Programmazione e Architetture (Modulo B)

Lezione 15
Filesystem

Luca Manzoni

Filesystem

E persistenza

- Una delle astrazioni fornite da un OS è quella dei file
- Vedremo come passare da un dispositivo di memoria di massa (disco fisso o memoria flash) a fornire questa astrazione
- Vedremo questo in due passi:
  - Come passare da un disco fisso/memoria flash a un dispositivo a blocchi
  - Come creare l’astrazione dei file a partire da un dispositivo a blocchi

Dispositivi a blocchi

L’astrazione che vogliamo ottenere

- Per poter definire un filesystem vogliamo avere una astrazione “comoda” per rappresentare i diversi dispostivi:
  - Dischi fissi, memorie flash, dispositivi ottici, etc.
- Per questo usiamo una astrazione in cui tutto lo spazio a disposizione in ognuno di questi dispositivi è suddiviso in blocchi di dimensione fissata (e.g., 512bit, 4KB, etc)
- Ogni blocco è dotato di un indirizzo (possiamo supporre che n blocchi siano numerati $0,\ldots,n-1$)
- Per semplificare, assumiamo che il sistema operativo ci permetta di leggere/scrivere un singolo blocco alla volta

Dischi fissi

Settori e tracce

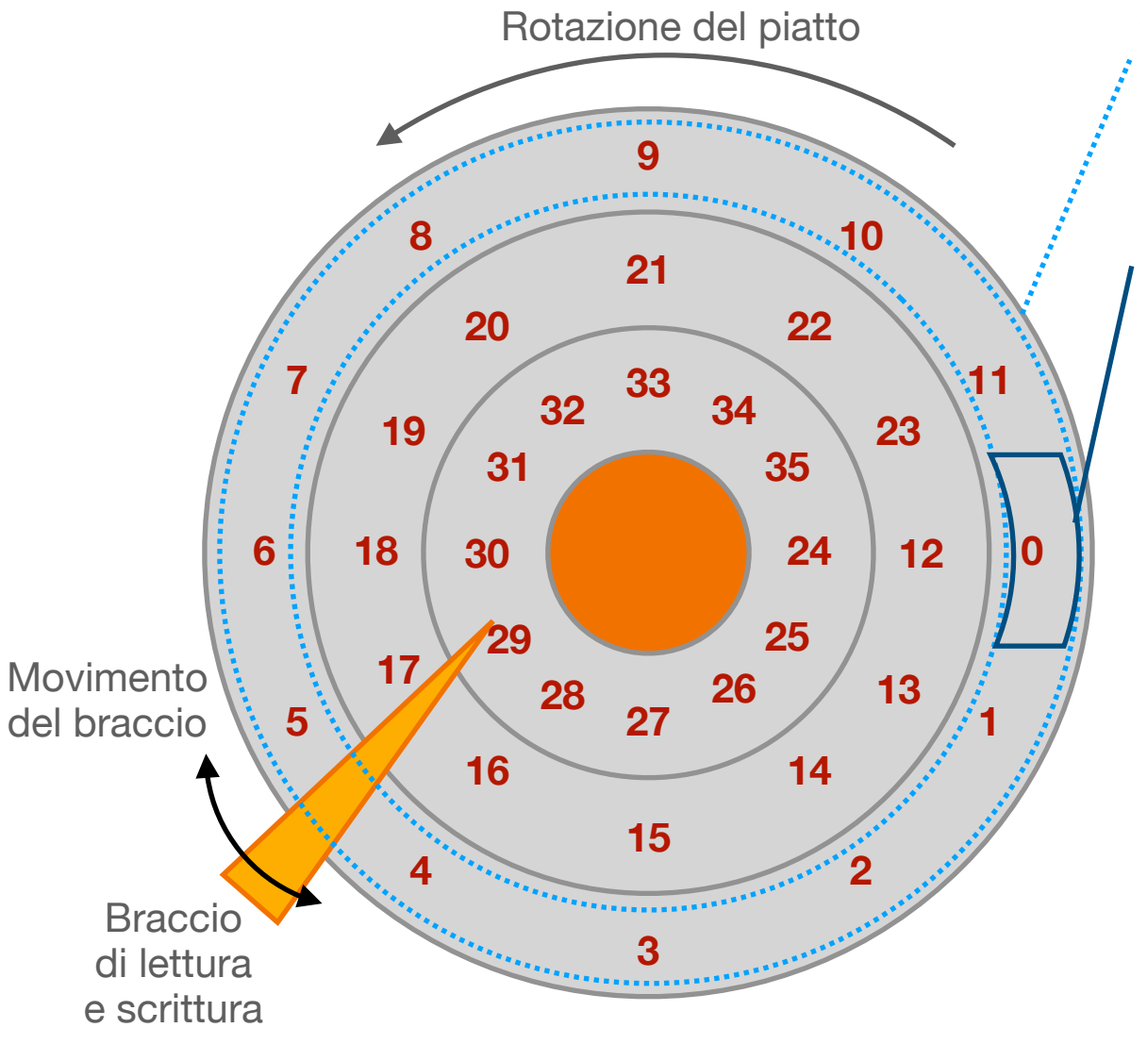

- Un disco fisso è diviso in più piatti, ognuno con un braccio che permette di leggere e scrivere
- I piatti ruotano a alcune migliaia di giri al minuto (rpm). Valori comuni sono 5400 o 7200 rpm
- Ogni piatto è diviso in più tracce concentriche
- Ogni traccia è divisa in più settori (tradizionalmente da 512 bytes l'uno)
- Per leggere o scrivere un settore il braccio deve spostarsi sulla traccia corretta (tempo di seek)
- Una volta sulla traccia corretta deve attendere che il settore corretto passi sotto la testina di lettura/scrittura

Memoria flash

Blocchi e pagine

Stessi nomi ma significati diversi rispetto a quello che abbiamo già visto

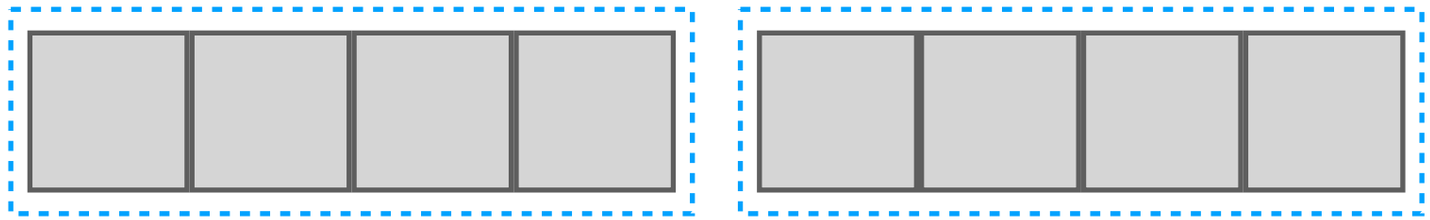

Una memoria flash è divisa in pagine raggruppate in blocchi

Le operazioni possibili sono:

- Lettura di una **pagina**
- Cancellazione di un **blocco**
- Programmazione (scrittura) di una **pagina** (solo su un blocco cancellato)

Notate che se vogliamo scrivere una pagina dobbiamo cancellare il blocco che la contiene!

Dobbiamo salvare e ri-scrivere tutte le altre pagine del blocco che contengono informazione che vogliamo salvare

In aggiunta a questo ogni blocco ha un numero limitato di scritture possibili!

Come viene creato un disco a stato solido (SSD) usando memorie flash?

SSD

Possiamo avere multiple memorie flash collegate in parallelo

Disco a stato solido (SSD) basato su memorie flash

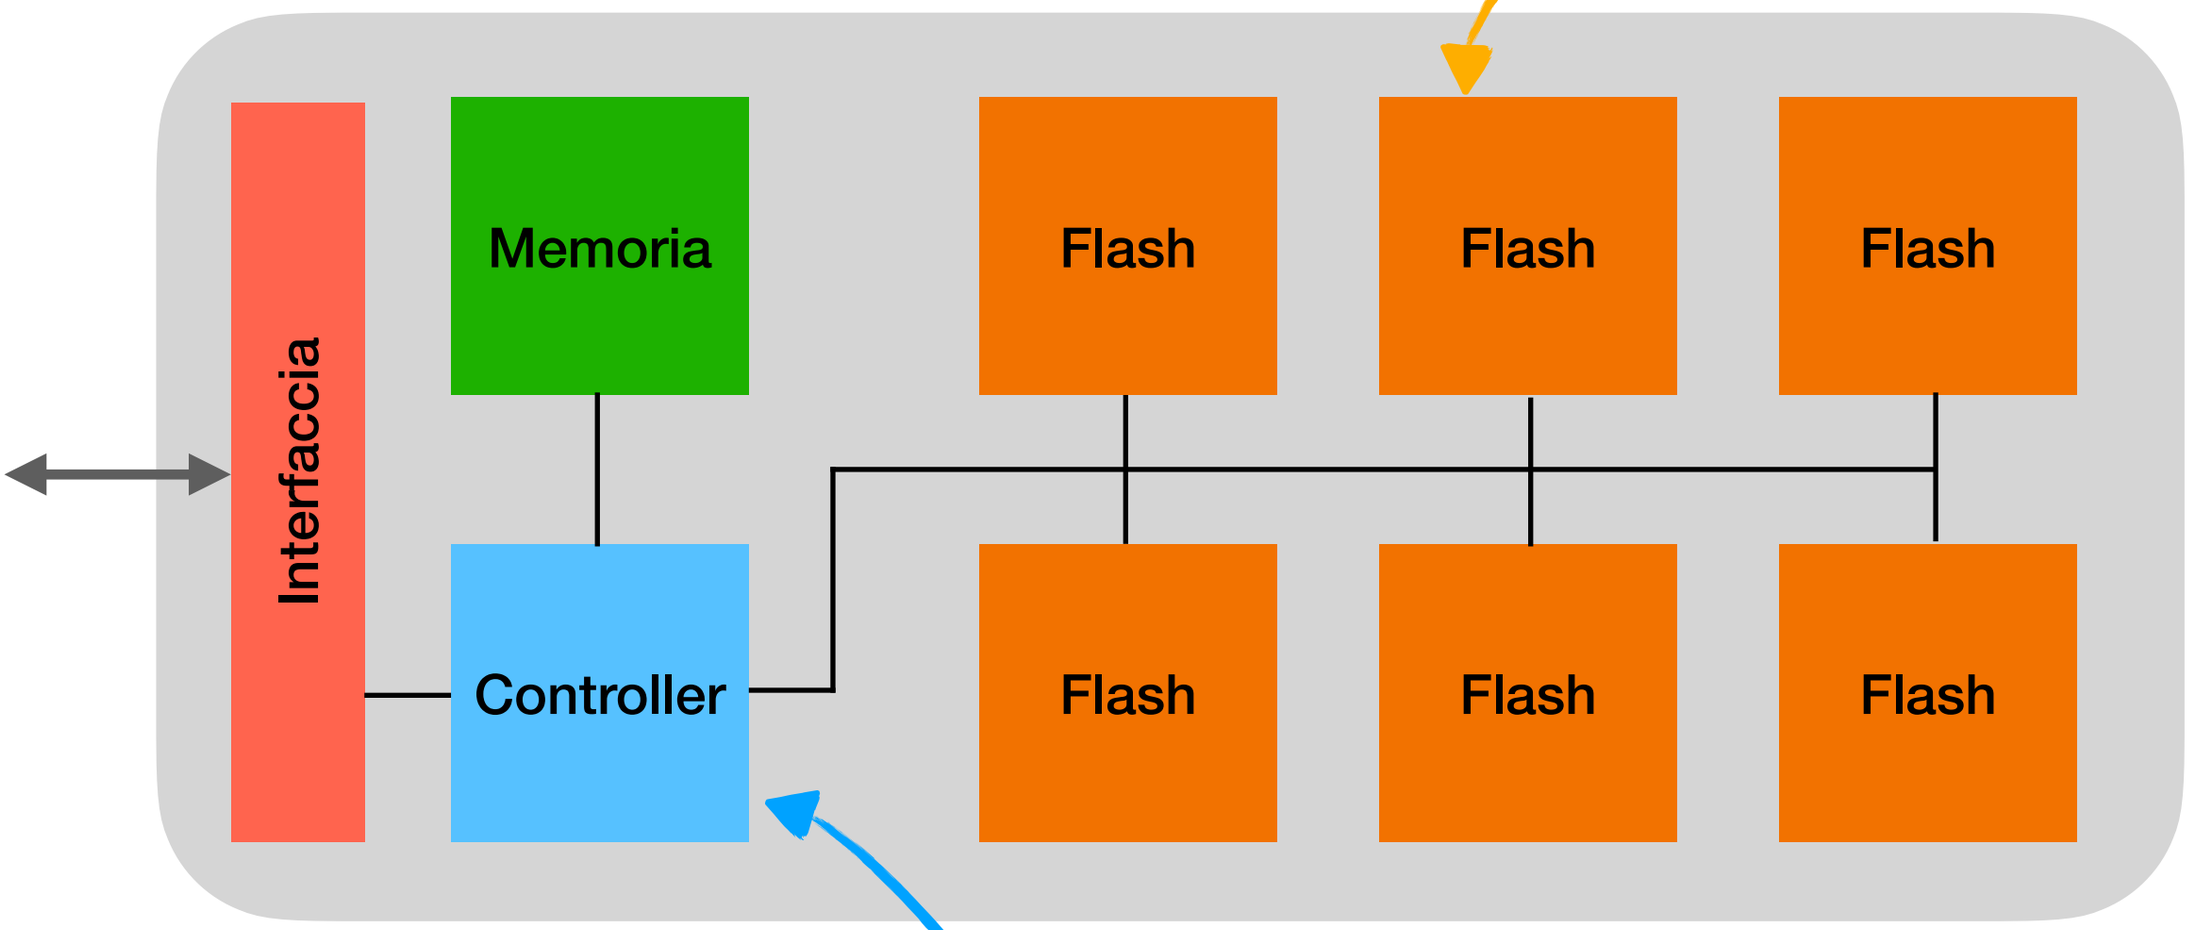

Il controller si occupa di distribuire le scritture in modo da rendere uniforme l'usura della flash (*wear levelling*) e di evitare che la quantità di scritture effettuate realmente rispetto a quelle richieste dall'OS sia bassa (limitate la *write amplification*)

Simple Filesystem

Imitare il “vecchio” Unix Filesystems

Supponiamo di avere un dispositivo a blocchi (in questo caso con 64 blocchi) tutti di dimensione fissata. Come facciamo ad ottenere file e directory?

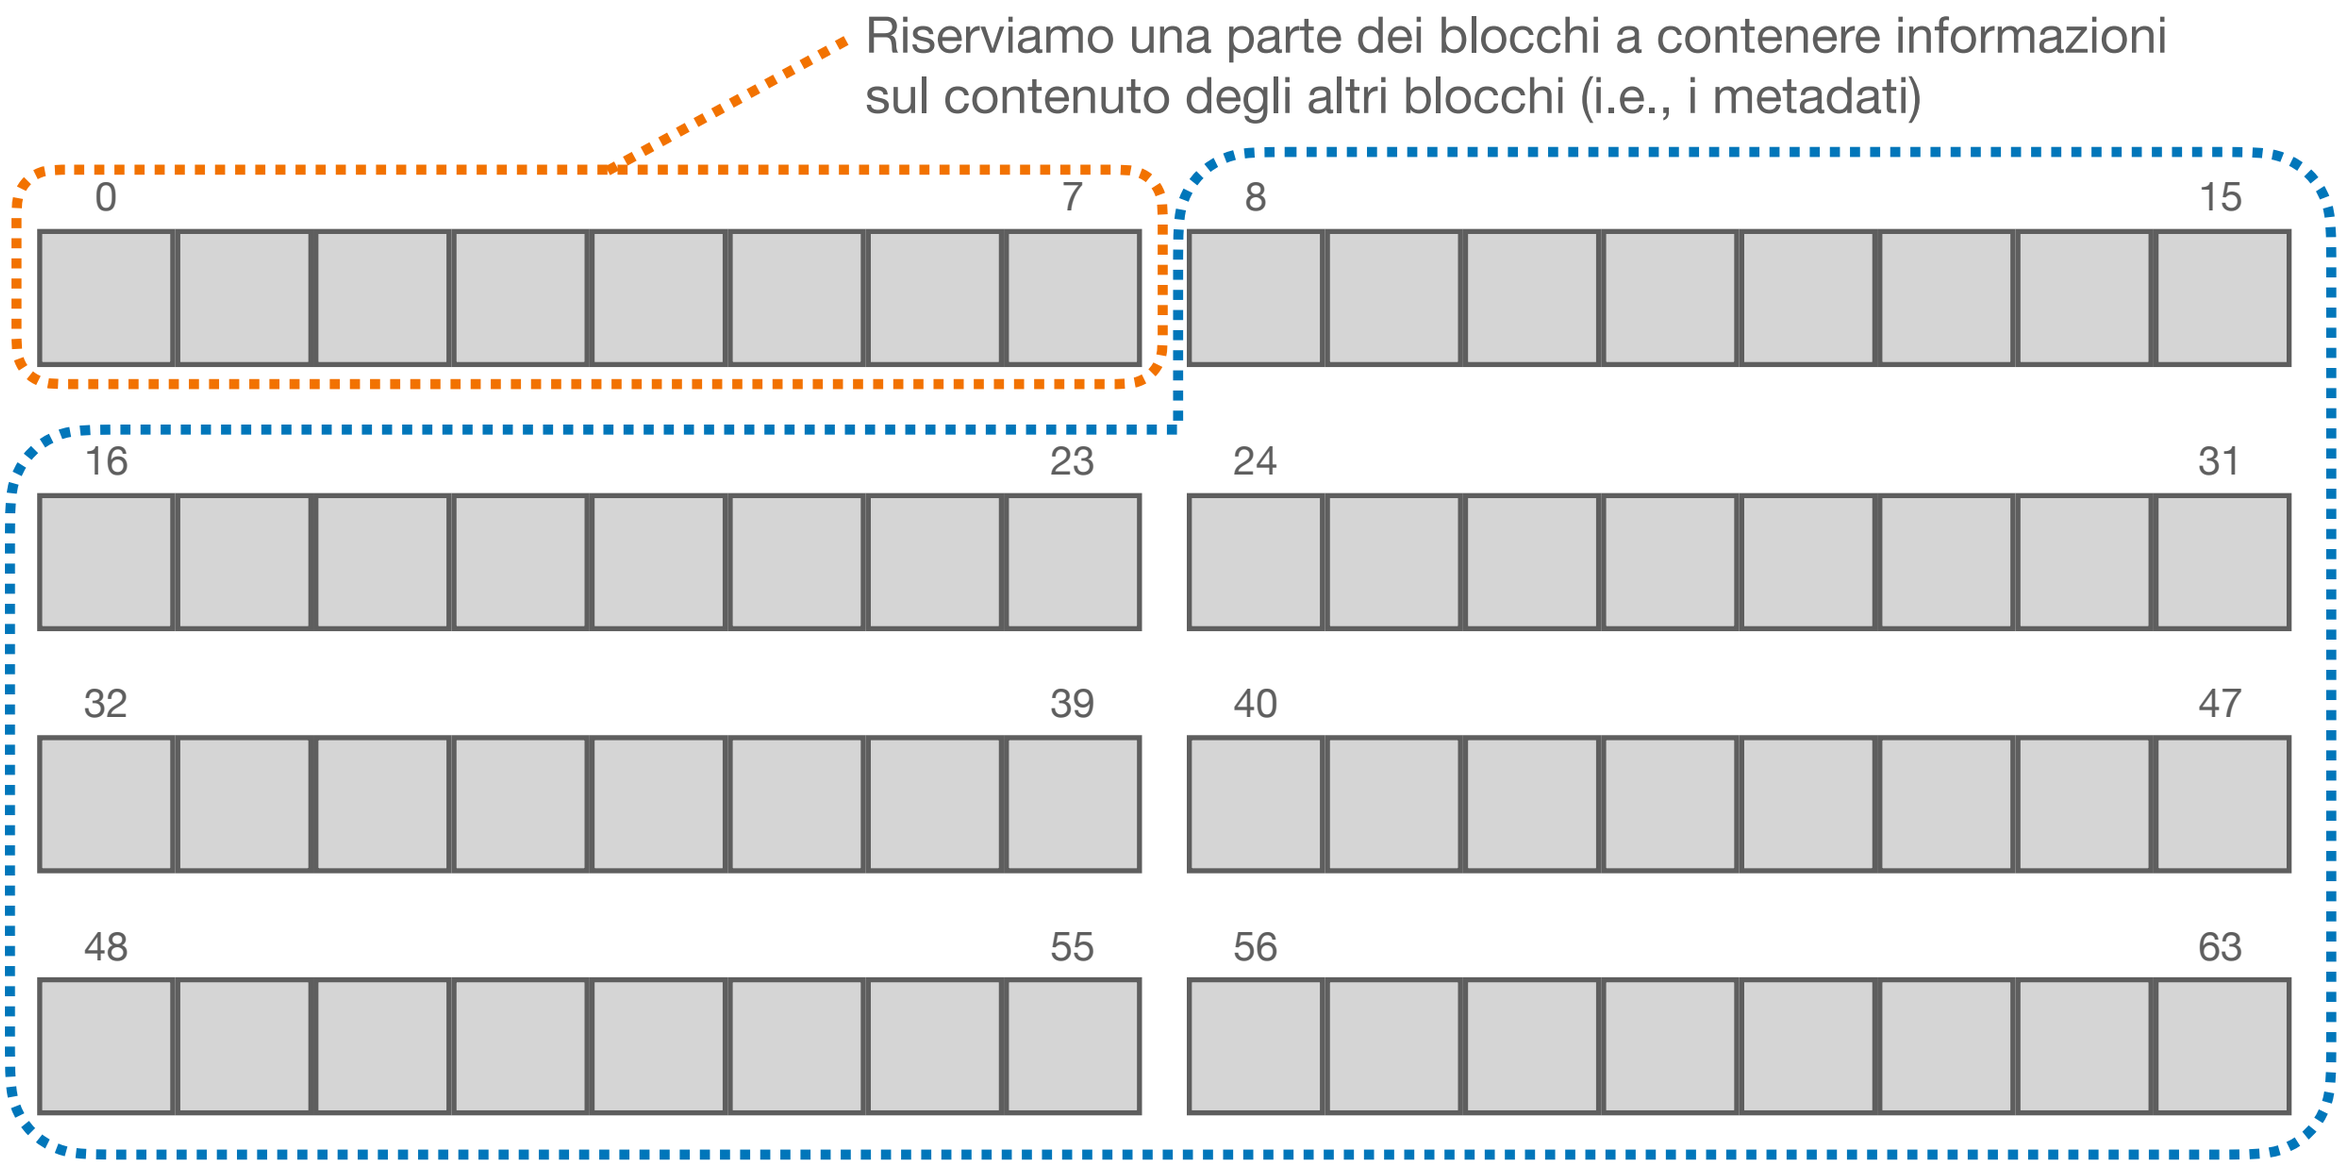

Metadati

Inodes, bitmap, superblocchi

Vediamo che tipologie di metadati contiene is nostro “Simple fileystem”:

Superblocco
Il superblocco contiene informazioni relative all’intero filesystem, come quali blocchi sono dedicati ai dati, dove si trovano gli inode, la inode bitmap e la data bitmap.
Di solito contiene anche un “magic number” che permette di identificare il tipo di filesystem

Inode bitmap
Una bitmap che ci dice quali inode sono occupati (i.e., corrispondono a file realmente esistenti) e quali sono liberi

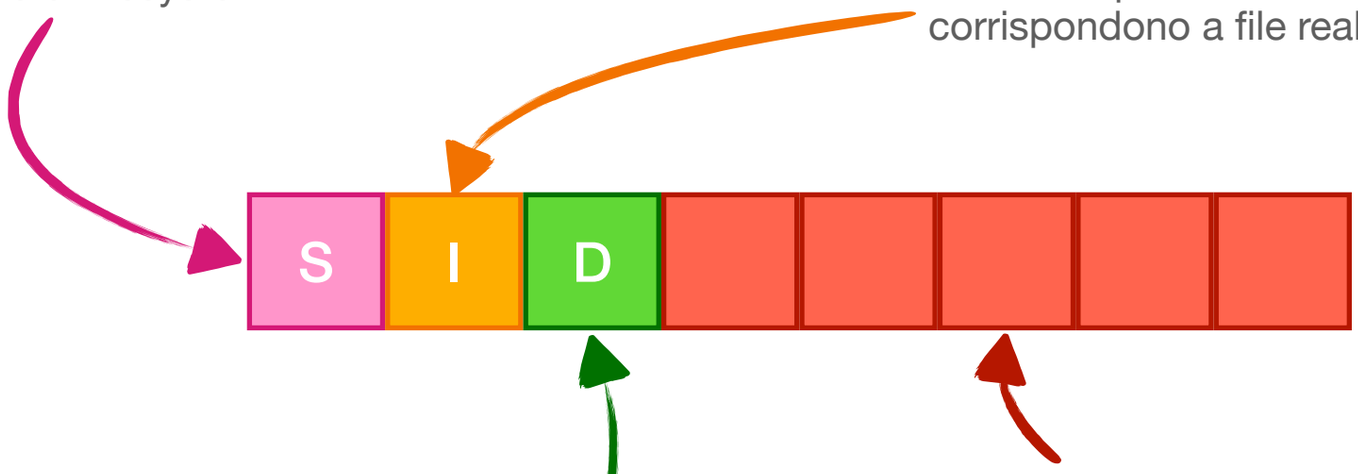

Data bitmap
Una bitmap ci indica quali blocchi nella parte dedicata ai dati risulta occupata

Gli **inodes** (contrazione di **index nodes**) sono uno per file/directory (ogni blocco ne contiene molteplici)
e contengono informazioni come:

- Che blocchi occupa un certo file
- Chi è il proprietario
- I permessi
- Tempo di ultimo accesso/modifica

Inode

Informazioni su un file

Un inode è rappresentabile da una struct con diversi campi:

rwxr-xr-x	**Permessi**: il file può essere letto/scritto/eseguito?
1001	**UID** (User ID): Utente proprietario del file
4096	**Dimensione**
01/04/2021 11:37	**Time**: momento di ultimo accesso al file
31/01/2019 9:22	**Ctime**: momento in cui il file è stato creato
10/03/2020 22:01	**Mtime**: momento dell'ultima modifica del file
-	**Dtime**: momento in cui l'inode è stato cancellato
1005	**GID** (Group ID): Gruppo proprietario del file
8	**Blocchi**: numero di blocchi allocati per il file
-	**Altri campi**: ACL (access control list — permessi aggiuntivi), etc.
	Puntatori ai blocchi (solitamente decine): puntatori ai blocchi occupati dal file

Timestamps

Vediamo come funzionano i puntatori ai blocchi e gli indici multi-livello

Puntatori ai blocchi occupati

Indice multi-livello

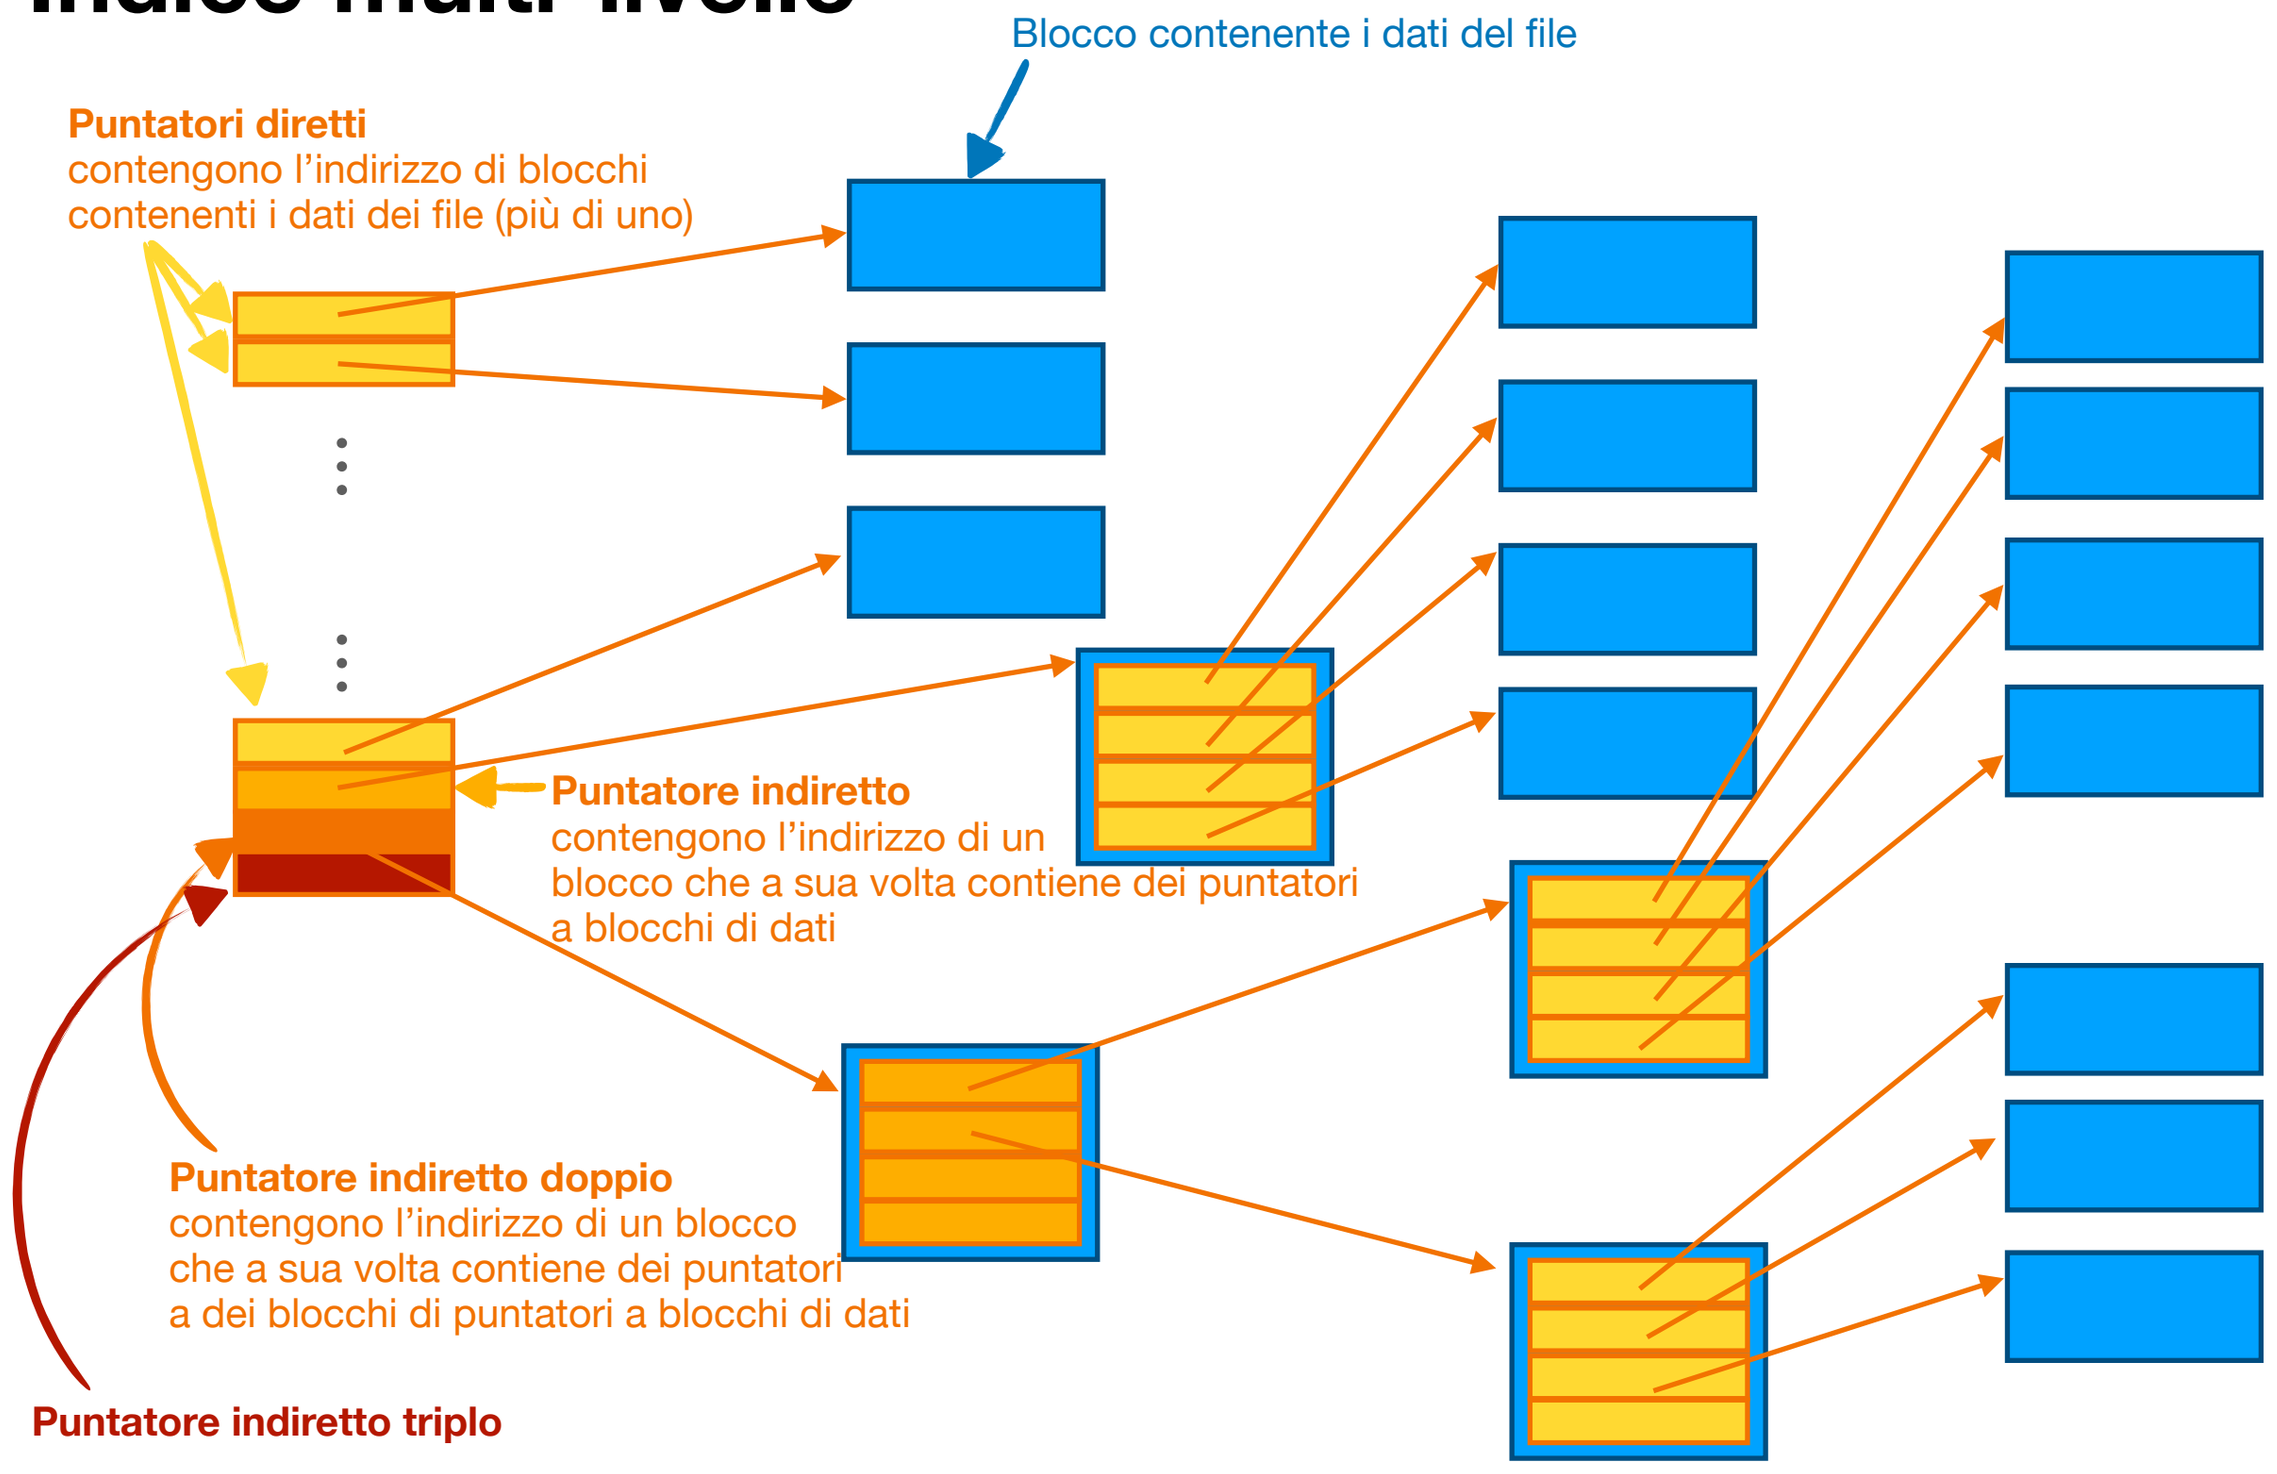

Perché questa struttura multi-livello?

Memorizzare efficacemente i file

- Supponiamo di avere blocchi di 4KB e ogni puntatore occupa 4 byte
- Supponiamo di avere 10 puntatori diretti
- Con 10 puntatori diretti possiamo indirizzare 10 blocchi (40KB)
- Ogni blocco, se usato per memorizzare puntatori, può contenere 1000 indirizzi di altri blocchi
- Un primo livello di indirezione ci consente 1000 blocchi (4MB) aggiuntivi
- Un secondo livello di indirezione ci consente 1000 blocchi ognuno con riferimenti a 1000 blocchi, consentendo 4GB aggiuntivi (i.e., 10^6 blocchi)
- Un terzo livello di indirezione ci consente 1000 blocchi ognuno con un 1000 riferimenti a blocchi ognuno con 1000 riferimenti a blocchi, consentendo 4TB aggiuntivi (i.e., 10^9 blocchi)
- La dimensione massima di un file è quindi poco oltre 4TB

Dove si trova il file?

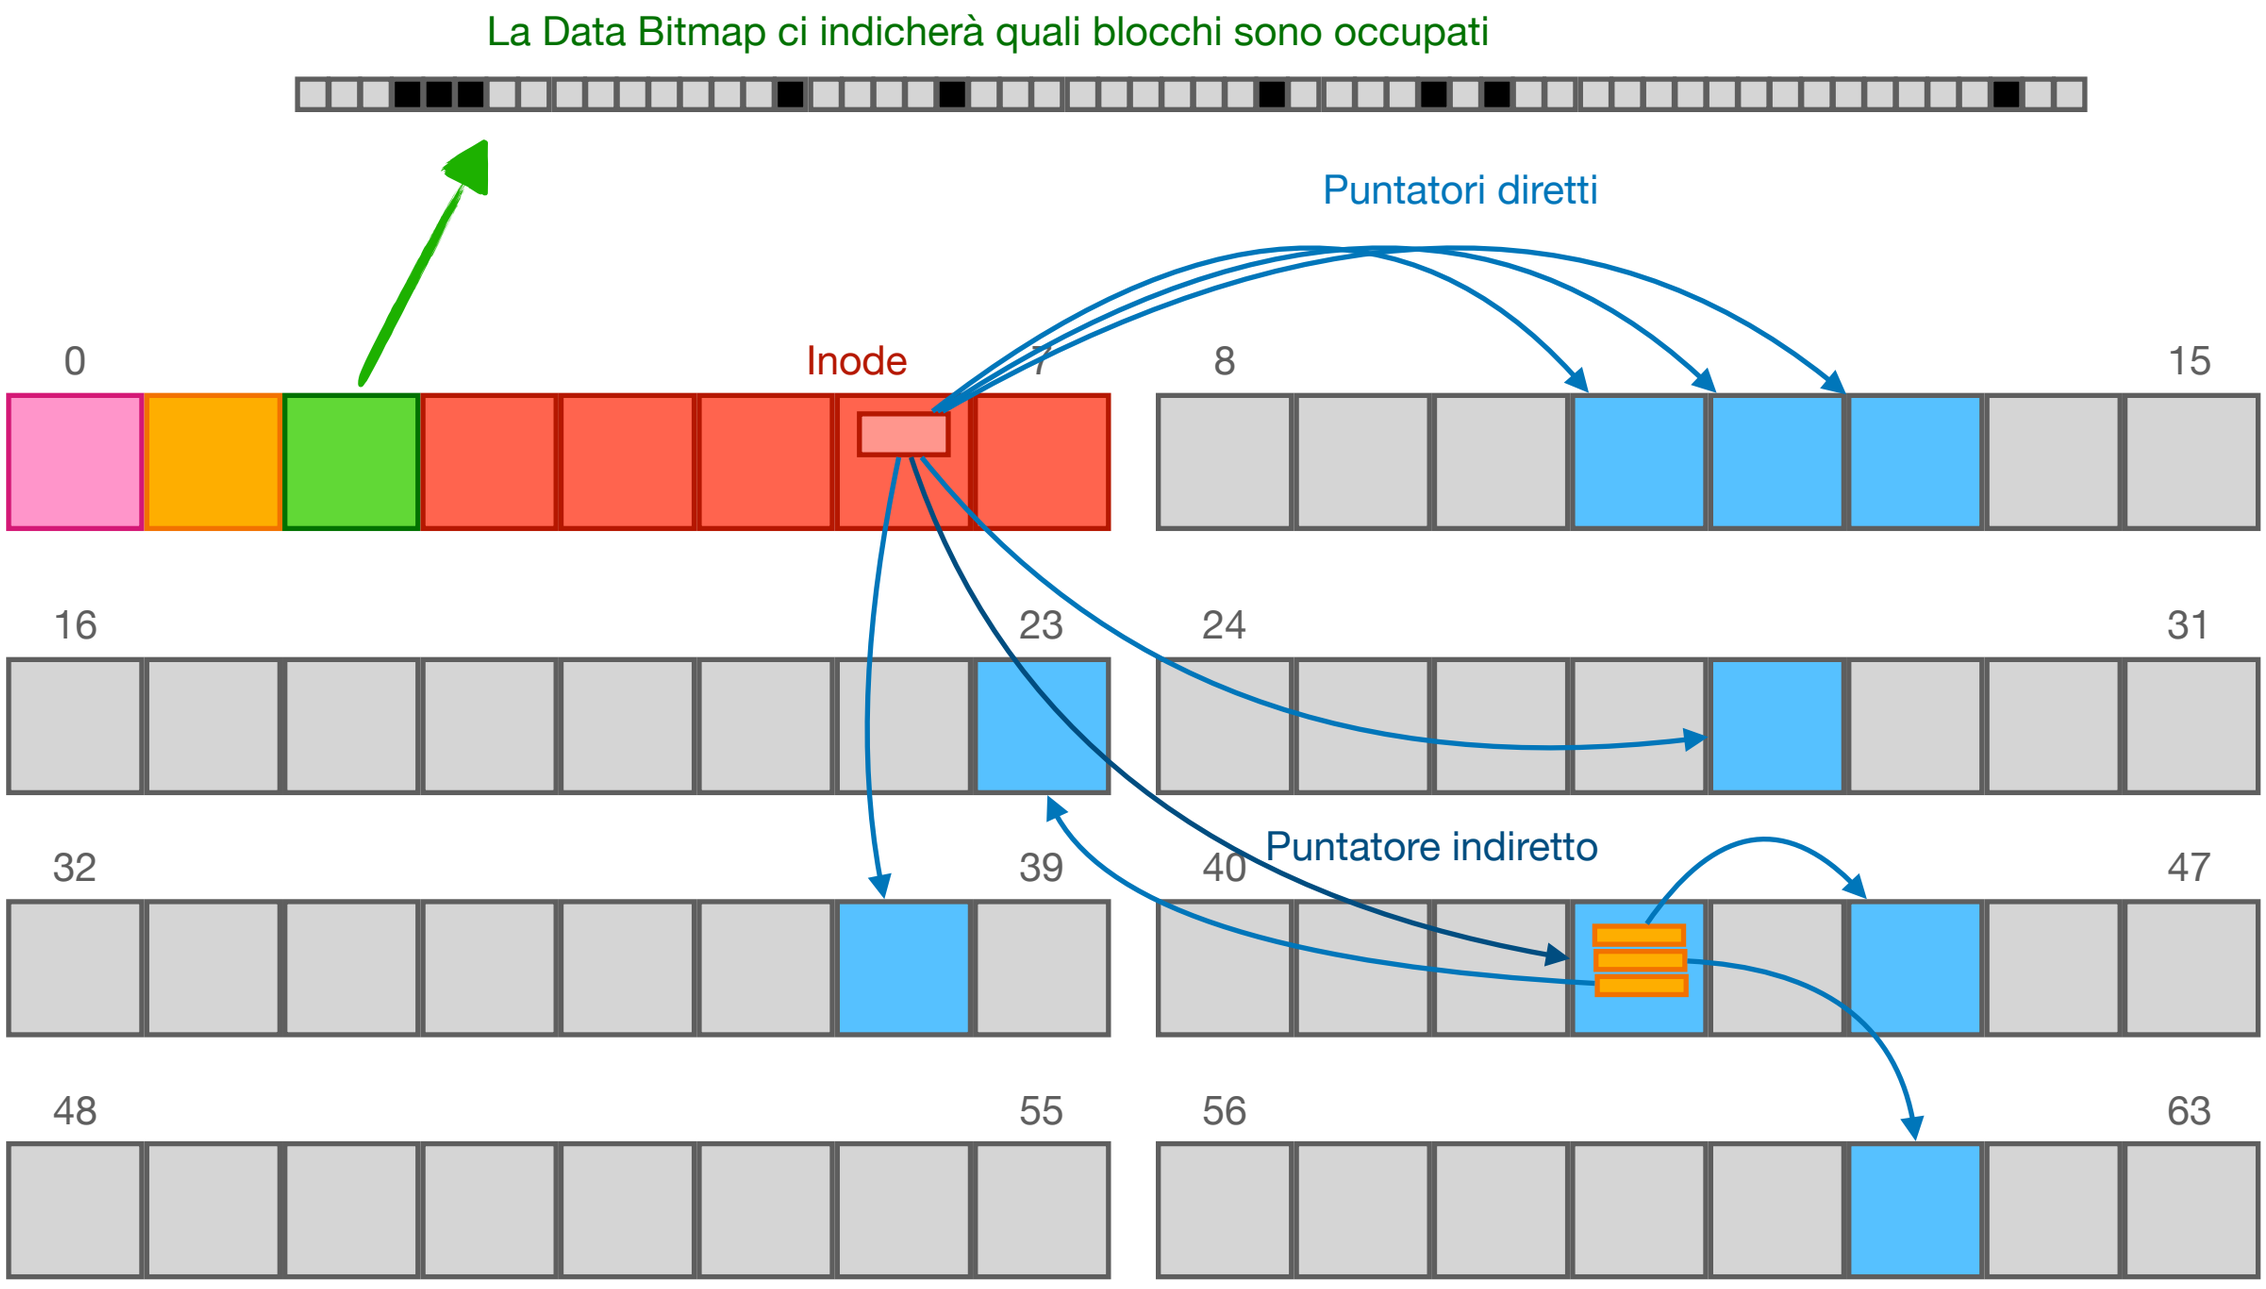

Accedere a un file

E modificare il contenuto

- Per poter accedere a un file abbiamo bisogno di sapere l'inode associato (che supponiamo di avere)
- Se vogliamo accedere ad una specifica posizione dobbiamo prima individuare in quale blocco è locata. Se il blocco è accessibile direttamente possiamo leggerlo, altrimenti è necessario leggere uno o più blocchi di puntatori
- Se cambiamo la dimensione del file aggiungendo o togliendo contenuto dobbiamo aggiornare i dati nell'inode e i dati nella data bitmap
- Se il file viene cancellato non è necessario eliminare solo l'inode ma anche segnare come liberi tutti i blocchi che occupava nella data bitmap

E le directory?

Directory come file

- Possiamo vedere una directory come un normale file
- Quello che cambia è il contenuto del file
- Nella sua forma più semplice una directory è un file il contenuto è una sequenza di coppie **(numero inode, nome file)**:
  - `(123, Esempio.txt)`
  - `(281, Esercizi)`
  - `…`
- Possiamo quindi memorizzare le directory come normali file, usando solo una interpretazione diversa del loro contenuto

Performance

E perché non è tutto così semplice

- Implementato in questo modo un filesystem che utilizzasse un disco fisso sarebbe molto lento

- I blocchi in cui è salvato il contenuto di un file sono salvati in modo “casuale” sul disco. Ogni lettura richiederebbe di riposizionare la testina e attendere il passaggio del settore sotto di essa

- Per questo i sistemi moderni tendono a cercare di allocare i file in blocchi consecutivi, in modo da poter leggere il contenuto spostando la testina del disco il meno possibile

- Questo ovviamente non vale per le memorie flash!

Consistenza

Conservare i dati in caso di spegnimento inatteso

- Cosa succede se il sistema si spegne mentre stiamo facendo una lettura/scrittura?
- Per esempio potremmo aver aggiornato un inode ma non la bitmap e il filesystem sarebbe in uno stato inconsistente
- Come risolvere?
  - Creare un programma di riparazione del filesystem (fsck). Approccio usato da ext2, ufs, fat32, …
  - Ordinare le scritture per limitare il tipo di inconsistenze che si possono presentare (soft updates). Approccio usato da UFS2 con soft updates (FreeBSD)

Consistenza (2)

Conservare i dati in caso di spegnimento inatteso

- **Filesystem journaled.**
  Tenere un journal delle operazioni che si stanno per svolgere, svolgerle, cancellare il journal. Se il journal non è vuoto si possono ripetere (o annullare) le operazioni per arrivare a uno stato consistente.
  Questo approccio è usato da ext3, ext4, xfs, hfs+, ntfs,…

- **Log-based filesystem.**
  Non si sovrascrivono mai i dati precedenti ma si aggiungono solo. Serve però avere un processo di “pulizia” che elimina i dati non più raggiungibili.

- Simili ai log-based filesystem sono i filesystem copy-on-write, che copiano (senza sovrascrivere) i blocchi.