


La memoria secondaria





Obiettivi

- ❖ Descrivere la struttura fisica dei diversi dispositivi di memoria secondaria e l'effetto della struttura di un dispositivo sul suo utilizzo
- ❖ Analizzare le prestazioni dei dispositivi di archiviazione di massa
- ❖ Valutare gli algoritmi di scheduling del disco
- ❖ Discutere i servizi forniti dal sistema operativo per la memorizzazione di massa





Sommario


- ❖ Struttura dei dispositivi di memorizzazione
- ❖ Scheduling dei dischi rigidi e dei dispositivi NVM
- ❖ Rilevamento e correzione di errori
- ❖ Gestione delle unità di memoria secondaria
- ❖ Gestione dell'area di swap
- ❖ Connessione dei dispositivi di memoria
- ❖ Strutture RAID *più dischi usati insieme per prestazioni o ridondanza*





Memorie di massa e dispositivi di I/O

- ❖ I dispositivi collegati ad un calcolatore possono avere caratteristiche altamente variabili 1/6
- ❖ Rappresentano, nel loro insieme, la componente più lenta, voluminosa e variegata dell'elaboratore
- ❖ Il sistema operativo deve offrire alle applicazioni funzionalità che consentano l'accesso ai dispositivi mediante interfacce semplici e uniformi
- ❖ Deve inoltre garantire l'ottimizzazione dell'I/O, che costituisce il collo di bottiglia delle prestazioni del sistema di calcolo





Memorie di massa

- ❖ I dischi magnetici e i dispositivi di memoria non volatile (*nonvolatile memory*, **NVM**) costituiscono i supporti fondamentali di **memoria secondaria** nei computer attuali

- Dischi magnetici (HDD – Hard Disk)
- Dischi a stato solido (SSD – Solid State Disk)

- ❖ **Memorie terziarie**

- Un solo drive, molti dispositivi rimovibili
 - ▶ Pen drive, memory card (flash)
 - ▶ CD, DVD, Blu-ray
- Spazio di memorizzazione su cloud



hard disk esterni



dischi ottici



pen drive





memory card





Dischi magnetici


- ❖ I dischi magnetici rappresentano ancora oggi un mezzo diffuso per la memorizzazione di massa
 - Costituiti da piatti, con un diametro che varia tra 1.8 e 3.5 pollici, sono rivestiti con materiale magnetico (ossido di ferro) ed erano originariamente in alluminio
 - La tecnologia attuale, viceversa, è orientata all'utilizzo del vetro: *→ non sensibile agli urti, rispetto all'alluminio sottile*
 - ▶ Superficie più uniforme ⇒ maggiore affidabilità (errori di lettura/scrittura meno frequenti)
 - ▶ Più rigido
 - ▶ Più resistente agli urti
 - ▶ Permette di ridurre la distanza della testina dalla superficie






Dischi magnetici – Nomenclatura

- ❖ **Piatto** – ^{ogni sup del disco e scrivibile} un disco rigido si compone di uno o più dischi paralleli, in cui ogni superficie, detta "piatto" e identificata da un numero univoco, è destinata alla memorizzazione dei dati
- ❖ **Traccia** – su ogni piatto, vi sono numerosi ^{tracce concentriche} anelli concentrici, detti tracce, ciascuno identificato da un numero univoco.
- ❖ **Cilindro** – ^{insieme di tutte le tracce equidistanti} l'insieme di tracce poste alla stessa distanza dal centro e relative a tutti i dischi; corrisponde a tutte le tracce con lo stesso numero, ma giacenti su piatti diversi
- ❖ **Settore** – ^{→ rag. che spiega traccia settore circolare} ogni traccia è suddivisa in settori circolari, ovvero in "spicchi" uguali, ciascuno identificato da un numero univoco (4KB) ^{la stessa quantità di info}
- ❖ **Blocco** – ^{rpm fissa: legge 8000 info 5 sec vicino a cilindro} l'insieme dei settori posti nella stessa posizione in tutti i piatti
- ❖ **Testina** – su ogni piatto è presente una testina di lettura/scrittura; la posizione di tale testina è solidale con tutte le altre sui diversi piatti (le testine sono attaccate al braccio del disco): se una testina è posizionata sopra una traccia, tutte le testine saranno posizionate sul cilindro a cui la traccia appartiene





Dischi magnetici – Nomenclatura




Migliaia di cilindri concentrici costituiti da tracce che contengono centinaia di settori


arm assembly
Testo di Teste
Sono attaccato
al mio
braccio
con un ciclo
per
Testo un
cilindro



Il settore è l'unità minima di trasferimento; originariamente costituito da 512 byte, dal 2010, la dimensione standard è 4KB




Contiene e altro





Dischi magnetici – Accesso


- ❖ I dischi ruotano ad una velocità compresa tra i 60 e i 250 giri al secondo
 - La velocità di trasferimento è la velocità con cui i dati fluiscono dall'unità a disco alla RAM (proporzionale alla velocità di rotazione)
 - Il tempo di posizionamento è il tempo necessario a spostare il braccio del disco in corrispondenza del cilindro desiderato (*seek time*), più il tempo necessario affinché il settore desiderato si porti sotto la testina (*latenza di rotazione*)
 - Il crollo della testina, normalmente sospesa su un cuscinetto d'aria di pochi micron (10^{-6} m), corrisponde all'impatto della stessa sulla superficie del disco
 - ▶ Di solito comporta la necessità di sostituire l'unità a disco
- ❖ I dischi possono essere rimovibili





Dischi magnetici – Lettura/Scrittura

- ❖ Memorizzazione e recupero dell'informazione tramite bobina conduttiva detta **testina** (head)
 - Durante la lettura/scrittura, la testina è stazionaria, mentre il disco ruota
 - **Scrittura**
 - ▶ la corrente, che fluisce nella bobina (nelle due possibili direzioni) produce un campo magnetico
 - ▶ le particelle aciculari dell'ossido di ferro si orientano in base al campo magnetico prodotto (0 e 1 memorizzati su disco)
 - **Lettura**
 - ▶ Il campo magnetico presente sul disco, muovendosi rispetto alla testina, induce corrente nella bobina
 - Lettura/scrittura sequenziale 60–250 MB/sec





Caratteristiche degli hard disk

- ❖ Il raggio dei piatti variava, storicamente, fra 14 e 85 pollici
- ❖ I formati attualmente più comuni sono 3.5", 2.5", e 1.8" *raggio dei piatti*
- ❖ La capacità standard dei dischi (interni) si attesta fra 500GB e 20TB (fino a 30TB entro la fine dell'anno)

❖ Performance

- Velocità di trasferimento (teorica): 6Gb/sec
- Velocità di trasferimento (effettiva): 1Gb/sec
- Seek time compreso fra 3msec e 12msec (9msec in media per i dischi presenti nei PC) *Tempo di movimento della testina meccanica*

- Tempo di latenza calcolato in base alla velocità di rotazione

Rotazione per giro

$$\triangleright 1 / (\text{RPM} / 60) = 60 / \text{RPM}$$

- Latenza media = $\frac{1}{2}$ giro

tempo per cui il

disco percorre un giro, è una media, per trovare il dato

Velocità di rotazione [rpm]	Latenza media [msec]
15000	2
10000	3
7200	4.16
5400	5.55
4800	6.25

60 / rpm

Tempo di un giro = Latenza



Prestazioni degli hard disk

❖ Tempo di accesso medio = seek time medio + latenza media

- Per i dischi più veloci $\Rightarrow 3\text{msec} + 2\text{msec} = 5\text{msec}$
- Per dischi lenti $\Rightarrow 9\text{msec} + 5.55\text{msec} = 14.55\text{msec}$

*Tempo trasferito
basandosi rispetto
al primario*

❖ Tempo medio di I/O = tempo medio di accesso + quantità di dati da trasferire/velocità di trasferimento + overhead

❖ Per esempio, per trasferire un blocco da 4KB su un disco con una velocità di rotazione pari a 7200 RPM, tempo medio di ricerca pari a 5msec, velocità di trasferimento di 1Gb/sec e con un overhead dovuto al controllore di 0.1msec, si ottiene:

- Tempo di trasferimento = $4\text{KB}/1\text{Gb/s} = 0.031\text{ msec}$
- Tempo medio di I/O per un blocco da 4KB
 $= \text{Seek} + \text{latenza: disco, 7200 RPM} + 0.1\text{msec} + \text{tempo di trasferimento}$
 $= 5\text{msec} + 4.16\text{msec} + 0.1\text{msec} + \text{tempo di trasferimento}$
 $= 9.26\text{msec} + 0.031\text{msec} \approx 9.3\text{msec}$

*di più anche
della velocità di
rotazione del disco*

*meglio avere
pagine grandi...*

3 ordini di grandezza
nel caso di disco con velocità di rotazione pari a 7200 RPM
l'indietro su cui leggere e scrivere

e modo R/W





Il primo hard disk commerciale

Lettera e scrittura in RAM? Tipo, quanto è la velocità, locazione collegato al tipo di sistema? al computer e CPU



1956

Il computer IBM 305 RAMAC – che occupava una stanza di 9m×15m – includeva il primo disco magnetico nella storia dei calcolatori

5Mbit...


- 5 milioni di caratteri da 7 bit più parità
- 50 dischi da 24"
- Tempo di accesso circa 600 msec





Dispositivi di memoria non volatile – 1

- ❖ Spesso inseriti in chassis simili agli HDD, e perciò denominati dischi a stato solido (SSD), sono costituiti da un controllore e da diversi chip di memoria NAND flash
- ❖ Altre forme includono unità USB (pen drive, unità flash) e DRAM dotate di batteria di backup
- ❖ Negli smartphone, le NVM sono montate sulla scheda madre e rappresentano il dispositivo primario di archiviazione
- ❖ Le NVM possono essere più affidabili degli HDD
- ❖ Hanno costo al MB più elevato
- ❖ Possono avere vita più breve *non si possono sovrascrivere*
- ❖ Sono molto più veloci e consumano meno energia
 - Nessuna parte meccanica in movimento, quindi nessun tempo di ricerca o latenza di rotazione e maggiore resistenza a sollecitazioni e urti (minor rumore e minore dispersione termica)






Dispositivi di memoria non volatile – 2

- ❖ Le caratteristiche dei semiconduttori **NAND** aprono a nuove sfide per l'affidabilità
- ❖ Letture e scritture con granularità di "pagina" (analogo del settore)

sfide di memorie NAND



- settori: ■ Impossibilità di cancellazione per "sovra-scrittura"
ROSSO solo cancellare tutto il BLOCCO
- Il contenuto della pagina deve prima essere cancellato e le cancellazioni avvengono per "blocchi" (della dimensione di blocco e diverse pagine) ⇒ operazione costosa
cancell. blocco e settori
- Le NAND si deteriorano ad ogni ciclo di cancellazione e dopo un dato numero di cicli (dipendente dal particolare supporto), le celle non sono più in grado di mantenere l'informazione
- Durata misurata in numero di scritture al giorno (DWPD, *Drive Writes per Day*)
 - ▶ Su una NAND da 1 TB di classe 5DWPD si possono scrivere 5 TB al giorno senza errori per il periodo di garanzia

Blocco HD






Dispositivi di memoria non volatile – 3

- ❖ Algoritmi di gestione ottimizzata — attuati per arginare l'usura — implementati dal controllore ^{SSD} e non di competenza del SO
- ❖ Il sistema operativo "si limita" a leggere e scrivere blocchi logici, mentre è il controller che si occupa dell'effettiva realizzazione delle operazioni

a livello di SO può solo ottimizzare il tempo di seek,
minimizzare movimento della Testina.

File e Metadati di una Filesystem. la voglio più vicina possibile







Memorie flash

- ❖ Sono memorie a stato solido (EEPROM)
 - In una memoria flash le informazioni vengono registrate in un array di **Floating Gate MOSFET**, una tipologia di transistor in grado di mantenere la carica elettrica per un tempo lungo
 - ▶ Ogni transistor costituisce una “cella di memoria” che conserva il valore di un bit
 - ▶ Le flash attuali utilizzano celle multilivello che permettono di registrare il valore di più bit in un solo transistor


Types of NAND Flash Memory





NAND flash – 1

- ❖ Senza sovrascrittura, i blocchi sono costituiti da un mix di pagine valide e non valide
- ❖ Per tenere traccia dei blocchi logici validi, il controllore mantiene la tabella **FTL** (*Flash Translation Layer*) per le celle da essere morte
- ❖ Implementa anche la garbage collection per liberare spazio
 - Per cancellare dati non validi, un controller SSD di norma deve prima copiare tutti i dati validi (quelli che dovranno essere ancora utilizzati in futuro) nelle pagine vuote di un altro blocco
 - Quindi deve cancellare tutte le celle del blocco da liberare (eliminando sia i dati da cancellare che quelli copiati per poter essere successivamente riutilizzati) e solo a quel punto può iniziare a scrivere nuovi dati nel blocco che è stato così liberato





NAND flash – 2

*utente vede 80-83% della memoria usata
come se fosse per gestione cancellazioni*

- ❖ Normalmente, si mantiene un **overprovisioning** (7–20% di pagine) per fornire spazio di lavoro per la garbage collection
- ❖ Ogni cella ha durata di vita limitata, quindi il livello di usura deve essere mantenuto uniforme
 - L'overprovisioning è anche funzionale a garantire un numero adeguato di celle sostituibili a quelle che raggiungono il limite del ciclo di programmazione e cancellazione, così da prolungare la vita dello stesso SSD

*Sceglie consente
di consumare blocchi
memoria allo stesso
modo*

valid page	valid page	invalid page	invalid page
invalid page	valid page	invalid page	valid page

Blocco NAND con pagine valide e non valide






Memoria volatile

- ❖ DRAM usata frequentemente come dispositivo di archiviazione di massa *Ci similitudine sopra dei file system*
 - Tecnicamente, non si può definire archiviazione secondaria perché volatile, ma può contenere file system, da utilizzare come storage secondario molto veloce
- ❖ Infatti, le unità RAM possono essere utilizzate come dispositivi a blocchi non formattati, ma più spesso contengono un file system
 - Supportate dai principali sistemi operativi
 - ▶ Linux: **/dev/ram**, **/tmp** (con file system temporaneo)
 - ▶ MAC OS: **diskutil** (creazione di dischi RAM)

es BOOT LIMIT RAM FS temporaneo per caricare blocchi che contengono il SO





Nastri magnetici

Magnetic tape was used as an early secondary-storage medium. Although it is nonvolatile and can hold large quantities of data, its access time is slow compared with that of main memory and drives. In addition, random access to magnetic tape is about a thousand times slower than random access to HDDs and about a hundred thousand times slower than random access to SSDs so tapes are not very useful for secondary storage. Tapes are used mainly for backup, for storage of infrequently used information, and as a medium for transferring information from one system to another.

A tape is kept in a spool and is wound or rewound past a read–write head. Moving to the correct spot on a tape can take minutes, but once positioned, tape drives can read and write data at speeds comparable to HDDs. Tape capacities vary greatly, depending on the particular kind of tape drive, with current capacities exceeding several terabytes. Some tapes have built-in compression that can more than double the effective storage. Tapes and their drivers are usually categorized by width, including 4, 8, and 19 millimeters and 1/4 and 1/2 inch. Some are named according to technology, such as LTO-6 (Figure 11.5) and SDLT.




Figure 11.5 An LTO-6 Tape drive with tape cartridge inserted.





Connessione – 1

- ❖ L'unità a disco è connessa al calcolatore per mezzo del **bus di I/O**
 - Diversi tipi: ATA (Advanced Technology Attachment), **SATA** (Serial ATA), USB (Universal Serial Bus), SAS (Serial Attached SCSI), FC (Fiber Channel)
- ❖ I bus standard possono essere troppo lenti per gli SSD
 - Collegamento al bus PCI di sistema con tecnologia NVM express (NVMe)
- ❖ Il trasferimento di dati in un bus è eseguito da speciali unità di elaborazione, dette **controllori**: gli **adattatori** sono i controllori posti all'estremità del bus relativa al calcolatore, i controllori dei dischi sono incorporati in ciascuna unità a disco





Connessione – 2

- ❖ Per eseguire un'operazione di I/O, si inserisce il comando opportuno nell'adattatore, generalmente mediante porte di I/O mappate in memoria
- ❖ L'adattatore invia il comando al controllore del disco, che gestisce l'hardware dell'unità, per portare a termine il compito richiesto
- ❖ Il trasferimento dei dati nell'unità a disco avviene tra la superficie del disco e la cache incorporata nel controllore
TRASFERIMENTO DISK ↔ BUFFER CONTROLLER DISK ↔ DMA → RAM
- ❖ Il trasferimento verso l'host avviene, a velocità elevate, tramite DMA





Mappatura degli indirizzi – 1

*Memoria logica la vediamo come un vettore di blocchi
Diciamo che la granularità di blocco ci mette logicamente come
vettore di blocchi logici*

- ❖ Le unità a disco vengono indirizzate come giganteschi vettori monodimensionali di **blocchi logici**, dove il blocco logico rappresenta la minima unità di trasferimento *avvicinando meglio i vettori in uno spazio 3D*
 - I blocchi logici sono creati all'atto della formattazione di basso livello *Per identificare un oggetto, il settore, la traccia del cilindro, il cilindro*
- ❖ L'array di blocchi logici viene mappato sequenzialmente nei settori del disco o sulle pagine di un blocco di una NVM
- ❖ Per esempio:
 - Il settore 0 è il primo settore della prima traccia del cilindro più esterno
 - La corrispondenza prosegue ordinatamente lungo la prima traccia, quindi lungo le rimanenti tracce del primo cilindro, e così via, di cilindro in cilindro, dall'esterno verso l'interno
 - I settori danneggiati vengono esclusi dall'operazione di mappatura e sostituiti con settori di riserva collocati in altre parti della stessa unità





Mappatura degli indirizzi – 2

Indirizzo fisico del blocco

MAPP DA
(CILINDRO, TRACCIA, SETTORE) → LBA
(CHIP, BLOCCO, PAGINA) → LBA

CHIP, Blocco Regia nell'SSD

- ❖ La mappatura da settori/pagine a blocchi logici trasforma tuple, <cilindro, traccia, settore> o <chip, blocco, pagina>, in indirizzi progressivi lineari – **LBA** per *Logical Block Address* – più facili da utilizzare dal punto di vista algoritmico
- ❖ Nella pratica, una traduzione diretta è difficile; per esempio, nel caso dei dischi magnetici, hanno impatto significativo:
 - La presenza di settori difettosi
 - Il diverso numero di settori per traccia
 - La gestione interna al controllore (ed estranea al SO) dell'operazione di mappatura
- ❖ Tuttavia, gli algoritmi di gestione degli HDD tendono a presumere che gli indirizzi logici siano relativamente correlati agli indirizzi fisici, ovvero ad associare la crescita dell'indirizzo logico con la crescita dell'indirizzo fisico

di poco sb
cane è
veol'è
il disco

se 2000 le scipio... p. 2000 e 2000 de

veol'è
LBA all'indirizzo fisico





Struttura logica del disco magnetico – 1

❖ **CLV** – Constant Linear Velocity: ^{POCO COMUNE} densità dei bit per traccia uniforme ^{aumenta ω quando r è più piccolo}


- Tracce più lontane dal centro del disco sono più lunghe e contengono un maggior numero di settori (fino al 40% in più rispetto alle tracce vicine al centro di rotazione)
 - La velocità di rotazione ^{velocità di rotazione costante} aumenta spostandosi verso l'interno ($v = \omega r$), per mantenere costante la velocità lineare e, ^{nella traccia esterna, ho più settori, meno dentro} quindi, la quantità di dati che passano sotto le testine nell'unità di tempo
- CD e DVD

Se ω è costante, al centro del disco, velocità

- Talvolta, si ha un'unica traccia a spirale


❖ **CAV** – Constant Angular Velocity: ^{disco percorre angoli uguali in tempi uguali (?)} velocità di rotazione costante

- La densità dei bit decresce dalle tracce interne alle più esterne per mantenere costante la quantità di dati che passano sotto le testine nell'unità di tempo
- Dischi magnetici





Struttura logica del disco magnetico – 2



Disco CAV a tracce concentriche

Disco CLV con un'unica traccia a spirale





Scheduling del disco – 1

- ❖ Il SO è responsabile dell'uso efficiente dell'hardware: per i dischi ciò significa garantire tempi di accesso contenuti e ampiezze di banda elevate
- ❖ Il tempo di accesso ^{leggi minimitore} al disco si può scindere in due componenti principali:
 - Tempo di ricerca (*seek time*) — è il tempo impiegato per spostare la testina sul cilindro che contiene il settore desiderato
 - Latenza di rotazione (*rotational latency*) — è il tempo necessario perché il disco ruoti fino a portare il settore desiderato sotto la testina
- ❖ Per migliorare le prestazioni si può intervenire solo sul tempo di ricerca e si tenta quindi di minimizzarlo
- ❖ Seek time $\propto$ distanza di spostamento fra le tracce ^{Se si cerca}

più dista c'è tra la traccia e maggiore è il tempo di giro della testina sul cilindro





Scheduling del disco – 2

- voglio massimizzare dt/sec*
- ❖ L'ampiezza di banda del disco è il numero totale di byte trasferiti, diviso per il tempo trascorso fra la prima richiesta e il completamento dell'ultimo trasferimento
 - ❖ Quando un processo (utente o di sistema) deve effettuare un'operazione di I/O relativa ad un'unità a disco, effettua una chiamata al SO
 - ❖ La richiesta di servizio contiene:
 - Specifica del tipo di operazione (immissione/emissione di dati)
 - Indirizzo su disco relativamente al quale effettuare il trasferimento
 - Indirizzo nella memoria relativamente al quale effettuare il trasferimento
 - Numero di byte da trasferire





Scheduling del disco – 3

di gestione le code del disco?

- ❖ Una richiesta di accesso al disco può venire soddisfatta immediatamente se unità a disco e controller sono disponibili; altrimenti la richiesta deve essere aggiunta alla coda delle richieste inevase per quella unità
- ❖ In passato, il SO era responsabile della gestione delle code, ovvero della schedulazione delle unità a disco *decidero di gestione*
 - **Scheduling del disco** ora integrato ai controller dei dispositivi di archiviazione, che traducono direttamente gli indirizzi di blocco logico e gestiscono le code
 - Tuttavia, lo scheduling deve mantenersi equo e tempestivo e garantire il raggruppamento di accessi che appaiono in sequenza, poiché si ottengono prestazioni migliori con I/O "sequenziali"

*SCHEDULING DISCO, come gestisce
le code di attesa di I/O?*





Scheduling del disco – 4

- ❖ Gli algoritmi di scheduling del disco verranno testati sulla coda di richieste per i cilindri (0–199):

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

La testina dell'unità a disco è inizialmente posizionata sul cilindro 53

SCHEDULING DISCO
SULLA CODA DI RICHIESTE
CILINDRI






First-Come-First-Served

- ❖ **FCFS** – *First Come First Served* – è un algoritmo intrinsecamente equo
- ❖ Si produce un movimento totale della testina pari a 640 cilindri

mi sono fermato per 640 cilindri


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

head starts at 53




STP no N
OTTIHO

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



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





SCAN – 1

*è equo, non
produce starvation*

da 0 a 100 e da 100 a 0

- ❖ Il braccio della testina si muove da un estremo all'altro del disco, servendo sequenzialmente le richieste; giunto ad un estremo inverte la direzione di marcia e, conseguentemente, l'ordine di servizio
- ❖ È chiamato anche **algoritmo dell'ascensore**
- ❖ Se gli accessi sono distribuiti uniformemente, quando la testina inverte il proprio movimento, la maggior densità di richieste si ha all'estremo opposto del disco
 - Tali richieste avranno anche i tempi più lunghi di attesa di servizio

sopra ho distribuito molto uniformemente...

questo r. disco da 100 a 0, ho

più richieste da leggere che

settori vicini a 100


perché lì ho più richieste

più equo e ribruco a vuoto





SCAN – 2



❖ Si ha un movimento totale pari a 236 cilindri





C-SCAN – 1


- ❖ Garantisce un tempo di attesa più uniforme rispetto a SCAN
- ❖ La testina si muove da un estremo all'altro del disco servendo sequenzialmente le richieste
- ❖ Quando raggiunge l'ultimo cilindro ritorna immediatamente all'inizio del disco, senza servire richieste durante il viaggio di ritorno
- ❖ Considera i cilindri come organizzati secondo una lista circolare, con l'ultimo cilindro adiacente al primo





C-SCAN – 2

queue = 98, 183, 37, 122, 14, 124, 65, 67
head starts at 53



ridurre la parte grande del disco...

❖ Si ha un movimento totale pari a 383 cilindri





Scelta di un algoritmo di scheduling

- ❖ SCAN e C-SCAN forniscono buone prestazioni in sistemi che utilizzano intensamente le unità a disco
- ❖ Le prestazioni dipendono comunque dal numero e dal tipo di richieste
- ❖ Vengono normalmente implementati nella forma LOOK (e C-LOOK) ovvero non percorrendo tutto il disco, ma raggiungendo l'ultima traccia (in entrambe le direzioni) su cui è stata fatta richiesta di accesso
MI FERMO ALL'ULTIMA TRACCE A CUI HO FATTO LE RICHIESTE
NON ARRIVO a 180 se richiesto fino a 183-
- ❖ Le richieste di I/O per l'unità a disco possono essere influenzate dal metodo di allocazione di file e directory





Esempio 1

- ❖ Un disco ha C cilindri. Un'operazione di ricerca richiede 6msec per lo spostamento tra un cilindro e l'altro, la latenza rotazionale media è di 10msec ed il tempo di trasferimento è di 0.25msec per blocco.

- Quanto tempo è necessario per leggere un file costituito da 20 blocchi e memorizzato in modo tale che blocchi logicamente contigui nel file distino mediamente 13 cilindri l'uno dall'altro sul disco?

NEW FIGURA.
Piste distanti
di 13 cilindri

- Quanto tempo è necessario per leggere un file con 100 blocchi mediamente distanti 2 cilindri?


❖ Soluzione

- Il tempo necessario per la lettura del file da 20 blocchi è

$$T_{L20} = 20 \times [13 \times 6 + 10 + 0.25] \text{ msec} = 1765 \text{ msec}$$

- Il tempo necessario per la lettura del file da 100 blocchi è

$$T_{L100} = 100 \times [2 \times 6 + 10 + 0.25] \text{ msec} = 2225 \text{ msec}$$







Esempio 2

- ❖ Al driver di un disco arrivano, nell'ordine, richieste per i cilindri 10,22,20,2,40,6,38. Uno spostamento da un traccia a quella adiacente richiede 6msec. Si stabilisca quanto tempo è necessario per servire le richieste con FCFS e C-LOOK (crescente). Si assuma, per tutti i casi, che il braccio si trovi inizialmente posizionato sul cilindro 10.

- ❖ **Soluzione FCFS**



$$T = 6 \times (12 + 2 + 18 + 38 + 34 + 32) \text{ msec} = 816 \text{ msec}$$






Esempio 2 (cont.)

❖ Soluzione C-LOOK crescente

10,22,20,2,40,6,38



$$T = 6 \times (10 + 2 + 16 + 2 + 38 + 4) \text{ msec} = 432 \text{ msec}$$





nei capitoli, richieste dinamiche

Esempio 3 (cont.)

❖ Un disco ha un tempo di seek di 0.5msec per ogni cilindro attraversato, un tempo di rotazione di 6msec e un tempo di trasferimento dei dati di un settore di $12\mu\text{sec}$. Inoltre, la testina è attualmente posizionata sul cilindro 12. Supponendo che al tempo attuale arrivino contemporaneamente le seguenti richieste di lettura di settori:

- 5 settori nel cilindro 14
- 3 settori nel cilindro 11
- 4 settori nel cilindro 19
- 1 settore nel cilindro 2
- 6 settori nel cilindro 31

Calcolare il tempo di completamento delle richieste nel caso in cui venga utilizzato l'algoritmo dell'ascensore (in modalità LOOK e con direzione iniziale verso i cilindri con numerazione crescente).

calcolo una sola volta tempo di seek, ma tempo di latenza è da calcolare ogni volta



NON C'E' L'IPOTESI CHE SIA CONTIGUI
I SETTORI

NON CI SONO INDICAZIONI SULLA SEQUENZIALITA' DEI SETTORI

esistono: over head 1 tempo Seek + 1 tempo LAT + 5 transfer

Qui 1 Tempo Seek + 5 Tempo LAT + 5 Transfer.



Esempio 3

❖ Soluzione


- 5 settori nel cilindro 14
- 3 settori nel cilindro 11
- 4 settori nel cilindro 19
- 1 settore nel cilindro 2
- 6 settori nel cilindro 31

Tempo latenza $\approx \frac{1}{2}$ Tempo Rotazione

Tempo di seek = 500 μ sec

Tempo di latenza (mezzo giro) = 3000 μ sec

Tempo di trasferimento = 12 μ sec



$$\begin{aligned} T &= \{[2 \times 500 + 5 \times 3012] + [5 \times 500 + 4 \times 3012] + [12 \times 500 + 6 \times 3012] + \\ &\quad [20 \times 500 + 3 \times 3012] + [9 \times 500 + 3012]\} \mu\text{sec} \\ &= \{24000 + 57228\} \mu\text{sec} = 81.228 \text{ msec} \end{aligned}$$





Esempio 4

- ❖ Nella coda delle richieste di una unità a disco composta da 200 tracce, si trovano, nell'ordine, le seguenti richieste di accesso ai blocchi:

39700 304 115 2600 2120 270 321 0 760 20000

Si supponga che il blocco i -esimo sia memorizzato alla traccia $i \bmod 200$. La testina ha eseguito l'ultimo movimento portandosi dalla traccia 85 alla traccia 97. Si ipotizzi che lo spostamento da una traccia alla successiva richieda un tempo medio pari a $40\mu\text{sec}$ per traccia, che l'inversione della direzione di movimento della testina richieda mediamente $80\mu\text{sec}$ e che la velocità di rotazione sia pari a 7200 rpm. Determinare il tempo totale di servizio con scheduling C-SCAN considerando trascurabile il tempo di trasferimento.






Esempio 4 (cont.)

❖ Soluzione

> blocco da leggere più tardi



*2000000
cili di
0 a 200*

3 blocchi

$$\begin{aligned}
 T_{\text{Lat}} &= 0.5 \times (60/7200) \text{sec} \approx 4.16 \text{msec} = 4160 \mu\text{sec} \\
 T_{\text{Tot}} &= [(3 \times 40 + 4160) + (4 \times 40 + 4160) + (11 \times 40 + 4160) + (5 \times 40 + 4160) + \\
 &\quad + (40 + 4160) + (39 \times 40 + 4160) + (39 \times 40 + 80) + \\
 &\quad + (199 \times 40 + 3 \times 4160) + 80 + (70 \times 40 + 4160)] \mu\text{sec} \\
 &= (371 \times 40 + 10 \times 4160 + 2 \times 80) \mu\text{sec} = 56.6 \text{msec}
 \end{aligned}$$

8 msec per frame in frame

Spout

latency

(in video)





Scheduling su NVM

❖ Nelle unità NVM, dove non esistono parti mobili, si utilizza di solito una politica FCFS

- L'unica ottimizzazione possibile riguarda il servizio combinato di richieste (di scrittura) relative a indirizzi logici adiacenti

❖ Tuttavia, il vantaggio dei dispositivi NVM è meno sensibile in caso di accesso sequenziale — contrariamente al tempo di ricerca sugli HDD che, in questo caso, è ridotto al minimo

- Prestazioni equivalenti o anche peggiori in caso di elevata usura del dispositivo

❖ Problema dell'amplificazione di scrittura, quando si attivano operazioni aggiuntive per la garbage collection

→ è da evitare

→ Copiare pagine, Overprovisioning
ecc. è costoso


Tempo di scrivere pagina





Rilevamento e correzione di errori

- ❖ Il rilevamento degli errori determina se si è verificato un problema (ad esempio un *bit flipping*)
 - A fronte del verificarsi di un errore, il sistema può interrompere l'operazione prima che l'errore venga propagato
 - Rilevazione eseguita frequentemente tramite **bit di parità**
- ❖ La parità è una forma di *checksum* che utilizza l'aritmetica modulare per calcolare, archiviare, confrontare valori su parole a lunghezza fissa
- ❖ Un altro metodo di rilevamento degli errori comune nelle reti è il *controllo di ridondanza ciclica* (CRC) che utilizza una funzione hash per rilevare errori su più bit
- ❖ Il *codice di correzione degli errori* (ECC) non solo rileva, ma può correggere alcuni errori *errori soft e correggibili*
 - Errori soft correggibili, errori hard rilevati ma non corretti
 - Utilizzati a livello di settore/pagina





Gestione dell'unità a disco – 1

❖ Formattazione di basso livello o fisica

- Si suddivide il disco in settori, che possono essere letti e scritti dal controllore del disco *in base al modo del supporto, dividendo il disco in settori (HDD) o pagine (SSD)*
- Dimensione standard pari a 4KB
- Nel caso di NVM devono essere inizializzate le pagine e creata la tabella **FTL** (Flash Translation Layer) *Td che contiene una mappa delle pagine in un blocco e mi dice se e' valida o no*
- In entrambi i casi, la formattazione di basso livello inserisce nel dispositivo una speciale struttura dati per ogni "blocco" di memoria:

intestazione	dati	coda

 - ▶ Intestazione, dati, coda
 - ▶ L'intestazione e la coda contengono informazioni (numero settore/pagina, codice ECC) ad uso del controllore

❖ La formattazione fisica è eseguita dal costruttore dell'unità come parte del processo produttivo





Gestione dell'unità a disco – 2

❖ Per poter impiegare un dispositivo per memorizzare i file, il SO deve mantenere le proprie strutture dati sul disco (HDD/SSD) *Divido HDD in Partiz, e partiz creo un FS*

- Si partiziona il dispositivo in uno o più gruppi di cilindri/pagine, ognuno dei quali rappresenta un "disco logico"

■ **Formattazione logica** o "creazione di un file system" *unico spazio che viene diviso a costituire un disco logico, partiz, che e' un volume o e' c'e' un FILE SYSTEM*

una struttura dati per permettere il disco di essere da parte del SO (FS)

▶ Strutture dati del SO per la descrizione dello spazio libero/occupato e creazione di una directory iniziale vuota

- Per migliorare le prestazioni, la maggior parte dei file system accorpa i blocchi in gruppi, detti cluster

▶ I/O su disco fatto per blocchi

▶ I/O via file system fatto per cluster *con granularita' piu' grossa* (accesso sequenziale)

▶ File e metadati vicini su HDD per diminuire i movimenti della testina *vicini i file*

l'elemento di Directory sono sono sullo stesso cilindro, per un gestione della testina

metadati: record descrittivo del file e contenuto directory (?)

• DIR e FILE vicini





Gestione dell'unità a disco – 3

Disco con SO hanno Partizioni Boot

- ❖ Un disco di avviamento o disco di sistema ha una partizione di boot nel primo settore del disco, c'è un MASTER BOOT SECTOR, contiene un numero del BOOTSTRAP, più grande del BIOS. Identifica nel disco
- ❖ Il primo blocco logico del dispositivo è il blocco di avvio o boot block una partizione con il SO info per reperire il SO, il kernel, e caricarlo in MEM

- ❖ La partizione di boot contiene il SO; altre partizioni possono contenere altri SO, altri file system o essere partizioni raw

CONTIENE

BOOT LOADER
E KERNEL

- Viene montata all'avvio del sistema
- Altre partizioni possono essere montate automaticamente o manualmente (al boot o successivamente)
- ❖ Al momento del montaggio di ogni partizione, si verifica la coerenza del file system (controllando la correttezza dei metadati)
 - Si aggiorna la tabella di montaggio

si monta la partizione di boot e anche dopo l'avvio del sistema posso montare altre partizioni

Montaggi anche espliciti con comando mount. UNIX permette montaggio solo in fase di boot 11.49, poi manuale





Gestione dell'unità a disco – 3

BOOT BLOCK
CONTIENE BOOTSTRAP


Primo blocco logico di un disco di avviamento è un BOOT BLOCK

❖ Nel **boot block** sono contenute le informazioni necessarie all'inizializzazione del sistema

❖ In Windows si chiama **MBR** (Master Boot Record)


- Esecuzione del codice del **bootstrap loader** contenuto nel firmware
1) viene eseguito Bootstrap loader (contenuto nel BIOS)
2) Bootstrap loader carica Bootstrap, situato nel boot block
- Lettura/esecuzione del codice contenuto nell'MBR, che contiene anche una tabella delle partizioni, con un flag che identifica la partizione di boot
- Caricamento, dalla partizione di boot, del kernel e dei sottosistemi del SO

• Bootstrap inizializza componenti (RAM, CPU, controller), individua la partizione di boot ⇒ Boot block punta alla partizione di boot, dove c'è il boot loader e il kernel
Boot block è nei primi blocchi del disco





Avviamento dal disco di Windows





Gestione dei blocchi difettosi

significato preciso
HDD: insieme dei settori sullo stesso cilindro
SSD: insieme dello pagine su un chip
e spesso di una sola pagina

grasso di memoria
con più spesso i bit

- ❖ I dischi magnetici sono strutturalmente pronti a malfunzionamenti, perché costituiti da parti mobili con basse tolleranze
- ❖ Si impiega l'**accantonamento dei settori** come modalità di gestione dei blocchi difettosi
 - Durante la formattazione fisica si mantiene un gruppo di settori di riserva non visibili al SO
 - Il controllore "è istruito" per sostituire, dal punto di vista logico, un settore difettoso con uno dei settori di riserva inutilizzati
- ❖ Anche i dispositivi NVM possono contenere pagine difettose, che vengono logicamente sostituite o con pagine accantonate o appartenenti alla riserva costituita dall'over-provisioning

difficoltà anche a fare stessa costruzione
mapping, (cylinder, track, head)

SSD (chip, blocco, pagine) e copia supporto in un gruppo di memoria

accantonamento dei settori, gestione del driver del dispositivo
es. con ECC, visto che c'è un errore

gruppo di settori che vengono logicamente sostituiti da quelli non difettosi, magari se sullo stesso cilindro per HDD o in un gruppo di memoria per SSD





Gestione dell'area di swap

area del disco usata
per mantenere copie del
processo non in uso

- ❖ La memoria virtuale impiega lo spazio su disco come un'estensione della memoria centrale
 - Pratica attualmente meno comune, grazie all'incremento nella capacità delle memorie
- ❖ L'obiettivo principale nella progettazione e realizzazione dell'area di swap è di fornire la migliore produttività per il sistema di memoria virtuale
- ❖ Lo spazio di swap può essere ricavato all'interno del normale file system o, più comunemente, si può trovare in una partizione separata del disco

in cui si manipolano le sue strutture
dati, accesso alla memoria con
procedimenti più diretti

- **Partizione raw:** adotta algoritmi ottimizzati rispetto alla velocità di accesso piuttosto che all'occupazione di spazio (frammentazione)

spazio w p's memoria, accessibile per la gestione






Gestione dell'area di swap in Linux – 1

Heap, Stack e dati non inizializzati... tutto il resto lo può recuperare dal File System
devo mettere un pezzo di codice? lo posso sentire via mezzo del FS


- ❖ L'area di swap, in Linux, è utilizzata solo per la memoria anonima, ovvero per dati che non corrispondono a file (stack, heap, dati non inizializzati)
- ❖ Linux permette l'istituzione di una o più aree di avviamento, sia in file che in una partizione raw, possibilmente situate su unità diverse per distribuire su più dispositivi il carico della paginazione
- ❖ Un'area di ^{SWAP} avviamento è formata da una serie di moduli di 4KB, detti slot delle pagine, la cui funzione è quella di conservare le pagine avviate





Gestione dell'area di swap in Linux – 2

- ❖ Ogni area dispone di una **mappa di avviciamento**, un array di contatori interi, ciascuno dei quali corrisponde ad uno slot dell'area
 - Se un contatore vale 0, la pagina che gli corrisponde è disponibile; valori maggiori di 0 indicano che lo slot è occupato da una delle pagine avvicendate
 - ▶ Il valore del contatore indica il numero di collegamenti alla pagina; se, per esempio, vale 3, la pagina fa parte dello spazio degli indirizzi virtuali di tre processi distinti





Connessione dei dispositivi di memoria

❖ I calcolatori accedono alla memoria secondaria in tre modi:

- Tramite un dispositivo collegato alla macchina *Power Bus I/O*
- Tramite un dispositivo connesso alla rete
- In cloud

Handwritten notes:

Network RPC
remote procedure call

*lo faccio
sempre tramite
applicazioni! acceso o creazione file vengono fatto con
tramite chiamata di sistema ma tramite applicazioni,
e sono mediate tramite app usata a DSP sul cloud*





Memoria secondaria connessa alla macchina

- ❖ Alla memoria secondaria connessa alla macchina si accede dalle porte locali di I/O che sono collegate al bus
 - Nei PC, con interfaccia SATA, due unità (al più) per ciascun bus di I/O
- ❖ Per accedere ad un maggiore spazio di archiviazione utilizzo di porte e cavi USB, FireWire o Thunderbolt
- ❖ **FC** (Fiber Channel) è un'architettura seriale ad alta velocità
 - Può gestire uno spazio d'indirizzi a 24 bit, che è alla base delle **storage area network** (SAN), nelle quali molti host sono connessi con altrettante unità di memorizzazione






Memoria secondaria connessa alla rete

NAS vs la stessa rete del traffico INTERNET

- ❖ Un dispositivo di memoria secondaria connessa alla rete (Network-Attached Storage, **NAS**) è un sistema di memoria specializzato al quale si accede in modo remoto attraverso la rete di trasmissione dati
- ❖ I client accedono alla memoria connessa alla rete tramite un'interfaccia RPC, supportata da protocolli quali NFS (UNIX) e CIFS (Windows)
- ❖ Le chiamate di procedura remota sono implementate per mezzo di TCP o UDP, sopra una rete IP, di solito la stessa rete che supporta tutto il traffico dei dati fra client e server

SPN non porta questo traffico pesante, usi rete dedicata, passano solo dati



CLOUD in accesso remoto WAN, più lento

ho rivolge alle macchine che se ci servono rivolgersi a macchina locale, con SYSTEM call, protocollo RPC





Memoria secondaria in cloud



- ❖ Similmente al NAS, fornisce l'accesso allo storage tramite rete
 - A differenza del NAS, l'accesso al data center remoto avviene tramite Internet o WAN
- ❖ NAS si presenta come un altro file system, mentre lo storage cloud è basato su API, con programmi che utilizzano le API per fornire l'accesso
 - Esempi di cloud storage includono **Dropbox, Amazon S3, Microsoft OneDrive, Apple iCloud, Google drive**
 - Si impiegano le API a causa delle lunghe latenze e per i numerosi scenari di errore che sono comuni sulle WAN





Storage Area Network

- ❖ Reti private (che impiegano protocolli specifici per la memorizzazione) tra server e unità di memoria secondaria
- ❖ Flessibilità: si possono connettere alla stessa SAN molti calcolatori e molti storage array





Strutture RAID – 1

- ❖ **RAID, Redundant Array of Independent Disks** —
l'affidabilità del sistema di memorizzazione viene garantita tramite la ridondanza *(Inexpensive) più dischi piccoli costano di meno*
Ridondanza e Migliaia di dischi
- ❖ Aumento del **tempo medio di guasto** *↳ STRIPING*
- ❖ Spesso affiancati dalla presenza di NVRAM per garantire la consistenza dei dati scritti "contemporaneamente" su dischi multipli e per migliorare le performance
- ❖ Inoltre... le tecniche per aumentare la velocità di accesso al disco implicano l'uso di più dischi cooperanti






Strutture RAID – 2


- ❖ Il **sezionamento del disco** o **data striping** (RAID 0) tratta un gruppo di dischi come un'unica unità di memorizzazione:
 - Ogni "blocco" di dati è suddiviso in "sottoblocchi" memorizzati su dischi distinti (es.: i bit di ciascun byte possono essere letti "in parallelo" su 8 dischi)
 - Il tempo di trasferimento per rotazioni sincronizzate diminuisce proporzionalmente al numero dei dischi nella batteria
- ❖ Gli schemi RAID migliorano prestazioni ed affidabilità del sistema memorizzando dati ridondanti:
 - Il **mirroring** o **shadowing** (RAID 1) conserva duplicati di ciascun disco

*Questa informazione identica su più dischi...
per mantenere un backup delle informazioni
non volatile (?)*






Alcuni livelli RAID



Il livello 0+1 consiste in una combinazione dei livelli RAID 0 e 1: il livello 0 garantisce le prestazioni e il livello 1 l'affidabilità



Fine del Capitolo 11

