CINECA SCAI
SuperComputing Applications and Innovation

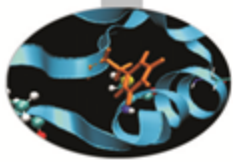

Introduzione al Calcolo Parallelo con MPI

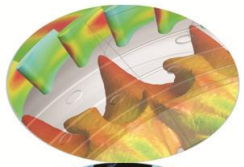
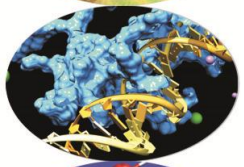
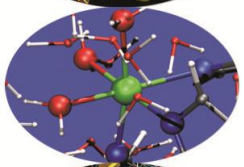
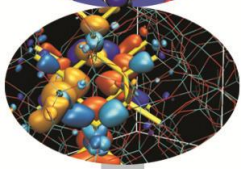

Claudia Truini
c.truini@cineca.it

Cristiano Padrin
c.padrin@cineca.it

Master in Calcolo Scientifico

CINECA

Gruppo di collaboratori → Calcolo Parallelo

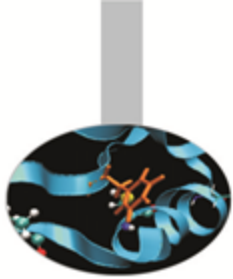

- Il calcolo parallelo, in generale, è l'uso simultaneo di più processi per risolvere un unico problema computazionale
- Per girare con più processi, un problema è diviso in parti discrete che possono essere risolte concorrentemente
- Le istruzioni che compongono ogni parte sono eseguite contemporaneamente su processi diversi
- Benefici:
  - si possono risolvere problemi più "grandi", superando i vincoli di memoria
  - si riduce il tempo di calcolo

Collaboratori scambiano messaggi → Message-passing

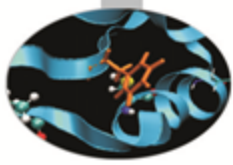

N processi cooperano scambiando messaggi

- Ogni processo svolge autonomamente la parte indipendente del task
- Ogni processo accede in lettura e scrittura ai soli dati disponibili nella sua memoria
- E' necessario ***scambiare messaggi*** tra i processi coinvolti quando
  - un processo deve accedere ad un dato presente nella memoria di un altro processo
  - più processi devono sincronizzarsi per l'esecuzione di un flusso d'istruzioni

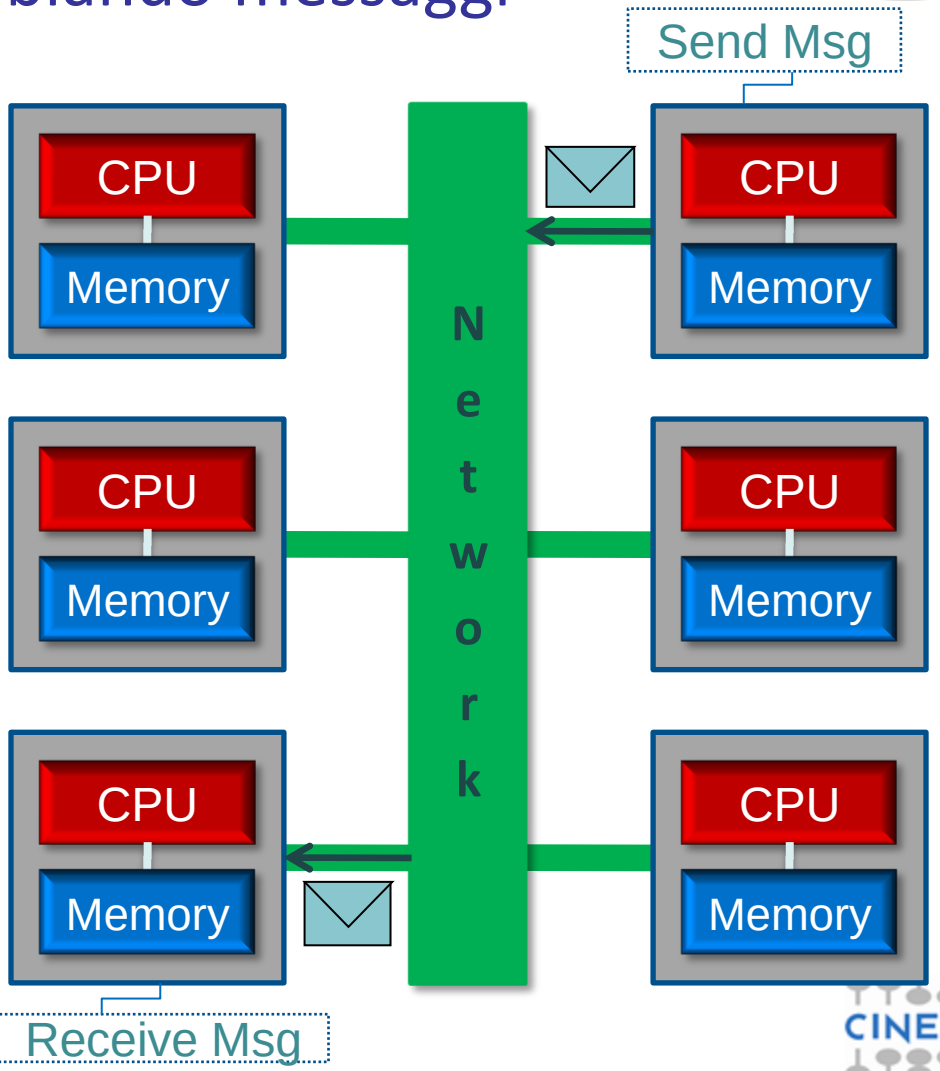

Modello di esecuzione: SPMD

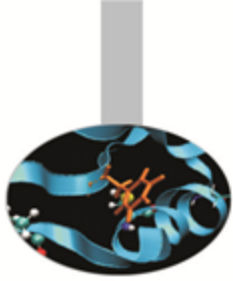

SPMD = Single Program Multiple Data

Ogni processo esegue lo stesso programma, ma opera in generale su dati diversi (nella propria memoria locale)

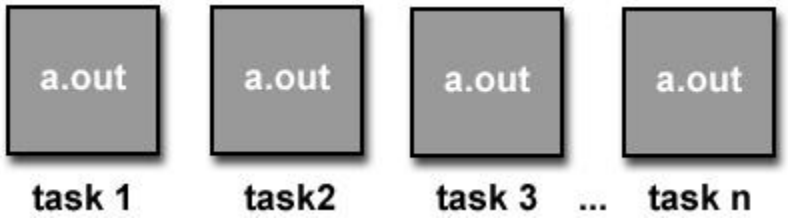

Processi differenti possono eseguire parti di codice differenti:

```
if (I am process 1)
   … do something …
if (I am process 2)
   … do something else …
```

Cos'è MPI

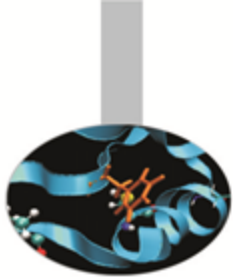

- **MPI:**
  - **MPI** è acronimo di **M***essage* **P***assing* **I***nterface*
  - **MPI** è una Application Programming Interface (API)
  - ***Standard*** per sviluppatori ed utenti
    http://www.mpi-forum.org

- **Calcolo Parallelo con MPI**
  - MPI è uno strumento di programmazione che permette di implementare il modello di calcolo parallelo appena descritto
  - MPI consente di:
    - generare e gestire il gruppo di collaboratori (processi)
    - scambiare dati tra loro

Funzionalità di MPI

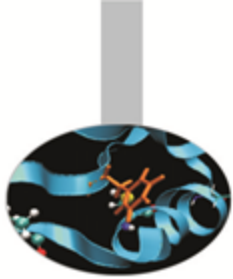

La libreria MPI fornisce:

- Funzioni di management della comunicazione
  - Definizione/identificazione di gruppi di processi (comunicatori) coinvolti nella comunicazione
  - Definizione/gestione dell'identità del singolo processo, all'interno di un gruppo
- Funzioni di scambio messaggi
  - Inviare/ricevere dati da un processo
  - Inviare/ricevere dati da un gruppo di processi
- Nuovi tipi di dati e costanti (macro) che semplificano la vita al programmatore

Formato delle chiamate MPI

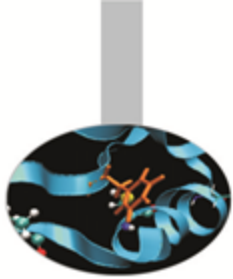

- In C:

  `err = MPI_Xxxxx(parameter, …)`

  - **`MPI_`** è prefisso di tutte le funzioni MPI
  - Dopo il prefisso, la prima lettera è maiuscola e tutte le altre minuscole
  - Praticamente tutte le funzioni MPI tornano un codice d'errore intero
  - Le macro sono scritte tutte in maiuscolo

- In Fortran:

  `call MPI_XXXX(parameter,…, err)`

  - **`MPI_`** è prefisso di tutte le subroutine MPI
  - Anche se il Fortran è *case insensitive*, le subroutine e le costanti MPI sono convenzionalmente scritte in maiuscolo
  - L'ultimo parametro è il codice d'errore (**`INTEGER`**)

Constants & Defaults

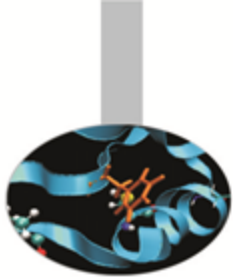

- Tutti i programmi che usano MPI devono includere *l'header file* (o *modulo*) standard
  - C: **mpi.h**
  - Fortran: **mpif.h**
  - Fortran: **use mpi** (no Fortran 77)
  - Fortran: **use mpi_f08** ← da MPI 3.0

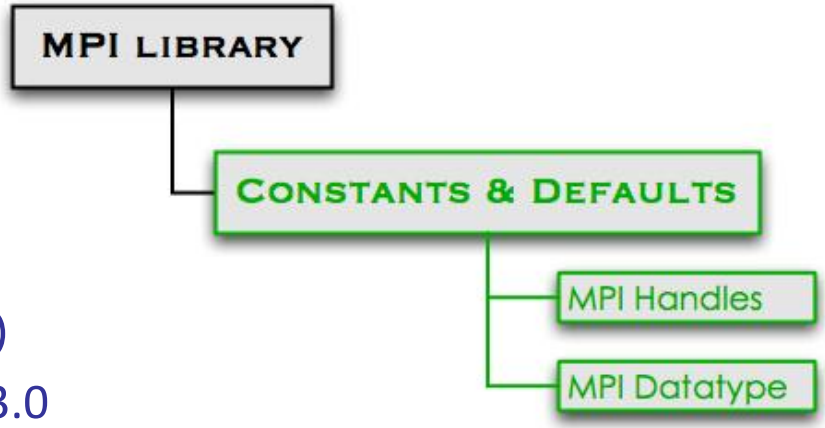

- Nell'*header file* standard sono contenute **definizioni**, **macro** e **prototipi di funzioni** necessari per la compilazione di un programma MPI
  - MPI mantiene strutture di dati interne legate alla comunicazione, referenziabili tramite *MPI Handles*
  - MPI referenzia i tipi di dati standard dei linguaggi C/Fortran attraverso *MPI Datatype*

Communication Environment

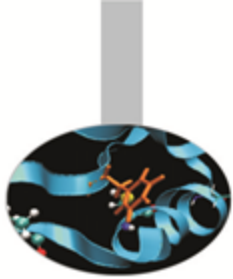

- **`MPI_Init`**
  - inizializza l'ambiente di comunicazione
  - tutti i programmi MPI devono contenere una sua chiamata
  - deve essere chiamata prima di qualsiasi altra routine MPI
  - deve essere chiamata una sola volt

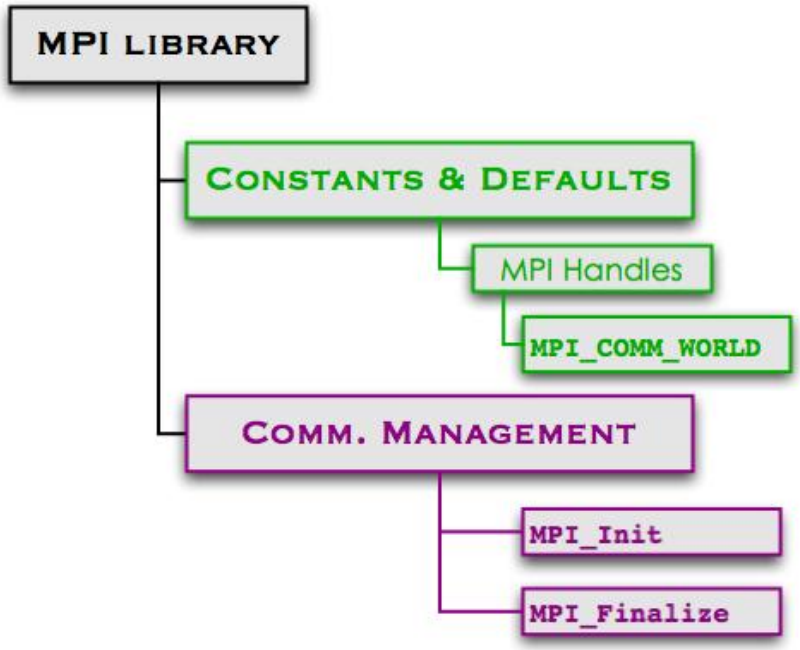

- **`MPI_Finalize`**
  - termina l'ambiente MPI
  - conclude la fase di comunicazione
  - provvede al rilascio pulito dell'ambiente di comunicazione
  - non è possibile eseguire ulteriori funzione MPI dopo la `MPI_Finalize`

MPI_Init e MPI_Finalize

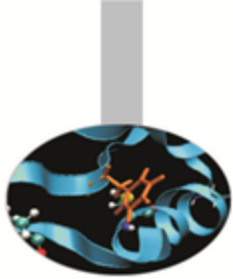

In C

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

```
int MPI_Finalize(void)
```

In Fortran

```
INTEGER err
MPI_INIT(err)
```

```
INTEGER err
MPI_FINALIZE(err)
```

In C, la funzione **`MPI_Init`** esegue il parsing degli argomenti forniti al programma da linea di comando

Comunicatori

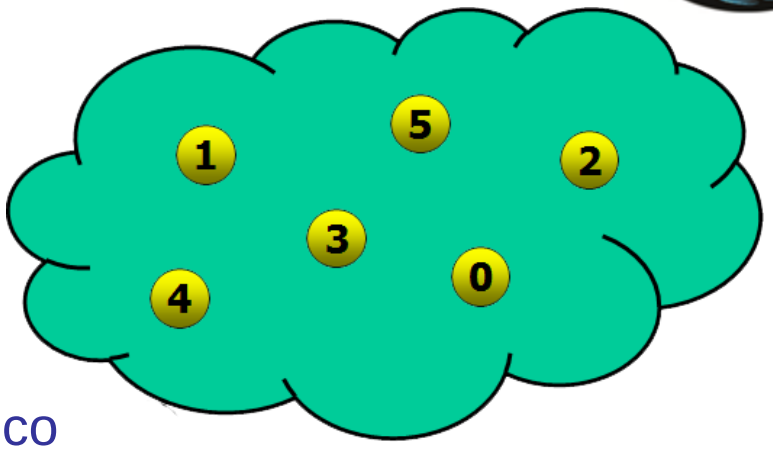

- Un comunicatore è un “oggetto” contenente un *gruppo* di processi ed un set di attributi associati
- All’interno di un comunicatore ogni processo ha un identificativo unico
- Due o più processi possono comunicare solo se fanno parte dello stesso comunicatore
- La funzione MPI_Init inizializza il comunicatore di *default* `MPI_COMM_WORLD`, che comprende tutti i processi che partecipano al job parallelo
- In un programma MPI può essere definito più di un comunicatore

Informazioni dal comunicatore

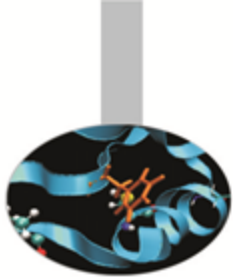

- *Communicator size*
  - La *size* di un comunicatore è la dimensione del gruppo di processi in esso contenuti
  - Un processo può determinare la *size* di un comunicatore di cui fa parte con una chiamata alla funzione **`MPI_Comm_size`**
  - La *size* di un comunicatore è un intero

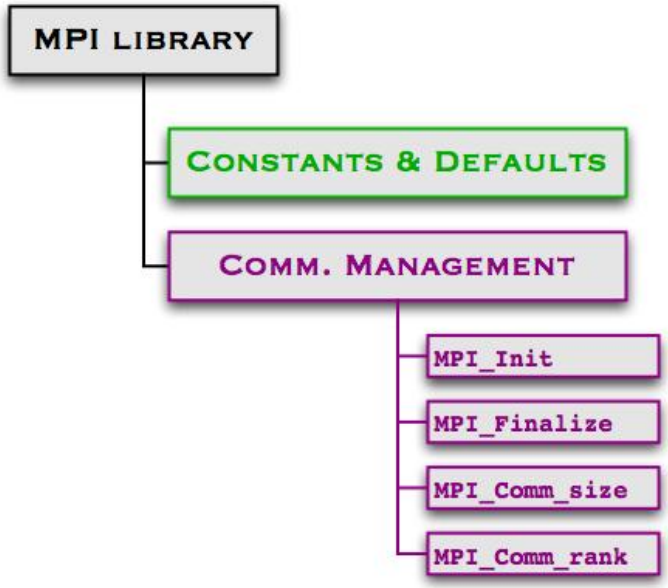

- *Process rank*
  - Un processo può determinare il proprio identificativo (*rank*) in un comunicatore con una chiamata a **`MPI_Comm_rank`**
  - I *rank* dei processi che fanno parte di un comunicatore sono numeri interi, consecutivi a partire da 0

MPI_Comm_size e MPI_Comm_rank

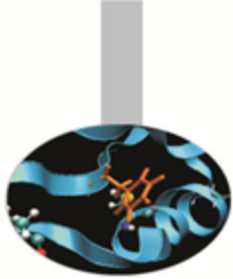

In C

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

In Fortran

```
MPI_COMM_SIZE(comm, size, err)
MPI_COMM_RANK(comm, rank, err)
```

- Input:
  - **comm** è di tipo **MPI_Comm** (INTEGER) ed è il comunicatore di cui si vuole conoscere la dimensione o all'interno del quale si vuole conoscere il rank del processo chiamante
- Output:
  - **size** è di tipo **int** (INTEGER) e conterrà la dimensione di **comm**
  - **rank** è di tipo **int** (INTEGER) e conterrà il *rank* nel comunicatore **comm** del processo chiamante

Il primo programma MPI

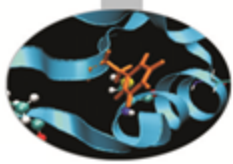

Operazioni da eseguire:

1. Inizializzare l'ambiente MPI
2. Richiedere al comunicatore di default il *rank* del processo
3. Richiedere al comunicatore di default la sua *size*
4. Stampare una stringa con le informazioni ottenute
5. Chiudere l'ambiente MPI

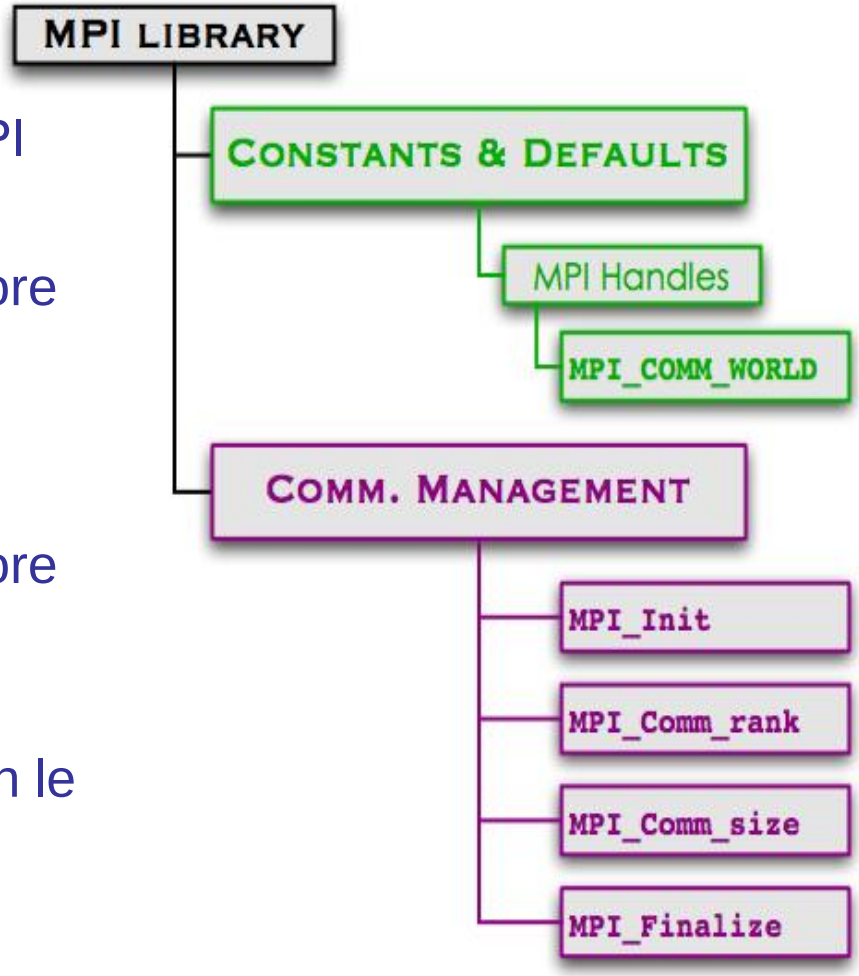

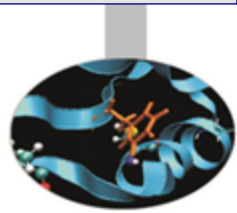

La versione in C …

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

  int myrank, size;

  /* 1. Initialize MPI */
  MPI_Init(&argc, &argv);

  /* 2. Get my rank */
  MPI_Comm_rank(MPI_COMM_WORLD, &myrank);

  /* 3. Get the total number of processes */
  MPI_Comm_size(MPI_COMM_WORLD, &size);

 /* 4. Print myrank and size */
  printf("Process %d of %d \n", myrank, size);

  /* 5. Terminate MPI */
  MPI_Finalize();
}
```

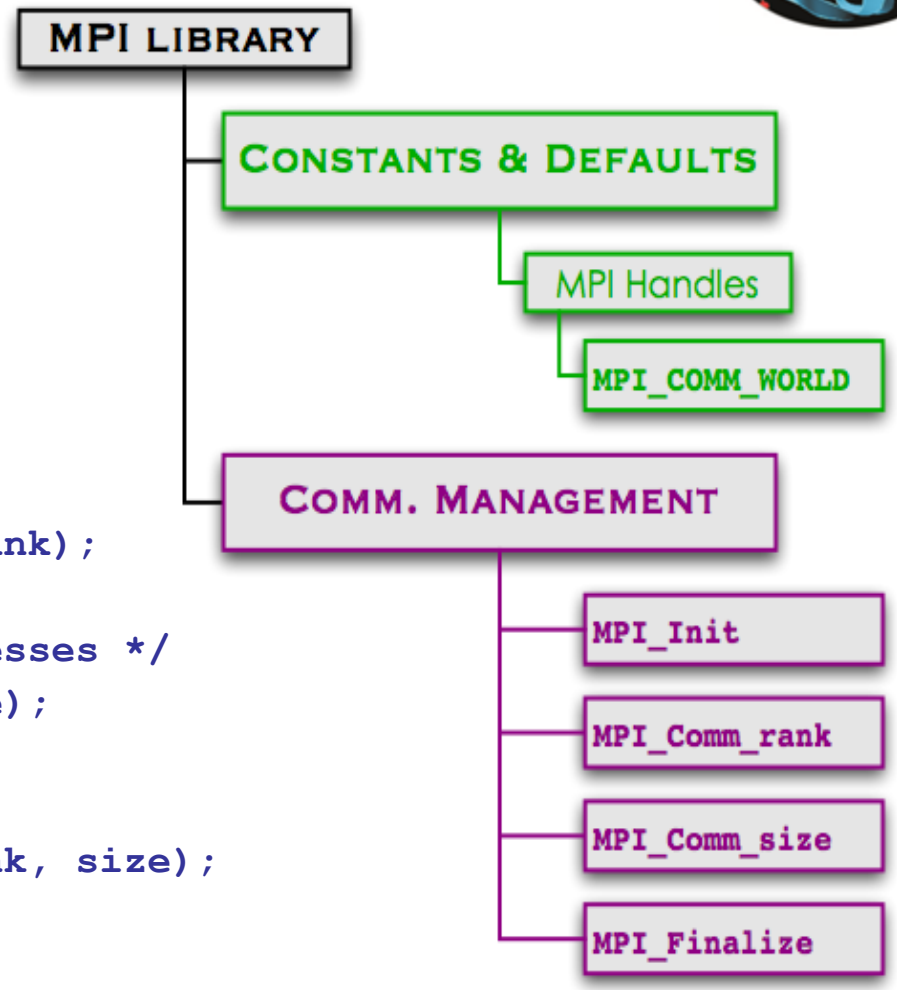

.. e quella in Fortran 77

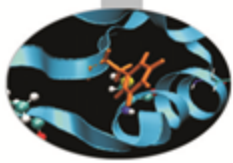

```
 PROGRAM hello

    INCLUDE 'mpif.h'
    INTEGER myrank, size, ierr

C 1. Initialize MPI:
    call MPI_INIT(ierr)

C 2. Get my rank:
    call MPI_COMM_RANK(MPI_COMM_WORLD, myrank, ierr)

C 3. Get the total number of processes:
    call MPI_COMM_SIZE(MPI_COMM_WORLD, size, ierr)

C 4. Print myrank and size
    PRINT *, "Process", myrank, "of", size, "

C 5. Terminate MPI:
    call MPI_FINALIZE(ierr)
    END
```

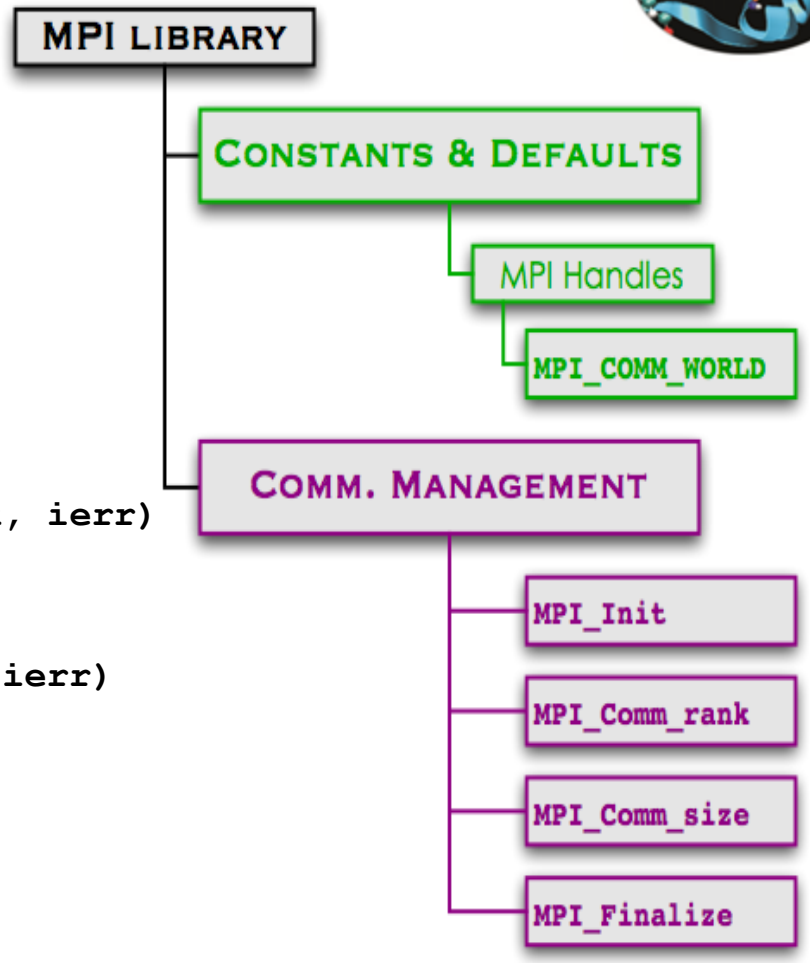

La comunicazione interprocesso

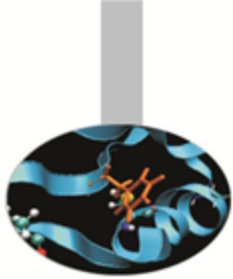

- Nella programmazione parallela ***message passing***
  la cooperazione tra processi avviene attraverso operazioni esplicite di comunicazione interprocesso

- L'operazione elementare di comunicazione è: ***point-to-point***
  - vede coinvolti due processi:
    - Il processo *sender* ***invia un messaggio***
    - Il processo *receiver* ***riceve il messaggio*** inviato

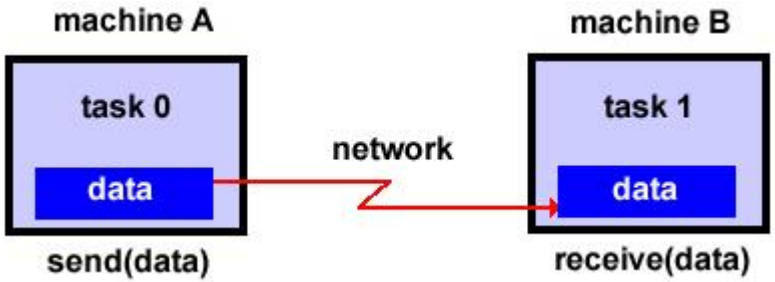

Cos'è un messaggio

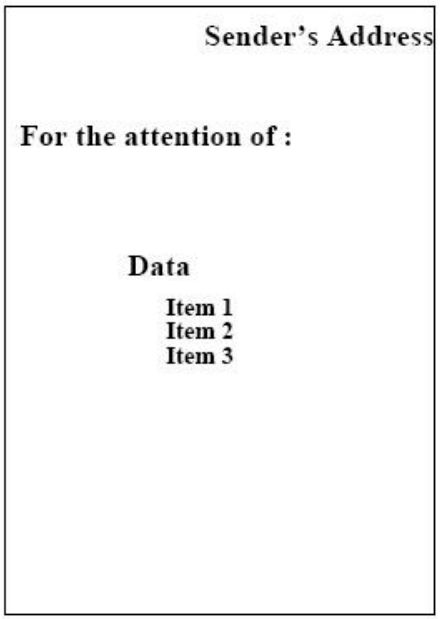

- Un messaggio è un blocco di dati da trasferire tra i processi
- È costituito da:
  - ***Envelope,*** che contiene
    - ***source***: l'identificativo del processo che lo invia
    - ***destination***: l'identificativo del processo che lo deve ricevere
    - ***communicator***: l'identificativo del gruppo di processi cui appartengono sorgente e destinazione del messaggio
    - ***tag***: un identificativo che classifica il messaggio
  - ***Body***, che contiene
    - ***buffer***: i dati del messaggio
    - ***datatype***: il tipo di dati contenuti nel messaggio
    - ***count***: il numero di occorrenze di tipo *datatype* contenute nel messaggio

I principali *MPI Datatype*

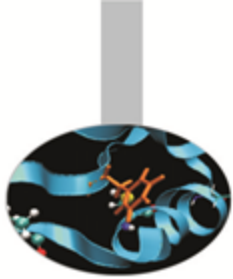

In C

MPI Datatype	C Type
MPI_INT	signed int
MPI_FLOAT	float
MPI_DOUBLE	double
MPI_CHAR	signed char
MPI_UNSIGNED_LONG	unsigned long int

In Fortran

MPI Datatype	Fortran Type
MPI_INTEGER	INTEGER
MPI_REAL	REAL
MPI_DOUBLE_PRECISION	DOUBLE PRECISION
MPI_CHARACTER	CHARACTER(1)
MPI_LOGICAL	LOGICAL

I passi di una comunicazione *point-to-point*

Per inviare/ricevere un messaggio:

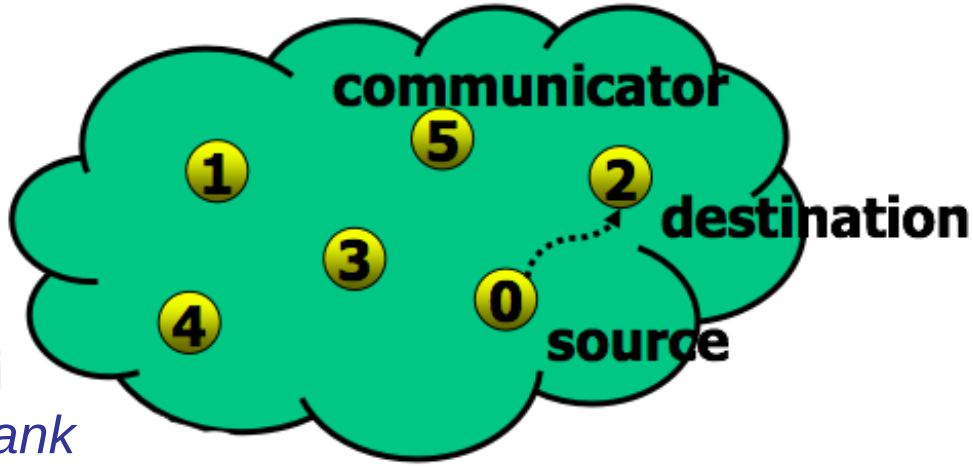

- il processo ***source*** effettua una chiamata ad una funzione MPI, in cui deve essere specificato il *rank* del processo *destination* nel comunicatore

- il processo ***destination*** deve effettuare una chiamata ad una funzione MPI per ricevere lo specifico messaggio inviato dal *source*

Inviare un messaggio

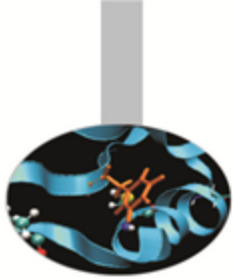

- Il processo ***source*** effettua una chiamata ad una primitiva con la quale specifica in modo univoco l'*envelope* e il *body* del messaggio da inviare:
  - l'identità della sorgente è implicita (il processo che effettua l'operazione)
  - gli altri elementi che completano la struttura del messaggio
    - identificativo del messaggio
    - identità della destinazione
    - comunicatore da utilizzare

    sono determinati esplicitamente dagli argomenti che il processo sorgente passa alla funzione di *send*

Ricevere un messaggio

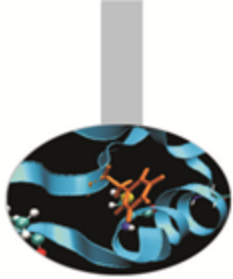

- Il processo destinazione chiama una primitiva, dai cui argomenti è determinato “in maniera univoca” l’*envelope* del messaggio da ricevere
- MPI confronta l’*envelope* del messaggio in ricezione con quelli dell’insieme dei messaggi ancora da ricevere (*pending messages*) e
  - se il messaggio è presente viene ricevuto
  - altrimenti l’operazione non può essere completata fino a che tra i *pending messages* ce ne sia uno con l’*envelope* richiesto
- Il processo di destinazione deve disporre di un’area di memoria sufficiente per salvare il *body* del messaggio

Binding di `MPI_Send`

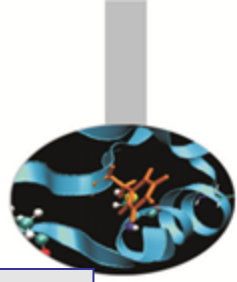

In C

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

In Fortran

```
MPI_SEND(buf, count, dtype, dest, tag, comm, err)
```

- Tutti gli argomenti sono di input
  - **`buf`** è l'indirizzo iniziale del *send* buffer
  - **`count`** è di tipo **`int`** e contiene il numero di elementi del *send* buffer
  - **`dtype`** è di tipo **`MPI_Datatype`** e descrive il tipo di ogni elemento del *send* buffer
  - **`dest`** è di tipo **`int`** e contiene il *rank* del *receiver* all'interno del comunicatore **`comm`**
  - **`tag`** è di tipo **`int`** e contiene l'identificativo del messaggio
  - **`comm`** è di tipo **`MPI_Comm`** ed è il comunicatore in cui avviene la *send*

Binding di `MPI_Recv`

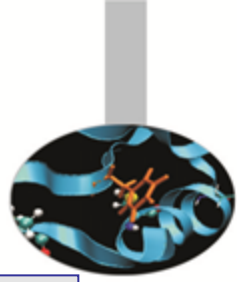

In C

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

In Fortran

```
MPI_RECV(buf, count, dtype, src, tag, comm, status, err)
```

- [OUT] **buf** è l'indirizzo iniziale del *receive* buffer
- [IN] **count** è di tipo **int** e contiene il numero di elementi del *receive* buffer
- [IN] **dtype** è di tipo **MPI_Datatype** e descrive il tipo di ogni elemento del *receive* buffer
- [IN] **src** è di tipo **int** e contiene il *rank* del *sender* all'interno del comunicatore **comm**
- [IN] **tag** è di tipo **int** e contiene l'identificativo del messaggio
- [IN] **comm** è di tipo **MPI_Comm** ed è il comunicatore in cui avviene la *send*
- [OUT] **status** è di tipo **MPI_Status** (`INTEGER(MPI_STATUS_SIZE)`) e conterrà informazioni sul messaggio che è stato ricevuto

send/receive: intero (C)

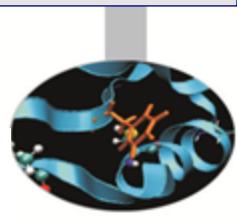

```c
#include <stdio.h>
#include <mpi.h>

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

    MPI_Status status;
    int rank, size;

    /* data to communicate */
    int     data_int;

    /* Start up MPI environment*/
    MPI_Init(&argc, &argv);

    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);

    if (rank == 0) {
        data_int = 10;
        MPI_Send(&data_int, 1, MPI_INT, 1, 666, MPI_COMM_WORLD);
    } else if (rank == 1) {
        MPI_Recv(&data_int, 1, MPI_INT, 0, 666, MPI_COMM_WORLD, &status);
        printf("Process 1 receives %d from process 0.\n", data_int);
    }

    /* Quit MPI environment*/
    MPI_Finalize();
    return 0;
}
```

send/receive: *array* di double (FORTRAN)

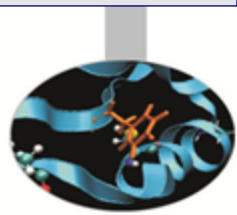

```
      program main

      implicit none
      include 'mpif.h'
      integer ierr, rank, nprocs
      integer i, j, status(MPI_STATUS_SIZE)

c--- data to communicate-------------------------------------------------------
      integer MSIZE
      parameter (MSIZE=10)
      double precision matrix(MSIZE, MSIZE)

c--- Start up MPI  ----------- -----------------------------------------------
      call MPI_INIT(ierr)
      call MPI_COMM_RANK(MPI_COMM_WORLD, rank, ierr)
      call MPI_COMM_SIZE(MPI_COMM_WORLD, nprocs, ierr)

      if (rank.eq.0) then
         do i=1,MSIZE
            do j=1,MSIZE
               matrix(i,j)= dble(i+j)
            enddo
         enddo
         CALL MPI_SEND(matrix, MSIZE*MSIZE, MPI_DOUBLE_PRECISION, 1, 666
     $        ,MPI_COMM_WORLD, ierr)
      else if (rank.eq.1) then
         CALL MPI_RECV(matrix, MSIZE*MSIZE, MPI_DOUBLE_PRECISION, 0, 666
     $        ,MPI_COMM_WORLD, status, ierr)
         print *,'Proc 1 receives the following matrix from proc 0'
         write (*,'(10(f6.2,2x))') matrix
      endif

      call MPI_FINALIZE(ierr)
      end
```

send/receive: *array* di *float* (C)

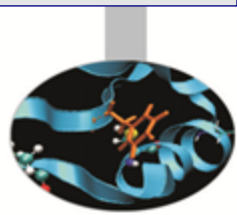

```c
#include <stdio.h>
#include <mpi.h>
#define MSIZE 10

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

    MPI_Status status;
    int rank, size;
    int i, j;

    /* data to communicate */
    float  matrix[MSIZE];

    /* Start up MPI */
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);

    if (rank == 0) {
        for (i = 0; i < MSIZE; i++)
           matrix[i] = (float)i;
        MPI_Send(matrix, MSIZE, MPI_FLOAT, 1, 666, MPI_COMM_WORLD);
    } else if (rank ==1) {
        MPI_Recv(matrix, MSIZE, MPI_FLOAT, 0, 666, MPI_COMM_WORLD, &status);
        printf("\nProcess 1 receives the following array from process 0.\n");
        for (i = 0; i < MSIZE; i++)
           printf("%6.2f\n", matrix[i]);
    }

    /* Quit MPI */
    MPI_Finalize();
    return 0;
}
```

send/receive: porzione di array (C)

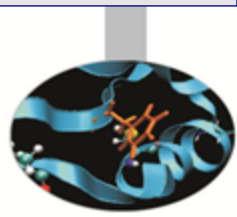

```c
#include <stdio.h>
#include <mpi.h>
#define VSIZE  50
#define BORDER 12

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

    MPI_Status status;
    int indx, rank, nprocs;
    int start_send_buf = BORDER;
    int start_recv_buf = VSIZE - BORDER;
    int length = 10;
    int vector[VSIZE];

    /* Start up MPI */
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &nprocs);

    /* all process initialize vector */
    for (indx = 0; indx < VSIZE; indx++) vector[indx] = rank;

    if (rank == 0) {
        /* send length integers starting from the "start_send_buf"-th position of vector */
        MPI_Send(&vector[start_send_buf], length, MPI_INT, 1, 666, MPI_COMM_WORLD);
    }
    if (rank == 1) {
        /* receive length integers in the "start_recv_buf"-th position of vector */
        MPI_Recv(&vector[start_recv_buf], length, MPI_INT, 0, 666, MPI_COMM_WORLD, &status);
    }

    /* Quit */
    MPI_Finalize();
    return 0;
}
```

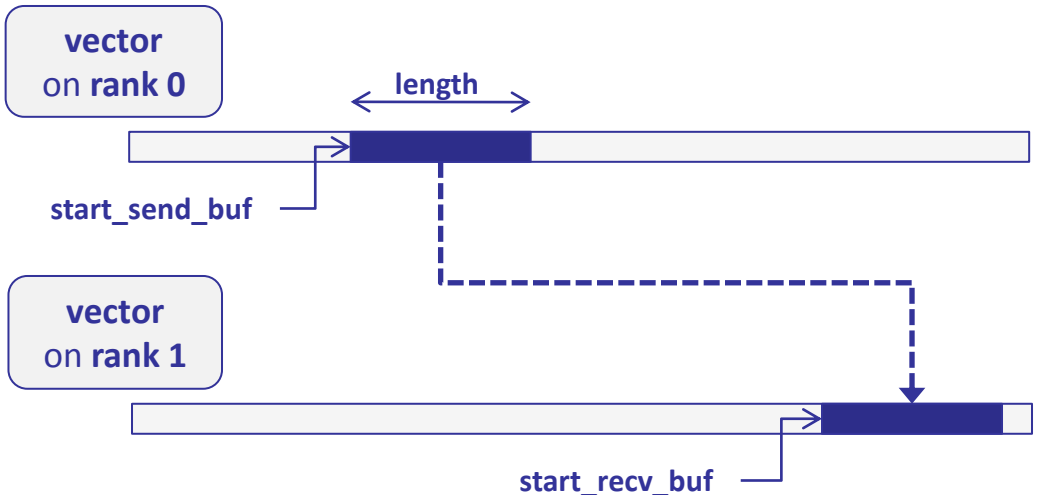

Compilare un sorgente MPI

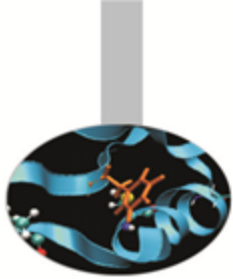

- MPI è una libreria che consiste di due componenti:
  - un archivio di funzioni
  - un *include file* con i prototipi delle funzioni, alcune costanti e *default*

- Per compilare un'applicazione MPI basterà quindi seguire le stesse procedure che seguiamo solitamente per compilare un programma che usi una libreria esterna:
  - Istruire il compilatore sul *path* degli include file (*switch* **`-I`**)
  - Istruire il compilatore sul *path* della libreria (*switch* **`-L`**)
  - Istruire il compilatore sul nome della libreria (*switch* **`-l`**)

Compilare un sorgente MPI (2)

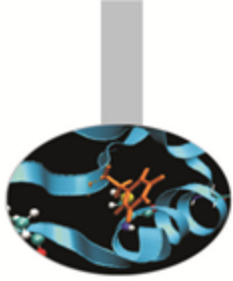

Per compilare il sorgente `sample.f` usando:

- il compilatore gnu `gfortran` (linux)
- le librerie `libmpi_f77.so` e `libmpi.so` che si trovano in `/usr/local/openmpi/lib/`
- gli include file che si trovano in `/usr/local/openmpi/include/`

utilizzeremo il comando:

```
gfortran -I/usr/local/include/ sample.f
-L/usr/local/openmpi/lib/ -lmpi_f77 -lmpi -o sample.x
```

Compilare un sorgente MPI (3)

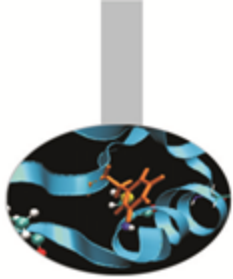

- … ma esiste un modo più comodo
- Ogni ambiente MPI fornisce un ‘compilatore’ (basato su uno dei compilatori seriali disponibili) che ha già definiti il giusto set di switch per la compilazione
- Ad esempio, usando `OpenMPI` (uno degli ambienti MPI più diffusi) per compilare `sample.F`

```
mpif90 sample.F –o sample.x
```

Eseguire un programma MPI

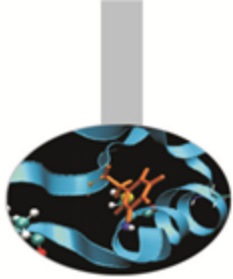

- Per eseguire un programma MPI è necessario lanciare tutti i processi (*process spawn*) con cui si vuole eseguire il calcolo in parallelo

- Ogni ambiente parallelo mette a disposizione dell'utente un ***MPI launcher***

- Il *launcher* MPI chiederà tipicamente:
  - Numero di processi
  - 'Nome' dei nodi che ospiteranno i processi
  - Stringa di esecuzione dell'applicazione parallela

Definizione dei processori su cui girare MPI

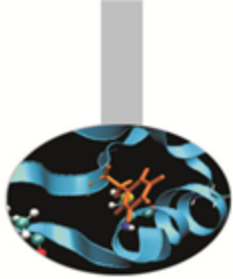

Il nome dei processori che ospiteranno i processi può essere scritto in un file con una specifica sintassi accettata dal *launcher* MPI

- Nel nostro caso si scrivono di seguito, su righe successive, i nomi delle macchine sulle quali gireranno i processi seguiti dalla *keyword* `slots=XX`, dove `XX` è il numero di processori della macchina
- Esempio:
  volendo girare 6 processi, 2 sulla macchina `node1` e 4 su node2, il file **`my_hostfile`** sarà:

```
node1 slots=2
node2 slots=4
```

Compilare ed eseguire

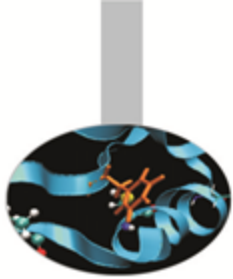

- Compilare:
  - Fortran F77 o F90 source:

```
(mpif77) mpif90 sample.F90 -o sample.x
mpifort sample.F90 -o sample.x  (da OpenMPI 1.7)
```

  - C source:

```
mpicc sample.c -o sample.x
```

  - C++ source:

```
mpic++  sample.cpp -o sample.x
```

- Eseguire:
  - il launcher OpenMPI è `mpirun` (oppure `mpiexec`):

```
mpiexec -hostfile my_hostfile -n 4 ./sample.x
```

Programma della 1° sessione di laboratorio

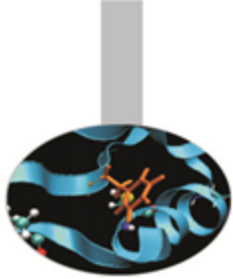

- Familiarizzare con l'ambiente MPI
  - *Hello World* in MPI (Esercizio 1)
- Esercizi da svolgere
  - *Send/Receive* di un intero e di un *array* di *float* (Esercizio 2)
  - Calcolo di π con il metodo integrale (Esercizio 3)
  - Calcolo di π con il metodo Monte Carlo (Esercizio 4)
  - *Communication Ring* (Esercizio 5)

MPI Hello World

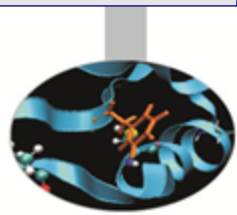

- Come si compila il codice:
  - In C:

```
mpicc helloworld.c -o hello.x
```

  - In Fortran:

```
mpif90 helloworld.f -o hello.x
```

- Come si manda in esecuzione utilizzando 4 processi:

```
mpiexec -n 4 ./hello.x
```

Send/Receive di un intero e di un array

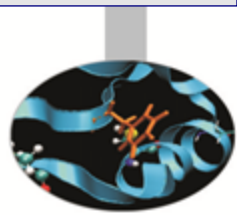

- Utilizzare tutte le sei funzioni di base della libreria MPI (MPI_Init, MPI_Finalize, MPI_Comm_rank, MPI_Comm_size, MPI_Send e MPI_Recv)
  - Provare a spedire e a ricevere dati da e in posizioni diverse dall'inizio dell'array
- Il processo con rank 0 inizializza la variabile (intero o array di float) e la spedisce al processo con rank 1
- Il processo con rank 1 riceve i dati spediti dal processo 0 e li stampa
- Provare a vedere cosa succede inviando e ricevendo quantità diverse di dati

Send/Receive di quantità diverse di dati

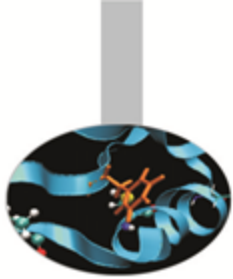

- Cosa succede se la lunghezza del messaggio ricevuto (r_count) è diversa dalla lunghezza del messaggio spedito (s_count) ?
  - Se s_count < r_count → solo le prime s_count locazioni di r_buf sono modificate
  - Se s_count > r_count → errore overflow

Inoltre

- La lunghezza del messaggio ricevuto (count) deve essere minore o uguale alla lunghezza del receive buffer (buf)
  - Se count < buf → solo le prime count locazioni di buf sono modificate
  - Se count > buf → errore overflow

- Per conoscere, al termine di una receive, la lunghezza del messaggio effettivamente ricevuto si può analizzare l'argomento **status**

Argomento status del recv

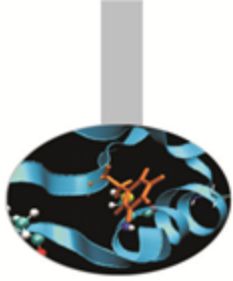

- struct in C e array of integer di lunghezza MPI_STATUS_SIZE in Fortran
- status contiene direttamente 3 field, più altre informazioni:
  - MPI_TAG
  - MPI_SOURCE
  - MPI_ERROR
- Per conoscere la lunghezza del messaggio ricevuto si utilizza la funzione MPI_GET_COUNT

In C

```
int MPI_Get_count(MPI_Status *status, MPI_Datatype
 dtype, int *count)
```

In Fortran

```
MPI_GET_COUNT(status, dtype, count, err)
```

  - [IN]: status, dtype [OUT]: count

Calcolo di π con il metodo integrale

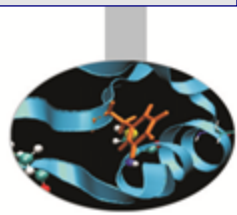

- Il valore di π può essere calcolato tramite l'integrale

$$\int_0^1 \frac{4}{1+x^2}\,dx = 4\cdot\arctan(x)\,|_0^1 = \pi$$

- In generale, se f è integrabile in [a,b]

$$\int_a^b f(x)dx = \lim_{N\to\infty} \sum_{i=1}^{N} f_i \cdot h \quad \text{con} \quad f_i = f(a+ih) \;\text{ e }\; h = \frac{b-a}{N}$$

- Dunque, per N sufficientemente grande

$$\pi \cong \sum_{i=1}^{N} \frac{4\cdot h}{1+(ih)^2} \quad \text{con} \quad h = \frac{1}{N}$$

Calcolo di π in seriale con il metodo integrale

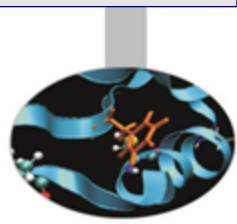

- L'intervallo [0,1] è diviso in N sotto intervalli, di dimensione h=1/N

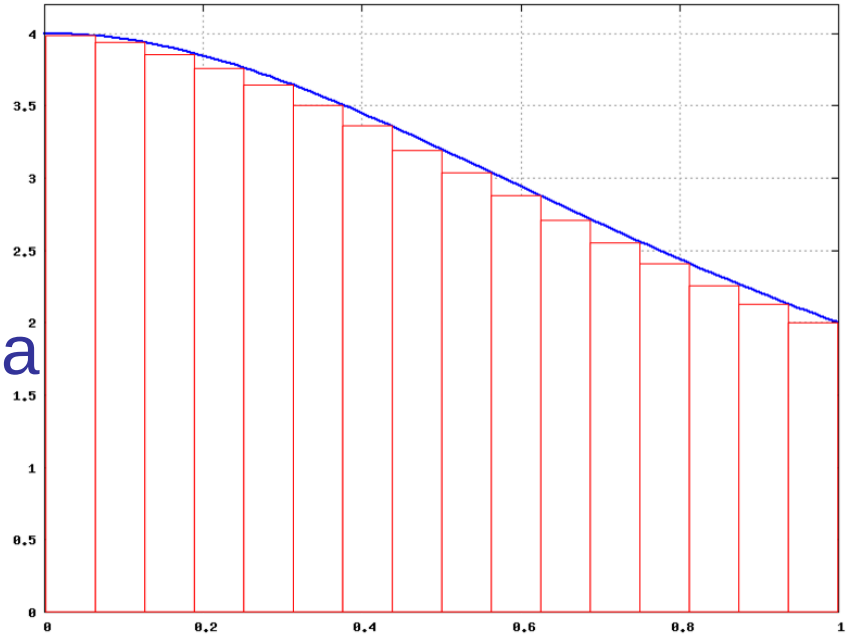

- L'integrale può essere approssimato con la somma della serie

$$\sum_{i=1}^{N} \frac{4 \cdot h}{1+(ih)^2} \quad \text{con} \quad h = \frac{1}{N}$$

che è uguale alla somma delle aree dei rettangoli in rosso

- Al crescere di N si ottiene una stima sempre più precisa di π

Il Calcolo di π: l'algoritmo parallelo

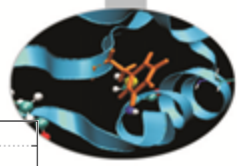

1. Ogni processo calcola la somma parziale di propria competenza rispetto alla decomposizione scelta
2. Ogni processo con *rank* ≠ 0 invia al processo di *rank* 0 la somma parziale calcolata
3. Il processo di *rank* 0
   - Riceve le P-1 somme parziali inviate dagli altri processi
   - Ricostruisce il valore dell'integrale sommando i contributi ricevuti dagli altri processi con quello calcolato localmente

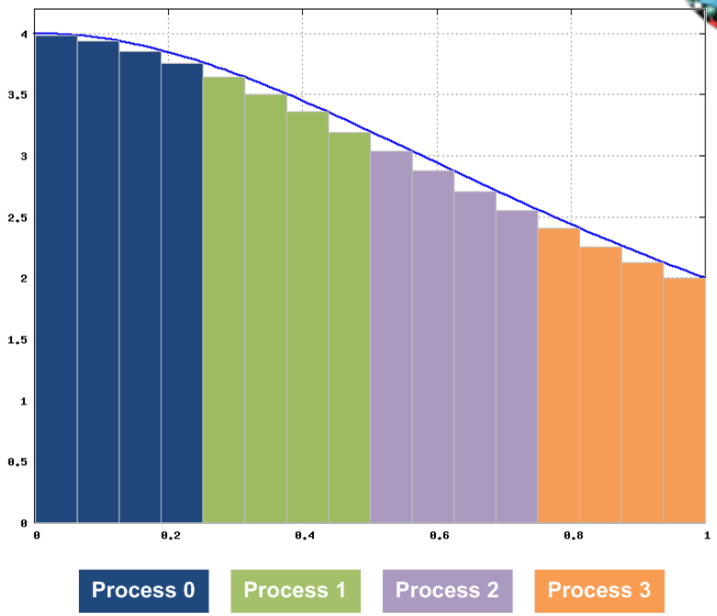

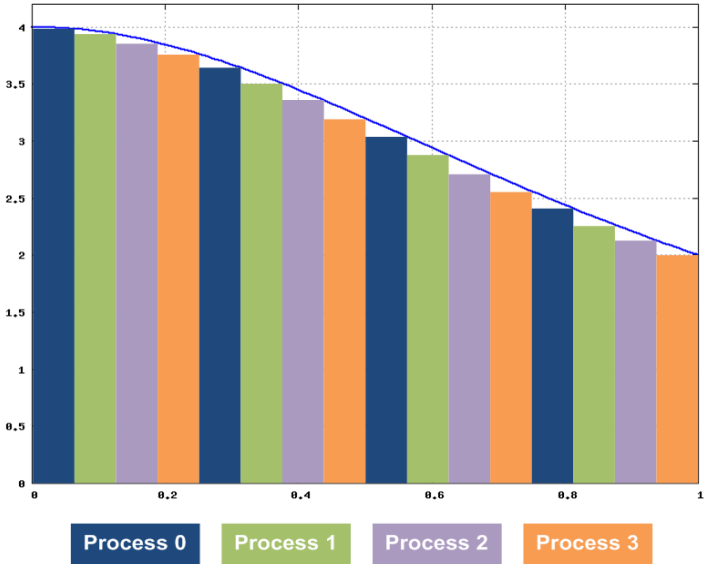

Il Calcolo di π con il metodo Monte Carlo

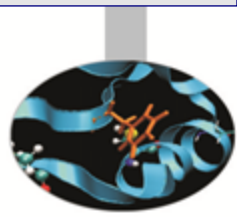

- *AOC* è il quadrante del cerchio unitario, la cui area è $\pi/4$
- Sia $Q = (x,y)$ una coppia di numeri casuali estratti da una distribuzione uniforme in $[0,1]$
- La probabilità p che il punto Q sia interno al quadrante *AOC* è pari al rapporto tra l'area di *AOC* e quella del quadrato *ABCO*, ovvero $4p = \pi$
- Con il metodo Monte Carlo possiamo campionare p e dunque stimare il valore di π

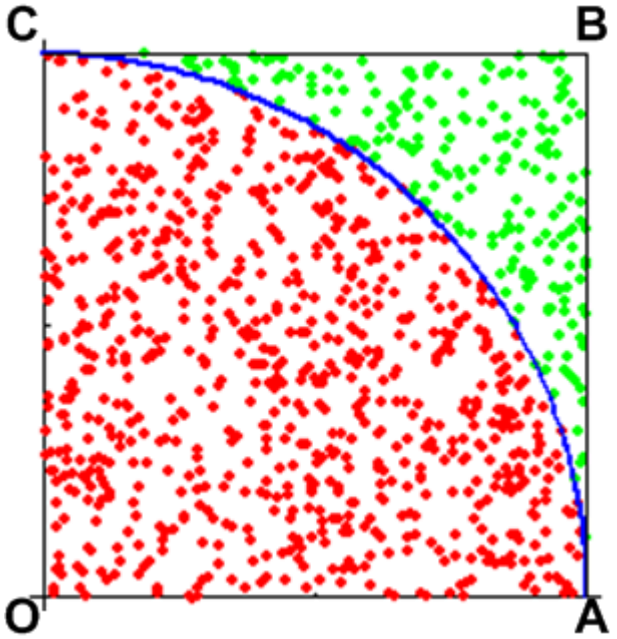

Il Calcolo di π in seriale (Monte Carlo)

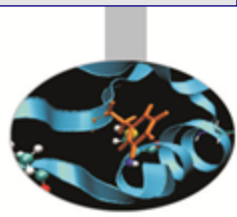

- Estrarre N coppie $Q_i=(x_i,y_i)$ di numeri pseudo casuali uniformemente distribuiti nell'intervallo [0,1]

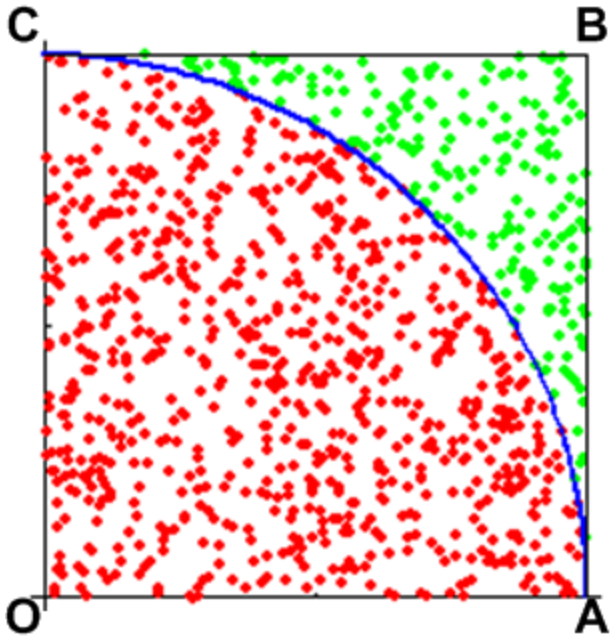

- Per ogni punto Q_i
  - calcolare $d_i = x_i^2 + y_i^2$
  - se $d_i \leq 1$ incrementare il valore di N_c, il numero di punti interni al quadrante AOC
- Il rapporto N_c/N è una stima della probabilità p
- $4*N_c/N$ è una stima di π, con errore dell'ordine 1/sqrt(N)

Il Calcolo di π con P processi (Monte Carlo)

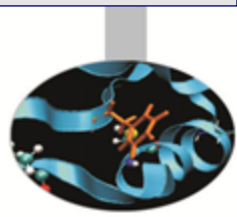

1. Ogni processo estrae N/P coppie $Q_i=(x_i,y_i)$ e calcola il relativo numero N_c di punti interni al quadrante AOC

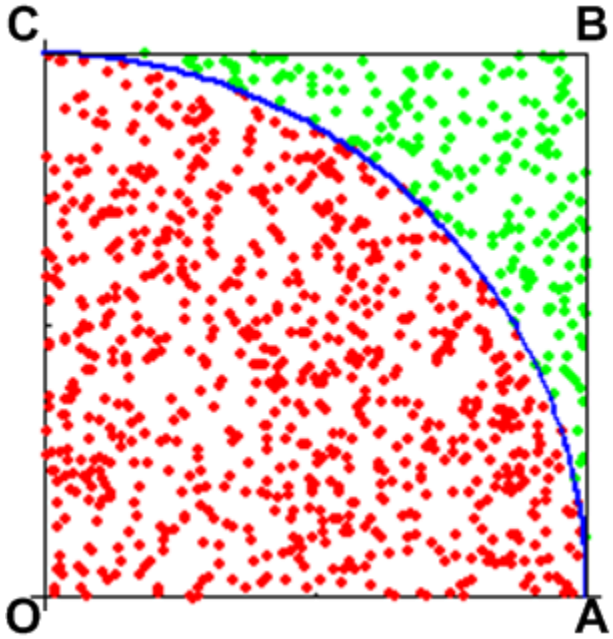

2. Ogni processo con *rank* $\neq 0$ invia al processo di *rank* 0 il valore calcolato di N_c

3. Il processo di *rank* 0
   - Riceve i P-1 valori di N_c inviati dagli altri processi
   - Ricostruisce il valore globale di N_c sommando i contributi ricevuti dagli altri processi con quello calcolato localmente
   - Calcola la stima di π (= $4*N_c/N$)

Communication Ring

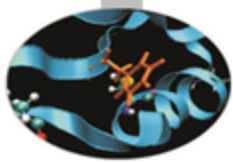

Scrivere un programma MPI in cui

- Il processo 0 legge da standard input un numero intero positivo *A*
  1. All'istante T_1 il processo 0 invia *A* al processo 1 e il processo 1 lo riceve
  2. All'istante T_2 il processo 1 invia *A* al processo 2 e il processo 2 lo riceve
  3. ….
  4. All'istante T_N il processo N-1 invia *A* al processo 0 e il processo 0 lo riceve
- Il processo 0
  - decrementa e stampa il valore di *A*
  - se *A* è ancora positivo torna al punto 1, altrimenti termina l'esecuzione

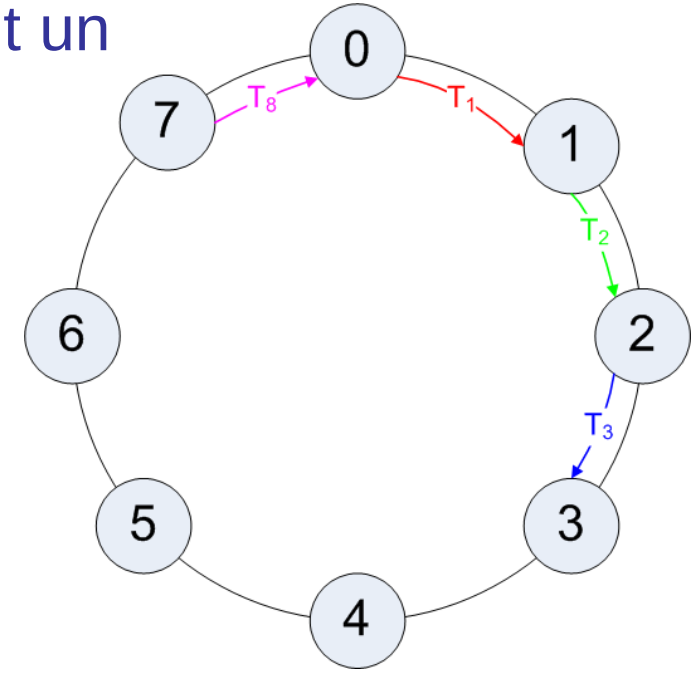

Calcolo parallelo con MPI

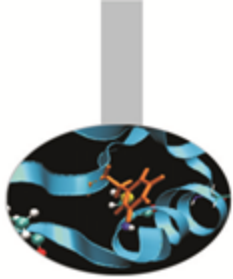

- Le sei funzioni di base: introduzione alla comunicazione *point-to-point*
- Laboratorio n° 1
- **Pattern di comunicazione *point-to-point: sendrecv***
- Introduzione alle comunicazioni collettive
- Laboratorio n° 2

Cosa abbiamo imparato di MPI

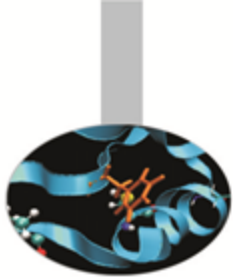

- Concetto di “aritmetica parallela”:
  - gruppo di collaboratori che lavorano indipendentemente su parti del problema
  - sulla base dei risultati parziali, si ottiene il risultato complessivo: questa fase richiede la comunicazione tra collaboratori
- MPI come strumento per implementare la comunicazione tra processi (l’equivalente informatico dei collaboratori)
- Le 6 funzioni di base ed alcune costanti di MPI che ci permettono di implementare lo scambio di messaggi tra due processi:
  - Communication Environment:
    - MPI_Init e MPI_Finalize
    - MPI_Comm_rank e MPI_Comm_size
  - Communication point-to-point:
    - MPI_Send e MPI_Recv
  - Comunicatore di default MPI_COMM_WORLD ed alcuni MPI_Datatype

Pattern di comunicazione

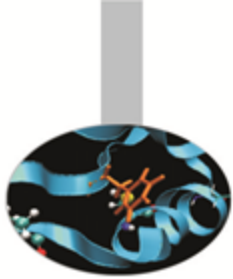

- Nella parallelizzazione di programmi reali, alcuni schemi di invio/ricezione del messaggio sono largamente diffusi: pattern di comunicazione

- I pattern di comunicazione possono essere di tipo
  - *point-to-point* , coinvolgono solo due processi
  - collettivi, coinvolgono più processi

- MPI mette a disposizione strumenti (funzioni MPI) per implementare alcuni pattern di comunicazione in modo corretto, robusto e semplice
  - il corretto funzionamento NON deve dipendere dal numero di processi

Pattern di comunicazione point-to-point: shift

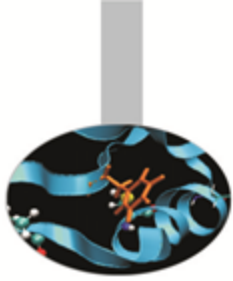

- Molti algoritmi paralleli richiedono la comunicazione tra ogni processo ed uno (o più) dei suoi vicini, con *rank* maggiore o minore.
  Questo tipo di pattern di comunicazione si chiama *shift*

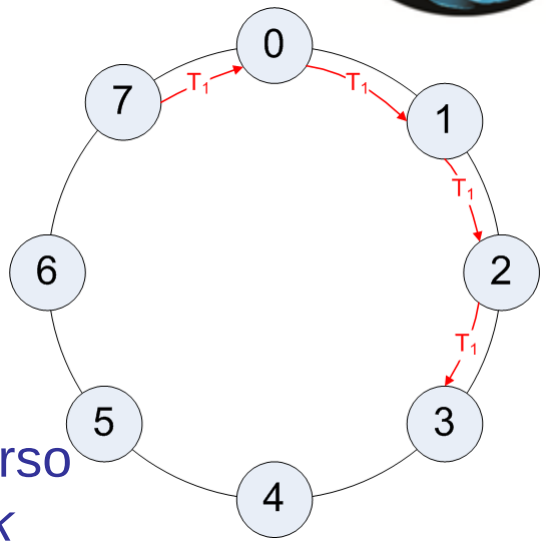

- Lo *shift* è un pattern *point-to-point*:
  - Ogni processo invia/riceve un set di dati in un verso (positivo/negativo) con una certa distanza di *rank*
    - Il processo i comunica al processo i+3 se Δrank=3
    - Il processo i comunica al processo i-1 se Δrank=1 con verso negativo
    - …
  - Se lo *shift* è periodico:
    - Il processo con rank=size-Δrank invia il set di dati al processo 0
    - Il processo con rank=size-Δrank+1 invia il set di dati al processo 1
    - …

Shift Circolare periodico

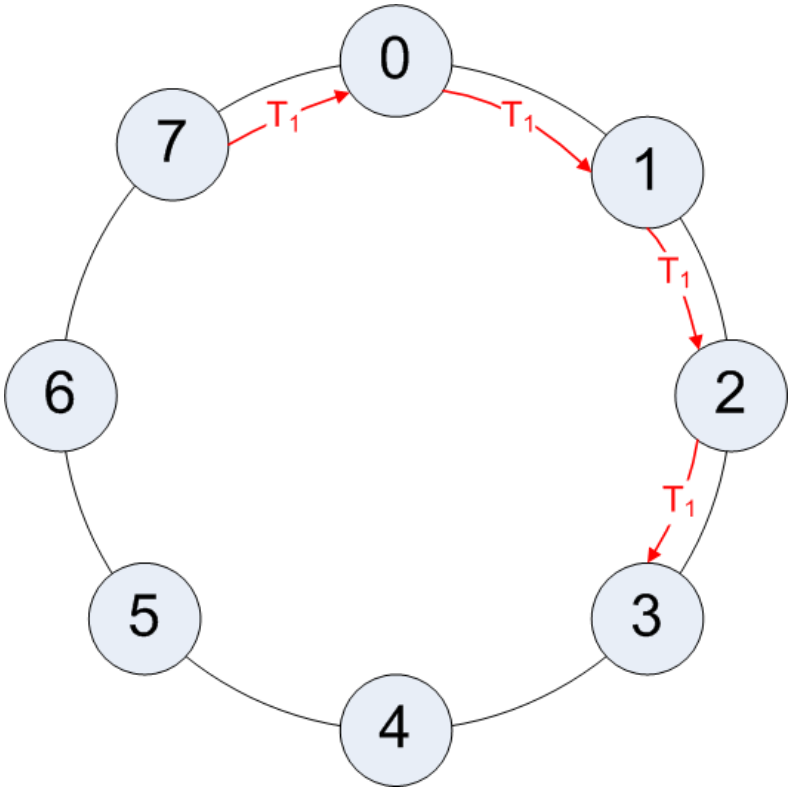

- Ogni processo genera un array `A`, popolandolo con interi pari al proprio rank
- Ogni processo invia il proprio array `A` al processo con rank immediatamente successivo
  - Periodic Boundary: l'ultimo processo invia l'array al primo processo
- Ogni processo riceve l'array `A` dal processo immediatamente precedente e lo immagazzina in un altro array `B`.
  - Periodic Boundary: il primo processo riceve l'array dall'ultimo processo
- Provare il programma dimensionando l'array A a 500, 1000 e 2000 elementi.

Shift circolare periodico: versione *naive*

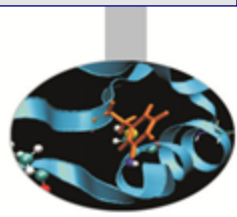

```
/* Start up MPI */
MPI_Init(&argc, &argv);
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
MPI_Comm_size(MPI_COMM_WORLD, &size);

tag = 201;
to = (rank + 1) % size;
from = (rank + size - 1) % size;

for (i = 0; i < MSIZE; i++)
    A[i] = rank;

/* starting send of array A */
MPI_Send(A, MSIZE, MPI_INT, to, tag, MPI_COMM_WORLD);
printf("Proc %d sends %d integers to proc %d\n",
    rank, MSIZE, to);

/* starting receive of array A in B */
MPI_Recv(B, MSIZE, MPI_INT, from, tag, MPI_COMM_WORLD, &status);
printf("Proc %d receives %d integers from proc %d\n",
    rank, MSIZE, from);

/* print first content of arrays A and B */
printf("Proc %d has A[0] = %d, B[0] = %d\n\n", rank, A[0], B[0]);

/* Quit */
MPI_Finalize();
```

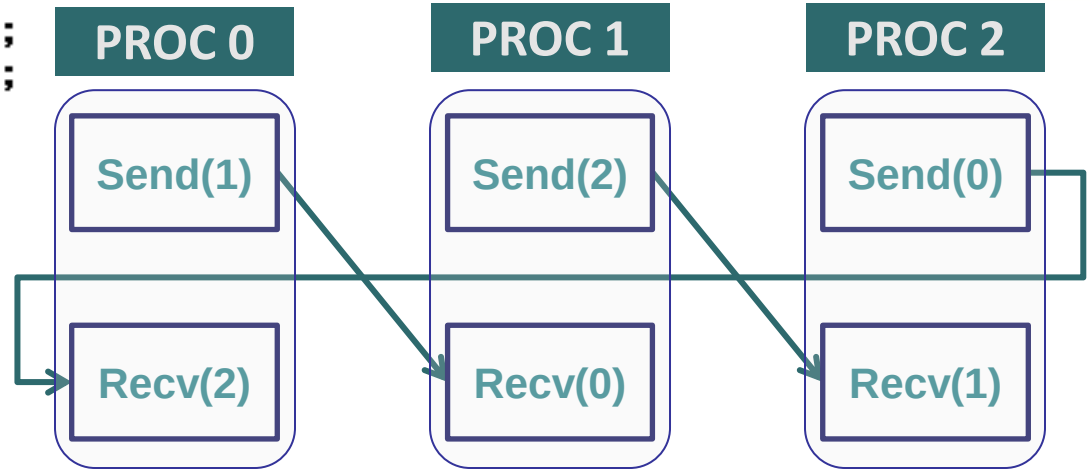

Shift circolare periodico: versione *naive*

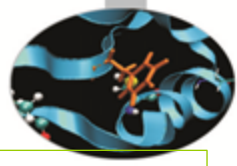

```
/* Start up MPI */
MPI_Init(&argc, &argv);
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
MPI_Comm_size(MPI_COMM_WORLD, &size);

tag = 201;
to = (rank + 1) % size;
from = (rank + size - 1) % size;

for (i = 0; i < MSIZE; i++)
    A[i] = rank;

/* starting send of array A */
MPI_Send(A, MSIZE, MPI_INT, to, tag, MPI_COMM_WORLD);
printf("Proc %d sends %d integers to proc %d\n",
    rank, MSIZE, to);

/* starting receive of array A in B */
MPI_Recv(B, MSIZE, MPI_INT, from, tag, MPI_COMM_WORLD, &status);
printf("Proc %d receives %d integers from proc %d\n",
    rank, MSIZE, from);

/* print first content of arrays A and B */
printf("Proc %d has A[0] = %d, B[0] = %d\n\n", rank, A[0], B[0]);

/* Quit */
MPI_Finalize();
```

- Cosa succede girando l'esempio al crescere del valore di **MSIZE**?
- Utilizzando l'ambiente parallelo OpenMPI sul nostro cluster, il programma funziona correttamente a **MSIZE = 1000**
- Se **MSIZE = 2000**, il programma va in *hang*

Il *deadlock*

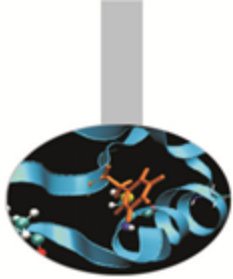

- L'implementazione *naive* dello *shift* circolare non è corretta: per `MSIZE>1000` si genera un *deadlock*
- Il *deadlock* è la condizione in cui ogni processo è in attesa di un altro per terminare la comunicazione e procedere poi nell'esecuzione del programma
- Per comprendere perché il *deadlock* si verifica per `MSIZE>1000` è necessario entrare nel dettaglio del meccanismo di scambio di messaggi tra due processi

Cenni sul meccanismo di comunicazione

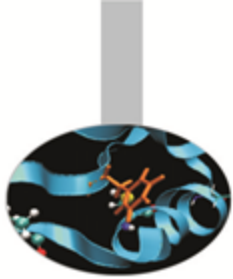

- Le funzioni send standard di MPI non ‘ritornano’ sino a che l’invio del messaggio non sia stato completato secondo una delle due modalità seguenti:
  - *Buffered*: l’invio del messaggio avviene attraverso una copia dal buffer di invio in un buffer di sistema
  - *Synchronous*: l’invio del messaggio avviene attraverso la copia diretta nel buffer di ricezione

Cosa fa `MPI_Send` nel nostro esempio

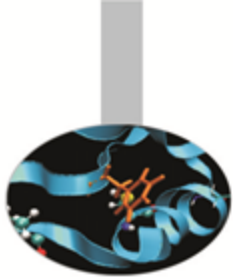

- La modalità di completamento di `MPI_Send` varia a seconda della *size* dei dati da inviare:
  - *Buffered* per *size* piccole
  - *Synchronous* per *size* grandi

- Nel nostro caso, sino a 1000 elementi di tipo `MPI_INT` la `MPI_Send` si comporta come *buffered,* ma a 2000 diventa *synchronous*
  - per MSIZE=1000 il processo può uscire fuori dalla *send* dopo che A sia stato copiato nel *buffer* locale al sistema in cui il processo è in esecuzione
  - Per MSIZE=2000 il processo può uscire fuori dalla *send* solo quando ci sia in esecuzione un'operazione di *receive* pronta ad accogliere A

Perché il deadlock?

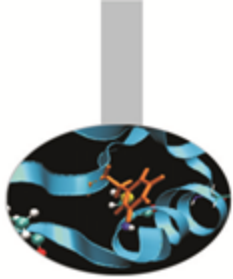

- Nel nostro caso l'algoritmo è del tipo

```
if (myrank = 0)
    SEND A to Process 1
    RECEIVE B from Process 1
else if (myrank = 1)
    SEND A to Process 0
    RECEIVE B from Process 0
endif
```

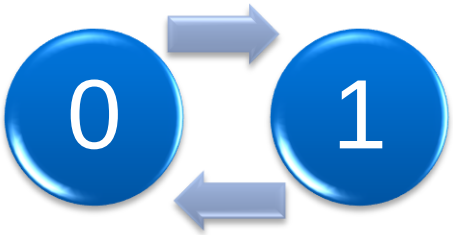

- Per MSIZE=2000, ci sono due *send* in attesa di due *receive*, ma le *receive* potranno essere eseguite solo dopo che le reciproche *send* siano state completate.
- DEADLOCK!

Soluzione del *deadlock* nello *shift* circolare: *Send-Receive*

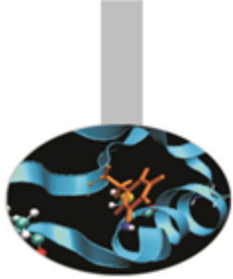

- Abbiamo la necessità di una funzione che tratti internamente l'ordine delle operazioni di *send* e *receive*
- La funzione che svolge questo compito è `MPI_Sendrecv`
  - La funzionalità MPI *send-receive* è utile quando un processo deve contemporaneamente inviare e ricevere dei dati
  - Può essere usata per implementare pattern di comunicazione di tipo *shift*

Binding MPI_Sendrecv

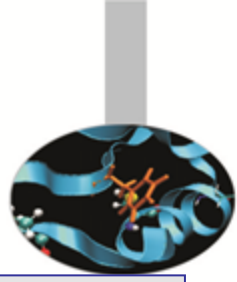

In C

```
int MPI_Sendrecv(void *sbuf,int scount,MPI_Datatype s_dtype,
  int dest,int stag,void *dbuf,int dcount,MPI_Datatype d_type,
  int src,int dtag,MPI_Comm comm,MPI_Status *status)
```

In Fortran

```
MPI_SENDRECV(SBUF, SCOUNT, S_DTYPE, DEST, STAG,
             DBUF, DCOUNT, D_DTYPE, SRC, DTAG,
             COMM, STATUS, ERR)
```

- I primi argomenti sono relativi alla *send*, gli altri alla *receive*
- Argomenti significativi:
  - [IN] **dest** è il *rank* del *receiver* all'interno del comunicatore **comm**
  - [IN] **stag** è l'identificativo del *send message*
  - [IN] **src** è il *rank* del *sender* all'interno del comunicatore **comm**
  - [IN] **dtag** è l'identificativo del *receive message*

Shift circolare: versione con *Send-Receive*

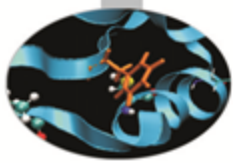

```c
#include <stdio.h>
#include <mpi.h>
#define MSIZE 50000

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

    MPI_Status status;
    int rank, size, tag, to, from;

    int A[MSIZE], B[MSIZE], i;

    /* Start up MPI environment */
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);

    to = (rank + 1) % size;
    from = (rank + size - 1) % size;

    for (i = 0; i < MSIZE; i++)
        A[i] = rank;

    MPI_Sendrecv(A, MSIZE, MPI_INT, to, 201, /* sending info */
                 B, MSIZE, MPI_INT, from, 201, /* recving info */
                 MPI_COMM_WORLD, &status);

    printf("Proc %d sends %d integers to proc %d\n", rank, MSIZE, to);
    printf("Proc %d receives %d integers from proc %d\n", rank, MSIZE, from);

    /* Quit MPI environment */
    MPI_Finalize();
    return 0;
}
```

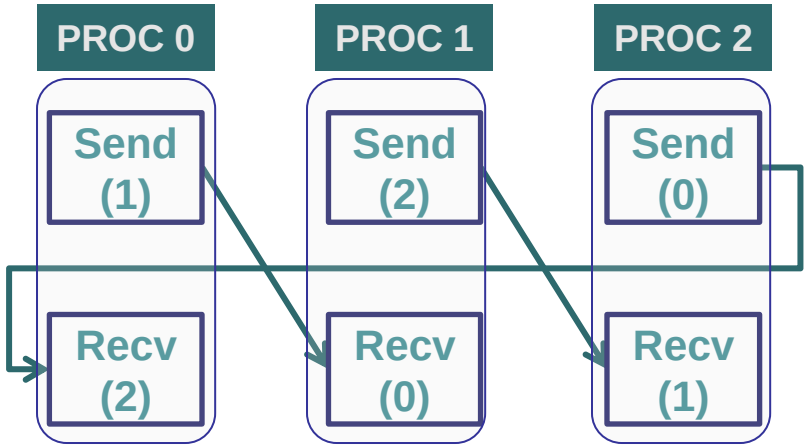

Calcolo parallelo con MPI

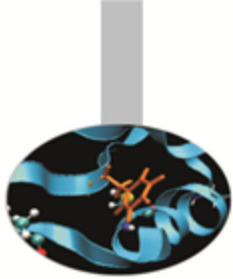

- Le sei funzioni di base: introduzione alla comunicazione *point-to-point*
- Laboratorio n° 1
- Pattern di comunicazione *point-to-point: sendrecv*
- **Introduzione alle comunicazioni collettive**
- Laboratorio n° 2

Introduzione alle comunicazioni collettive

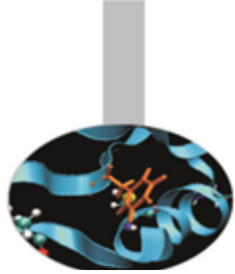

- Alcuni pattern di comunicazione prevedono il coinvolgimento di tutti i processi di un comunicatore
  - Esempio: il calcolo della somma dei contributi parziali dell'integrale per il calcolo del π

```
if (rank != 0) {

    /* slave processes send partial pi sum to master process 0 */
    MPI_Send(&pi, 1, MPI_DOUBLE, 0, tag, MPI_COMM_WORLD);

} else {

    for (from = 1; from < size; from++) {

        printf("I have pi = %f\n", pi);

        /* master process receives partial pi sum from other processes */
            MPI_Recv(&sum, 1, MPI_DOUBLE, from, tag, MPI_COMM_WORLD, &status);

        printf(".. received %f from proc %d\n", sum, from);
            pi = pi + sum;

        fflush(stdout);
    }
}
```

- MPI mette a disposizione alcune funzioni che implementano questi pattern
  - Si evita così al programmatore l'onere e la complicazione di dover programmare questi pattern a partire da comunicazioni *point-to-point*
  - Sono implementati con gli algoritmi più efficaci

- È possibile catalogare queste funzioni, sulla base del/dei *sender* e del/dei *receiver*, in tre classi: ***all-to-one***, ***one-to-all***, ***all-to-all***.
  La divisione in classi ci permette di trovare facilmente la funzione cercata

REDUCE

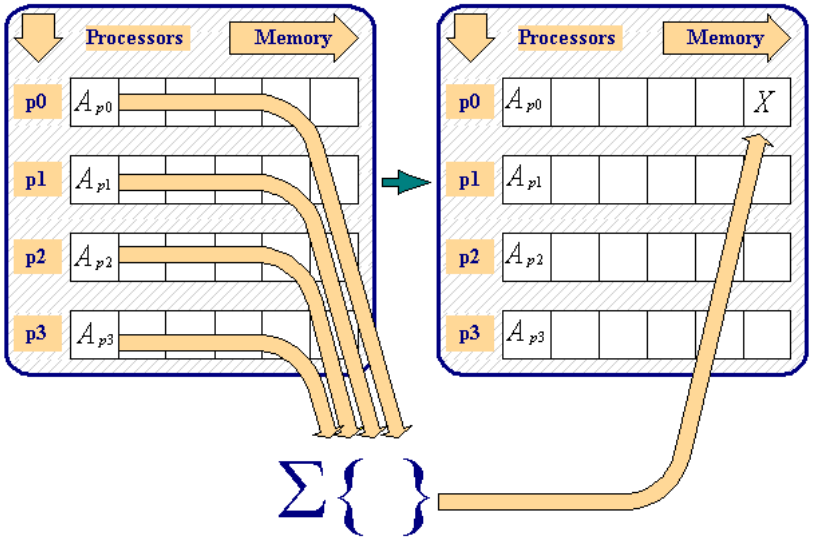

- L'operazione di *REDUCE* consente di:
  - Raccogliere da ogni processo i dati provenienti dal *send buffer*
  - Ridurre i dati ad un solo valore attraverso un operatore (la somma in figura)
  - Salvare il risultato nel *receive buffer* del processo di destinazione, chiamato convenzionalmente *root* (p0 in figura)
- Appartiene alla classe *all-to-one*

Binding di MPI_Reduce

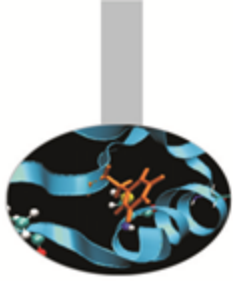

In C

```
int MPI_Reduce(void* sbuf, void* rbuf, int count,
  MPI_Datatype dtype, MPI_Op op, int root, MPI_Comm comm)
```

In Fortran

```
MPI_REDUCE(SBUF, RBUF, COUNT, DTYPE, OP, ROOT, COMM, ERR)
```

- [IN] **sbuf** è l'indirizzo del *send* buffer
- [OUT] **rbuf** è l'indirizzo del *receive* buffer
- [IN] **count** è di tipo `int` e contiene il numero di elementi del *send/receive* buffer
- [IN] **dtype** è di tipo `MPI_Datatype` e descrive il tipo di ogni elemento del *send/receive* buffer
- [IN] **op** è di tipo `MPI_Op` e referenzia l'operatore di reduce da utilizzare
- [IN] **root** è di tipo `int` e contiene il *rank* del processo *root* della reduce
- [IN] **comm** è di tipo `MPI_Comm` ed è il comunicatore cui appartengono i processi coinvolti nella reduce

Operatori di *Reduce*

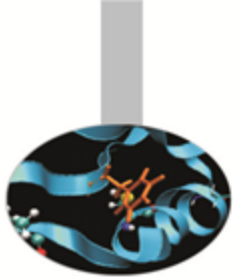

- Le principali operazioni di reduce predefinite sono
  - Massimo (MPI_MAX)
  - Minimo (MPI_MIN)
  - Somma (MPI_SUM)
  - Prodotto (MPI_PROD)
  - operazioni logiche (MPI_LAND, MPI_LOR, MPI_LXOR)
  - operazioni *bitwise* (MPI_BAND, MPI_BOR, MPI_BXOR)
- Gli operatori di reduce sono associativi e commutativi (almeno nella versione a precisione infinita)
- L'utente può definire operatori *ad-hoc* (MPI_Op_create)

Calcolo di π con *reduce*

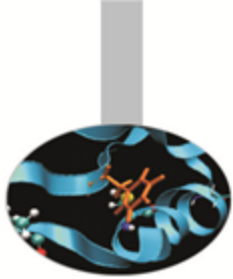

```c
#include <stdio.h>
#include "mpi.h"
#define INTERVALS 10000

int main(int argc, char **argv) {

    int rank, nprocs, tag;
    int i;
    int interval = INTERVALS;
    double x, dx, f, sum, pi;

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

    sum = 0.0; dx = 1.0 / (double) interval;

    /* each process computes integral */
    for (i = rank; i < interval; i = i+nprocs) {
        x = dx * ((double) (i - 0.5));
        f = 4.0 / (1.0 + x*x);
        sum = sum + f;
    }
    pi = dx*sum;
    sum = pi; /* using variable sum as sending buffer */

    MPI_Reduce(&sum, &pi, 1, MPI_DOUBLE, MPI_SUM, 0, MPI_COMM_WORLD);

    if (rank == 0)
        printf("Computed PI %.24f\n", pi);

    /* Quit */
    MPI_Finalize();
    return 0;
}
```

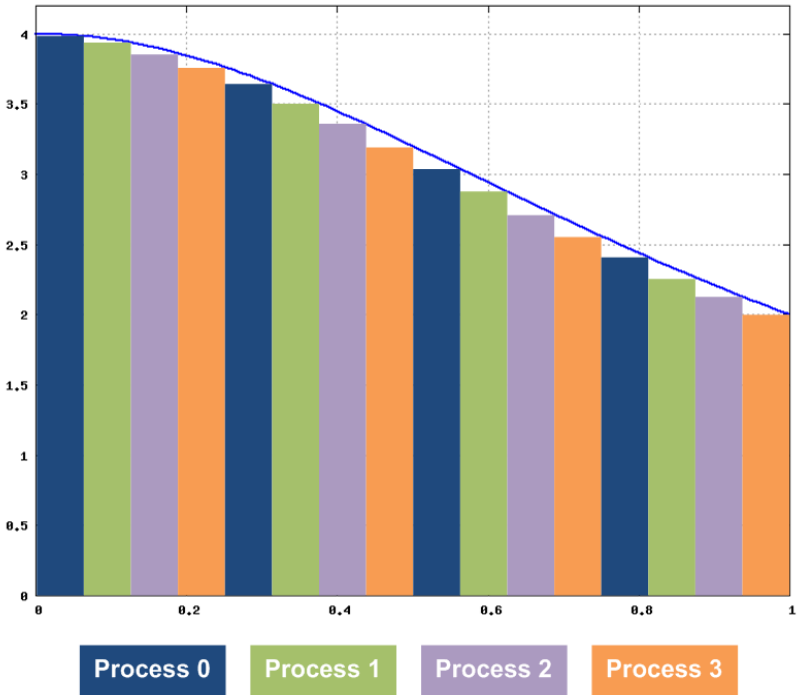

BROADCAST

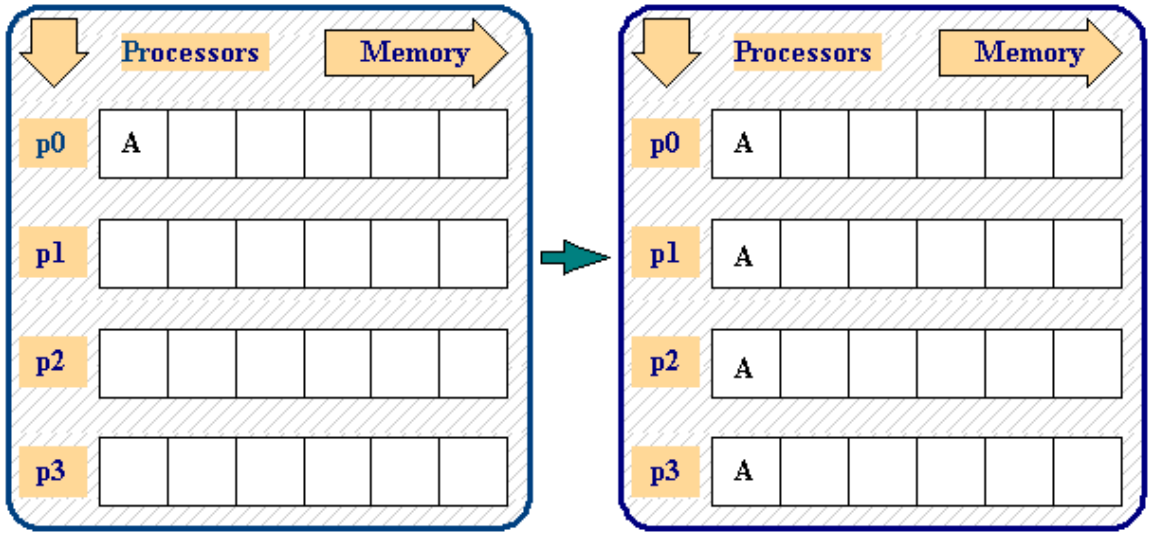

- La funzionalità di *BROADCAST* consente di copiare dati dal *send* buffer del processo *root* (p0 nella figura) al *receive* buffer di tutti gli altri processi appartenenti al comunicatore utilizzato (processo *root* incluso)

- Appartiene alla classe *one-to-all*

Binding di `MPI_Bcast`

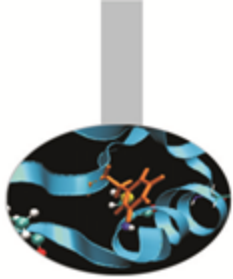

In C

```
int MPI_Bcast(void* buf, int count, MPI_Datatype dtype,
              int root, MPI_Comm comm)
```

In Fortran

```
MPI_BCAST(BUF, COUNT, DTYPE, ROOT, COMM, ERR)
```

- `[IN/OUT]` **`buf`** è l'indirizzo del *send/receive buffer*
- `[IN]` **`count`** è di tipo `int` e contiene il numero di elementi del *buffer*
- `[IN]` **`dtype`** è di tipo `MPI_Datatype` e descrive il tipo di ogni elemento del *buffer*
- `[IN]` **`root`** è di tipo `int` e contiene il *rank* del processo *root* dell'operazione di *broadcast*
- `[IN]` **`comm`** è di tipo `MPI_Comm` ed è il comunicatore cui appartengono i processi coinvolti nell'operazione di *broadcast*

SCATTER

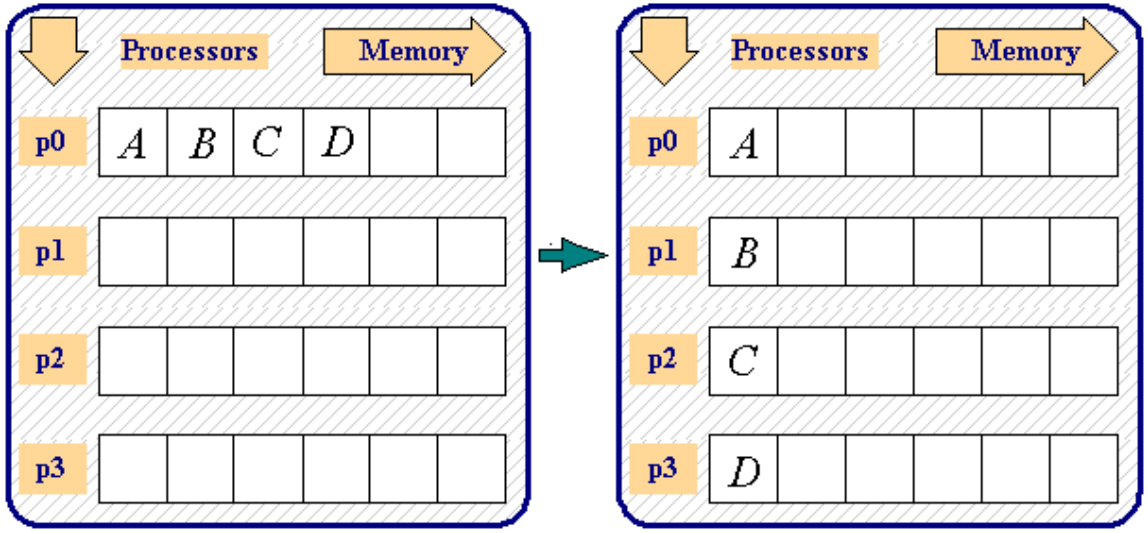

- Il processo *root* (p0 nella figura)
  - divide in N parti uguali un insieme di dati contigui in memoria
  - invia una parte ad ogni processo in ordine di *rank*

- Appartiene alla classe *one-to-all*

Binding di `MPI_Scatter`

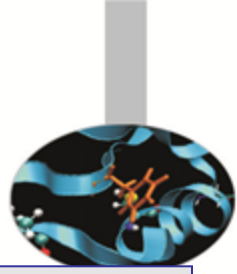

In C

```
int MPI_Scatter(void* sbuf, int scount, MPI_Datatype s_dtype, void*
    rbuf, int rcount, MPI_Datatype r_dtype, int root, MPI_Comm comm)
```

In Fortran

```
MPI_SCATTER(SBUF, SCOUNT, S_DTYPE, RBUF, RCOUNT, R_DTYPE, ROOT,
            COMM, ERR)
```

- [IN] **sbuf** è l'indirizzo del send buffer
- [IN] **scount**, di tipo `int`, contiene il numero di elementi spediti ad ogni processo
- [IN] **s_dtype**, di tipo `MPI_Datatype`, descrive il tipo di ogni elemento del *send buffer*
- [OUT] **rbuf** è l'indirizzo del *receive buffer*
- [IN] **rcount**, di tipo `int`, contiene il numero di elementi del *receive buffer*
- [IN] **r_dtype**, di tipo `MPI_Datatype`, descrive il tipo di ogni elemento del *receive buffer*
- [IN] **root**, di tipo `int`, contiene il *rank* del processo *root* della *scatter*
- [IN] **comm**, di tipo `MPI_Comm`, è il comunicatore cui appartengono i processi coinvolti nella *scatter*

GATHER

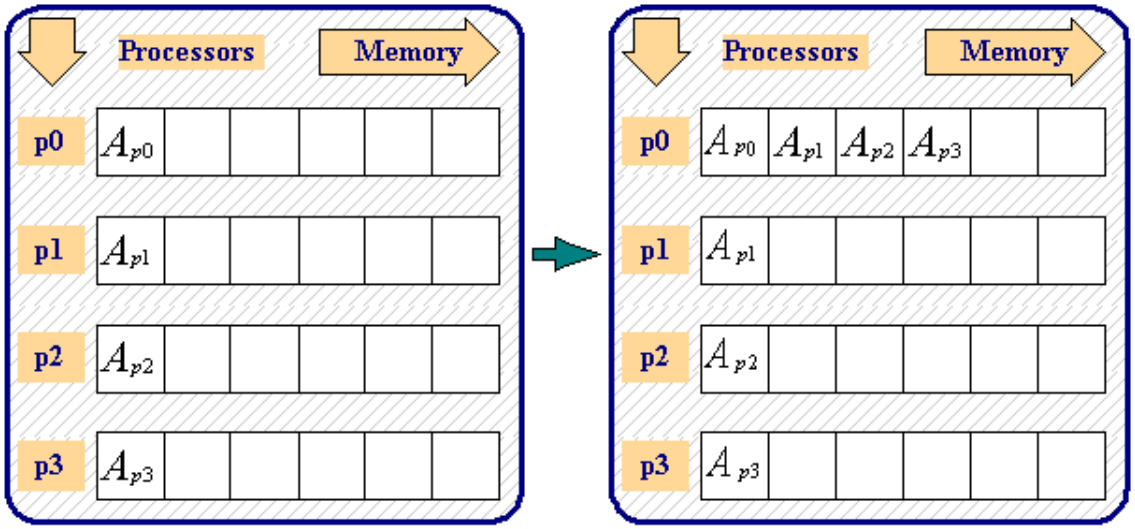

- Con la funzionalità *GATHER* ogni processo (incluso il *root*) invia il contenuto del proprio *send* buffer al processo *root*
- Il processo *root* riceve i dati e li ordina in funzione del *rank* del processo *sender*
- È l'inverso dell'operazione di scatter
- Appartiene alla classe *all-to-one*

Binding di MPI_Gather

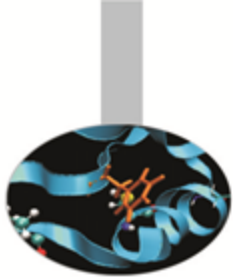

In C

```
int MPI_Gather(void* sbuf, int scount, MPI_Datatype s_dtype,
               void* rbuf, int rcount, MPI_Datatype r_dtype,
               int root, MPI_Comm comm)
```

In Fortran

```
MPI_GATHER(SBUF, SCOUNT, S_DTYPE, RBUF, RCOUNT, R_DTYPE,
           ROOT, COMM, ERR)
```

- [IN] **sbuf** è l'indirizzo del *send buffer*
- [IN] **scount** è di tipo `int` e contiene il numero di elementi del *send buffer*
- [IN] **s_dtype** è di tipo `MPI_Datatype` e descrive il tipo di ogni elemento del *send buffer*
- [OUT] **rbuf** è l'indirizzo del *receive buffer*
- [IN] **rcount** è di tipo `int` e contiene il numero di elementi del *receive buffer*
- [IN] **r_dtype** è di tipo `MPI_Datatype` e descrive il tipo di ogni elemento del *receive buffer*
- [IN] **root** è di tipo `int` e contiene il *rank* del processo *root* della *gather*
- [IN] **comm** è di tipo `MPI_Comm` ed è il comunicatore cui appartengono i processi coinvolti nella *gather*

ALLGATHER

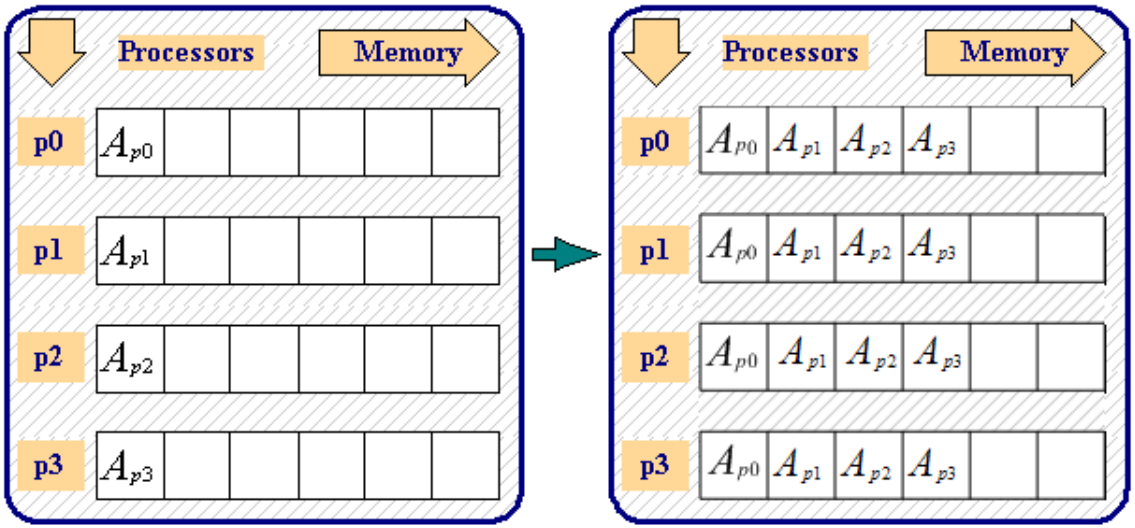

- Di fatto è l'equivalente di un'operazione di *GATHER*, in cui il processo *root* dopo esegue una *BROADCAST*
- È molto più conveniente ed efficiente eseguire una operazione *ALLGATHER* piuttosto che la sequenza *GATHER+BROADCAST*
- Appartiene alla classe *all-to-all*

Binding di MPI_ALLGather

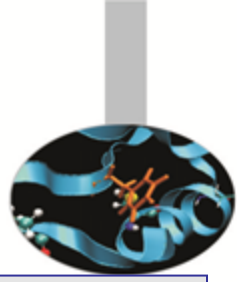

In C

```
int MPI_Allgather(void* sbuf, int scount,MPI_Datatype s_dtype,
        void* rbuf, int rcount, MPI_Datatype r_dtype, MPI_Comm comm)
```

In Fortran

```
MPI_ALLGATHER(SBUF, SCOUNT, S_DTYPE, RBUF, RCOUNT, R_DTYPE, COMM,
              ERR)
```

- [IN] **sbuf** è l'indirizzo del *send buffer*
- [IN] **scount** è di tipo `int` e contiene il numero di elementi del *send buffer*
- [IN] **s_dtype** è di tipo `MPI_Datatype` e descrive il tipo di ogni elemento del *send buffer*
- [OUT] **rbuf** è l'indirizzo del *receive buffer*
- [IN] **rcount** è di tipo `int` e contiene il numero di elementi del *receive buffer*
- [IN] **r_dtype** è di tipo `MPI_Datatype` e descrive il tipo di ogni elemento del *receive buffer*
- [IN] **comm** è di tipo `MPI_Comm` ed è il comunicatore cui appartengono i processi coinvolti nella ALL*Gather*

Altre comunicazioni collettive

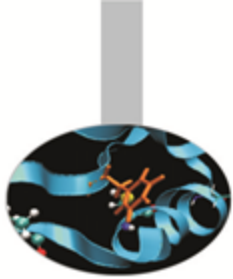

- **`MPI_BARRIER`**: L'esecuzione di ogni processo appartenente allo stesso comunicatore viene messa in pausa fino a quando tutti i processi non sono giunti a questa istruzione

- **`MPI_ALL_REDUCE`**: Il risultato della REDUCE viene comunicato a tutti i processi. È equivalente ad una REDUCE seguita da un BROADCAST

- **`MPI_SCATTERV`** e **`MPI_GATHERV`**: come SCATTER e GATHER, ma consentono di comunicare blocchi di dati di dimensione diversa

Overview: le comunicazioni collettive

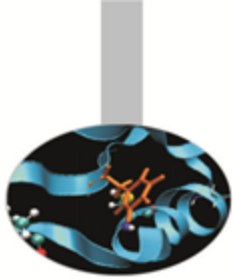

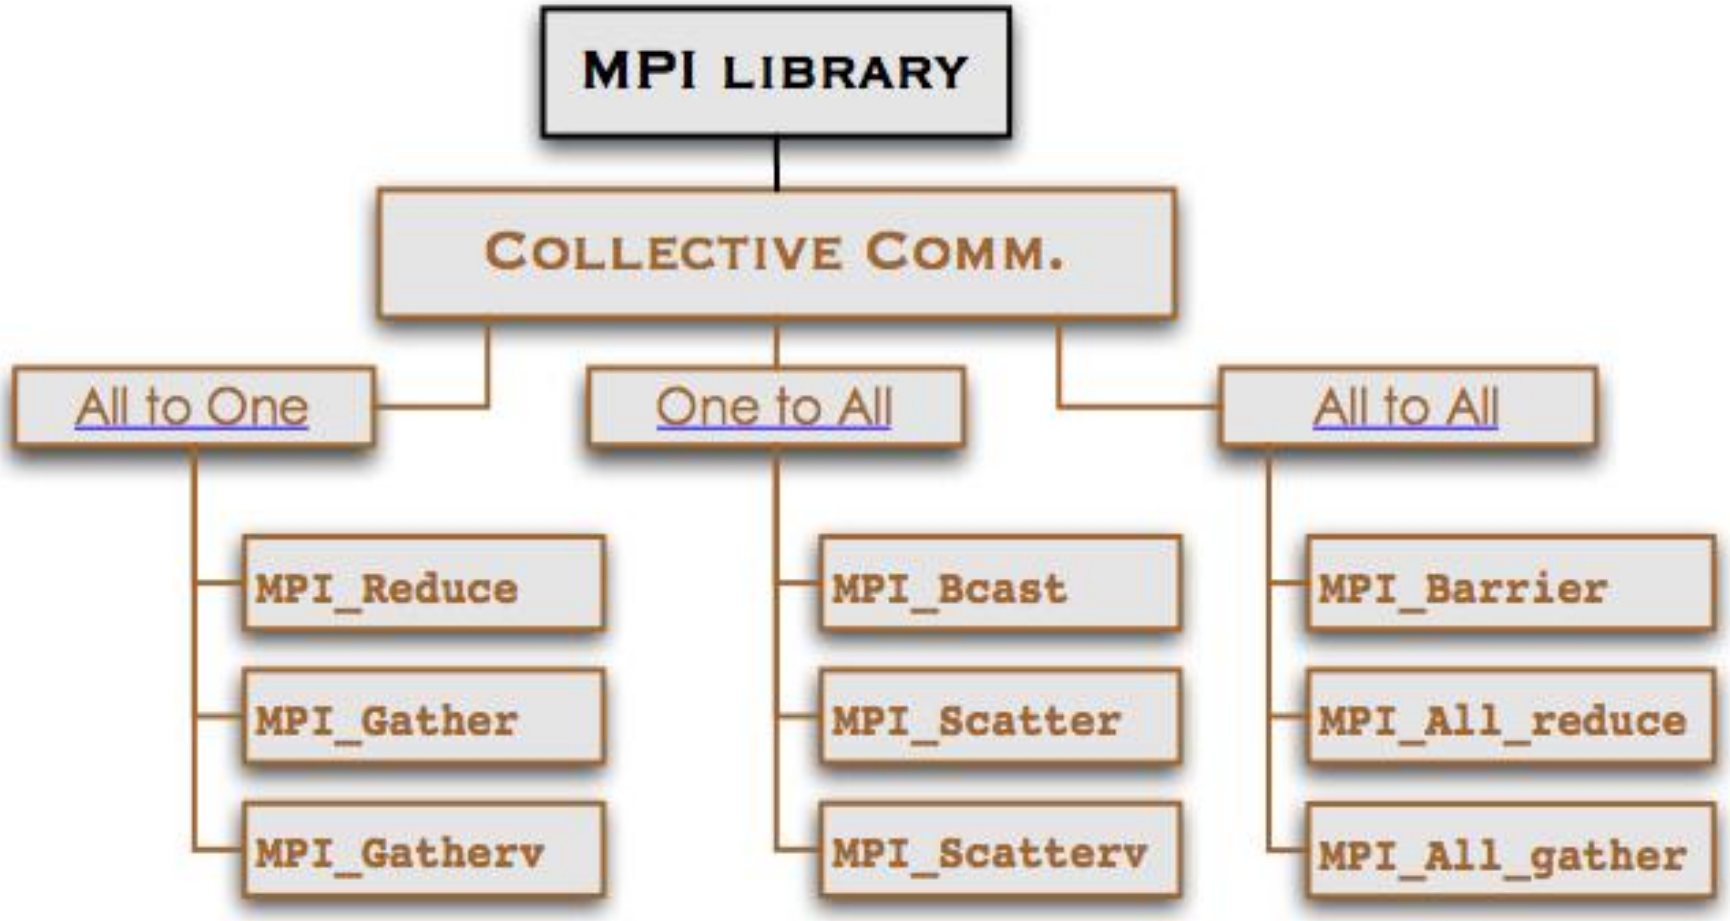

Calcolo parallelo con MPI

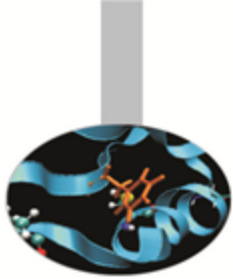

- Le sei funzioni di base: introduzione alla comunicazione *point-to-point*
- Laboratorio n° 1
- Pattern di comunicazione *point-to-point: sendrecv*
- Introduzione alle comunicazioni collettive
- Laboratorio n° 2

Programma della 2° sessione di laboratorio

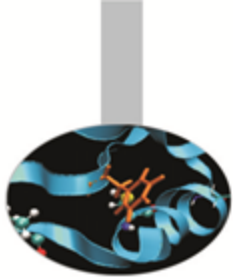

- Funzioni di comunicazione standard e pattern di comunicazione
  - *Shift* circolare con `MPI_Sendrecv` (Esercizio 7)
  - *Array Smoothing* (Esercizio 8)
- Utilizzare le funzioni collettive per implementare pattern di comunicazione standard
  - Calcolo di π con comunicazioni collettive (Eserc. 9)
  - Prodotto matrice-vettore (Esercizio 10)
  - Prodotto matrice-matrice (Esercizio 11)

Shift Circolare periodico con `MPI_Sendrecv`

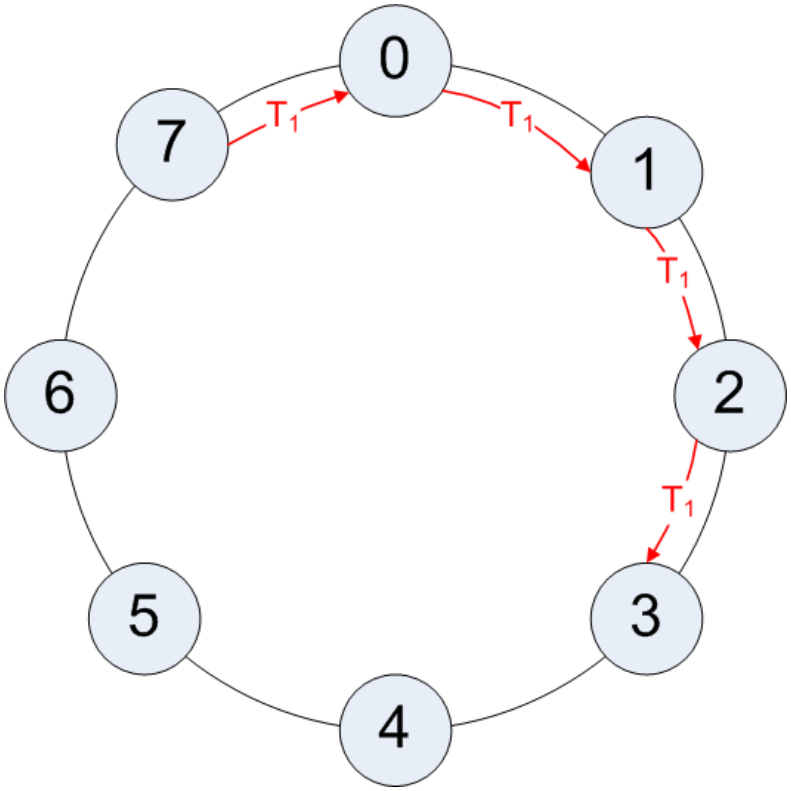

- Ogni processo genera un array `A`, popolandolo con interi pari al proprio rank
- Ogni processo invia il proprio array `A` al processo con rank immediatamente successivo
  - Periodic Boundary: L'ultimo processo invia l'array al primo processo
- Ogni processo riceve l'array `A` dal processo immediatamente precedente e lo immagazzina in un altro array `B`.
  - Periodic Boundary: il primo processo riceve l'array dall'ultimo processo
- Le comunicazioni devono essere di tipo *Sendrecv*

Array smoothing

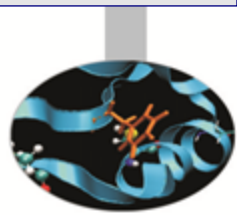

- dato un *array* A[N]
  - inizializzare e stampare il vettore A
- per iter volte:
  - calcolare un nuovo *array* B in cui ogni elemento sia uguale alla media aritmetica del suo valore e dei suoi K primi vicini al passo precedente
    - nota: l'array è periodico, quindi il primo e l'ultimo elemento di A sono considerati primi vicini
  - stampare il vettore B
  - copiare B in A e continuare l'iterazione

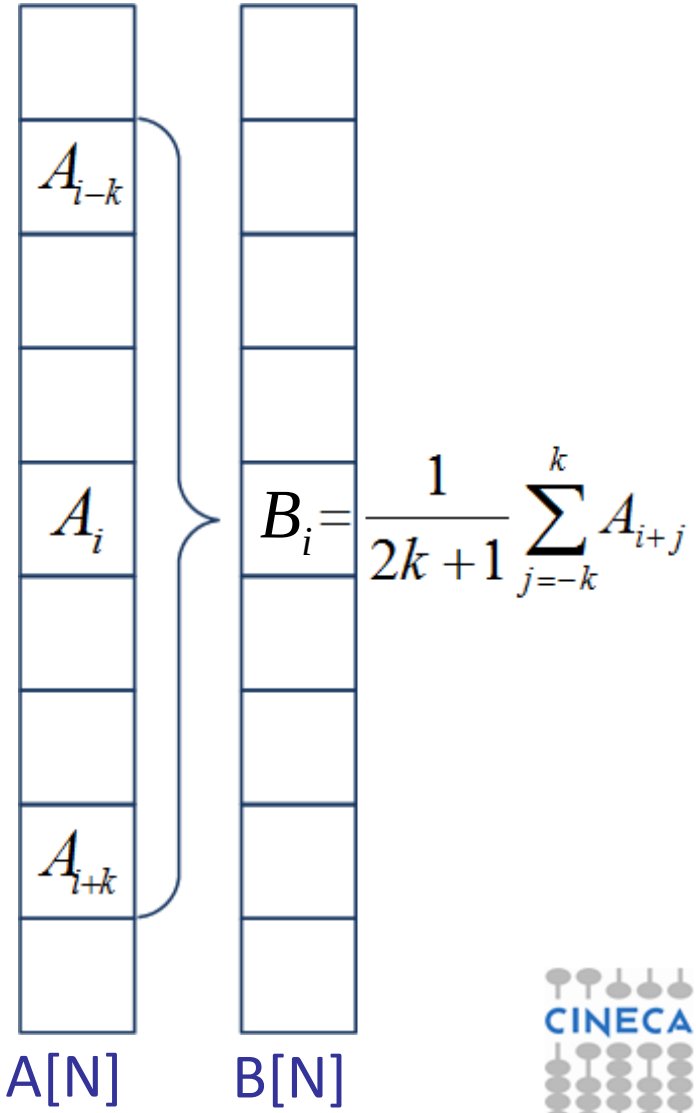

Array smoothing: algoritmo parallelo

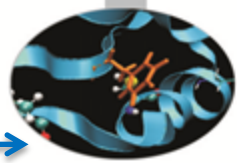

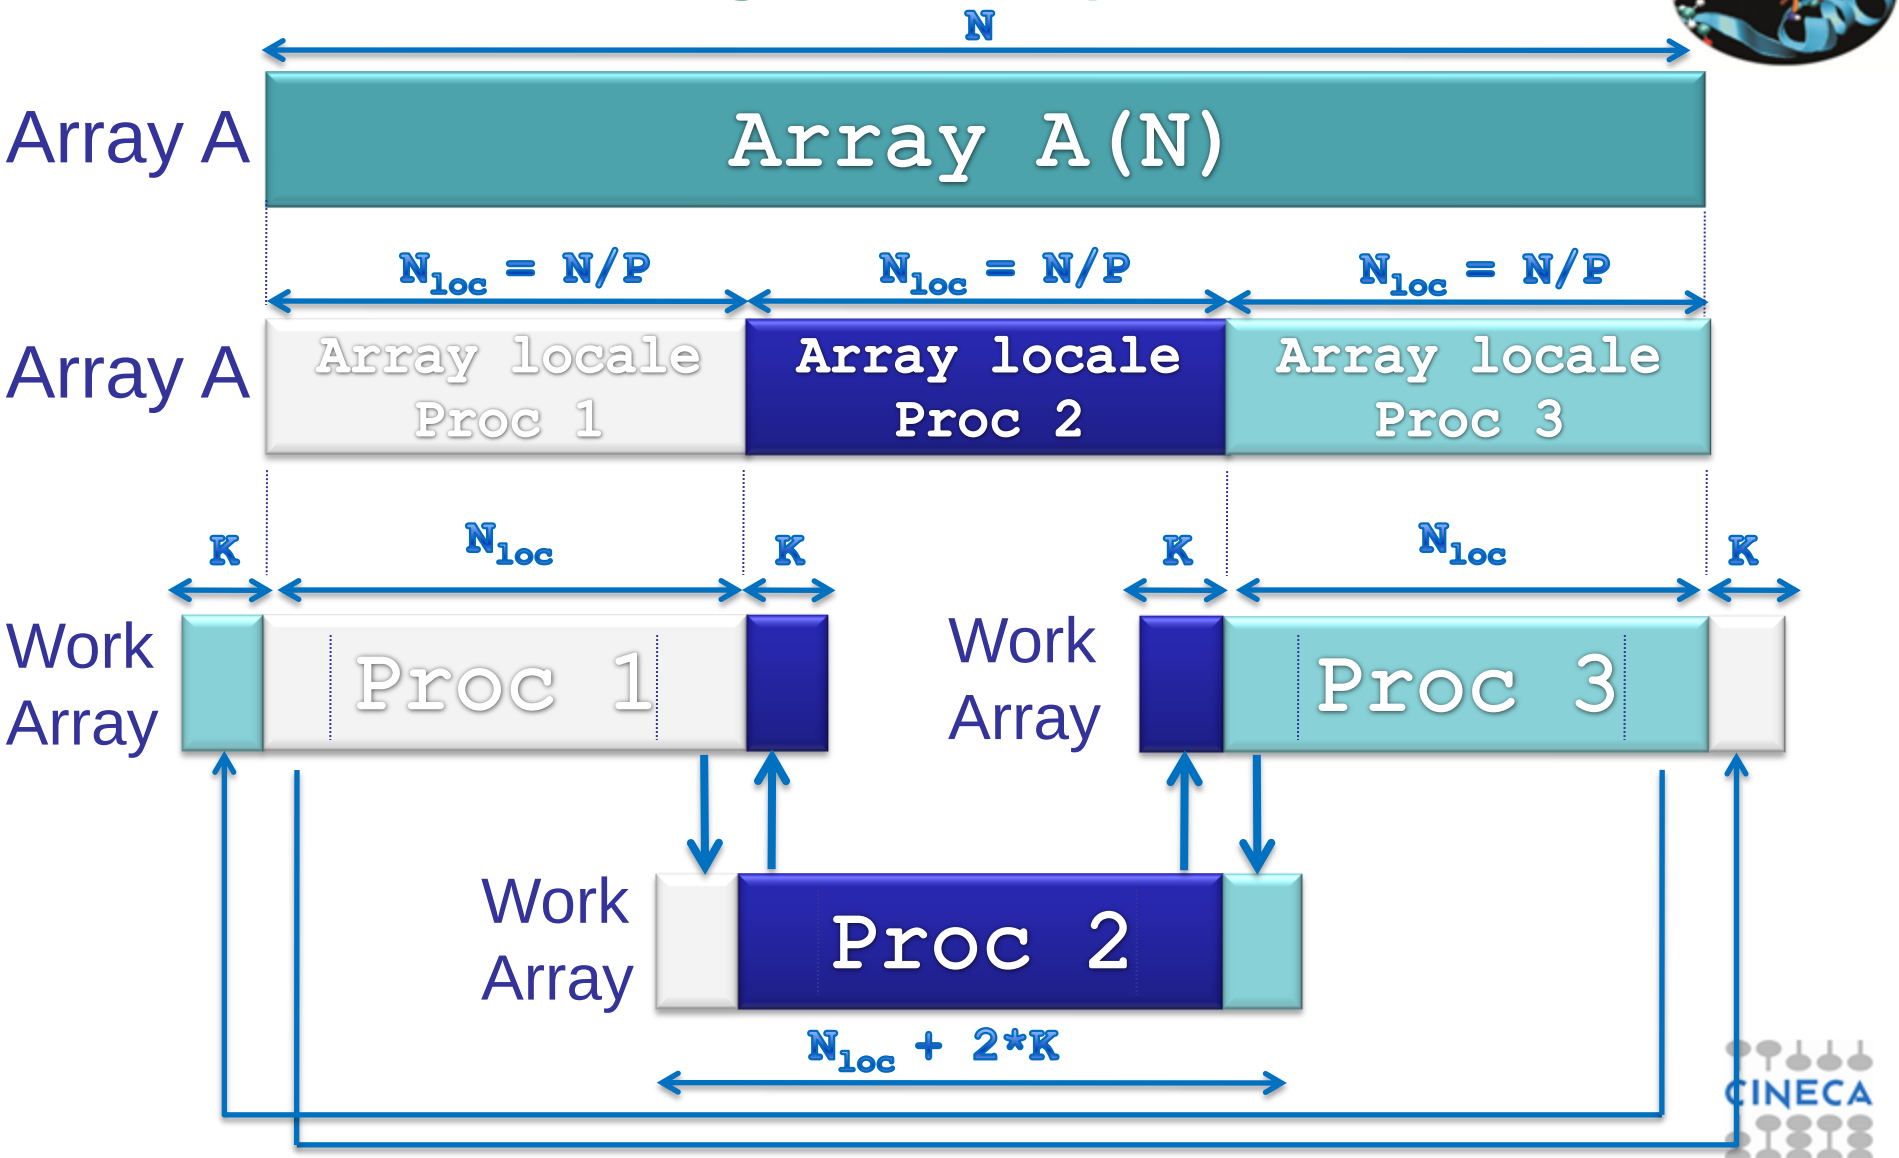

Array smoothing: algoritmo parallelo

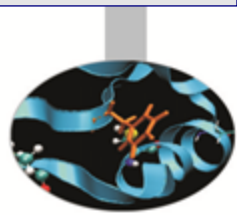

- Il processo di *rank* 0
  - genera l'*array* globale di dimensione N , multiplo del numero P di processi
  - inizializza il vettore A con A[i] =i
  - distribuisce il vettore A ai P processi i quali riceveranno N_{loc} elementi nell'array locale (MPI_Scatter)
- Ciascun processo ad ogni passo di *smoothing*:
  - costruisce l'array di lavoro:
    - I primi K elementi dovranno ospitare la copia degli ultimi K elementi *dell'array* locale in carico al processo precedente (MPI_Sendrecv)
    - I successivi N_{loc} elementi dovranno ospitare la copia degli N_{loc} elementi dell'*array* locale in carico al processo stesso
    - Gli ultimi K elementi dovranno ospitare la copia dei primi K elementi del l'*array* locale in carico al processo di *rank* immediatamente superiore (MPI_Sendrecv)
  - Effettua lo *smoothing* degli N_{loc} elementi interni e scrive i nuovi elementi sull'array A
- Il processo di *rank* 0 ad ogni passo raccoglie (MPI_Gather) e stampa i risultati parziali

Calcolo di π con *reduction*: algoritmo parallelo

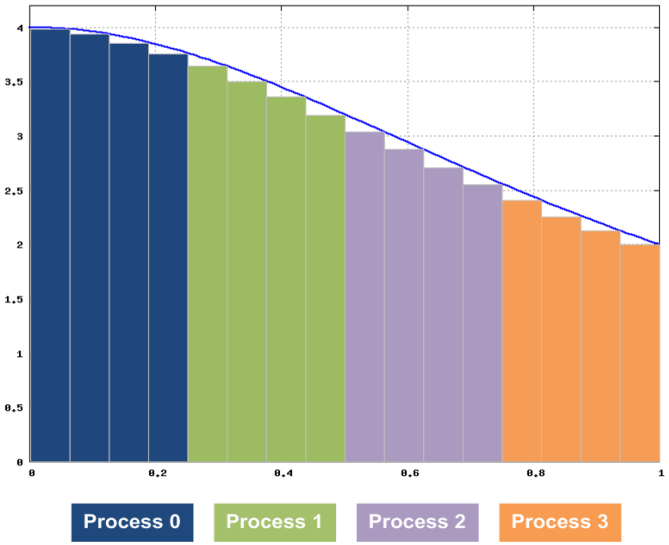

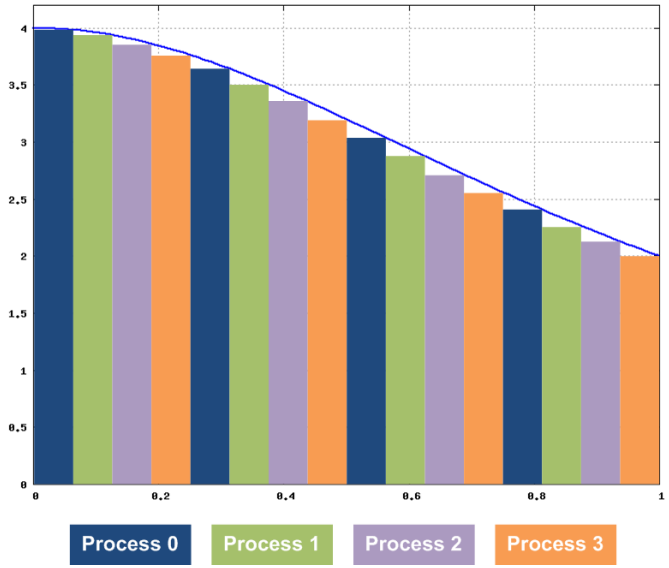

- Ogni processo calcola la somma parziale di propria competenza rispetto alla decomposizione scelta, come nel caso dell'esercizio 3
- Tutti i processi contribuiscono all'operazione di somma globale utilizzando la funzione di comunicazione collettiva `MPI_Reduce`

Calcolo di π in parallelo con *reduction*: *flowchart*

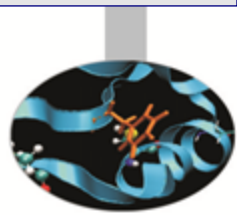

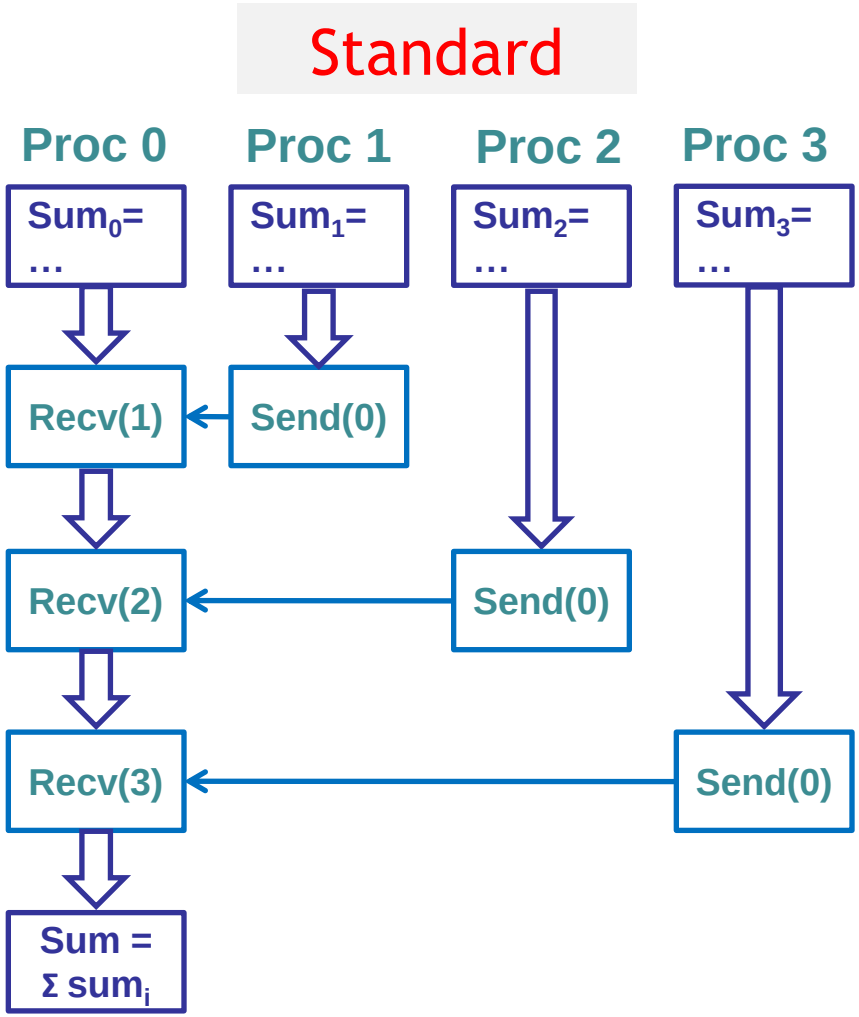

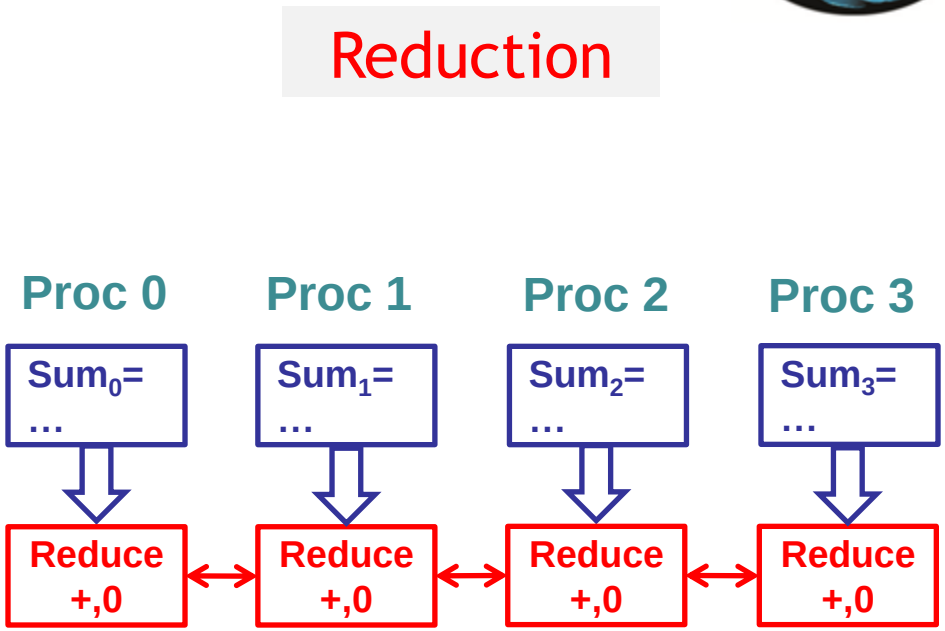

Prodotto Matrice-Vettore

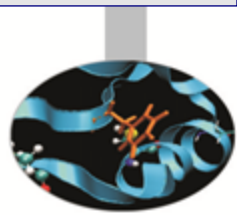

- Data una matrice A, di dimensione `size*size`, ed un vettore V di dimensione `size`, calcolare il prodotto C=A*V
- Ricordando che:

$$C_m = \sum_{n=1}^{size} A_{mn} V_n$$

- Nella versione parallela, per semplicità, assumiamo che `size` sia multiplo del numero di processi

Prodotto matrice-vettore: algoritmo seriale

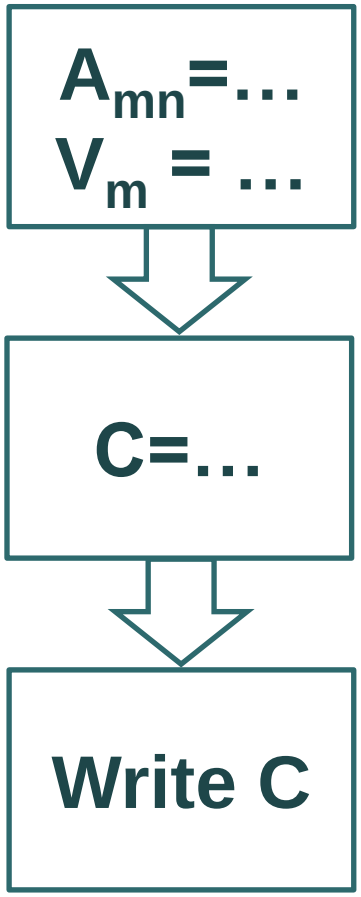

- Inizializzare gli array A e V
  - $A_{mn} = m+n$
  - $V_m = m$
- Core del calcolo
  - Loop esterno sull'indice m=1,`size` di riga della matrice A (e del vettore C)
  - Loop interno sull'indice n=1,size del vettore V
  - Calcolo del prodotto $A_{mn}*V_n$ ed accumulo su C_m
- Scrittura del vettore C

Prodotto matrice-vettore

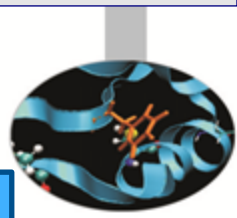

Versione seriale

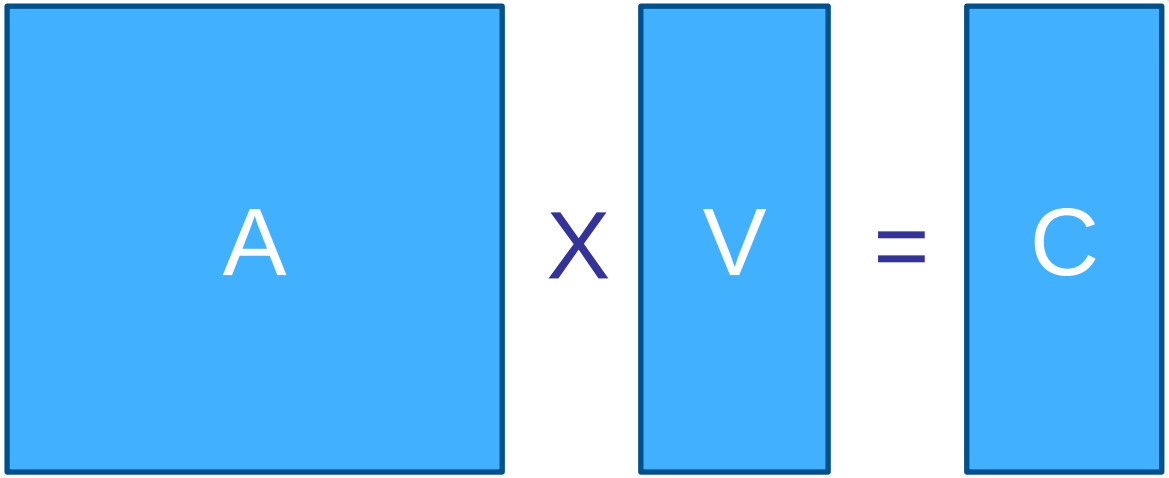

Versione parallela

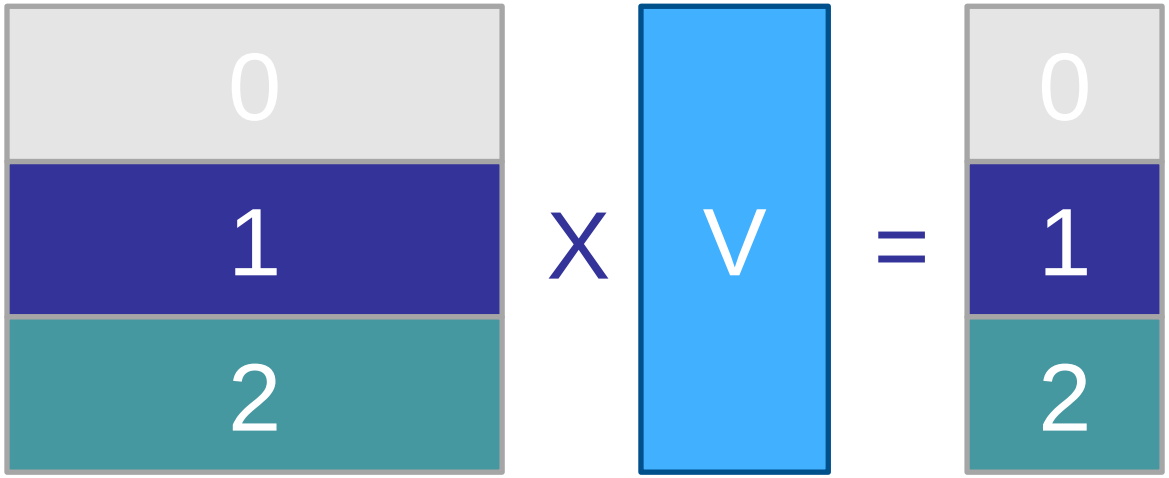

N.B. Poiché in Fotran le matrici sono allocate per colonne,
è necessario effettuare la trasposizione della matrice A

Prodotto matrice-vettore in parallelo

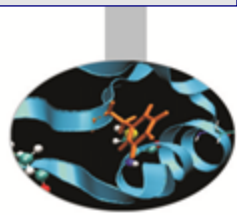

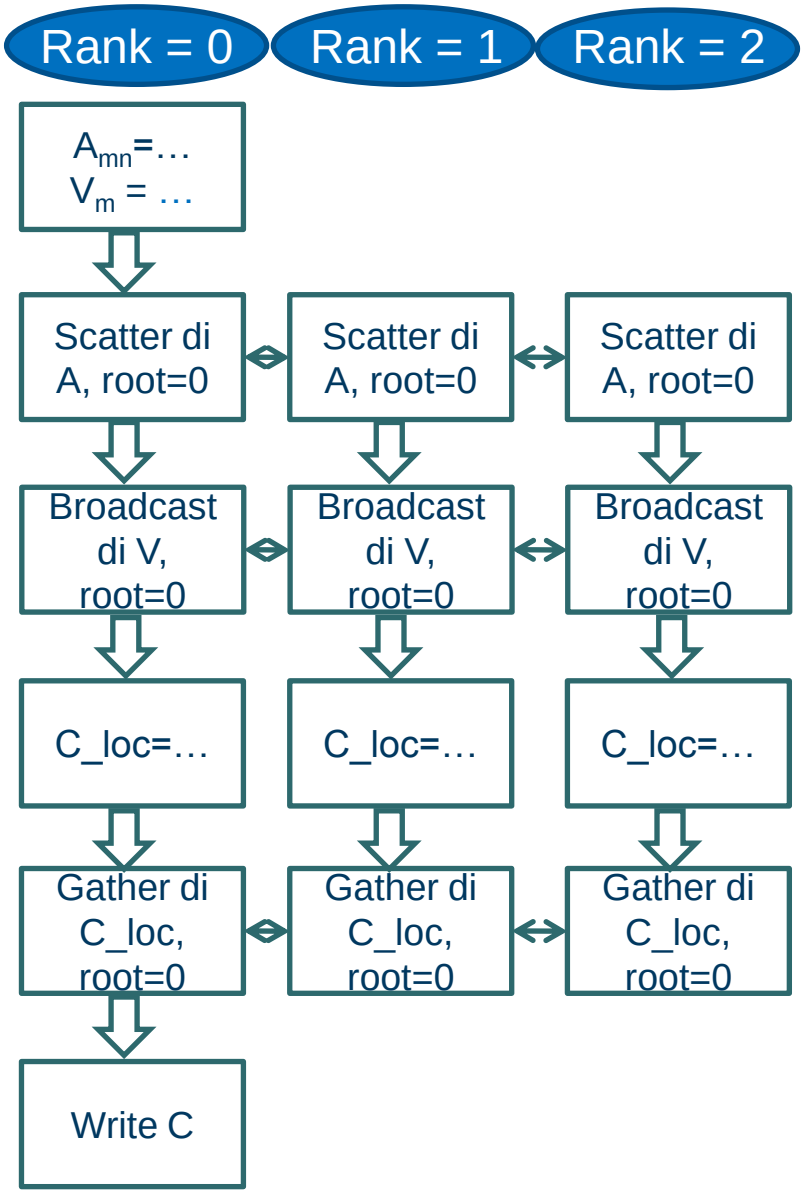

- Inizializzare gli array `A` e `V` sul solo processo master (rank = 0)
- Scatter della matrice `A` e broadcast del vettore `V`
  - Il processo master distribuisce a tutti i processi, se stesso incluso, un sotto-array (un set di righe contigue) di `A`
  - Il processo master distribuibuisce a tutti i processi, se stesso incluso, l'intero vettore `V`
  - I vari processi raccolgono i sotto-array di `A` e `V` in array locali al processo (es. `A_loc` e `V_loc`)
- Core del calcolo sui soli elementi di matrice locali ad ogni processo (es. `A_loc` e `V_loc`)
  - Loop esterno sull'indice `m=1,size/nprocs`
  - Accumulo su C_loc_m
- Gather del vettore `C`
  - Il processo master (rank = 0) raccoglie gli elementi di matrice del vettore risultato C calcolate da ogni processo (C_loc)
- Scrittura del vettore `C` da parte del solo processo master

Prodotto Matrice-Matrice

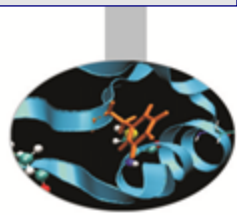

- Date due matrici A e B di dimensione size*size, calcolare il prodotto C=A*B
- Ricordando che:

$$C_{mn} = \sum_{k=1}^{size} A_{mk} B_{kn}$$

- La versione parallela andrà implementata assumendo che size sia multiplo del numero di processi

Prodotto matrice-matrice: algoritmo seriale

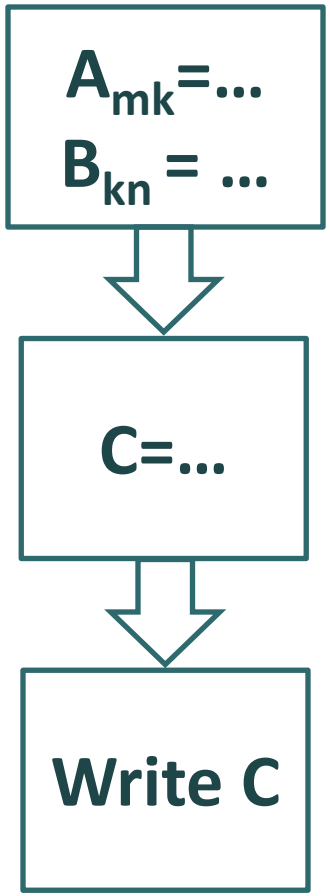

- Inizializzazione degli array A e B
  - A_{mk} = m+k
  - B_{kn} = n+k
- Core del calcolo
  - Loop esterno sull'indice m=1,size di riga della matrice A (e della matrice C)
  - Loop intermedio sull'indice n=1,size di colonna della matrice B (e della matrice C)
  - Loop interno sull'indice k=1,size di colonna della matrice A e di riga della matrice B
  - Calcolo del prodotto A_{mk}*B_{kn} ed accumulo su C_{mn}
- Scrittura della matrice C

Prodotto matrice-matrice in C

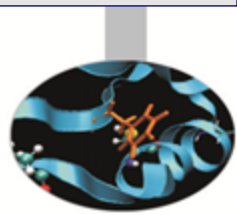

Versione seriale

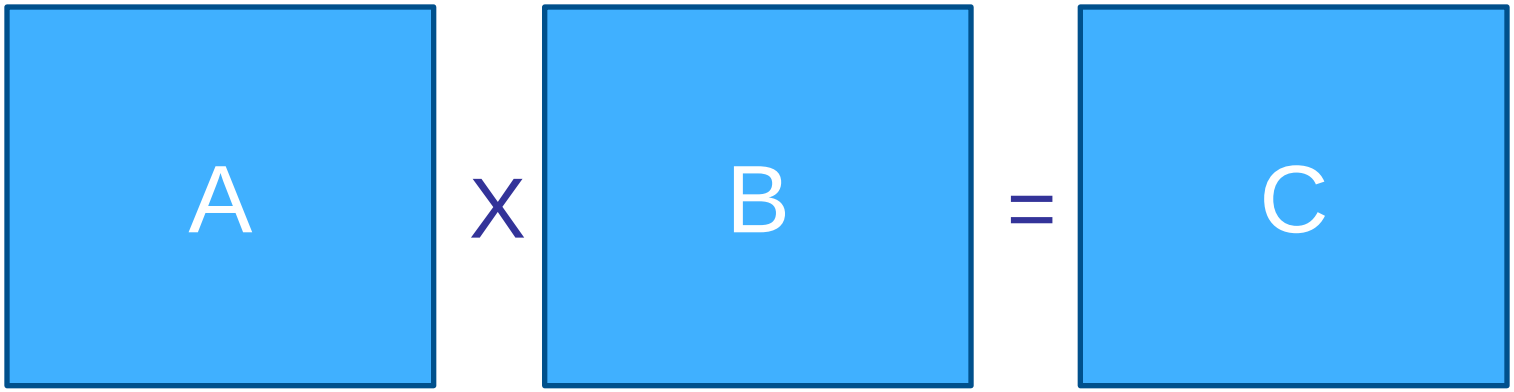

Versione parallela

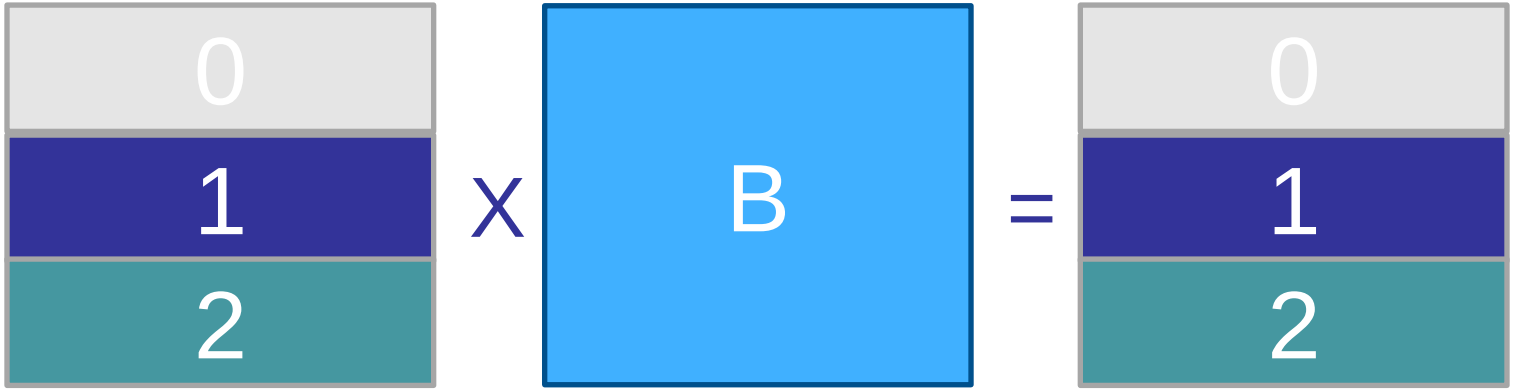

Prodotto matrice-matrice in Fortran

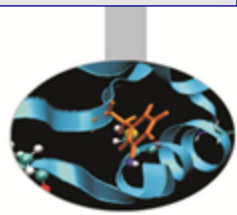

Versione seriale

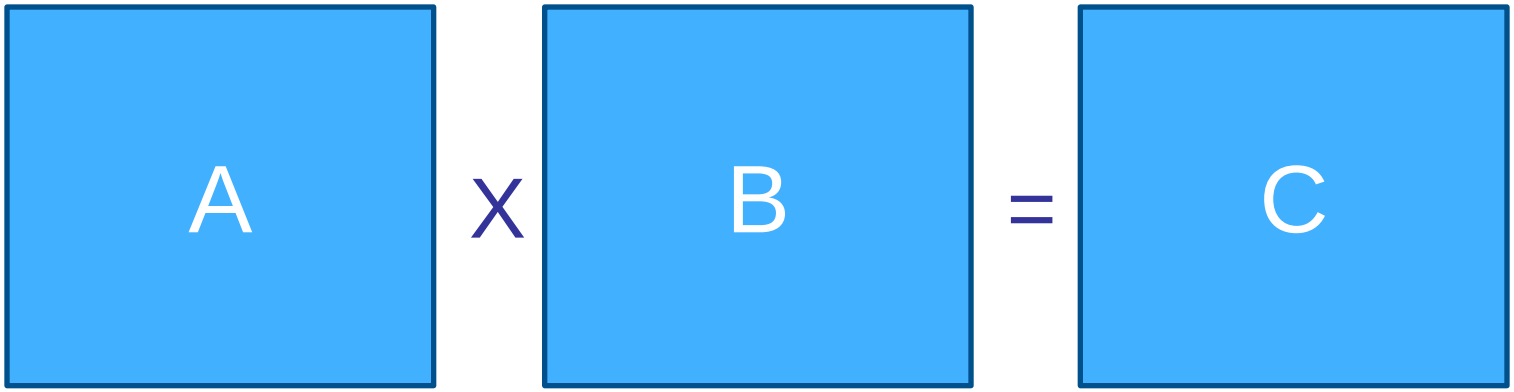

Versione parallela

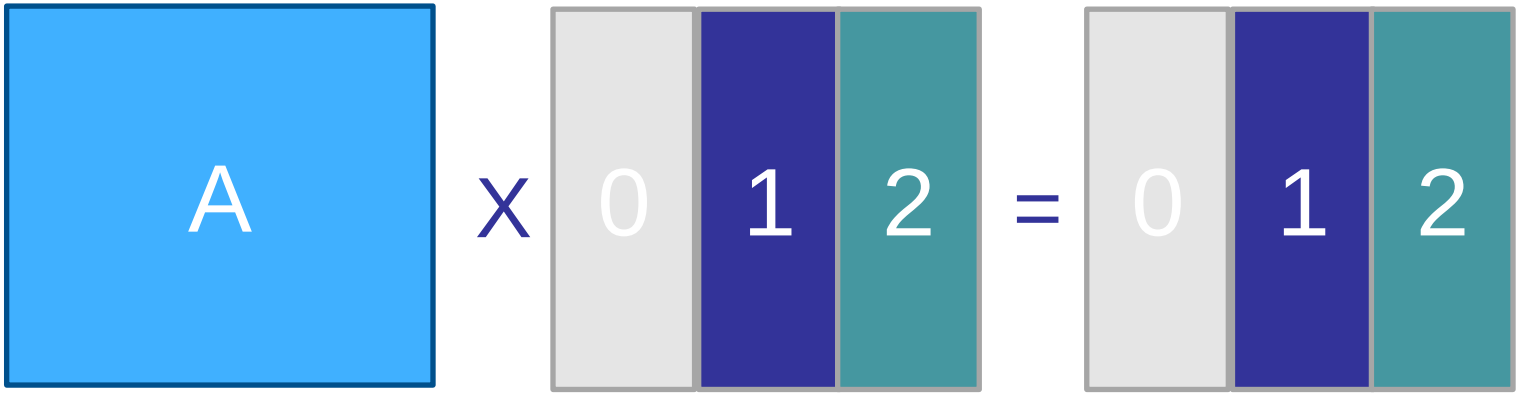

Prodotto matrice-matrice in parallelo

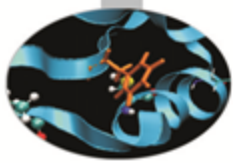

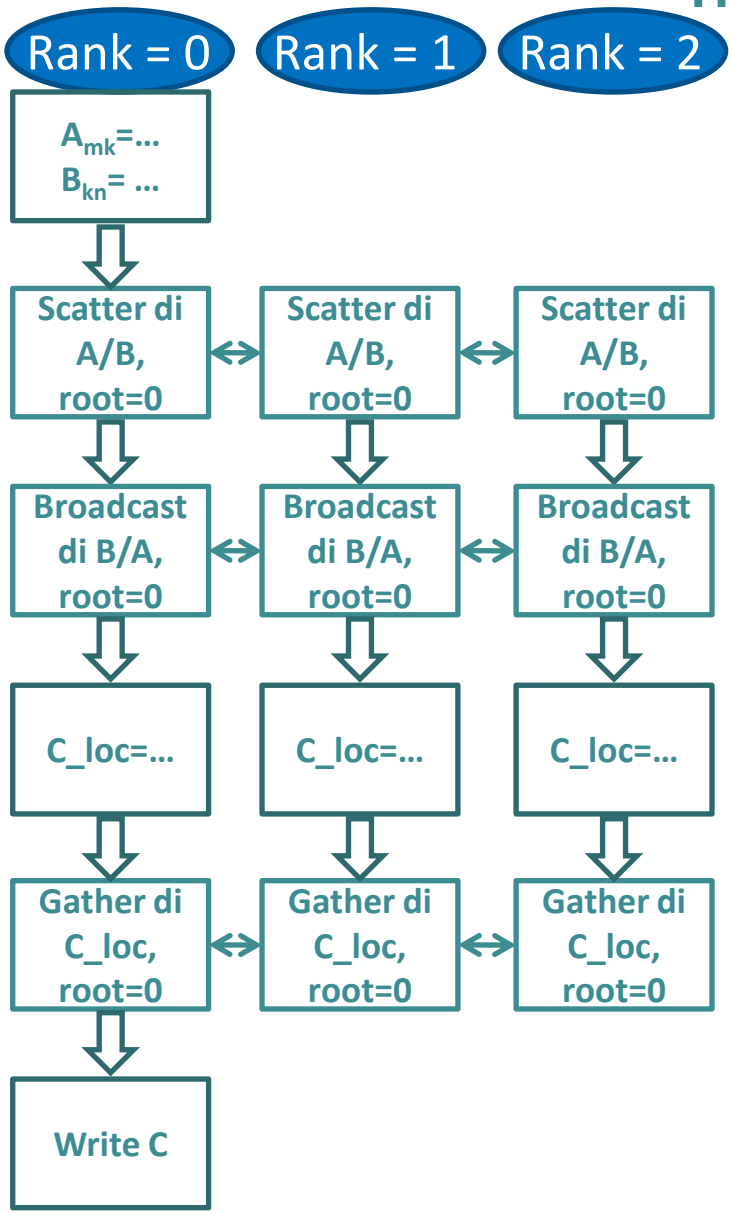

- Inizializzare le matrici `A` e `B` sul solo processo master (rank = 0)
- In C Scatter della matrice `A` e Broadcast di `B` (viceversa in Fortran)
  - Il processo master distribuisce a tutti i processi, se stesso incluso, un sotto-array (un set di righe contigue) di `A` (B in Fortran)
  - Il processo root distribuisce a tutti i processi, se stesso incluso, l'intera matrice `B (A)`
  - I vari processi raccolgono i sotto-array di `A (B)` in un array locale al processo (es `A_loc`)
- Core del calcolo sui soli elementi di matrice locali ad ogni processo
  - Loop esterno sull'indice `m=1,size/nprocs`
  - Accumulo su C_loc_m
- Gather della matrice `C`
  - Il processo master (rank = 0) raccoglie gli elementi della matrice risultato C calcolate da ogni processo (C_local)
- Scrittura della matrice `C` da parte del solo processo master