Curso de Computación Científica en Clusters
Programación de Plataformas Paralelas II: MPI

Javier Cuenca

Universidad de Murcia

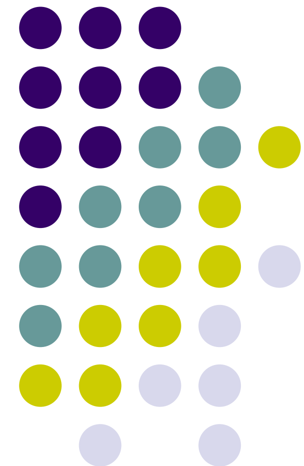

Introducción

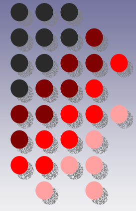

- Previamente PVM: Parallel Virtual Machine
- MPI: Message Passing Interface
- Una especificación para paso de mensajes
- La primera librería de paso de mensajes estándar y portable
- Por consenso MPI Forum. Participantes de unas 40 organizaciones
- Acabado y publicado en mayo 1994. Actualizado en junio 1995
- MPI2, HeteroMPI, FT-MPI

Introducción.
¿Qué ofrece?

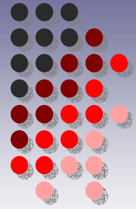

- Estandarización
- Portabilidad: multiprocesadores, multicomputadores, redes, heterogéneos, ...
- Buenas prestaciones, ..., si están disponibles para el sistema
- Amplia funcionalidad
- Implementaciones libres (mpich, lam, ...)

Introducción.
Procesos

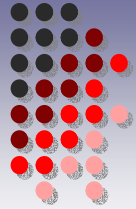

- Programa MPI: conjunto de procesos autónomos
- Cada proceso puede ejecutar codigo diferente
- Procesos comunican vía primitivas MPI
- Proceso: secuencial o multithreads
- MPI no proveé mecanismos para situar procesos en procesadores. Eso es misión de cada implementación en cada plataforma
- MPI 2.0:
  - Es posible la creación/borrado de procesos dinámicamente durante ejecución
  - Es posible el acceso a memoria remota
  - Es posible la entrada/salida paralela

Introducción.
Ejemplo: hello.c

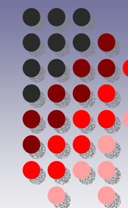

```
#include <stdio.h>
#include <string.h>
#include "mpi.h"
main(int argc, char*argv[]) {

int name, p, source, dest, tag = 0;
char message[100];
MPI_Status status;

MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&name)
;
MPI_Comm_size(MPI_COMM_WORLD,&p);
```

Introducción.
Ejemplo: hello.c

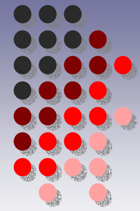

```
if (name != 0)
{
    printf("Processor %d of %d\n",name, p);
    sprintf(message,"greetings from process %d!", name);
    dest = 0;
    MPI_Send(message, strlen(message)+1, MPI_CHAR, dest, tag,
MPI_COMM_WORLD);
}
else
{
    printf("processor 0, p = %d \n",p);
    for(source=1; source < p; source++)
    {
      MPI_Recv(message,100, MPI_CHAR, source, tag,  MPI_COMM_WORLD,
&status);
      printf("%s\n",message);
    }
  }
  MPI_Finalize();
}
```

Introducción.
Ejemplo de uso

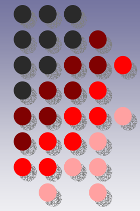

- Compilación
  - `mpicc -o ejemplo ejemplo.c -lm -lmpi`
- Ejecución
  - `mpirun –np 4 ejemplo`

Introducción. Ejemplo de uso

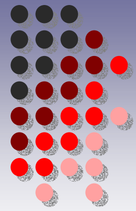

- Fichero cabecera:
  `#include <mpi.h>`

- Formato de las funciones:
  `error=MPI_nombre(parámetros ...)`

- Inicialización:
  `int MPI_Init ( int *argc , char **argv )`

- Comunicador: Conjunto de procesos en que se hacen comunicaciones
  `MPI_COMM_WORD` , el mundo de los procesos MPI

Introducción.
Ejemplo de uso

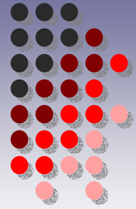

- Identificación de procesos:

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

- Procesos en el comunicador:

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

- Finalización:

```
int  MPI_Finalize ( )
```

Introducción.
Ejemplo de uso

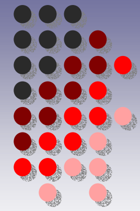

- MENSAJE: Formado por un cierto número de elementos de un tipo MPI
- Tipos MPI Básicos:

MPI_CHAR	signed char
MPI_SHORT	signed short int
MPI_INT	signed int
MPI_LONG	signed long int
MPI_UNSIGNED_CHAR	unsigned char
MPI_UNSIGNED_SHOT	unsigned short int
MPI_UNSIGNED	unsigned int
MPI_UNSIGNED_LONG	unsigned long int
MPI_FLOAT	float
MPI_DOUBLE	double
MPI_LONG_DOUBLE	long double
MPI_BYTE	
MPI_PACKED	

- Tipos MPI Derivados: los construye el programador

Introducción.
Ejemplo de uso

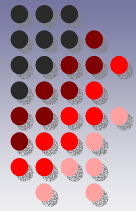

- Envío:

```
int MPI_Send ( void  *buffer , int contador , MPI_Datatype
   tipo , int destino , int tag , MPI_Comm  comunicador )
```

- Recepción:

```
int MPI_Recv ( void  *buffer , int contador , MPI_Datatype
   tipo , int origen , int tag , MPI_Comm  comunicador ,
   MPI_Status  *estado)
```

```
MPI_ANY_TAG
MPI_ANY_SOURCE
```

Tipos de comunicación

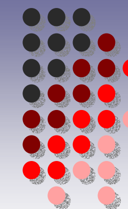

- Envío:
  - Envío síncrono: `MPI_Ssend`
    Acaba cuando la recepción empieza
  - Envío con buffer: `MPI_Bsend`
    Acaba siempre, independiente del receptor
  - Envío estándar: `MPI_Send`
    Síncrono o con buffer
  - Envío "ready": `MPI_Rsend`
    Acaba independiente de que acabe la recepción
- Recepción: `MPI_Recv`
  Acaba cuando se ha recibido un mensaje.

Comunicación asíncrona (nonblocking)

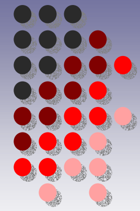

- `MPI_Isend(buf, count, datatype, dest, tag, comm, request)`
- `MPI_Irecv(buf, count, datatype, source, tag, comm, request)`

  Parámetro `request` para saber si la operación ha acabado

- `MPI_Wait( )`
  vuelve si la operación se ha completado. Espera hasta que se completa
- `MPI_Test( )`
  devuelve un flag diciendo si la operación se ha completado

Comunicación asíncrona (nonblocking). Ejemplo: hello_nonblocking.c (1/2)

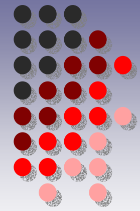

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&name);
MPI_Comm_size(MPI_COMM_WORLD,&p);

 p_requests = (MPI_Request *) malloc ( p * sizeof(MPI_Request) );

if (name != 0)
{
   sprintf(message,"greetings from process %d!",name);
   dest = 0;
   MPI_Isend(message, strlen(message)+1, MPI_CHAR, dest, tag,
   MPI_COMM_WORLD, &request);
   printf("Procesador %d ya ha hecho el ISEND al procesador
   0\n",name);


   /* …. Código por aquí enmedio …*/

   MPI_Wait(&request,&status);
   printf("Procesador %d ya ha pasado el WAIT tras
   envio\n",name);
}
```

Comunicación asíncrona (nonblocking). Ejemplo: hello_nonblocking.c (2/2)

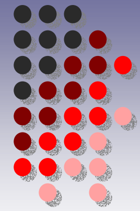

```
else
{
  for(source=1; source < p; source++)
  {
    MPI_Irecv(messages[source],100,MPI_CHAR,MPI_ANY_SOURCE,tag,
   MPI_COMM_WORLD, &p_requests[source]);
    printf("Proc.   0   ya   ha   hecho   IRECV   para   recibir   de
   source=%d\n\n",source);
  }

   /* …. Código por aquí enmedio …*/


  for(source=1; source < p; source++)
  {
    MPI_Wait(&p_requests[source],&status);
    printf("Tras el Wait del Receive: %s\n",messages[source]);
  }

}
free(p_requests);
MPI_Finalize();
}
```

Comunicaciones colectivas

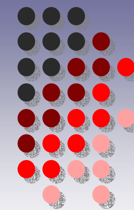

- `MPI_Barrier( )`
  bloquea los procesos hasta que la llaman todos
- `MPI_Bcast( )`
  broadcast del proceso raíz a todos los demás
- `MPI_Gather( )`
  recibe valores de un grupo de procesos
- `MPI_Scatter( )`
  distribuye un buffer en partes a un grupo de procesos
- `MPI_Alltoall( )`
  envía datos de todos los procesos a todos
- `MPI_Reduce( )`
  combina valores de todos los procesos
- `MPI_Reduce_scatter( )`
  combina valores de todos los procesos y distribuye
- `MPI_Scan( )`
  reducción prefija (0,...,i-1 a i)

Comunicaciones colectivas. broadcast.c

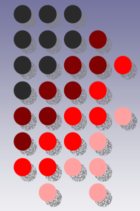

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_Comm_size(MPI_COMM_WORLD,&p);

if(my_rank==0)
{
   printf("Introduce el dato:  a (float): ");scanf("%f",&a);
    pintf("Introduce     el     dato:           b     (float):     ");
       scanf("%f",&b);
   printf("Introduce     el     dato:           n     (entero):     ");
       scanf("%d",&n);
}

MPI_Bcast(&a,1,MPI_FLOAT,root,MPI_COMM_WORLD);
MPI_Bcast(&b,1,MPI_FLOAT,root,MPI_COMM_WORLD);
MPI_Bcast(&n,1,MPI_INT,root,MPI_COMM_WORLD);

if(my_rank !=0)
{
   printf("En procesador %d, los datos recibidos son a:%f   b:%f
   n:%d \n",my_rank,a,b,n);
}
MPI_Finalize();
```

Comunicaciones colectivas. broadcast.c

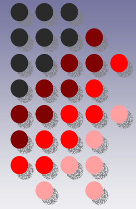

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_Comm_size(MPI_COMM_WORLD,&p);
```

```
MPI_Bcast(&a,1,MPI_FLOAT,root,MPI_COMM_WORLD);
```

&a:	dirección de comienzo de buffer
1:	número de elementos en buffer
MPI_FLOAT:	tipo de datos del buffer
root:	identif. del root de la operación broadcast
MPI_COMM_WORLD:	comunicador

```
}
MPI_Finalize();
```

Comunicaciones colectivas. broadcast.c

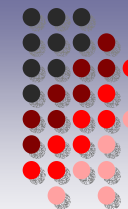

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_Comm_size(MPI_COMM_WORLD,&p);

if(my_rank==0)
{
   printf("Introduce el dato:  a (float): ");scanf("%f",&a);
    p
   pr
}

MPI_B
MPI_B
MPI_B

if(my
{
   pr
   n:%d \n",my_rank,a,b,n);
}
MPI_Finalize();
```

```
 make broadcast
mpicc -O4  broadcast.c -o broadcast -lmpi -llapack -lblas -lm
$ mpirun -np 4 broadcast
Introduce el dato:  a (float): 4.2
Introduce el dato:  b (float): 5.3
Introduce el dato:  n (entero): 6
En procesador 2, los datos recibidos son a:4.200000   b:5.300000   n:6
En procesador 1, los datos recibidos son a:4.200000   b:5.300000   n:6
En procesador 3, los datos recibidos son a:4.200000   b:5.300000   n:6
```

Comunicaciones colectivas. gather.c

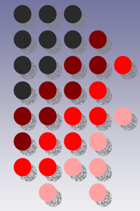

```
inicializa(my_rank,mis_datos,TAMA);
 if(my_rank==0)
        {
                datos=(int*)malloc(sizeof(int)*TAMA*p);
        }

  MPI_Gather(mis_datos,TAMA,MPI_INT,datos,TAMA,MPI_INT,root,MPI_C
  OMM_WORLD);
 if(my_rank==0)
        {
                printf("\n TODOS LOS DATOS RECIBIDOS EN PROCESO
  ROOT SON:\n");
                escribe(datos,TAMA*p);
                free(datos);
        }
```

Comunicaciones colectivas.
gather.c

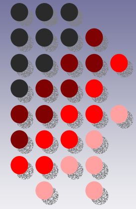

```
inicializa(my_rank,mis_datos,TAMA);
 if(my_rank==0)
```

```
MPI_Gather(mis_datos,TAMA,MPI_INT,datos,TAMA,MPI_INT,root,MPI_COMM_WORLD);
```

```
Mis_datos:        dirección buffer de envío (en cada nodo emisor)
TAMA:             número de elementos a enviar desde cada proceso
MPI_INT:          tipo de datos de los elementos del buffer de envio
datos:            dirección buffer de recepción (en nodo receptor)
TAMA:             número de elementos de cada recepción individual
MPI_INT:          tipo de datos del buffer de recepción
root:             identificador del proceso que recibe los datos
MPI_COMM_WORLD:   comunicador
```

Com

gath

i

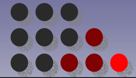

```
$ mpirun -np 4 gather

 Datos iniciales en el proceso 1:

 10000    10001    10002    10003    10004    10005    10006    10007
10008    10009

 Datos iniciales en el proceso 2:

20000    20001    20002    20003    20004    20005    20006    20007    20008
20009

 Datos iniciales en el proceso 3:

30000    30001    30002    30003    30004    30005    30006    30007    30008
30009

 Datos iniciales en el proceso 0:

  0    1    2    3    4    5    6    7    8    9

 TODOS LOS DATOS RECIBIDOS EN PROCESO ROOT SON:

0    1    2    3    4    5    6    7    8    9    10000    10001    10002
10003    10004    10005    10006    10007    10008    10009    20000    20001
20002    20003    20004    20005    20006    20007    20008    20009    30000
30001    30002    30003    30004    30005    30006    30007    30008    30009
```

Comunicaciones colectivas. scatter.c

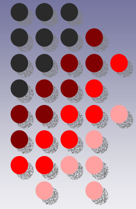

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_Comm_size(MPI_COMM_WORLD,&p);

if(my_rank==0)
{
   datos=(int*)malloc(sizeof(int)*TAMA*p);
    inicializa(my_rank,datos,TAMA*p);
}

MPI_Scatter(datos,TAMA,MPI_INT,mis_datos,TAMA,MPI_INT,root,MPI_CO
   MM_WORLD)

printf("Datos recibidos por proceso %d son:\n", my_rank);
escribe(mis_datos,TAMA);


if(my_rank==0)
{
   free(datos);
}

MPI_Finalize();
```

Comunicaciones colectivas. scatter.c

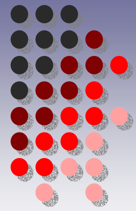

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_Comm_size(MPI_COMM_WORLD,&p);
```

MPI_Scatter(datos,TAMA,MPI_INT,mis_datos,TAMA,MPI_INT,root,MPI_COMM_WORLD)

```
datos:          dirección buffer de envío
TAMA:           número de elementos a enviar a cada proceso
MPI_INT:        tipo de datos de los elementos del buffer de envio
mis_datos:      dirección buffer de recepción
TAMA:           número de elementos en buffer de recepción
MPI_INT:        tipo de datos del buffer de recepción
root:           identificador del proceso que envia datos
MPI_COMM_WORLD: comunicador
```

```
MPI_Finalize();
```

Comunicaciones colectivas. scatter.c

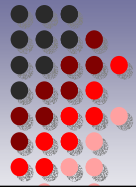

```
$ mpirun -np 4 scatter



 Datos iniciales en proceso 0 son:

  0     1     2     3     4     5     6     7     8     9     10     11     12     13
14     15     16     17     18     19     20     21     22     23     24     25     26
27     28     29     30     31     32     33     34     35     36     37     38     39

Datos recibidos por proceso 1 son:

10     11     12     13     14     15     16     17     18     19

Datos recibidos por proceso 0 son:

  0     1     2     3     4     5     6     7     8     9

Datos recibidos por proceso 2 son:

 20     21     22     23     24     25     26     27     28     29

Datos recibidos por proceso 3 son:

30     31     32     33     34     35     36     37     38     39
```

Comunicaciones colectivas.
reduce.c

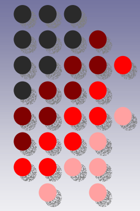

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_Comm_size(MPI_COMM_WORLD,&p);

   inicializa(my_rank,mis_datos,TAMA);

if(my_rank==0)
{
   datos=(int*)malloc(sizeof(int)*TAMA);
}


MPI_Reduce(mis_datos,datos,TAMA,MPI_INT,MPI_SUM,root,MPI_COMM_WORLD);

if(my_rank==0)
{
   printf("\n LOS DATOS, TRAS REDUCCION,  EN PROCESO ROOT SON:\n");
    escribe(datos,TAMA);
    free(datos);
}

MPI_Finalize();
```

Comunicaciones colectivas. reduce.c

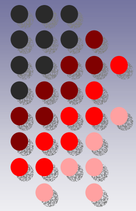

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_Comm_size(MPI_COMM_WORLD,&p);
```

```
MPI_Reduce(mis_datos,datos,TAMA,MPI_INT,MPI_SUM,root,MPI_COMM_WORLD);

mis_datos:      dirección buffer de envío

datos:          dirección buffer de recepción

TAMA:           número de elementos en buffer de envío

MPI_INT:        tipo de elementos de buffer de envío

MPI_SUM:        operación a realizar durante la reducción

root:           identificador del proceso root

MPI_COMM_WORLD:comunicador
```

```
MPI_Finalize();
```

Comunicaciones colectivas. reduce.c

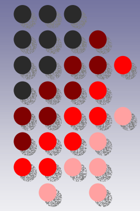

```
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);
MPI_C

    in

if(my
{
    da
}


MPI_R

if(my
{
    pr
     e
     f
}

MPI_F
```

```
$ mpirun -np 3 reduce


 En proceso 2 los datos son:
  20000    20001    20002    20003    20004    20005    20006    20007
20008    20009


 En proceso 0 los datos son:
  0    1    2    3    4    5    6    7    8    9


 En proceso 1 los datos son:
  10000    10001    10002    10003    10004    10005    10006    10007
10008    10009


 LOS DATOS, TRAS REDUCCION,  EN PROCESO ROOT SON:
  30000    30003    30006    30009    30012    30015    30018    30021
30024    30027
```

Comunicaciones colectivas. Operaciones de reducción

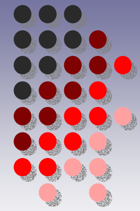

MPI Operator	Operation
MPI_MAX	maximum
MPI_MIN	minimum
MPI_SUM	sum
MPI_PROD	product
MPI_LAND	logical and
MPI_BAND	bitwise and
MPI_LOR	logical or
MPI_BOR	bitwise or
MPI_LXOR	logical exclusive or
MPI_BXOR	bitwise exclusive or
MPI_MAXLOC	max value and location
MPI_MINLOC	min value and location

Agrupación de datos

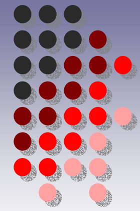

- Con contador en rutinas de envío y recepción: agrupar los datos a enviar
  - Con tipos derivados
  - Con empaquetamiento

Agrupación de datos. Tipos derivados

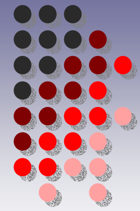

- Se crean en tiempo de ejecución
- Se especifica la disposición de los datos en el tipo:

```
Int MPI_Type_Struct
     (
   int                          count,
   int                          *array_of_block_lengths,
   MPI_Aint                     *array_of_displacements,
   MPI_Datatype                 *array_of_types,
   MPI_Datatype                 *newtype
   )
```

- Se pueden construir tipos de manera recursiva
- La creación de tipos requiere trabajo adicional

Agrupación de datos.
Tipos derivados: derivados.c (1/2)

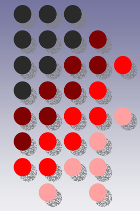

```
typedef struct
{
        float   a;
        float   b;
        int     n;
} INDATA_TYPE;
INDATA_TYPE     indata;
MPI_Datatype    message_type;

if(my_rank==0)
{
   printf("Introduce el dato:a (float): ");scanf("%f",&(indata.a));
   printf("Introduce el dato:b (float): ");scanf("%f",&(indata.b));
   printf("Introduce el dato:n(entero): ");scanf("%d",&(indata.n));
}

Build_derived_type(&indata,&message_type);

MPI_Bcast(&indata,count,message_type,root,MPI_COMM_WORLD);

if(my_rank !=0)
   printf("En procesador %d, los datos recibidos son a:%f    b:%f
   n:%d \n",my_rank,indata.a,indata.b,indata.n)
```

Agrupación de datos.
Tipos derivados: derivados.c (2/2)

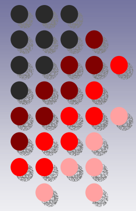

```
void       Build_derived_type(INDATA_TYPE      *indata,      MPI_Datatype
   *message_type_ptr)
{
 int               block_lenghts[3];
 MPI_Aint          dis[3];
 MPI_Aint          addresses[4];
 MPI_Datatype      typelist[3];

 typelist[0]=MPI_FLOAT;
 typelist[1]=MPI_FLOAT;
 typelist[2]=MPI_INT;

 block_lenghts[0]=1;
 block_lenghts[1]=1;
 block_lenghts[2]=1;

 MPI_Address(indata,&addresses[0]);
 MPI_Address(&(indata->a),&addresses[1]);
 MPI_Address(&(indata->b),&addresses[2]);
 MPI_Address(&(indata->n),&addresses[3]);
       /*...continua...*/
```

```
/*...continuación...*/
dis[0]=addresses[1]-addresses[0];
dis[1]=addresses[2]-addresses[0];
dis[2]=addresses[3]-addresses[0];

MPI_Type_struct(3,block_lenghts,dis,
typelist,message_type_ptr);

MPI_Type_commit(message_type_ptr);
}
```

Agrupación de datos.
Tipos derivados

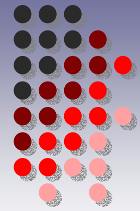

- Si los datos que constituyen el nuevo tipo son un subconjunto de entradas hay mecanismos especiales para construirlos (1/3):

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

- Crea un tipo derivado formado por `count` elementos del tipo `oldtype` contiguos en memoria.

Agrupación de datos.
Tipos derivados

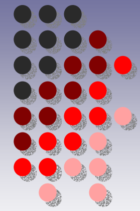

- Si los datos que constituyen el nuevo tipo son un subconjunto de entradas hay mecanismos especiales para construirlos (2/3):

```
int MPI_Type_vector
(
   int count,
   int block_lenght,
   int stride,
   MPI_Datatype element_type,
   MPI_Datatype *newtype
)
```

- Crea un tipo derivado formado por **`count`** elementos, cada uno de ellos con **`block_lenght`** elementos del tipo **`element_type`**.
- **`stride`** es el número de elementos del tipo **`element_type`** entre elementos sucesivos del tipo **`new_type`**.
- De este modo, los elementos pueden ser entradas igualmente espaciadas en un array.

Agrupación de datos.
Tipos derivados

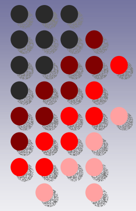

- Si los datos que constituyen el nuevo tipo son un subconjunto de entradas hay mecanismos especiales para construirlos (3/3):

```
int MPI_Type_indexed
(
    int count,
    int *array_of_block_lengths,
    int *array_of_displacements,
    MPI_Datatype element_type,
    MPI_Datatype *newtype
)
```

- Crea un tipo derivado con **count** elementos, habiendo en cada elemento **array_of_block_lengths[i]** entradas de tipo **element_type**, y el desplazamiento **array_of_displacements[i]** unidades de tipo **element_type** desde el comienzo de **newtype**

Agrupación de datos. Empaquetamiento

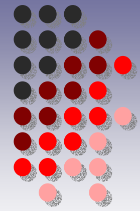

- Los datos se pueden empaquetar para ser enviados, y desempaquetarse tras ser recibidos.

- Se empaquetan **in_count** datos de tipo **datatype**, y **pack_data** referencia los datos a empaquetar en el **buffer**, que debe consistir de **size** bytes (puede ser una cantidad mayor a la que se va a ocupar).

```
int MPI_Pack
(
void              *pack_data,
int               in_count,
MPI_Datatype      datatype,
void              *buffer,
int               size,
int               *position_ptr,
MPI_Comm          comm
)
```

- El parámetro **position_ptr** es de E/S:
  - Como entrada, el dato se copia en la posición **buffer+*position_ptr**.
  - Como salida, referencia la siguiente posición en el **buffer** después del dato empaquetado.
  - El cálculo de dónde se sitúa en el **buffer** el siguiente elemento a empaquetar lo hace MPI automáticamente.

Agrupación de datos. Empaquetamiento

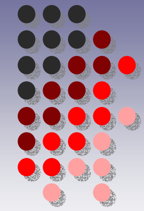

- Copia **count** elementos de tipo **datatype** en **unpack_data**, tomándolos de la posición **buffer+*position_ptr del buffer**.

- El tamaño del **buffer** (**size**) en bytes, y **position_ptr** es manejado por MPI de manera similar a como lo hace en MPI_Pack.

```
int MPI_Unpack
(
void            *buffer,
int             size,
int             *position_ptr,
Void            *unpack_data,
int             count,
MPI_Datatype    datatype,
MPI_Comm        comm
)
```

Agrupación de datos.
Empaquetamiento: empaquetados.c

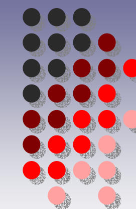

```
if(my_rank==0)
{
printf("Introduce      el      dato:          a      (float):      ");
   scanf("%f",&a);
printf("Introduce      el      dato:          b      (float):      ");
   scanf("%f",&b);
printf("Introduce      el      dato:          n      (entero):      ");
   scanf("%d",&n);
}
position=0;
MPI_Pack(&a,1,MPI_FLOAT,buffer,100,&position,MPI_COMM_WORLD);
MPI_Pack(&b,1,MPI_FLOAT,buffer,100,&position,MPI_COMM_WORLD);
MPI_Pack(&n,1,MPI_INT,buffer,100,&position,MPI_COMM_WORLD);

MPI_Bcast(buffer,position,MPI_PACKED,root,MPI_COMM_WORLD);

position=0;
MPI_Unpack(buffer,100,&position,&a,1,MPI_FLOAT,MPI_COMM_WORLD);
MPI_Unpack(buffer,100,&position,&b,1,MPI_FLOAT,MPI_COMM_WORLD);
MPI_Unpack(buffer,100,&position,&n,1,MPI_INT,MPI_COMM_WORLD);

printf("En procesador %d, los datos recibidos son a:%f    b:%f
   n:%d \n",my_rank,a,b,n);
```

Comunicadores

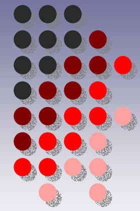

- MPI_COMM_WORLD incluye a todos los procesos
- Se puede definir comunicadores con un número menor de procesos: para comunicar datos en cada fila de procesos en la malla, en cada columna, ...
- Dos tipos de comunicadores:

1. **intra-comunicadores:** se utilizan para enviar mensajes entre los procesos en ese comunicador,
2. **inter-comunicadores:** se utilizan para enviar mensajes entre procesos en distintos comunicadores.

Comunicadores.
Intra-comunicadores

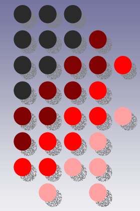

1. **Intra-comunicador**. Consta de:

   - **Un grupo**, que es una colección ordenada de procesos a los que se asocia identificadores entre 0 y *p*-1.
   - **Un contexto**, que es un identificador que asocia el sistema al grupo.
   - Adicionalmente, a un comunicador se le puede asociar **una topología virtual**.

Comunicadores.
Intra-comunicadores

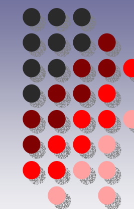

- MPI_COMM_WORLD consta de $p=q^2$ procesos agrupados en q filas y q columnas. El proceso número r tiene las coordenadas (r div$q$,r mod q).

- Ejemplo: Creación un comunicador cuyos procesos son los de la primera fila de nuestra malla virtual.

```
MPI_Group  MPI_GROUP_WORLD;
MPI_Group  first_row_group, first_row_comm;
int   row_size;
int   *process_ranks;

process_ranks=(int *) malloc(q*sizeof(int));

for(proc=0;proc<q;proc++)
   process_ranks[proc]=proc;

MPI_Comm_group(MPI_COMM_WORLD,&MPI_GROUP_WORLD);
MPI_Group_incl(MPI_GROUP_WORLD,q,process_ranks,&first_row_group);
MPI_Comm_create(MPI_COMM_WORLD,first_row_group,&first_row_comm);
```

Comunicadores.
Intra-comunicadores

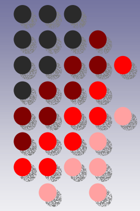

- Para crear varios comunicadores disjuntos

```
int MPI_Comm_split
(
        MPI_Comm old_comm,
        int split_key,
        int rank_key,
        MPI_Comm *new_comm
)
```

- Crea un nuevo comunicador para cada valor de `split_key`.
- Los procesos con el mismo valor de `split_key` forman un grupo.
- Si dos procesos ***a*** y ***b*** tienen el mismo valor de `split_key` y el `rank_key` de ***a*** es menor que el de ***b***, en el nuevo grupo ***a*** tiene identificador menor que ***b***.
- Si los dos procesos tienen el mismo `rank_key` el sistema asigna los identificadores arbitrariamente.

Comunicadores. Intra-comunicadores

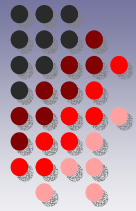

```
int MPI_Comm_split
        ( ...
        )
```

- Es una operación colectiva.
- Todos los procesos en el comunicador deben llamarla.
- Los procesos que no se quiere incluir en ningún nuevo comunicador pueden utilizar el valor `MPI_UNDEFINDED` en `rank_key`, con lo que el valor de retorno de `new_comm` es `MPI_COMM_NULL`.
- Ejemplo: crear *q* grupos de procesos asociados a las *q* filas:

```
MPI_Comm my_row_comm;
int my_row;

my_row=my_rank/q;
MPI_Comm_split (MPI_COMM_WORLD,my_row,my_rank,&my_row_comm);
```

Comunicadores.
Intra-comunicadores. Topologías

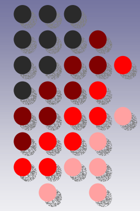

- A un grupo se le puede asociar una topología virtual:
  - topología de grafo en general
  - de malla o cartesiana

- Una topología cartesiana se crea:

```
int MPI_Card_create (
   MPI_Comm  old_comm,
   int  number_of_dims,
   int *dim_sizes,
   int *periods,
     int reorder,
     MPI_Comm *cart_comm    )
```

- El número de dimensiones de la malla es `number_of_dims`
- El número de procesos en cada dimensión está en `dim_sizes`
- Con `periods` se indica si cada dimensión es circular o lineal
- Un valor de 1 en `reorder` indica al sistema que se reordenen los procesos para optimizar la relación entre el sistema físico y el lógico.

Comunicadores. Intra-comunicadores. Topologías

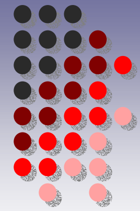

- Las coordenadas de un proceso conocido su identificador se obtienen con

```
int MPI_Cart_coords( MPI_Comm comm, int rank,
int number_of_dims, int *coordinates)
```

- El identificador, conocidas las coordenadas con

```
int MPI_Cart_rank( MPI_Comm comm, int *coordinates, int *rank)
```

- Una malla se puede particionar en mallas de menor dimensión

```
int MPI_Cart_sub(MPI_Comm old_comm, int *varying_coords,
MPI_Comm *new_comm)
```

  - en `varying_coords` se indica para cada dimensión si pertenece al nuevo comunicador.
  - Si `varying_coords[0]=0` y `varying_coords[1]=1` para obtener el nuevo comunicador no se varía la primera dimensión pero sí la segunda. Se crean *q* comunicadores, uno por cada fila.
  - Es colectiva.

MPI-2

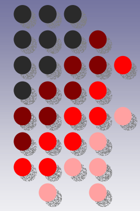

- Corregir errores de MPI-1
- Entrada/Salida paralela (MPI-IO)
  - Aumentar prestaciones E/S
  - Accesos no contiguos a memoria y a ficheros
  - Operaciones colectivas de E/S
  - Punteros a ficheros tantos individuales como colectivos
  - E/S asíncrona
  - Representaciones de datos portables y ajustadas a las necesidades
- Operaciones remotas de memoria
  - Proveer elementos del “tipo” de memoria compartida
  - Concepto de “ventana de memoria”: porción de memoria de un proceso que es expuesta explícitamente a accesos de otros procesos
  - Operación remotas son asíncronas → necesidad de sincronizaciones explícitas
- Gestión dinámica de procesos
  - Un proceso MPI puede participar en la creación de nuevos procesos: *spawing*
  - Un proceso MPI puede comunicarse con procesos creados separadamente: *connecting*
  - La clave: **intercomunicadores**: comunicadores que contienen 2 grupos de procesos
  - Extensión de comunicaciones colectivas a intercomunicadores

MPI-2
Entrada/Salida paralela (MPI-IO): escribiendo en diferentes ficheros: mpi_io_1.c

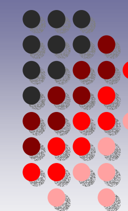

```
int main(int argc, char *argv[])
{
  int i, myrank, buf[BUFSIZE];
  char filename[128];
  MPI_File myfile;

  MPI_Init(&argc, &argv);
  MPI_Comm_rank(MPI_COMM_WORLD,&myrank);

  for (i=0;i<BUFSIZE;i++)
    buf[i]=myrank*BUFSIZE+i;

  sprintf(filename,"testfile.%d",myrank);//cada proceso → un fichero

  MPI_File_open(MPI_COMM_SELF,filename, MPI_MODE_WRONLY |
     MPI_MODE_CREATE, MPI_INFO_NULL,&myfile);
  MPI_File_write(myfile,buf,BUFSIZE,MPI_INT,MPI_STATUS_IGNORE);
  MPI_File_close(&myfile);

  MPI_Finalize();
  return 0;
}
```

MPI-2
Entrada/Salida paralela (MPI-IO): escribiendo en diferentes ficheros: mpi_io_1.c

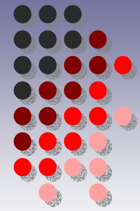

```
MPI_File_open(MPI_COMM_SELF,filename, MPI_MODE_WRONLY |
    MPI_MODE_CREATE, MPI_INFO_NULL,&myfile);
```

- MPI_COMM_SELF: Comunicador del fichero abierto. En este caso cada proceso abre el suyo propio
- Modo apertura
- Campo nulo
- Descriptor del fichero

```
MPI_File_write(myfile,buf,BUFSIZE,MPI_INT,MPI_STATUS_IGNORE);
```

- Descriptor del fichero
- Datos a escribir
- Tamaño
- Tipo
- MPI_STATUS_IGNORE: para que no me devuelva información en Status, porque no la necesito

```
}
```

MPI-2
Entrada/Salida paralela (MPI-IO): escribiendo en un fichero único: mpi_io_2.c

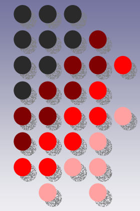

```
int main(int argc, char *argv[])
{
  int i, myrank, buf[BUFSIZE];
  char filename[128];
  MPI_File myfile;
  MPI_Init(&argc, &argv);
  MPI_Comm_rank(MPI_COMM_WORLD,&myrank);
  for (i=0;i<BUFSIZE;i++)
   buf[i]=myrank*BUFSIZE+i;

  sprintf(filename,"testfile");//todos procesos → un único fichero
  MPI_File_open(MPI_COMM_WORLD,filename, MPI_MODE_WRONLY |
     MPI_MODE_CREATE, MPI_INFO_NULL,&myfile);
MPI_File_set_view(myfile,myrank*BUFSIZE*sizeof(int),MPI_INT,MPI_INT,"
     native",MPI_INFO_NULL);
  MPI_File_write(myfile,buf,BUFSIZE,MPI_INT,MPI_STATUS_IGNORE);
  MPI_File_close(&myfile);

  MPI_Finalize();
  return 0;
}
```

MPI-2
Entrada/Salida paralela (MPI-IO): escribiendo en un fichero único: mpi_io_2.c

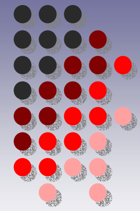

```
MPI_File_set_view(myfile,myrank*BUFSIZE*sizeof(int),MPI_INT,MPI_INT,"
    native",MPI_INFO_NULL);
```

```
Descriptor del Fichero
Desplazamiento donde escribir
Tipo a escribir
Tipo zona discontinua del fichero
"native"representqción del dato a escribir tal como se
    representa en memoria
```

MPI-2
Entrada/Salida paralela (MPI-IO): leyendo de un fichero único: mpi_io_3.c

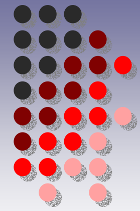

```
int main(int argc, char *argv[])
{
     /* … */

  MPI_File_open(MPI_COMM_WORLD,"testfile", MPI_MODE_RDONLY,
     MPI_INFO_NULL,&myfile);

  MPI_File_get_size(myfile,&filesize); //in bytes
  filesize=filesize/sizeof(int); //in number of ints
  bufsize=filesize/numprocs +1; //local number to read
  buf=(int *) malloc (bufsize*sizeof(int));

     MPI_File_set_view(myfile,myrank*bufsize*sizeof(int),MPI_INT,MPI_
     INT,"native",MPI_INFO_NULL);
  MPI_File_read(myfile,buf,bufsize,MPI_INT,&status);
  MPI_Get_count(&status,MPI_INT,&count);

  printf("process %d read %d ints \n",myrank,count);

  /* … */

}
```

Ejercicios

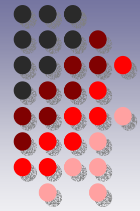

1. Copia a tu directorio y prueba los ejemplos que están en: `/home/javiercm/ejemplos_MPI`

```
Conectarse a luna.inf.um.es
        ssh luna.inf.um.es
        usuario       XXXX
        clave         YYYY
        PATH=$PATH:.
        lamboot

Para obtener los programas de ejemplo:
        cp /home/javiercm/ejemplos_mpi/*.c .

Para compilar el programa hello.c:
        mpicc hello.c  -o hello -lm -lmpi

Para ejecutarlo con 4 procesos:
        mpirun –np 4 hello
```

Ejercicios

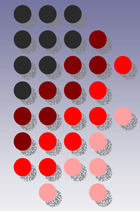

2. Amplia el programa broadcast.c de manera que además de los datos que se distribuyen en la versión actual también se envie una cadena de 10 caracteres.

3. Modifica el programa gather.c para que además del vector **datos**, se recopile en el proceso raiz el vector **resultados**, también formado de enteros.

4. Modifica el programa scatter.c para que el array **datos** distribuido desde el proceso 0 contenga números reales de doble precisión en lugar de enteros.

5. Amplia el programa reduce.c para que, además de calcular la suma, calcule el valor máximo relativo a cada posición de los arrays locales de los distintos procesos (el máximo de la posición 0, el de la posición 1,…)

6. Amplia el programa hello.c para que al final del programa cada proceso **i** mande otro mensaje de saludo al nodo **(i+1)%p**, y tras ello, cada proceso muestre el mensaje recibido en pantalla.

Ejercicios

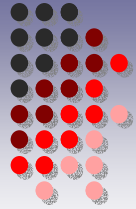

7. Completa el programa de ejemplo mult_mpi.c (calcula el producto de matrices C <= A*B) que conlleva:

- **broadcast**: La matriz A se manda completamente a todos.
- **scatter**: La matriz B se distribuye por bloques de columnas.
- **mm**: Cada proceso calcula un bloque de columnas de C multiplicando la matriz A por el bloque de columnas de B que le ha correspondido. Por ejemplo, P_1 calcularía:

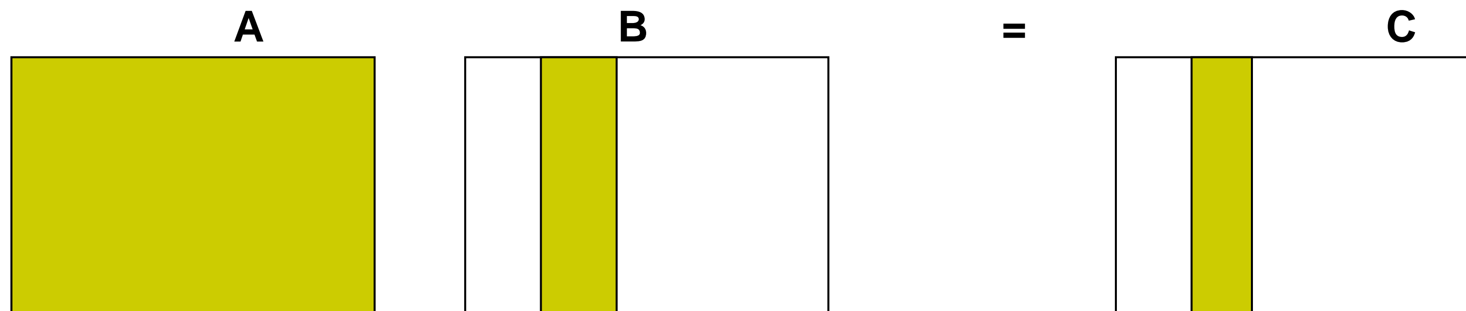

- **gather**: Todos los procesos mandan al root sus resultados parciales, es decir, sus bloques de columnas de C. Al finalizar, el proceso root contendrá la matriz C resultado completamente.

Ejercicios

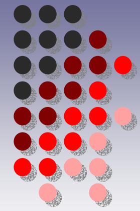

8. Amplia el programa **derivados.c** para que el tipo derivado que se forma y se envía contenga también una cadena de 48 caracteres.

9. Amplia el programa **empaquetados.c** para que el paquete de datos que se forma y se envía contenga también un vector de 100 números reales de doble precisión.