CINECA SCAI
SuperComputing Applications and Innovation

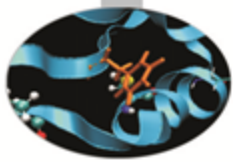

Elementi di Programmazione Parallela

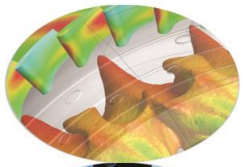
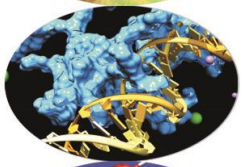
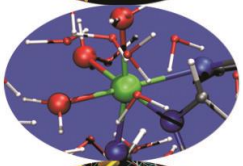
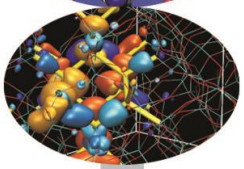

Claudia Truini
c.truini@caspur.it

Vittorio Ruggiero
v.ruggiero@caspur.it

Cristiano Padrin
c.padrin@caspur.it

CINECA

Sommario

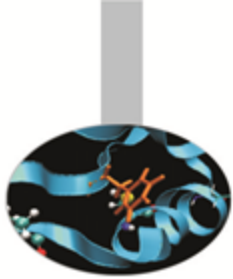

- *Analysis & design* delle applicazioni parallele
- Misura delle prestazioni parallele
- Tecniche di partizionamento
- Comunicazioni
- *Load balancing*

Primi passi: analizzare il problema

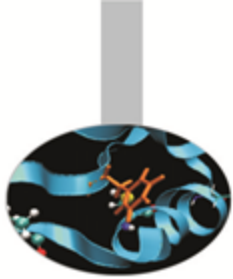

Prima di iniziare a scrivere un codice parallelo:

- Capire il problema che si vuole parallelizzare
- Capire il codice seriale (se esiste)
- Capire se il problema può essere parallelizzato:
  - Problema parallelizzabile: esempio
    - Serie geometrica:

$$\sum_{i=1}^{N} x^{i} = \sum_{i=1}^{P} S_{i} = \sum_{i=1}^{P} \left(\sum_{j=1}^{N/P} x^{\frac{N}{P}(i-1)+j} \right)$$

    - I calcoli sono indipendenti → possono essere calcolati in parallelo
  - Problema non parallelizzabile: esempio
    - Successione di Fibonacci:
      F (n) = F (n - 1) + F (n - 2) F (1) = 1 F (2) = 1
    - I calcoli sono dipendenti: per calcolare il valore F (n) devo conoscere i due valori precedenti F (n-1) e F (n-2) → non possono essere calcolati in parallelo

Primi passi: costruire l'applicazione parallela

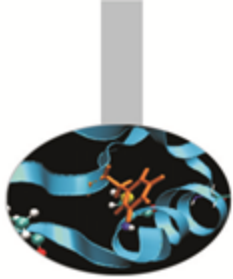

Se il codice può essere parallelizzato:

- Identificare le parti maggiormente pesanti e su quelle focalizzare l'attenzione
  - generalmente nelle applicazioni tecnico-scientifiche la maggior parte del tempo è spesa in poche sezioni di codice (spesso *loop*)
- Identificare i possibili "colli di bottiglia": provare a eliminarli o ridurli
- Identificare inibitori al parallelismo (ad. es. dipendenza dei dati)
- Studiare differenti algoritmi
- Distribuire i dati in modo da ridurre le comunicazioni e bilanciare il carico di lavoro
- Gestire le comunicazioni e la sincronizzazione tra i processi paralleli

Misurare le prestazioni

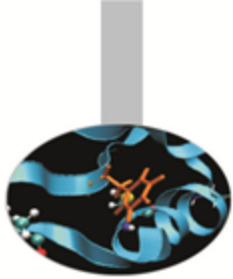

- **Speedup**: aumento della velocità (= diminuzione del tempo) dovuto all'uso di n processi:
  - **S(n) = T(1)/T(n)**
    - T(1) = tempo totale seriale
    - T(n) = tempo totale usando n processi
    - S(n) = n → speed-up lineare (caso ideale)
    - S(n) < n → speed-up di una caso reale
    - S(n) > n → speed-up superlineare (effetti di cache)

Misurare le prestazioni

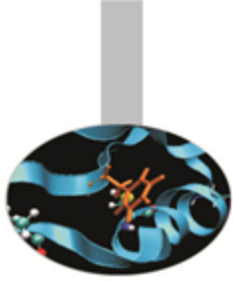

- **Efficienza**: effettivo sfruttamento della macchina parallela:
  - **E(n)** = S(n)/n = T(1)/(T(n)*n)
    - E(n) = 1 → caso ideale
    - E(n) < 1 → caso reale
    - E(n) << 1 → ci sono problemi …
- **Scalabilità**: capacità di essere efficiente su una macchina parallela
  - aumento le dimensione del problema proporzionalmente al numero di processi

Legge di Amdhal

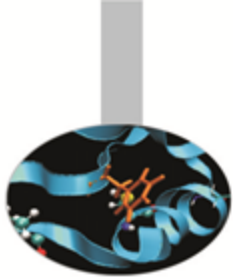

- Quale è lo speed-up massimo raggiungibile?
- Tempo seriale: $T = F + P$
  - F = tempo della parte seriale (non parallelizzata o non parallelizzabile)
  - P = tempo della parte parallela
- Tempo con n processi:

$$T(n) = F + P/n$$

- Speed-up su n processi:

$$S(n) = T(1)/T(n) = (F + P)/(F+P/n)$$

  - Per n grande $S(n) = (F + P)/F$
  - esiste un limite asintotico allo speed-up!

Legge di Amdhal: Speedup

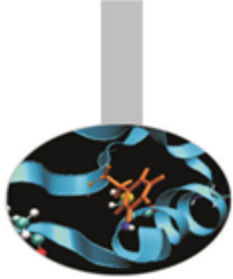

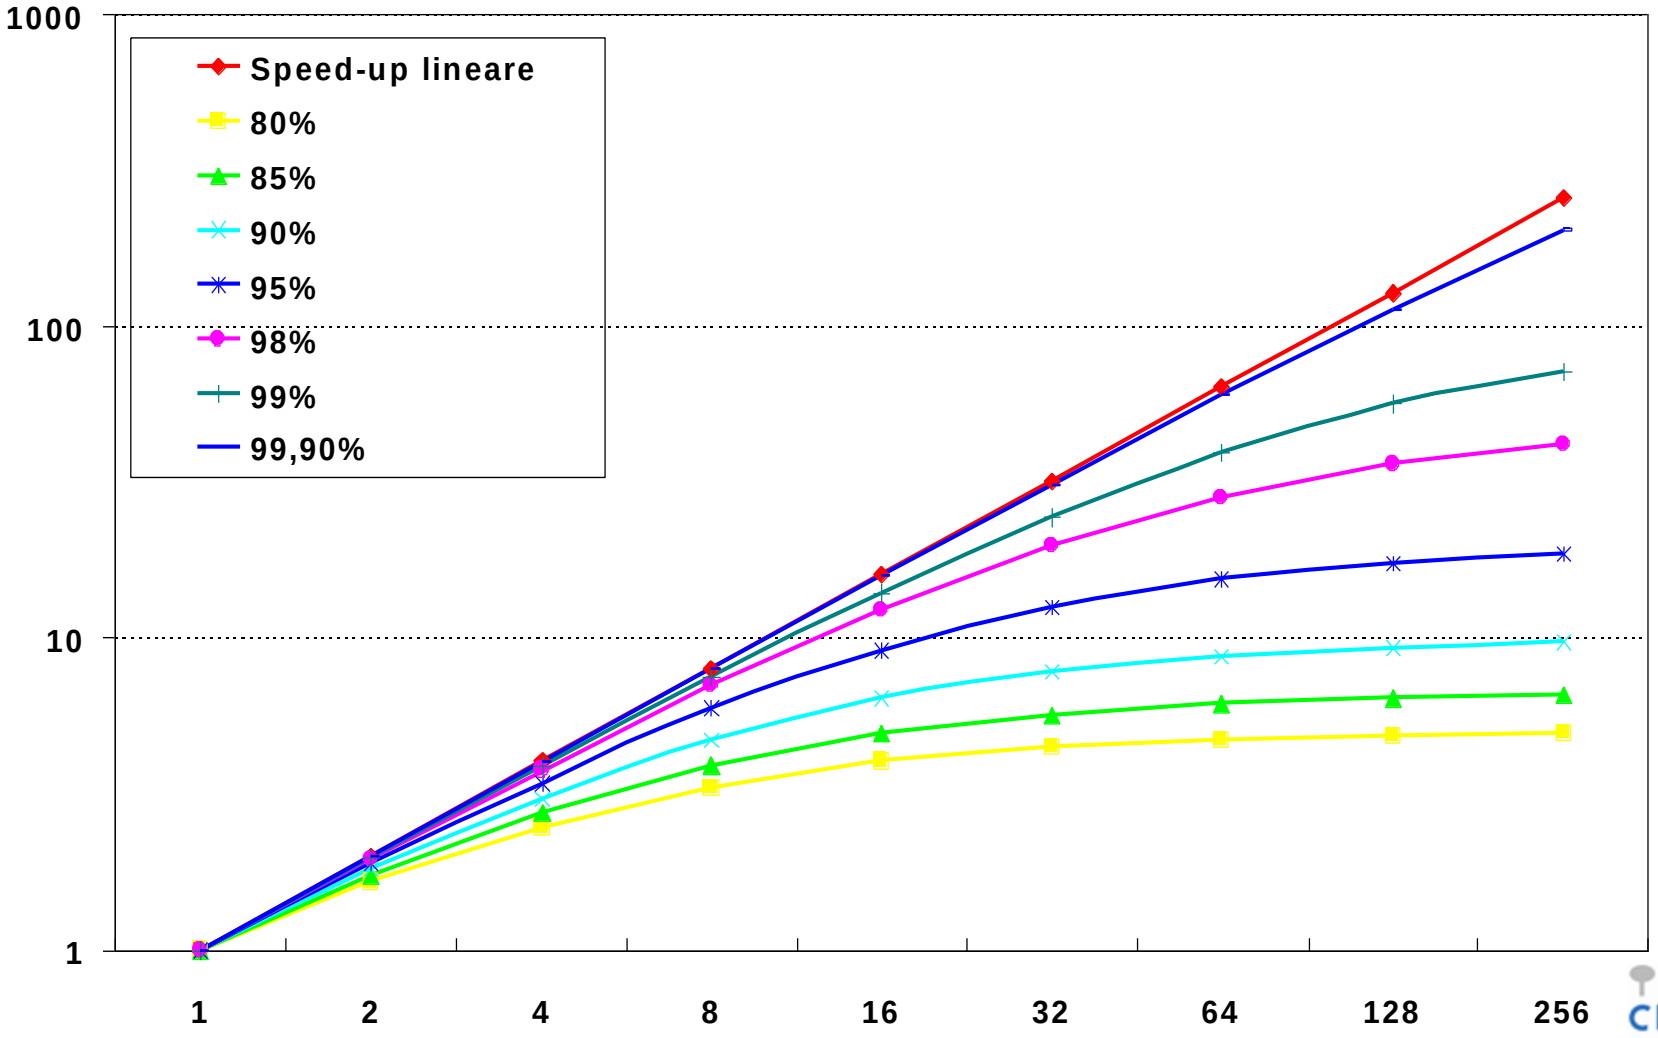

Legge di Amdhal: Speedup

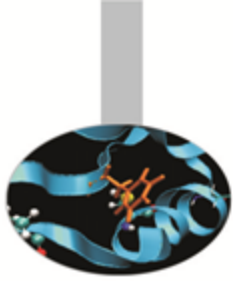

- Massimo speed-up raggiungibile in funzione della percentuale della parte parallele

	1	2	4	8	16	32	64	128	256
80%	1.0	1.7	2.5	3.3	4.0	4.4	4.7	4.8	4.9
85%	1.0	1.7	2.8	3.9	4.9	5.7	6.1	6.4	6.5
90%	1.0	1.8	3.1	4.7	6.4	7.8	8.8	9.3	9.7
95%	1.0	1.9	3.5	5.9	9.1	12.6	15.4	17.4	18.6
98%	1.0	2.0	3.8	7.0	12.3	19.8	28.3	36.2	42.0
99%	1.0	2.0	3.9	7.5	13.9	24.4	39.3	56.4	72.1
99.9%	1.0	2.0	4.0	7.9	15.8	31.0	60.2	113.6	204.0
Ideale	1.0	2.0	4.0	8.0	16.0	32.0	64.0	128.0	256.0

Legge di Amdhal: Efficienza

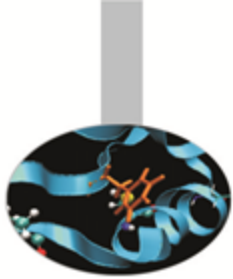

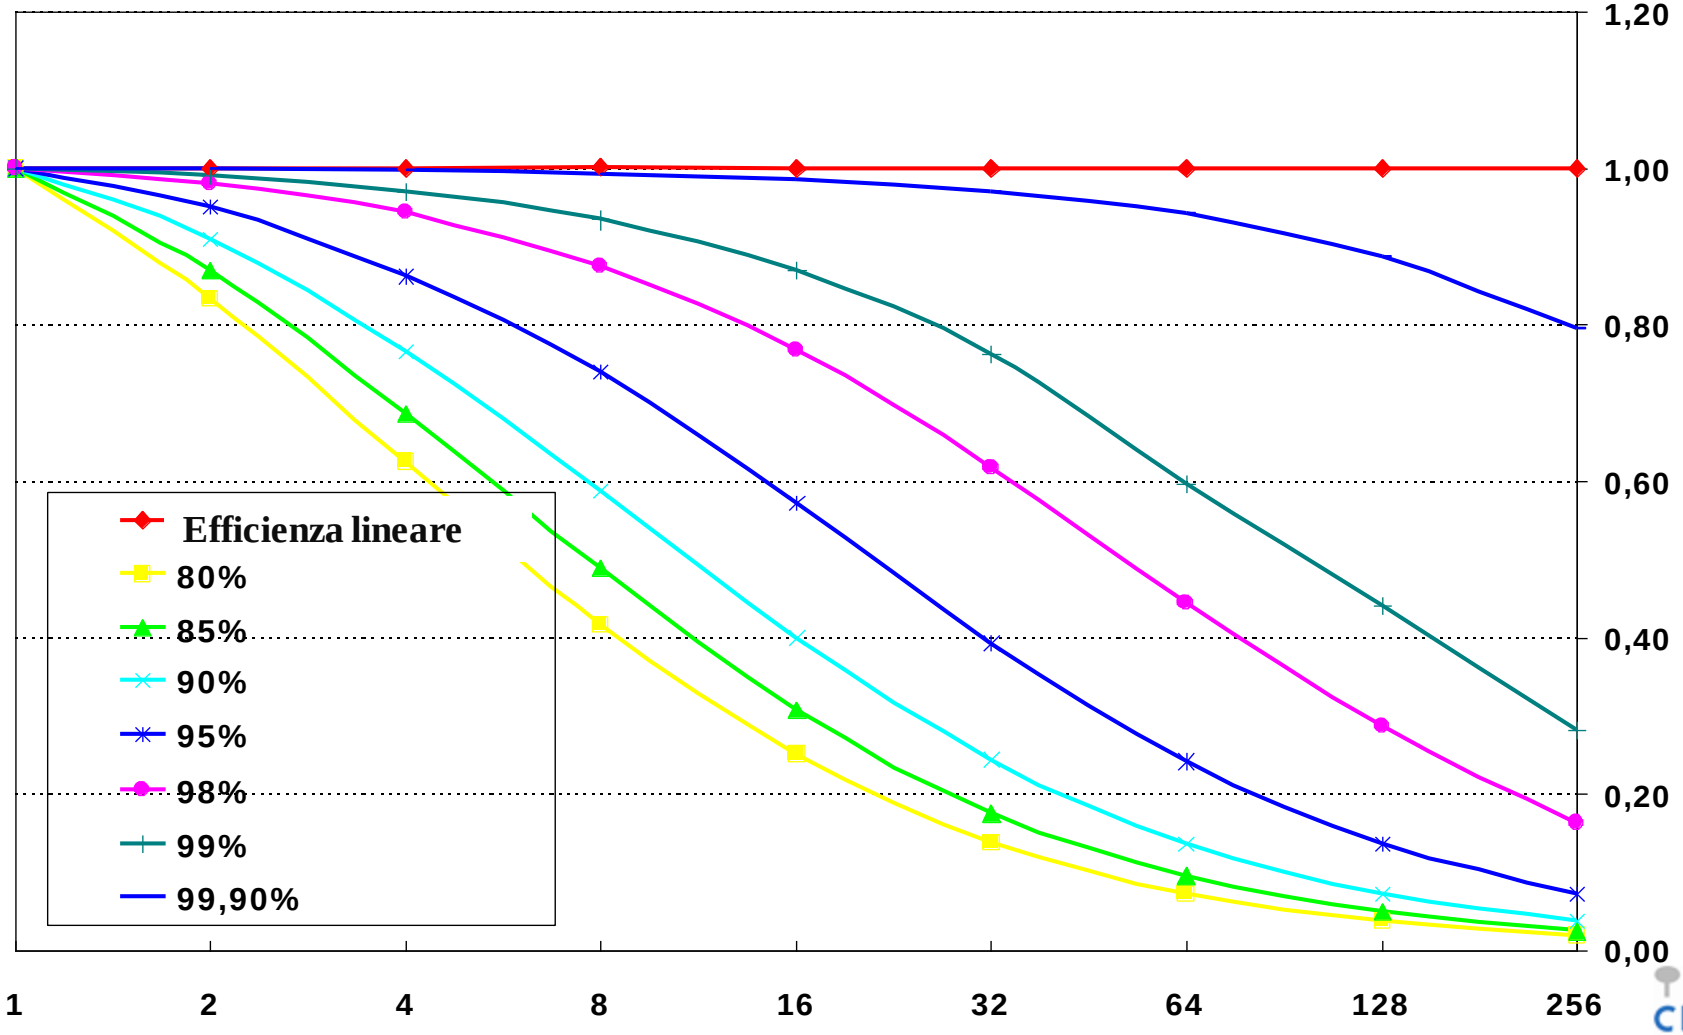

Tecniche di Partizionamento

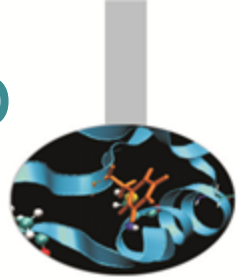

- Si divide il problema in n parti, ciascuna parte viene assegnata ad un processo differente

- Distribuzione del lavoro tra più soggetti:
  - tutti eseguono le stesse operazioni, ma su un sottoinsieme di dati
  - → partizionamento dei dati

- Distribuzione delle funzioni tra più soggetti:
  - non tutti eseguono le stesse operazioni
  - → decomposizione funzionale

Partizionamento dei dati

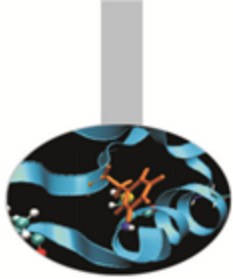

- Insieme (ordinato) di dati da elaborare tutti allo stesso modo
- Decompongo i dati associati al problema
- Ogni processo esegue le stesse operazioni su una porzione dei dati (→ SPMD)

- PRO: scalabile con la quantità di dati
- CONTRO: vantaggiosa solo per casi sufficientemente grandi

Partizionamento dei dati: esempio

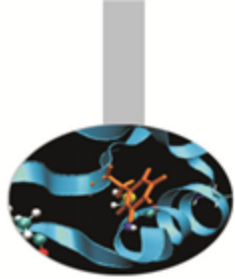

- Vari modi possibili per partizionare i dati
- Ogni processo lavora su una porzione di dati

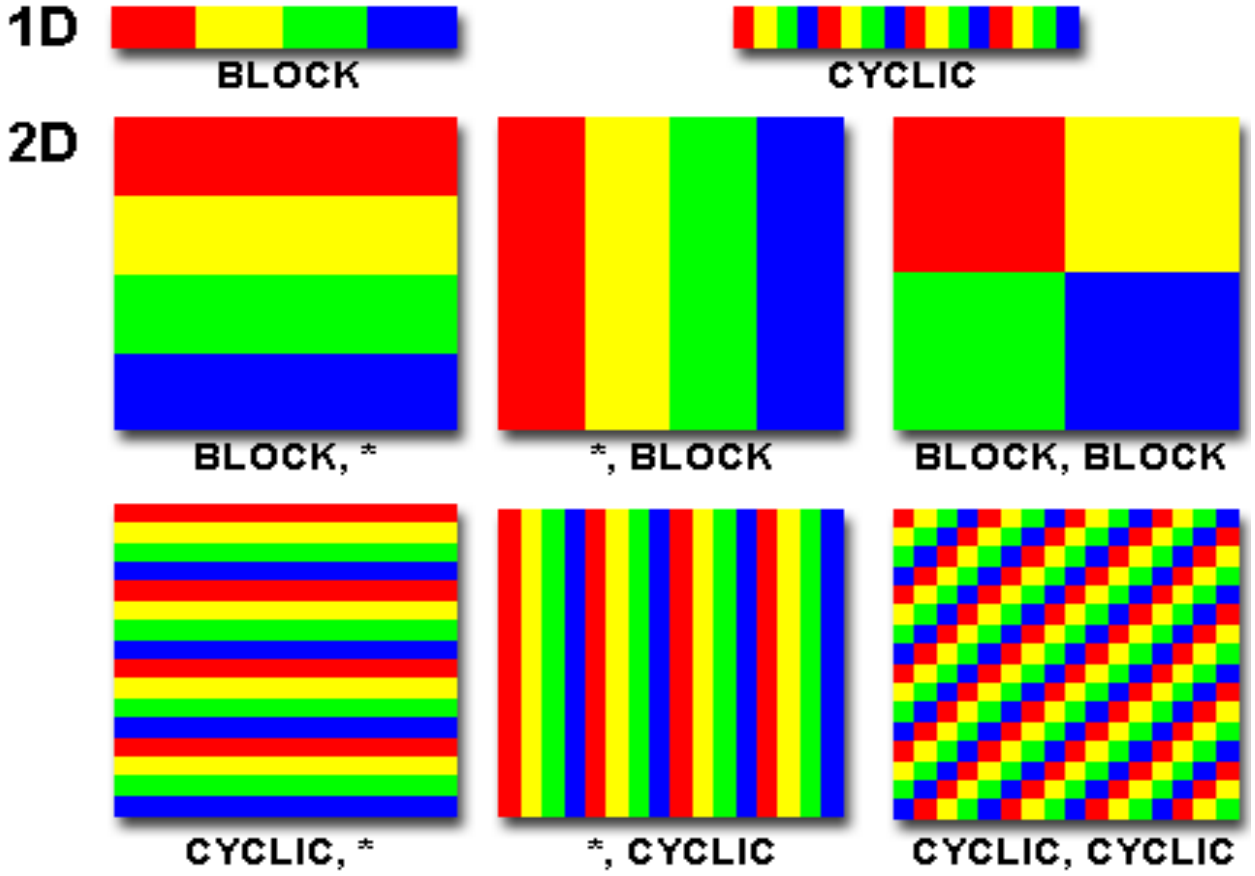

Decomposizione funzionale

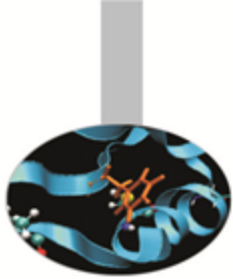

- Insieme di elaborazioni differenti ed indipendenti
- Decompongo il problema in base al lavoro che deve essere svolto
- Ogni processo prende in carico una particolare elaborazione (→MPMD)

- PRO: scalabile con il numero di elaborazioni indipendenti
- CONTRO: vantaggiosa solo per elaborazioni sufficientemente complesse

Decomposizione funzionale: esempio

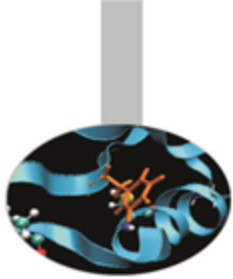

- Modello climatico

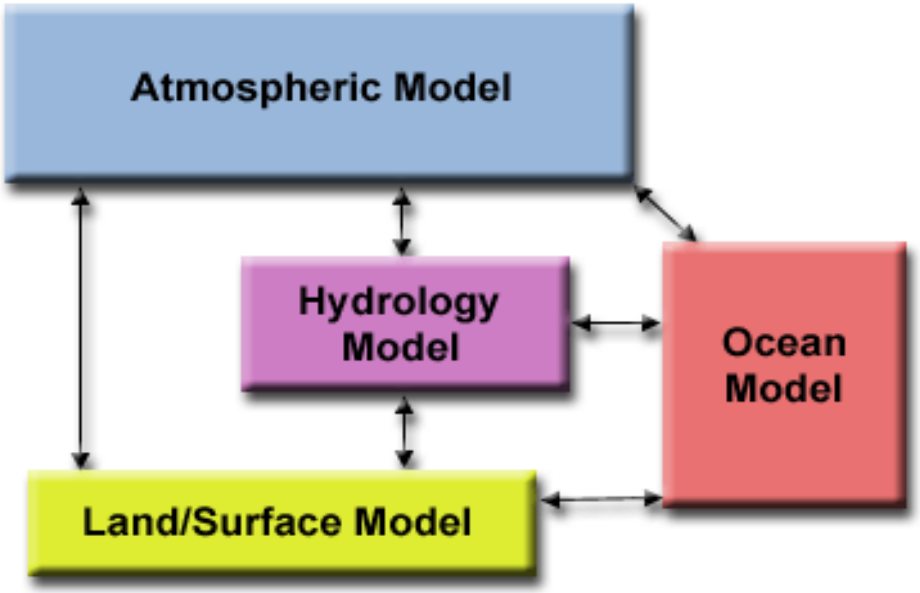

- Ogni componente del modello può essere considerata come un processo separato.
  - Le frecce rappresentano gli scambi di dati tra le componenti durante il calcolo

Operazione di riduzione/scattering

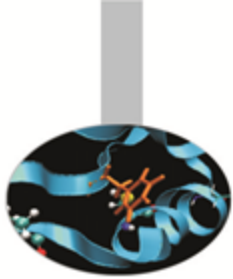

- Mettere tutto assieme/distribuire
- Somma/distribuzione dei vari risultati parziali in un risultato globale (e.g. somma dell'integrale)
- Necessita di sincronizzazione e barriere tra i processi

- PRO: è necessaria
- CONTRO: overhead dovuto al parallelo
- CONTRO: onerosa all'aumentare del numero di processi

Comunicazioni

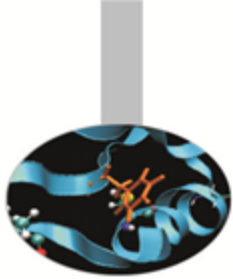

- Sono necessarie?
  - dipende dal problema
    - no, se il problema è “imbarazzantemente parallelo”
    - si, se il problema richiede dati di altri processi
- Quanto comunicare?
  - dipende dal problema e da come viene partizionato
- Tutte le comunicazioni implicano un overhead

…e la rete?

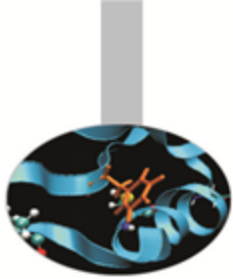

- Fare attenzione anche alla rete di comunicazione
- Quando si pianifica il pattern di comunicazione tra task, e quando si disegnano in dettaglio le comunicazioni, ci sono diversi fattori da tenere in considerazione:
  - **Latenza** (**L**): tempo necessario per "spedire" un messaggio vuoto (tempo di start-up)
  - **Bandwidth** (**B**): velocità di trasferimento dei dati (Mb/sec.)
  - Relazione tra latenza e bandwidth
    - grossa bandwidth e bassa latenza:
      - il migliore dei mondi possibili ☺
    - piccola bandwidth e grande latenza:
      - il peggiore dei mondi possibili ☹
  - **Tempo di comunicazione** (**T**) di un messaggio di N MB:

$$T = L + N/B$$

Legge di Amdhal

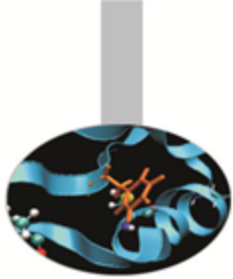

- Quale è lo speed-up massimo raggiungibile?
- Tempo seriale: T = F + P
  - F = parte seriale (non parallelizzata/parallelizzabile)
  - P = parte parallela
  - C(n) = comunicazione, sincronizzazione etc….
  - T(n) = F + P/n + C(n)
  - S(n) = T(1)/T(n) = (F + P)/(F+P/n+C(n))

  - per n grande S(n) = (F + P)/(F+C(n))
  - Il limite asintotico allo speed-up è peggiore!
  - ☺ Però potrebbe essere possibile nascondere comunicazione nel calcolo ….

Granularità

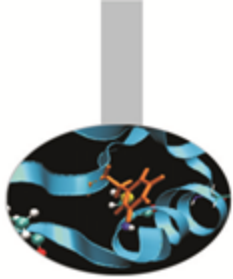

- Parallelismo a grana fine
  - Pochi calcoli tra le comunicazioni
  - → rapporto tra il calcolo e le comunicazioni è piccolo
  - Può essere facile bilanciare il carico
  - Overhead di comunicazioni

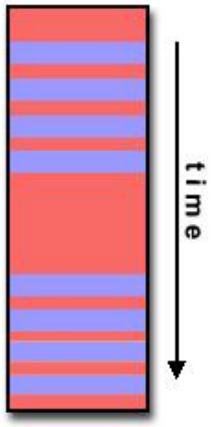

- Parallelismo a grana grossa
  - Molti calcoli tra le comunicazioni
  - → rapporto tra il calcolo e le comunicazioni è grande
  - Può essere difficile bilanciare il carico
  - Probabile aumento delle performance

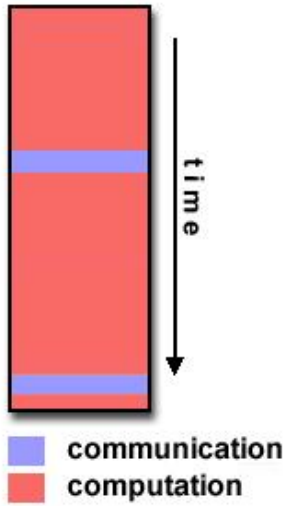

Load balancing

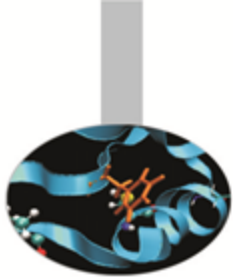

- È importante per le performance dei programmi paralleli
- Distribuire il carico di lavoro in modo da minimizzare i tempi morti (tempi di attesa) dei processi

- Esempio con 4 processi:
  - tempo seriale = 40
  - tempo parallelo (teorico) = 10
  - tempo parallelo (reale) = 12
    → 20% più lento

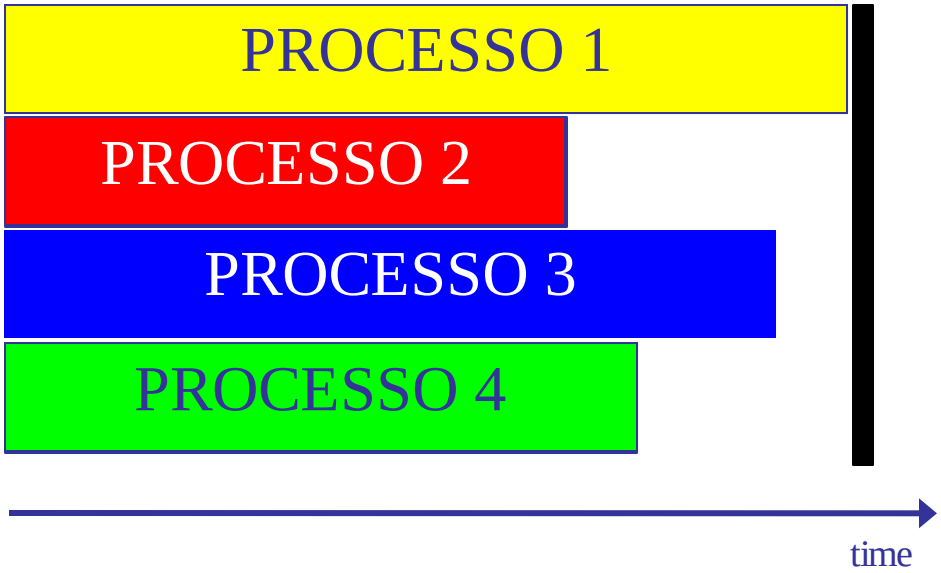

- La velocità dell'esecuzione dipenderà dal processo più lento

Load balancing: assegnazione statica

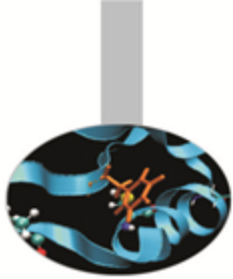

- Partizionare ugualmente il lavoro di ogni processo
- Per operazioni su array/matrici dove ogni processo svolge operazioni simili, distribuisco uniformemente i dati sui processi
- Per cicli dove il lavoro fatto in ogni iterazione è simile, distribuisco le iterazioni uniformemente sui processi

Load balancing: assegnazione dinamica

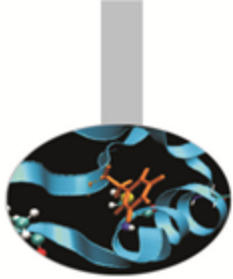

- Alcuni partizionamenti anche se uniformi risultano sempre non bilanciati
  - Matrici sparse
  - Metodi con griglie adattative
  - …
- In questi casi solo l'**assegnazione dinamica** può riuscire a bilanciare il carico computazionale
  - divido la regione in tante parti (maggiori del numero di processi)
  - ogni processo prenderà in carico una parte
  - quando un processo termina una parte, ne prende in carico una nuova

Load balancing: confronti

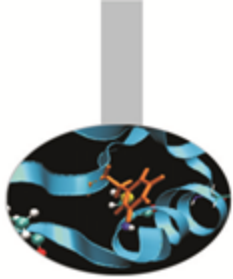

- Assegnazione statica:
  - si usa nella domain decomposition
  - ☺ in genere semplice, proporzionale al volume
  - ☹ soffre di possibili sbilanciamenti
- Assegnazione dinamica:
  - ☺ può curare problemi di sbilanciamento
  - ☹ introduce un overhead dovuto alla gestione del bilanciamento

Input e Output

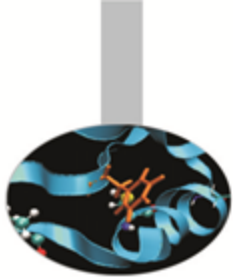

- Le operazioni di I/O sono generalmente seriali
- Possono creare “colli di bottiglia”

- La gestione dell’I/O porta all’utilizzo di costrutti specifici del linguaggio e del modello di programmazione usato:
  - Gather/Scatter per rimettere insieme/distribuire i dati su modelli message-passing (MPI)
  - Utilizzo di un solo thread nel modello di programmazione multi-threaded (OpenMP)