Sistemi Operativi per LT Informatica

Gestione della memoria secondaria
A.A. 2017-2018

Docente: Salvatore Sorce

Interfacce I/O

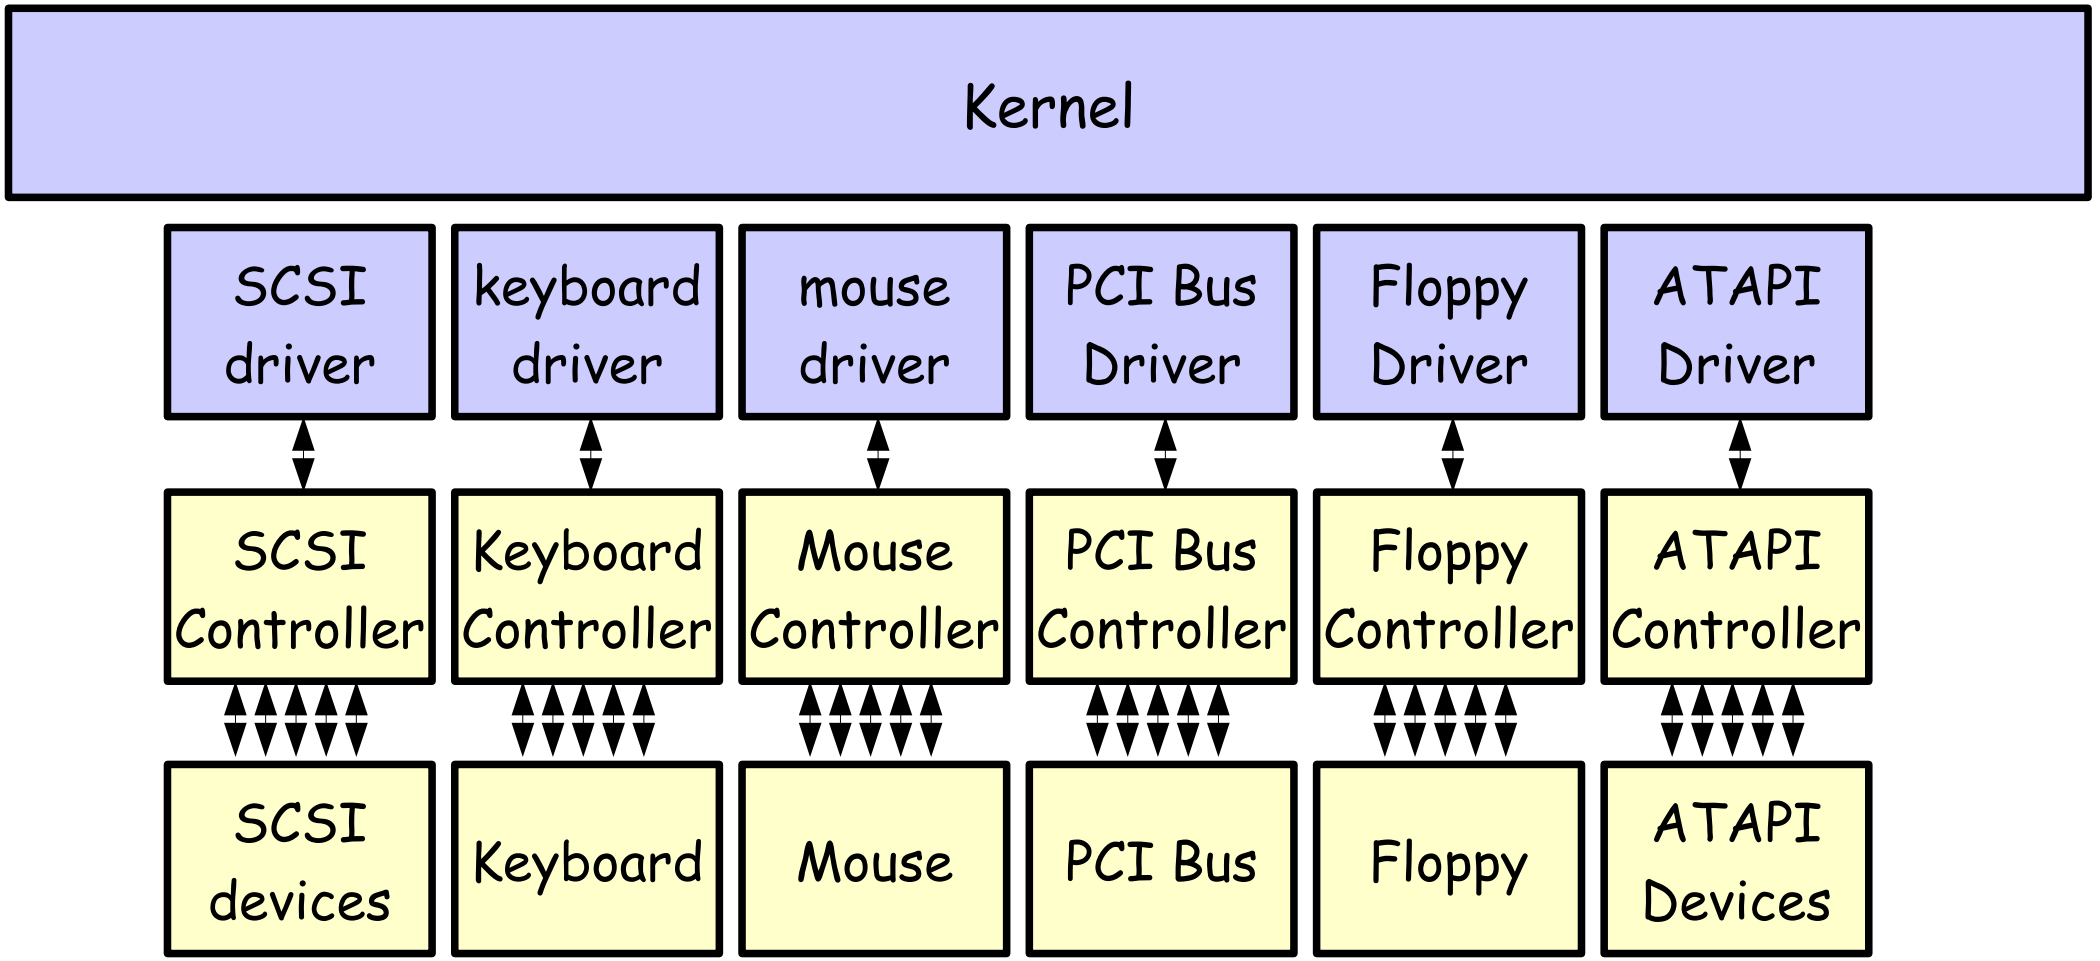

Come classificare i sistemi di I/O

Aspetto	*Variazioni*	*Esempi*
Modalità di trasferimento	Caratteri Blocchi	Terminale Dischi
Modalità di accesso	Sequenziale Random	Modem CD-ROM
Trasferimento	Sincrono Asincrono	Nastri Mouse
Condivisione	Dedicato Condivisibile	Nastri Tastiera
Velocità	Pochi byte/s Gigabyte/s	Tastiere Schede di rete
Direzione di I/O	Sola lettura Sola scrittura Lettura/scrittura	Mouse Scheda video Dischi

Dispositivi a blocchi / caratteri

- **Interfaccia di comunicazione a blocchi**
  - i dati vengono letti/scritti a blocchi (tipicamente 512-1024 byte)
  - raw I/O
    - operazioni di read, write, seek per blocchi
  - accesso tramite file system
    - operazioni di read, write, seek su file
  - accesso tramite memory-mapped I/O
    - il contenuto di un file viene mappato in memoria
    - accesso tramite istruzioni di load/store del processore

Dispositivi a blocchi / caratteri

- **Interfaccia di comunicazione a caratteri**
  - i dati vengono letti/scritti un carattere alla volta
  - raw I/O
    - operazioni di get/put di un singolo carattere
  - bufferizzazione
    - lettura/scrittura di “una linea alla volta”

Progettazione del sistema di I/O

- **Tecniche di gestione dei dispositivi di I/O**
  - buffering
  - caching
  - spooling
  - I/O scheduling

Progettazione del sistema di I/O

- **Tre motivazioni per il buffering**
  - per gestire una differenza di velocità tra il produttore e il consumatore di un certo flusso di dati
  - per gestire la differenza di dimensioni nell'unità di trasferimento
  - per implementare la “semantica di copia” delle operazioni di I/O
- **Caching**
  - mantiene una copia in memoria primaria di informazioni che si trovano in memoria secondaria
  - è differente dal buffering
    - nel buffer si trova l'unica *istanza* di un'informazione
    - la cache mantiene la *copia* di un'informazione

Progettazione del sistema di I/O

- **Spool**
  - è un buffer che mantiene output per un dispositivo che non può accettare flussi di dati distinti
  - ad esempio, stampanti

Collegamento di memorie secondarie

- Dispositivi collegati tramite bus/porte I/O
- Esempi: SCSI, USB, ATA/SATA, IDE/EIDE, ecc
  - Spesso più dispositivi su uno stesso bus (unico controller)
  - I/O directed to bus ID, device ID, logical unit (LUN)

Collegamento di memorie secondarie

- Network-attached storage (**NAS**) è un modo di collegare memorie di massa via rete
- Si usano file system di rete (NFS e CIFS più diffusi)
- Implementati tramite remote procedure calls (RPCs) tra host e storage, tipicamente usando TCP o UDP su reti IP

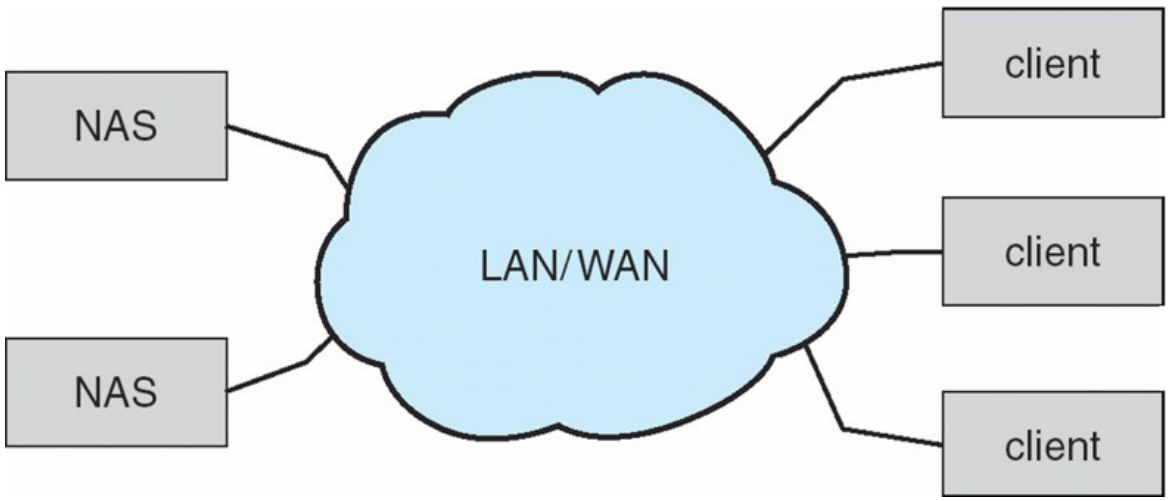

Grandezze caratteristiche

- SEEK/POSITIONING TIME: il tempo necessario per posizionare la testina di lettura/scrittura – espresso in secondi o frazioni
- TRANSFER RATE: il numero di byte che l'unità può trasferire nell'unità di tempo una volta posizionata la testina – espresso in B/Sec o multipli
- LATENCY TIME: dipende dal dispositivo e dal tipo di memorizzazione

Tipi di memorie secondarie – NASTRI MAGNETICI

- Usati inizialmente come memorie di massa
- Evoluzione da bobine aperte a cartucce/cassette
- Supporti di memorizzazione permanente, ad alta capacità
- Tempo di accesso molto lento (~1000 volte più lento di un disco)
- Accesso sequenziale
- Usati principalmente per backup, memorizzazione di dati usati raramente, trasferimento tra sistemi
- Uso di spool in attesa del posizionamento della testina
- Una volta in posizione, il tempo di trasferimento è comparabile con quello di un disco → 140MB/sec ed oltre
- Capacità tipiche da 200GB a 1.5TB

Tipi di memorie secondarie – Solid State Disks (SSD)

- Memorie a stato solido non volatili usate come hard disk
- Diverse implementazioni
- Possono essere più affidabili dei dischi magnetici
- Più costosi per MB
- Vita media più breve di un disco magnetico
- Capacità minore di un disco magnetico
- ...ma velocità molto maggiore
- Niente parti in movimento, quindi niente latenza di seek o rotazionale

Tipi di memorie secondarie – dischi magnetici

- Memorie non volatili su supporto magnetico, molto usate per capacità, affidabilità, costo
- Dischi rotanti con velocità 4200-15000 rpm (70-250 rps)
- Tempo totale di accesso dato da:

  Transfer rate (velocità di trasfermento dati tra sistema e disco in B/sec o multipli)

  Positioning time, a sua volta dato da *seek time* (tempo necessario a posizionare il braccio porta-testine sul cilindro desiderato) + *rotational latency* (tempo necessario al settore dediserato di passare sotto la testina)
- Problemi: **Head crash**, quando la testina "precipita" sul disco, causando il distacco di parti di materiale magnetico – MOLTO BRUTTO
- Si collegano tramite qualche I/O bus (IDE, SCSI, ATA) → possono essere rimovibili

Caratteristiche dei dischi

- **Struttura di un disco**
  - un disco è composto da un insieme di piatti, suddivisi in tracce, le quali sono suddivise in settori

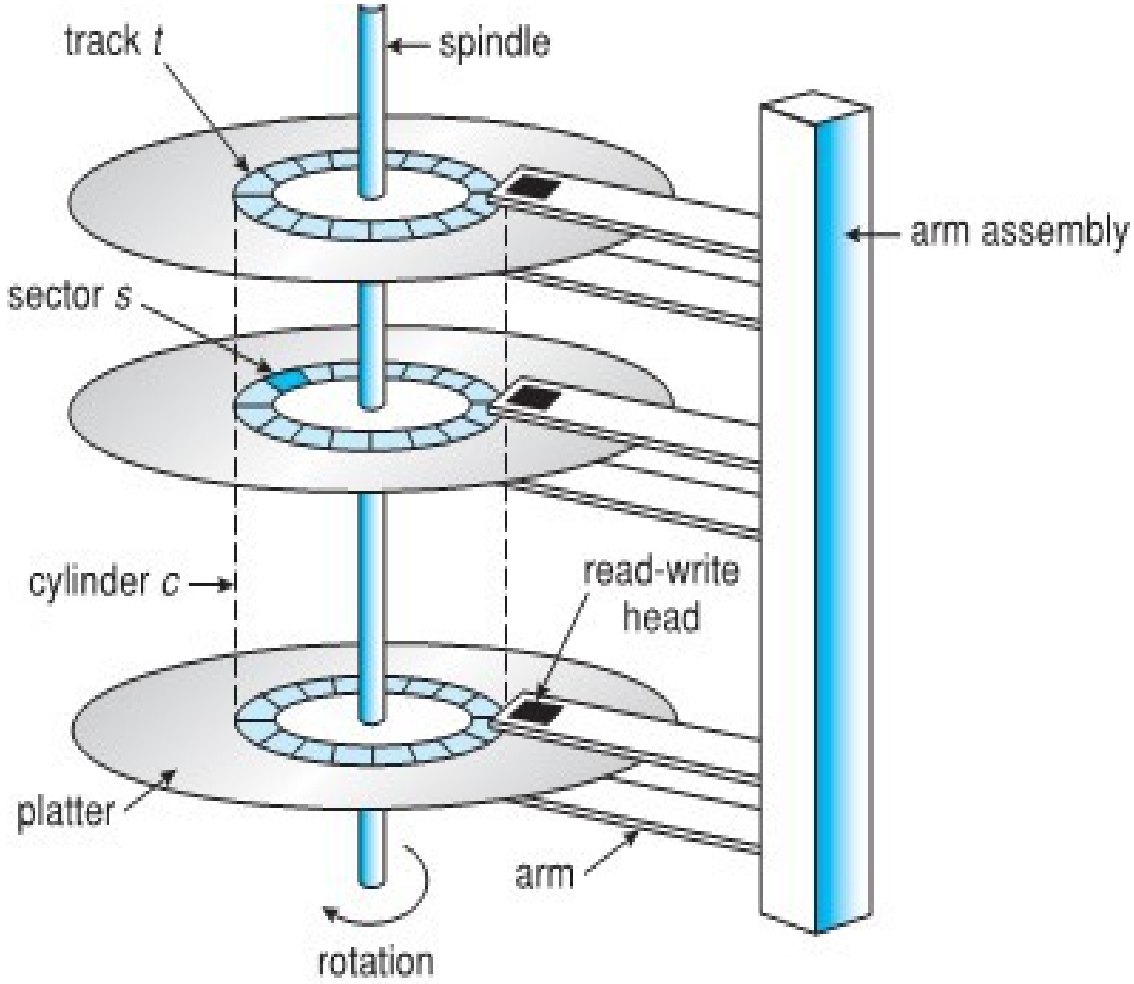

Caratteristiche dei dischi

- **I dischi sono caratterizzati da tre parametri fondamentali**
  - r
    - la velocità di rotazione, espressa in *rpm* (*revolutions per minute*)
  - T_s
    - il tempo di seek, ovvero il tempo medio necessario affinchè la testina si sposti sulla traccia desiderata
  - V_r
    - la velocità di trasferimento, espressa in byte al secondo

Caratteristiche dei dischi

- **Il tempo di accesso**
  - è il tempo necessario per leggere un settore del disco, composto da tempo di seek, ritardo rotazionale e tempo di trasferimento
- **Ritardo rotazionale**
  - il tempo medio necessario affinchè il settore desiderato arrivi sotto la testina
  - è uguale a (1 / 2r) [minuti] ovvero (1/2)*(60/r) [secondi]

Spindle [rpm]	Average latency [ms]
4200	7.14
5400	5.56
7200	4.17
10000	3
15000	2

- **Transfer time**
  - dipende dalla quantità di dati b da leggere (supponendo che siano contigui sulla stessa traccia)
  - è uguale a b/Vr

Caratteristiche dei dischi

- **Access Latency** = **Average access time** = average seek time + average latency
  - Dischi veloci: 3ms + 2ms = 5ms
  - Dischi più lenti: 9ms + 5.56ms = 14.56ms
- Average I/O time = average access time + (amount to transfer / transfer rate) + controller overhead
- Esempio: per trasferire un blocco da 4KB su un disco a 7200 RPM con 5ms di average seek time, 1Gb/sec transfer rate e 0.1ms controller overhead
  - 5ms + 4.17ms + 0.1ms + transfer time
  - Transfer time = 4KB / 1Gb/s * 8Gb / GB * 1GB / 1024^2KB = 32 / (1024^2) = 0.031 ms
  - Average I/O time per un blocco da 4KB = 9.27ms + .031ms = 9.301ms

Organizzazione logica dei dischi

- I dischi sono organizzati come array monodimensionali di blocchi logici
- Un blocco logico è il più piccolo ammontare di dati che si può trasferire/indirizzare
- L'array di blocchi logici viene mappato sull'insieme dei settori in maniera sequenziale
- Il settore 0 è il primo settore della prima traccia del cilindro più esterno
- Il riempimento prosegue lungo la stessa traccia, poi lungo le tracce dello stesso cilindro, e poi lungo i cilindri verso l'interno
- Numero di settori per traccia:
  - Costanti: velocità di rotazione costante, non si sfrutta al meglio la capacità del supporto
  - Variabili: velocità angolare variabile, si sfrutta al meglio la capacità del supporto

Disk Scheduling

- **Gestione software dei dischi**
  - il gestore del disco può avere numerose richieste pendenti, da parte dei vari processi presenti nel sistema
  - il sistema sarà più efficiente se le richieste pendenti verranno evase seguendo un ordine che minimizza il numero di operazioni che richiedono molto tempo (e.g. seek)
- **Valori tipici**
  - tempo di seek: 8-10 ms
  - velocità rotazionale: 5400, 7200, 10000 rpm

FCFS

- **First Come, First Served (altrimenti detta FIFO)**
  - è una politica di gestione fair
  - non minimizza il numero di seek
  - non può mai generare starvation

FCFS - Esempio

- **Coda delle richieste: 98, 184, 39, 121, 14, 125, 65, 68**
- **Posizione iniziale: 54**

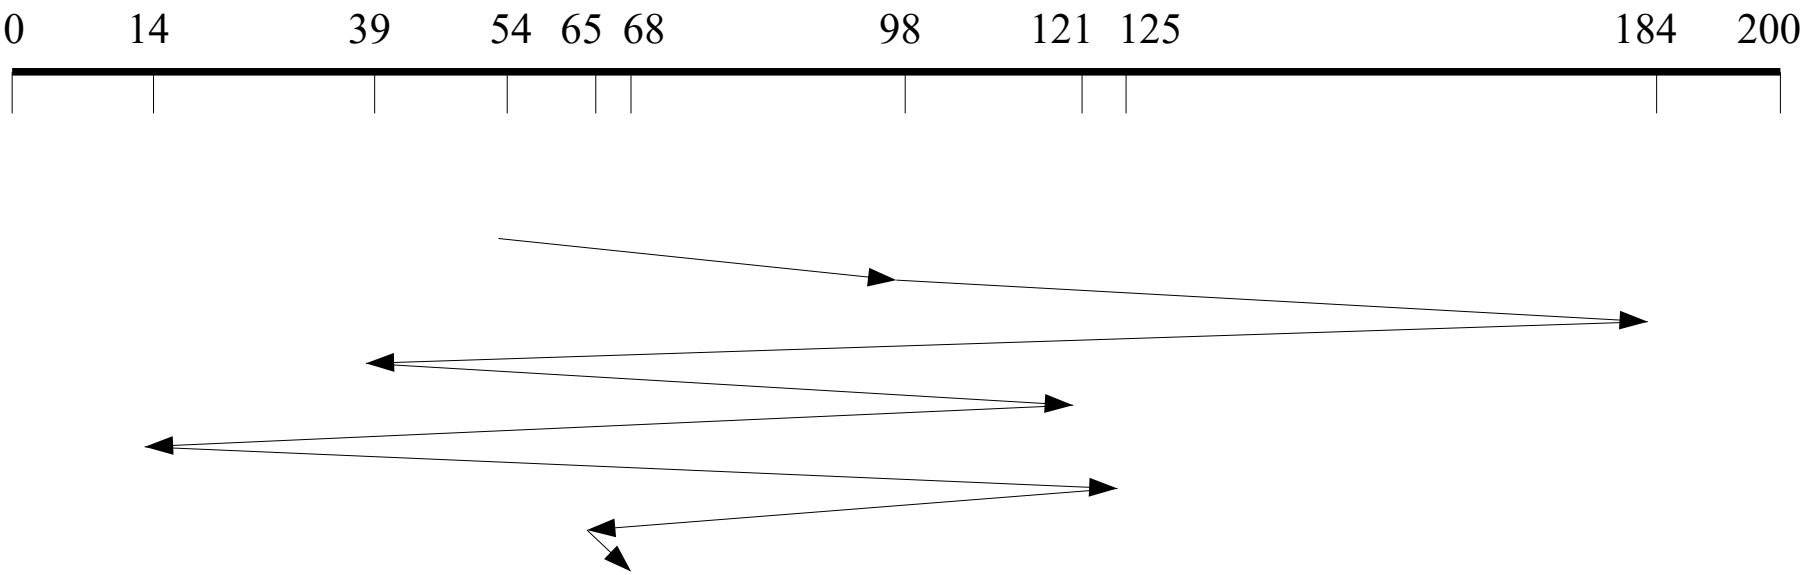

Lunghezza di seek totale: 639

media: 79.88

SSTF

- **Shortest Seek Time First**
  - seleziona la richieste che prevede il minor spostamento della testina dalla posizione corrente
  - nel caso di equidistanza, la direzione viene scelta casualmente
  - può provocare starvation

SSTF - Esempio

- **Coda delle richieste: 98, 184, 39, 121, 14, 125, 65, 68**
- **Posizione iniziale: 54**

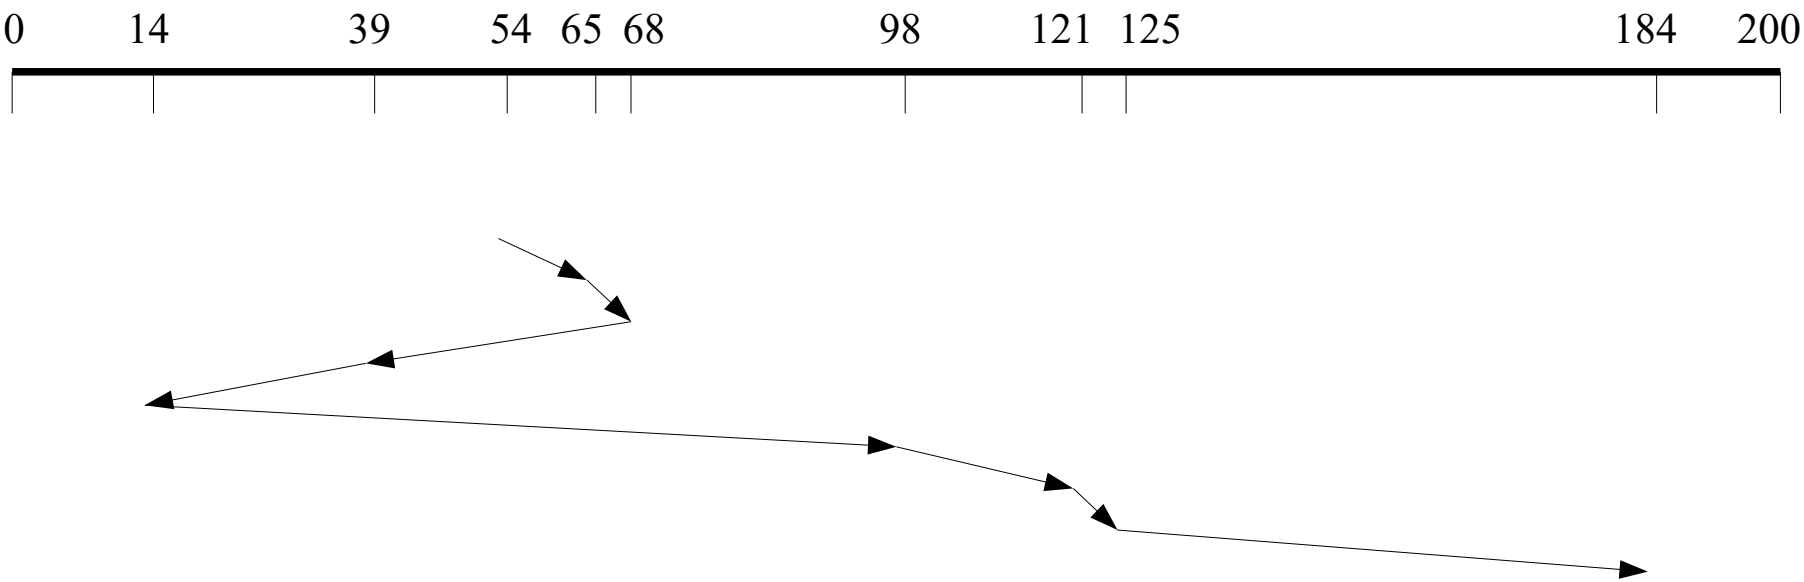

Lunghezza di seek totale: 238

media: 29.75

LOOK

- **Detto anche algoritmo dell'ascensore**
  - ad ogni istante, la testina è associata ad una direzione
  - la testina si sposta di richiesta in richiesta, seguendo la direzione scelta
  - quando si raggiunge l'ultima richiesta nella direzione scelta, la direzione viene invertita e si eseguono le richieste nella direzione opposta
- **Caratteristiche**
  - è efficiente
  - il tempo medio di accesso al disco non è omogeneo;
    sono privilegiate le tracce centrali
  - è esente da starvation (parzialmente, vedi prossimi lucidi)

LOOK - Esempio

- **Coda delle richieste: 98, 184, 39, 121, 14, 125, 65, 68**
- **Posizione iniziale: 54**

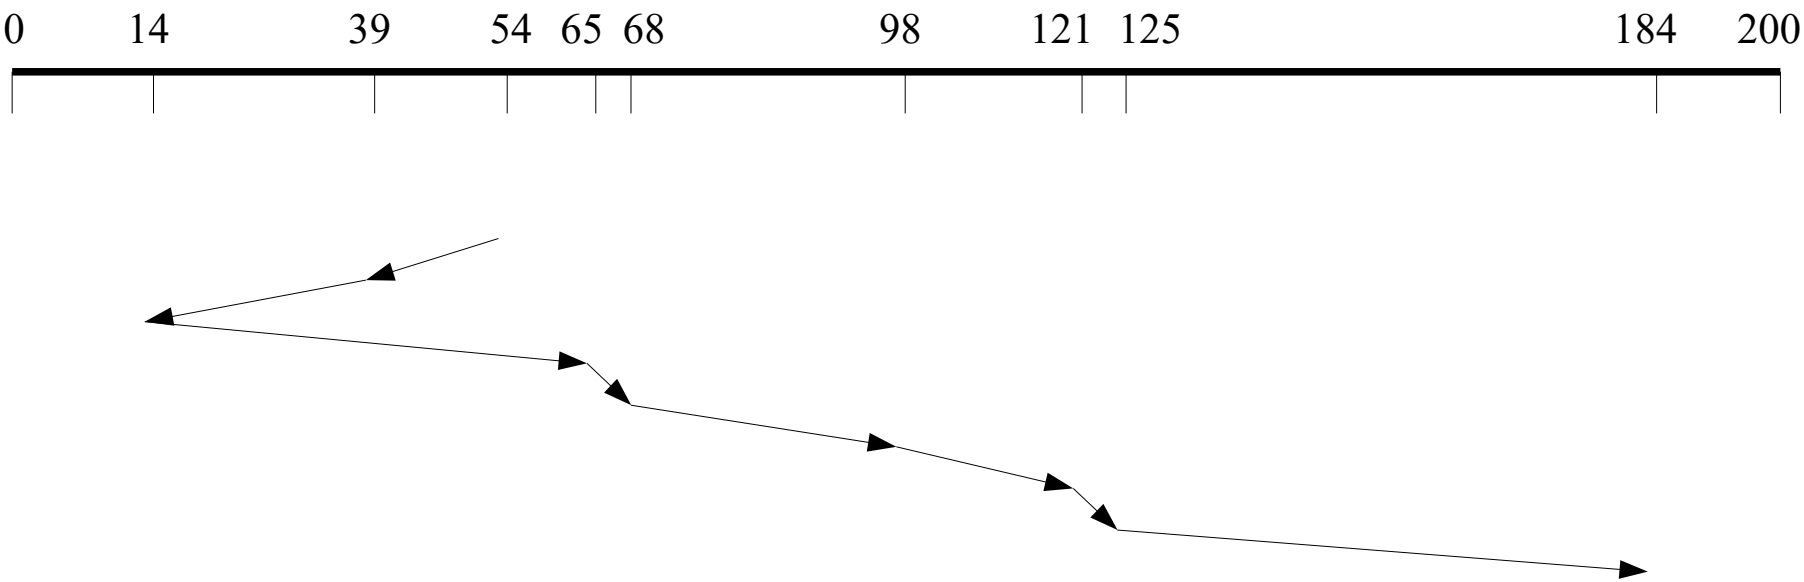

Lunghezza di seek totale: 210

media: 26.25

C-LOOK

- **C-LOOK**
  - ha lo stesso principio di funzionamento del metodo LOOK, ma la scansione del disco avviene in una sola direzione
  - quando si raggiunge l'ultima richiesta in una direzione, la testina si sposta direttamente alla prima richiesta,

C-LOOK - Esempio

- **Coda delle richieste: 98, 184, 39, 121, 14, 125, 65, 68**
- **Posizione iniziale: 54**

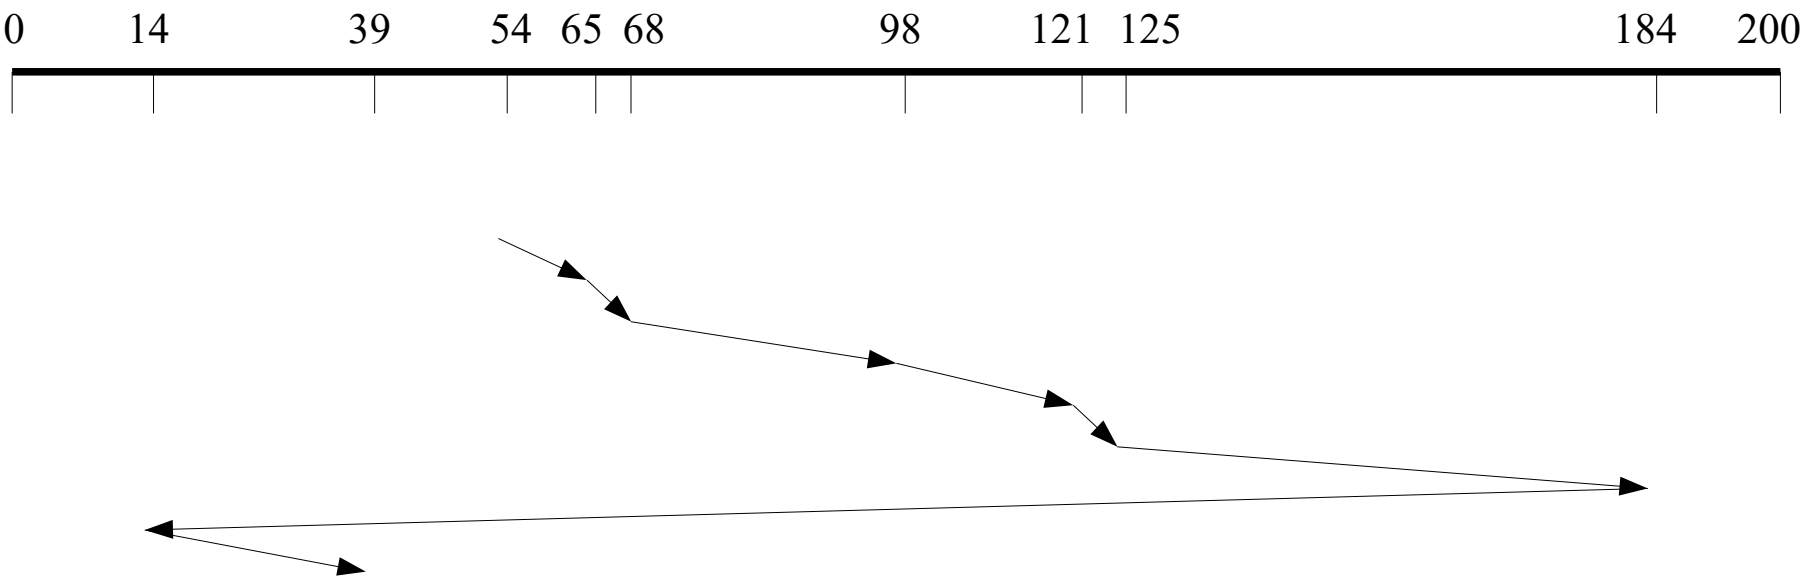

Lunghezza di seek totale: 325

media: 40.63

SSTF, LOOK e C-LOOK

- **Problema**
  - è possibile che il braccio della testina non si muova per un periodo considerevole di tempo
  - e.g., se un certo numero di processi continua a leggere sullo stesso cilindro
- **Soluzione**
  - la coda delle richieste può essere suddivisa in due sottocode separate
  - mentre il disk scheduler sta soddisfacendo le richieste di una coda, le richieste che arrivano vengono inserite nell'altra
  - quando tutte le richieste della prima coda sono state esaurite, si scambiano le due code

SCAN e C-SCAN

- Simili a LOOK e C-LOOK
- si muovono sempre tra gli estremi del disco (tracce più interne e esterne)

SCAN – ESEMPIO

queue = 98, 183, 37, 122, 14, 124, 65, 67

head starts at 53

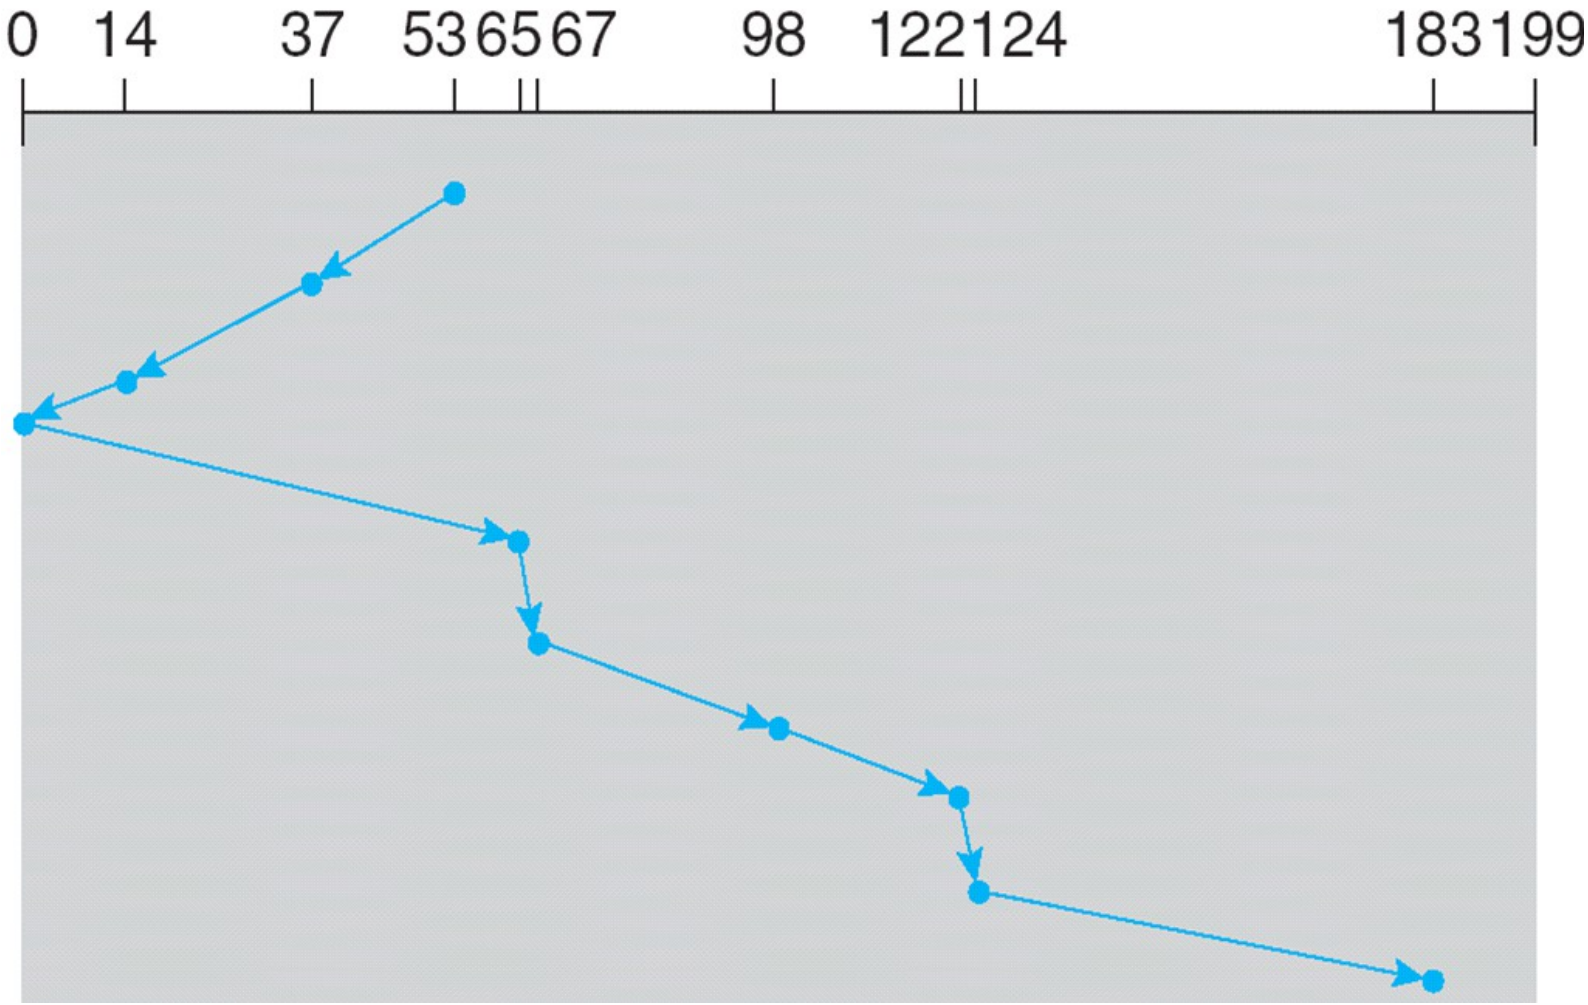

C-SCAN – ESEMPIO

queue = 98, 183, 37, 122, 14, 124, 65, 67

head starts at 53

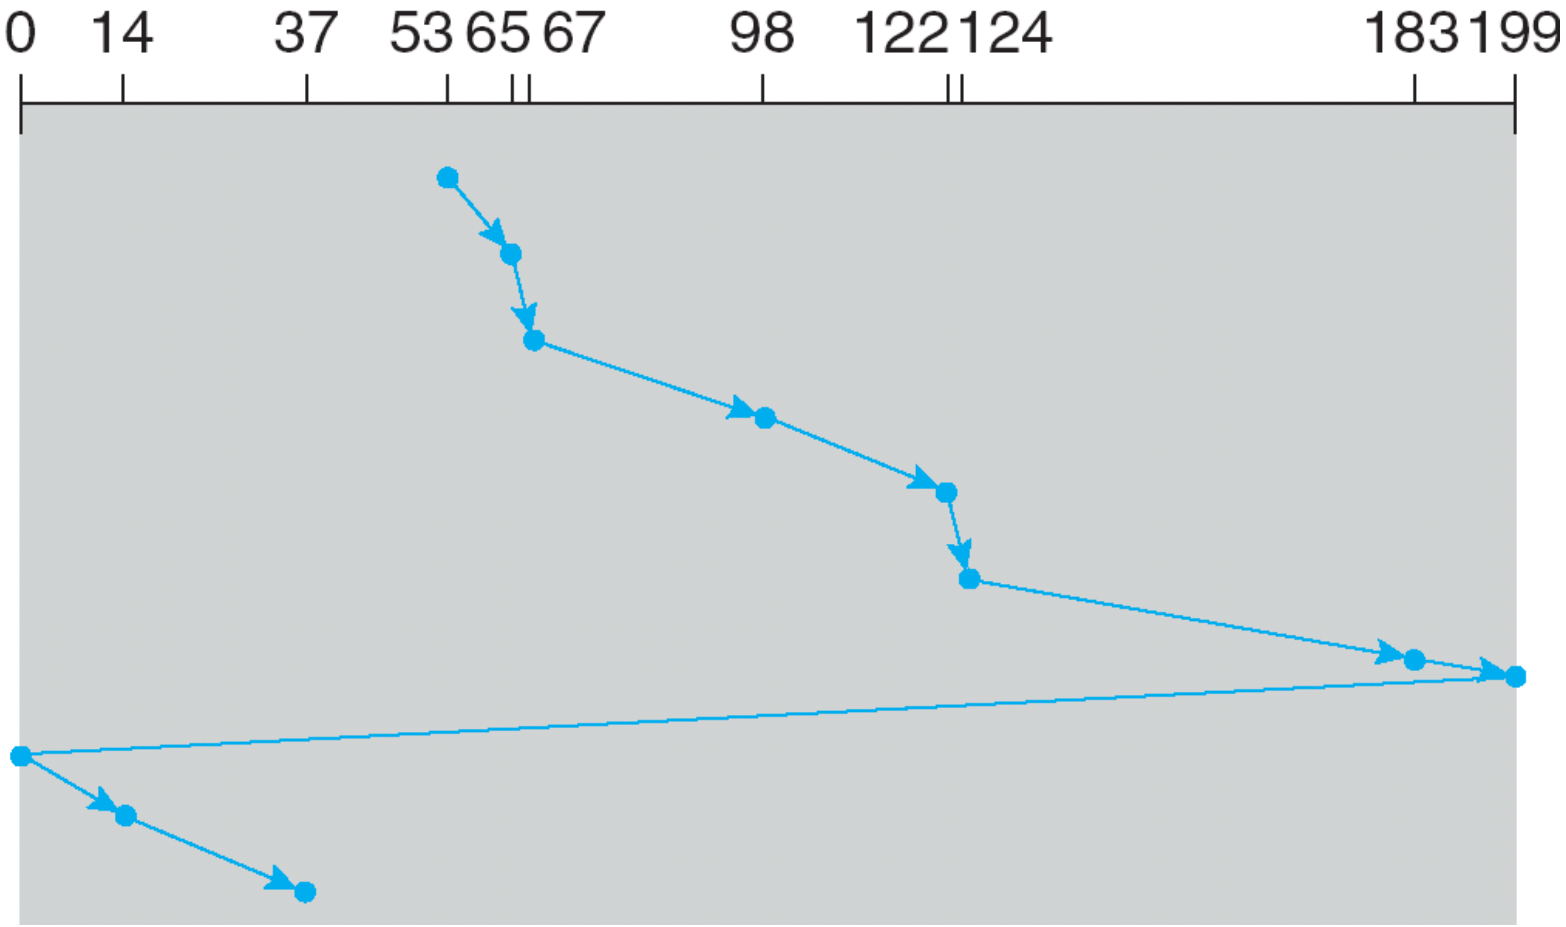

Scelta dell'algoritmo di scheduling

- SSTF e LOOK sono abbastanza diffusi
  - buone prestazioni su sistemi general purpose
- SCAN e C-SCAN hanno prestazioni migliori su sistemi che usano pesantemente i dischi
  - Starvation ridotta
- In generale, le prestazioni dipendono dal numero e dal tipo di richieste
- Le prestazioni possono essere inoltre influenzate dal tipo di strategia usata per l'allocazione dei file
- L'algoritmo di scheduling del disco andrebbe scritto come modulo separato per consentirne la sostituzione con versioni diverse/più efficienti
- L'algoritmo di scheduling del disco influenza le prestazioni dell'intero sistema
  - Influenza sulla gestione dei processi

Gestione del disco

- Low-level formatting (physical formatting): suddivisione del disco in settori e tracce che il controller possa accedere per lettura e scrittura
  - Ogni settore può contenere dati di servizio (intestazioni, codici per il rilevamento/correzione di errori, ecc.)
  - Tipicamente 512-1024 bytes per settore
- Per usare un disco come “contenitore di files”, il SO deve **registrare** la proprie strutture-dati sul disco stesso
  - Raggruppare i cilindri in **partizioni**, ognuna trattata come un disco logico indipendente
  - **Formattazione** logica, o **ad alto livello** = creare il file sistem
  - Per aumentare l'efficienza di I/O (e per tenere conto dell'overhead di servizio), spesso i file system raggruppano i blocchi in **clusters**
    - Disk I/O realizzato a blocchi
    - File I/O realizzato a clusters

Gestione del disco

- Alcune applicazioni hanno accesso “raw” al disco, per gestire autonomamente (senza interessare il SO) l'accesso ai blocchi
  - Database
- **Boot blocks** contengono le informazioni di avvio del SO
  - Il bootstrap (del sistema) si trova in ROM
  - Il bootstrap loader (del SO) si trova nei boot blocks della boot partition

Gestione del disco – esempio (Windows)

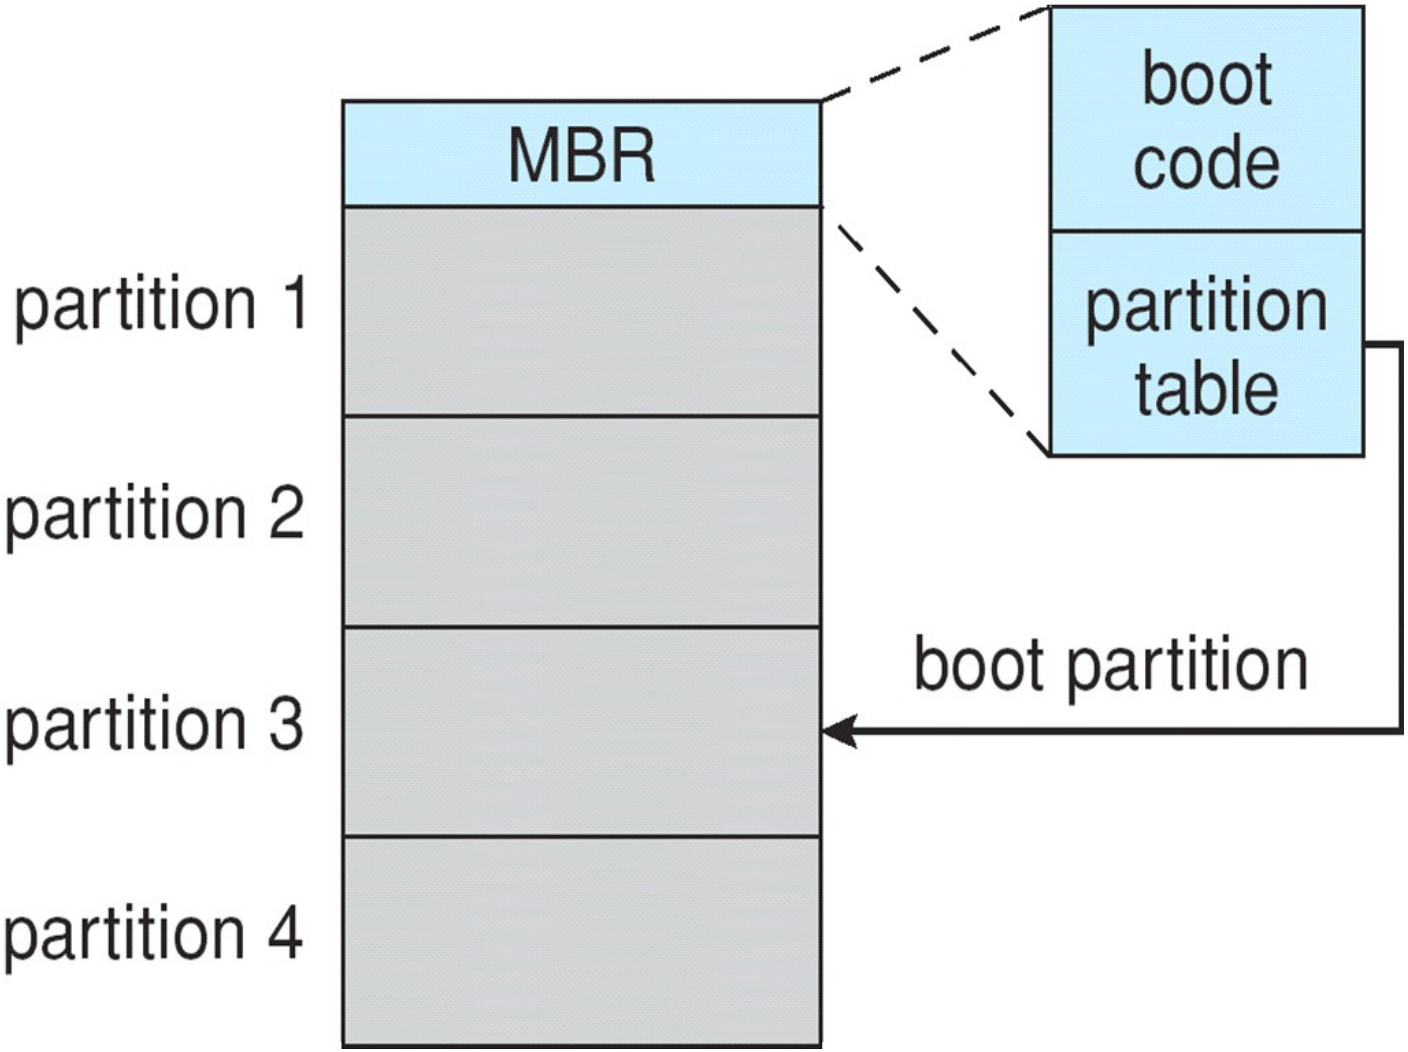

RAID

- **Problema**
  - la velocità dei processori cresce secondo la legge di Moore, la velocità dei dispositivi di memoria secondaria molto più lentamente
- **Considerazioni**
  - per aumentare la velocità di un componente, una delle possibilità è quella di utilizzare il parallelismo
  - l'idea è quella di utilizzare un array di dischi indipendenti, che possano gestire più richieste di I/O in parallelo
  - dobbiamo però garantire che i dati letti in parallelo risiedano su dischi indipendenti

RAID

- **Redundant Array of Independent Disks**
  - uno standard industriale per l'utilizzo di più dischi in parallelo
  - consiste di 7 schemi diversi (0-6) che rappresentano diverse architetture di distribuzione dei dati
- **Caratteristiche comuni ai sette schemi:**
  - un array di dischi visti dal s.o. come un singolo disco logico
  - i dati sono distribuiti fra i vari dischi dell'array
  - la capacità ridondante dei dischi può essere utilizzata per memorizzare informazioni di parità, che garantiscono il recovery dei dati in caso di guasti
- **Nota**
  - l'acronimo nell'articolo originale era *Redundant Array of Inexpensive Disks*

RAID

- **Considerazioni sui guasti**
  - l'utilizzo di più dischi aumenta le probabilità di guasto nel sistema
  - per compensare questa riduzione di affidabilità, RAID utilizza meccanismi di parità
- **Considerazioni sulle performance**
  - il data path che va dai dischi alla memoria (controller, bus, etc) deve essere in grado di sostenere le maggiori performance
  - il s.o. deve presentare al disco richieste che possano essere soddisfatte in modo efficiente
    - richieste di lettura di grandi quantità di dati sequenziali
    - gran numero di richieste indipendenti

RAID 0 (striping)

- **RAID Level 0**
  - non dovrebbe essere un membro "a tutti gli effetti" della famiglia RAID, perché non possiede meccanismi di ridondanza
  - può essere utilizzato per applicazioni in cui l'affidabilità non è un grosso problema, ma lo sono la velocità e il basso costo
- **Descrizione**
  - i dati vengono distribuiti su più dischi
  - vantaggi:
    - se due richieste di I/O riguardano blocchi indipendenti di dati, c'è la possibilità che i blocchi siano su dischi differenti
    - le due richieste possono essere servite in parallelo

RAID 0 (striping)

- **Striping**
  - il sistema RAID viene visto come un disco logico
  - i dati nel disco logico vengono suddivisi in strip (e.g., settori, blocchi, oppure qualche altro multiplo)
  - strip consecutivi sono distribuiti su dischi diversi, aumentando le performance della lettura dei dati sequenziali

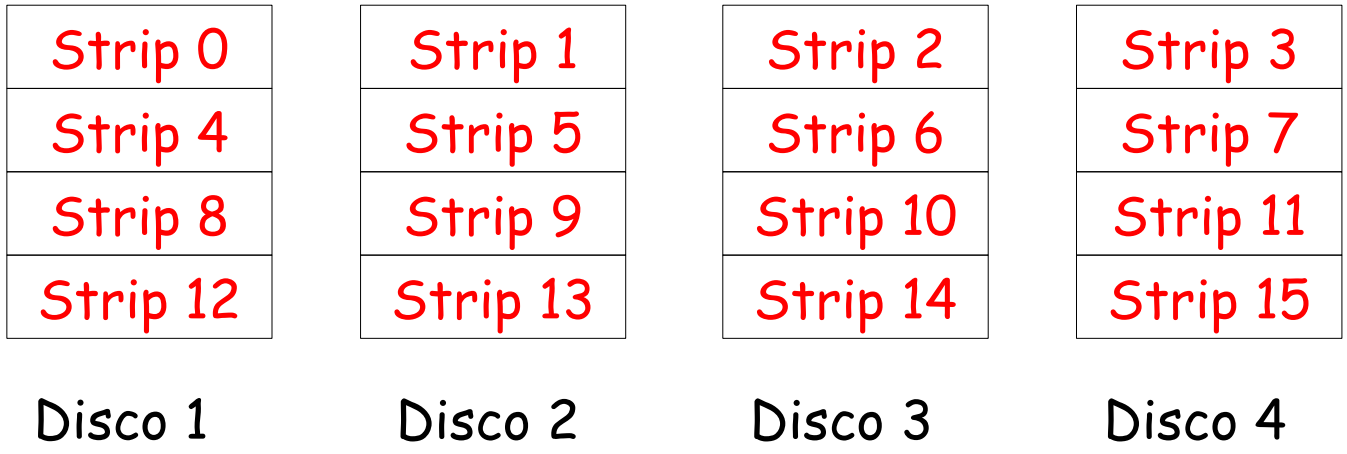

RAID 0

- **Performance di RAID 0**
  - per grandi trasferimenti di dati,
    - efficiente, in particolare se la quantità di dati richiesta è relativamente grande rispetto alla dimensione degli strip
  - per un gran numero di richieste indipendenti
    - efficiente, in particolare se la quantità di dati richiesta è paragonabile alla dimensione degli strip
- **Ridondanza**
  - nessuna

RAID 1 (mirroring)

- **RAID level 1**
  - differisce dagli schemi 2-6 per come la ridondanza è gestita
  - la ridondanza è ottenuto duplicando tutti i dati su due insiemi indipendenti di dischi
  - come prima, il sistema è basato su striping, ma questa volta uno strip viene scritto su due dischi diversi
  - il costo per unità di memorizzazione raddoppia

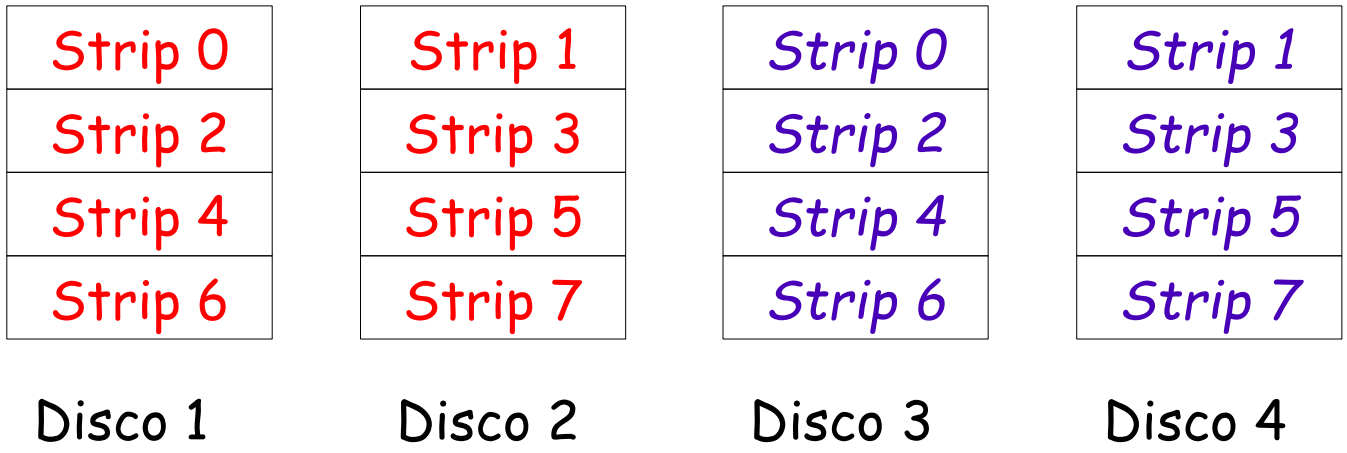

RAID 1 (mirroring)

- **Performance di RAID 1**
  - una richiesta di lettura può essere servita da uno qualsiasi dei dischi che ospitano il dato
    - può essere scelto quello con tempo di seek minore
  - una richiesta di scrittura può essere servita da uno qualsiasi dei dischi che ospitano il dato
    - dipende dal disco con tempo di seek maggiore
- **Ridondanza di RAID 1**
  - il recovery è molto semplice;
    - se un disco si guasta, i dati sono accessibili dall'altro disco
    - è necessario sostituire il disco guasto e fare una copia del disco funzionante

RAID 2-3 (parallel access)

- **RAID level 2-3**
  - *accesso parallelo*
    - tutti i dischi partecipano all'esecuzione di ogni richiesta di I/O
  - i dischi sono sincronizzati in modo che le testine di lettura siano nella stessa posizione allo stesso istante
  - si utilizza data striping, con gli strip molto piccoli (byte, word)
  - i dischi vengono suddivisi fra *dischi dati* e *dischi parità*
    - un codice di correzione di errore o di parità viene calcolato a partire dai bit corrispondenti dei dischi dati
    - questo codice viene memorizzato nei dischi parità

RAID 2-3

- **RAID level 2**
  - il codice calcolato è basato sul codice di Hamming
  - il numero di dischi di parità è dato dal logaritmo del numero di dischi di dati
  - permette di correggere errori fino a un bit (e di rilevare errori fino a due bit)
  - non molto utilizzato, perchè utile solo in ambienti con un alto numero di errori di disco

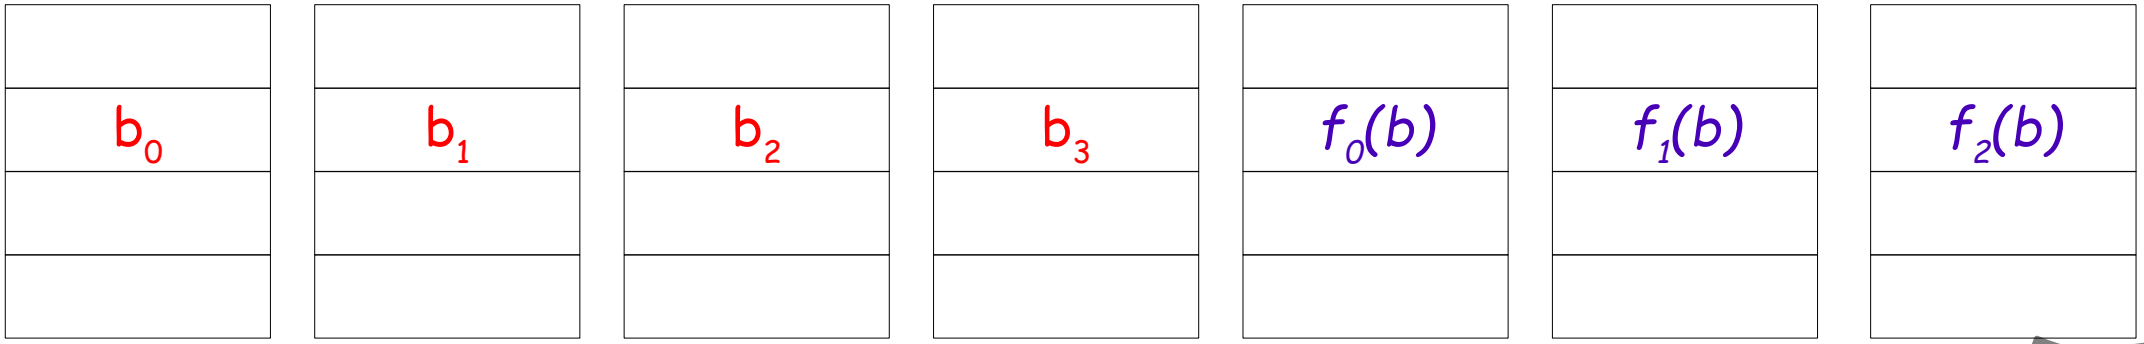

RAID 2-3

- **RAID level 3**
  - il codice calcolato è un semplice bit di parità
  - è richiesto un solo disco di parità

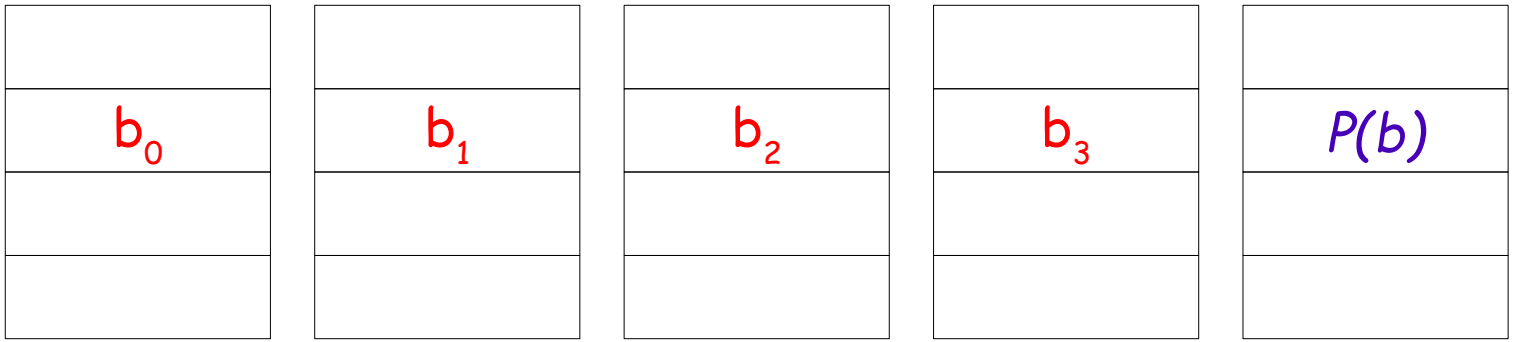

RAID 2-3

- **Ridondanza di RAID 3**
  - supponiamo di avere quattro dischi dati (numerati 0-3) e un disco di parità (numerato 4)
  - la parità per il quarto disco è calcolata nel modo seguente
    - $b_4(i) = b_0(i) \oplus b_1(i) \oplus b_2(i) \oplus b_3(i)$
  - nel caso di guasto di un disco (diciamo il disco 1), è possibile calcolare il valore corrispondente utilizzando il disco di parità
    - $b_1(i) = b_0(i) \oplus b_4(i) \oplus b_2(i) \oplus b_3(i)$
- **In caso di guasto**
  - il sistema è in modalità "ridotta"
  - bisogna sostituire il disco e rigenerare i dati mancanti

RAID 2-3

- **Performance di RAID 2-3**
  - sono più adatti per sistemi che richiedono alte velocità di trasferimento dati
    - i dati sono "striped" in quantità molto piccole
    - il sistema può raggiungere alte velocità di trasferimento dati, leggendo/scrivendo su tutti i dischi contemporaneamente
  - poiché ogni lettura coinvolge tutti i dischi, RAID 2-3 non sono adatti per sistemi con un grande numero di richieste di I/O indipendenti

RAID 4-6

- **RAID level 4-6**
  - *accesso indipendente*
    - ogni disco opera in modo indipendente, in modo che richieste indipendenti possano essere accedute in parallelo
  - come in RAID 3, si utilizza un disco di parità
- **Performance**
  - sono più adatti per sistemi con un gran numero di richieste indipendenti
  - un po' meno adatti per sistemi che richiedono il trasferimento di grandi quantità di dati

RAID 4

- **Descrizione**
  - si utilizza il meccanismo di data striping, con strip relativamente grandi
  - strip di parità
    - viene calcolato uno strip di parità, a partire dagli strip di dati corrispondenti, calcolato bit-per-bit
    - lo strip di parità viene posto sul disco di parità

Disco 1	Disco 2	Disco 3	Disco 4	Disco 5
Strip 0	Strip 1	Strip 2	Strip 3	P(0-3)
Strip 4	Strip 5	Strip 6	Strip 7	P(4-7)
Strip 8	Strip 9	Strip 10	Strip 11	P(8-11)
Strip 12	Strip 13	Strip 14	Strip 15	P(12-16)

RAID 4

- **Lettura (in assenza di guasti)**
  - si individua lo strip corrispondente e si effettua la lettura dello strip
- **Lettura (in presenza di guasti)**
  - si individua lo strip corrispondente; se il disco corrispondente è guasto, si effettua la lettura di tutti gli strip rimasti e tramite il disco di parità di ottiene lo strip mancante
- **Scrittura (in assenza di guasti)**
  - quanti strip devono essere coinvolti?
  - a prima vista, si direbbe tutti (lo strip dati da scrivere, tutti gli altri strip da leggere, lo strip di parità in scrittura)

RAID 4

- **Scrittura (in assenza di guasti)**
  - in realtà, ne bastano 3
  - spiegazione
    - supponiamo che si voglia cambiare lo strip 1; il calcolo da effettuare è questo

      $$S'_4(i) = S_0(i) \oplus S'_1(i) \oplus S_2(i) \oplus S_3(i)$$

      dove $S'_1(i)$ è il nuovo valore dello strip da scrivere, e $S'_4(i)$ è il nuovo valore dello strip di parità da scrivere
    - possiamo scrivere

      $$S'_4(i) = S_0(i) \oplus S'_1(i) \oplus S_1(i) \oplus S_1(i) \oplus S_2(i) \oplus S_3(i)$$

      $$S'_4(i) = S_4(i) \oplus S'_1(i) \oplus S_1(i)$$

RAID 5

- **Descrizione**
  - come RAID 4, ma i blocchi di parità sono sparsi fra i vari dischi
  - il vantaggio è che non esiste un disco di parità che diventa un bottleneck

RAID 6

- **Descrizione**
  - come RAID 5, ma si utilizzano due strip di parità invece di uno
  - aumenta l'affidabilità (è necessario il guasto di tre dischi affinchè i dati non siano utilizzabili)