Laboratorio di Calcolo Parallelo

Lezione 2: Aspetti avanzati ed esempi in MPI

Francesco Versaci & Alberto Bertoldo

Università di Padova

6 maggio 2009

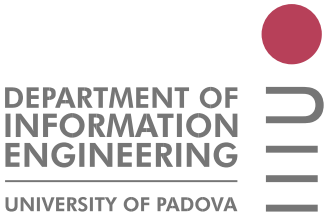

Outline

Deadlock
Sempre

```
#include <mpi.h>
#include <stdio.h>
int main(int argc, char **argv) {
  int me, np, q, sendto;
  MPI_Status status;
  MPI_Init(&argc, &argv);
  MPI_Comm_size(MPI_COMM_WORLD, &np);
  MPI_Comm_rank(MPI_COMM_WORLD, &me);
  if (np%2==1) return 0;
  if (me%2==1) {sendto = me-1;}
  else {sendto = me+1;}
  MPI_Recv(&q, 1, MPI_INT, sendto, sendto, \
    MPI_COMM_WORLD, &status);
  MPI_Send(&me, 1, MPI_INT, sendto, me, MPI_COMM_WORLD);
  printf("Sent %d to proc %d, received %d from proc %d\n", \
    me, sendto, q, sendto);
  MPI_Finalize();
  return 0;
}
```


Deadlock
Dipende

```
#include <mpi.h>
#include <stdio.h>
int main(int argc, char **argv) {
  int me, np, q, sendto;
  MPI_Status status;
  MPI_Init(&argc, &argv);
  MPI_Comm_size(MPI_COMM_WORLD, &np);
  MPI_Comm_rank(MPI_COMM_WORLD, &me);
  if (np%2==1) return 0;
  if (me%2==1) {sendto = me-1;}
  else {sendto = me+1;}
  MPI_Send(&me, 1, MPI_INT, sendto, me, MPI_COMM_WORLD);
  MPI_Recv(&q, 1, MPI_INT, sendto, sendto, \
    MPI_COMM_WORLD, &status);
  printf("Sent %d to proc %d, received %d from proc %d\n", \
    me, sendto, q, sendto);
  MPI_Finalize();
  return 0;
}
```

Deadlock
Come evitarlo

- Cambiare l'**ordine** delle chiamate
  - Pericoloso se le dipendenze coinvolgono più di 2 processi
  - Occorre avere ben chiaro il pattern di comunicazione
  - Non aumenta la complessità del programma
- Usare le chiamate **non bloccanti**
  - Aumenta la complessità del programma
  - Può anche aumentare l'efficienza
- Usare la modalità **bidirezionale**
  - Non è sempre applicabile
  - Rende più leggibile e semplice il codice
- Usare la modalità **buffered**
  - Occorre gestire i buffer
  - Comportamento prevedibile
  - Non aumenta di molto la complessità

Deadlock
Evitarlo cambiando l'ordine delle chiamate

```
#include <mpi.h>
#include <stdio.h>
int main(int argc, char **argv) {
  int me, np, q, sendto;
  MPI_Status st;
  MPI_Init(&argc, &argv);
  MPI_Comm_size(MPI_COMM_WORLD, &np);
  MPI_Comm_rank(MPI_COMM_WORLD, &me);
  if (np%2==1) return 0;
  if (me%2==1) {sendto = me-1;}
  else {sendto = me+1;}
  if (me%2 == 0) {
    MPI_Send(&me, 1, MPI_INT, sendto, me, MPI_COMM_WORLD);
    MPI_Recv(&q, 1, MPI_INT, sendto, sendto, MPI_COMM_WORLD, &st);
} else {
    MPI_Recv(&q, 1, MPI_INT, sendto, sendto, MPI_COMM_WORLD, &st);
    MPI_Send(&me, 1, MPI_INT, sendto, me, MPI_COMM_WORLD);
  }
  printf("Sent %d to proc %d, received %d from proc %d\n", \
    me, sendto, q, sendto);
  MPI_Finalize();
  return 0;
}
```

Spedire un messaggio

```
int MPI_Isend(void* buf, int count, \
  MPI_Datatype datatype, int dest, int tag, \
  MPI_Comm comm, MPI_Request *request)
```

- Inizializza il processo di spedizione
- Ritorna quando la richiesta di spedizione è stata registrata
- `buf` non puo' essere sovrascritto finche' la richiesta è **pendente**
- Occorre controllare lo stato della richiesta di spedizione
- Può corrispondere a una ricezione bloccante

Note sull'efficienza

- Aumenta la sovrapposizione tra computazione e comunicazione
- Il grado di sovrapposizione dipende dall'implementazione e dallo hardware

Ricevere un messaggio

```
int MPI_Irecv(void* buf, int count, \
  MPI_Datatype datatype, int source, \
  int tag, MPI_Comm comm, MPI_Request *request)
```

- Inizializza il processo di ricezione (recv posting)
- Ritorna quando il richiesta di ricezione è stata registrata
- `buf` non puo' essere usato finche' la richiesta è pendente
- Occorre controllare lo stato della richiesta di ricezione
- Può corrispondere a una spedizione bloccante

Note sull'efficienza

È consigliabile effettuare il posting ASAP:

- Può sbloccare un mittente

Comunicazioni punto-punto *standard*
Primitive non bloccanti

Controllare lo stato

```
int MPI_Test(MPI_Request *request, \
  int *flag, MPI_Status *status)
```

- Ritorna subito dopo aver controllato lo stato
- `flag = true` se l'operazione è stata completata e:
  send: `buf` può essere aggiornato
  recv: `buf` contiene i dati ricevuti

Aspettare la conclusione

```
int MPI_Wait(MPI_Request *request, MPI_Status *st)
```

- Ritorna quando l'operazione è conclusa

Note sull'efficienza

È consigliabile effettuare la wait ALAP

Comunicazioni punto-punto *standard*
Primitive non bloccanti

Stato di richieste multiple

```
int MPI_Waitany(int count, MPI_Request *array_req, \
  int *index, MPI_Status *st)

int MPI_Waitall(int count, MPI_Request *array_req, \
  MPI_Status *array_st)

int MPI_Waitsome(int incount, MPI_Request *array_req, \
  int *outcount, int *array_ind, MPI_Status *array_st)
```

N.B.: Esistono primitive analoghe per il **test**

ANY: una sola operazione tra quelle in sospeso

ALL: tutte le operazioni in sospeso

SOME: almeno una operazione tra quelle in sospeso

Comunicazioni punto-punto
Esempio 3: Nearest neighbor exchange in ring topology

```
int numtasks, rank, next, prev, buf[2], tag1=1, tag2=2;
MPI_Request reqs[4];
MPI_Status stats[4];

MPI_Init(&argc,&argv);
MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
MPI_Comm_rank(MPI_COMM_WORLD, &rank);

prev = (rank-1)%numtasks;
next = (rank+1)%numtasks;

MPI_Irecv(&buf[0], 1, MPI_INT, prev, tag1, MPI_COMM_WORLD, &reqs[0]);
MPI_Irecv(&buf[1], 1, MPI_INT, next, tag2, MPI_COMM_WORLD, &reqs[1]);
MPI_Isend(&rank, 1, MPI_INT, prev, tag2, MPI_COMM_WORLD, &reqs[2]);
MPI_Isend(&rank, 1, MPI_INT, next, tag1, MPI_COMM_WORLD, &reqs[3]);

      { do some work }

MPI_Waitall(4, reqs, stats);

MPI_Finalize();
```


Comunicazioni collettive
Panoramica

Comunicazione tra più processi MPI

Tutti o nessuno

- Tutti i processi del comunicatore sono coinvolti
- Le primitive sono tutte bloccanti (nel senso che abbiamo visto)
- Se un processo non partecipa?

Tipi di comunicazioni collettive:

Sincronizzazione: barrier

Trasferimento dati: broadcast, scatter, gather, all-to-all

Operazioni di riduzione: sum, max, min, ...

Sincronizzare i processi

```
int MPI_Barrier(MPI_Comm comm)
```

- Blocca il chiamante finché tutti i processi effettuano la chiamata

Replicare i dati

```
int MPI_Bcast(void* buffer, int count, \
  MPI_Datatype datatype, int root, MPI_Comm comm)
```

- Replica il contenuto di `buffer` da `root` a tutti gli altri processi
- Non implica necessariamente la sincronizzazione

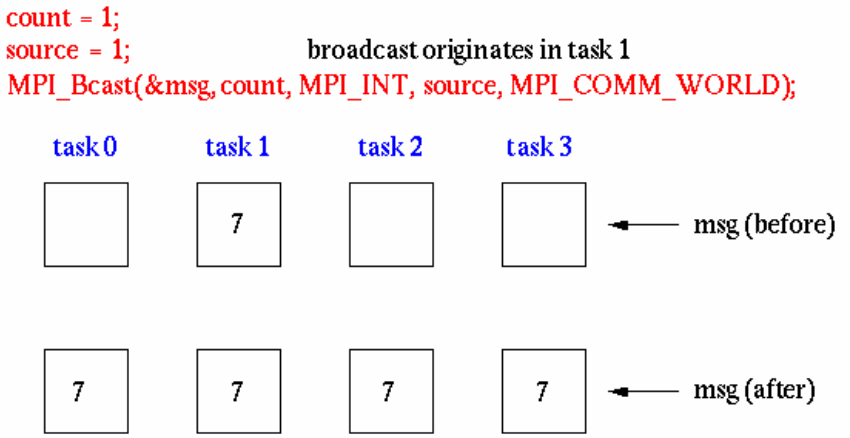

Distribuire i dati

```
int MPI_Scatter(void* sendbuf, int sendcount, \
  MPI_Datatype sendtype, void* recvbuf, int recvcount, \
  MPI_Datatype recvtype, int root, MPI_Comm comm)
```

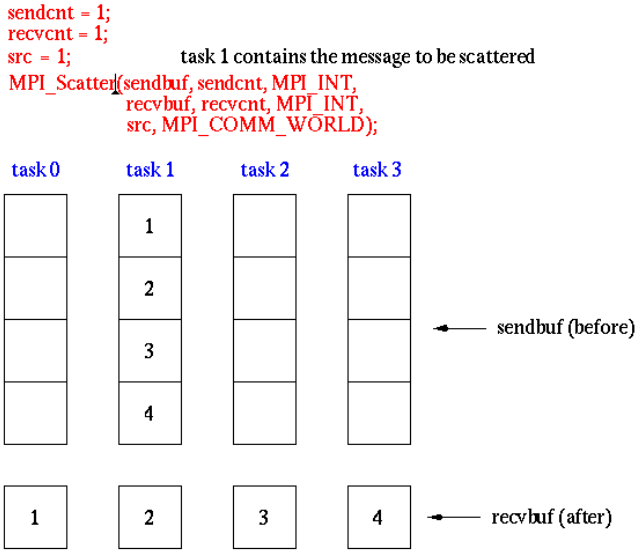

Raccogliere i dati

```
int MPI_Gather(void* sendbuf, int sendcount, \
  MPI_Datatype sendtype, void* recvbuf, int recvcount, \
  MPI_Datatype recvtype, int root, MPI_Comm comm)
```

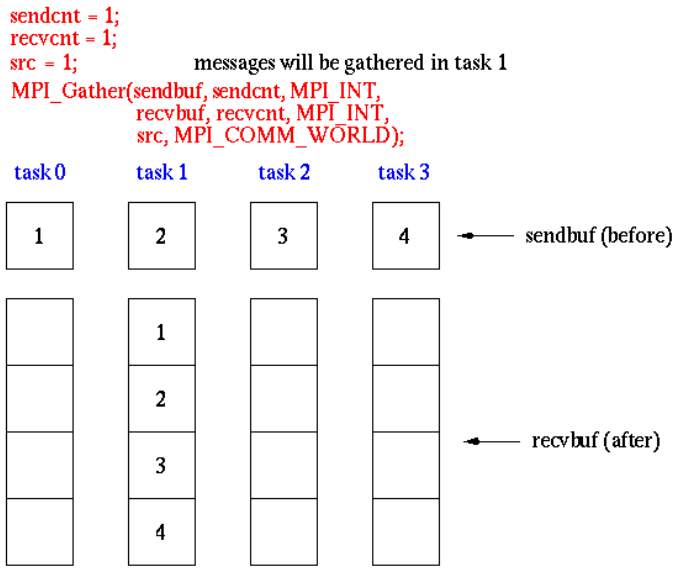

Raccogliere i dati + replicazione

```
int MPI_Allgather(void* sendbuf, int sendcount, \
  MPI_Datatype sendtype, void* recvbuf, int recvcount, \
  MPI_Datatype recvtype, MPI_Comm comm)
```

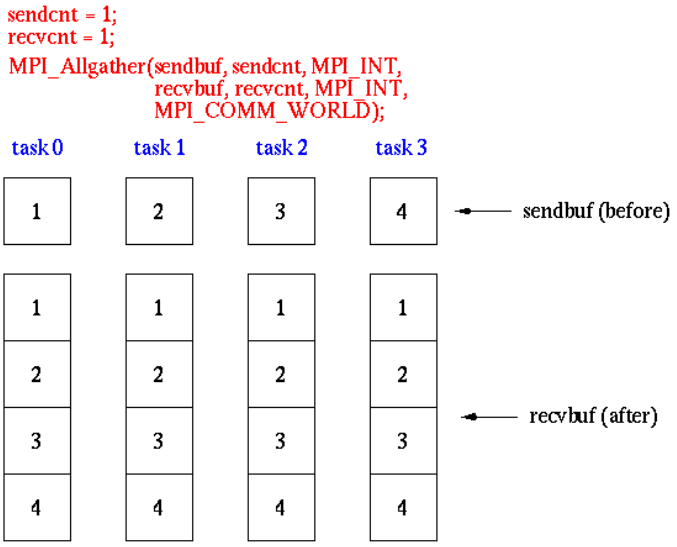

Scambio da tutti a tutti

```
int MPI_Alltoall(
 void* sendbuf, \
 int sendcount, \
 MPI_Datatype sendtype, \
 void* recvbuf, \
 int recvcount, \
 MPI_Datatype recvtype, \
 MPI_Comm comm)
```

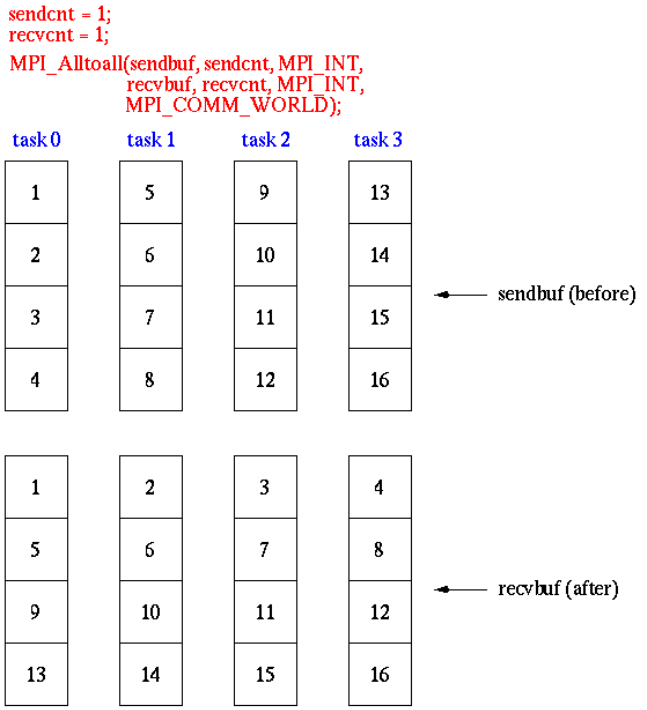

Operazioni di riduzione

```
int MPI_Reduce(void* sendbuf, void* recvbuf, \
  int count, MPI_Datatype datatype, MPI_Op op, \
  int root, MPI_Comm comm)
```

- Operazioni predefinite: `MPI_MAX`, `MPI_MIN`, `MPI_SUM`, `MPI_PROD`, ...
- Operazioni definite dall'utente

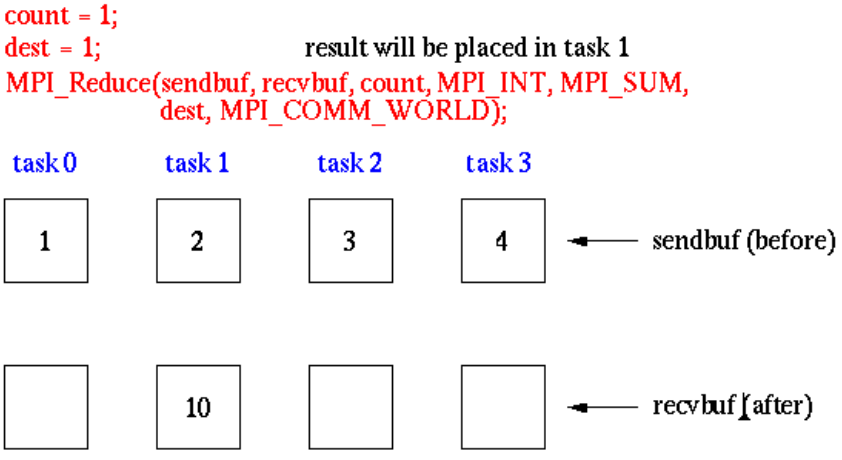

Operazioni di riduzione + replicazione

```
int MPI_Allreduce(void* sendbuf, void* recvbuf, \
  int count, MPI_Datatype datatype, \
  MPI_Op op, MPI_Comm comm)
```

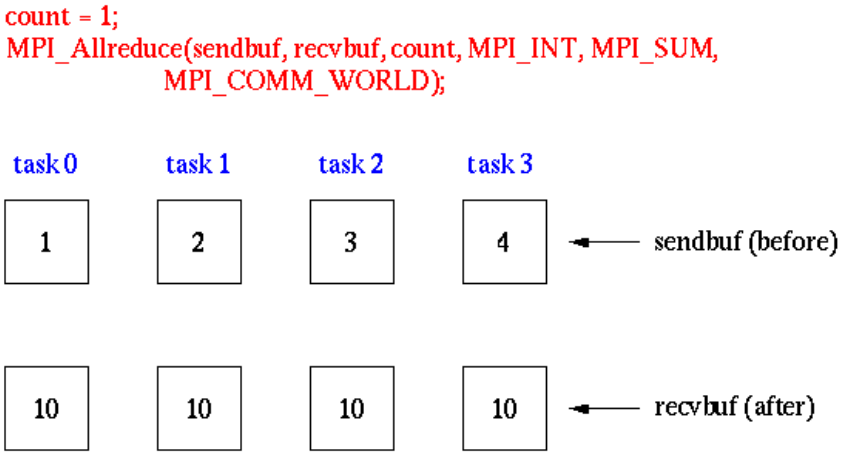


```
#define SIZE 4
int numtasks, rank, sendcount, recvcount, source;
float sendbuf[SIZE][SIZE] = {
  {1.0, 2.0, 3.0, 4.0}, {5.0, 6.0, 7.0, 8.0},
  {9.0, 10.0, 11.0, 12.0}, {13.0, 14.0, 15.0, 16.0}  };
float recvbuf[SIZE];
MPI_Init(&argc,&argv);
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
if (numtasks == SIZE) {
  source = 1;
  sendcount = 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 procs. Terminating.\n",SIZE);
MPI_Finalize();
```

Misurazione delle prestazioni

Misurare il tempo di esecuzione

double MPI_Wtime(**void**)

- I timer standard (es. POSIX) non sono adeguati per programmi MPI:
  - hanno accuratezza insufficiente
  - non sono portabili
- Ritorna il tempo locale (in secondi) trascorso da un istante prefissato
- Non ha senso in termini assoluti
- Occorre misurare intervalli di tempo come differenza

Accuratezza della misurazione

double MPI_Wtick(**void**)

- Restituisce la risoluzione del timer in secondi

Misurazione delle prestazioni

Esempio 5

```
double t0, t1, time;
...
t0 = MPI_Wtime();
if (myproc == 0) {
  MPI_Send(a, size, MPI_DOUBLE, 1, 0, MPI_COMM_WORLD);
  MPI_Recv(b, size, MPI_DOUBLE, 1, 0, MPI_COMM_WORLD, &st);
} else {
  MPI_Recv(b, size, MPI_DOUBLE, 0, 0, MPI_COMM_WORLD, &st);

  /* do something */

  MPI_Send(b, size, MPI_DOUBLE, 0, 0, MPI_COMM_WORLD);
}
t1 = MPI_Wtime();
time = 1.e6 * (t1 - t0);
printf("That took %f useconds\n",time);
```

C'è altro?

- Lo standard MPI-1 prevede più di 100 primitive!!!
- Lo standard MPI-2 ne prevede un numero ancor maggiore
- Molte implementazioni MPI prevedono primitive aggiuntive

- Altre modalità di comunicazione punto-punto
- ... e le loro versioni non bloccanti
- Comunicazioni collettive vettoriali
- Tipi di dato derivati
- Operazioni di riduzione derivate
- Gestione dei comunicatori
- Topologie virtuali
- ...

Sommario

Moltiplicazione di matrici
Definizione del problema

Siano date tre matrici dense $\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C} \in \mathbb{R}^{m \times m}$

Vogliamo calcolare $\mathbf{C} \leftarrow \mathbf{A} \times \mathbf{B}$ utilizzando n processi di calcolo (supponiamo m divisibile per n)

Occorre definire:

1. Il formato di input/output
2. L'algoritmo parallelo:
   - Come distribuire i dati tra i processi
   - Cosa fa ciascun processo
   - Quali dati occorre scambiare

Moltiplicazione di matrici
Distribuzione dei dati

La scelta di come distribuire i dati tra i processi dipende da:

- Eventuali **vincoli** sul formato in input/output
- Proprietà dell'algoritmo
- **Tradeoff** tra comunicazione e replicazione
- Semplicità implementativa

Esempi di distribuzione di matrici tra 4 processi:

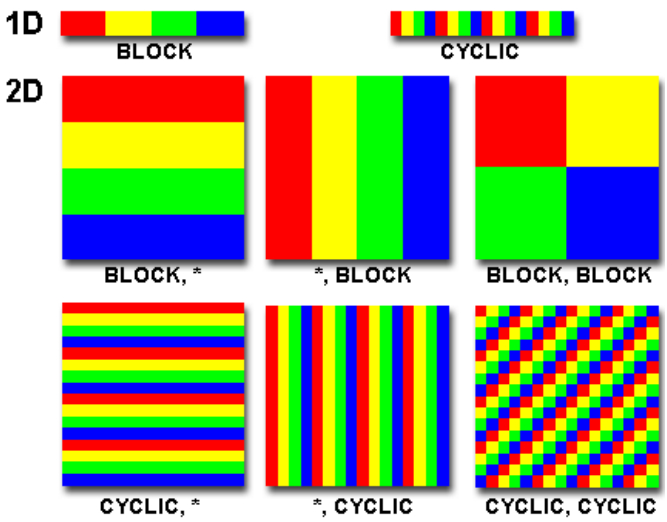

Moltiplicazione di matrici
Algoritmo naïve master/slave

Distribuzione 2D a blocchi su righe di $\mathbf{A}$ e $\mathbf{C}$ (con replicazione)

- Il processo p ottiene $\mathbf{A}(p) \in \mathbb{R}^{\frac{m}{n} \times m}$
- La matrice $\mathbf{B}$ viene replicata
- Calcola $\mathbf{C}(p) \leftarrow \mathbf{A}(p) \times \mathbf{B}$

Master $p = 0$

1. Legge $\mathbf{A}$ e $\mathbf{B}$ da un file
2. Distribuisce $\mathbf{A}(\mathbf{p})$ al processo p
3. Replica $\mathbf{B}$ in ciascun processo
4. Calcola $\mathbf{C}(0) \leftarrow \mathbf{A}(0) \times \mathbf{B}$
5. Raccoglie $\mathbf{C}(\mathbf{p})$ dal processo p
6. Scrive $\mathbf{C}$ in un file

Moltiplicazione di matrici
Algoritmo naïve master/slave

Distribuzione 2D a blocchi su righe di $\mathbf{A}$ e $\mathbf{C}$ (con replicazione)

- Il processo p ottiene $\mathbf{A}(p) \in \mathbb{R}^{\frac{m}{n} \times m}$
- La matrice $\mathbf{B}$ viene replicata
- Calcola $\mathbf{C}(p) \leftarrow \mathbf{A}(p) \times \mathbf{B}$

Master $p = 0$

1. Legge $\mathbf{A}$ e $\mathbf{B}$ da un file
2. Distribuisce $\mathbf{A}(\mathbf{p})$ al processo p (**MPI_Scatter**)
3. Replica $\mathbf{B}$ in ciascun processo (**MPI_Bcast**)
4. Calcola $\mathbf{C}(0) \leftarrow \mathbf{A}(0) \times \mathbf{B}$
5. Raccoglie $\mathbf{C}(\mathbf{p})$ dal processo p (**MPI_Gather**)
6. Scrive $\mathbf{C}$ in un file

Moltiplicazione di matrici
Algoritmo naïve master/slave

Distribuzione 2D a blocchi su righe di $\mathbf{A}$ e $\mathbf{C}$ (con replicazione)

- Il processo p ottiene $\mathbf{A}(p) \in \mathbb{R}^{\frac{m}{n} \times m}$
- La matrice $\mathbf{B}$ viene replicata
- Calcola $\mathbf{C}(p) \leftarrow \mathbf{A}(p) \times \mathbf{B}$

Slave $p > 0$

1. ...
2. Ottiene $\mathbf{A}(\mathbf{p})$ distribuito dal master
3. Ottiene $\mathbf{B}$ replicato dal master
4. Calcola $\mathbf{C}(p) \leftarrow \mathbf{A}(p) \times \mathbf{B}$
5. Invia $\mathbf{C}(\mathbf{p})$ al master che lo raccoglie
6. ...

Moltiplicazione di matrici
Algoritmo naïve master/slave

Distribuzione 2D a blocchi su righe di $\mathbf{A}$ e $\mathbf{C}$ (con replicazione)

- Il processo p ottiene $\mathbf{A}(p) \in \mathbb{R}^{\frac{m}{n} \times m}$
- La matrice $\mathbf{B}$ viene replicata
- Calcola $\mathbf{C}(p) \leftarrow \mathbf{A}(p) \times \mathbf{B}$

Slave $p > 0$

1. ...
2. Ottiene $\mathbf{A}(\mathbf{p})$ distribuito dal master (**MPI_Scatter**)
3. Ottiene $\mathbf{B}$ replicato dal master (**MPI_Bcast**)
4. Calcola $\mathbf{C}(p) \leftarrow \mathbf{A}(p) \times \mathbf{B}$
5. Invia $\mathbf{C}(\mathbf{p})$ al master che lo raccoglie (**MPI_Gather**)
6. ...

Moltiplicazione di matrici
Variante senza replicazione

Distribuzione 2D a blocchi su righe di $\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C}$

- Il processo p ottiene $\mathbf{A}(p), \mathbf{B}(p) \in \mathbb{R}^{\frac{m}{n} \times m}$
- Calcola $\mathbf{C}(p) \leftarrow \sum_q \mathbf{A}(p,q) \times \mathbf{B}(q)$
- Il processo p necessita di $\mathbf{B}(q)$ durante il calcolo di $\mathbf{C}(p)$, $\forall q \neq p$

Per ogni $q = 0 \ldots n-1$

1. Se $p = q$ distribuisco $\mathbf{B}(p)$ a $\forall q \neq p$
2. Se $p \neq q$ ottengo $\mathbf{B}(q)$ da q
3. Calcola $\mathbf{C}(p) \leftarrow \mathbf{C}(p) + \mathbf{A}(p,q) \times \mathbf{B}(q)$

Notare che ogni processo memorizza solo 2 blocchi di $\mathbf{B}$

Moltiplicazione di matrici
Variante senza replicazione

Distribuzione 2D a blocchi su righe di $\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C}$

- Il processo p ottiene $\mathbf{A}(p), \mathbf{B}(p) \in \mathbb{R}^{\frac{m}{n} \times m}$
- Calcola $\mathbf{C}(p) \leftarrow \sum_q \mathbf{A}(p,q) \times \mathbf{B}(q)$
- Il processo p necessita di $\mathbf{B}(q)$ durante il calcolo di $\mathbf{C}(p)$, $\forall q \neq p$

Per ogni $q = 0 \ldots n-1$

1. Se $p = q$ distribuisco $\mathbf{B}(p)$ a $\forall q \neq p$ (**MPI_Bcast**)
2. Se $p \neq q$ ottengo $\mathbf{B}(q)$ da q (**MPI_Bcast**)
3. Calcola $\mathbf{C}(p) \leftarrow \mathbf{C}(p) + \mathbf{A}(p,q) \times \mathbf{B}(q)$

Notare che ogni processo memorizza solo 2 blocchi di $\mathbf{B}$

Francesco Versaci (Università di Padova) Laboratorio di Calcolo Parallelo – Lezione 2 6 maggio 2009 28 / 31

Moltiplicazione di matrici
Algoritmo di Cannon

Distribuzione 2D a blocchi su righe e colonne di $\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C}$

- Assumiamo $n = s^2$ e n è divisibile per s
- I processi sono disposti (virtualmente) in una griglia 2D
- Il processo (i, j) ottiene $\mathbf{A}(i, j), \mathbf{B}(i, j) \in \mathbb{R}^{\frac{m}{s} \times \frac{m}{s}}$
- Calcola $\mathbf{C}(i, j) \leftarrow \sum_k \mathbf{A}(i, k) \times \mathbf{B}(k, j)$

Inizializzazione:

1. Il processo (i, j) ruota ciclicamente a sx la riga i di $\mathbf{A}$ di i posizioni
2. Il processo (i, j) ruota ciclicamente in su la colonna j di $\mathbf{B}$ di j posizioni

NOTA

Le rotazioni sovrascrivono $\mathbf{A}(i, j)$ e $\mathbf{B}(i, j)$

Moltiplicazione di matrici
Algoritmo di Cannon

Distribuzione 2D a blocchi su righe e colonne di $\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C}$

- Assumiamo $n = s^2$ e n è divisibile per s
- I processi sono disposti (virtualmente) in una griglia 2D
- Il processo (i, j) ottiene $\mathbf{A}(i, j), \mathbf{B}(i, j) \in \mathbb{R}^{\frac{m}{s} \times \frac{m}{s}}$
- Calcola $\mathbf{C}(i, j) \leftarrow \sum_k \mathbf{A}(i, k) \times \mathbf{B}(k, j)$

Inizializzazione:

1. Il processo (i, j) ruota ciclicamente a sx la riga i di $\mathbf{A}$ di i posizioni (**MPI_Send** e **MPI_Recv**)
2. Il processo (i, j) ruota ciclicamente in su la colonna j di $\mathbf{B}$ di j posizioni (**MPI_Send** e **MPI_Recv**)

NOTA

Le rotazioni sovrascrivono $\mathbf{A}(i, j)$ e $\mathbf{B}(i, j)$

Francesco Versaci (Università di Padova) Laboratorio di Calcolo Parallelo – Lezione 2 6 maggio 2009 29 / 31

Moltiplicazione di matrici
Algoritmo di Cannon

Distribuzione 2D a blocchi su righe e colonne di $\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C}$

- Assumiamo $n = s^2$ e n è divisibile per s
- I processi sono disposti (virtualmente) in una griglia 2D
- Il processo (i, j) ottiene $\mathbf{A}(i, j), \mathbf{B}(i, j) \in \mathbb{R}^{\frac{m}{s} \times \frac{m}{s}}$
- Calcola $\mathbf{C}(i, j) \leftarrow \sum_k \mathbf{A}(i, k) \times \mathbf{B}(k, j)$

Per s volte il processo (i, j) ripete:

1. Calcola $\mathbf{C}(i, j) \leftarrow \mathbf{C}(i, j) + \mathbf{A}(i, j) \times \mathbf{B}(i, j)$
2. Ruota ciclicamente a sx la riga i di $\mathbf{A}$ di 1 posizione
3. Ruota ciclicamente in su la colonna j di $\mathbf{B}$ di 1 posizione

NOTA

Le rotazioni sovrascrivono $\mathbf{A}(i, j)$ e $\mathbf{B}(i, j)$

Moltiplicazione di matrici
Esempio: Algoritmo di Cannon

Distribuzione iniziale:

A(0,0)	A(0,1)	A(0,2)
A(1,0)	A(1,1)	A(1,2)
A(2,0)	A(2,1)	A(2,2)

B(0,0)	B(0,1)	B(0,2)
B(1,0)	B(1,1)	B(1,2)
B(2,0)	B(2,1)	B(2,2)

Dopo l'inizializzazione:

A(0,0)	A(0,1)	A(0,2)
A(1,1)	A(1,2)	A(1,0)
A(2,2)	A(2,0)	A(2,1)

B(0,0)	B(1,1)	B(2,2)
B(1,0)	B(2,1)	B(0,2)
B(2,0)	B(0,1)	B(1,2)

Moltiplicazione di matrici
Esempio: Algoritmo di Cannon

Step 1:

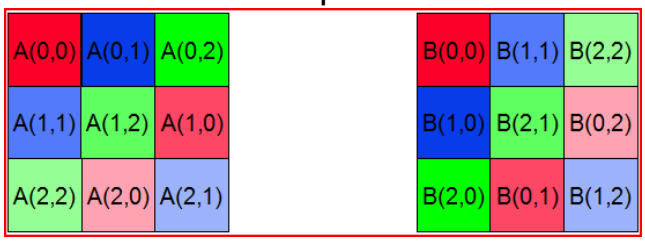

Step 2:

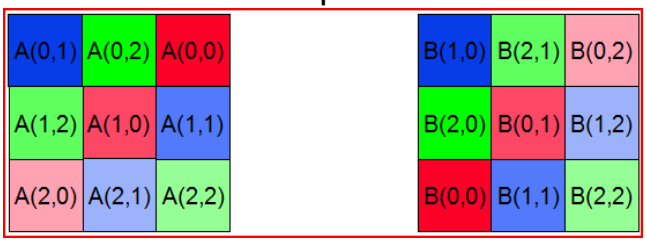

Step 3:

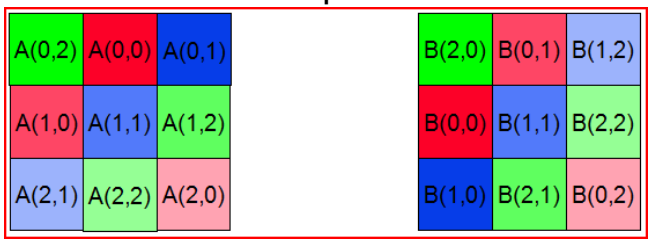

Riferimenti

- Per lo standard:
  `http://www.mpi-forum.org/docs`
- Tutorial:
  `https://computing.llnl.gov/tutorials/mpi`
- Per l'implementazione IBM:
  `http://www.dei.unipd.it/~addetto/manuali_online/index.html`
- In particolare:
  `http://www.redbooks.ibm.com/redbooks/pdfs/sg245380.pdf`