ARCHITETTURA DI UN DBMS

- Finora abbiamo visto modelli di DBMS ad alto livello (livello *logico)*: e' il livello corretto per gli *utenti* del DB

- Un fattore importante nell'accettazione da parte dell'utente e' dato dalle prestazioni

- Le prestazioni del DBMS dipendono dall'efficienza delle strutture dati e dall'efficienza del sistema nell'operare su tali strutture dati

- Esistono varie strutture alternative per implementare un modello dei dati

- La scelta dalla strutture piu' efficienti dipende dal tipo di accessi che si eseguono sui dati

- Normalmente un DBMS ha le proprie strategie di implementazione di un modello dei dati; tuttavia l'utente (esperto) puo' influenzare le scelte fatte dal sistema

ARCHITETTURA DI UN DBMS

Un DBMS consiste di un numero di **componenti funzionali** che includono:

- il **file system**: gestisce l'allocazione dello spazio su disco e le strutture dati usate per rappresentare le informazioni memorizzate su disco
- il **buffer manager** e' responsabile per il trasferimento delle informazioni tra disco e main memory
- il **query parser** traduce i comandi del DDL e del DML in un formato interno (parse tree)
- l'**optimizer** trasforma una richiesta utente in una equivalente ma piu' efficiente
- l'**authorization and integrity manager** controlla che i vincoli di integrita' (per esempio le chiavi) siano verificati e controlla che gli utenti abbiano i diritti di accesso ai dati
- il **recovery manager** assicura che il DB rimanga in uno stato consistente a fronte di cadute del sistema
- il **concurrency controller** assicura che interazioni concorrenti procedano senza conflitti

ARCHITETTURA DI UN DBMS

Un DBMS contiene inoltre alcune strutture dati che includono:

- i file con i dati (cioe' i file per memorizzare il DB stesso)

- i file dei dati di sistema (che includono il dizionario dei dati e le autorizzazioni)

- indici (esempio B-tree o tabelle hash)

- dati statistici (esempio il numero di tuple in una relazione) che sono usati dallo strategy selector per determinare la strategia ottima di esecuzione

ARCHITETTURA DI UN DBMS

utente

query parser

optimizer

transazione utente

log

recovery manager

concurrency controller

tabella dei lock

buffer manager buffer (main memory)

file manager

disco

dati satistici

indici

dati utente dati di sistema

SUPPORTI DI MEMORIZZAZIONE

I dati memorizzati in una base di dati devono essere fisicamente memorizzati su un supporto fisico di memorizzazione

Memoria primaria

memoria principale (*main memory*) e memorie piu' piccole e piu' veloci

- i dati sono manipolati direttamente dalla CPU
- accesso veloce ai dati
- capacita' di memorizzazione limitata
- *volatile* (il contenuto e' perso se va via la corrente o si ha una caduta di sistema)

Memoria secondaria

Dischi magnetici, dischi ottici e nastri

- capacita' maggiore, costo inferiore e accesso piu' lento
- necessita' di trasferire i dati in memoria principale per elaborazione dalla CPU
- *non volatile*

SUPPORTI DI MEMORIZZAZIONE

Basi di dati in genere sono memorizzate su memoria secondaria (dischi magnetici)

- troppo grosse per risiedere in memoria principale
- maggiori garanzie di persistenza dei dati
- costo per unita' di memorizzazione decisamente inferiore

Dischi

- l'informazione e'memorizzata su una superficie del disco in cerchi concentrici di piccola ampiezza, ognuno con un diametro distinto, detti **tracce**
- per i dischi a piu' piatti, le tracce con lo stesso diametro sulle varie superfici sono dette un **cilindro**
- dati memorizzati su uno stesso cilindro possono essere recuperati molto piu' velocemente che non dati distribuiti su diversi cilindri

SUPPORTI DI MEMORIZZAZIONE
Dischi

- i dati sono trasferiti tra il disco e la memoria principale in unita' chiamate **blocchi**

- un blocco e' una sequenza di byte contigui memorizzati in una stessa traccia di un singolo cilindro

- la dimensione del blocco dipende dal sistema operativo

- il tempo di trasferimento di un blocco e' il tempo impiegato dalla testina per trasferire un blocco nel buffer, una volta posizionata all'inizio del blocco

- tale tempo e' molto piu' breve del tempo necessario per posizionare la testina all'inizio del blocco *(*tempo di *seek)*

ORGANIZZAZIONE DI FILE

- i dati sono generalmente memorizzati in forma di **record**

- un record e'costituito da un insieme di valori (*campi*) collegati

- -un **file** e' una sequenza di record

- file con record a lunghezza fissa se tutti i record memorizzati nel file hanno la stessa dimensione (in byte)

- file con record a lunghezza variabile sono pero' necessari per:

    - memorizzazione di tipi di record diversi nello stesso file
    - memorizzazione di tipi di record con campi di lunghezza variabile
    - memorizzazione di tipi di record con campi multivalore (es. basi di dati O-O o OR)

ORGANIZZAZIONE DI FILE

Organizzazione di record in blocchi

- Un file puo' essere visto come una collezione di record

- Tuttavia, poiche' i dati sono trasferiti in blocchi tra la MS e la MM, e' importante assegnare i record ai blocchi in modo tale che uno stesso blocco contenga record tra loro interrelati

- Se si riesce a memorizzare sullo stesso blocco record che sono spesso richiesti insieme si risparmiano accessi a disco

MAPPING DI RELAZIONI A FILE

- Per DBMS di piccole dimensioni (es. per PC) una soluzione spesso adottata e' di memorizzare ogni relazione in un file separato

- Per DBMS large scale una strategia frequente e' di allocare per il DBMS un unico grosso file, in cui sono memorizzate tutte le relazioni;
  la gestione di questo file e' lasciata al DBMS

MAPPING DI RELAZIONI A FILE
CLUSTERING

```
SELECT Imp#, Nome, Sede
FROM Impiegati, Dipartimenti
WHERE Impiegati.Dip# = Dipartimenti.Dip#
```

- una strategia di memorizzazione efficiente e' basata sul raggruppamento (clustering) delle tuple che hanno lo stesso valore dell'attributo di join

- il clustering puo' rendere inefficiente l'esecuzione di altre interrogazioni
  (es. **`SELECT * FROM Dipartimenti`**)

CLUSTERING

10	Edilizia Civile	1100	D1	7977		
7782	Neri	ingegnere	01-Giu-81	2,450.00	200.00	10
7839	Dare	ingegnere	17-Nov-81	2,600.00	300.00	10
7934	Milli	ingegnere	23-Gen-82	1,300.00	150.00	10
7977	Verdi	dirigente	10-Dic-80	3,000.00	?	10
20	Ricerche	2200	D1	7566		
7369	Rossi	ingegnere	17-Dic-80	1,600.00	500.00	20
7566	Rosi	dirigente	02-Apr-81	2,975.00	?	20
7788	Scotti	segretaria	09-Nov-81	800.00	?	20
7876	Adami	ingegnere	23-Set-81	1,100.00	500.00	20
7902	Fordi	segretaria	03-Dic-81	1,000.00	?	20
30	Edilizia Stradale	5100	D2	7698		
7499	Andrei	tecnico	20-Feb-81	800.00	?	30
7521	Bianchi	tecnico	20-Feb-81	800.00	100.00	30
7654	Martini	segretaria	28-Set-81	800.00	?	30
7698	Blacchi	dirigente	01-Mag-81	2,850.00	?	30
7844	Turni	tecnico	08-Set-81	1,500.00	?	30
7900	Gianni	ingegnere	03-Dic-81	1,950.00	?	30

STRUTTURE AUSILIARIE DI ACCESSO

- Spesso le interrogazioni accedono solo un piccolo sottoinsieme dei dati

- Per risolvere efficientemente le interrogazioni puo' essere utile allocare delle strutture ausiliarie che permettano di determinare direttamente i record che verificano una data query (senza scandire tutti i dati)

- I meccanismi piu' comunemente usati dai DBMS sono: indici, funzioni hash

- Ogni tecnica deve essere valutata in base a:
  - tempo di accesso
  - tempo di inserzione
  - tempo di cancellazione
  - occupazione di spazio

- Molto spesso e' preferibile aumentare l'occupazione di spazio se questo contribuisce a migliorare le prestazioni

- Si usa il termine *chiave di ricerca* per indicare un attributo o insiemi di attributi usati per la ricerca (questo concetto di chiave e' diverso dalla chiave primaria)

STRUTTURE AUSILIARIE DI ACCESSO

Una ricerca puo' essere effettuata per:

- **chiave primaria**: il valore della chiave identifica un unico record
  (es. il contribuente con codice fiscale GRRGNN69R48)

- **chiave secondaria**: il valore della chiave puo' identificare piu' record (es. i contribuenti di Genova)

- **intervallo di valori** (sia per chiave primaria che per secondaria)
  (es. i contribuenti con reddito compreso tra 60 e 90 milioni)

- combinazioni delle precedenti
  (es. i contribuenti di Genova e La Spezia con reddito compreso tra 60 e 90 milioni)

Per effettuare la ricerca in modo piu' efficiente si puo' pensare di mantenere il file ordinato secondo il valore di una chiave di ricerca

- il costo di ricerca e' logaritmico nel numero di blocchi del file (comunque elevato nel caso di file di grandi dimensioni)

- la ricerca su altri campi e' inefficiente

STRUTTURE AUSILIARIE DI ACCESSO

- **organizzazioni primarie**: impongono un criterio di allocazione dei dati (organizzazioni ad albero o hash)
- **organizzazioni secondarie**: uso di indici (separati dal file dei dati) normalmente organizzati ad albero

- in generale si hanno a disposizione piu' modalita' (cammini) di accesso ai dati

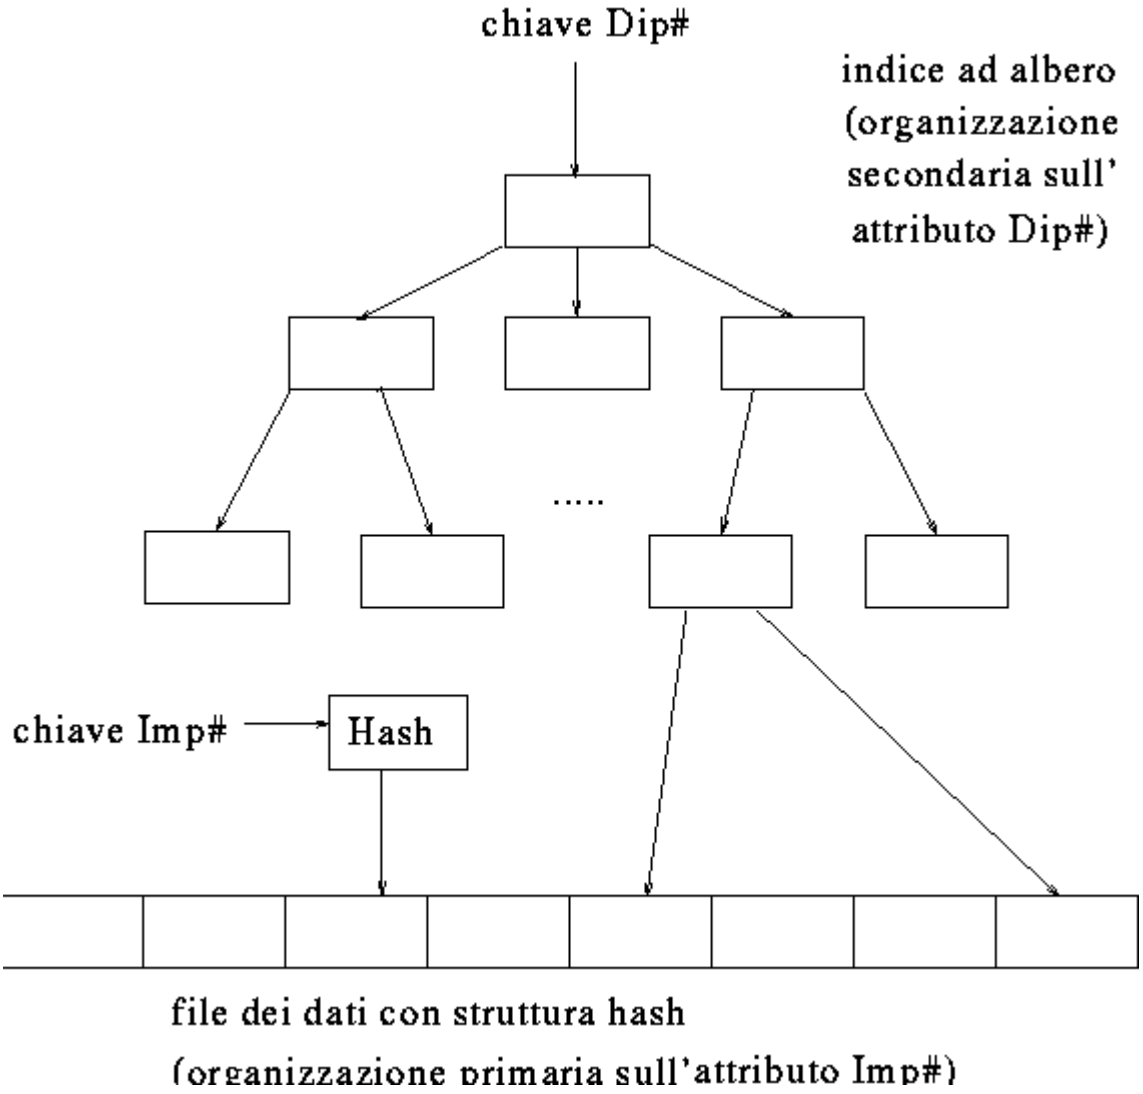

INDICI

idea base: associare al file dei dati una "tabella"nella quale l'entrata i-esima memorizza una coppia (k_i,r_i) dove:

- k_i e'un valore di chiave del campo su cui l'indice e' costruito
- r_i e'un riferimento al record (eventualmente il solo) con valore di chiave k_i

il riferimento puo' essere un indirizzo (logico o fisico) di record o di blocco

esempio:

file dei dati:

c5	c2	c11	c7	c4
0	8	16	32	48

indice:

chiave	indirizzo
c2	8
c4	48
c5	0
c7	32
c11	16

INDICI

- le diverse tecniche differiscono nel modo in cui organizzano l'insieme di coppie (k_i,r_i)

- vantaggio nell'uso di un indice: la chiave e' solo parte dell'informazione contenuta in un record, quindi l'indice occupa meno spazio del file dei dati

- un indice puo' comunque raggiungere notevoli dimensioni che determinano problemi di gestione simili a quelli del file dei dati (es. indice per un file di 50k record, in cui i valori di chiave sono stringhe di 20 byte e i puntatori sono di 4 byte, richiede circa 1,2Mb)

TIPI DI INDICE

Unicita' dei valori di chiave

- *indice su chiave primaria*: indice su un attributo che e' chiave primaria per la relazione
  (a ogni entrata dell'indice corrisponde un solo record)

- *indice su chiave secondaria*: indice su un attributo che non e' chiave primaria per la relazione
  (a ogni entrata dell'indice possono corrispondere piu' record)

TIPI DI INDICE

Numero di entrate dell'indice

- **Indice denso**: l'indice contiene un'entrata per ogni valore della chiave di ricerca nel file

- **Indice sparso**: le entrate dell'indice sono create solo per alcuni valori della chiave. Ricerca:

    - scansione fino a trovare il record con il piu' alto valore della chiave che sia minore o uguale al valore cercato

    - scansione sequenziale del file dei dati fino a trovare il record cercato

- Un indice denso consente una ricerca piu' veloce, ma impone maggiori costi di aggiornamento

- Un indice sparso e' meno efficiente ma impone minori costi di aggiornamento

- Poiche' molto spesso la strategia e' di minimizzare il numero di blocchi trasferiti, un compromesso spesso adottato consiste nell'avere una entrata nell'indice per ogni blocco

TIPI DI INDICE

Indice denso

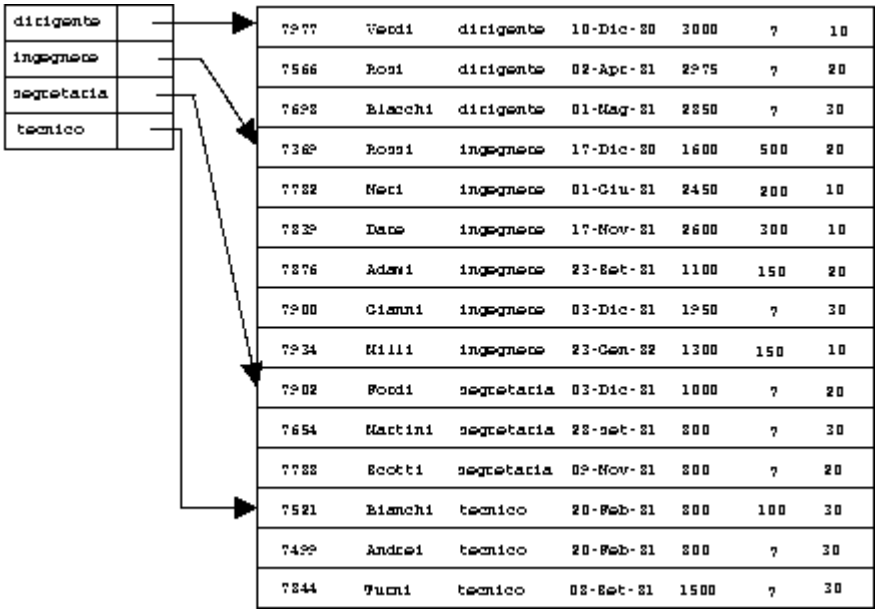

Indice sparso

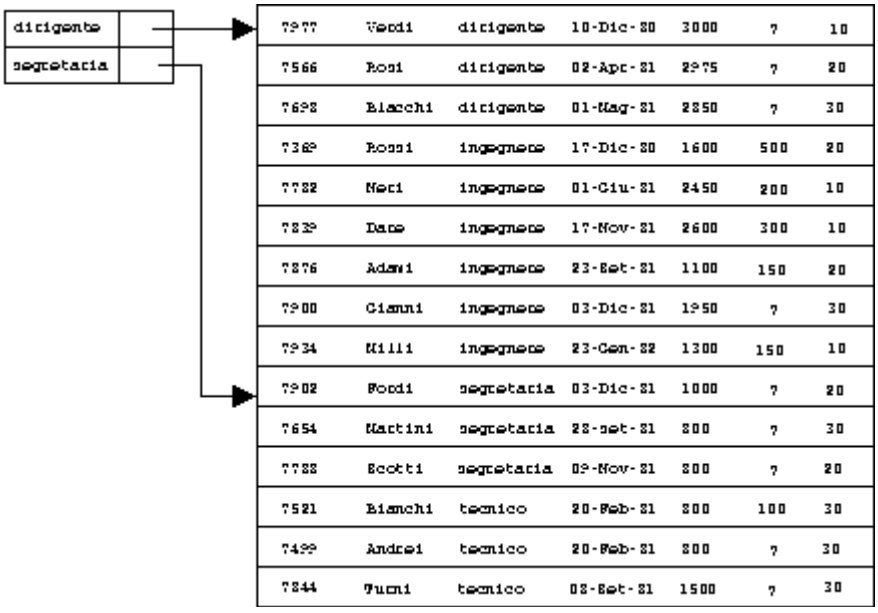

TIPI DI INDICE

Ordinamento dei record nel file dei dati

- *indice clusterizzato (o indice primario)*: indice sull'attributo secondo i cui valori il file dei dati e' mantenuto ordinato

- *indice non clusterizzato (o indice secondario)*: indice su un attributo secondo i cui valori il file dei dati non e' mantenuto ordinato

- l'uso di piu' indici secondari rende l'esecuzione delle interrogazioni piu' efficiente, ma rende piu' costosi gli aggiornamenti

- quando si esegue l'inserzione o la cancellazione di un record e' necessario modificare tutti gli indici allocati sul file

- gli indici secondari sono in genere di solito indici densi, mentre gli indici primari sono indici sparsi (notare che i record nel file dei dati sono ordinati in base al valore delle chiavi di ricerca dell'indice primario)

INDICI MULTILIVELLO

- Molto spesso un indice anche se sparso puo' essere di dimensioni notevoli

- Se l'indice e' piccolo puo' essere tenuto in MM

- Molto spesso pero' e' necessario tenerlo su disco e quindi la scansione dell'indice puo' richiedere parecchi trasferimenti di blocchi

- Se l'indice occupa un numero b di blocchi e si usa una ricerca binaria e' necessario accedere un numero di blocchi pari a $1+\log_2(b)$

- Quindi e' necessario trattare l'indice come un file ed allocare un indice sparso sull'indice stesso
  (indice *multilivello*)

INDICI MULTILIVELLO

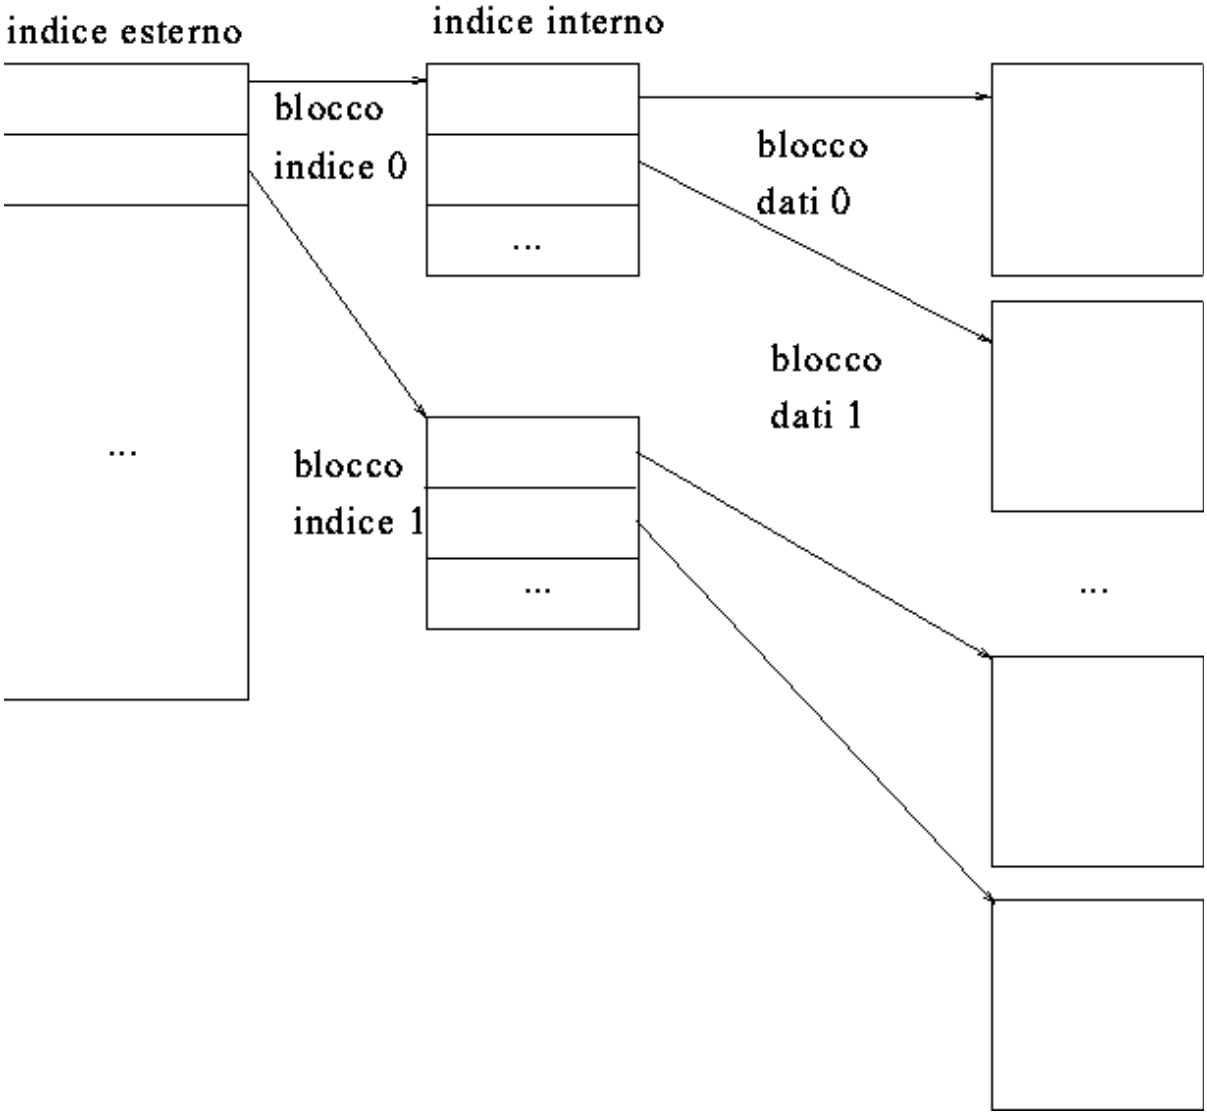

STRUTTURE AUSILIARIE DI ACCESSO

- Le strutture per MS differiscono da quelle per MM perche' si cerca di minimizzare e' il numero di **blocchi** acceduti (che determina il costo della ricerca)

- **Btree** e varianti (B+tree)
  - organizzazioni ad albero binario di ricerca bilanciato in cui ogni nodo corrisponde a un blocco (quindi memorizza molti valori di chiave e tipicamente ha centinaia di figli)
  - il costo delle operazioni e' lineare nell'altezza dell'albero (logaritmico negli elementi memorizzati), raramente si hanno alberi di altezza superiore a tre
  - B+tree: nodi fogli collegati a lista per facilitare la soluzione di interrogazioni di tipo range

- Organizzazioni **hash**
  - ogni indirizzo generato dalla funzione hash individua una pagina logica (blocco o bucket di blocchi)
  - il costo delle operazioni e' costante (se la struttura e' ben progettata)
  - nelle organizzazioni hash dinamiche il numero di pagine indirizzate dalla funzione hash varia dinamicamente per adattarsi al volume effettivo dei dati

STRUTTURE AUSILIARIE DI ACCESSO

- L'uso di una tecnica piuttosto che di un'altra dipende spesso dal tipo di query

- Se la maggior parte delle interrogazioni ha la forma:

select A1,A2,.....An **from** R **where** Ai=C

la tecnica hash e' preferibile

la scansione di un indice ha un costo proporzionale al logaritmo del numero di valori in R per Ai
in una struttura hash il tempo di ricerca e' indipendente dalla dimensione del DB

- Strutture ad albero sono preferibili se le interrogazioni usano condizioni di range

select A1,A2,.....An **from** R **where** C1 $\leq$Ai $\leq$C2

(infatti e' difficile determinare funzioni hash che mantengono l'ordine)

- Quasi tutti i sistemi usano strutture di indici ad albero perche' e' difficile prevedere a priori il tipo di interrogazioni

STRUTTURE DI ACCESSO PER APPLICAZIONI AVANZATE

- Metodi per l'accesso a testi e documenti

  In questo caso le interrogazioni non sono esatte come nei casi visti finora

  In generale si cerca di recuperare a seguito di una richiesta i documenti *probabilmente* rilevanti rispetto alla richiesta

  Organizzazioni piu' comunemente seguite:
  signature file, liste invertite sulle parole

- Metodi per applicazioni spaziali e geografiche

  Esempio: determinare tutte le citta' contenute in una data area geografica

  Organizzazioni piu' comunemente seguite:
  quad tree, grid file, R-trees

DEFINIZIONE DI CLUSTER E INDICI IN SQL

- La maggior parte dei DBMS relazionali fornisce varie primitive che permettono al progettista della base di dati di definire la configurazione fisica dei dati

- Queste primitive sono rese disponibili all'utente come comandi del linguaggio SQL

- I comandi piu' importanti sono il comando per la creazione di indici (**CREATE INDEX**), su una o piu' colonne di una relazione, e il comando per la creazione di cluster (**CREATE CLUSTER**)

- Un cluster permette di memorizzare fisicamente contigue le tuple di una o piu'relazioni che hanno lo stesso valore per una o piu'colonne, dette colonne del cluster

GESTIONE DEL BUFFER

- L'obiettivo principale delle strategie di memorizzazione e' di minimizzare gli accessi a disco
- Un altro modo e' di mantenere piu' blocchi possibile in MM
- Si usa un buffer che permette di tenere in MM copia di alcune pagine di disco
- Il buffer e' organizzato in pagine, che hanno la stessa dimensione dei blocchi
- Quando una pagina della MS e' presente nel buffer, il DBMS puo' effettuare le sue operazioni di lettura e scrittura direttamente su di essa
- I tempi di accesso alla MS sono dell'ordine di millesimi di secondo mentre quelli di accesso alla MM sono dell'ordine di milionesimi di secondo
- Accedere alle pagine nel buffer invece che alle corrispondenti pagine su disco influenza notevolmente le prestazioni

GESTIONE DEL BUFFER

- Il buffer manager di un DBMS usa alcune politiche di gestione che sono piu' sofisticate delle politiche usate nei SO; in particolare

  (i) le politiche di LRU non sempre sono le piu' adatte per i DBMS

  (ii) per motivi legati alla gestione del recovery in alcuni casi un blocco non puo' essere trasferito su disco (in tal caso il blocco e' detto *pinned)*

  (iii) per motivi legati alla gestione del recovery in alcuni casi e' necessario forzare un blocco su disco (anche se il suo spazio non e' stato reclamato)

GESTIONE DEL BUFFER

- Un DBMS e' in grado di predire meglio di un SO il tipo dei futuri riferimenti

Esempio: operazione di join

`Impiegati` |x| **`Dipartimenti`**

(assumendo che le due relazioni siano in due file diversi)

- relazione **`Impiegati`**
  - una volta che una tupla della relazione e' stata usata non e' piu' necessaria
  - non appena tutte le tuple di un blocco sono state esaminate il blocco non serve piu' (strategia *toss-immediate*)

- relazione **`Dipartimenti`**
  - il blocco piu' recentemente acceduto sara' riferito di nuovo solo dopo che tutti gli altri blocchi saranno stati esaminati
  - la strategia migliore per il file **`Dipartimenti`** e' di rimuovere l'ultimo blocco esaminato (strategia *most recently used* - MRU)
  - e' pero' necessario eseguire il *pin* del blocco correntemente esaminato fino a che si siano esaminate tutte le tuple; quindi si puo' rendere il blocco unpinned

ESECUZIONE DI INTERROGAZIONI

- Abbiamo visto finora come organizzare i dati in un DB

- Le decisioni sulle strutture da allocare sono determinate durante la progettazione fisica del DB

- La modifica di tali strutture in seguito puo' essere costosa

- Quindi quando una query e' presentata al sistema occorre determinare il modo piu' efficiente per eseguirla usando le strutture disponibili

- Per interrogazioni complesse esistono piu' strategie possibili

- Anche se il costo di determinare la strategia ottima puo' essere alto, il vantaggio in termini di efficienza che se ne ricava e' tale che in genere conviene eseguire l'ottimizzazione

PASSI NELL'ESECUZIONE DI UNA INTERROGAZIONE

- **Parsing**
  Viene controllata la correttezza sintattica della query e ne viene generata una rappresentazione interna (parse tree)

- **Trasformazioni algebriche**
  La query viene trasformata in una query equivalente ma piu' efficiente da eseguire (ci si basa sulle proprieta' dell'algebra relazionale)

- **Selezione della strategia**
  Si determina in modo preciso come la query sara' eseguita (per esempio si determina che indici si useranno)
  La scelta della strategia e' fatta principalmente in base al numero di accessi a disco

- **Esecuzione della strategia scelta**

E' possibile eseguire alcuni dei passi a tempo di compilazione del programma (DB2 e System R usano questa strategia) o a tempo di esecuzione (Oracle usa questa strategia)

PERCHE' OTTIMIZZARE LE INTERROGAZIONI?

- Consideriamo le relazioni

```
Studenti(MatrS,Nome,Ind,AltreInfo)
Esami(Corso,MatrS,Voto,Data)
```

- Supponiamo di voler trovare il nome degli studenti e la data degli esami per gli studenti che hanno sostenuto BD con 30

```
SELECT Nome,Data
FROM Studenti NATURAL JOIN Esami
WHERE Corso ='BD' AND Voto =30
```

- Consideriamo un database con 2.000 studenti e 20.000 esami, di cui 500 di BD e di questi solo 50 con 30 (consideriamo solo la scansione sequenziale delle relazioni)

- Se si fa il prodotto cartesiano delle due relazioni, si ottiene una relazione temporanea con 40.000.000 tuple, da queste si estraggono poi le 50 tuple desiderate (costo proporzionale a 120.000.000 accessi)

- Se si selezionano i 50 esami di BD con 30 e poi si fa il join di questa relazione temporanea con **`Studenti`** si ha un costo proporzionale a 120.050

TRASFORMAZIONI ALGEBRICHE

Basate su un'insieme di leggi di equivalenza tra espressioni dell'algebra, e su alcune regole per applicarle quali:

- Eseguire le operazioni di selezione il prima possibile

- Trasformare espressioni della forma $\sigma_{P1 \text{ AND } P2}(e)$ in
  $\sigma_{P1}(\sigma_{P2}(e))$

- In caso di join tra tre o piu' relazioni eseguire per primo il join che da' luogo alla relazione temporanea di dimensione minore

- Evitare i join che diventano prodotti cartesiani

- Anticipare le proiezioni in modo da eliminare gli attributi inutili dalle relazioni temporanee

  gli unici attributi da non eliminare sono quelli che
  - appaiono nel risultato della query
  - sono necessari in operazioni successive

SELEZIONE DELLA STRATEGIA
Profili delle relazioni

- La strategia scelta dipende dalla dimensione di ogni relazione e dalla distribuzione dei valori nelle varie colonne

- Per selezionare la strategia si utilizzano stime del costo di esecuzione, basate su **profili** delle relazioni

- Quindi normalmente i DBMS mantengono statistiche per ogni relazione memorizzata:

    1. n_r numero di tuple nella relazione r
    2. S_r dimensione di una tupla della relazione r in byte (per tuple a lunghezza fissa, altrimenti si usano valori medi)
    3. V(A, r) il numero di valori distinti che appaiono nella relazione r per l'attributo A
    4. SA dimensione in byte di ciascun attributo A

- Da tali profili si ottengono i profili delle relazioni temporanee ottenute applicando operazioni algebriche alle relazioni di base

    (ad es. il prodotto cartesiano r x s contiene $n_r * n_s$ tuple di dimensione $S_r + S_s$)

SELEZIONE DELLA STRATEGIA

- Il profilo delle relazioni che coinvolgono selezioni e join viene stimato sotto l'ipotesi che ogni valore appaia con la stessa probabilita'

- Si stima cioe' che $\sigma_{A=a}(r)$ selezioni un numero di tuple pari a $n_r/V(A, r)$

- La quantita' $1/V(A,r)$ e' detta *fattore di selettivita' del predicato*)

- In alcune situazioni non e' realistico assumere l'equiprobabilita' dei valori

- Per esempio se consideriamo la relazione Impiegati e l'attributo mansione, ci si puo' aspettare che ci siano piu' tecnici che dirigenti e quindi alcune mansioni appariranno con maggiore probabilita' di altre

- Tuttavia l'ipotesi di equiprobabilita' e' una buona approssimazione in molti casi

- Un'altra assunzione fondamentale (anche se non sempre realistica) e' la non correlazione tra valori di attributi diversi (es. mansione-stipendio)

SELEZIONE DELLA STRATEGIA

- Nei sistemi si usano in genere modelli dei costi piu' complicati, che tengono conto delle strategie di memorizzazione delle relazioni e della possibilita' di usare indici nelle interrogazioni

- Ad esempio, in aggiunta alle statistiche viste si considerano

  - per ogni relazione r: NPAG(r), numero delle pagine di r

  - per ogni indice I: NLEAF(I), numero di foglie dell'indice I

- Le statistiche sono aggiornate in seguito al caricamento delle relazioni o alla creazione di un indice (ma l'utente puo' richiedere esplicitamente il loro aggiornamento)

<u>Nota importante: granularita' dell'ottimizzazione</u>
L'ottimizzazione e' eseguita separatamente per ogni interrogazione pertanto e' bene formulare interrogazioni complesse e non scomporle in tante interrogazioni piu' semplici perche' cio' fa perdere i vantaggi dell'ottimizzazione

SELEZIONE DELLA STRATEGIA
Interrogazione su una singola relazione

Consideriamo il caso di voler utilizzare al piu' un indice per relazione (spesso e' cosi')

- *predicato di ricerca* (o *predicato risolubile*) e' un predicato per il quale:
  - esiste un indice utilizzabile per trovare le tuple che soddisfano il predicato
  - l'indice e' utile per ridurre il costo della verifica della condizione (es. C+D=1.000 o D <> 20 non sono predicati di ricerca)

- *fattore booleano* e' un predicato, che se falso, rende falsa tutta l'interrogazione; tutte le tuple del risultato quindi verificano i fattori booleani

Passi:

- per ogni predicato di ricerca fattore booleano si valuta il costo di accesso con l'impiego dell'indice, si sceglie quello con costo minimo
- si controlla la condizione sui dati

Nota: a volte puo' risultare piu' efficiente la scansione sequenziale

SELEZIONE DELLA STRATEGIA
Ordinamento delle tuple

- Se si usa un indice per accedere alle tuple della relazione, le tuple vengono restituite nell'ordine dei valori dell'attributo su cui e' costruito l'indice

- La query puo' richiedere che le tuple siano in un dato ordine (es. clausole ORDER BY, GROUP BY)
  Pertanto, prima di restituire le tuple all'utente, e' necessario ordinarle se non lo sono gia'

- In questo caso si devono distinguere tra vie di accesso (indici o scansione sequenziale) che producono l'ordinamento richiesto e vie di accesso che non lo producono

- Nel secondo caso e' necessario calcolare anche il costo di ordinamento della relazione risultato

SELEZIONE DELLA STRATEGIA
Join

- Il costo dell'esecuzione di un join e' influenzato da vari fattori:

  • l'ordine fisico delle tuple in una relazione
  • la presenza e il tipo di indici
    (*clusterizzati* vs *non-clusterizzati*)
  • il costo di costruire un indice temporaneo allo scopo di eseguire il join

- Diverse strategie possibili (iterazione semplice, iterazione orientata ai blocchi, merge-join, uso di indici, three-way join)

TRANSAZIONI

- Per mantenere le informazioni consistenti e' necessario controllare opportunamente le sequenze di accessi e aggiornamenti ai dati

- Tali sequenze sono dette **transazioni**

- Ogni transazione e'eseguita o completamente (cioe' effettua il *commit*), oppure per nulla (cioe' effettua l'*abort*) se si verifica un qualche errore (hardware o software) durante l'esecuzione

- Necessita' di garantire che le transazioni eseguite *concorrentemente* si comportino come se fossero state eseguite in sequenza

- Necessita' di tecniche per r*ipristinare* uno stato corretto della base di dati a fronte di malfunzionamenti di sistema.

TRANSAZIONI: CONCETTI DI BASE

- Gli utenti interagiscono con la base di dati attraverso programmi applicativi ai quali viene dato il nome di transazioni

- Una transazione e' un insieme parzialmente ordinato di operazioni di lettura e scrittura; essa costituisce l'effetto dell'esecuzione di programmi che effettuano le funzioni desiderate dagli utenti

- L'insieme di operazioni che costituiscono una transazione deve soddisfare alcune proprieta', note come proprieta' **ACID**:

    - Atomicita'
    - Consistenza
    - Isolamento
    - Durabilita'

TRANSAZIONI

Atomicita'

- e' detta anche proprieta' tutto-o-niente

- tutte le operazioni di una transazione devono essere trattate come una singola unita': o vengono eseguite tutte, oppure non ne viene eseguita alcuna

- l'atomicita' delle transazioni e' assicurata dal sottosistema di *ripristino* (*recovery*)

Consistenza

- una transazione deve agire sulla base di dati in modo corretto

- se viene eseguita su una base di dati in assenza di altre transazioni, la transazione trasforma la base di dati da uno stato consistente (cioe' che riflette lo stato reale del mondo che la base di dati deve modellare) ad un altro stato ancora consistente

- l'esecuzione di un insieme di transazioni corrette e concorrenti deve a sua volta mantenere consistente la base di dati

- il sottosistema di *controllo della concorrenza* (*concurrency control*) sincronizzale transazioni concorrenti in modo da assicurare esecuzioni concorrenti libere da interferenze

TRANSAZIONI

Isolamento

- ogni transazione deve sempre osservare una base di dati consistente, cioe', non puo' leggere risultati intermedi di altre transazioni

- la proprieta' di isolamento e' assicurata dal sottosistema di controllo della concorrenza che isola gli effetti di una transazione fino alla sua terminazione

Durabilita' (**persistenza**)

- i risultati di una transazione terminata con successo devono essere resi permanenti nella base di dati nonostante possibili malfunzionamenti del sistema

- la persistenza e' assicurata dal sottosistema di ripristino

- tale sottosistema uo' inoltre fornire misure addizionali, quali back-up su supporti diversi e journaling elle transazioni, per garantire la durabilita' anche a fronte di guasti ai dispositivi i memorizzazione

TRANSAZIONI: PROPRIETA' ACID

Le proprieta' ACID vengono assicurate utilizzando due insiemi distinti di algoritmi o protocolli, che assicurano:

- **l'atomicita' dell'esecuzione**
    - mantenere la consistenza globale della base di dati e quindi assicurare la proprieta' di consistenza delle transazioni (anche concorrenti)
    - protocolli di *controllo della concorrenza*
- **l'atomicita' del fallimento**
    - assicura l'atomicita', l'isolamento e la persistenza
    - protocolli di *ripristino*

TRANSAZIONI FLAT

- Facciamo riferimento al modello di transazioni piu' semplice (*transazioni flat*), che prevede un solo livello di controllo a cui appartengono tutte le transazioni eseguite (e' il modello usato nei DBMS commerciali)

- Tutte le istruzioni eseguite devono essere contenute tra le istruzioni **`BeginWork`** e **`CommitWork`**

    - l'istruzione **`BeginWork`** dichiara l'inizio di una transazione flat

    - l'istruzione **`CommitWork`** e' invocata per indicare che il sistema ha raggiunto un nuovo stato consistente

- La transazione puo' terminare la propria esecuzione con successo (*commit*) e rendere definitivi i cambiamenti prodotti sulla base di dati dalle istruzioni eseguite tra **`BeginWork`** e **`CommitWork`**, oppure sara' disfatta (cioe' i suoi effetti saranno annullati) e tutti gli aggiornamenti eseguiti andranno persi (*abort*)

- In questo caso, si dice che viene eseguito il *rollback* della transazione

TRANSAZIONI FLAT

- i vari DBMS forniscono specifiche istruzioni SQL per supportare l'uso di transazioni flat

- tali istruzioni sono invocate all'interno di programmi applicativi e consentono al programmatore di identificare l'inizio e la fine di una transazione

- l'istruzione

  `exec sql connect :user_name identified by :user_pws`

  (cioe' l'istruzione di connessione) avvia la transazione, cioe' implementa la primitiva **`BeginWork`**

- l'istruzione **`exec sql commit work`** esegue il commit di una transazione

- l'istruzione **`exec sql rollback`** esegue il rollback di una transazione

CONTROLLO DELLA CONCORRENZA

Scopo:
garantire l'integrita'della base di dati in presenza di accessi concorrenti da parte di piu' utenti

necessita' di sincronizzare le transazioni eseguite concorrentemente

Esempio di problema:

- base di dati che organizza le informazioni sui conti dei clienti di una banca

- il sig. Rossi e' titolare di due conti: un conto corrente (intestato anche alla sig.ra Rossi) e un libretto di risparmio, i cui saldi sono Lit. 100.000 e Lit. 1.000.000

- con la transazione T1 il sig. Rossi trasferisce Lit. 150.000 dal libretto di risparmio al conto corrente

- contemporaneamente con la transazione T2 la sig.ra Rossi deposita Lit.500.000 sul conto corrente

CONTROLLO DELLA CONCORRENZA

Esempio

T1	T2
Read(Lr)	
Lr = Lr – 150000	
	Read(Cc)
Write(Lr)	
	Cc = Cc + 500000
Read(Cc)	
	Write(Cc)
	Commit
Cc = Cc + 150000	
Write(Cc)	
Commit	

La somma depositata da T2 e' persa (*lost update*)
e non si ottiene l'effetto voluto sulla base di dati

- l'esecuzione concorrente di piu' transazioni genera un'alternanza di computazioni da parte delle varie transazioni, detta *interleaving*

- l'interleaving tra le transazioni T1 e T2 nell'esempio produce uno stato della base di dati scorretto; si sarebbe ottenuto uno stato corretto se ciascuna transazione fosse stata eseguita da sola o se le due transazioni fossero state eseguite l'una dopo l'altra, consecutivamente

LOCK

- **idea base:** ritardare l'esecuzione di operazioni in conflitto imponendo che le transazioni pongano dei blocchi (*lock*) sui dati per poter effettuare operazioni di lettura e scrittura

- due operazioni si dicono in conflitto se operano sullo stesso dato e almeno una delle due e' un'operazione di scrittura

- una transazione puo' accedere ad un dato solo se ha un lock su quel dato

- due tipi di lock:

  - **shared** se una transazione T ha ottenuto un lock con modalita' shared (condivisa) sul dato Q, allora T puo' leggere questo dato ma non puo' modificarlo

  - **exclusive** se una transazione T ha ottenuto un lock con modalita' exclusive (esclusiva) sul dato Q, allora T puo' sia leggere che modificare Q

- richiesta di lock (esclusivo, condiviso) sul dato Q: **`Ls(Q)`**, **`Lx(Q)`**

- rilascio di lock sul dato Q: **`Un(Q)`**

LOCK

matrice di compatibilita' dei lock:

	Shared	**Exclusive**
Shared	S	N
Exclusive	N	N

se Ti richiede un lock di modalita' A sul dato Q su cui Tj (Ti ≠Tj) possiede un lock di modalita' B, a Ti puo' essere concesso un lock su Q se il lock di modalita' A e' **compatibile** con il lock di modalita' B.

ogni transazione deve effettuare richieste di lock e unlock in due fasi distinte:

- *fase di acquisizione* in cui una transazione puo' ottenere dei lock, ma non puo'rilasciarne

- *fase di rilascio* in cui una transazione puo' rilasciare dei lock, ma non puo' ottenerne di nuovi

inizialmente, una transazione si trova nella fase di acquisizione e acquisisce i lock necessari

non appena la transazione rilascia un lock, inizia la fase di rilascio e non puo' piu' essere richiesto alcun lock

PROTOCOLLO TWO-PHASE LOCKING

- il protocollo di two-phase locking visto assicura che le esecuzioni concorrenti di transazioni corrette non producano stati inconsistenti, ma puo' provocare **deadlock**

- per aumentare il grado di parallelismo viene consentito l'uso di **conversioni**:

  uno shared lock puo' essere promosso a exclusive lock e un exclusive lock puo' essere regredito ad uno shared lock

- la promozione di lock puo' avvenire solo durante la fase di acquisizione, la regressione solo durante la fase di rilascio

- esistono anche altri meccanismi di controllo della concorrenza, ma quello basato sui lock e' il piu' utilizzato

GESTIONE DEL RIPRISTINO

Tre principali tipi di malfunzionamenti:

- **malfunzionamenti del disco:** le informazioni residenti su disco vengono perse (rottura della testina, errori durante il trasferimento dei dati)

- **malfunzionamenti di alimentazione:** le informazioni memorizzate in memoria centrale e nei registri vengono perse

- **errori nel software:** si possono generare risultati scorretti e il sistema potrebbe essere in uno stato inconsistente (errori logici ed errori di sistema)

Il **sottosistema di recovery** (ripristino) deve identificare i malfunzionamenti e ripristinare la base di dati allo stato (consistente) precedente il malfunzionamento

CLASSIFICAZIONE DELLE MEMORIE

- **memoria volatile** le informazioni contenute vengono perse in caso di cadute di sistema

  esempi: memoria principale e cache

- **memoria non volatile** le informazioni contenute sopravvivono a cadute di sistema, possono pero' essere perse a causa di altri malfunzionamenti

  esempi: disco e nastri magnetici

- **memoria stabile** le informazioni contenute non possono essere perse (astrazione teorica)

  se ne implementano approssimazioni, duplicando le informazioni in diverse memorie non volatili con probabilita' di fallimento indipendenti

MODELLO ASTRATTO PER L'ESECUZIONE DI TRANSAZIONI

una transazione e' sempre in uno dei seguenti stati:

- **active:** lo stato iniziale
- **partially committed:** lo stato raggiunto dopo che e' stata eseguita l'ultima istruzione
- **failed:** lo stato raggiunto dopo aver determinato che l'esecuzione non puo' procedere normalmente
- **aborted:** lo stato raggiunto dopo che la transazione ha subito un rollback e la base di dati e' stata ripristinata allo stato precedente l'inizio della transazione
- **committed:** dopo il completamento con successo

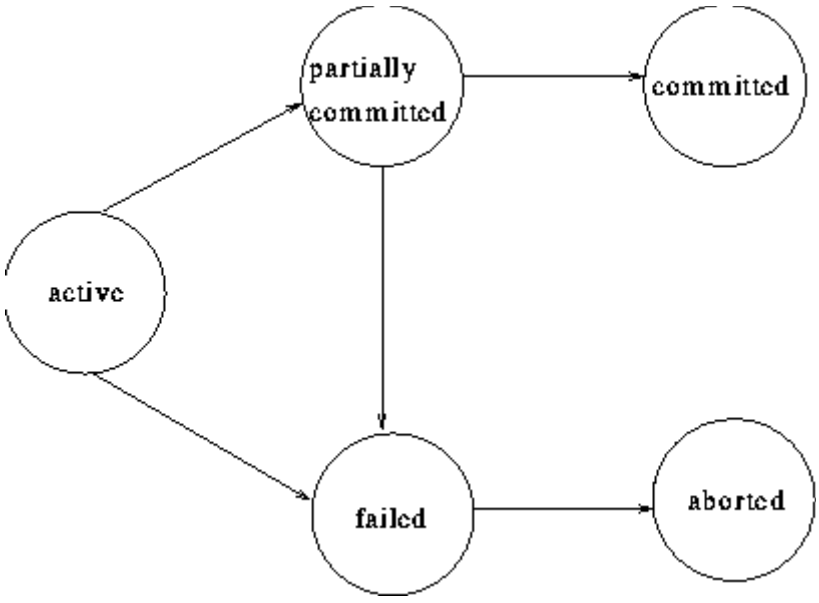

MODELLO ASTRATTO PER L'ESECUZIONE DI TRANSAZIONI

e' importante che una transazione non effettui *scritture esterne osservabili* (cioe' scritture che non possono essere "cancellate", ad es. su terminale o stampante) prima di entrare nello stato di commit

dopo il rollback di una transazione, il sistema ha due possibilita':

rieseguire la transazione ha senso solo se la transazione e' stata abortita a seguito di errori software o hardware non dipendenti dalla logica interna della transazione

eliminare la transazione se si verificano degli errori interni che possono essere corretti solo riscrivendo il programma applicativo

GESTIONE DEL RIPRISTINO: ESEMPIO

T transazione che trasferisce Lit. 100000 dal conto A al conto B

A = Lit. 1000000, B = Lit. 15000000

dopo la modifica di A e prima della modifica di B, si verifica una caduta di sistema e i contenuti della memoria vengono persi

- se si riesegue T: stato (inconsistente) in cui A = Lit. 800000 e B = Lit. 15.100000

- se non si riesegue T : stato corrente (inconsistente) in cui A = Lit. 900000 e B = Lit. 15000000

in entrambi i casi lo stato risultante e' inconsistente

il problema e' causato dal fatto di avere modificato la base di dati prima di avere la certezza che la transazione abbia terminato con successo

MECCANISMI DI RECOVERY CON LOG

- durante l'esecuzione di una transazione tutte le operazioni di scrittura sono registrate in un particolare file gestito dal sistema, detto **file di log**

- concettualmente, il log puo' essere pensato come un file sequenziale, nell'implementazione effettiva possono essere usati piu' file fisici

- ad ogni record inserito nel log viene attribuito un identificatore unico (LSN, log sequence number o numero di sequenza di log) che in genere e' l'indirizzo logico del record

- la versione non volatile del log e' memorizzata su memoria stabile

- i record di log sono memorizzati in un primo momento solo nei buffer dei file di log nella memoria volatile

- prima di cominciare il commit, tutti i record di log fino ad un certo punto, identificato da un LSN, vengono scritti su memoria stabile (il log viene *forzato* fino a quel LSN)

- tramite il log, il sistema puo' gestire qualsiasi malfunzionamento che non implichi la perdita di informazioni contenute in memoria non volatile

LOG INCREMENTALE CON MODIFICHE IMMEDIATE

- gli aggiornamenti sono effettuati sulla base di dati e un log incrementale tiene traccia di tutti i cambiamenti; tali informazioni sono usate per riportare la base di dati allo stato consistente precedente in caso di malfunzionamento

durante l'esecuzione di una transazione Ti:

- prima che Ti cominci la propria esecuzione viene scritto nel log il record <Ti start>

- ogni operazione di scrittura **write[x]** e' preceduta dalla scrittura un record di log della forma: <Ti, x, vecchio valore, nuovo valore >

- quando Ti entra in stato partially committed, viene scritto nel log il record <Ti commit>

non si puo' aggiornare effettivamente la base di dati prima che il corrispondente record di log sia scritto in memoria stabile

LOG INCREMENTALE CON MODIFICHE IMMEDIATE

due procedure di ripristino:

- **undo(Ti):** ripristina i valori di tutti i dati aggiornati da Ti ai vecchi valori

- **redo(Ti):** pone il valore di tutti i dati aggiornati da Ti ai nuovi valori

entrambe devono essere idempotenti

a seguito di un malfunzionamento:

- Ti e' disfatta se il log contiene <Ti start>, ma non <Ti commit>

- Ti e' rieseguita se il log contiene sia <Ti start> che <Ti commit>

LOG INCREMENTALE CON MODIFICHE IMMEDIATE – ESEMPIO

T1	T2
Read(Lr)	Read(Cc2)
Lr = Lr –1500000	Cc2 = Cc2 – 200000
Write(Lr)	Write(Cc2)
Read(Cc1)	commit
Cc1 = Cc1 + 150000	
Write(Cc1)	
Commit	

Esecuzione sequenziale T1; T2

Stato iniziale: Lr = 500.000, Cc1 = 600.000, Cc2 = 800.000

contenuto del log al termine dell'esecuzione delle due transazioni:
< T_1, start >
< T_1, Lr,350000 >
< T_1, Cc1, 750000 >
< T_1, commit >
< T_2, start >
< T_2, Cc2, 600000 >
< T_2, commit >

LOG INCREMENTALE CON MODIFICHE IMMEDIATE – ESEMPIO

se si verifica un crash subito dopo aver scritto su memoria stabile il record di log per l'operazione Write Cc1, lo stato del log al momento del crash e' il seguente:
< T_1, start >
< T_1, Lr,500000,350000 >
< T_1, Cc1, 600000,750000 >

si esegue l'azione di undo(T1), il nuovo stato dei dati e':
Lr = 500000 Cc1 = 600000 Cc2 = 800000

se si verifica un crash subito dopo aver scritto su memoria stabile il record di log per l'operazione Write Cc2, lo stato del log al momento del crash e' il seguente:
< T_1, start >
< T_1, Lr,500000,350000 >
< T_1, Cc1, 600000,750000 >
< T_1, commit >
< T_2, start >
< T_2, Cc2, 800000,600000 >

viene effettuato redo(T1) e undo(T2), lo stato della base di dati diventa:

Lr = 350000 Cc1 = 750000 Cc2 = 800000

LIVELLI DI ISOLAMENTO

grado 0 *chaos*: non consente che piu' transazioni aggiornino simultaneamente un dato

grado 1 *browse:* non consente la sovrascrittura di dati aggiornati da transazioni che non hanno effettuato il commit

grado 2 *cursor stability*: 1 + impone alle transazioni di leggere solo i dati che sono stati aggiornati da transazioni che hanno effettuato il commit

grado 3 *repeatable reads:* una transazione che vuole leggere/scrivere un dato deve attendere il completamento di tutte le altre transazioni che hanno precedentemente letto/scritto quel dato

fornisce un isolamento completo