POLITECNICO DI MILANO

La Memoria Cache

Informatica B

Daniele Loiacono

Il problema della memoria

- Obiettivo:
  - fornire agli utenti una memoria grande e veloce
  - fornire al processore i dati alla velocità con cui è in grado di elaborarli
- Problema: Il tasso di crescita nella velocità dei processori non è stato seguito da quello delle memorie

  Tempo di accesso alle SRAM: 2 - 25ns al costo di $100 - $250 per Mbyte.
  Tempo di accesso alle DRAM: 60-120ns al costo di $5 - $10 per Mbyte.
  Tempo di accesso al disco: da 10 a 20 million ns al costo di $.10 - $.20 per Mbyte.

Prestazioni di processori e cache

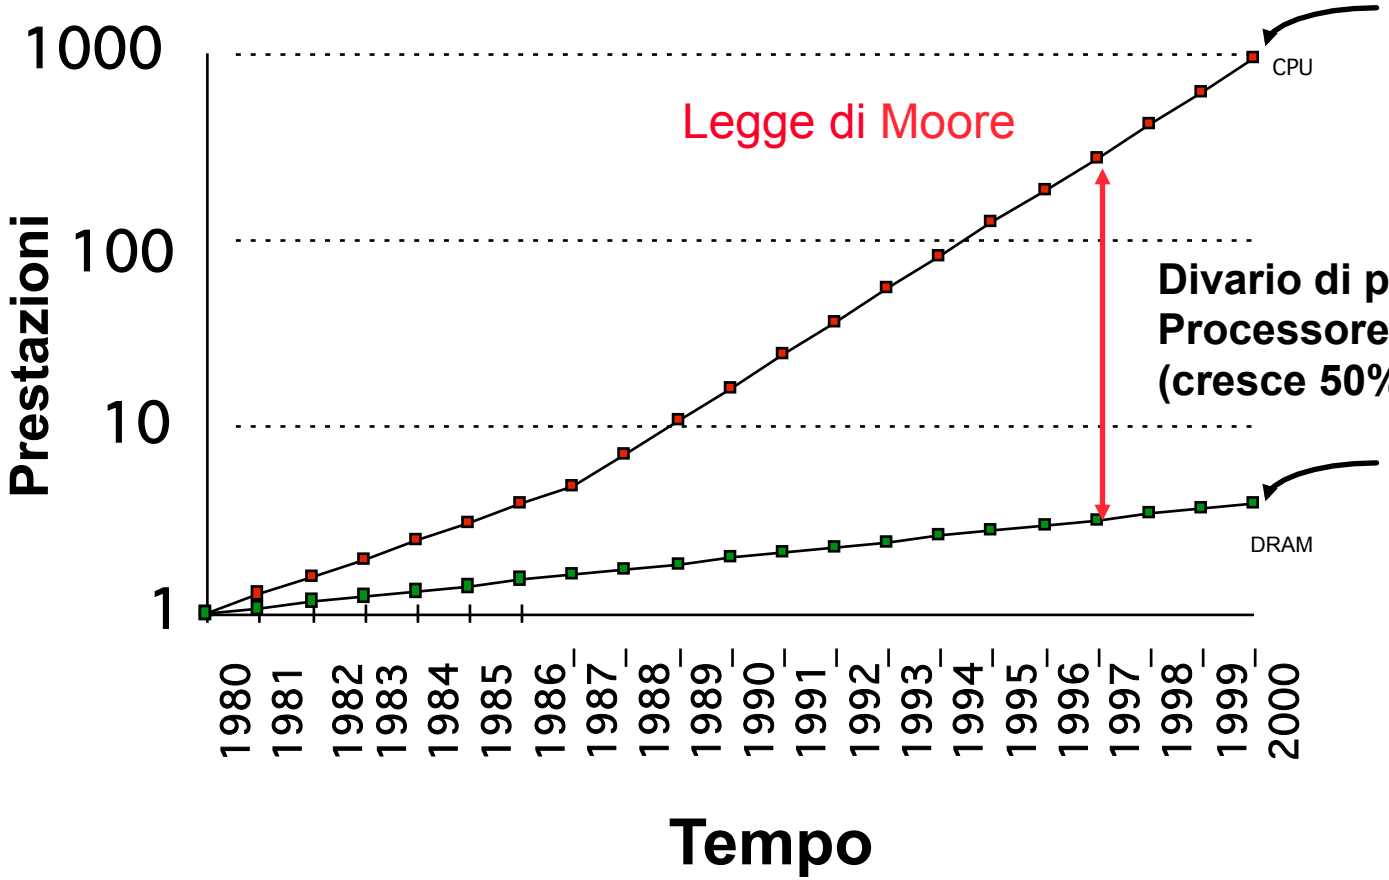

µProc
60%/anno
(2X/1.5yr)

DRAM
9%/anno
(2X/10
anni)

Soluzione: gerarchia di memoria

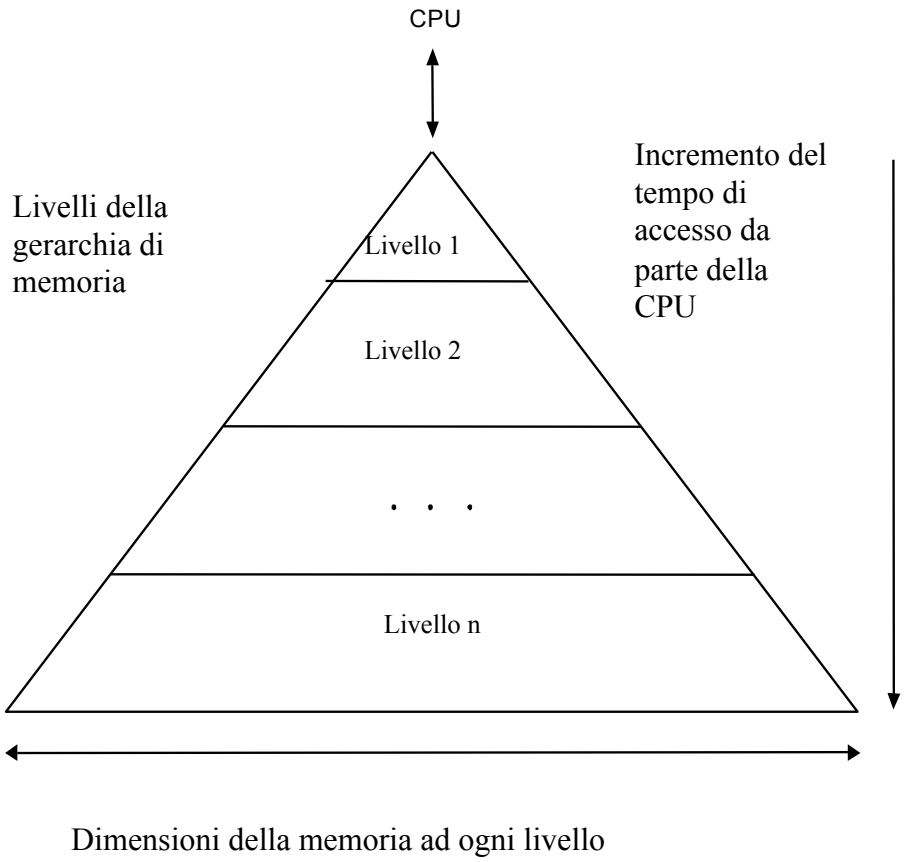

Utilizzare diversi livelli di memoria, con tecnologie diverse in modo da ottenere un buon compromesso costo/prestazioni

Livelli della gerarchia di memoria

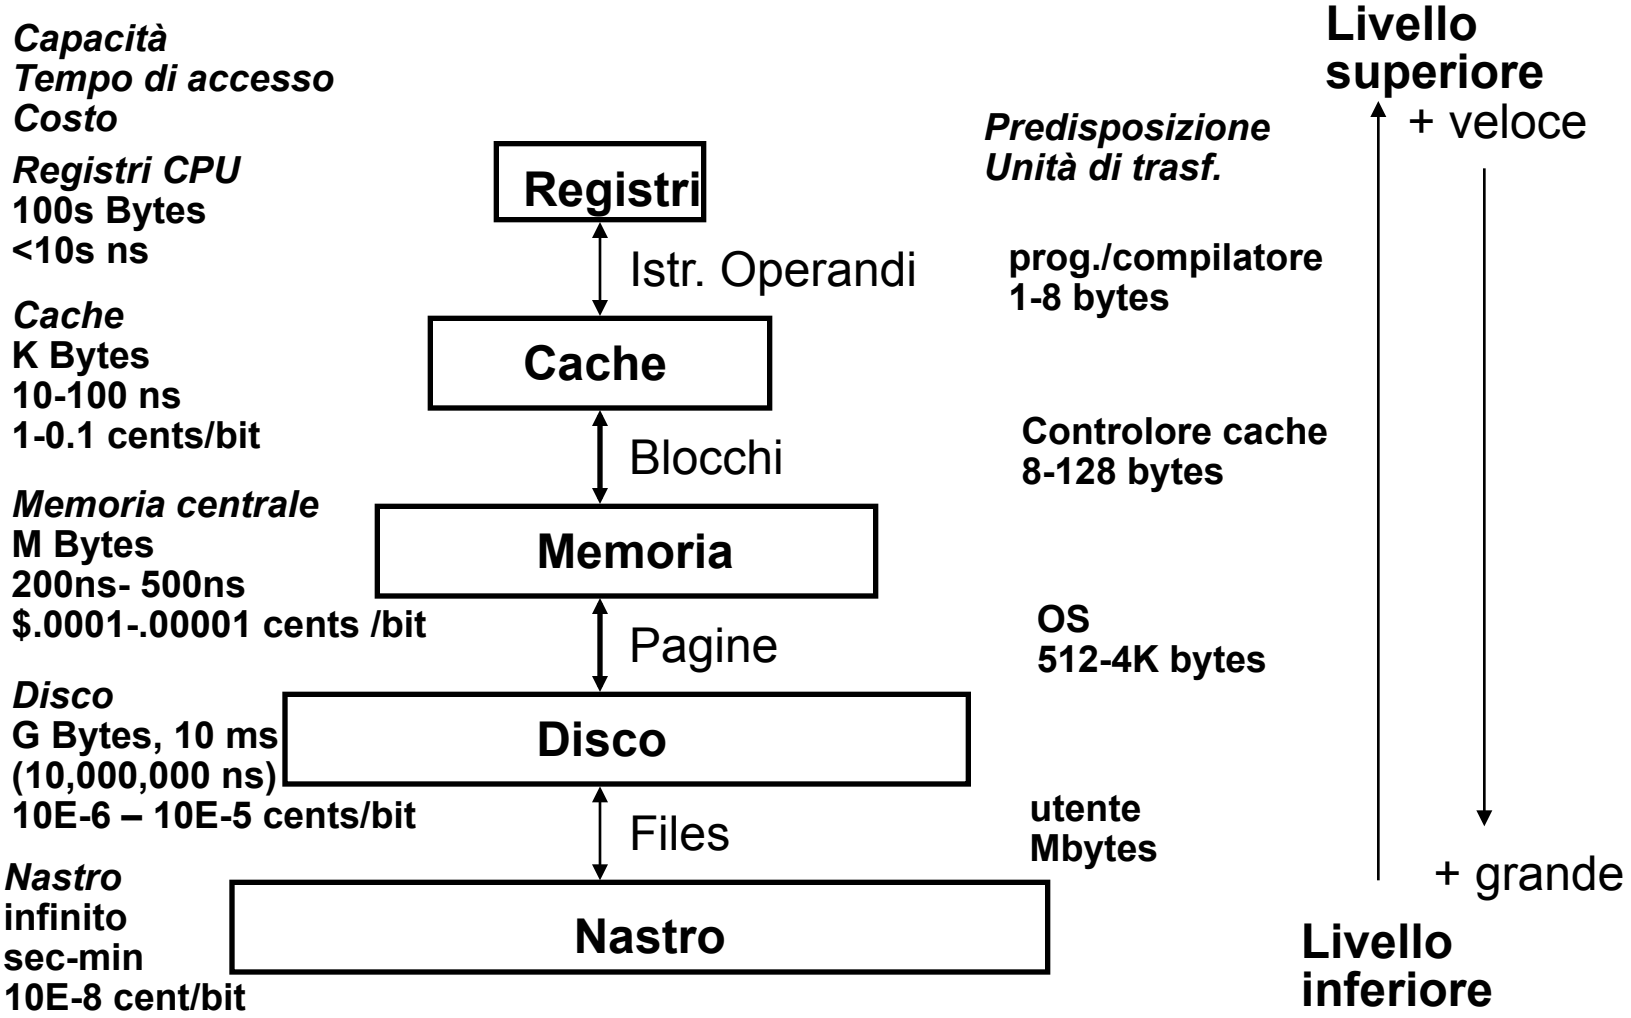

Località

- Il principio che rende la gerarchia di memoria una buona idea per incrementare le prestazioni del sistema di memoria
- Località: in ogni istante di tempo un programma accede a una parte relativamente piccola del suo spazio di indirizzamento
- Esistono due diversi tipi di località: *temporale* e *spaziale*

Il principio di località

- Località temporale: se un dato viene referenziato in un dato istante, è probabile che lo stesso dato venga nuovamente richiesto entro breve
- Località Spaziale: Se un dato viene utilizzato in un dato istante, è probabile che dati posizionati in celle di memoria adiacenti vengano anch'essi richiesti entro breve
- Negli ultimi 15 anni, le tecniche di miglioramento delle prestazioni nell'hardware si sono basate sul principio di località

Gerarchia di memoria

- Si considerino solo due livelli di gerarchia:
- Il processore richiede un dato al sistema di memoria:
  - La richiesta viene prima inviata al livello di memoria superiore (più vicino al processore)
  - Se il dato non è presente nel livello superiore (fallimento della richiesta) la ricerca viene effettuata nel livello inferiore

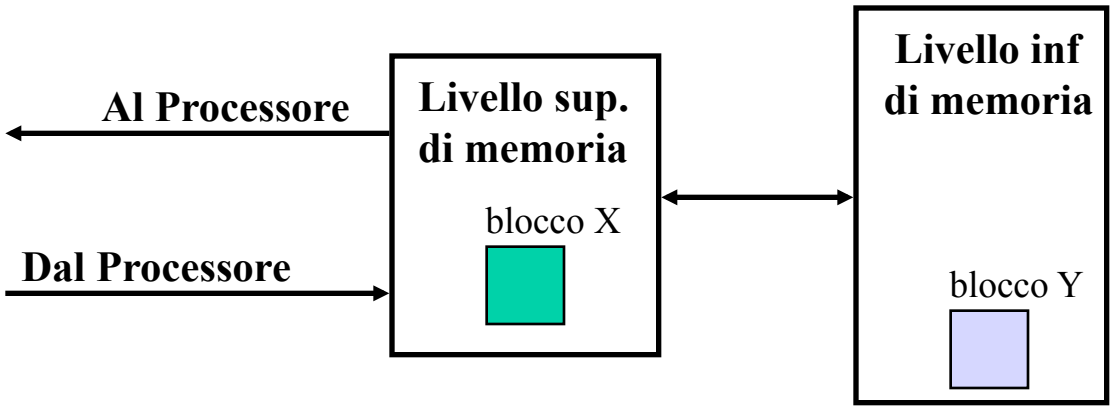

Gerarchia di memoria: definizioni

- Hit (successo): dati presenti in un blocco del livello superiore (esempio: Blocco X)
  - Hit Rate (tasso di successo): numero di accessi a memoria che trovano il dato nel livello superiore sul numero totale di accessi
  - Hit Time (tempo di successo): tempo per accedere al dato nel livello superiore della gerarchia:

    Tempo di accesso alla cache + tempo per determinare successo/fallimento della richiesta

Gerarchia di memoria: definizioni

- Miss (fallimento): i dati devono essere recuperati dal livello inferiore della memoria (Blocco Y)
  - Miss Rate (tasso di fallimento) = 1 - (Hit Rate)
  - Miss Penalty (tempo di fallimento): tempo necessario a sosituire un blocco nel livello superiore + tempo per trasferire il blocco al processore
  - Hit Time << Miss Penalty

Gerarchia di memoria: definizioni

- Memoria al livello superiore della gerarchia
- Sfruttare il principio di località dei programmi e tenere in memoria cache i dati utilizzati più di recente
- Obiettivo: fornire dati al processore in uno o due cicli di clock
- Memoria cache: veloce nei tempi di accesso ma di dimensioni ridotte

Esercizio

- Considerate i seguenti sistemi di memoria:
  - Sistema A: memoria centrale con memoria cache che ha le seguenti caratteristiche:
    - Hit Rate = 70%
    - Hit Time = 10ns
    - Miss Penalty = 300ns
  - Sistema B: Una memoria centrale senza memoria cache con un tempo medio di accesso di 90ns
- Rispondere alle seguenti domande:
  - Quale dei due sistemi di memoria è migliore?

Calcoliamo il tempo medio di accesso alla memoria a) T:

T = HR*HT+(1-HR)*MP = 0.70*10ns+0.30*300ns = 97ns

→ Il sistema B è migliore

Esercizio

- Considerate i seguenti sistemi di memoria:
  - Una memoria centrale con memoria cache che ha le seguenti caratteristiche:
    - Hit Rate = 70%
    - Hit Time = 10ns
    - Miss Penalty = 300ns
  - Una memoria centrale senza memoria cache con un tempo medio di accesso di 90ns
- Rispondere alle seguenti domande:
  - Cambierebbe la vostra risposta se l'Hit Rate fosse pari all'80% ?

Se HR=80% il tempo medio di accesso diventa

T' = HR'*HT+(1-HR')*MP = 0.80*10ns+0.20*300ns = 68ns

→ Il sistema A diventerebbe migliore