




**Corso di formazione per il progetto TEDAT
ENEA C. R. Brindisi, 24-25 giugno 2013**

Introduzione al calcolo scientifico ad alte prestazioni

Agostino Funel
agostino.funel@enea.it
ENEA Centro Ricerche Portici
P.le Enrico Fermi 1, Portici (Napoli)



PARTE I

- Breve introduzione storica all'informatica
- Esempi concreti della necessità dei supercalcolatori
- Evoluzione tecnologica: verso i sistemi massicciamente paralleli
- Supercalcolo e calcolo distribuito: un accenno a ENEA-GRID
- La top500: la classifica mondiale dei supercalcolatori

PARTE II

- Principi del calcolo parallelo
- Il paradigma MPI (Message Passing Interface)
- Valutazione delle prestazioni
- Esempi


Introduzione

Il metodo scientifico: confronto tra
teoria ed **esperimenti**.


**Teoria : problemi complessi, conti
complicati, metodi numerici.**

**Esperimenti : producono moltissimi
dati da analizzare.**


Modelli ↔ Simulazioni



Galileo Galilei (Pisa, 1564 – Arcetri, 1642)



**Sono necessari strumenti
di calcolo automatico**




Un po' di storia/1

1757 : la data di ritorno della **cometa di Halley** viene calcolata dai tre matematici francesi Alexis Clairault, Joseph Lalande e Nicole-Reine Lepaute : “il ritorno della cometa avverrà con 651 giorni di ritardo per effetto dei pianeti Giove e Saturno”.

La cometa anticipa di soli 31 giorni la data prevista.



Il calcolo aveva impegnato a tempo pieno per 5 mesi i tre matematici!



Un po' di storia/2



1790 : l'Assemblea Nazionale francese introduce il sistema metrico. La proposta si estende anche alla misura degli angoli :
l'angolo retto viene diviso in 100 parti.

Servono **nuove tavole trigonometriche!**

L'incarico viene assegnato ad un ingegnere Gaspard de Prony :

Una squadra di 90 “calcolatori” lavora per 3 anni producendo 18 volumi manoscritti.

1795 : la nuova unità viene abbandonata.



L'informatica moderna

Fino alla II guerra mondiale “computer” indica una professione : il “Mathematical Table Project” (USA, 1938) impiega 450 “computers” per preparare tavole matematiche di ogni tipo.

L'evoluzione delle tecnologie elettromeccaniche/elettroniche negli anni di guerra produce i primi “computer” automatici (Z3 Germania 1941, ENIAC USA 1943...)

Durante la II guerra mondiale i computer furono utilizzati in USA nei Los Alamos Laboratories per la costruzione della prima bomba atomica.

L'invenzione del **microprocessore** (1970) rende possibile l'**informatica di consumo** (>1980) e della **connettività diffusa** (>1990).

Oggi il PC di casa esegue $\sim 10^9$ operazioni/secondo e comunica a $10^5 - 10^6$ caratteri/secondo.



J. Von Neumann
(Budapest 1903 - Washington 1957)



Scienze computazionali/1


A partire dalla teoria di base è possibile costruire modelli concreti il cui studio dettagliato richiede spesso l'esecuzione di moltissime operazioni matematiche. In questo caso è assolutamente necessario usare i supercalcolatori. A volte il calcolo consente di predire fenomeni sia su piccola che su grande scala.

Un caso concreto: simulazione di aerodinamica esterna di interesse industriale.

La simulazione è stata fatta sul supercalcolatore CRESCO dell'ENEA.

30 milioni di celle

$\sim 5 \times 10^{15}$ operazioni matematiche




Un caso concreto: simulazione di dinamica molecolare per studiare l'immagazzinamento dell'idrogeno nei metalli ibridi.

Il sistema è composto da una cavità di nanoparticelle contenente 266 atomi di Mg.

Calcolo della densità elettronica.


La simulazione è stata fatta sul supercalcolatore CRESCO dell'ENEA.

La simulazione ha richiesto in media $\sim 1.8 \times 10^{14}$ operazioni matematiche per fare una sola iterazione.



Combustion Dynamics in VOLVO FligMotor

C3H8/Air Premixed Combustor




[E. Giacomazzi et al., Comb. and Flame, 2004]

CH4/Air Premixed Comb.

in DG15-CON [ENEA]

[D. Cecere et al., Flow
Turbul. and Comb., 2011]




SANDIA Syngas Jet Flame "A"

[E. Giacomazzi et al.,
Comb. Theory and Modelling, 2007]

Comb. Theory and Modelling, 2008]

**Combustione: simulazione
fatta sul supercalcolatore
CRESCO dell'ENEA.3 mesi di
calcolo con più di 1000 core**




PSI Pressurized Syngas/Air Premixed
Combustor

H2 Supersonic Combustion

in HyShot II SCRAMJET

[D. Cecere et al.,
Int. J. of Hydrogen Energy, 2011]

Shock Waves, 2012]




Il supercalcolo (HPC High Performance Computing)

Supercomputer: sono i calcolatori più potenti disponibili in un dato arco di tempo. **Potente**: in termini di velocità di esecuzione, capacità di memoria, precisione di macchina.


Aumentare la velocità dei componenti elettronici: **limite imposto dalla velocità della luce, problemi di dissipazione del calore.**

Aumentare il numero di componenti elettronici: sistemi massicciamente paralleli. Sì, ma non basta...velocità diverse per componenti diversi generano cali di prestazioni.

Nuovo paradigma di sviluppo dei codici!





Legge di Moore: il numero dei transistor per unità di area raddoppia ogni 18 mesi.



ENEA
AGENZIA NAZIONALE
PER LE NUOVE TECNOLOGIE, L'ENERGIA
E LO SVILUPPO ECONOMICO SOSTENIBILE

I Centri ENEA-GRID sono connessi dalla rete GARR.

Brindisi: ~100



La classifica dei supercomputer

II LINPACK Benchmark

È il benchmark utilizzato per classificare la potenza computazionale dei supercomputer in base al numero di operazioni in virgola mobile che il sistema può fare in 1 secondo

FLOPS: Floating-point Operations Per Second.

Top500 List - June 2013

$R_{\max}$ and R_{peak} values are in TFlops.



www.top500.org

Computer performance

Name	FLOPS
yottaFLOPS	10^{24}
zettaFLOPS	10^{21}
exaFLOPS	10^{18}
petaFLOPS	10^{15}
teraFLOPS	10^{12}
gigaFLOPS	10^9
megaFLOPS	10^6
kiloFLOPS	10^3

Rank	Site	System	Cores	Rmax (TFlop/s)	Rpeak (TFlop/s)	Power (kW)
1	National University of Defense Technology China	Tianhe-2 (MilkyWay-2) - TH-IVB-FEP Cluster, Intel Xeon E5-2692 12C 2.200GHz, TH Express-2, Intel Xeon Phi 31S1P NUDT	3120000	33862.7	54902.4	17808

Argomenti

- Concetto di elaborazione parallela
- Principali architetture parallele
- Paradigmi della programmazione parallela
- Modelli di parallelismo
- Gestione dei conflitti


Elaborazione parallela

Filosofia: dividere un problema complesso in più parti che possono essere risolte separatamente ed elaborarle simultaneamente (“in parallelo”).


Programmazione parallela: programma in cui più processi (**task**) comunicano tra loro per risolvere un problema mediante **algoritmi non sequenziali**.

Calcolatore parallelo: sistema **multiprocessore** in grado di eseguire programmi paralleli.


Elaborazione sequenziale




Pipelining




Elaborazione parallela




Architetture parallele




Sistema a Memoria Distribuita




Sistema a Memoria Condivisa




Sistema ibrido



Data Parallel (memoria condivisa): tutti i processi, generalmente **thread**, vedono la stessa memoria condivisa e possono direttamente accedervi. **Variabili e strutture dati condivise.**




Message Passing (memoria distribuita): ciascun processo può accedere solo alla sua memoria locale e comunica con gli altri processi **scambiandosi messaggi.**




Paradigmi della programmazione parallela/2

Data Parallel	Message Passing
Compilatori ad hoc	Compilatori standard
Linguaggi: Fortran/90, C/C+,...	Linguaggi: Fortran/90, C/C++,...
Direttive al compilatore nel codice sorgente	Librerie per la comunicazione
Eseguibile si lancia come un comando di shell Unix	L'eseguibile si lancia mediante appositi wrapper
Standard: Open MP , HPF,...	Standard: MPI , PVM,...

Parallelismo sui dati (domain decomposition) : i dati sono divisi in parti aventi approssimativamente la stessa dimensione e sono mappati su processori diversi. Ciascun processore esegue lo stesso programma sulla sua parte di dati (**SPMD Single Program Multiple Data**).




- Il posizionamento dei dati è critico
- Problema della gestione del bordo
- Problema del bilanciamento del carico
- Programmazione in message passing



Parallelismo funzionale (functional decomposition) : il problema è suddiviso in un gran numero di “compiti” o “funzioni” o “sottoprogrammi”, che vengono assegnati ai processori. Ogni processore esegue una diversa “funzione” appena è disponibile. Un processore può operare su dati condivisi (**MPSD Multiple Program Single Data**) oppure su dati privati (**MPMD Multiple Program Multiple Data**). Implementazione: client/server oppure master/slave.

- Identificare le funzioni e i requisiti sui dati
- Gestione dei conflitti sui dati condivisi
- Programmazione in data parallel o message passing




Modello Shared Memory.

L'accesso concorrente in lettura a una stessa locazione di memoria non causa problemi: ogni processore fa una copia del contenuto della locazione di memoria e la memorizza in un proprio registro.

Il problema si verifica quando c'è un accesso concorrente in scrittura ossia quando più processi scrivono simultaneamente sulla stessa locazione di memoria.

Il programmatore, il linguaggio di programmazione e/o l'architettura devono fornire strumenti per gestire il conflitto.



Modello Shared Memory.

Il non determinismo (race condition): avviene quando due istruzioni in task concorrenti accedono la stessa locazione di memoria e almeno una delle istruzioni è in scrittura. Non c'è un ordine di esecuzione garantito tra gli accessi.

Il problema si può risolvere sincronizzando l'utilizzo dei dati condivisi.

Le porzioni di programma che richiedono sincronizzazione sono dette **sezioni critiche**. Occorrono costrutti per accedere in modo **mutuamente esclusivo** alle sezioni critiche.

Processor 1:

LOCK (X)

$X = X + 1$

UNLOCK (X)

Processor 2:


LOCK (X)

$X = X + 2$

UNLOCK (X)

Deadlock o stallo.

Si verifica quando due (o più) processi sono **bloccati** perché ciascuno aspetta che l'altro faccia qualcosa.



Argomenti

- Il paradigma MPI
- Tipi di comunicazione
- Tipi di sincronizzazione
- Aspetti importanti della tecnica di programmazione
- Struttura di un programma MPI
- Comunicazione point-to-point
- Comunicazioni collettive
- Valutazione delle prestazioni
- Esempi

MPI – Message Passing Interface/1



Standard per la programmazione parallela:

<http://www.mpi-forum.org/>

Ogni processo ha le sue risorse **locali** (spazio degli indirizzi logici disgiunto). La comunicazione avviene attraverso **scambi di messaggi**.

Messaggi: istruzioni, dati, segnali di sincronizzazione.

Lo schema MPI si può implementare anche su architetture shared memory, ma non conviene perché il ritardo della comunicazione è maggiore di quello che si ha accedendo a variabili condivise in una memoria comune.

MPI – Message Passing Interface/2


Il processo mittente e quello destinatario devono cooperare.

Tempo della comunicazione: inizializzazione + trasferimento dati + sincronizzazione + chiusura (finalizzazione) dei processi.

Due operazioni fondamentali:

Send(messaggio, parametri)

Receive(messaggio, parametri)



Comunicazione simmetrica:

il mittente nomina esplicitamente il destinatario
il destinatario nomina il processo con cui vuole comunicare
lo schema di comunicazione è **da uno a uno**

Comunicazione asimmetrica:

il mittente nomina esplicitamente il destinatario
il destinatario non indica il nome del processo con cui vuole comunicare
schemi di comunicazione:

- **da molti a uno**
- **da uno a molti**
- **da molti a molti**

Bloccante:

- il processo mittente si blocca e attende che l'operazione richiesta dalla send giunga a compimento
- il processo ricevente rimane bloccato finché sul canale da cui vuole ricevere non viene inviato il messaggio richiesto

Non bloccante:

- il processo che emette una send non bloccante non attende che il messaggio spedito sia andato a buon fine, ma passa ad eseguire le istruzioni successive. Altre primitive consentono di verificare lo stato del messaggio inviato
- il processo che invoca una receive non bloccante consente di verificare lo stato del canale e restituisce il messaggio oppure una flag che indica che il messaggio non è ancora arrivato

Load Balancing

- Dividere equamente il carico di lavoro tra le risorse disponibili: processori, memoria, network bandwidth, I/O,...
- Più facile nel domain decomposition che nel functional decomposition model

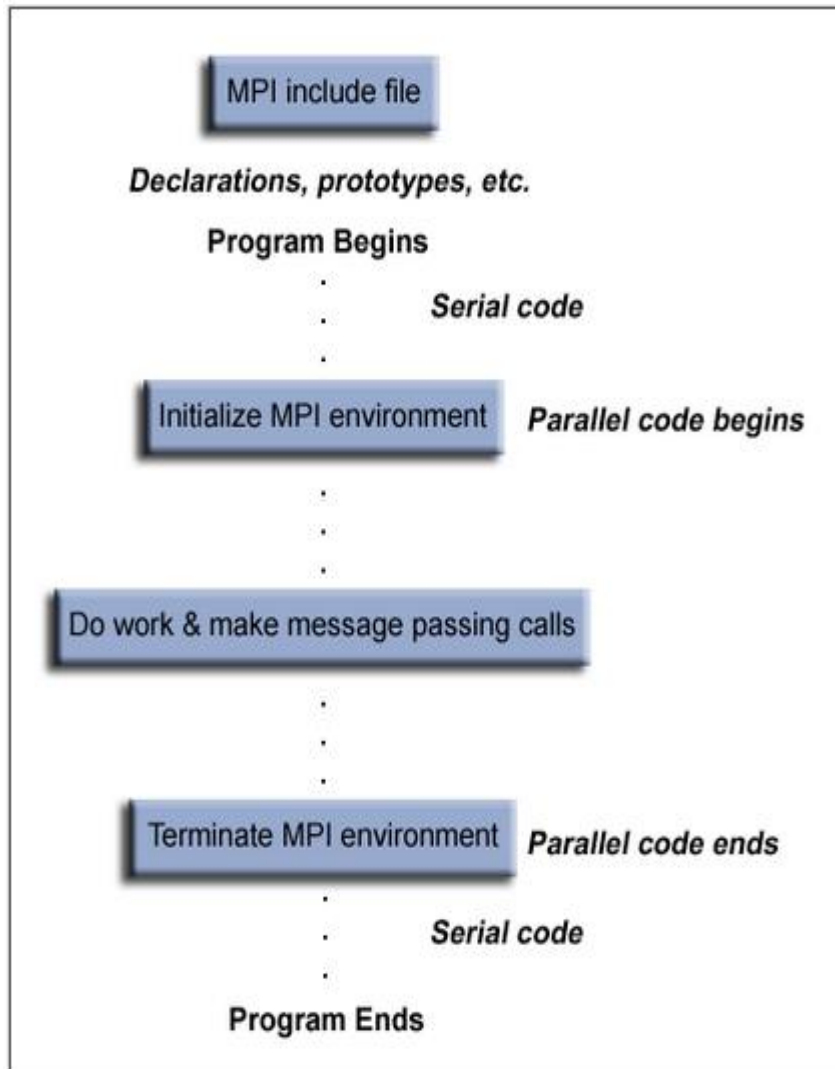
Minimizzare la comunicazione

- Raggruppare tante piccole comunicazione in una sola più grande
- Eliminare il più possibile le sincronizzazioni

Sovrapporre comunicazione e calcolo

- Programmare in modo che i processi continuino ad eseguire calcolo mentre comunicano

MPI – Tipica struttura del programma



```
#include "mpi.h"
```

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

```
#include <stdlib.h>
```

```
#define MASTER 0
```

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

```
{
```

```
int numtasks, taskid, len;
```

```
char hostname[MPI_MAX_PROCESSOR_NAME];
```

```
MPI_Init(&argc, &argv);
```

```
MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
```

```
MPI_Comm_rank(MPI_COMM_WORLD, &taskid);
```

```
MPI_Get_processor_name(hostname, &len);
```

```
printf ("Hello from task %d on %s!\n", taskid, hostname);
```

```
if (taskid == MASTER)
```

```
printf("MASTER: Number of MPI tasks is:
```

```
%d\n", numtasks);
```

```
MPI_Finalize();
```

```
}
```

La compilazione non è standard:


- Si devono specificare i path degli include (-I/mpidir/include)
- Il linker deve conoscere i path delle librerie (-L/mpidir/lib -lmpi)
- Se possibile utilizzare i wrapper per compilare/linkare (mpicc, mpif90)

L'esecuzione non è standard:

- Utilizzare degli appositi wrapper (mpirun, mpiexec)

Il Communicator è una variabile che identifica un gruppo di processi ai quali è consentito di comunicare tra loro.

Il comunicatore di default è **MPI_COMM_WORLD** ed include tutti i processi: tutti possono comunicare con tutti.



MPI_COMM_WORLD


Tutte le funzioni di comunicazione MPI hanno come argomento un comunicatore.

Il programmatore può definire più comunicatori all'interno dello stesso programma.

Dimensione del Communicator e rango di un processo

Size: numero dei processi associati al comunicatore

Rank: è l'indice del processo all'interno del gruppo associato al comunicatore (**rank = 0, 1,...,N-1**). Il rank è usato per identificare il processo mittente e destinatario in una comunicazione.



C	Fortran
Error = MPI_Xxxx(parametro,...) MPI_Xxxx(parametro,...)	CALL MPI_XXXX(parametro,...,IERROR)

Quanti processi sono associati al comunicatore?

MPI_Comm_size(MPI_Comm, int* size)

OUTPUT : size

Qual è il rank del processo?

MPI_Comm_rank(MPI_Comm, int *rank)

OUTPUT : rank

Comunicazione Point-to-Point


La comunicazione point to point è la base della comunicazione MPI.
Concettualmente semplice: A invia un **messaggio** a B e B riceve il messaggio da A.

La comunicazione avviene all'interno di un comunicatore.

Il mittente e il destinatario sono identificati dal loro **rank** all'interno del comunicatore.

Message Structure

envelope				body		
source	destination	communicator	tag	buffer	count	datatype



- Il messaggio è un array di tipi di dato MPI
- Tipi di dato differenti per C e Fortran
- Il messaggio può essere ricevuto solo se il ricevente specifica correttamente la **busta (envelope)**

Standard Send e Receive

Fortran:

```
MPI_SEND(buf, count, type, dest, tag, comm, ierr)  
MPI_RECV(buf, count, type, dest, tag, comm, status, ierr)
```

Message body envelope

C:

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

```
int MPI_Recv (void *buf, int count, MPI_Datatype type, int  
dest, int tag, MPI_Comm comm, MPI_Status *status);
```

Buf array of type `type` see table.

Count (INTEGER) number of element of `buf` to be sent

Type (INTEGER) MPI type of `buf`

Dest (INTEGER) rank of the destination process

Tag (INTEGER) number identifying the message

Comm (INTEGER) communicator of the sender and receiver

Status (INTEGER) array of size `MPI_STATUS_SIZE` containing
communication status information

Ierr (INTEGER) error code (if `ierr=0` no error occurs)

Sia in C che in Fortran `MPI_RECV` accetta le wildcard **`MPI_ANYSOURCE`** per ricevere da ogni mittente e **`MPI_ANYTAG`** per ricevere con qualsiasi tag.

Send e Receive bloccanti e non bloccanti

Mode	Completion Condition	Blocking subroutine	Non-blocking subroutine
Standard send	Message sent (receive state unknown)	<code>MPI_SEND</code>	<code>MPI_ISEND</code>
receive	Completes when a message has arrived	<code>MPI_RECV</code>	<code>MPI_IRECV</code>
Synchronous send	Only completes when the receive has completed	<code>MPI_SSEND</code>	<code>MPI_ISSEND</code>
Buffered send	Always completes, irrespective of receiver	<code>MPI_BSEND</code>	<code>MPI_IBSEND</code>
Ready send	Always completes, irrespective of whether the receive has completed	<code>MPI_RSEND</code>	<code>MPI_IRSEND</code>

Send e Receive : un esempio

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

void main (int argc, char * argv[])
{
    int      nproc, myid;
    MPI_Status status;
    float a[2];

    MPI_Init(&argc, &argv);
    nproc= MPI_Comm_size(MPI_COMM_WORLD, &nproc);
    myid = MPI_Comm_rank(MPI_COMM_WORLD, &myid);

    if( myid == 0 ) {
        a[0] = 3.0, a[1] = 5.0;
        MPI_Send(a, 2, MPI_FLOAT, 1, 10, MPI_COMM_WORLD);
    } else if( myid == 1 ) {
        MPI_Recv(a, 2, MPI_FLOAT, 0, 10, MPI_COMM_WORLD, &status);
        printf("%d: a[0]=%f a[1]=%f\n", myid, a[0], a[1]);
    }

    MPI_Finalize();
}
```

Coinvolgono un gruppo di processi


In un programma MPI le funzioni di comunicazione collettiva **sono chiamate da tutti i processi** appartenenti al comunicatore

Le comunicazioni collettive non interferiscono con le comunicazioni point-to-point e viveversa

Sono tutte bloccanti

I buffer di ricezione devono avere l'esatta dimensione

Ferma i processi fino a quando **tutti** i processi del comunicatore raggiungono la barriera. Si usa per la **sincronizzazione**.



Fortran:

```
CALL MPI_BARRIER( comm, ierr)
```

C:

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


Broadcast: **uno a tutti**. **Gli stessi dati** sono inviati dal processo root a tutti gli altri processi che fanno parte del comunicatore.

Fortran:

```
CALL MPI_BCAST(buf, count, type, root, comm, ierr)  
INTEGER count, type, root, comm, ierr  
Buf array of type type
```

C:



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



Comunicazioni collettive: Scatter/Gather

Scatter: uno a tutti. Dati differenti inviati dal processo root a tutti gli altri processi del comunicatore

Gather: tutti a uno. Dati differenti, inviati da tutti i processi del comunicatore, sono raccolti dal processo root.



Comunicazioni collettive: Scatter/Gather

Scatter: uno a tutti. Dati differenti inviati dal processo root a tutti gli altri processi del comunicatore

Gather: tutti a uno. Dati differenti, inviati da tutti i processi del comunicatore, sono raccolti dal processo root.


Fortran:

```
CALL MPI_SCATTER(sndbuf, sndcount, sndtype, rcvbuf, rcvcount, rcvtype, root, comm, ierr)
```


sender receiver

- Arguments definition are like other MPI subroutine
- **sndcount** is the number of elements sent to each process, not the size of **sndbuf**, that should be **sndcount** times the number of process in the communicator
- The sender arguments are significant only at root


Scatter



Gather



Alltoall: tutti a tutti. Ciascun processo invia i suoi dati a tutti gli altri.
Molto impegnativa per il network.




Comunicazioni collettive: Reduction

- raccogliere i dati da ciascun processo
- ridurre i dati a un singolo valore e immagazzinarli sul processo root
- diverse operazioni (somma, prodotto, min, max, operatori logici)

C:

```
int MPI_Reduce(void * snd_buf, void * rcv_buf, int count, MPI_Datatype type,  
MPI_Op op, int root, MPI_Comm comm)
```

snd_buf	input array of type type containing local values.
rcv_buf	output array of type type containing global results
Count	(INTEGER) number of element of snd_buf and rcv_buf
type	(INTEGER) MPI type of snd_buf and rcv_buf
op	(INTEGER) parallel operation to be performed
root	(INTEGER) MPI id of the process storing the result
comm	(INTEGER) communicator of processes involved in the operation
ierr	(INTEGER) output, error code (if ierr=0 no error occurs)



Un'architettura si dice **scalabile** se continua ad avere le stesse prestazioni per processore al crescere del numero dei processori e della dimensione del problema.

Due “criteri”: **speedup** ed **efficienza**.

Tempo di esecuzione seriale T_s : tempo di esecuzione del programma su di un singolo processore.

Tempo di esecuzione parallelo T_p : tempo di esecuzione del programma su un dato numero P di processori.


Molti fattori influenzano T_p : l'hardware, l'algoritmo, comunicazione, I/O,

Speedup: $S = T_s / T_p$

Speedup lineare $S = p$: corrisponde al caso (ideale) in cui $T_p = T_s / P$.

Speedup sub-lineare $S < P$: più normale. Dovuto a overhead di inizializzazione, sincronizzazione, comunicazione etc.

Speedup super-lineare $S > P$: non è frequente. Si può avere perché si presentano condizioni particolari: il programma sfrutta in maniera ottimale le gerarchie di memoria (dati in cache fit), miglior scheduling delle istruzioni, algoritmo particolarmente efficiente.



Un programma scala, per un numero di processori P , se passando da $P-1$ a P processori non si osserva una diminuzione dello speedup.

Efficienza: $E=S/P$

Speedup lineare $\Rightarrow E=1$ ciascun processore lavora in maniera ottimale.

Lo speedup tende a raggiungere un plateau (saturazione) quando si raggiunge un certo numero di processori. Aumentare ulteriormente il numero dei processori non migliora lo speedup.

Sia C_s un codice seriale e T_s il suo tempo di esecuzione.

La parallelizzazione non sarà mai totale.

Frazione seriale $f_s = (\text{tmp. esec. parte seriale su 1 P})/T_s$

Frazione parallela $f_p = (\text{tmp. esec. della parte par. su 1 P})/T_s$ $(f_s + f_p) = 1$



$$T_p = T_s f_s + (T_s f_p)/P \text{ (caso ideale)}$$

$$S = T_s/T_p = 1/[f_s + (f_p/P)] \quad P \rightarrow \infty \quad S \rightarrow 1/f_s$$

“Legge” di Amdhal: se un codice parallelo ha una frazione seriale (non parallelizzabile) lo speedup ha un limite superiore.

Per es. se il 5% del codice è sequenziale lo speedup non potrà mai superare 20 anche aumentando indefinitamente il numero dei processori.

Valutazione delle prestazioni/5



cores	1	32	64	128	256	520	1024	1600	2000
speed-up	1	25.5	53.4	106.2	217.2	482.2	913.3	1491.4	1867.5
efficiency	1	0.80	0.83	0.83	0.85	0.93	0.89	0.93	0.93
time	62.7 days	2days 11h	1 day 4h	14.2 hours	7 hours	3h 7min	1h 38min	1 hour	48 min

Moltiplicazione di matrici MPI


- Il processo master invia una riga di A e una colonna di B al processo worker

```
MPI_Send(&a,...); MPI_Send(&b,...);
```

- Il worker riceve e calcola l'elemento di C

```
MPI_Recv(&a,...); MPI_Recv(&b,...);
```

```
for (k=0; k<NCB; k++)  
  for (i=0; i<rows; i++)  
  {  
    c[i][k] = 0.0;  
    for (j=0; j<NCA; j++)  
      c[i][k] = c[i][k] + a[i][j] * b[j][k];  
  }
```



- Il worker invia il risultato al master

```
MPI_Send(&c,...);
```

- Il master riceve , stampa il risultato e chiude tutti i processi

```
MPI_Recv(&c,...);
```

Moltiplicazione di matrici: risultati

- **Compilazione e lancio programma seriale**

```
icc -o ser_mm_c ser_mm.c
```

```
time ./ser_mm_c
```

- **Compilazione e lancio programma parallelo**

```
mpicc -o mpi_mm_c mpi_mm.c
```

```
time mpirun -np numero_core ./mpi_mm_c
```

Dimensione matrice N	Tempo seriale	Tempo 4 core	Tempo 8 core	Tempo 16 core
1000	3s	2.6s	2s	3s
2000	24s	12s	8s	9s
5000	6m 30s	2m 47s	2m 4s	2m 11s


- **Al crescere di N il programma parallelo è più vantaggioso**

Calcolo di Pi col metodo Monte Carlo

- Area cerchio/Area quadrato = $\pi/4$
- Si generano **N** punti a caso nel quadrato
- Si conta il numero **Nc** di punti che cadono nel cerchio
- $\pi \approx 4 \text{ Nc} / \text{N}$
- Ciascun processo genera **N / num. proc.** punti e conta (**mysum**) quanti di essi capitano nel cerchio
- Ciascun processo invia al master la sua conta parziale (**mysum**); il master le somma (**MPI_SUM**), calcola **Nc** e quindi π

`MPI_Reduce(&mysum,&Nc,...,MPI_SUM,master_rank,..);`

	Tempo seriale	Tempo 4 core	Tempo 8 core	Tempo 16 core
N= 10¹⁰	4m 57s	1m 15s	43s	33s



- Trovare gli interi J tra A e B che soddisfano la relazione $F(J)=C$ dove F è una funzione assegnata e C una costante
- Programma seriale: esamina uno per volta tutti gli interi J tra A e B e controlla se ciascuno di essi soddisfa $F(J)=C$
- Programma parallelo (p processi): ciascun processo esamina un sottoinsieme di $[A,B]$

id=0 $[A, A+p, A+2p, \dots]$


id=1 $[A+1, (A+1) + p, (A+1) + 2p, \dots]$

Tempo seriale	Tempo 4 core	Tempo 8 core	Tempo 16 core
58s	20s	12s	7s

Riferimenti



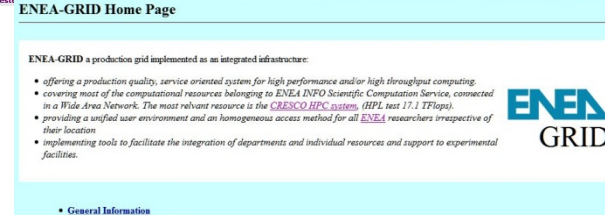
- **www.enea.it**



- **www.cresco.enea.it**



- **www.eneagrid.enea.it**



- **www.afs.enea.it**




Back slides



OpenMP (Open Multi Processing)

- Interfaccia di programmazione basata sul **multithreading** utilizzata su sistemi a **memoria condivisa**.
- Programmazione basata su « **direttive** » al **compilatore**, **librerie run time**, **variabili di ambiente**.
- Regioni parallele **Fork-Join**.



Processo: è un programma in esecuzione.

Istruzioni eseguite in sequenza come specificato nel testo del programma.

Il SO può gestire l'esecuzione di più processi.

Contex switch: l'uso della CPU viene commutato da un processo ad un altro (oneroso).

Il SO associa delle risorse a un processo: connessioni di rete, memoria, disco etc.

Processi diversi accedono ad aree di memoria diverse.

Il processo è rappresentato da:

- **codice** (text) del programma eseguito
- **Dati:** variabili globali
- **Program Counter**
- Alcuni **registri** di CPU
- **Stack:** parametri, variabili locali a funzioni/procedure

Un “thread” (o processo leggero) è un flusso di esecuzione che vive all'interno di un processo.

Thread= {PC, registri, stack}

Un thread condivide con il processo e con altri thread (multithreading) dati, codice e risorse.

Ecco perché su un singolo nodo l'accesso alla memoria condivisa è più veloce rispetto al caso di più processi!

Il context switch tra i thread è più veloce rispetto a quello tra processi.

Poiché i thread condividono i dati bisogna gestire bene i conflitti!

OMP – Tipica struttura del programma

```
#include <omp.h>

main () {

int var1, var2, var3;

Serial code
    .
    .
    .

Beginning of parallel section. Fork a team of threads.
Specify variable scoping

#pragma omp parallel private(var1, var2) shared(var3)
{

    Parallel section executed by all threads
    .
    Other OpenMP directives
    .
    Run-time Library calls
    .
    All threads join master thread and disband

}


Resume serial code
    .
    .
    .
}
```

```
#include <omp.h>
#include <stdio.h>
#include <stdlib.h>
int main (int argc, char *argv[])
{
int nthreads, tid;

/* Fork a team of threads giving them their own copies of
variables */


#pragma omp parallel private(nthreads, tid)
{
    /* Obtain thread number */
    tid = omp_get_thread_num();
    printf("Hello World from thread = %d\n", tid);
    /* Only master thread does this */
    if (tid == 0)
    {
        nthreads = omp_get_num_threads();
        printf("Number of threads = %d\n", nthreads);
    }
} /* All threads join master thread and disband */
}
```

Su architetture distribuite in cui ogni nodo di calcolo è dotato di più core che condividono una stessa memoria è possibile implementare una modalità di programmazione ibrida che combini le funzioni di scambio di messaggi tra nodi diversi fornita da MPI a quelle del « Multiprocessing » su memoria condivise fornite da OpenMP



Moltiplicazione di matrici - OpenMP

```
/** Region parallela **/  
#pragma omp parallel shared(a,b,c,nthreads,chunk) private(tid,i,j,k)  
{  
    tid = omp_get_thread_num();  
    if (tid == 0)  
    {  
        nthreads = omp_get_num_threads();  
        printf("Starting matrix multiple example with %d threads\n",nthreads);  
        printf("Initializing matrices...\n");  
    }  
    /** Initialize matrices **/  
    #pragma omp for schedule (static, chunk)  
    for (i=0; i<NRA; i++)  
        for (j=0; j<NCA; j++)  
            a[i][j]= i+j;  
    .....  
    #pragma omp for schedule (static, chunk)  
    for (i=0; i<NRA; i++)  
    {  
        // printf("Thread=%d did row=%d\n",tid,i);  
        for(j=0; j<NCB; j++)  
            for (k=0; k<NCA; k++)  
                c[i][j] += a[i][k] * b[k][j];  
    }  
} /** Fine della regione parallela**/
```



**Un solo processo che fa una « fork »:
l'accesso alla memoria condivisa è più
veloce rispetto al caso in cui si hanno
più processi indipendenti.**

Moltiplicazione di matrici - OpenMP

- Compilazione e lancio del programma **su singolo nodo shared memory con 16 core**

```
icc -o omp_mm_c -openmp -parallel omp_mm.c
```

```
export OMP_NUM_THREADS=numero_thread
```

```
time ./omp_mm_c
```

Dimensione matrice N	Tempo seriale	Tempo 4 thread	Tempo 4 core (MPI)	Tempo 8 thread	Tempo 8 core (MPI)	Tempo 16 thread	Tempo 4 core (MPI)
1000	3.04s	0.82s	2.6s	0.61s	2s	0.41s	3s
2000	23s	9s	12s	5s	8s	3s	9s
5000	6m 34s	2m 5s	2m 47s	1m 13s	2m 4s	58s	2m 11s

Sul singolo nodo l'accesso alla memoria condivisa è più veloce nel caso multithreading!


La CPU

CPU (Central Processing Unit) è il microprocessore principale che coordina tutte le unità di elaborazione presenti sul chip.

Esegue le istruzioni di un programma dopo averlo caricato in memoria.

Architettura di Von Neumann: dati e istruzioni risiedono nella stessa memoria.

Architettura di Harvard: dati e istr. in memorie separate.



La CPU contiene:

- **CU (Central Unit):** legge dalla memoria le istruzioni, i dati per eseguire le istruzioni, esegue l'istruzione e scrive il risultato nella memoria centrale o nei registri.
- **ALU (Arithmetic Logic Unit):** esegue le op. logiche e aritmetiche
- **Registri:** piccole memorie interne molto veloci.
- **Program Counter:** indirizzo di memoria della prossima istr. da eseguire
- **Flag:** insieme di bit che segnalano lo stato della CPU e alcune info sul risultato dell'ultima op. eseguita
- **FPU (Floating Point Unit):** esegue le op. in virgola mobile
- **MMU (Memory Management Unit):** traduce gli indirizzi di memoria logici in fisici, supporta meccanismi di protezione della memoria e/o la mem. virtuale.