Implementazione del File System

Ivan Scagnetto

Università di Udine — Facoltà di Scienze MM.FF.NN.

A.A. 2008-2009

Copyright ©2000–04 Marino Miculan (miculan@dimi.uniud.it)

La copia letterale e la distribuzione di questa presentazione nella sua integrità sono permesse con qualsiasi mezzo, a condizione che questa nota sia riprodotta.

I dispositivi tipici per realizzare file system: dischi

- trasferimento a blocchi (tip. 512 byte, ma variabile)
- accesso diretto a tutta la superficie, sia in lettura che in scrittura
- dimensione finita

Struttura dei file system

programmi di applicazioni: applicativi, ma anche comandi (ls, dir, . . .)

file system logico: presenta i diversi file system come un'unica struttura; implementa i controlli di protezione

organizzazione dei file: controlla l'allocazione dei blocchi fisici e la loro corrispondenza con quelli logici. Effettua la traduzione da indirizzi logici a fisici.

file system di base: usa i driver per accedere ai blocchi fisici sull'appropriato dispositivo.

controllo dell'I/O: i driver dei dispositivi

dispositivi: i controller hardware dei dischi, nastri, ecc.

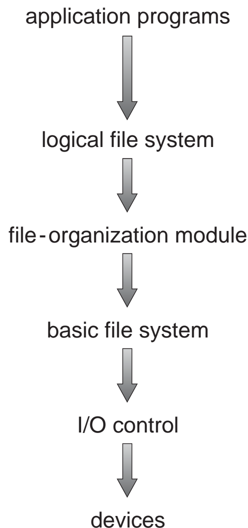

Tabella dei file aperti

- Per accedere ad un file è necessario conoscere informazioni riguardo la sua posizione, protezione, ...
- questi dati sono accessibili attraverso le directory
- per evitare continui accessi al disco, si mantiene in memoria una tabella dei file aperti. Ogni elemento descrive un file aperto (file control block)
  - Alla prima open, si caricano in memoria i metadati relativi al file aperto
  - Ogni operazione viene effettuata riferendosi al file control block in memoria
  - Quando il file viene chiuso da tutti i processi che vi accedevano, le informazioni vengono copiate su disco e il blocco deallocato
- Problemi di affidabilità (e.g., se manca la corrente...)

Mounting dei file system

- Ogni file system fisico, prima di essere utilizzabile, deve essere montato nel file system logico
- Il montaggio può avvenire
  - al boot, secondo regole implicite o configurabili
  - dinamicamente: supporti rimovibili, remoti, . . .
- Il punto di montaggio può essere
  - fissato (A:, C:, . . . sotto Windows, sulla scrivania sotto MacOS)
  - configurabile in qualsiasi punto del file system logico (Unix)
- Il kernel esamina il file system fisico per riconoscerne la struttura ed il tipo
- Prima di spegnere o rimuovere il media, il file system deve essere smontato (pena gravi inconsistenze!)

Allocazione contigua

Ogni file occupa un insieme di blocchi contigui sul disco

- Semplice: basta conoscere il blocco iniziale e la lunghezza
- L'accesso random è facile da implementare
- Frammentazione esterna. Problema di allocazione dinamica.
- I file non possono crescere (a meno di deframmentazione)
- Frammentazione interna se i file devono allocare tutto lo spazio che gli può servire a priori
- Traduzione dall'indirizzo logico a quello fisico (per blocchi da 512 byte):

$$LA/512 \begin{cases} Q \\ R \end{cases}$$

  - Il blocco da accedere = Q + blocco di partenza
  - Offset all'interno del blocco = R

Allocazione concatenata

Ogni file è una linked list di blocchi, che possono essere sparpagliati ovunque sul disco

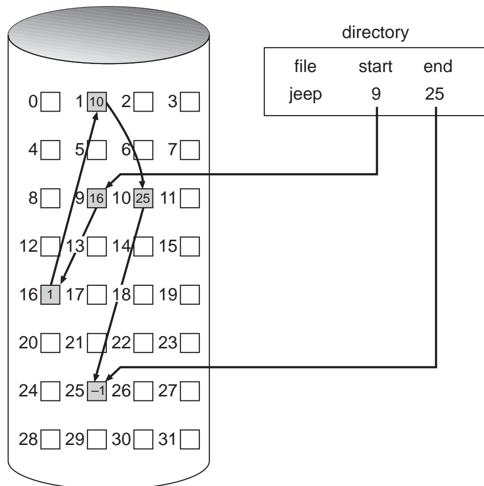

Allocazione concatenata

- Allocazione su richiesta; i blocchi vengono semplicemente collegati alla fine del file
- Semplice: basta sapere l'indirizzo del primo blocco
- Non c'è frammentazione esterna
- Bisogna gestire i blocchi liberi
- Non supporta l'accesso diretto (seek)
- Traduzione indirizzo logico:

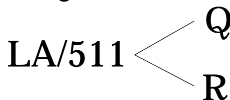

  - Il blocco da accedere è il Q-esimo della lista
  - Offset nel blocco = R + 1

Allocazione concatenata

Variante: *File-allocation table (FAT)* di MS-DOS e Windows. Mantiene la linked list in una struttura dedicata, all'inizio di ogni partizione

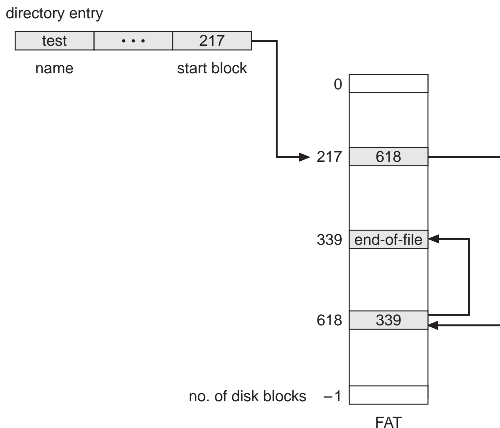

Allocazione indicizzata

Si mantengono tutti i puntatori ai blocchi di un file in una tabella indice.

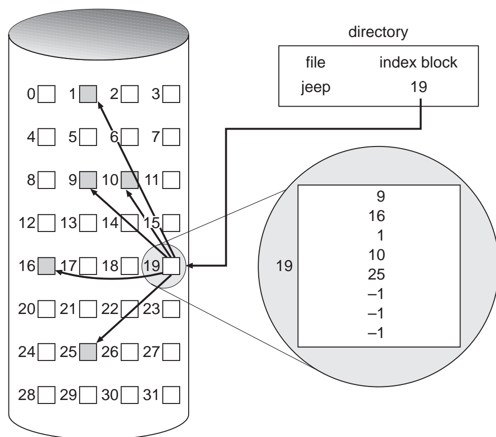

Allocazione indicizzata

- Supporta accesso random
- Allocazione dinamica senza frammentazione esterna
- Traduzione: file di max 256K word e blocchi di 512 word: serve 1 blocco per l'indice

$$LA/512 \begin{cases} Q \\ R \end{cases}$$

  - Q = offset nell'indice
  - R = offset nel blocco indicato dall'indice

Allocazione indicizzata

- Problema: come implementare il blocco indice
  - è una struttura supplementare: overhead ⇒ meglio piccolo
  - dobbiamo supportare anche file di grandi dimensioni ⇒ meglio grande
- Indice concatenato: l'indice è composto da blocchi concatenati. Nessun limite sulla lunghezza, maggiore costo di accesso.

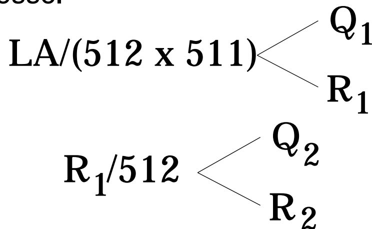

  - Q_1 = blocco dell'indice da accedere
  - Q_2 = offset all'interno del blocco dell'indice
  - R_2 = offset all'interno del blocco del file

Allocazione indicizzata

Indice a due (o più) livelli.

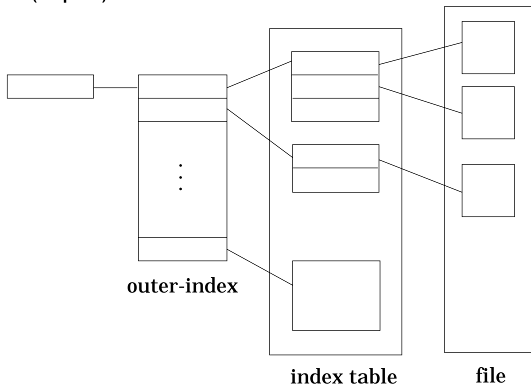

Dim. massima: con blocchi da 4K, si arriva a $(4096/4)^2 = 2^{20}$ blocchi $= 2^{32}B = 4GB$.

Allocazione indicizzata

- Con blocchi da 512 parole:

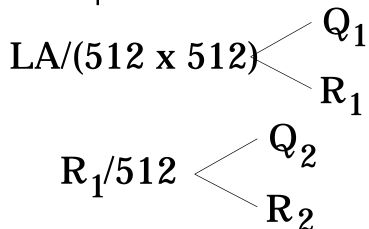

- Q_1 = offset nell'indice esterno
- Q_2 = offset nel blocco della tabella indice
- R_2 = offset nel blocco del file

Unix: Inodes

Un file in Unix è rappresentato da un inode (nodo indice): gli inode sono allocati in numero finito alla creazione del file system

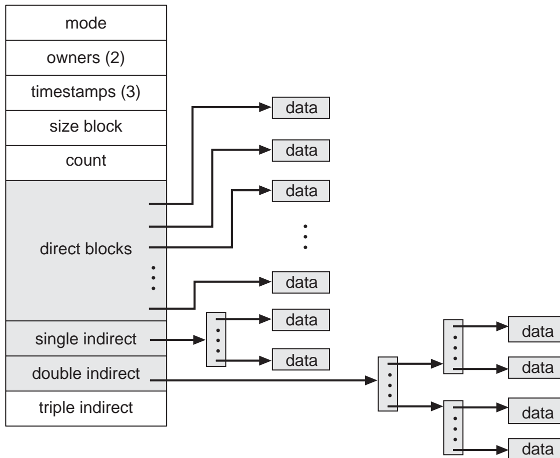

Unix: Inodes

Ogni inode contiene

- **Modo:** bit di accesso, di tipo e speciali del file
- **UID e GID** del possessore
- **Dimensione** del file in byte
- **Timestamp** di ultimo accesso (atime), di ultima modifica (mtime), di ultimo cambiamento dell'inode (ctime)
- **Numero di link** hard che puntano a questo inode
- **Blocchi diretti:** puntatori ai primi 12 blocchi del file
- **Primo indiretto:** indirizzo del blocco indice dei primi indiretti
- **Secondo indiretto:** indirizzo del blocco indice dei secondi indiretti
- **Terzo indiretto:** indirizzo del blocco indice dei terzi indiretti (mai usato!)

Inodes

- Gli indici indiretti vengono allocati su richiesta
- Accesso più veloce per file piccoli
- N. massimo di blocchi indirizzabile: con blocchi da 4K, puntatori da 4byte

$$\begin{aligned} L_{max} &= 12 + 1024 + 1024^2 + 1024^3 \\ &> 1024^3 = 2^{30} blk \\ &= 2^{42} byte = 4TB \end{aligned}$$

molto oltre le capacità dei sistemi a 32 bit.

Gestione dello spazio libero

I blocchi non utilizzati sono indicati da una lista di blocchi liberi — che spesso lista non è

- Vettore di bit (block map): 1 bit per ogni blocco

  0101110101010111111011000000101000000001011010101011

$$\text{bit}[i] = \begin{cases} 0 \Rightarrow \text{block}[i] \text{ occupato} \\ 1 \Rightarrow \text{block}[i] \text{ libero} \end{cases}$$

- Comodo per operazioni assembler di manipolazione dei bit
- Calcolo del numero del blocco
  (numero di bit per parola) $*$
  (numero di parole di valore 0) +
  offset del primo bit a 1

Gestione dello spazio libero

- La bit map consuma spazio. Esempio:
  block size = 2^{12} bytes
  disk size = 2^{35} bytes (32 gigabyte)
  $n = 2^{35}/2^{12} = 2^{23}$ bits = 2^{20} byte = 1M byte
- Facile trovare blocchi liberi contigui
- Alternativa: Linked list (free list)
  - Inefficiente - non facile trovare blocchi liberi contigui
  - Non c'è spreco di spazio.

Implementazione delle directory

Le directory sono essenziali per passare dal nome del file ai suoi attributi (anche necessari per reperire i blocchi dei dati).

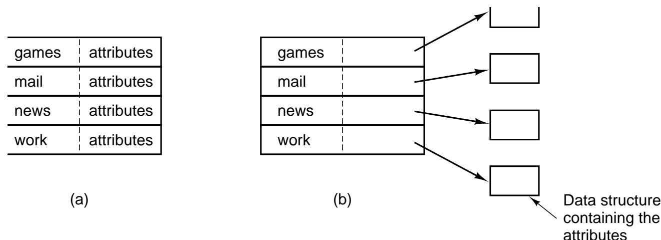

a) Gli attributi risiedono nelle entry stesse della directory (MS-DOS, Windows)
b) Gli attributi risiedono in strutture esterne (eg. inodes), e nelle directory ci sono solo i puntatori a tali strutture (UNIX)

Directory: a dimensioni fisse, o a heap

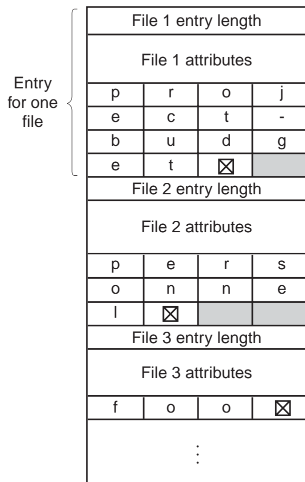

(a)

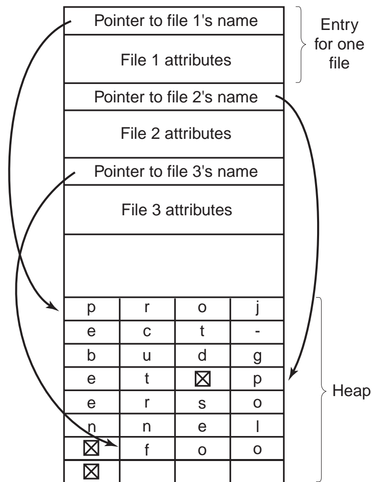

(b)

Directory: liste, hash, B-tree

- Lista lineare di file names con puntatori ai blocchi dati
  - semplice da implementare
  - lenta nella ricerca, inserimento e cancellazione di file
  - può essere migliorata mettendo le directory in cache in memoria
- Tabella hash: lista lineare con una struttura hash per l'accesso veloce
  - si entra nella hash con il nome del file
  - abbassa i tempi di accesso
  - bisogna gestire le *collisioni*: ad es., ogni entry è una lista
- B-tree: albero binario bilanciato
  - ricerca binaria
  - abbassa i tempi di accesso
  - bisogna mantenere il bilanciamento

Efficienza e performance

Dipende da

- algoritmi di allocazione spazio disco e gestione directory
- tipo di dati contenuti nelle directory
- grandezza dei blocchi
  - blocchi piccoli per aumentare l'efficienza (meno frammentazione interna)
  - blocchi grandi per aumentare le performance
  - e bisogna tenere conto anche della paginazione!

Sulla dimensione dei blocchi

Consideriamo questo caso: un disco con

- 131072 byte per traccia
- tempo di rotazione = 8.33 msec
- seek time = 10 msec

Il tempo per leggere un blocco di k byte è allora

$$10 + 4.165 + (k/131072) * 8.33$$

Sulla dimensione dei blocchi

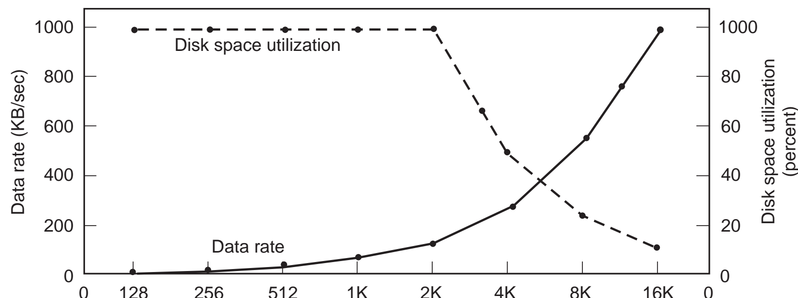

La mediana della lunghezza di un file Unix è circa 2KB.
Tipiche misure: 1K-4K (Linux, Unix); sotto Windows il cluster size spesso è imposto dalla FAT (anche se l'accesso ai file è assai più complicato).
UFS e derivati ammettono anche il fragment (tipicamente 1/4 del block size).

Migliorare le performance: caching

disk cache – usare memoria RAM per bufferizzare i blocchi più usati. Può essere

- sul controller: usato come buffer di traccia per ridurre la latenza a 0 (quasi)
- (gran) parte della memoria principale, prelevando pagine dalla free list. Può arrivare a riempire tutta la memoria RAM: “un byte non usato è un byte sprecato”.

Migliorare le performance: caching

I buffer sono organizzati in una coda con accesso hash

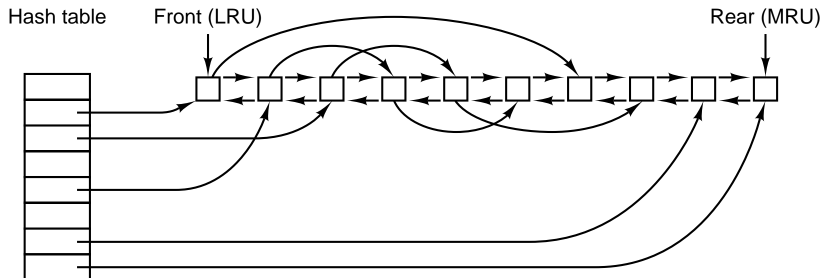

- La coda può essere gestita LRU, o CLOCK, ...
- Un blocco viene salvato su disco quando deve essere liberato dalla coda.
- Se blocchi critici vengono modificati ma non salvati mai (perché molto acceduti), si rischia l'inconsistenza in seguito ai crash.

Migliorare le performance: caching

- Variante di LRU: dividere i blocchi in categorie a seconda se
  - il blocco verrà riusato a breve? in tal caso, viene messo in fondo alla lista.
  - il blocco è critico per la consistenza del file system? (tutti i blocchi tranne quelli dati) allora ogni modifica viene immediatamente trasferita al disco.

Anche le modifiche ai blocchi dati vengono trasferite prima della deallocazione:

- asincrono: ogni 20-30 secondi (Unix, Windows)
- sincrono: ogni scrittura viene immediatamente trasferita anche al disco (write-through cache, DOS).

Altri accorgimenti

- *read-ahead*: leggere blocchi in cache prima che siano realmente richiesti.
  - Aumenta il throughput del device
  - Molto adatto a file che vengono letti in modo sequenziale; Inadatto per file ad accesso casuale (es. librerie)
  - Il file system può tenere traccia del modo di accesso dei file per migliorare le scelte.
- Ridurre il movimento del disco
  - durante la scrittura del file, sistemare vicini i blocchi a cui si accede di seguito (facile con bitmap per i blocchi liberi, meno facile con liste)

Altri accorgimenti

- Ridurre il movimento del disco
  - raggruppare (e leggere) i blocchi in gruppi (cluster)
  - collocare i blocchi con i metadati (inode, p.e.) presso i rispettivi dati

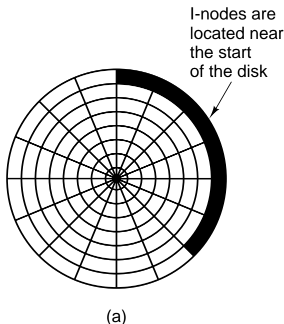

(a)

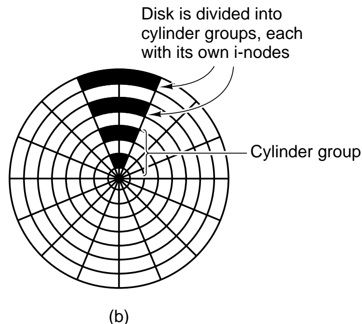

(b)

Affidabilità del file system

- I dispositivi di memoria di massa hanno un MTBF relativamente breve
- Inoltre i crash di sistema possono essere causa di perdita di informazioni in cache non ancora trasferite al supporto magnetico.
- Due tipi di affidabilità:
  - Affidabilità dei dati: avere la certezza che i dati salvati possano venir recuperati.
  - Affidabilità dei metadati: garantire che i metadati non vadano perduti/alterati (struttura del file system, bitmap dei blocchi liberi, directory, inodes. . .).
- Perdere dei dati è costoso; perdere dei metadati è critico: può comportare la perdita della consistenza del file system (spesso irreparabile e molto costoso).

Affidabilità dei dati

Possibili soluzioni per aumentare l'affidabilità dei dati

- Aumentare l'affidabilità dei dispositivi (es. RAID).
- Backup (automatico o manuale) dei dati dal disco ad altro supporto (altro disco, nastri, ...)
  - dump fisico: direttamente i blocchi del file system (veloce, ma difficilmente incrementale e non selettivo)
  - dump logico: porzioni del virtual file system (più selettivo, ma a volte troppo astratto (link, file con buchi...))

Recupero dei file perduti (o interi file system) dal backup: dall'amministratore, o direttamente dall'utente.

Consistenza del file system

- Alcuni blocchi contengono informazioni critiche sul file system (specialmente quelli contenenti metadati)
- Per motivi di efficienza, questi blocchi critici non sono sempre sincronizzati (a causa delle cache)
- Consistenza del file system: in seguito ad un crash, blocchi critici possono contenere informazioni incoerenti, sbagliate e contradditorie.
- Due approcci al problema della consistenza del file system:

  curare le inconsistenze dopo che si sono verificate, con programmi di controllo della consistenza (scandisk, fsck): usano la ridondanza dei metadati, cercando di risolvere le inconsistenze. Lenti, e non sempre funzionano.

  prevenire le inconsistenze: i journalled file system.

Journalled File System

Nei file system journalled (o journaling) si usano strutture e tecniche da DBMS (B+tree e "transazioni") per aumentare affidabilità (e velocità complessiva)

- Variazioni dei metadati (inodes, directories, bitmap, ...) sono scritti immediatamente in un'area a parte, il log o giornale, prima di essere effettuate.
- Dopo un crash, per ripristinare la consistenza dei metadati è sufficiente ripercorrere il log $\Rightarrow$ non serve il *fsck*!
- Adatti a situazioni mission-critical (alta affidabilità, minimi tempi di recovery) e grandi quantità di dati.
- Esempi di file system journalled:

  XFS (SGI, su IRIX e Linux): fino a $2^{64} = 16$ exabytes > 16 milioni TB
  JFS (IBM, su AIX e Linux): fino a $2^{55} = 32$ petabyte > 32 mila TB
  ReiserFS e EXT3 (su Linux): fino a 16TB e 4TB, rispettivamente

Esempio di layout di un disco fisico