

Tutorial sobre MPI

Introducción

Autor: Abel Francisco Paz Gallardo

Evento: Tutorial MPI

Lugar / Fecha: Trujillo, 11 y 18 de Mayo 2010



GOBIERNO
DE ESPAÑA

MINISTERIO
DE CIENCIA
E INNOVACIÓN



CENTRO EXTREMEÑO DE
TECNOLOGÍAS AVANZADAS

CETA Ciemat



FEDER

Fondo Europeo de Desarrollo Regional

Una manera de hacer Europa

INDICE

- 1 Introducción a MPI
.....
- 2 Nociones básicas
.....
- 3 Funciones de MPI
.....
- 4 Casos prácticos
.....

Tutorial MPI – Primeros pasos



GOBIERNO
DE ESPAÑA

MINISTERIO
DE CIENCIA
E INNOVACIÓN



CENTRO EXTREMEÑO DE
TECNOLOGÍAS AVANZADAS

CETA Ciemat



FEDER

Fondo Europeo de Desarrollo Regional

Una manera de hacer Europa

¿Qué es MPI?

- MPI es una **interfaz de paso de mensaje** que representa un esfuerzo prometedor de mejorar la disponibilidad de un software **altamente eficiente y portable** para satisfacer las necesidades actuales en la **computación de alto rendimiento** a través de la definición de un estándar de paso de mensajes **universal**.

William D. Gropp et al.

- **Protocolo** de comunicación entre máquinas
- **Estándar** para la comunicación entre los nodos que ejecutan un programa en un sistema de memoria distribuida
- **Conjunto de librerías** de funciones que pueden ser utilizadas en programas escritos en C, C++, Fortran y Ada

Ventajas de utilizar MPI

- **Portabilidad:** MPI ha sido implementado para casi toda arquitectura de memoria distribuida
- **Velocidad:** Cada implementación de la biblioteca ha sido optimizada para el hardware en la cual se ejecuta
 - *Ejemplo:* Clusters de Bull utilizan MPIBull2 optimizada para IB
- **Estándar:** 60 personas de 40 organizaciones diferentes principalmente de U.S.A. y Europa trabajaron en estandarizarlo (IBM, INTEL, NXI, Express, nCUBE's Vernex, p4, PARMACS, Zipcode, Chimp, PVM, Chameleon, PICL...)
- **Amplia funcionalidad**
- Gran variedad de **implementaciones libres** (MPICH, OpenMPI, LAM-MPI...)

Implementaciones de MPI (“MPI flavors/flavours”)

- LAM/MPI (Local Area Multicomputer).
- **OpenMPI**
- **MPICH**: MPICH2 (estándar MPI 2.1)
- Diferentes ramas en cada implementación:
 - Para GRID: MPICH-G2, MPICH-GM, MPICH-VM2...
 - Para Infiniband: MVAPICH, MPIBull2...
- Otros lenguajes: Python (PyMPI), Java (mpiJava), ...
- Más info sobre el estándar MPI 2.0:
<http://www.mcs.anl.gov/research/projects/mpi/mpi-standard/mpi-report-2.0/mpi2-report.htm>

Nociones básicas

- La **unidad básica** en MPI son los **procesos**.
- Tienen espacios de memoria independientes.
- El Intercambio de información es mediante **paso de mensajes**.
- Introduce en concepto de **comunicadores** (grupo de procesos más contexto).
- A **cada proceso** se le asigna un **identificador interno** propio de MPI (rank).

Primer programa en MPI

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

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

 printf("Hola soy el proceso %d de %d\n", myrank, size);

 MPI_Finalize();
 exit(0);
}
```

### ¿Qué son los comunicadores?

- MPI **agrupa los procesos** implicados en una ejecución paralela en **comunicadores**.
- Un comunicador **agrupa a procesos que pueden intercambiarse mensajes**.
- El comunicador **MPI\_COMM\_WORLD** está creado por defecto y engloba a todos los procesos.
- Pueden definirse varios comunicadores.
  - *MPI\_Comm\_create, MPI\_Comm\_free, MPI\_Comm\_group, MPI\_Group\_include, MPI\_Group\_exclude...*



### Inicio y Finalización

- **int MPI\_Init(int \*argc, char \*\*argv)**
  - Primera llamada **OBLIGATORIA** de cada uno de los procesos MPI
  - Establece entorno
  - Un proceso solo puede hacer una llamada MPI\_INIT
- **int MPI\_Finalize(void)**
  - Termina la ejecución en MPI
  - Libera los recursos utilizados por MPI

### Identificación de procesos

- **MPI\_Comm\_rank (comm, &identificador);**
  - Devuelve el **identificador** del proceso dentro del comunicador **comm** especificado (ej.: MPI\_COMM\_WORLD).
- **MPI\_Comm\_size (comm, &num\_proc);**
  - Devuelve en **num\_proc** el número de procesos del comunicador especificado.

### Primer programa en MPI (segundo vistazo)

- `#include <stdio.h>`
- `#include "mpi.h"`
- ```
int main(int argc, char *argv[ ]) {  
    int myrank, size;  
  
    MPI_Init(&argc, &argv);  
    MPI_Comm_rank(MPI_COMM_WORLD, &myrank);  
    MPI_Comm_size(MPI_COMM_WORLD, &size);  
  
    printf("Hola soy el proceso %d de %d\n", myrank, size);  
  
    MPI_Finalize();  
    exit(0);  
}
```

Tipos de datos

- **Todo tipo de datos:**

- **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_SHORT** unsigned short int
- **MPI_UNSIGNED** unsigned int
- **MPI_UNSIGNED_LONG** unsigned long int
- **MPI_FLOAT** float
- **MPI_DOUBLE** double
- **MPI_LONG_DOUBLE** long double
- ...
- MPI también permite definir **tipos de datos propios** (MPI_TYPE_VECTOR, MPI_TYPE_STRUCT...)

Funciones de MPI

- **MPI 1.2 tiene 129 funciones**
- Las **funciones principales** de MPI son:
 - MPI_Init
 - MPI_Finalize
 - MPI_Comm_size
 - MPI_Comm_rank
 - MPI_Send
 - MPI_Recv


Tipos de mensajes (1)

- **Punto a punto:** 1 emisor - 1 receptor
 - **Síncronos:** El emisor **se espera** a que la comunicación se produzca (o que el buffer del receptor este disponible). **BLOQUEANTE**
 - *Send, Recv, SendRecv, Bsend, Ssend, ...*
 - **Asíncronos:** El emisor **NO se espera** a que la comunicación se produzca y se comprueba más tarde si se ha producido. **NO BLOQUEANTES**
 - *Isend, Irecv, ...*

Tipos de mensajes (2)

- **MPI_Send**(buf, count, datatype, dest, tag, comm)
- **MPI_Recv**(buf, count, datatype, source, tag, comm, status)
- **buf**: Dirección donde comienza el mensaje.
- **count**: número de elementos del mensaje.
- **datatype**: tipo del mensaje.
- **dest/source**: posición relativa del proceso fuente/destino dentro del comunicador.
 - MPI_ANY_SOURCE: permite recibir mensaje de cualquier fuente
- **status**: estado de la recepción

Tipos de mensajes (3)



Tipos de mensajes (4)







- **Variantes de MPI_Send para casos especiales**
- **Síncrono: MPI_Ssend(.....)**
 - La operación se da por terminada sólo **cuando el mensaje ha sido recibido en destino**. (MPI_Send termina cuando encuentra y receptor y envía su mensaje)
- **Buffered: MPI_Bsend(.....)**
 - Cuando se hace un envío con buffer **se guarda inmediatamente, en un buffer al efecto en el emisor**, una copia del mensaje. La operación se da por completa en cuanto se ha efectuado esta copia. Si no hay espacio en el buffer, el envío fracasa.
- **Ready: MPI_Rsend(.....)**
 - Sólo se puede hacer si antes **el otro extremo está preparado para una recepción inmediata**. No hay copias adicionales del mensaje (como en el caso del modo con buffer), y tampoco podemos confiar en bloquearnos hasta que el receptor esté preparado.

(para más info mirar referencias al final)

Tipos de mensajes (5)

- **Multipunto:** 1 o N emisores - 1 o N receptores
 - MPI_Barrier() - Sincronización global entre los procesadores del comunicador.
 - MPI_Bcast()
 - MPI_Gather()
 - MPI_Scatter()
 - MPI_Alltoall()
 - MPI_Reduce()
 - MPI_Reduce_scatter()
 - MPI_Scan() ...

3 Funciones de MPI



Tipos de reducción

- **MPI_MAX** maximum
- **MPI_MIN** minimum
- **MPI_SUM** sum
- **MPI_PROD** product
- **MPI_LAND** logical and
- **MPI_BAND** bit-wise and
- **MPI_LOR** logical or
- **MPI_BOR** bit-wise or
- **MPI_LXOR** logical xor
- **MPI_BXOR** bit-wise xor
- **MPI_MAXLOC** max value and location
- **MPI_MINLOC** min value and location

Caso práctico 1

- Crear un programa sencillo en C utilizando MPI, en el que un nodo (maestro) salude a otros nodos (esclavos).
- Condiciones:
 - El saludo tiene que realizarlo antes el maestro que los esclavos.
 - El maestro tiene que enviar un mensaje que muestren por pantalla los nodos esclavos.

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

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

Caso práctico 1


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

int main(int argc, char** argv) {
    char host[20], Recv[20];
    MPI_Status status;
    int rank, size, tag=0, i;
    gethostname(host,20);
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);

    if (rank == 0) { /* proc 0 => send message */
        for (i = 1; i < size; ++i) {
            MPI_Send("Hola desde P0 !", 20, MPI_CHAR, i , tag, MPI_COMM_WORLD);
            printf ("Hola, soy el nodo % de %i nodos. Estoy en la máquina %s y he enviado un mensaje a %i\n",rank,size, host,i);
        }
    }
    if (rank != 0) { /* proc 1 => receive message */
        MPI_Recv(Recv, 20, MPI_CHAR, 0, tag, MPI_COMM_WORLD,&status);
        printf("Hola! Soy el nodo %i de un total de %i nodos. Estoy en la máquina %s y he recibido el mensaje: '%s'\n",
            rank,size,host,Recv);
    }
    MPI_Finalize();
}
```

Caso práctico 2

- Crear un programa sencillo que utilice la función Broadcast para que el nodo maestro mande un entero al resto de nodos.



`Int MPI_Bcast ( void *buffer, int count, MPI_Datatype datatype, source, MPI_Comm comm )`

Caso práctico 2

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

int main(int argc, char** argv) {
    int rank;
    int n;
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);

    if (rank == 0) { /* proc 0 => send message */
        printf("Hola, soy el nodo maestro, vamos a mandarle el numero 2010 al todos los nodos. ");
        n = 2010;
    }

    MPI_Bcast(&n,1,MPI_INT,0,MPI_COMM_WORLD);

    printf("Hola, soy el proceso %d y el numero es el %d\n",rank,n);

    MPI_Finalize();
}
```

Enviar trabajos al cluster de GPUs

- Acceder como usuario **tutorial**

ssh tutorial@ce-gpu-test.ceta-ciemat.es

- Crear carpeta de usuario en /home/tutorial/minombredeusuario
- Enviar un trabajo:

qsub -q gpu -pe gpupe <numero_nodos> script.sh

- Script.sh

```
export MPICH2_ROOT=/opt/mpi/mpibull2-1.3.9-14.s
export PATH=$MPICH2_ROOT/bin:$PATH
export MPD_CON_EXT="sge_$JOB_ID.$SGE_TASK_ID"
```

```
echo "Got $NSLOTS slots."
```

```
mpirexec -machinefile $TMPDIR/machines -n $NSLOTS /opt/exp_soft/tutorial/mpisend
```

```
exit 0
```

Tiene que ser
accesible por
todos los nodos

Referencias

- **MPI: Message Passing Interface.** Universidad Carlos III Madrid. http://svn.ceta-ciemat.es/gpus/trunk/Bibliograf%c3%ada/MPI/Curso-MPI_CarlosIIIMadrid.pdf
- **Interfaz de Paso de Mensajes** – Wikipedia. http://es.wikipedia.org/wiki/Interfaz_de_Paso_de_Mensajes
- **Message Passing Interface (MPI)** - Blaise Barney, Lawrence Livermore National Laboratory. <https://computing.llnl.gov/tutorials/mpi/>
- **MPI: The Complete Reference** - <http://www.netlib.org/utk/papers/mpi-book/mpi-book.html>
- **MPI Routines (official):** <http://www.mcs.anl.gov/research/projects/mpi/www/>

Conventual de San Francisco, Sola 1, 10200 Trujillo
Teléfono: 927 65 93 17 Fax: 927 32 32 37
www.ceta-ciemat.es



GOBIERNO
DE ESPAÑA

MINISTERIO
DE CIENCIA
E INNOVACIÓN



CENTRO EXTREMEÑO DE
TECNOLOGÍAS AVANZADAS

CETA Ciemat



FEDER

Fondo Europeo de Desarrollo Regional

Una manera de hacer Europa

Cómo funciona MPI

- SEGUNDA PARTE DEL TUTORIAL MPI
- Mpich, demonios... MPD..



GOBIERNO
DE ESPAÑA

MINISTERIO
DE CIENCIA
E INNOVACIÓN



CENTRO EXTREMEÑO DE
TECNOLOGÍAS AVANZADAS

CETA Ciemat

Una manera de hacer Europa

Tutorial sobre MPI

Abel Francisco Paz Gallardo

CETA-Ciemat/ Mayo 2010

CENTRO EXTREMEÑO DE TECNOLOGÍAS AVANZADAS