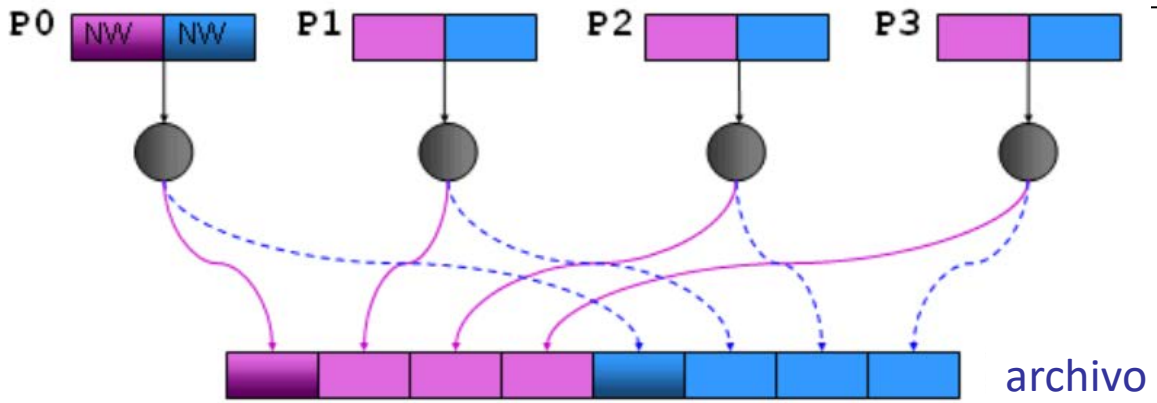

Vistas: acceso no contiguo

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- El acceso no contiguo es fundamental en el paralelismo
- Ejemplo: arrays distribuidos almacenados en archivos
- Una de las principales ventajas de la E/S en MPI sobre la de Lixux es la capacidad de especificar accesos no contiguous en memoria y en archivos en una única invocación a función, usando tipos derivados.
- Permite implementaciones optimizadas para mejorar el desempeño
- Los accesos no contiguous combinados con operaciones de E/S colectivas permiten alcanzar los mejores niveles de desempeño

E/S colectiva

- Una optimización crítica para implementar E/S paralela
- Todos los procesos en un grupo (comunicador) deben invocar la función de E/S colectiva
- Permite al file system tener una vision global de las transferencias de datos e implementarlas en dos fases: 1) comunicación y 2) E/S
- Comunicaciones preliminaries usan MPI para agregar datos
- Idea: construir grandes bloques de datos para lectura/escritura eficiente

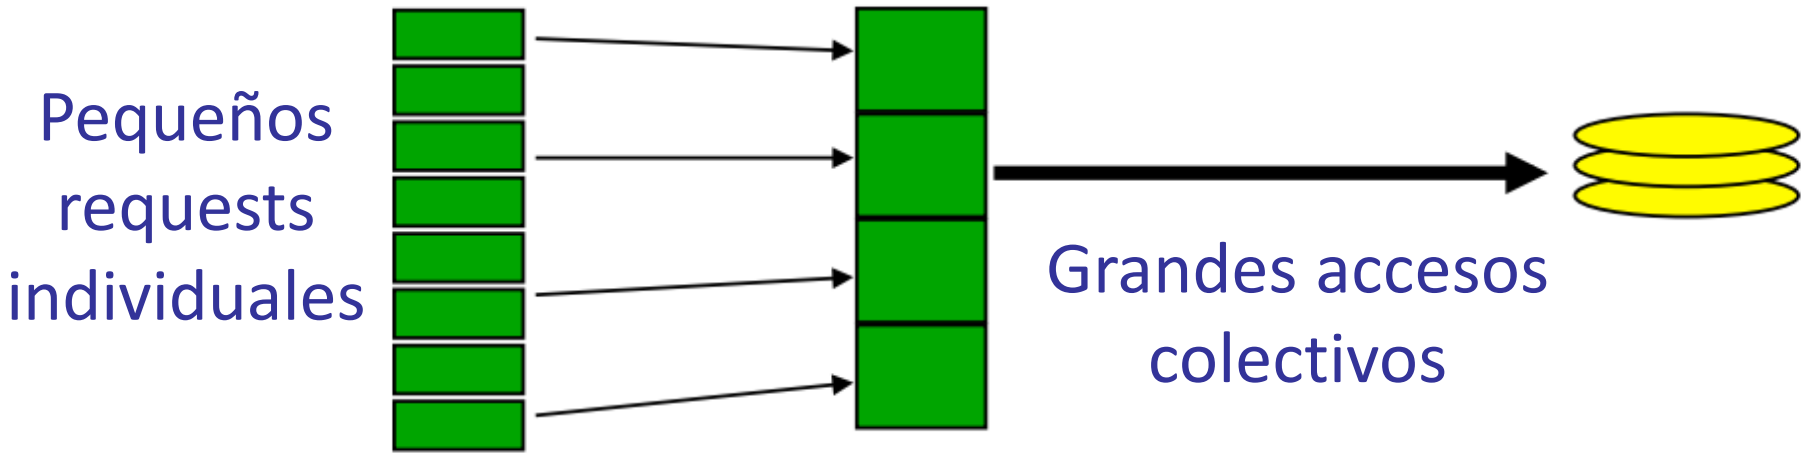

E/S colectiva

- Idea: construir grandes bloques de datos para lectura/escritura eficiente
- Requests de diferentes procesos pueden agruparse
- Particularmente efectivo cuando los accesos de diferentes procesos son no-contiguos e intercalados

Estructuras de memoria en cuatro procesos

MPI recolecta en buffers intermedios

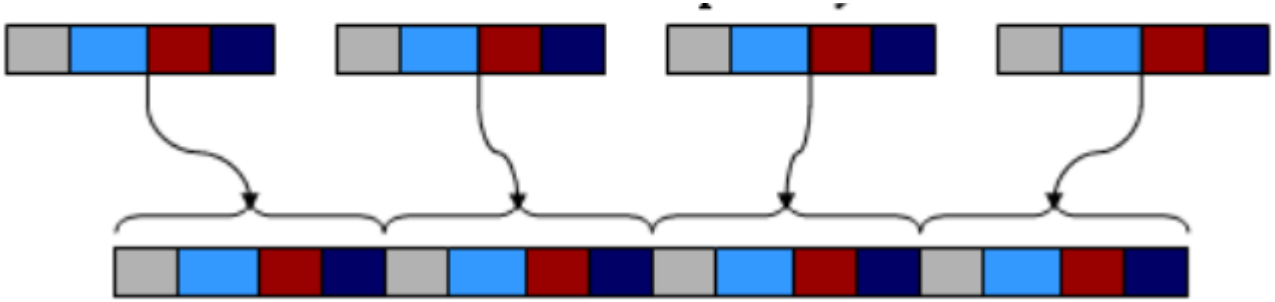

MPI escribe en archivo con el formato especificado

E/S colectiva

- MPI_File_write_at_all escritura colectiva para procesos en un grupo
- El grupo es el del comunicador indicado en MPI_File_open

```
int MPI_File_write_at_all (MPI_File fp, MPI_Offset offset, void
*buf, int count, MPI_Datatype datatype, MPI_Status *status)
```

  - **fp**: handler para acceso
  - **offset**: offset en el archivo (relativo al inicio del archivo)
  - **buffer**: dirección del buffer a escribir
  - **count**: número de elementos a escribir
  - **datatype**: tipo de datos MPI (estándar o derivado)
  - **status**: información adicional
- MPI_File_read_at_all tiene el mismo header
- MPI_File_write_at_all y MPI_File_read_at_all indicanla posición en el archive, no necesitan modificar el file pointer y por ello son thread-safe, a diferencia de una invocación separada a MPI_File_seek

E/S: niveles de acceso

- Ejemplo: acceso a una gran estructura de datos [array] distribuida entre 16 procesos

P0	P1	P2	P3
P4	P5	P6	P7
P8	P9	P10	P11
P12	P13	P14	P15

Cada cuadrado representa un subarray en la memoria de un único proceso

- Patrón de accesos en el archivo

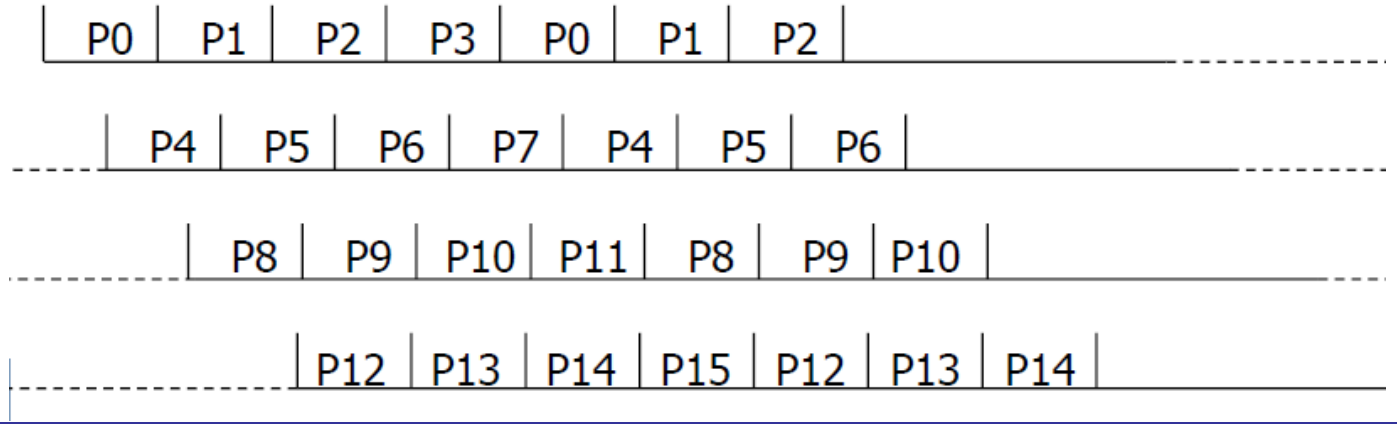

E/S: niveles de acceso

- Acceso de nivel 0: cada proceso realiza lecturas independientes para cada fila en el array (como en Linux/Unix)

```
MPI_File_open(..., file, ..., &fh);
for (i=0; i<n_local_rows; i++) {
    MPI_File_seek(fh, ...);
    MPI_File_read(fh, &(A[i][0]), ...);
}
MPI_File_close(&fh);
```

E/S: niveles de acceso

- Acceso de nivel 1: similar al acceso de nivel 0, pero cada proceso utiliza funciones de E/S colectiva

```
MPI_File_open(MPI_COMM_WORLD, file, ..., &fh);
for (i=0; i<n_local_rows; i++) {
    MPI_File_seek(fh, ...);
    MPI_File_read_all(fh, &(A[i][0]), ...);
}
MPI_File_close(&fh);
```

E/S: niveles de acceso

- Acceso de nivel 2: cada proceso crea un tipo de datos derivado para describir el patrón de acceso no contiguo, define una vista y realiza lecturas independientes

```
MPI_Type_create_subarray(..., &subarray, ...);
MPI_Type_commit(&subarray);
MPI_File_open(..., file, ..., &fh);
MPI_File_set_view(fh, ..., subarray, ...);
MPI_File_read(fh, A, ...);
MPI_File_close(&fh);
```

E/S: niveles de acceso

- Acceso de nivel 3: similar al acceso de nivel 2, excepto que cada proceso utiliza funciones de E/S colectiva

```
MPI_Type_create_subarray(..., &subarray, ...);
MPI_Type_commit(&subarray);
MPI_File_open(MPI_COMM_WORLD, file,..., &fh);
MPI_File_set_view(fh, ..., subarray, ...);
MPI_File_read_all(fh, A, ...);
MPI_File_close(&fh);
```

E/S: niveles de acceso

- Los cuatro niveles de acceso

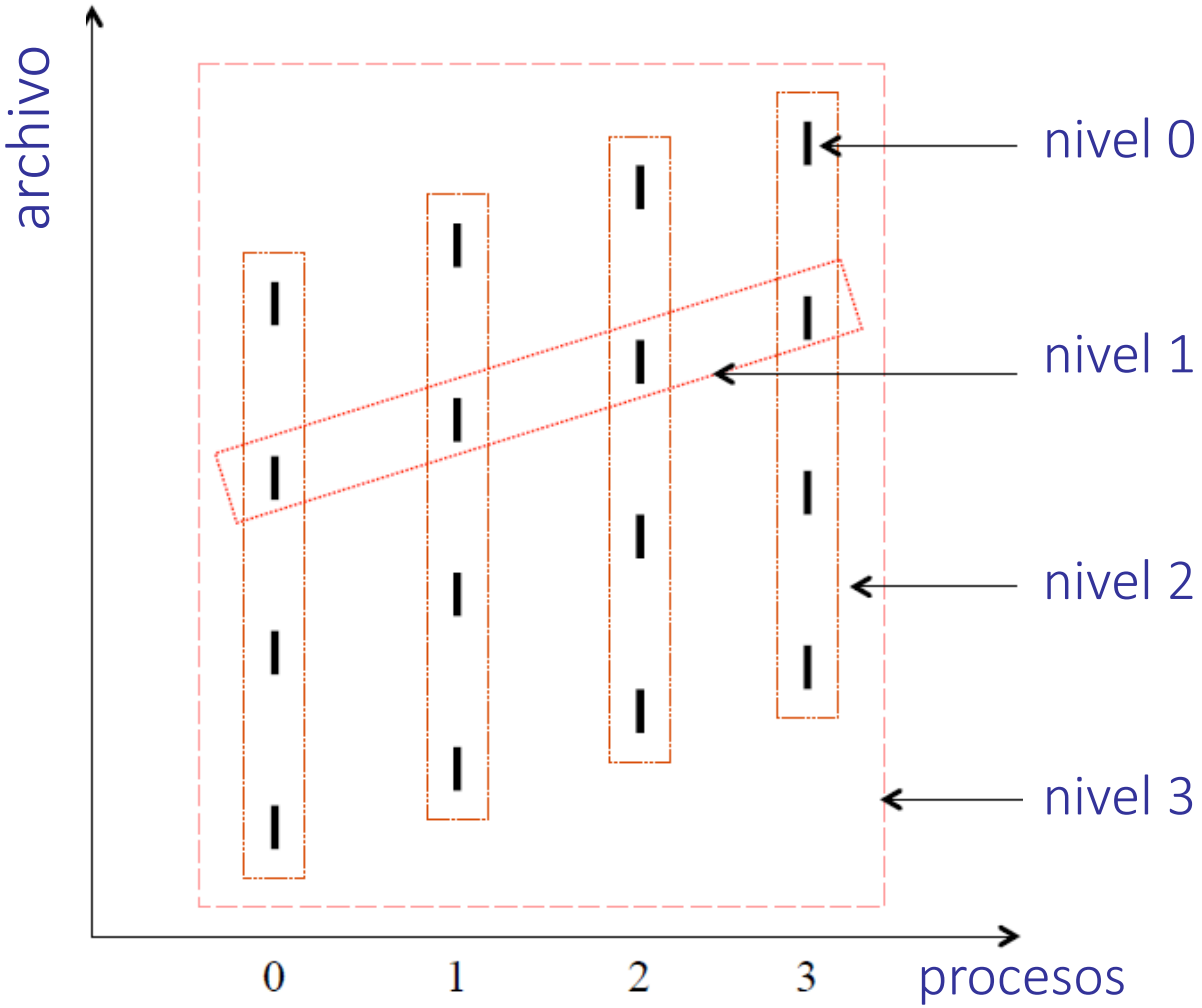

E/S: niveles de acceso y desempeño

- Desempeño de la escritura de un array 3D usando 256 procesos, en dos supercomputadoras

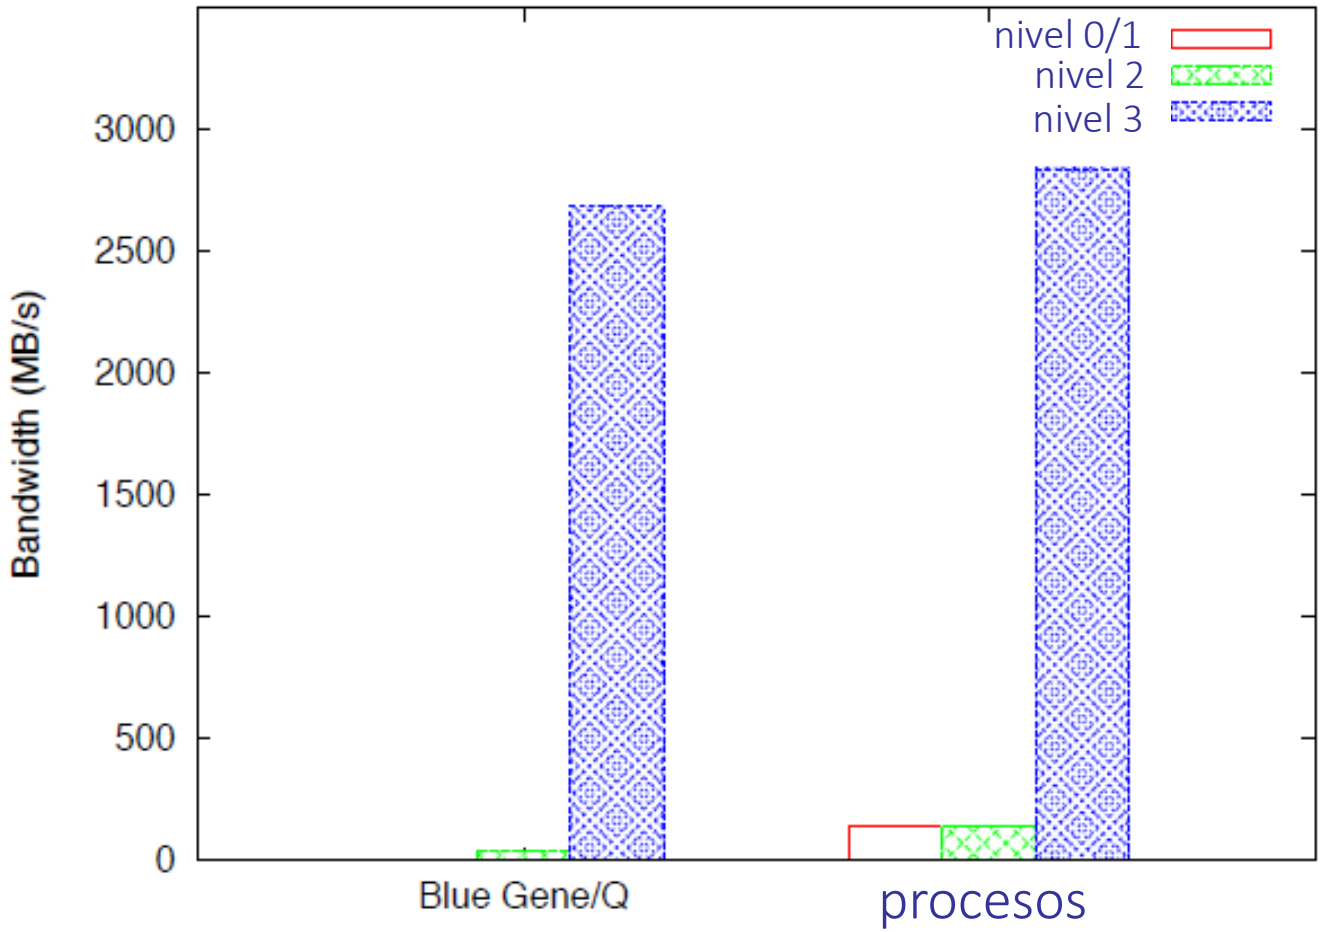

Comunicaciones de una vía

- La idea es desacoplar el movimiento/comunicación de datos con la necesidad de sincronización
- El proceso local puede copiar datos sin necesidad de que el proceso remoto sincronice
- Un proceso expone una parte de la memoria para acceso (lectura/escritura) por parte de otros procesos

Espacio de direccionamiento global

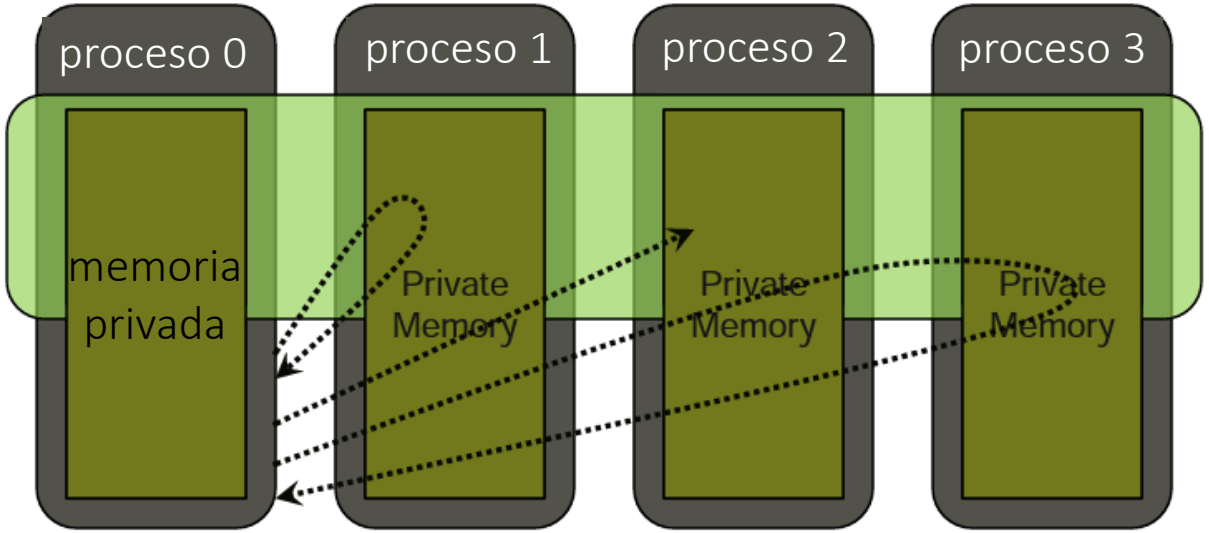

Comunicaciones de dos vías

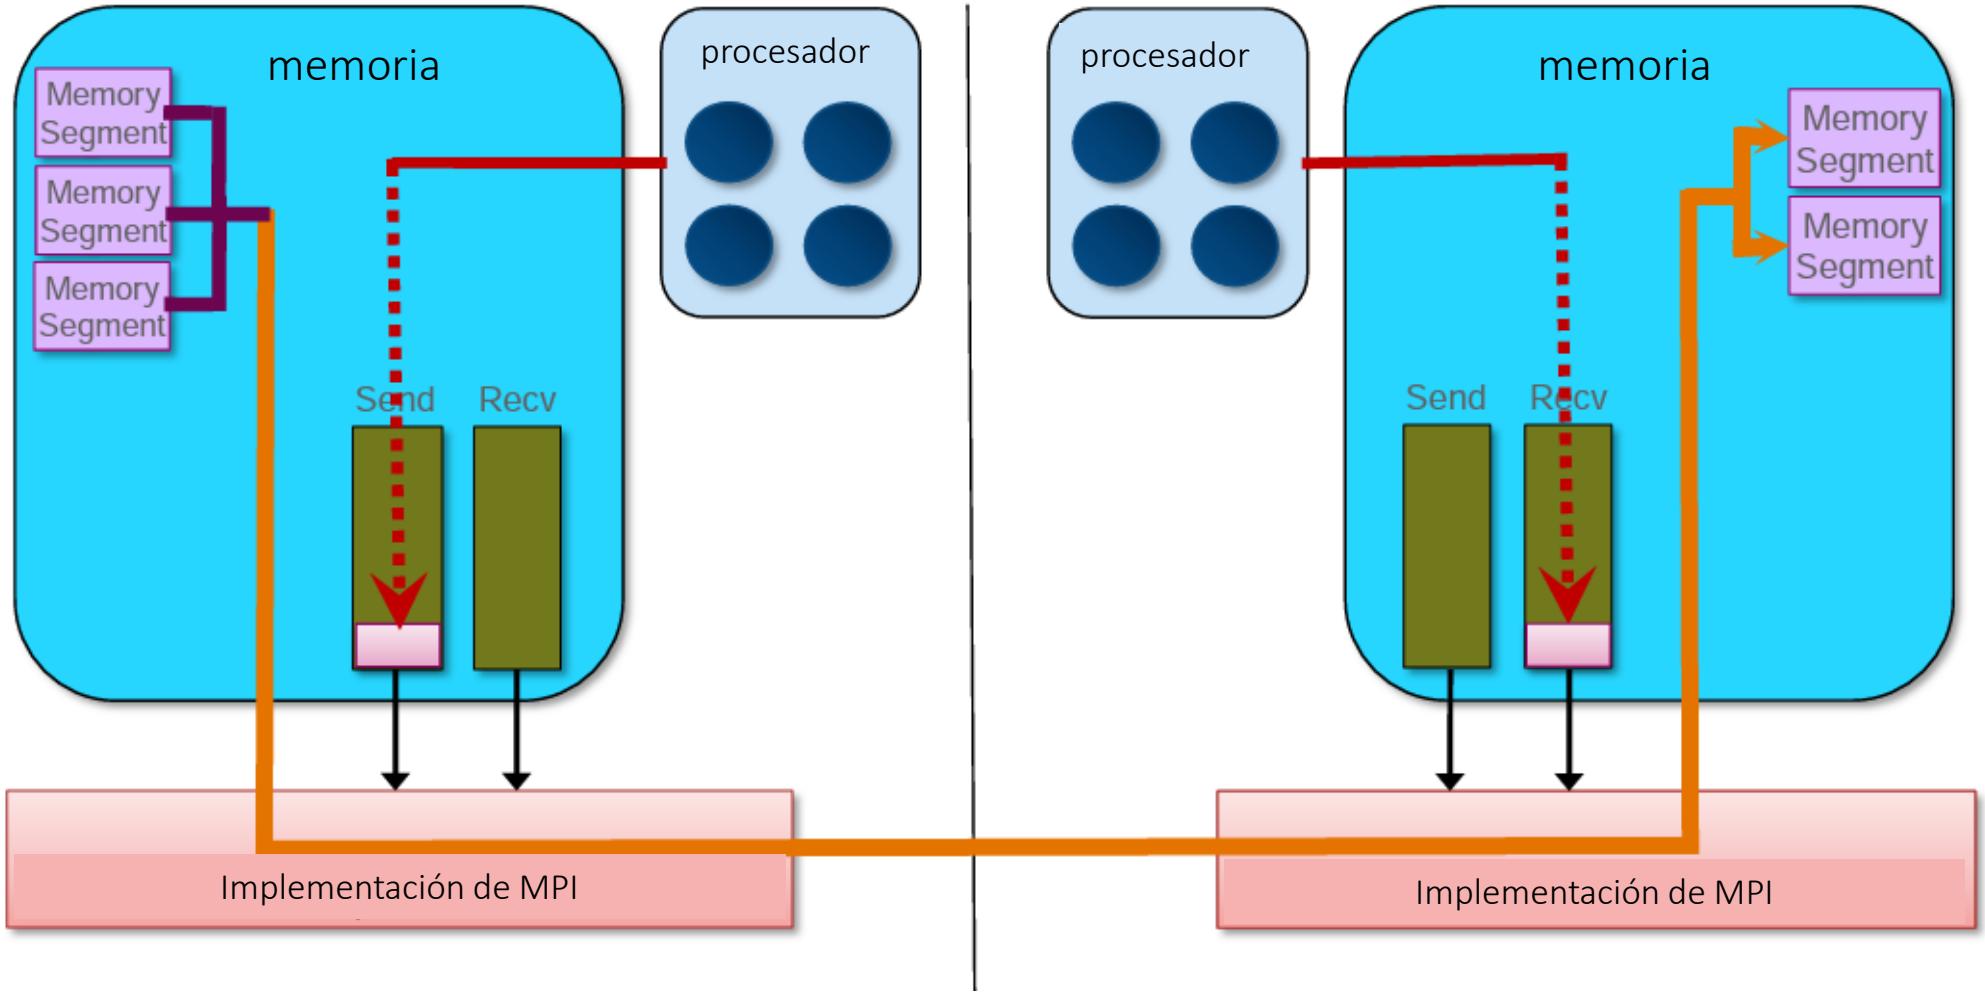

Comunicaciones de una vía

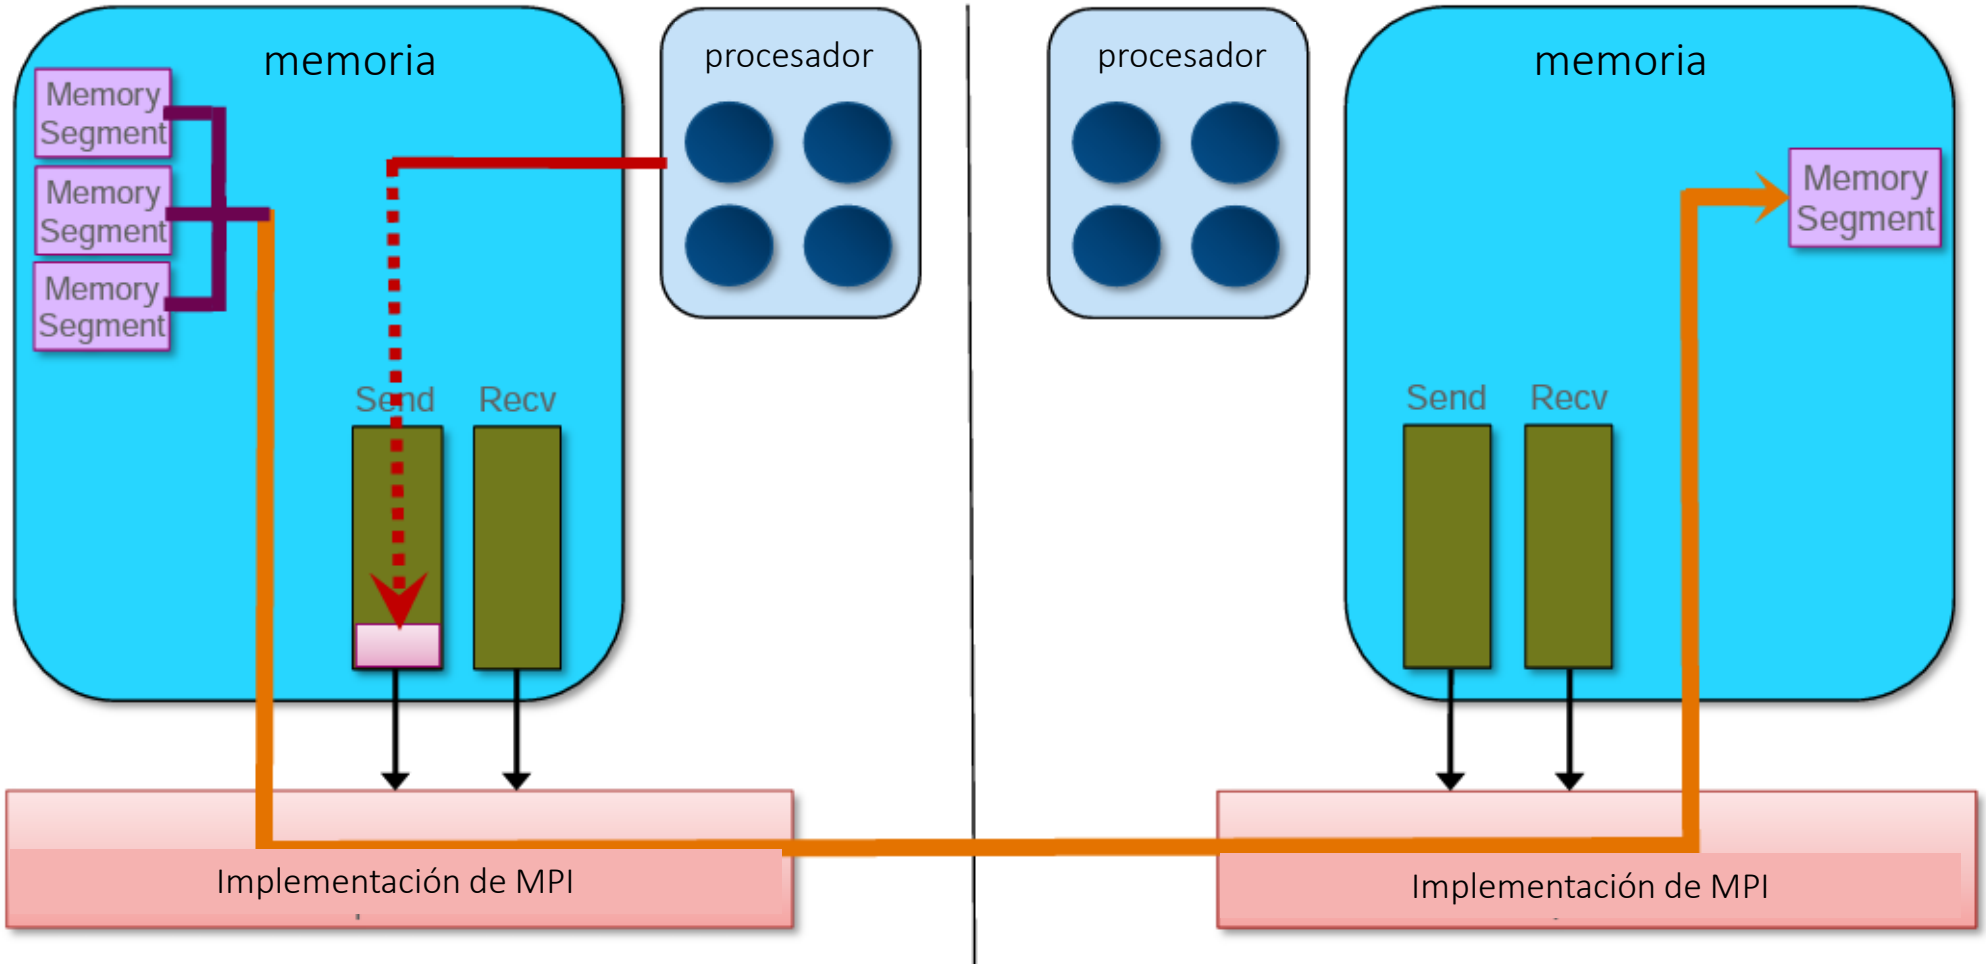

Comunicaciones de una y dos vías

- Desacopla al proceso emisor del proceso receptor

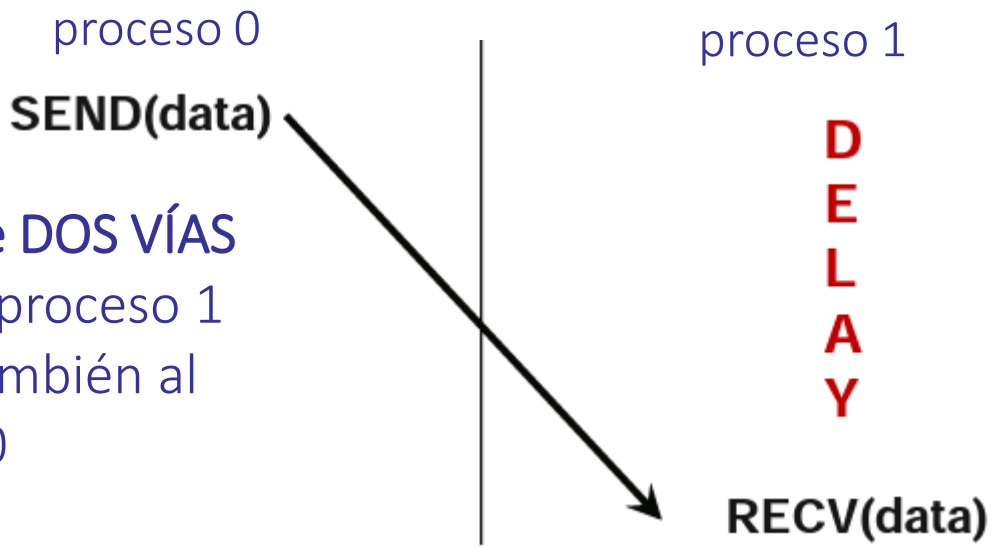

COMUNICACIÓN de DOS VÍAS

Una demora en el proceso 1 puede detener también al proceso 0

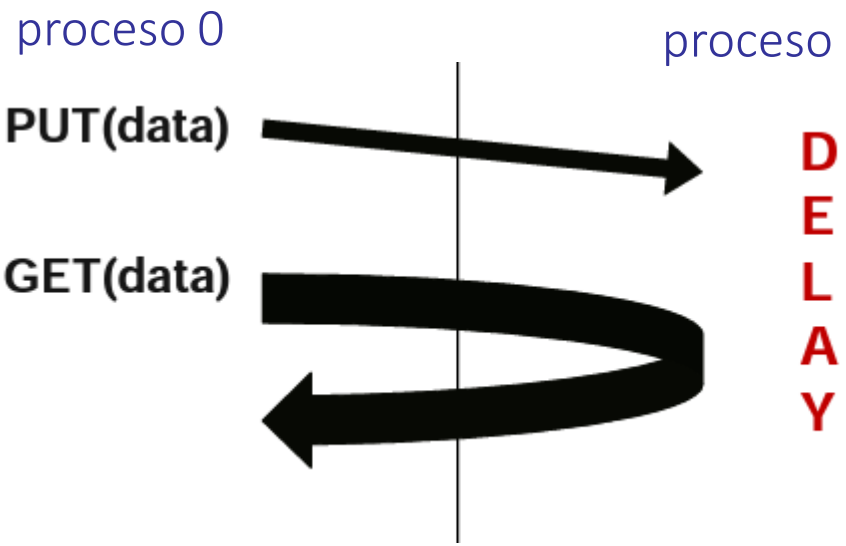

COMUNICACIÓN de UNA VÍA

Una demora en el proceso 1 no afecta al proceso 0

Comunicaciones de una vía/RMA

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Existe un modelo formal para implementar las comunicaciones de una vía en MPI-3: el acceso a memoria remota (RMA)
- Conceptos y acciones implementadas:
  - Creación
  - Lectura y escritura
  - Sincronización de datos
  - Modelos de memoria
- La memoria usada por un proceso solo es accesible localmente
- Luego de alocar la memoria, el proceso debe realizar una invocación explícita a una rutina MPI para declarar una variable o region de memoria como accesible remotamente.
- Luego de declarada la memoria remota, todos los procesos participantes pueden leer y escribir datos sin sincronizarse explícitamente

RMA en MPI

- Para MPI RMA es “Un grupo de procesos que colectivamente crean una ventana de memoria"
- Cuatro modelos:
  - MPI_WIN_ALLOCATE: crear un espacio de memoria (buffer) y hacerlo accesible remotamente.
  - MPI_WIN_CREATE: hacer accesible un espacio de memoria (buffer) ya creado
  - MPI_WIN_CREATE_DYNAMIC: el espacio de memoria (buffer) a compartir aún no está creado, pero lo será en el futuro. Permite agregar/remover dinámicamente buffers a/de una ventana.
  - MPI_WIN_ALLOCATE_SHARED: multiples procesos en el mismo nodo de cómputo comparten un espacio de memoria (buffer).

Creación de ventana

- MPI_Win_allocate crea una región de memoria remotamente accesible en una ventana RMA. Solo los datos expuestos en la ventana son accesibles mediante operaciones RMA.

```
MPI_Win_allocate(MPI_Aint size, int disp_unit, MPI_Info
  info, MPI_Comm comm, void *baseptr, MPI_Win * win)
```

  - size: tamaño de la ventana, en bytes
  - disp_unit: unidad para desplazamientos en la ventana, en bytes
  - info: información adicional
  - comm: comunicador asociado al grupo de procesos de la ventana
  - baseptr: dirección base de la ventana en memoria local
  - win: handler de la ventana definida (puntero)

MPI_Win_allocate: ejemplo

```
int main(intargc, char ** argv) {
int* a;
MPI_Win win;

MPI_Init(&argc, &argv);
/* creación colectiva de una ventana para acceso remoto */
MPI_Win_allocate(1000*sizeof(int), sizeof(int), MPI_INFO_NULL,
                    MPI_COMM_WORLD, &a, &win);
/* El vector ‘a’ es accesible a todos los procesos
      en MPI_COMM_WORLD */
MPI_Win_free(&win);
MPI_Finalize();
return 0;
}
```

Creación de ventana

- MPI_Win_create crea un objeto ventana para comunicaciones de una vía mediante operaciones RMA

```
MPI_Win_create(void *base, MPI_Aint size, int disp_unit,
  MPI_Info info, MPI_Comm comm, MPI_Win * win)
```

  - base: dirección inicial de la ventana
  - size: tamaño de la ventana, en bytes
  - disp_unit: unidad para desplazamientos en la ventana, en bytes
  - info: información adicional
  - comm: comunicador asociado al grupo de procesos de la ventana
  - win: handler de la ventana definida (puntero)

- La diferencia con MPI_Win_allocate es que MPI_Win_create recibe un buffer o variable de memoria ya alocada

MPI_Win_create: ejemplo

```
Int main(int argc, char **argv) {
int* a;
MPI_Win win;
MPI_Init(&argc, &argv);
/* crear memoria privada y utilizarla */
MPI_Alloc_mem(1000*sizeof(int), MPI_INFO_NULL, &a);
/* creación colectiva de una ventana para acceso remoto */
MPI_Win_create(a, 1000*sizeof(int), sizeof(int),
MPI_INFO_NULL,MPI_COMM_WORLD, &win);
/* El vector ‘a’ es accesible a todos los procesos
       en MPI_COMM_WORLD */
MPI_Win_free(&win);
MPI_Free_mem(a);
MPI_Finalize();
return 0;
}
```

Creación de ventana dinámica

- MPI_Win_create_dynamic crea una ventana para comunicaciones de una vía mediante operaciones RMA luego agregar para datos

```
MPI_Win_create_dynamic(MPI_Info info, MPI_Comm comm,
                       MPI_Win * win)
```

  - info: información adicional
  - comm: comunicador asociado al grupo de procesos de la ventana
  - win: handler de la ventana definida (puntero)
- Inicialmente la ventana está vacía.
- Los procesos pueden acoplarse/desacoplarse y acceder a la memoria expuesta en la ventana usando MPI_Win_attach y MPI_Win_detach
- El origen de la ventana es MPI_BOTTOM
- Todos los desplazamientos son relativos a MPI_BOTTOM
- Un proceso debe comunicar el desplazamiento luego del attach

MPI_Win_create_dynamic: ejemplo

```
Int main(int argc, char **argv) {
int* a; MPI_Win win;
MPI_Init(&argc, &argv);
MPI_Win_create_dynamic(MPI_INFO_NULL, MPI_COMM_WORLD, &win);
/* crear memoria privada y utilizarla */
a = (int*) malloc(1000 * sizeof(int)); a[0] = 1;  a[1] = 2;
/* Acoplarse a la ventana y exponer el vector a */
MPI_Win_attach(win, a, 1000*sizeof(int));
/* El vector ‘a’ es accesible a los procesos en MPI_COMM_WORLD */
/* Desacoplarse de la ventana, el vector a ya no es compartido*/
MPI_Win_detach(win, a);
free(a);
MPI_Win_free(&win);
MPI_Free_mem(a);
MPI_Finalize();
return 0; }
```

Memoria remota: movimiento de datos

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- MPI provee funciones para que un proceso local pueda leer, escribir y modificar atómicamente datos en ventanas de memoria remota
- MPI_Put: escribir (local → remota)
- MPI_Get: leer (remota → local)
- MPI_Accumulate: acumular (local → remota, atómica)
- MPI_Get_accumulate: leer y acumular (remota → remota, atómica)
- MPI_Compare_and_swap: comparar e intercambiar, remota → remota)
- MPI_Fetch_and_op: similar a MPI_Get_accumulate, remota → remota atómica - atómica)
- Las operaciones son no bloqueantes
- Las operaciones se completan (en origen y destino) invocando una operación de sincronización sobre la ventana

Memoria remota: movimiento de datos

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Las operaciones de movimiento de datos son no bloqueantes
- El buffer de la aplicación (local) no debe modificarse hasta que la operación se haya completado (mediante la invocación a la función de sincronización).
- No debe accederse concurrentemente a la misma dirección de memoria en una ventana (conflicto): si una ubicación se actualiza mediante MPI_Put o MPI_Accumulate, la ubicación no puede ser accedida por un MPI_Get o por otra operación de RMA mientras la operación de actualización no se haya completado.
- Una ventana no puede actualizarse mediante MPI_Put o MPI_Accumulate simultáneamente con una operación de modificación local, aunque las actualizaciones se realicen sobre ubicaciones diferentes de la ventana.
- El proceso invocante puede ser también destino: un proceso puede usar operaciones RMA para mover datos en su propia memoria.

Memoria remota: movimiento de datos

- MPI_Put permite escribir datos en una ventana

```
MPI_Put(void *origin_addr, int origin_count, MPI_Datatype
  origin_dtype, int target_rank, MPI_Aint target_disp, int
  target_count, MPI_Datatype target_dtype, MPI_Win win)
```

  - origin_addr: dirección inicial del buffer de origen
  - origin_count: número de entradas en el buffer de origen
  - origin_dtype: tipo de datos de las entradas en el buffer de origen
  - target_rank: rango del proceso destino
  - target_disp: desplazamiento desde el inicio de la venta del buffer destino
  - target _count: número de entradas en el buffer de destino
  - target _dtype: tipo de datos de las entradas en el buffer de destino
  - win: ventana para la comunicación de una vía
- Copia origin_count elementos de tipo origin_datatype, comenzando en origin_addr del proceso origen a la ventana win del proceso target_rank

Memoria remota: movimiento de datos

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- MPI_Put copia origin_count elementos de tipo origin_datatype, comenzando en origin_addr del proceso origen a la ventana win del proceso target_rank
- Los datos se escriben en el buffer de destino en la dirección, win_base + target_disp × disp_unit, siendo win_base la dirección base de la ventana y disp_unit el desplazamiento unitario, ambos especificados en la inicialización de la ventana, por el proceso destino
- La transferencia de datos es similar a un envío (MPI_Send) de origin_count elementos de tipo origin_datatype, ubicados a partir de origin_addr desde el proceso origen al proceso target_rank, que los recibe con MPI_Recv en target_addr (buffer de destino), sobre un comunicador que englobe a ambos procesos.
- Los datos a copiar deben poder contenerse (sin truncamiento) en el buffer de destino y éste debe poder contenerse en la ventana de destino.

Memoria remota: movimiento de datos

- MPI_Get permite leer datos de una ventana

```
MPI_Get(void *origin_addr, int origin_count, MPI_Datatype
  origin_dtype, int target_rank, MPI_Aint target_disp, int
  target_count, MPI_Datatype target_dtype, MPI_Win win)
```

  - origin_addr: dirección inicial del buffer de origen
  - origin_count: número de entradas en el buffer de origen
  - origin_dtype: tipo de datos de las entradas en el buffer de origen
  - target_rank: rango del proceso destino
  - target_disp: desplazamiento desde el inicio de la venta del buffer destino
  - target _count: número de entradas en el buffer de destino
  - target _dtype: tipo de datos de las entradas en el buffer de destino
  - win: ventana para la comunicación de una vía
- Lee datos desde el proceso destino (target_rank) al proceso origen
- Similar a MPI_Put, con direcciones invertidas

Memoria remota: movimiento de datos

- MPI_Accumulate aplica operaciones sobre datos de una ventana

```
MPI_Accumulate(void *origin_addr, int origin_count, MPI_Datatype
  origin_dtype, int target_rank, MPI_Aint target_disp, int
  target_count, MPI_Datatype target_dtype, MPI_Op op; MPI_Win win)
```

  - origin_addr: dirección inicial del buffer de origen
  - origin_count: número de entradas en el buffer de origen
  - origin_dtype: tipo de datos de las entradas en el buffer de origen
  - target_rank: rango del proceso destino
  - target_disp: desplazamiento desde el inicio de la venta del buffer destino
  - target _count: número de entradas en el buffer de destino
  - target _dtype: tipo de datos de las entradas en el buffer de destino
  - op: operación de reducción
  - win: ventana para la comunicación de una vía
- Reduce datos de origen y destino en el buffer de destino aplicando la operación indicada (op) como recombinador

Memoria remota: movimiento de datos

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- MPI_Accumulate reduce datos de origen y destino en el buffer de destino aplicando la operación indicada (op) como recombinador
- Operaciones predefinidas: MPI_SUM, MPI_PROD, MPI_OR, MPI_REPLACE, MPI_NO_OP
- No admite operaciones de finidas por el usuario
- Tripletas de descripción de datos diferentes para origen y destino
- Los tipos de datos de los operandos deben concordar con los de la operación op
- MPI_REPLACE implementa f(a,b) = b , con un MPI_Put atómico implícito

Memoria remota: movimiento de datos

- MPI_Get_Accumulate implementa una combinación de leer-modificar-escribir de manera atómica

```
MPI_Get_Accumulate(void *origin_addr, int origin_count,
  MPI_Datatype origin_dtype, void *result_addr, int
  result_count, MPI_Datatype result_dtype, int target_rank,
  MPI_Aint target_disp, int target_count, MPI_Datatype
  target_dtype, MPI_Op op; MPI_Win win)
```

  - origin_addr: dirección inicial del buffer de origen
  - origin_count: número de entradas en el buffer de origen
  - origin_dtype: tipo de datos de las entradas en el buffer de origen
  - result_addr: dirección inicial del buffer resultado
  - result _count: número de entradas en el buffer resultado
  - result _dtype: tipo de datos de las entradas en el buffer resultado
  - …

Memoria remota: movimiento de datos

```
MPI_Get_Accumulate(void *origin_addr, int origin_count,
  MPI_Datatype origin_dtype, void *result_addr, int
  result_count, MPI_Datatype result_dtype, int target_rank,
  MPI_Aint target_disp, int target_count, MPI_Datatype
  target_dtype, MPI_Op op; MPI_Win win)
```

- …
- target_rank: rango del proceso destino
- target_disp: desplazamiento desde el inicio de la venta del buffer destino
- target _count: número de entradas en el buffer de destino
- target _dtype: tipo de datos de las entradas en el buffer de destino
- op: operación de reducción
- win: ventana para la comunicación de una vía

- Retorna en el buffer resultado el contenido del buffer destino antes de aplicar la operación de acumulación

Memoria remota: movimiento de datos

- MPI_Fetch_and_op es una versión simple de MPI_Get_Accumulate, implementa una combinación de leer-modificar-escribir de manera atómica para un elemento de un tipo de dato predefinido

```
MPI_Fetch_and_op(const void *origin_addr, void *result_addr,
  MPI_Datatype datatype, int target_rank, MPI_Aint target_disp,
  MPI_Op op, MPI_Win win)
```

  - origin_addr: dirección inicial del buffer de origen
  - result_addr: dirección inicial del buffer resultado
  - datatype: tipo de datos del elemento a modificar
  - target_rank: rango del proceso destino
  - target_disp: desplazamiento desde el inicio de la venta del buffer destino
  - op: operación de reducción
  - win: ventana para la comunicación de una vía
- Todos los buffers comparten el tipo de dato predefinido. No se incluye un argumento count (que es 1)

Memoria remota: movimiento de datos

- MPI_Compare_and_swap compara elementos y los intercambia

```
MPI_Compare_and_swap(const void *origin_addr, const void
  *compare_addr, void *result_addr, MPI_Datatype datatype, int
  target_rank, MPI_Aint target_disp, MPI_Win win)
```

  - origin_addr: dirección inicial del buffer de origen
  - compare_addr: dirección inicial del buffer de comparación
  - datatype: tipo de datos del elemento a comparar
  - target_rank: rango del proceso destino
  - target_disp: desplazamiento desde el inicio de la venta del buffer destino
  - win: ventana para la comunicación de una vía
- Compara un elemento de tipo datatype en el buffer de comparación (compare_addr) con el elemento en target_disp en la ventana de destino (especificada por target_rank y win) y reemplaza el valor en el destino con el valor en el origen (origin_addr) si los elementos comparados son idénticos. El valor original en el destino se retorna en result_addr.

Acceso concurrente con RMA

- RMA no garantiza un correcto ordenamiento de las operaciones de lectura y escritura
- El resultado de puts concurrentes a la misma ubicación no está definido
- El resultado de un get concurrente con un put/accumulate no está definido
- Puede ser un resultado incorrecto o basura en ambos casos
- El resultado de operaciones de acumulación concurrentes sobre la misma ubicación se definen según el orden en que ocurrieron
  - MPI_Put atómico: MPI_ Accumulate con op = MPI_REPLACE
  - MPI_Get atómico: MPI_ Get_accumulate con op = MPI_NO_OP
- Las operaciones de acumulación ejecutadas por un proceso están ordenadas por defecto.
- Se puede especificar que no se siga el orden, e indicar un modelo de acceso a memoria: RAW (read-after-write), WAR, RAR, or WAW

Acceso concurrente con RMA

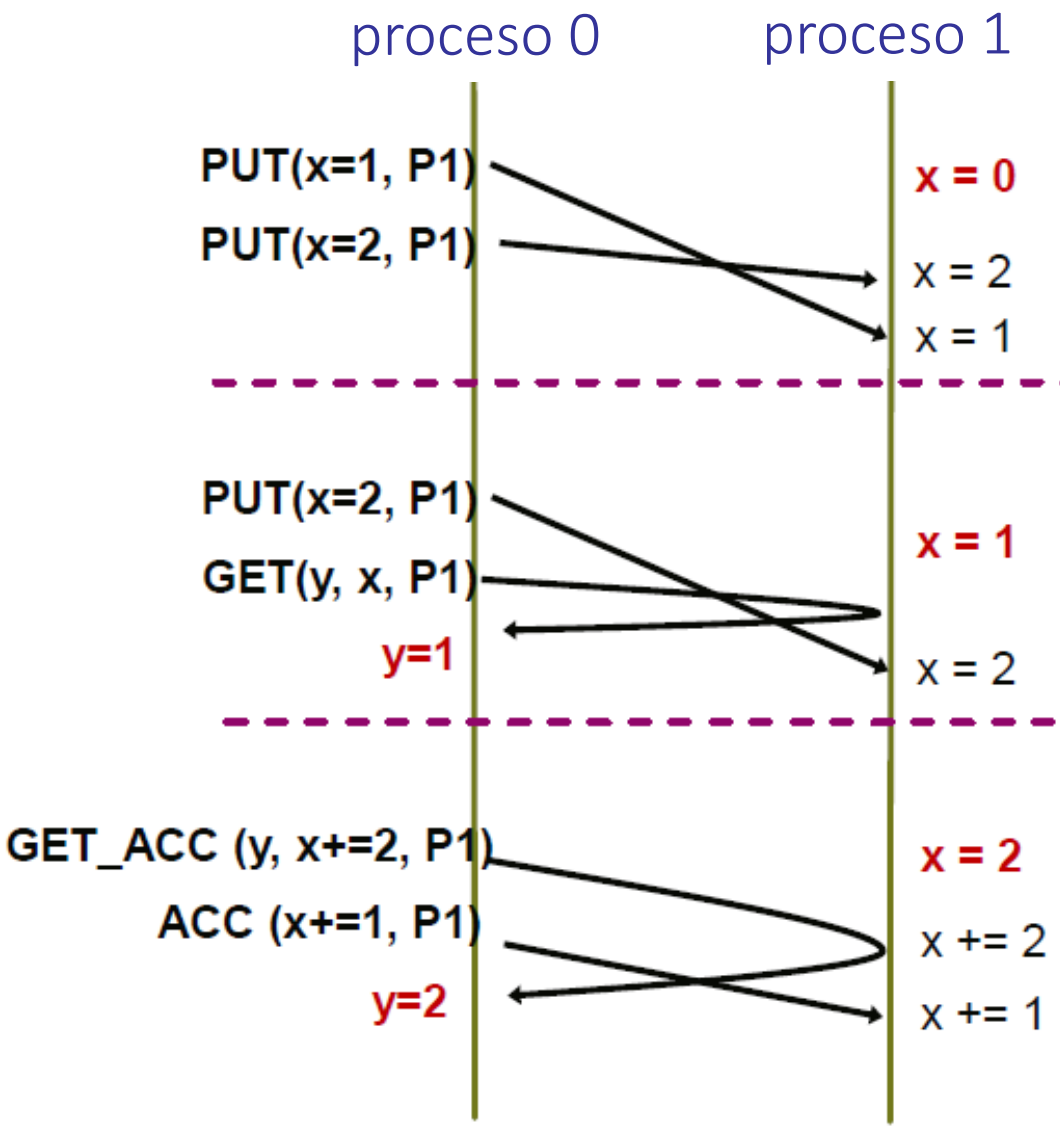

1. Puts concurrentes.
   Resultado no definido

2. Get concurrente con put/accumulate.
   Resultado no definido

3. Acumulaciones concurrentes.
   El orden está garantizado

RMA: modelo de acceso de datos

- Modelo de acceso de datos
  - ¿Cuándo se permite a un proceso leer/escribir memoria remota?
  - ¿Cuándo están disponibles los datos escritos por el proceso X para que los lea el proceso Y?
- El modelo de sincronización define la semántica.
- RMA en MPI provee tres modelos de sincronización
  - Fence (comunicación de destino activo)
  - Post-start-complete-wait (comunicación de destino activo generalizado)
  - Lock/Unlock (comunicación de destino pasivo)

RMA: modelo de acceso de datos

- Comunicación de destino activo: los datos se mueven de la memoria de un proceso a la memoria de otro, y ambos procesos están explícitamente involucrados en la comunicación.
- Patrón similar al pasaje de mensajes, excepto que los parámetros de transferencia de datos son indicados por el proceso origen y el proceso destino solo participa en la sincronización.
- Comunicación de destino pasivo : los datos se mueven de la memoria de un proceso a la memoria de otro, y solo el proceso origen está explícitamente involucrado en la transferencia.
- Dos procesos de origen pueden comunicarse accediendo a la misma ubicación en una ventana de destino de un proceso diferente a ambos (el proceso destino no participa explícitamente en la comunicación).
- Paradigma similar a memoria compartida: todos los procesos pueden acceder a los datos compartidos, independientemente de su ubicación.

RMA: modelo de acceso de datos

- El acceso a los datos ocurre en “épocas”
- Épocas de acceso: contienen un conjunto de operaciones realizadas por un proceso origen
- Épocas de exposición: permite que los procesos remotos actualicen la ventana de un proceso destino
- Las épocas definen la semántica de ordenación y finalización.
- Los modelos de sincronización proporcionan mecanismos para establecer épocas, por ejemplo, épocas de inicio, finalización y sincronización.

RMA: sincronización

- MPI_Win_fence inicia y finaliza una época de exposición de datos en todos los procesos de una ventana.

```
MPI_Win_fence(int assert, MPI_Win win)
```

  - assert: condición sobre el contexto de la invocación, assert = 0 para un caso general
  - win: ventana para la comunicación de una vía
- Modelo de sincronización colectiva
  - Todos los procesos en el grupo de win deben ejecutar MPI_Win_fence para iniciar una época
  - Todos los procesos pueden realizar operaciones de get/put para leer y escribir datos en la ventana
  - Todos los procesos en el grupo de win deben ejecutar MPI_Win_fence para finalizar la época
  - Todas las operaciones se completan con la invocación de finalización

RMA: sincronización

- MPI_Win_fence provee soporte para un modelo de sincronización simple, (loosely-synchronous model) comúnmente utilizado en cómputos paralelos en los que una fase de cómputo global se alterna con fases de comunicaciones globales.

- El mecanismo es útil para algoritmos poco sincronizados, donde la topología del grafo de comunicaciones cambia con mucha frecuencia o en los que cada proceso se comunica con muchos otros.
- Las invocaciones a MPI_Win_fence deben preceder y seguir a todas las operaciones de get, put y accumulate que se sincronizan con ese fence

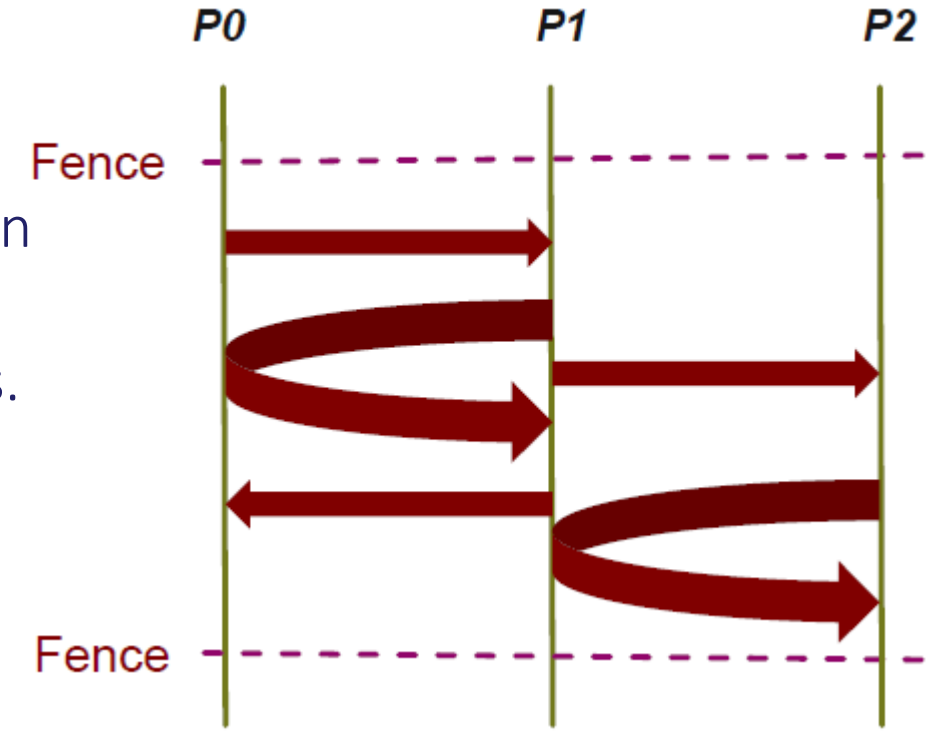

RMA: sincronización general activa

- MPI_Win_start/post inicia una época de accesos RMA para una ventana.

  `MPI_Win_start(MPI_Group group, int assert, MPI_Win win)`

  `MPI_Win_post(MPI_Group group, int assert, MPI_Win win)`

  - **group**: grupo de procesos destino
  - **assert**: condición sobre el contexto, assert = 0 para un caso general
  - **win**: ventana para la comunicación de una vía
- Invocaciones a funciones RMA sobre win durante la época solo pueden acceder a ventanas en procesos de group.
- Cada proceso destino en group debe invocar a MPI_Win_post.
- Accesos RMA a cada ventana de destino serán diferidos, si es necesario, hasta que el proceso destino invoque el MPI_Win_post correspondiente.
- MPI_Win_complete/wait finaliza la época de accesos para la ventana

  `MPI_Win_complete(MPI_Win win)` en procesos origen

  `MPI_Win_wait(MPI_Win win)` en procesos destino

RMA: sincronización pasiva

- Comunicaciones asíncronas de una vía, sin participación del proceso destino (similar a un modelo de memoria compartida)
- MPI_Win_lock inicia una época de accesos RMA para una ventana en modo pasivo.

```
MPI_Win_lock(int locktype, int rank, int assert, MPI_Win win)
```

  - locktype: tipo de acceso/lock
  - rank: rango del proceso destino (el que tiene la ventana)
  - assert: condición sobre el contexto, assert = 0 para un caso general
  - win: ventana para la comunicación de una vía
- La invocación solo la realiza el proceso origen (no el proceso destino)
- Se pueden iniciar multiples épocas de acceso pasivo para diferentes procesos
- No se pueden definer épocas de acceso concurrentes para el mismo proceso (afecta a los threads)

RMA: sincronización pasiva

```
MPI_Win_lock(int locktype, int rank, int assert, MPI_Win win)
```

- Tipos de acceso (locktype):
  - SHARED: otros procesos que indiquen el modo shared pueden acceder concurrentemente
  - EXCLUSIVE: ningún otro proceso puede acceder concurrentemente
- MPI_Win_unlock finaliza la época de accesos RMA para una ventana en modo pasivo

```
MPI_Win_unlock(int rank, MPI_Win win)
```

  - rank: rango del proceso destino
  - win: ventana para la comunicación de una vía
- MPI_Win_flush/flush_local complete las operaciones RMA al destino

```
MPI_Win_flush/flush_local(int rank, MPI_Win win)
```

  - rank: rango del proceso destino
  - win: ventana para la comunicación de una vía

RMA: sincronización pasiva

- Comunicaciones asíncronas de una vía, sin participación del proceso destino (similar a un modelo de memoria compartida)
- MPI_Win_start/post inicia una época de accesos RMA para una ventana.

  `MPI_Win_start/post(MPI_Group group, int assert, MPI_Win win))`
  - group: grupo de procesos destino
  - assert: condición sobre el contexto, assert = 0 para un caso general
  - win: ventana para la comunicación de una vía
- Invocaciones a funciones RMA sobre win durante la época solo pueden acceder a ventanas en procesos de group.
- Cada proceso destino en group debe invocar a MPI_Win_start/post.
- Accesos RMA a cada ventana de destino serán diferidos, si es necesario, hasta que el proceso destino invoque el MPI_Win_post correspondiente.

RMA: sincronización pasiva

- Comunicaciones asíncronas de una vía, sin participación del proceso destino (similar a un modelo de memoria compartida)
- MPI_Win_complete/wait finaliza la época de accesos para la ventana

  `MPI_Win_complete(MPI_Win win)` en procesos origen

  `MPI_Win_wait(MPI_Win win)` en procesos destino

Acceso a memoria remota: ejemplo

```
MPI_Win win;
if (rank == 0) {
   MPI_Win_create(NULL,0,1, MPI_INFO_NULL,MPI_COMM_WORLD,&win);
   MPI_Win_lock(MPI_LOCK_SHARED,1,0,win);    // lock del proceso 1
   MPI_Put(buf,1,MPI_INT,1,0,1,MPI_INT,win); // copia datos (de manera
                                                protegida)
   MPI_Win_unlock(1,win);
   MPI_Win_free(&win);
} else {
   MPI_Win_create(buf,2*sizeof(int),sizeof(int),MPI_INFO_NULL,
                  MPI_COMM_WORLD,&win);
}
```

Operaciones colectivas

- Operaciones colectivas no bloqueantes: permiten solapar cómputo y comunicaciones e implementar diversos mecanismos de paralelismo (por ejemplo, software pipelines)

```
MPI_Ibcast(buf, count, type, root, comm, &request);
... // cómputo
MPI_Wait(&request, &status);
```

- Operaciones colectivas para topologías de procesos

```
// crer una topología 3D
MPI_Cart_create(comm, 3, {2,2,2}, {1,1,1}, 1, &newcomm);
// leer datos siguiendo el orden de procesos en newcomm
while(!converged) {
        // comunicaciones entre vecinos
        MPI_Ineighbor_alltoall(..., &newcomm, &req);
        ... // computar internamente en la grilla
        MPI_Wait(&req, MPI_STATUS_IGNORE);
        ... // realizar cómputos externos
}
```

Procesos dinámicos

- A partir de MPI-2 se proporciona la creación de nuevos procesos a través de la operación colectiva: `MPI_Comm_spawn`
- MPI-2 usa los intercomunicadores (a diferencia de intracomunicadores)
- Los puntos importantes de esta operación son:
  - Es una operación colectiva (invocada por los padres) y también es colectiva en los procesos nuevos MPI_Init
  - Retorna un intercomunicador en el cual los procesos padres forman un grupo local y los procesos remotos son los procesos creados
  - Los procesos nuevos tienen su propio MPI_COMM_WORLD
  - La función MPI_Comm_parent, invocada por los procesos nuevos, retorna un intercomunicador conteniendo a los hijos como grupo local y a los padres como grupo remoto

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

Ejercicios

Ejercicio 0: hello world master-slave

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Código correspondiente a la slide 76
- Utilizando send y receive, en sus diferentes versiones
- Un proceso (maestro) recibe mensajes de otros procesos (esclavos) y es el encargado de imprimir los mensajes de forma centralizada
- Envío y recepción bloqueante y no bloqueante, impresión sincrónica y asincrónica de mensajes recibidos.

Ejercicio 1: envío y procesamiento

- Código correspondiente a la slide 74

1. Modificar el programa que realiza el envío de un vector para que el proceso P1 devuelva a P0 la suma de los elementos del vector recibido.
   - P0 deberá imprimir el resultado final
2. Modificar el programa para que un proceso (maestro) envíe a k procesos esclavos

Ejercicio 2: operaciones colectivas

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Utilizar operaciones colectivas para calcular cuántos números primos hay entre 1 y un determinado número tope N
- Analizar el desempeño y la escalabilidad para diferente valores de N y diferente número de procesos en ejecución

Ejercicio 3: sistema de I/O master-slave

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Sistema de I/O que permita
  1. ordenar entradas y salidas de programas, incluyendo:
     - Salida ordenada (proceso 2 luego de proceso 1)
     - Eliminar duplicados (imprimir un solo "Hello world" en lugar de uno por proceso)
  2. indicar entradas a todos los procesos desde una única terminal
- Idea: separar procesos en MPI_COMM_WORLD en clases (masters, encargados de I/O, y slaves, que realizan cálculos [por ejemplo, Jacobi] y hacen su I/O contactando al master), cada clase con su comunicador
- El master debe aceptar mensajes de los slave (tipo MPI_CHAR, largo máximo 256) e imprimirlos en orden. Al menos dos mensajes deben ser enviados por los esclavos (“hello” y “goodbye”, con su rank correspondiente)
- Sugerencias: usar las rutinas MPI_Comm_split, MPI_Send y MPI_Recv

Ejercicio 4: broadcasting y procesamiento

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Implementar una aplicación que utilice un proceso maestro que lee desde un archivo de texto y comunica a todos los procesos en ejecución el número de datos leídos y los datos en sí
- El archivo de texto de entrada cuenta con un un número entero entre 0 y 9 por línea
- Los procesos se encargan de contar cuantas ocurrencias de su rango hay en el archivo de entrada, y reportan los datos al proceso con rango 0
- El proceso de rango 0 imprime las estadísticas al final

Ejercicio 5: el pequeño hacker

UNIVERSIDAD DE LA REPÚBLICA URUGUAY

- Se desea descifrar un texto secreto. Se conoce el valor del texto cifrado, el largo máximo del texto secreto, y el método que se utilizó para cifrarlo. Un ejemplo de código C idéntico al utilizado en el cifrado de la clave secreta.

```
#include <unistd.h>
#include <stdio.h>
#include <stdlib.h>
#include <crypt.h>
int main(void){
  char *p = crypt("texto secreto", "13");
  printf("%s\n", p);
}
```

- Sabiendo que el texto secreto no tiene más de 6 caracteres alfabéticos en minúscula [a-z], el salt del método crypt() utilizado durante el cifrado fue 13, y que el cifrado del texto secreto es 13rfeUmpQl2s6, implemente un algoritmo paralelo que utilice la fuerza bruta para descubrir el texto utilizando MPI.
- Para compilar el ejemplo es necesario agregar -lcrypt como argumento del comando gcc.

MPI: bibliografía

- Peter S. Pacheco. 1996. Parallel Programming with MPI. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.
- Marc Snir, Steve Otto, Steven Huss-Lederman, David Walker, and Jack Dongarra. 1998. Mpi-The Complete Reference, Volume 1: The MPI Core (2nd. (Revised) ed.). MIT Press, Cambridge, MA, USA.
- William Gropp, Ewing Lusk, and Anthony Skjellum. 1999. Using MPI (2nd Ed.): Portable Parallel Programming with the Message-Passing Interface. MIT Press, Cambridge, MA, USA.