Basi di Dati

Memorie Permanenti

Basi di Dati – Dove ci troviamo?

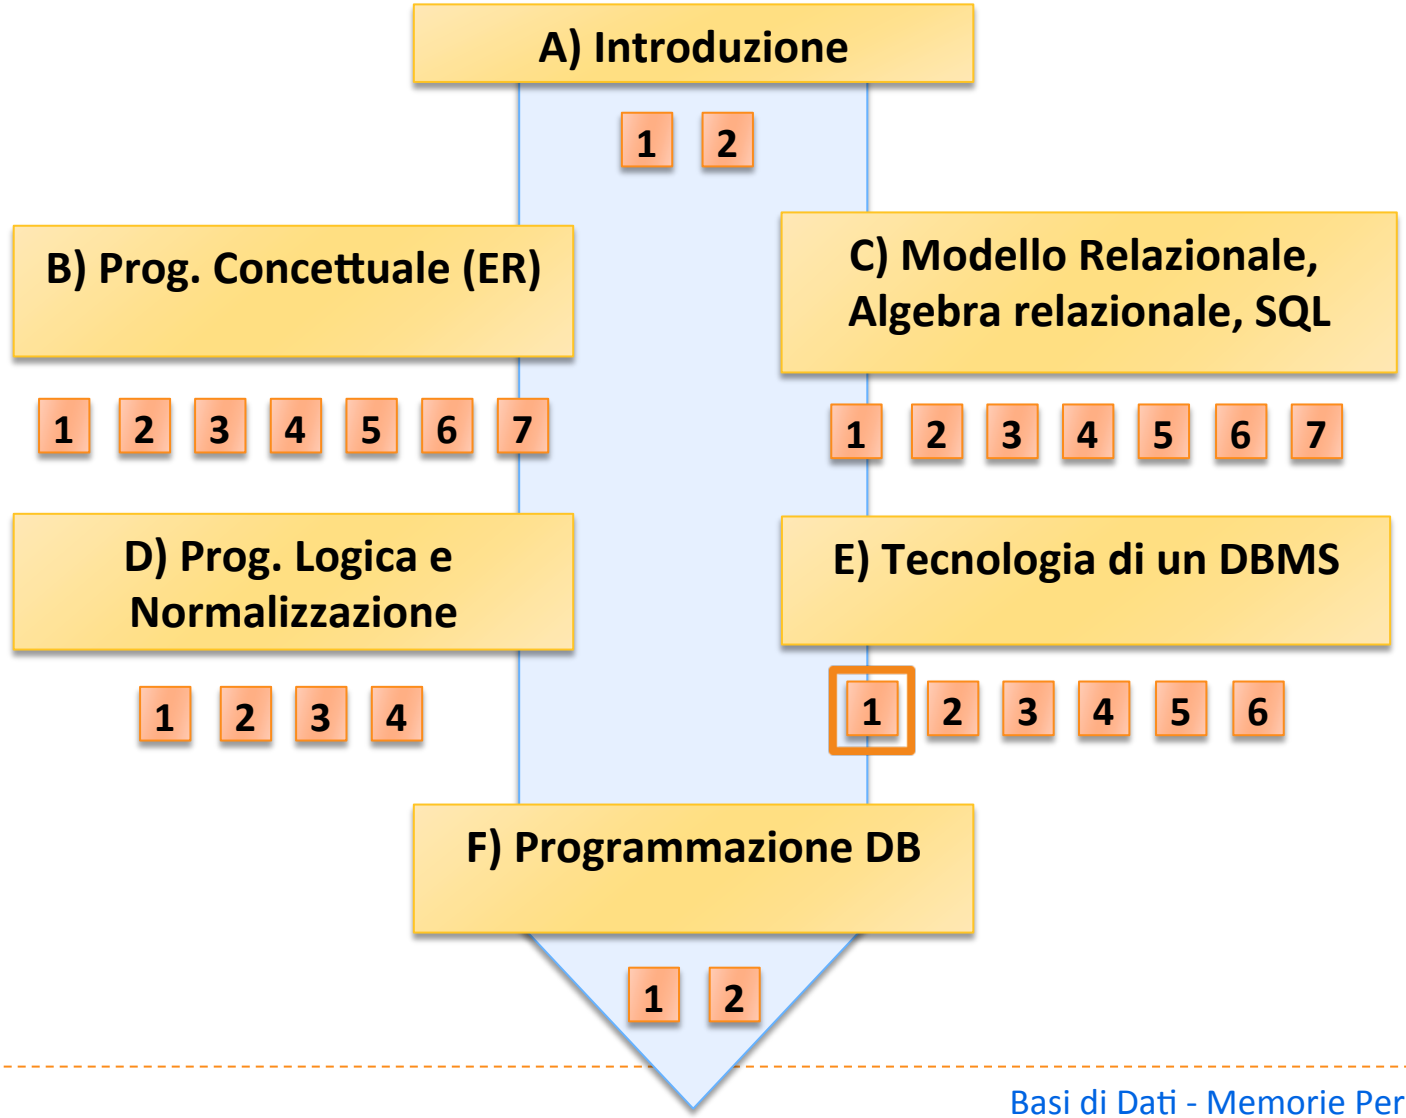

In questa lezione

- **Presenteremo:**
  - **le unità di memoria permanente**
  - **il loro funzionamento**
  - **le caratteristiche principali**
  - **l'affidabilità**

Struttura di un data server

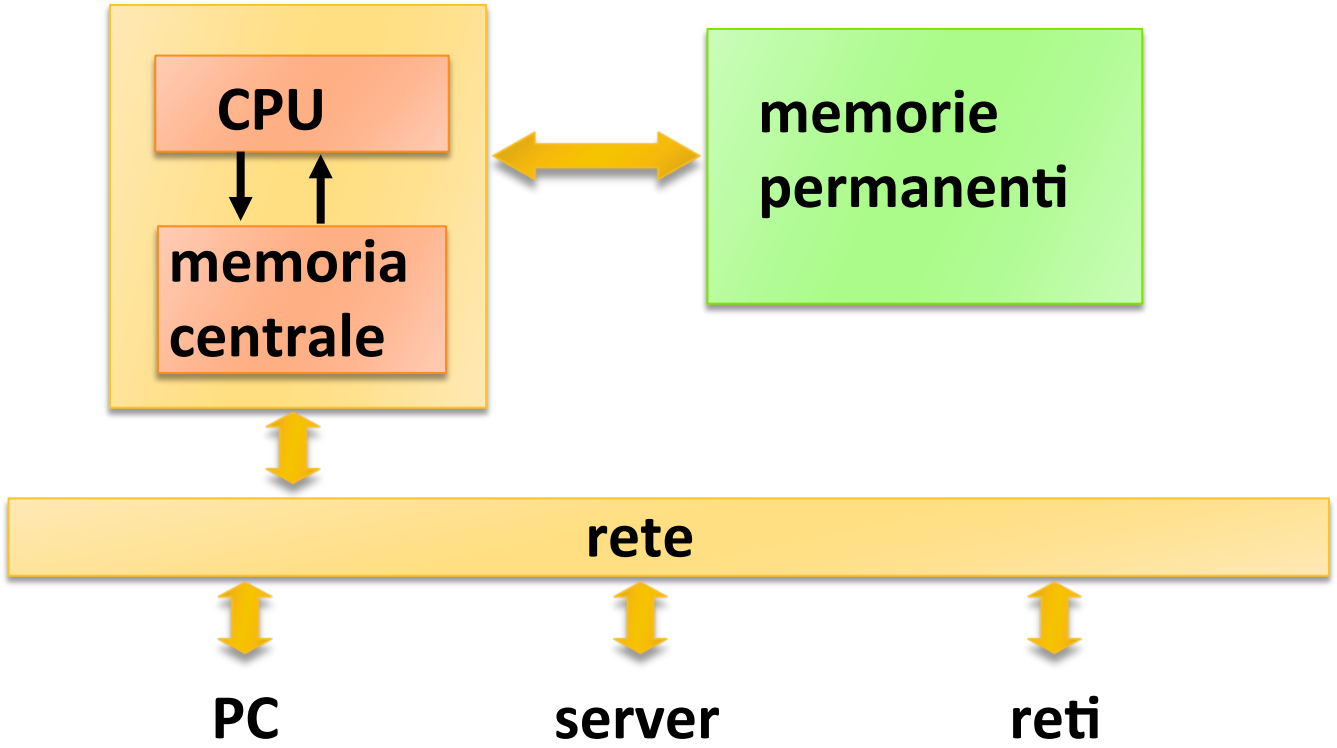

Qualità di un data server

- velocità della CPU
- capacità e velocità della memoria centrale (…o memoria di sevizio…)
- capacità e velocità delle memorie permanenti (…o memorie secondarie…)

  si tende ad enfatizzare le prime due mentre la più importante è la terza!

  perché condiziona la velocità del servizio nelle applicazioni gestionali

Qualità di un data server

- La **qualità della CPU, a parità di tecnologia** elettronica costruttiva, si misura in numero di **Mhz** del clock e in **numero di bit** dei registri (32-64)
- le **prestazioni** generali tendono e migliorare di circa 1.5 volte ogni anno (negli ultimi anni)
- i **costi** sono in forte calo (a parità di prestazioni)

Qualità di un data server

- secondo la **legge di Amdahl**, tenendo ferma la tecnologia delle memorie permanenti ed aumentando la velocità della CPU di un fattore 10, si avrebbe un miglioramento delle prestazioni del server di un fattore 5; aumentando di un fattore 100 si avrebbe un miglioramento di solamente 10
- ciò giustifica lo sforzo dell'industria per adeguare le prestazioni delle memorie permanenti

Legge di Amdahl (dei rendimenti decrescenti):

il miglioramento di una delle componenti di una macchina non produce un aumento delle prestazioni proporzionale al miglioramento. Il possibile incremento delle prestazioni è limitato dall'ammontare dell'utilizzo del componente.

UNITA' STANDARD

grandezza	nome	abbreviazione
$10^{15} \div 2^{50}$	peta	p, P
$10^{12} \div 2^{40}$	tera	t, T
$10^{9} \div 2^{30}$	giga	g, G
$10^{6} \div 2^{20}$	mega	m, M
$10^{3} \div 2^{10}$	kilo	k, K
10^{-3}	milli	m
10^{-6}	micro	μ
10^{-9}	nano	n
10^{-12}	pico	p

UNITA' STANDARD

hertz (1 ciclo al sec.)	Hz,hz
bit	b
byte (8 bit)	B
bits(bytes) per second	bps (Bps)
instructions per sec.	ips
I/O operations per sec.	I/Ops
transactions per sec.	tps
bits per inch (2.5 cm)	bpi
rounds per minute	rpm

Capacità presente e futura dei sistemi di memoria

Presenti:
alcuni Giga(10^9)
Terabytes (10^{12})
Petabytes (10^{15})

vicine:
Exabytes (10^{18})
Zettabytes (10^{21})

future:
Yottabytes(10^{24})

Un'idea sull'hardware

PC di oggi: 3 Ghz multi-core, 4096 MB RAM,
2 TB di disco, velocita' massima: fino a 100 Gigaflops

Titan (Cray XK7, 2012): 17,59 Petaflops, 560640 core,
710 Terabyte RAM, 40 PetaByte di disco (97M $)

Sequoia (IBM BlueGene/Q, 2009): 16,32 Petaflops, 1572864 core,
1.6 Petabyte RAM, 55 PetaByte di disco

K computer (Fujitsu K, 2008): 10,51 Petaflops, 705024 core

http://en.wikipedia.org/wiki/TOP500

Ordini di grandezza

- 1 byte: 1 carattere
- 1 pag. di libro : 50 righe per 80 caratteri → 4 kB
- 1 libro di 500 pag.: 2MB (senza figure)
- 1 pag. di vocabolario: 2×60×80 caratteri → 9.6 kB
- 1 vocabolario di circa 2000 pag. → 20 MB
- att.: l'occupazione di memoria è superiore se le pagine ed i caratteri sono "strutturati"
- in 500MB di 1 CD vanno 250 libri o 25 vocabolari
- in un BD-ROM da 50 GB: 25000 libri o 2500 vocabolari
- Nota: con tecniche di compressione è possibile incrementare anche di molto queste cifre

Tipi di memorie permanenti

- memorie elettroniche
  - memorie flash
- memorie magnetiche
  - dischi rigidi
    - disco singolo
    - RAID (dischi paralleli)
- memorie ottiche
  - CD-ROM, CD-R, CD-RW
  - DVD-ROM, DVD-R, DVD-RW
  - BD-ROM, HD-DVD
  - magneto-ottiche riscrivibili

Memorie elettroniche - flash

- **Esistono vari tipi di memorie elettroniche permanenti. Molto comuni sono le Flash Memory, usate per memorizzare informazioni in modo veloce e semplice, come dei piccoli hard disk.**

- **Alcuni esempi di Flash Memory:**
  - **Il BIOS del computer**
  - **"Chiavi" USB**
  - **Schede CompactFlash, Memory Stick, SD (fotocamere digitali)**
  - **Dischi SSD (Solid State Drive)**
  - **Memory card usate nelle console**

Memorie ottiche

- La più nota è il CD-ROM:
- funzionamento start-stop
- accesso diretto (n × 100 ms
  con data rate n × 100 KB/sec)
- molta memoria (600 MB → oltre)
- unità di sola lettura
- costituiscono una memoria di terzo livello

Memorie ottiche

- Simile al CD-ROM è il DVD-ROM
  - Maggiore quantità di dati contenibile, grazie a…
    - alta densità dei dati (distanza tra le spire di 740 nanometri, contro i 1600 dei CD)
    - tecnologia multi-layer, che consente di raggiungere 15.9GB per DVD doppio lato e doppio strato
    - Migliori algoritmi di error correction, che consentono un minore spazio sprecato da informazioni duplicate
- Ultima generazione di memorie ottiche è il Blu-Ray Disk
  - laser a luce blu (405 nm) per una ancora maggiore densità dei dati
  - tecnologia multi-layer, che consente di raggiungere 50GB per BD doppio strato (BD-50)

Memorie magnetiche – il disco

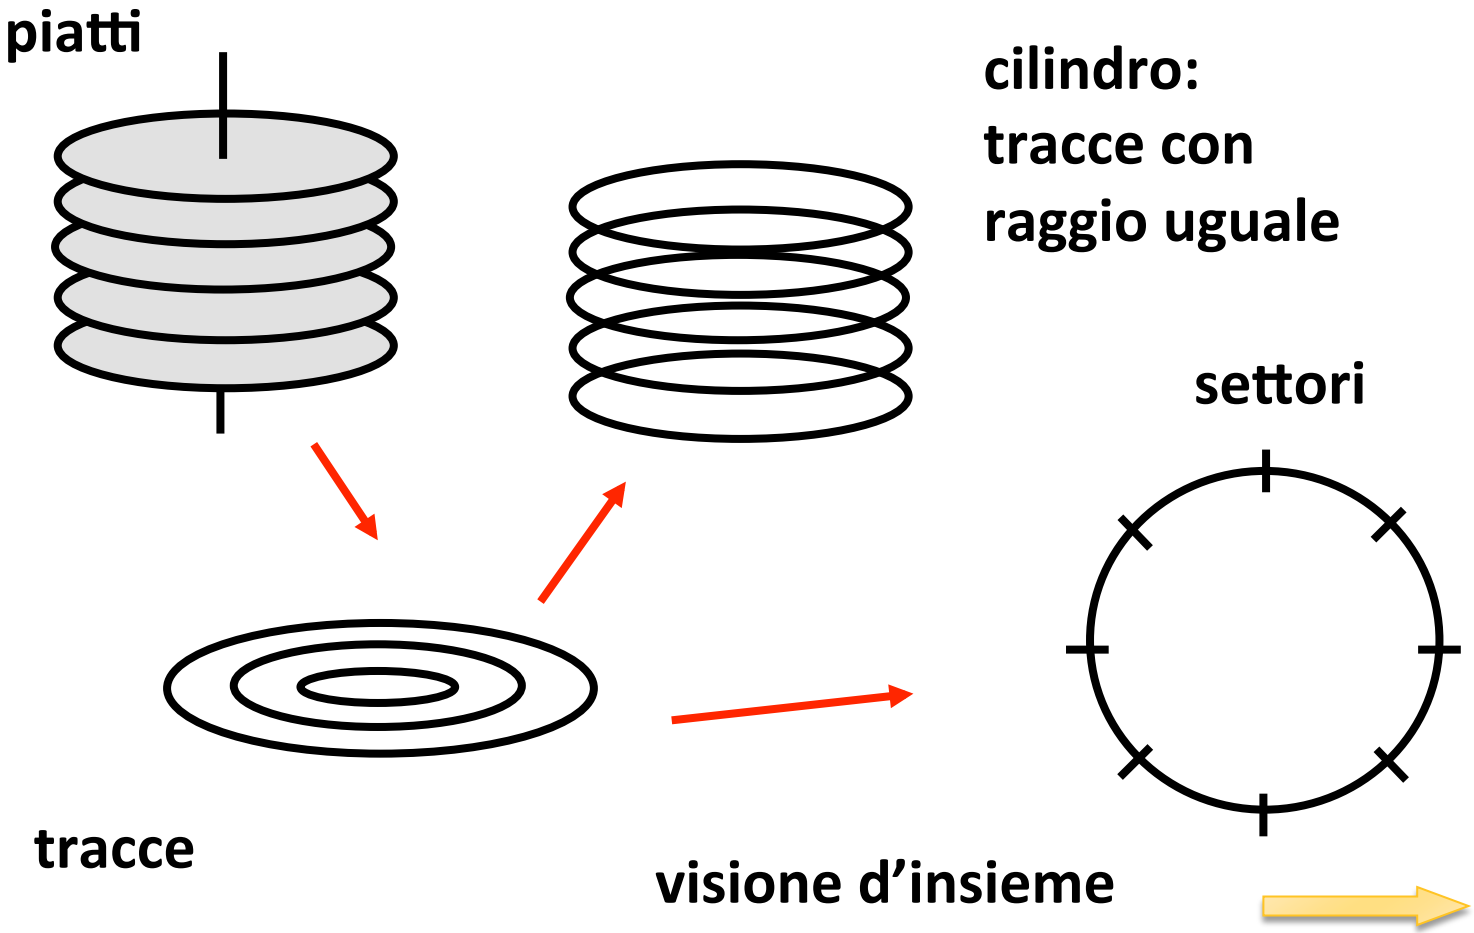

Memorie magnetiche – il disco

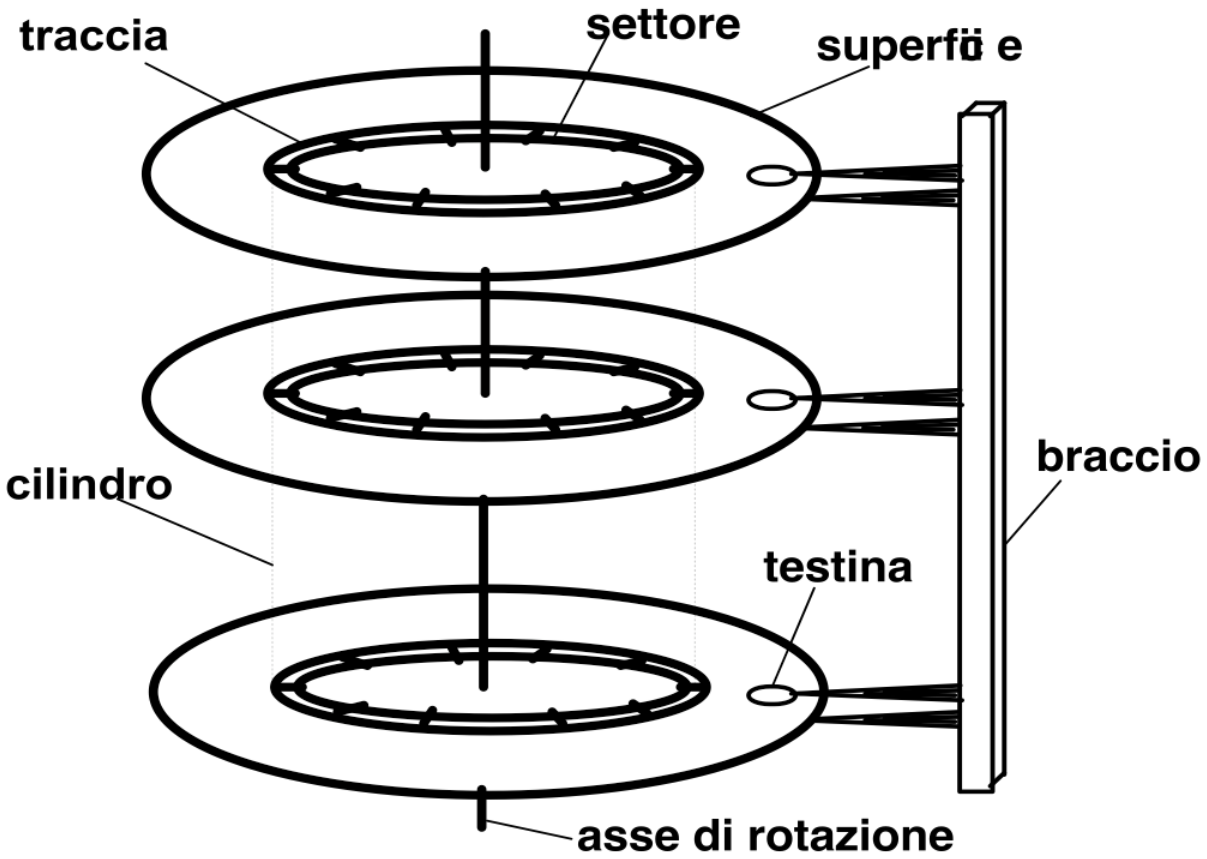

Grandezze

- **velocità** di rotazione (rpm): 5400 → 10000 ed oltre
- **no. piatti**: 1 → 20 ed oltre
- **tracce** per piatto (quindi cilindri) 3000 → 20000 ed oltre
- **diametro** disco 1 → 8 inch
- **densità:** n Giga bit per inch ^{2}
- **dimensione del settore:** 4k ed oltre
- **settori per traccia**: (2^n ad es. 64) da circa alcune decine ed oltre

Grandezze

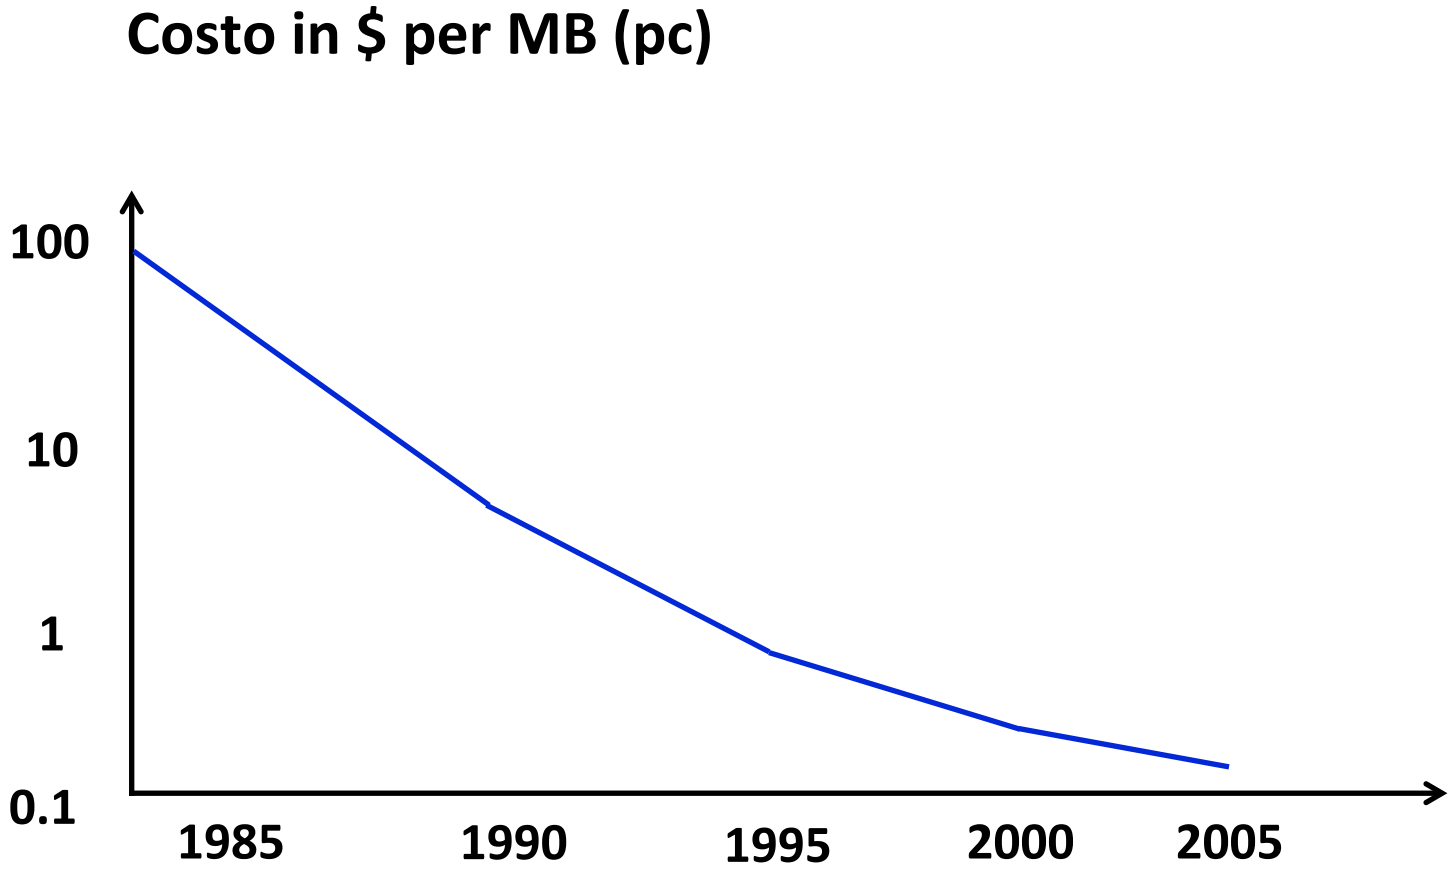

Dimensione del settore

- Ad esempio, con i file system in Windows:
  - NTFS (Windows NT - Windows 7…)
    - 4K block size per dischi più grandi di 2GB
  - FAT-32 (Windows 95, 98, ME)
    - 4K per dischi fino a 8GB
    - 8K fino a 16GB
    - 16K fino a 32GB
    - 32K oltre 32GB.

Meccanica del disco

Funzionamento: movimento del pettine, raggiungimento del cilindro richiesto, attivazione della testa relativa alla traccia, attesa del settore , lettura/scrittura

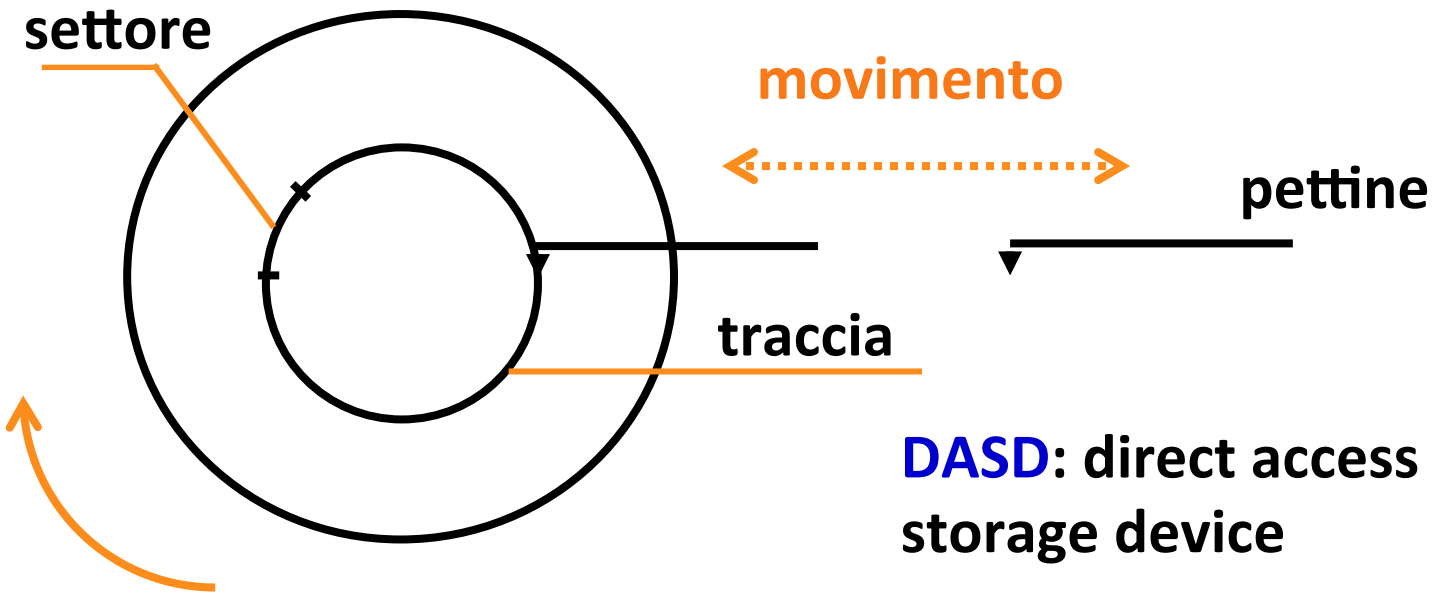

DASD: direct access storage device

Meccanica del disco

- Il settore è l'unità minima di trasferimento, i settori possono essere raggruppati in blocchi (pagine)
- l'indirizzo di un settore (blocco) è :
  - num. cilindro, num. traccia, num. settore.
- il tempo di servizio è:
  - tempo di posizionamento (seek time) : Ts
  - tempo di latenza rotazionale : Tr
  - tempo di lettura (scrittura) : Tb
  - per la scrittura si usa anche il metodo read after write che ricontrolla dopo un giro
  - tempo impiegato dal controller (elettr.):Tc

Meccanica del disco

- il tempo di posizionamento (seek time) : Ts viene indicato dal costruttore come tempo medio di spostamento tra due possibili tracce, vengono anche indicati il Tmax ed il Tmin.
- il tempo di latenza rotazionale : Tr è mediamente la metà del tempo di rotazione
- il tempo di lettura (scrittura) : Tb dipende dalla dimensione del blocco
- il metodo read after write richiede un ulteriore 2×Tr
- il tempo impiegato dal controller (elettr.):Tc è generalmente indicato dal costruttore
- transfer rate misurato in MB/sec.

Meccanica del disco

- **Esempio:**

  Ts = 9ms, transfer rate = 30 MB/sec ,

  blocco = 4096 bytes, Tc = 1 ms.

  rotazione 7200 rpm

- **tempo di accesso:**

  Ts + Tr + Tb + Tc=

  9 ms + 0.5 / 7200rpm + 4KB / 30MB/sec +1 ms = 9 + 4.15 + 0.1 + 1 = 14.3 ms

- **con read after write :**

  14.3 + 2×4.15 = 22.6 ms

  l'ordine di grandezza è di molto superiore a quello delle operazioni elettroniche

Meccanica del disco

- Le memorie elettroniche avrebbero un tempo di accesso di circa 100000 volte inferiore … ma un costo di circa 100 volte superiore
- i tempi di seek e di latenza sono da ridurre:
  - costruttivamente, riducendo i diametri, aumentando la velocità del pettine e di rotazione, aumentando la densità dei bit sulla superficie e riducendo di conseguenza l'altezza di volo delle testine sui piatti……..

    l'altezza di volo è inferiore a 0.5 micron (si pensi che un capello ha un diametro di circa 80, la polvere da 6 a 30 ed un'impronta digitale di 15 micron)

Meccanica del disco

L'*altezza di volo della testina* è strettamente connessa alla densità di registrazione: minore è la distanza, migliore è la possibilità di rilevare le variazioni di campo magnetico, maggiore è la densità possibile.

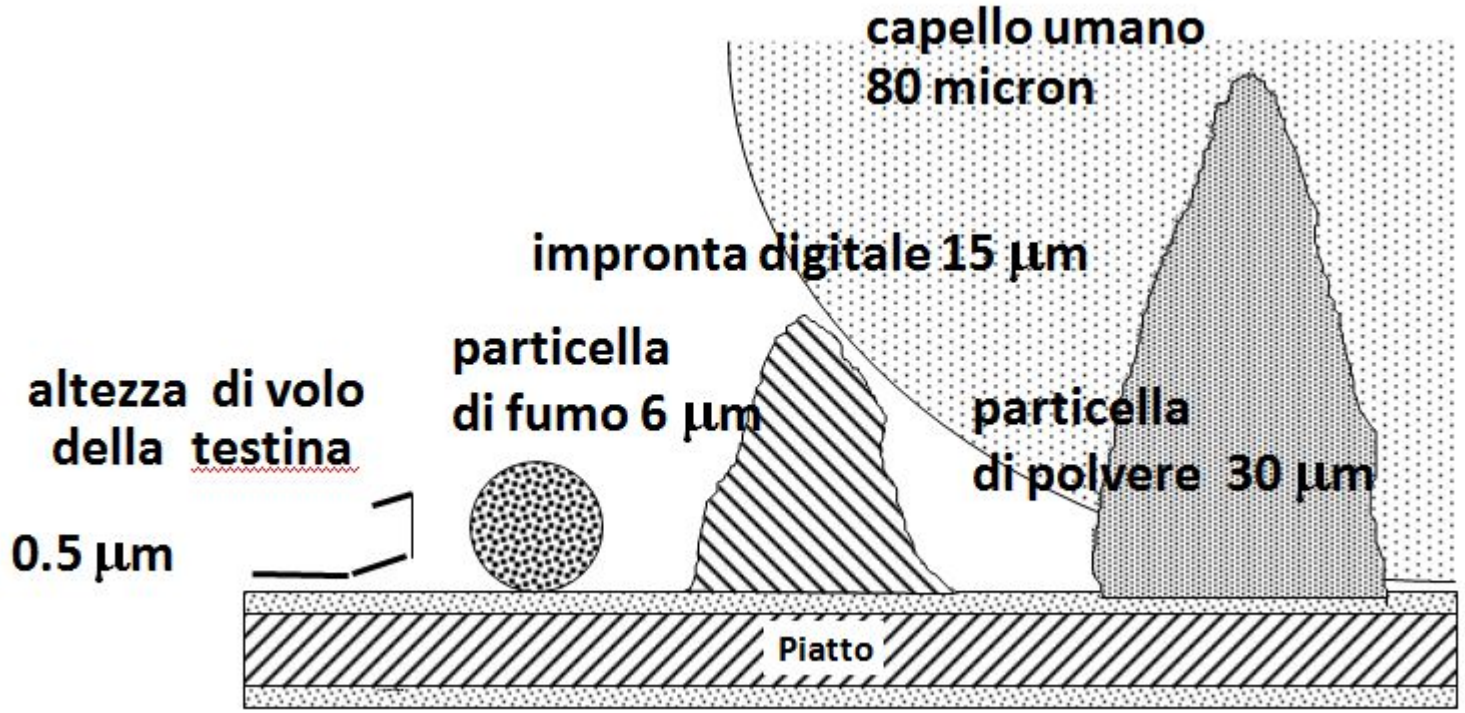

Meccanica del disco

- riducendo l'ampiezza degli spostamenti del pettine organizzando la coda delle richieste dell'utenza:

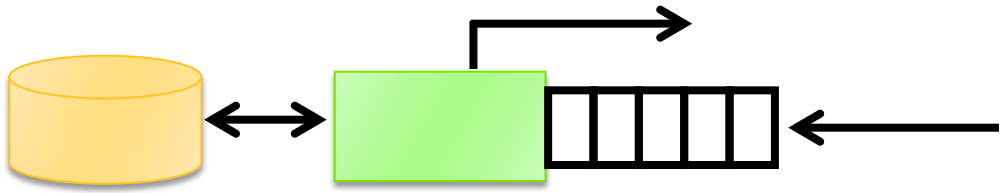

disco gestore coda di richieste

Parallelismo e sicurezza

Disk Mirroring : dischi con dati replicati

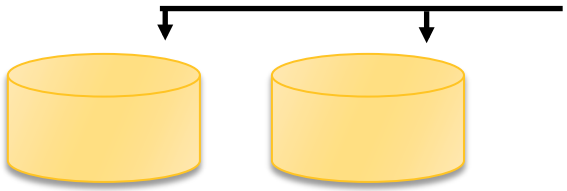

letture indipendenti
scritture su entrambi

- **aumentando il numero di dischi aumenta la probabilità di averne uno guasto**
- **diminuisce la probabilità di perdita dei dati dovuta al guasto contemporaneo**
- **ridondanza eccessiva**

la ridondanza è utile!

Dischi RAID

Redundant Array of Inexpensive Disks

- architettura che migliora le prestazioni e l'affidabilità del sistema di mem. permanente
- l'uso di N dischi consente di suddividere i dati in piccoli blocchi da scrivere e leggere in parallelo
- informazioni ridondanti consentono la correzione di errori dovuti a guasti

Dischi RAID

- servizio parallelo indipendente per letture brevi per più utenti (parallelismo inter-query)
- servizio parallelo per letture lunghe per lo stesso utente (parallelismo intra-query)
- RAID 0 : striping, nessuna ridondanza (es. 8 dischi)
- RAID 1 : mirroring (es. 16 dischi)
- RAID 2-3: striping, unico movimento parallelo delle testine
- RAID 4: striping, prevede un disco in più per l'informazione ridondante : la parità

Dischi RAID

Concetto di parità:

- dati 8 bit c'è un nono bit che contiene la somma modulo 2 (è 0 se il numero di 1 nel byte è pari altrimenti è 1)

  0 0 1 0 1 1 0 1 → 0

  1 0 1 1 0 1 1 0 → 1

- se un bit si inverte la parità non torna quindi c'è un bit errato (però non si sa quale)

- nel RAID 4 tutti bit di parità stanno sul nono disco

Dischi RAID

- Se un disco si guasta il controller se ne accorge e l'informazione viene ricostruita con la parità:

0 0 1 0 x 1 0 1 → 0 poiché la parità è 0 il bit era 1

1 0 x 1 0 1 1 0 → 1 poiché la parità è 1 il bit era 1

Il RAID 4 ha un eccesso di letture sul nono disco

Dischi RAID

Il RAID 5 ha 1 solo disco in più ma parità e dati sono distribuiti ciclicamente su tutti: un blocco di dati viene memorizzato sui dischi da 1 a 8 e la parità sul 9, un secondo blocco dati viene memorizzato sui dischi da 9 a 7 e la parità sul 8 ….

Il RAID 6 ha 2 dischi in più ma l'informazione è codificata con il codice Reed Solomon e riesce a correggere due guasti

RAID 5

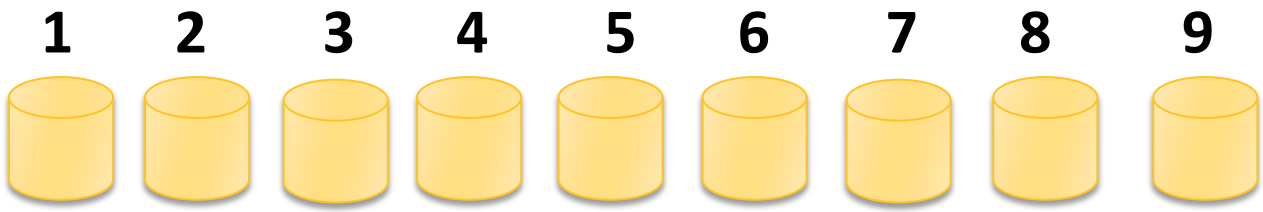

a1	a2	a3	a4	a5	a6	a7	a8	pa
b2	b3	b4	b5	b6	b7	b8	pb	b1
c3	c4	c5	c6	c7	c8	pc	c1	c2
d4	d5	d6	d7	d8	pd	d1	d2	d3

disposizione Left Symmetric

Alcuni concetti sulla probabilità

- **Sia P(A) la probabilità che un evento A accada in un dato periodo di tempo**
- **P(A) è tra 0 e 1 e 1- P(A) è la probabilità che l'evento A non accada nel periodo**
- **Due eventi A e B sono indipendenti se l'occorrenza di uno non influenza l'occorrenza dell'altro, allora:**

P(A and B)= P(A) x P(B) ***(entrambi accadono)***

P(A or B)= P(A)+ (1- P(A)) x P(B) ***(uno solo accade)***

= P(A) + P(B) – P(A)xP(B) ≈ P(A) + P(B)

Alcuni concetti sulla probabilità

- **Poiché le P sono troppo piccole si usa al loro posto il MT(A) cioè il tempo medio di occorrenza dell'evento *(mean time to event)* : MT(A) =1/P(A)**

- **Attenzione, se i tre componenti lavorano insieme MT(almeno uno) è il MT globale! Quindi per alzare il MT globale bisogna alzare la qualità di tutti.**

  MT(G) = 1/(P(A)+P(B)+P(C)) =

  1/(1/MT(A)+1/MT(B)+1/MT(C))

  se gli MT di N componenti sono uguali allora:

  MT(G)= MT(A)/N

Analisi della affidabilità

- Ipotesi:
  - i guasti nei vari dischi sono indipendenti
  - la possibilità di guasto è invariabile nel tempo
- le grandezze di interesse sono :
  - MTTF: mean time to failure
  - MTTR: mean time to repair
  - MTTDL: mean time to data loss

Analisi della affidabilità

- **RAID 0 (poco affidabili):**

  $MTTF_{RAID0} = MTTF_{DISCO} / N = MTTDL$

- **Es.:**

  $MTTF_{DISCO} = 30000$ h > 3 anni

  con 100 dischi:

  $MTTF_{RAID0} = 30000 / 100 = 300$ h ≈ 2 sett.

  con 8 dischi : 3759 h ≈ 22 sett.

Analisi della affidabilità

- **RAID 1 (molto affidabili):**

  $MTTF_{RAID1} = MTTF_{DISCO} / (2 \times N)$

- **Es.:**

  con 16 dischi : ≈ 11 sett.

Però!

MTTDL (mean time to data loss) è elevatissimo: si dovrebbero guastare contemporaneamente un disco e la sua copia

Analisi della affidabilità

- **RAID 5 (molto affidabili):**

  $MTTDL_{RAID5} =$

  $(MTTF_{DISCO})^2 / (N \times (N-1) \times MTTR)$

- **Es.:**

  con 9 dischi e MTTR = 24 h : ≈ 60 anni

  molto inferiore al RAID 6 ma molto superiore ai dischi SLED (single large expensive disk)