# Sistemi Operativi Modulo I

Primo canale (A-L) e Teledidattica

A.A. 2021/2022

Corso di Laurea in Informatica

# La Gestione dell'Input/Output

Igor Melatti

Sapienza Università di Roma
Dipartimento di Informatica

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# Categorie per i Dispositivi di I/O

- Area assai problematica per la progettazione di sistemi operativi
  - c'è una grande varietà di dispositivi di I/O
  - e anche una grande varietà di applicazioni che li usano
  - difficile scrivere un SO che tenga conto di tutto
- Tre categorie di dispositivi
  - leggibili dall'utente
  - leggibili dalla macchina
  - dispositivi di comunicazione

# Dispositivi Leggibili dall'Utente

- Dispositivi usati per la comunicazione diretta con l'utente
  - stampanti
  - "terminali": ovvero monitor + tastiera (+ mouse)
    - da non confondere con i "terminali" software, ovvero applicazioni sulle quali è possibile invocare una shell
    - per "shell" si intende un'applicazione che permette di effettuare syscall in maniera interattiva
    - ad esempio, per esplorare il filesystem
  - joystick
  - ...

# Dispositivi Leggibili dalla Macchina

- Dispositivi usati per la comunicazione con materiale elettronico
  - dischi
  - chiavi USB
  - sensori
  - controllori
  - attuatori

# Dispositivi per la Comunicazione

- Dispositivi usati per la comunicazione con dispositivi remoti
  - modem
  - schede Ethernet
  - Wi-Fi

# Funzionamento (Semplificato) dei Dispositivi di I/O

- Un dispositivo di input prevede di essere interrogato sul valore di una certa grandezza fisica al suo interno
  - tastiera: codice Unicode degli ultimi tasti premuti
  - mouse: coordinate dell'ultimo spostamento effettuato, quali tasti sono stati premuti
  - disco: valore dei bit che si trovano in una certa posizione al suo interno
- Un processo che effettua una syscall `read` su un dispositivo del genere vuole conoscere questo dato
  - per poterlo ovviamente elaborare: il processo che gestisce un editor, una volta saputo quale tasto è stato premuto sulla tastiera, può fare l'echo del carattere corrispondente

# Funzionamento (Semplificato) dei Dispositivi di I/O

- Un dispositivo di output prevede di poter cambiare il valore di una certa grandezza fisica al suo interno
  - monitor moderno: valore RGB di tutti i suoi pixel
    - o anche solo di quelli che cambiano rispetto alla situazione immediatamente precedente
  - stampante moderna: PDF o PS di un file da stampare
  - disco: valore dei bit che devono sovrascrivere quelli che si trovano in una certa posizione al suo interno
- Un processo che effettua una syscall `write` su un dispositivo del genere vuole cambiare qualcosa
  - spesso l'effetto è direttamente visibile all'utente (monitor, stampante)
  - in altre occasioni l'effetto è visibile solo usando altre funzionalità di lettura (disco)

# Funzionamento (Semplificato) dei Dispositivi di I/O

- Ci sono quindi, minimalmente, due syscall `read` e `write`
  - tra i loro argomenti c'è un identificativo del dispositivo da leggere o scrivere
  - per esempio, Unix e Linux hanno i *file descriptor*
- Entra in gioco il kernel, che comanda l'inizializzazione del trasferimento di informazioni, mette il processo in blocked e passa ad altro
  - la parte del kernel che gestisce un particolare dispositivo di I/O è chiamata *driver*
  - spesso il trasferimento si fa con DMA
- A trasferimento completato, arriva l'interrupt, si termina l'operazione e il processo ritorna ready
  - l'operazione potrebbe anche fallire (bad block su disco...)
  - potrebbe anche necessario fare ulteriori trasferimenti, per esempio dalla RAM dedicata al DMA a quella del processo

# Differenze tra Dispositivi di I/O

- I dispositivi di I/O possono differire sotto molti aspetti
  - data rate (frequenza di accettazione/emissione di dati)
  - applicazione
  - difficoltà nel controllo (tastiera vs. disco...)
  - unità di trasferimento dati (caratteri vs. blocchi)
  - rappresentazione dei dati
  - condizioni di errore

# Data Rate

Differenze anche molto elevate

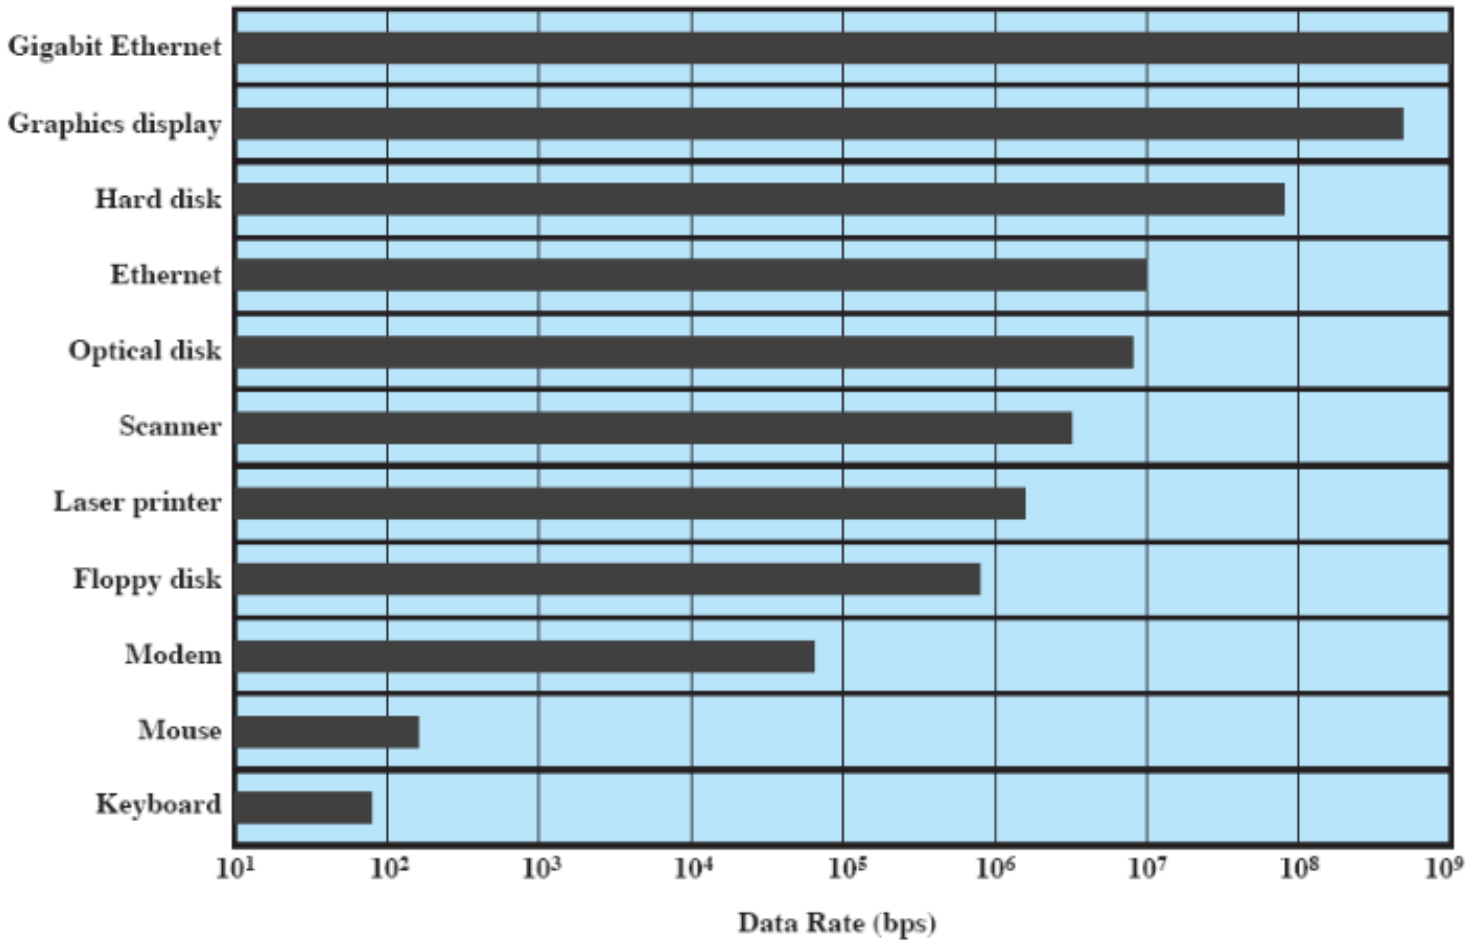

# Applicazioni

- I dischi sono usati per memorizzare files, richiedono un software per la gestione dei file
- I dischi sono usati anche per la memoria virtuale, per la quale serve altro software apposito (nonché hardware)
- Un terminale usato da un amministratore di sistema dovrebbe avere una priorità più alta

# Complessità del Controllo

- Una tastiera o un mouse richiedono un controllo molto semplice
- Una stampante è più complicata, ma non troppo
  - alle stampanti moderne basta ricevere un PDF o un PS
  - la traduzione da PDF ad azioni della stampante è ovviamente complessa
- Il disco è tra le cose più complicate da controllare
- Fortunatamente, non si fa tutto col software, e molte cose vengono controllate da hardware dedicato

# Unità di Trasferimento Dati

- I dati possono essere trasferiti (dal dispositivo che li genera alla memoria o viceversa):
  - in blocchi di byte di lunghezza fissa
    - usato per la memoria secondaria: dischi, chiavi USB, CD/DVD, ...
  - come un flusso (*stream*) di byte, o equivalentemente di caratteri
    - qualsiasi cosa *non* sia memoria secondaria: terminali, stampanti, schede audio (sia input che output), dispositivi di comunicazione di rete, ...

# Rappresentazione dei Dati

- I dati sono rappresentati secondo codifiche diverse in dispositivi diversi
  - una vecchia tastiera magari li rappresenta in ASCII puro, una moderna con l'UNICODE
- Possono essere diversi anche i controlli di parità

# Condizioni d'Errore

- La natura degli errori varia di molto da dispositivo a dispositivo
- Ad esempio:
  - nel modo in cui gli errori vengono notificati
  - sulle loro conseguenze (fatali/ignorabili)
  - su come possono essere gestiti

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# Tecniche per Effettuare l'I/O

- Programmato
- Guidato dagli interrupt
- Accesso diretto in memoria (DMA)

| | **Senza Interruzioni** | **Con Interruzioni** |
|---|---|---|
| **Passando per la CPU** | I/O programmato | I/O guidato dalle interruzioni |
| **Direttam. in memoria** | | DMA |

# Direct Memory Access

- Il processore delega le operazioni di I/O al modulo DMA
- Il modulo DMA trasferisce i dati direttamente da o verso la memoria principale
- Quando l'operazione è completata, il modulo DMA genera un interrupt per il processore

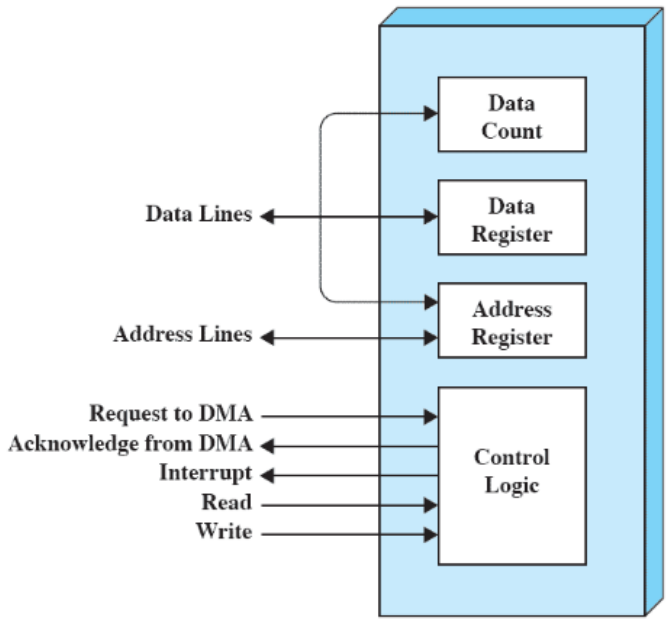

# Evoluzione della Funzione di I/O

1. Il processore controlla il dispositivo periferico
2. Viene aggiunto un modulo (o controllore) di I/O, direttamente sul dispositivo
   - I/O programmato, senza interrupt
   - ma il processore non si deve occupare di alcuni dettagli del dispositivo stesso
3. Modulo o controllore di I/O con interrupt
   - migliora l'efficienza del processore, che non deve aspettare il completamento dell'operazione di I/O

# Evoluzione della Funzione di I/O

4. DMA
   - blocchi di dati viaggiano tra dispositivo e memoria, senza usare il processore
   - il processore fa qualcosa solo all'inizio e alla fine di un'operazione di I/O
5. Il modulo di I/O diventa un processore separato (*I/O channel*)
   - il processore "principale" comanda al processore di I/O di eseguire un certo programma di I/O in memoria principale
6. Processore per l'I/O (*I/O processor* o anche *I/O channel*)
   - ha una sua memoria dedicata
   - usato per le comunicazioni con terminali interattivi

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# Obiettivo: Efficienza

- La maggior parte dei dispositivi di I/O sono molto lenti rispetto alla memoria principale
- Grazie alla multiprogrammazione, alcuni processi potrebbero essere in attesa del completamento di un'operazione di I/O mentre altri processi sono in esecuzione
- Ma l'I/O potrebbe comunque non tenere il passo con il processore
  - quindi il numero di processi ready si riduce fino a diventare zero
  - si potrebbe pensare che sia sufficiente portare altri processi ready ma sospesi in memoria principale (medium-term scheduler)
  - ma anche questa è un'operazione di I/O
- Necessario quindi cercare soluzioni software dedicate, a livello di SO, per l'I/O
  - in particolare, per il disco

# Obiettivo: Generalità

- Per semplicità e per evitare errori, sarebbe bene gestire i dispositivi di I/O, pur nella loro diversità, in modo uniforme
- Nascondere la maggior parte dei dettagli dei dispositivi di I/O nelle procedure di basso livello
- Progettare le funzioni di I/O in modo modulare e gerarchico (anche se è difficile farlo in modo generale)
- Funzionalità da offrire: read, write, lock, unlock, open, close, ...
    - leggere da tastiera o da mouse sono cose molto diverse, ma il SO può farle sembrare uguali o quasi

# Progettazione Gerarchica

- Simile al concetto di gerarchia nel progetto di un sistema operativo: insieme di livelli
- Ogni livello si basa sul fatto che il livello sottostante sa effettuare operazioni più primitive
- Ogni livello fornisce servizi al livello superiore
- Ogni livello contiene funzionalità simili per complessità, tempi di esecuzione, livello di astrazione
- Modificare l'implementazione di un livello non dovrebbe avere effetti sugli altri livelli
- Per l'I/O, ci sono 3 macrotipi maggiormente usati

# Dispositivo Locale

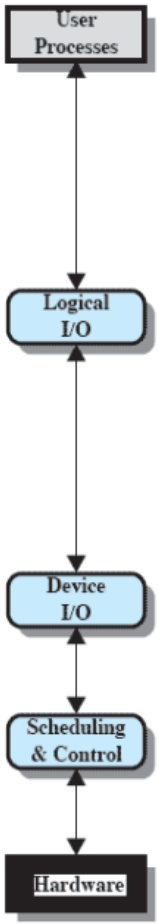


- Esempi: stampante, monitor, tastiera, ...
- Logical I/O: il dispositivo viene visto come una risorsa logica (open, close, read, ...)
- Device I/O: trasforma richieste logiche in sequenze di comandi di I/O
- Scheduling and Control: esegue e controlla le sequenze di comandi, eventualmente gestendo l'accodamento

# Dispositivo di Comunicazione


- Esempi: scheda Ethernet, WiFi, ...
- Come prima, ma al posto del logical I/O c'è una architettura di comunicazione: il dispositivo viene visto come una risorsa logica
- A sua volta, questa consiste in un certo numero di livelli
- Es.: TCP/IP

# File System


- Esempi: disco HDD o SDD, scheda di memoria SSD, CD, DVD, floppy disk, USB key ...
- Directory Management: da nomi di file a identificatori di file; tutte le operazioni utente che hanno a che fare con i file (crearli, cancellarli, spostarli, ...)
- File System: struttura logica ed operazioni (apri, chiudi, leggi, scrivi, ...)
- Organizzazione fisica: da identificatori di file a indirizzi fisici su disco; allocazione/deallocazione

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# Buffering dell'I/O

- Nell'attesa del completamento di un'operazione di I/O, alcune pagine devono rimanere in memoria principale per evitare il deadlock
  - un processo richiede un I/O su una certa sua zona di memoria (DMA), ma viene subito swappato (quindi sospeso)
  - per poter essere completata, la richiesta di I/O necessita che il processo sia riportato in memoria
  - ma per essere riportato in memoria, la richiesta di I/O dovrebbe essere completata...
- Risolvibile con il frame blocking, ma si limita il numero di pagine swappabili, e le prestazioni del SO potrebbero decrescere
- Altra possibile soluzione: *buffering*
  - può essere più efficiente effettuare trasferimenti di input in anticipo e di output in ritardo rispetto alle richieste

# Senza Buffer

Il SO accede al dispositivo nel momento in cui ne ha necessità

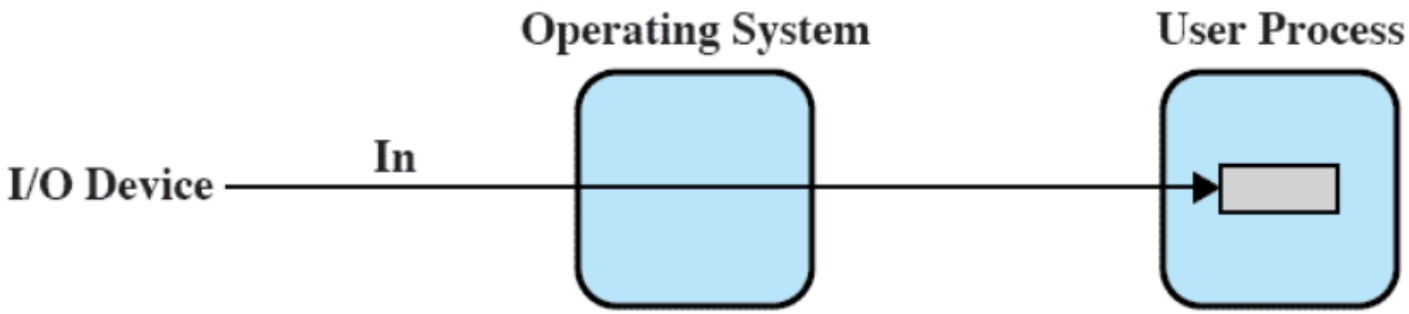

# Buffer Singolo

Il SO crea un buffer in memoria principale (system space, non user space!) per una data richiesta di I/O

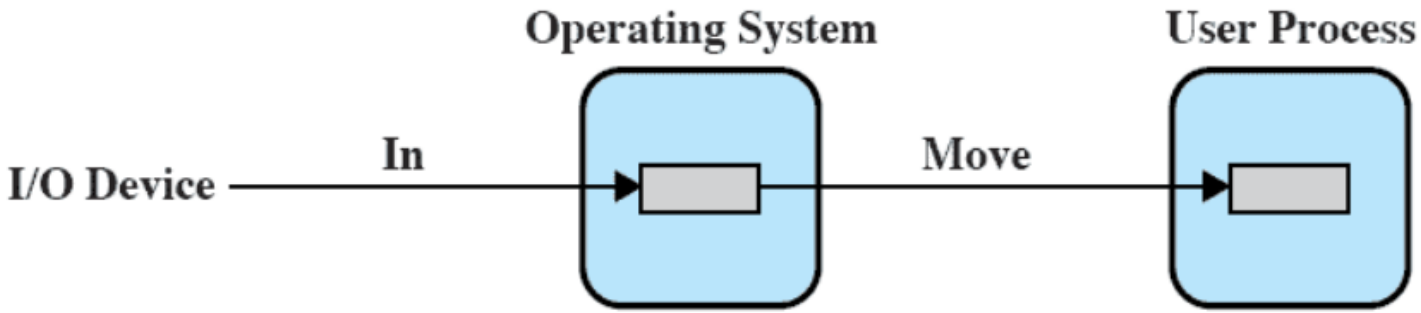

# Buffer Singolo Orientato ai Blocchi

- I trasferimenti di input sono fatti al buffer in system memory
- Blocco viene mandato nello spazio utente quando necessario
- Il prossimo blocco viene comunque letto nel buffer
  - input anticipato (*anticipated input*), o lettura in anticipo (*read ahead*)
  - i dati, solitamente, sono acceduti sequenzialmente: c'è buona probabilità che servirà, e sarà già stato letto
- L'output, invece, viene posticipato
  - per questo serve la system call `flush`...

# Buffer Singolo Orientato agli Stream

- I terminali tipicamente hanno a che fare con linee (caratteri più Invio)
- Quindi, si bufferizza una linea intera di input o di output
- Un byte alla volta per i device in cui un singolo carattere premuto va gestito
  - anche per sensori e controllori
  - in pratica, è un'istanza di un ben noto problema di concorrenza: il produttore/consumatore

# Buffer Doppio

Due buffer anziché uno: un processo può trasferire dati da o a uno dei buffer, mentre il SO svuota o riempie l'altro

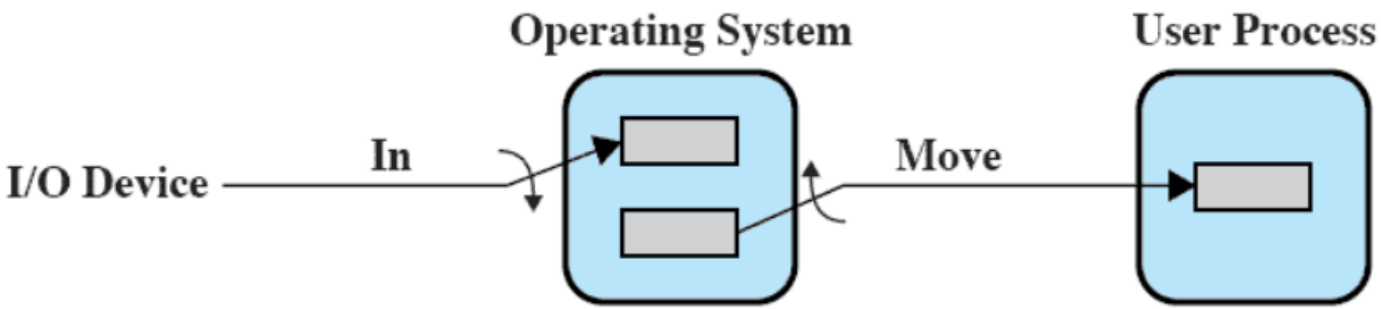

# Buffer Circolare

- Più di 2 buffer
- Ciascun buffer è un'unità di buffer circolare
- Usato quando l'operazione di I/O deve tenere il passo del processo
- Di nuovo: è proprio il produttore/consumatore!

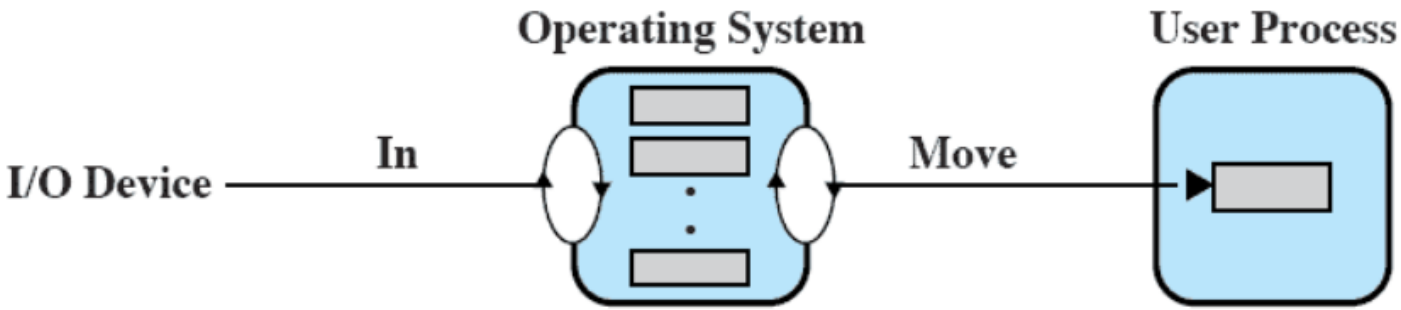

# Buffer: Pro e Contro

- Il buffering smussa i picchi di richieste di I/O
  - ma se la domanda è molta, i buffer si riempiono e il vantaggio si perde
- Utile soprattutto quando ci sono molti e vari dispositivi di I/O da servire
  - migliora l'efficienza dei processi e del SO

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# HDD vs SSD

- Quello che diremo vale per gli hard drive disk (HDD), non per i solid state disk (SSD)
- Gli SSD hanno problemi diversi, che noi non tratteremo

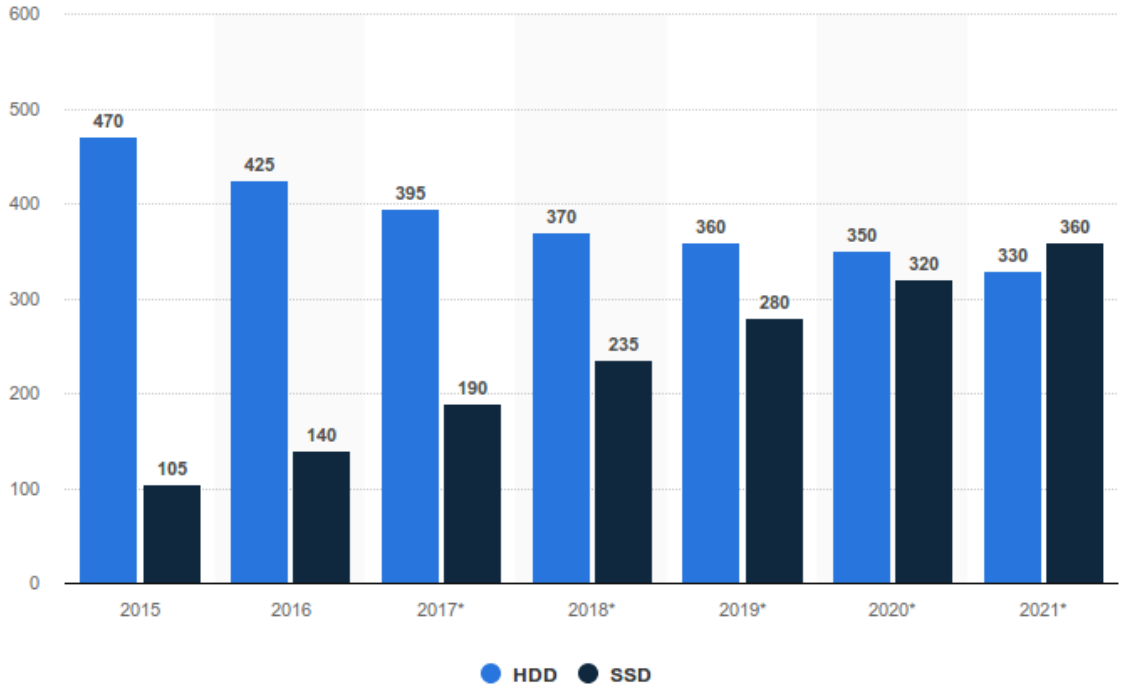

# Il Disco

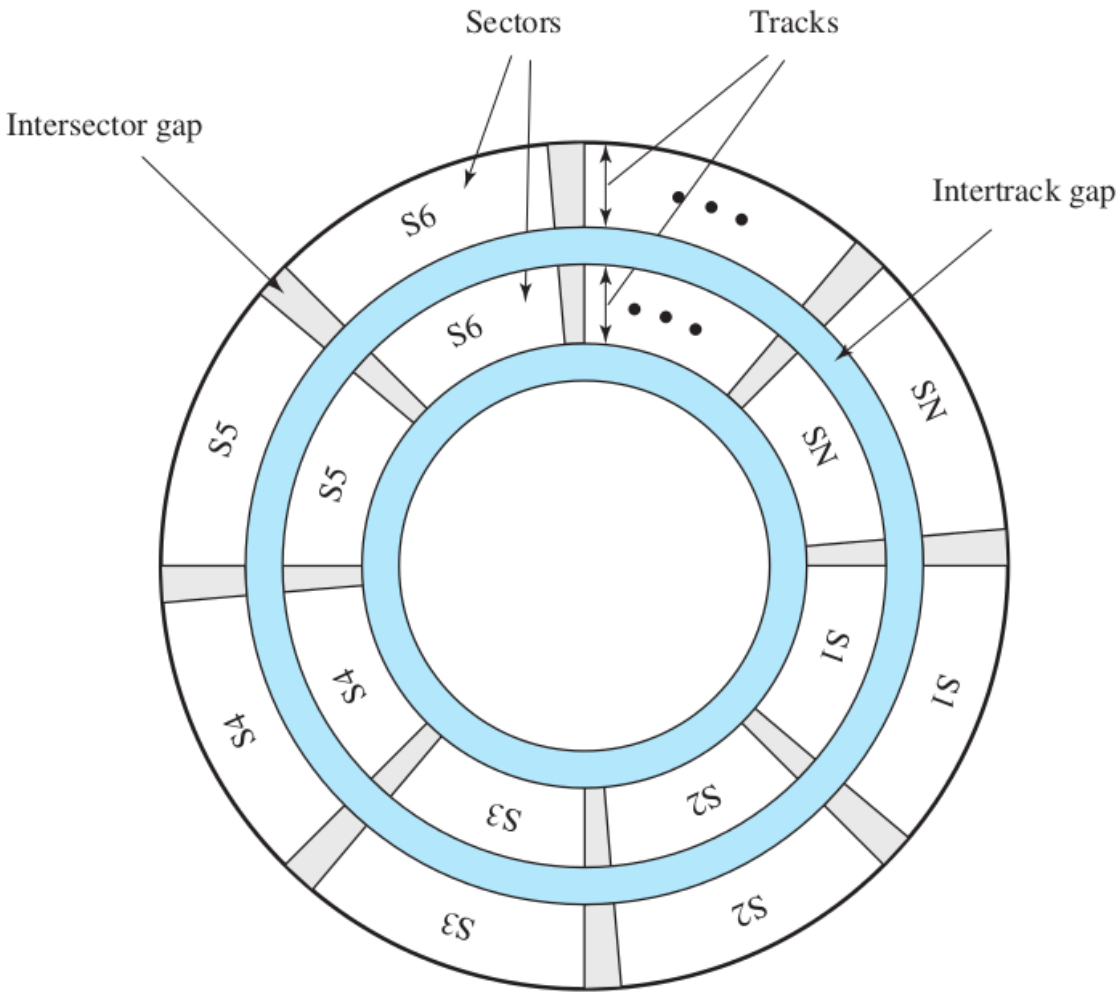
Sectors
Tracks
Intersector gap
Intertrack gap
S6
S5
S4
S3
S2
S1
N5

# Come Funziona un Disco

- I dati si trovano sulle tracce (corone concentriche)
  - su un certo insieme di settori
- Quindi per leggere/scrivere occorre sapere su quale traccia si trovano i dati
  - e sulla traccia, su quale settore
- Per selezionare una traccia bisogna:
  - spostare una testina, se il disco ha testine mobili
  - selezionare una testina, se il disco ha testine fisse
- Per selezionare un settore su una traccia bisogna aspettare che il disco ruoti (a velocità costante)
- Se i dati sono tanti, potrebbero essere su più settori o addirittura su più tracce
  - tipica misura di un settore: 512 bytes

# Prestazioni del Disco

- Un'operazione su disco dipende da molti dettagli
- La linea temporale generale può essere riassunta come segue

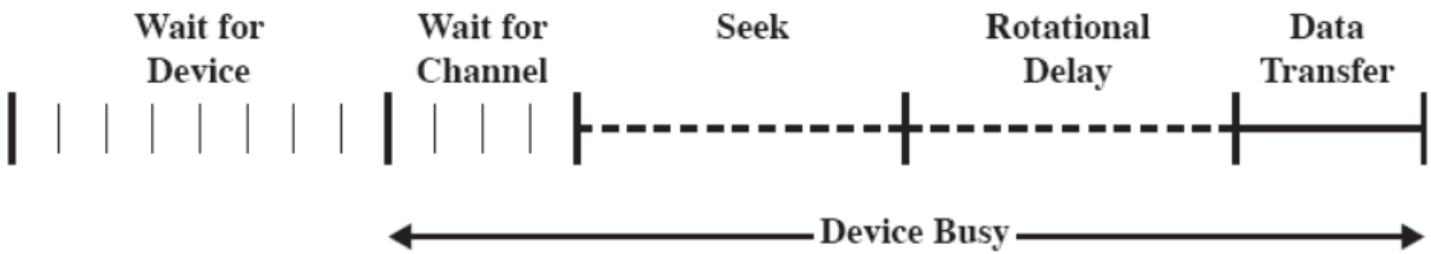

# Prestazioni del Disco

Tempo di accesso (*access time*) che è la somma di:

Tempo di posizionamento (*seek time*): tempo necessario perché la testina si posizioni sulla traccia desiderata

Ritardo di rotazione (*rotational delay* o *latency*): tempo necessario affinché l'inizio del settore raggiunga la testina

Tempo di trasferimento (*transfer time*) tempo necessario a trasferire i dati che scorrono sotto la testina

A parte:

- *wait for device*: attesa che il dispositivo sia assegnato alla richiesta
- *wait for channel*: attesa che il sottodispositivo sia assegnato alla richiesta
  - se ci sono più dischi che condividono un unico canale di comunicazione

# Politiche di Scheduling per il Disco

- Le confronteremo su un esempio comune
- All'inizio, la testina si trova sulla traccia numero 100
- Ci sono 200 tracce
- Vengono richieste le seguenti tracce nel seguente ordine:

$$55, 58, 39, 18, 90, 160, 150, 38, 184$$

- Considereremo solo il seek time, che è il parametro più importante per le prestazioni
- Confronto con il random, che è lo scheduling peggiore

# FIFO

- Le richieste sono servite in modo sequenziale
- Equo nei confronti dei processi
- Se ci sono molti processi in esecuzione, le prestazioni sono simili allo scheduling random

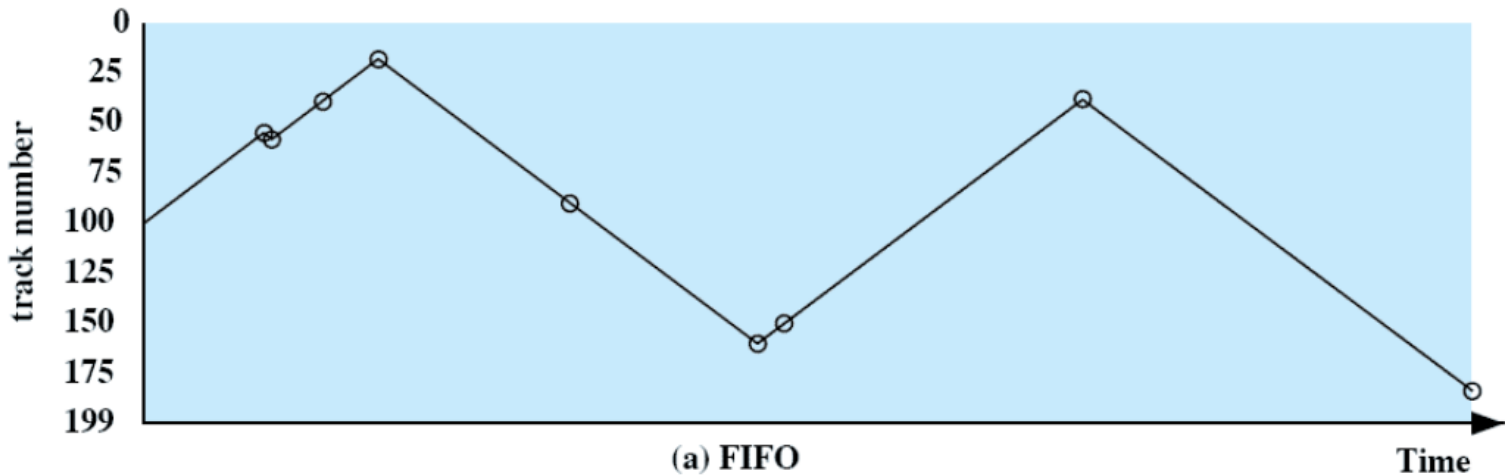

# Priorità

- L'obiettivo non è ottimizzare il disco, ma raggiungere altri obiettivi
- I processi batch corti potrebbero avere priorità più alta
- È desiderabile fornire un buon tempo di risposta ai processi interattivi
- Ma i processi più lunghi potrebbero dover aspettare troppo
- Non va bene per i DBMS
- Impossibile fare il grafico: bisognerebbe sapere, per ogni richiesta, qual è la priorità del processo che l'ha fatta

# LIFO

- Ottimo per DBMS con transazioni
- Il dispositivo è dato all'utente più recente
- Possibile la starvation
- Impossibile fare il grafico: bisognerebbe sapere, per ogni richiesta, a quale utente appartiene
- Motivazioni: se si tratta dello stesso utente, probabilmente sta accedendo sequenzialmente ad un file
  - quindi, è più efficiente mandare avanti lui

# Minimo Tempo di Servizio

- Da qui in poi, occorre conoscere la posizione della testina
- Sceglie la richiesta che minimizza il movimento del braccio (dalla posizione attuale)
- Quindi sceglie sempre il tempo di posizionamento minore
  - ovviamente, rispetto alle richieste attualmente pervenute
- Possibile la starvation delle richieste: arrivano continuamente richieste più vicine

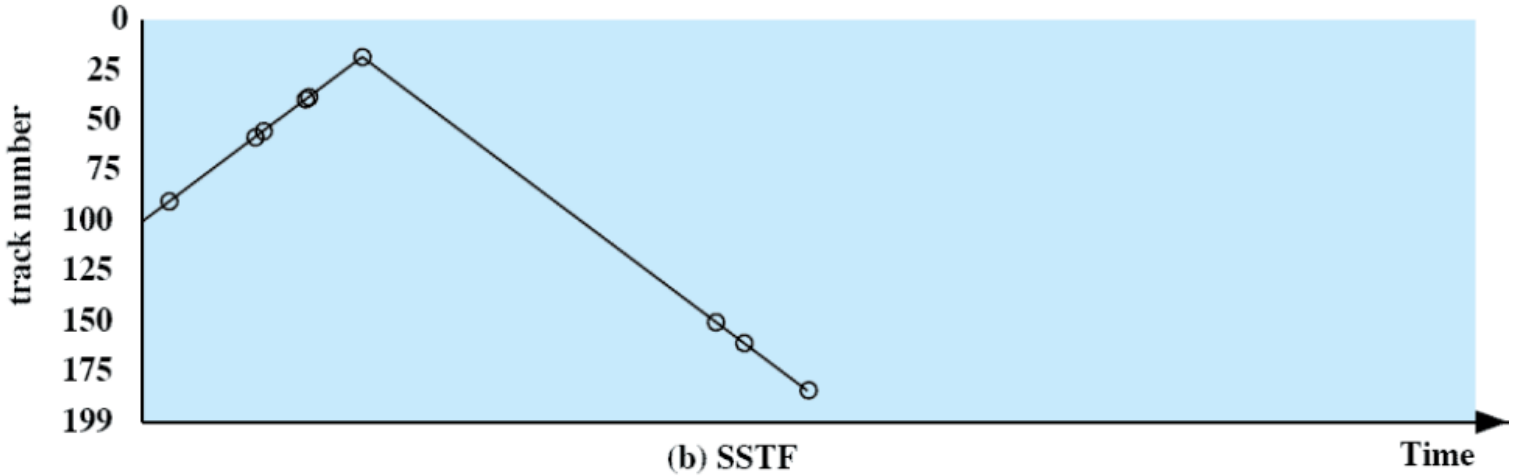

(b) SSTF

# SCAN

- Si scelgono le richieste in modo tale che il braccio si muova sempre in un verso, e poi torni indietro
- Niente starvation delle richieste, ma è poco "fair":
  - favorisce le richieste ai bordi (attraversati 2 volte in poco tempo...) $\rightarrow$ C-SCAN
  - favorisce le richieste appena arrivate $\rightarrow$ N-step-SCAN
    - nel senso che, se ben piazzate rispetto alla testina, possono precedere richieste che attendono da molto

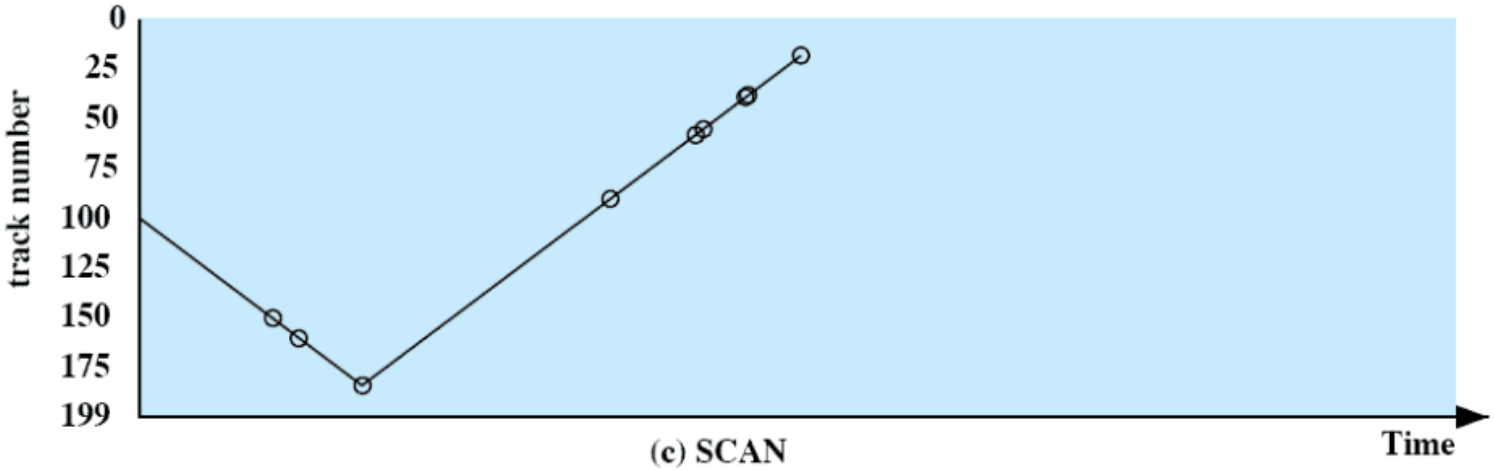

# C-SCAN

- Come SCAN, ma niente marcia indietro
- O meglio, nella marcia indietro non si scelgono richieste
- Quindi i bordi non sono più visitati 2 volte in poco tempo

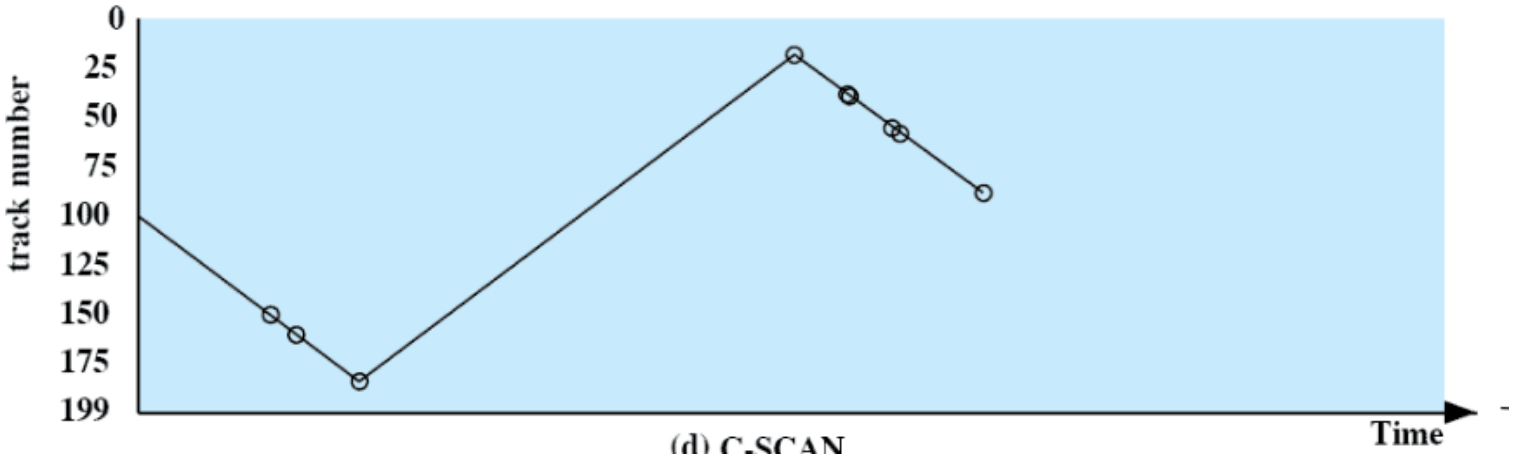

# FSCAN

- Due code anziché una
- Quando SCAN inizia, tutte le richieste sono nella coda $F$, e l'altra coda $R$ è vuota
- Mentre SCAN serve tutta $F$, ogni nuova richiesta è aggiunta ad $R$
- Quando SCAN finisce di servire $F$, si scambiano $F$ ed $R$
- Ogni nuova richiesta deve aspettare che tutte le precedenti vengano servite
- Quindi le richieste vecchie non sono sopravanzate come in SCAN

# N-step-SCAN

- Generalizzazione di FSCAN a $N > 2$ code
- Si accodano le richieste nella coda $i$-esima finché non si riempie; poi si passa alla $(i + 1)$ mod $N$
- Non sono mai aggiunte a quella attualmente servita
- Se $N$ è alto, le prestazioni sono quelle di SCAN (ma con fairness)
- Se $N = 1$, allora si usa il FIFO per evitare di essere unfair

# Confronto Prestazionale

| (a) FIFO (starting at track 100) | | (b) SSTF (starting at track 100) | | (c) SCAN (starting at track 100, in the direction of increasing track number) | | (d) C-SCAN (starting at track 100, in the direction of increasing track number) | |
|---|---|---|---|---|---|---|---|
| **Next track accessed** | **Number of tracks traversed** | **Next track accessed** | **Number of tracks traversed** | **Next track accessed** | **Number of tracks traversed** | **Next track accessed** | **Number of tracks traversed** |
| 55 | 45 | 90 | 10 | 150 | 50 | 150 | 50 |
| 58 | 3 | 58 | 32 | 160 | 10 | 160 | 10 |
| 39 | 19 | 55 | 3 | 184 | 24 | 184 | 24 |
| 18 | 21 | 39 | 16 | 90 | 94 | 18 | 166 |
| 90 | 72 | 38 | 1 | 58 | 32 | 38 | 20 |
| 160 | 70 | 18 | 20 | 55 | 3 | 39 | 1 |
| 150 | 10 | 150 | 132 | 39 | 16 | 55 | 16 |
| 38 | 112 | 160 | 10 | 38 | 1 | 58 | 3 |
| 184 | 146 | 184 | 24 | 18 | 20 | 90 | 32 |
| **Average seek length** | 55.3 | **Average seek length** | 27.5 | **Average seek length** | 27.8 | **Average seek length** | 35.8 |

# Prospetto

| Algoritmo | Descrizione | Note |
|---|---|---|
| **Selezione a cura del richiedente** | | |
| RSS | Scheduling random | Solo per simulazioni e confronti |
| FIFO | A coda semplice | Il più equo |
| LIFO | Ultimo utente | A sorpresa, può andare bene |
| PRI | Priorità del processo | Se la priorità è importante |
| **Selezione sulla base del dato richiesto** | | |
| SSTF | Tempo di servizio più corto | Alto uso del disco, piccole code |
| SCAN | Avanti ed indietro sul disco | Miglior distribuzione del servizio |
| C-SCAN | Avanti, con ritorno veloce | Minore variabilità di servizio |
| N-step-SCAN | SCAN su $N$ richieste | Garanzia del servizio |
| FSCAN | N-step-SCAN con due code | Tiene conto del carico |

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# Cache del Disco

- È un buffer in memoria principale, usato per i settori del disco
- Contiene una copia di alcuni settori del disco
- Quando si fa una richiesta di I/O per dati che si trovano su un certo settore, si vede prima se tale settore è nella cache
- Se non c'è, il settore letto viene anche copiato nella cache
- Ci sono svariati metodi per gestire questa cache
- Spesso chiamata *page cache*; da non confondere con la cache spesso presente direttamente sui dischi
  - quest'ultima è hardware e quindi trasparente per il sistema operativo
  - `https://en.wikipedia.org/wiki/Page_cache`

# Usato Meno di Recente (LRU)

- Se occorre rimpiazzare qualche settore nella cache piena, si prende quello nella cache da più tempo senza referenze
- La cache viene puntata da uno "stack" di puntatori
  - quello riferito più di frequente è alla cima dello stack
  - quindi, ogni volta che un settore viene referenziato o copiato nella cache, il suo puntatore viene portato in cima allo stack
  - non è un vero stack, perché non è acceduto usando solo push, pop e top

# Usato Meno di Frequente (LFU)

- Si rimpiazza il settore con meno referenze
- Ovviamente, serve un contatore per ogni settore
  - incrementato ad ogni riferimento
  - inizialmente 1
  - si sceglie il settore col contatore minimo
- Sembra più sensato di LRU: meno vieni usato, meno servi
- Ma la località potrebbe avere un effetto curioso:
  - un settore viene acceduto svariate volte di fila, perché contiene dati acceduti secondo il principio di località
  - dopodiché, non serve più
  - a questo punto, ha un valore abbastanza alto, ma andrebbe invece sostituito

# Sostituzione Basata su Frequenza

- C'è uno "stack" di puntatori, come nell'LRU
  - quando un blocco viene referenziato, lo si sposta all'inizio dello stack
- Ma è spezzato in 2: una parte nuova e una vecchia
  - come LFU, si incrementa un contatore ad ogni riferimento, ma solo se si è nella parte vecchia
  - e si sceglie il blocco con contatore minimo *che sia nella parte vecchia*
    - in caso di parità, quello più recente
  - si passa dalla parte nuova alla vecchia per scorrimento: quando un blocco vecchio viene riferito e diventa nuovo, spinge l'ultimo dei nuovi a diventare primo dei vecchi
- Ancora non ci siamo:
  - se non c'è *presto* un riferimento ad un blocco, questo potrebbe essere sostituito solo perché è appena arrivato nella parte vecchia
  - ma magari serviva, i riferimenti sarebbero arrivati di lì a poco

# Sostituzione Basata su Frequenza: 3 Segmenti

- Nuovo
  - unica parte dove i contatori non vengono incrementati
  - non eleggibile per rimpiazzamento
- Medio
  - i contatori vengono incrementati, ma ancora non eleggibile per il rimpiazzamento
- Vecchio
  - i contatori vengono incrementati e i blocchi sono eleggibili per il rimpiazzamento
- Risolve i problemi visti sopra

# Sostituzione Basata su Frequenza

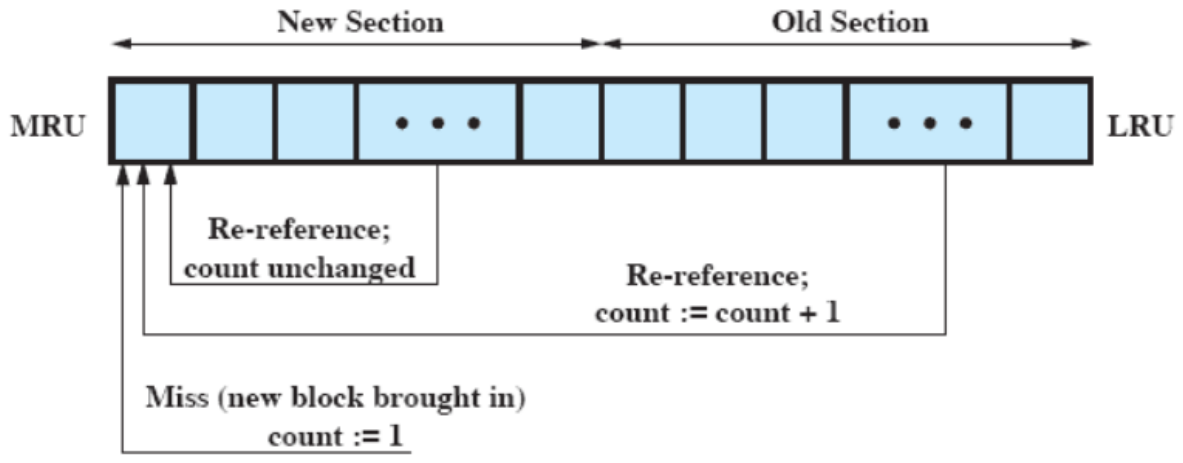


(a) FIFO

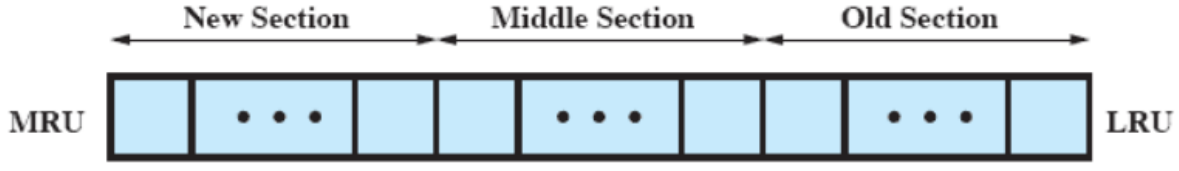


(b) Use of three sections

# Prestazioni della Cache del Disco

LRU

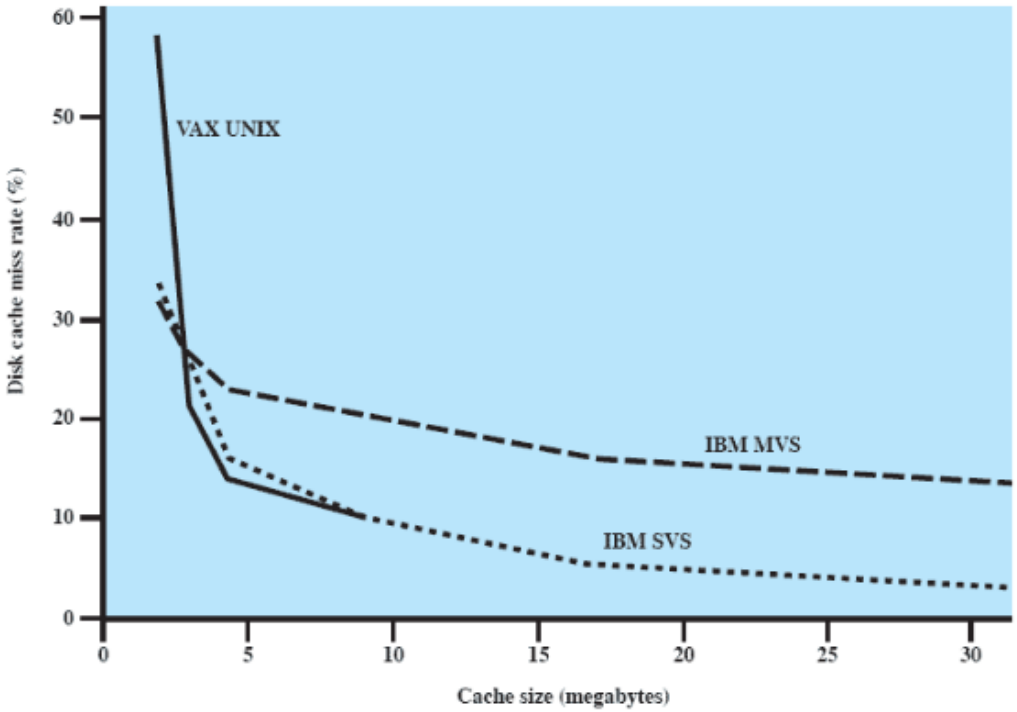


LFU

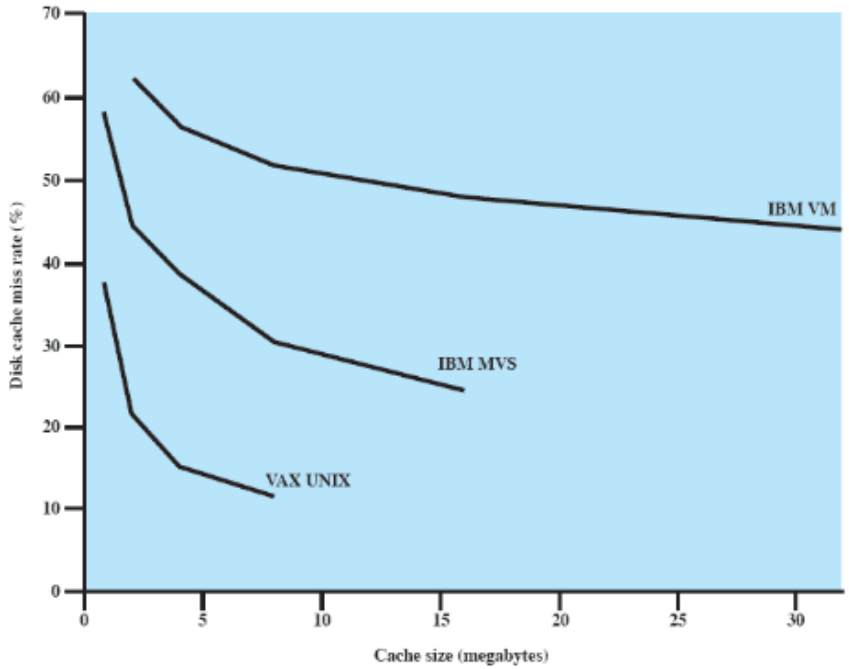


LRU meglio perché sono studi diversi: se la sequenza è la stessa, viene meglio LFU

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# Dischi RAID

- Redundant array of independent disks
- In alcuni casi, si hanno a disposizione più dischi fisici
- È possibile trattarli separatamente
  - per esempio, Windows li mostrerebbe esplicitamente come dischi diversi, con etichette diverse
  - in Linux, si potrebbe dire che alcune directory sono in un disco, altre su un altro
  - si specifica all'inizio e poi non ci si pensa più
- Oppure, si possono considerare diversi dischi fisici come un unico disco

# Dischi multipli

- Possibilità ovvia: Linux LVM (Logical Volume Manager)
  - alcuni files/directory sono memorizzati su un disco, altri su un altro
  - ci pensa una parte del kernel, l'LVM appunto
  - tipicamente, è un modulo di quelli da aggiungere
  - l'utente può non occuparsi di decidere dove salvare i file
  - con la tecnica del mount si directory diverse, potrebbe succedere che una directory cresca fino a riempire il relativo disco, mentre l'altra resta vuota
  - l'LVM è fatto apposta per tenere conto di questo problema

# Dischi RAID

- L'LVM va bene per pochi dischi, ed in generale se non si è interessati alla ridondanza
  - un dato è ridondante se è memorizzato (uguale) su diversi dispositivi
  - se si rompe un disco, posso comunque prendere quel dato dall'altro disco
  - ovviamente, modifiche al file su un disco vanno propagate anche all'altro disco (o agli altri dischi)
- Allora RAID
  - non solo ridondanza: riesce anche a velocizzare alcune operazioni
- Esistono device composti da più dischi fisici gestiti da un RAID direttamente a livello di dispositivo
  - il sistema operativo fa solo read e write, ci penso il dispositivo stesso a gestire internamente il RAID

# Dischi RAID: la Gerarchia

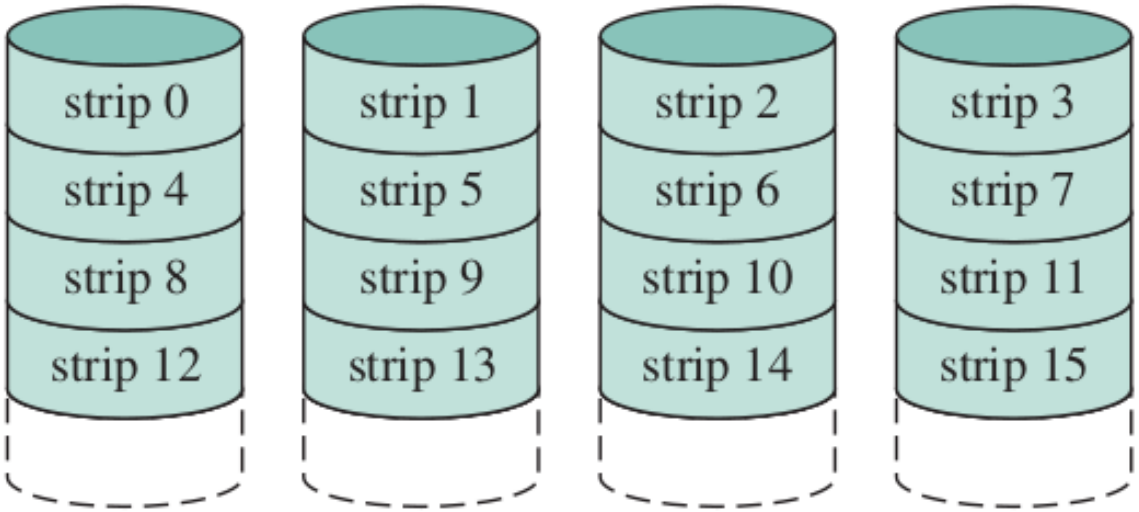


(a) RAID 0 (nonredundant)

- Dati distribuiti per maggiore efficienza nell'accesso: può essere parallelo
- Ogni *strip* contiene un certo numero di settori
- Un insieme di strips sui vari dischi (una riga) si chiama *stripe*

# Dischi RAID: la Gerarchia

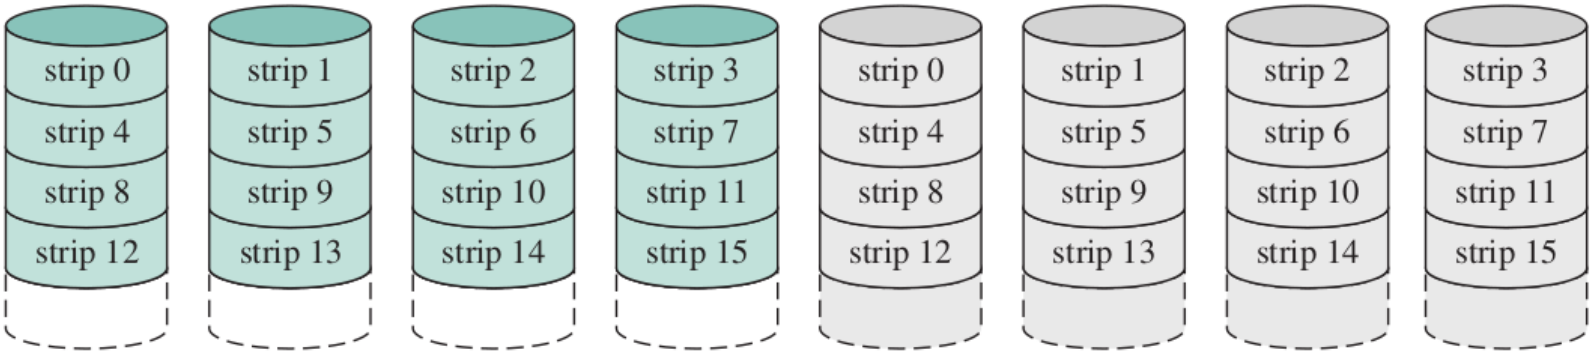


(b) RAID 1 (mirrored)

- Come RAID0, ma duplicando ogni dato
- Fisicamente si hanno $2N$, ma la capacità di memorizzazione è quella di $N$ dischi
- Se si rompe un disco, recupero sicuro
- Se se ne rompono due, dipende da quali si sono rotti...

# Dischi RAID: la Gerarchia (Non Usato)

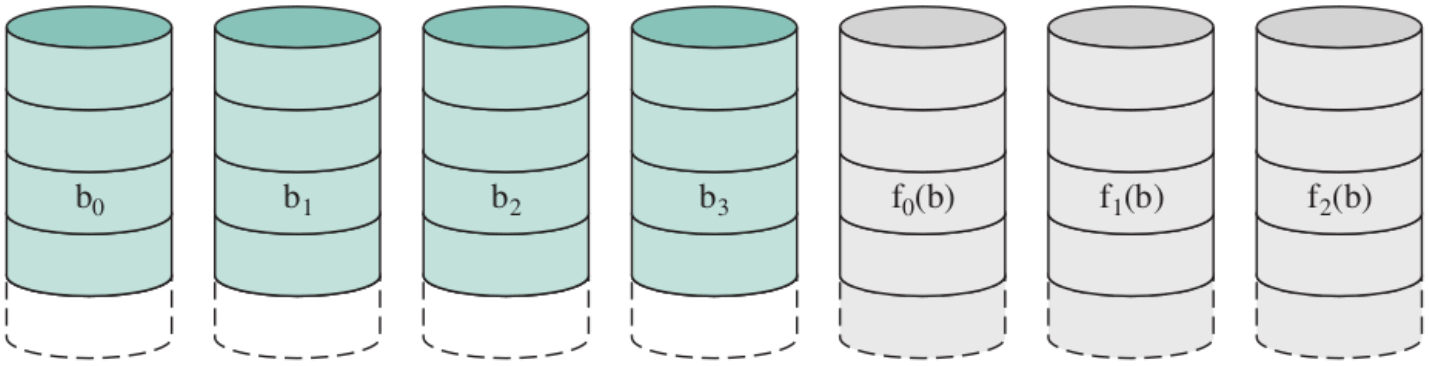


(c) RAID 2 (redundancy through Hamming code)

- Nei casi (rari!) in cui gli errori non sono il fallimento di un intero disco, ma magari il flip di qualche singolo bit...
- ... invece di replicare l'intera informazione, si usano codici particolari
  - per esempio, Hamming: può *correggere* errori su singoli bit e *rilevare* errori su 2 bit
- Non più $N$ dischi di overhead, ma tanti quanti servono per memorizzare il codice di Hamming: proporzionale al logaritmo della capacità dei dischi
- Praticamente non usato

# Dischi RAID: la Gerarchia (Non Usato)

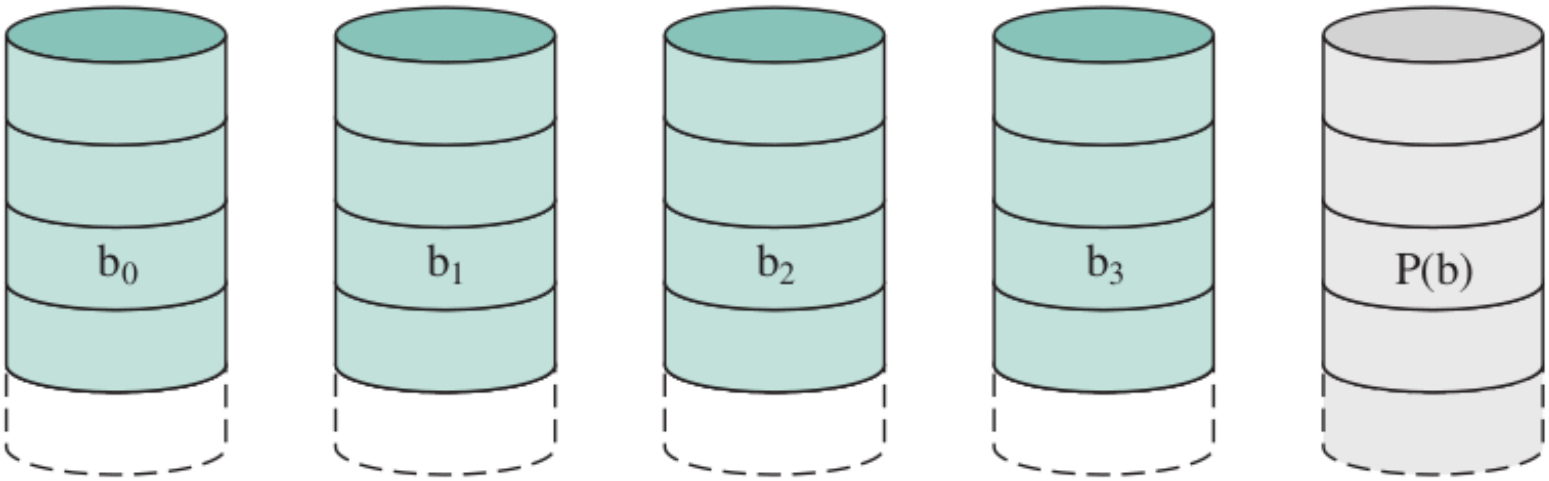


(d) RAID 3 (bit-interleaved parity)

- Un solo disco di overhead
- Memorizza, per ogni bit, la parità dei bit che hanno la stessa posizione
- Nonostante la semplicità, resta possibile recuperare i dati quando fallisce un unico disco
- Ogni strip è un byte
- E se muore proprio il disco di parità?

# Dischi RAID: la Gerarchia (Non Usato)

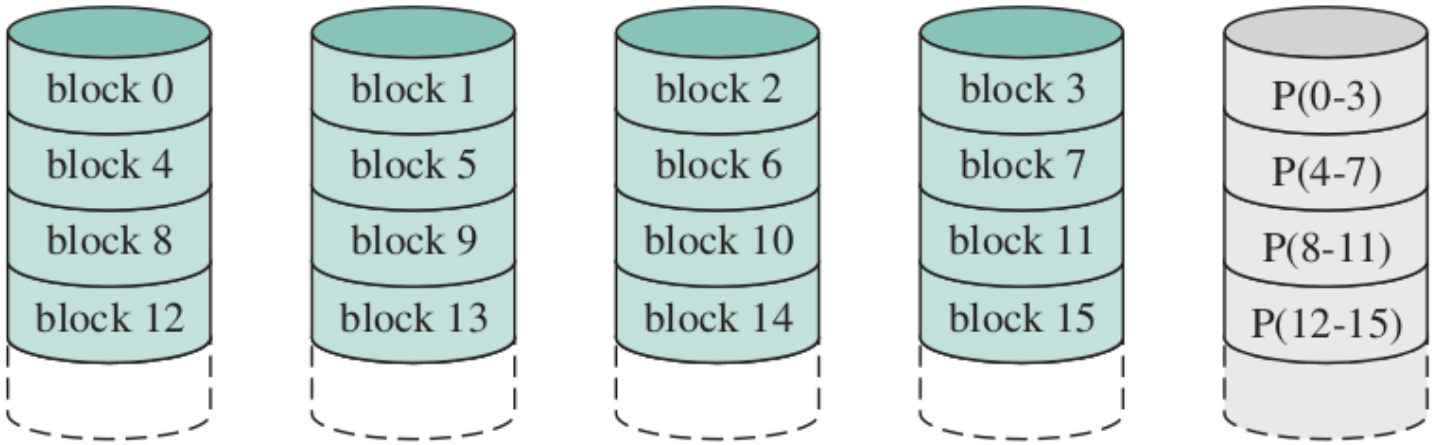


(e) RAID 4 (block-level parity)

- Come RAID3, ma ogni strip è un "blocco", potenzialmente grande
- Recuperabile in caso di fallimento di un unico disco
- Migliore parallellismo di RAID3, ma più complicato gestire piccole scritture

# Dischi RAID: la Gerarchia

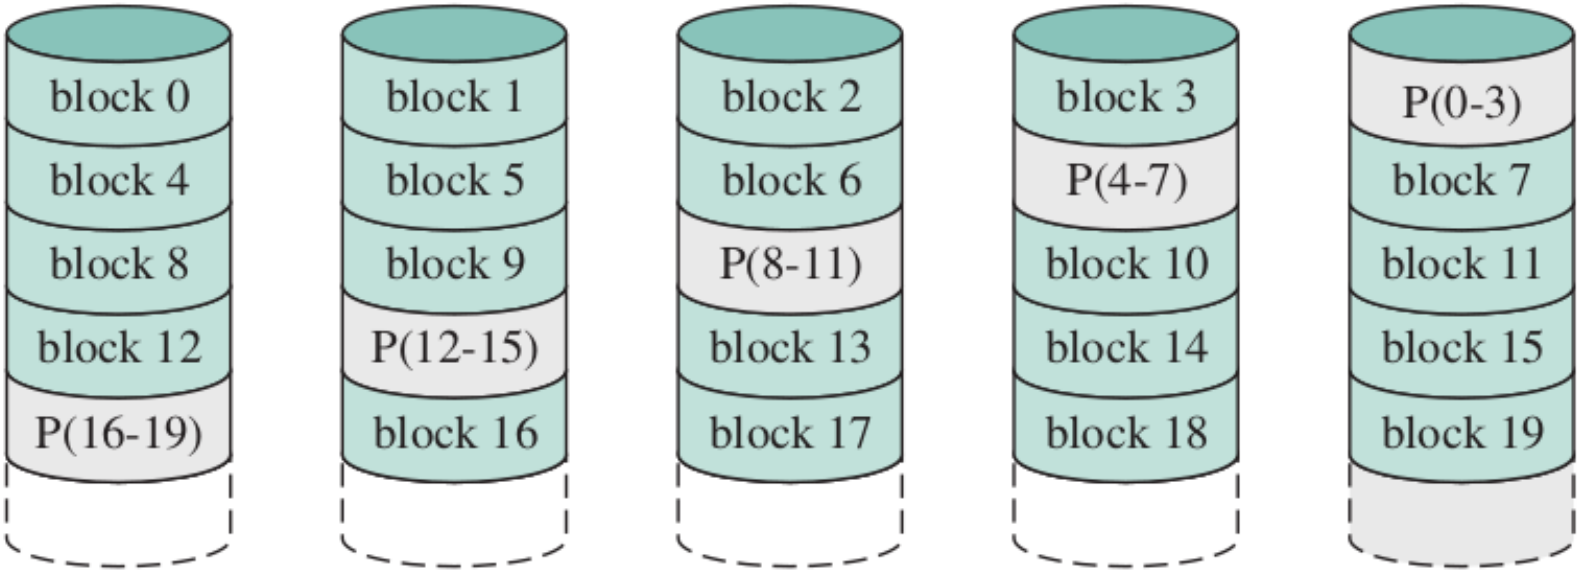


(f) RAID 5 (block-level distributed parity)

- Come RAID4, ma le informazioni di parità non sono tutte su un unico disco
- Evita il collo di bottiglia del disco di parità
  - nel RAID4, ogni scrittura ha effetto sul disco di parità
  - qui, invece, non c'è un disco "privilegiato"

# Dischi RAID: la Gerarchia

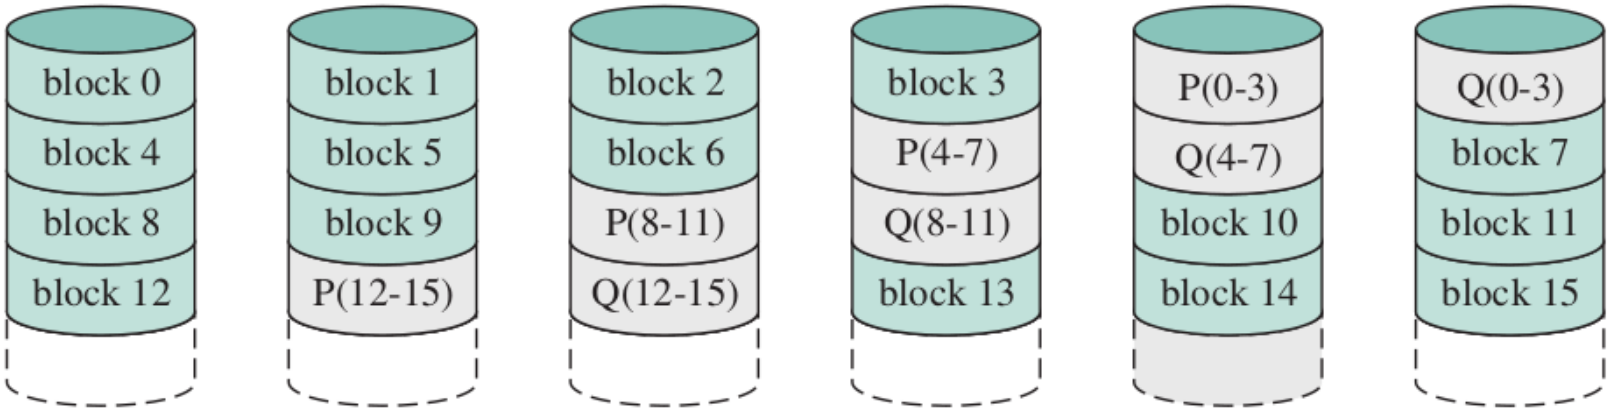


(g) RAID 6 (dual redundancy)

- Come RAID5, ma con 2 dischi di parità indipendenti
- Permette di recuperare anche 2 fallimenti di disco
- 30% di pensalità in più, rispetto a RAID5, per le operazioni di scrittura
- Per le operazioni di lettura, RAID5 e RAID6 si equivalgono

# Dischi RAID: Riassunto

**Table 11.4** RAID Levels

| Category | Level | Description | Disks Required | Data Availability | Large I/O Data Transfer Capacity | Small I/O Request Rate |
|---|---|---|---|---|---|---|
| Striping | 0 | Nonredundant | $N$ | Lower than single disk | Very high | Very high for both read and write |
| Mirroring | 1 | Mirrored | $2N$ | Higher than RAID 2, 3, 4, or 5; lower than RAID 6 | Higher than single disk for read; similar to single disk for write | Up to twice that of a single disk for read; similar to single disk for write |
| Parallel access | 2 | Redundant via Hamming code | $N + m$ | Much higher than single disk; comparable to RAID 3, 4, or 5 | Highest of all listed alternatives | Approximately twice that of a single disk |
| | 3 | Bit-interleaved parity | $N + 1$ | Much higher than single disk; comparable to RAID 2, 4, or 5 | Highest of all listed alternatives | Approximately twice that of a single disk |
| Independent access | 4 | Block-interleaved parity | $N + 1$ | Much higher than single disk; comparable to RAID 2, 3, or 5 | Similar to RAID 0 for read; significantly lower than single disk for write | Similar to RAID 0 for read; significantly lower than single disk for write |
| | 5 | Block-interleaved distributed parity | $N + 1$ | Much higher than single disk; comparable to RAID 2, 3, or 4 | Similar to RAID 0 for read; lower than single disk for write | Similar to RAID 0 for read; generally lower than single disk for write |
| | 6 | Block-interleaved dual distributed parity | $N + 2$ | Highest of all listed alternatives | Similar to RAID 0 for read; lower than RAID 5 for write | Similar to RAID 0 for read; significantly lower than RAID 5 for write |

Note: $N$, number of data disks; $m$, proportional to log $N$.

# Dischi RAID: Riassunto

- Parallel access: se faccio un'operazione sul RAID, tutti i dischi effettuano in sincrono quell'operazione
- Independent: un'operazione sul RAID è un'operazione su un sottoinsieme dei suoi dischi
  - permette il completamento in parallelo di richieste I/O *distinte*
- Data availability: capacità di recupero in caso di fallimento
- Small I/O request rate: velocità nel rispondere a piccole richiesto di I/O

# Roadmap

- Dispositivi di I/O
- Organizzazione della funzione di I/O
- Problemi nel progetto del sistema operativo
- Buffering dell'I/O
- Scheduling del disco
- Cache del disco
- RAID
- I/O in Linux

# Page Cache in Linux

- Unica page cache per tutti i trasferimenti tra disco e memoria
  - compresi quelli dovuti alla gestione della memoria virtuale (una sorta di page buffering)
- 2 vantaggi:
  - scritture condensate
  - sfruttando la località dei riferimenti, si risparmiano accessi a disco
- Scrittura su disco quando:
  - è rimasta poca memoria: una parte della page cache è ridestinata ad uso diretto dei processi
  - quando l'età delle pagine "sporche" va sopra una certa soglia
- Niente politica separata di replacement: è la stessa usata per il rimpiazzamento delle pagine
  - ovvero: la page cache è paginata, e le sue pagine sono rimpiazzate con l'algoritmo visto per la gestione della memoria