

Basi di Dati: Strutture ed Algoritmi

Soluzione degli Appelli del 2002

A cura di: Giacomo Del Rio

Appello del 10.1.2002

1. Si consideri la relazione:

Impiegati(Codice, Nome, AnnoNascita, Dipartimento)

Per le seguenti interrogazioni si dia un piano di accesso e si stimi il costo considerando due casi: il primo con l'interrogazione nel modo in cui è scritta e il secondo riscrivendo l'interrogazione in modo da trovare un piano migliore:

a) Esiste un indice a B^+ -albero su AnnoNascita:

```
SELECT    Dipartimento
FROM      Impiegati
WHERE     AnnoNascita = 1960 OR AnnoNascita = 1970 ;
```

b) Esiste un indice a B^+ -albero su AnnoNascita:

```
SELECT    Dipartimento
FROM      Impiegati
WHERE     AnnoNascita < 1970 AND AnnoNascita > 1968 ;
```

c) Esiste un indice a B^+ -albero su AnnoNascita:

```
SELECT    Dipartimento
FROM      Impiegati
WHERE     2*AnnoNascita = 3920;
```

d) Non esistono indici:

```
SELECT    Dipartimento, AVG(AnnoNascita)
FROM      Impiegati
GROUP BY  Dipartimento
HAVING    Dipartimento = 20;
```

e) Si consideri anche la tabella

Dipartimenti(Numero, NomeD, Indirizzo, Telefono, Direttore)

in cui Direttore è una chiave esterna per Impiegati, con chiave primaria Codice, e possono esistere dipartimenti privi di direttori:

```
SELECT    Codice
FROM      Impiegati, Dipartimenti
WHERE     Codice = Direttore;
```

2. Si considerino le transazioni:

$$T_1 = \{r_1[A], w_1[A], r_1[B], w_1[B]\},$$

$$T_2 = \{r_2[B], r_2[A], w_2[A], w_2[B]\}$$

Si supponga che il serializzatore aggiunga le richieste di blocco esclusivo come segue:

$$T_1 = \{wl_1(A), r_1[A], w_1[A], wl_1(B), r_1[B], w_1[B], commit, wu_1(A), wu_1(B)\}$$

$$T_2 = \{wl_2(B), r_2[B], wl_2(A), r_2[A], w_2[A], w_2[B], commit, wu_2(A), wu_2(B)\}$$

Supponendo che le transazioni vengano eseguite concorrentemente, si risponda alle seguenti domande (giustificando le risposte):

- La storia prodotta è c-serializzabile?
- Può verificarsi uno stallo? Supponendo che parta prima T_1 , quale transazione riparte se si adotta il protocollo di prevenzione dello stallo *wait-die*?
- Può verificarsi una cascata di abort?

Si supponga che il serializzatore aggiunga le richieste di blocco esclusivo in questo altro modo:

$$T_1 = \{wl_1(A), r_1[A], w_1[A], wl_1(B), wu_1(A), r_1[B], w_1[B], wu_1(B)\}$$

$$T_2 = \{wl_2(A), wl_2(B), r_2[B], r_2[A], w_2[A], wu_2(A), w_2[B], wu_2[B]\}$$


- La storia prodotta è c-serializzabile?
- Può verificarsi uno stallo? Supponendo che parta prima T_1 , quale transazione riparte se si adotta il protocollo di prevenzione dello stallo *wound-wait*?
- Può verificarsi una cascata di abort?

3. Spiegare come viene eseguito dal gestore del buffer il comando di lettura di una pagina. Quando il gestore del buffer scrive una pagina nella memoria permanente?

Soluzione Appello del 10.1.2002

Esercizio 1

a) *Normale*:




$$C_{TS} = N_{pag}(Impiegati)$$

Riscritta:

```

SELECT Dipartimento
FROM Impiegati
WHERE AnnoNascita = 1960
UNION ALL
SELECT Dipartimento
FROM Impiegati
WHERE AnnoNascita = 1970
  
```




$$C_{IF} = C_I + C_D = f_s(AnnoNascita = 1970) \times N_{leaf}(IdxAN) + \Phi\left(\frac{N_{reg}(Impiegati)}{N_{key}(AnnoNascita)}, N_{pag}(Impiegati)\right)$$

$$C_{UA} = 2 \times C_{IF}$$

In questo caso è possibile sfruttare l'operatore UnionAll in quanto i due insiemi di record ritornati dagli operandi sono disgiunti.

b) *Normale*:



$$C_{IF} = C_I + C_D = f_s(\text{AnnoNascita} < 1970) \times N_{leaf}(\text{IdxAN}) + f_s(\text{AnnoNascita} < 1970) \times N_{key}(\text{IdxAN}) \times \Phi\left(\frac{N_{reg}(\text{Impiegati})}{N_{key}(\text{AnnoNascita})}, N_{pag}(\text{Impiegati})\right)$$

Riscritta:


```

SELECT  Dipartimento
FROM    Impiegati
WHERE   AnnoNascita = 1969
  
```



$$C_{IF} = C_I + C_D = f_s(\text{AnnoNascita} = 1969) \times N_{leaf}(\text{IdxAN}) + f_s(\text{AnnoNascita} = 1969) \times \Phi\left(\frac{N_{reg}(\text{Impiegati})}{N_{key}(\text{AnnoNascita})}, N_{pag}(\text{Impiegati})\right)$$

c) *Normale*:



$$C_{TS} = N_{pag}(\text{Impiegati})$$

Riscritta:


```
SELECT Dipartimento
FROM Impiegati
WHERE AnnoNascita = 1960
```



$$C_{IF} = C_I + C_D = f_s(\text{AnnoNascita} = 1969) \times N_{leaf}(\text{IdxAN}) + f_s(\text{AnnoNascita} = 1969) \times \Phi\left(\frac{N_{reg}(\text{Impiegati})}{N_{key}(\text{AnnoNascita})}, N_{pag}(\text{Impiegati})\right)$$

Non tutti gli ottimizzatori sono in grado di riscrivere la condizione in modo da poter utilizzare un indice.


d) *Normale:*



$$C_{SS} = 5 \times N_{pag}(\text{Impiegati})$$

Riscritta:


```
SELECT Dipartimento, AVG(AnnoNascita)
FROM Impiegati
WHERE Dipartimento = 20
GROUP BY Dipartimento;
```



$$C_{TS} = N_{pag}(\text{Impiegati})$$

La coppia Group By-Having dell'interrogazione originale si limitava a considerare il gruppo dei record con codice dipartimento uguale a 20; questo può essere fatto in maniera più efficiente con una restrizione. Inoltre, poichè filtrare su una condizione di uguaglianza equivale anche ad ordinare sull'attributo della condizione, non è necessario ordinare i dati sui quali opera il GroupBy.

e) *Normale:*




$$C_{PNL} = N_{pag}(Impiegati) + N_{pag}(Impiegati) \times N_{pag}(Dipartimenti)$$

Riscritta:

```

SELECT  Direttore AS Codice
FROM    Dipartimenti
WHERE   Direttore <> NULL;
  
```



$$C_{TS} = N_{pag}(Dipartimenti)$$

L'interrogazione cercava i codici dei direttori di dipartimenti e questa informazione si può ottenere direttamente dai dipartimenti.

Esercizio 2

- a) Se osserviamo come sono aggiunte le richieste di blocco nelle due transazioni scopriamo che la storia ottenuta è legale secondo il protocollo 2PL-stretto; per questo motivo, sapendo che il protocollo 2PL-stretto produce storie c-serializzabili, anche la storia ottenuta sarà c-serializzabile

- b) Il protocollo 2PL-stretto è pronò allo stallo, dunque è possibile che un tale evento si verifichi. Se si utilizza il protocollo di prevenzione dello stallo *wait-die*, in caso di richieste di blocco non soddisfacibili, una transazione rimane in attesa solo se il dato bloccato appartiene ad una transazione più giovane, in caso contrario la transazione viene interrotta e fatta ripartire.

Vediamo un esempio con le transazioni T_1 e T_2 :

	Comandi		Blocchi Concessi	
	T_1	T_2	T_1	T_2
t_0	$wl(A)$		W_A	
t_1	$r[A]$		W_A	
t_2		$wl(B)$	W_A	W_B
t_3		$r[B]$	W_A	W_B
t_4	$w[A]$		W_A	W_B
t_5		$wl(A)$	W_A	W_B
t_6		<i>abort</i>	W_A	
t_7	$wl(B)$		W_A W_B	
t_9	$r[B]$		W_A W_B	
t_{10}	$w[B]$		W_A W_B	
t_{11}	<i>commit</i>		W_A W_B	
t_{12}	$wu(A)$		W_B	
t_{13}	$wu(B)$			
t_{14}		$wl(B)$		W_B
t_{15}	

La prima transazione a partire è T_1 dunque si avrà che, in caso di richieste di blocco non soddisfacibili, T_1 , la più vecchia, potrà aspettare, mentre T_2 dovrà essere interrotta. Al tempo t_5 abbiamo la prima richiesta di blocco non soddisfacibile, infatti il blocco in scrittura su A richiesto da T_2 è posseduto da T_1 : il protocollo *wait-die* entra in funzione e fa abortire T_2 . A questo punto T_1 può tranquillamente procedere con la sua esecuzione e portare a termine le operazioni. È interessante notare che, se non ci fosse stato l'abort di T_2 , al tempo t_7 si sarebbe creata una condizione di stallo.

Nel nostro caso la transazione T_2 viene fatta ripartire dopo il commit di T_1 , ma questo non è un comportamento obbligatorio: T_2 sarebbe potuta ripartire in ogni momento dopo il suo abort. Tuttavia, se lo avesse fatto in un tempo anteriore a t_{12} (cioè prima che T_1 rilasciasse il blocco su A), ancora una volta sarebbe stata costretta ad abortire, in quanto la sua marca temporale, identica a quella della prima partenza, sarebbe stata più grande di quella di T_1 (cioè sarebbe stata ancora la transazione più giovane delle due). Questo fatto ci garantisce che sia sempre la transazione ad aver svolto il minor carico di lavoro a doversi interrompere.

- c) No, perchè sappiamo che il protocollo 2PL-stretto è ripristinabile e senza cascata di abort (*cascadeless*).
- d) Questa volta siamo di fronte a storie legali per il protocollo 2PL classico, che sappiamo produrre storie c-serializzabili.
- e) Come per la versione stretta è ancora possibile avere situazioni di stallo. Se si utilizza il protocollo di prevenzione dello stallo *wound-wait*, in caso di una richiesta di blocco non soddisfacibile, una transazione rimane in attesa solo se il dato bloccato appartiene ad una transazione più vecchia, in caso contrario la transazione più giovane viene interrotta e fatta ripartire.

Vediamo un esempio con le transazioni T_1 e T_2 : (*l'asterisco indica transazioni in attesa*)

	Comandi		Blocchi Concessi	
	T_1	T_2	T_1	T_2
t_0	$wl(A)$		W_A	
t_1	$r[A]$		W_A	
t_2	$w[A]$		W_A	
t_3		$wl(A)$	W_A	
t_4	$wl(B)$	*	$W_A W_B$	
t_5	$wu(A)$	*	W_B	W_A
t_6		$wl(B)$	W_B	W_A
t_7	$r[B]$	*	W_B	W_A
t_8	$w[B]$	*	W_B	W_A
t_9	$wu(B)$	*		$W_A W_B$
t_{10}		$r[B]$		$W_A W_B$
t_{11}		$r[A]$		$W_A W_B$
t_{12}		$w[A]$		$W_A W_B$
t_{13}		$wu(A)$		W_B
t_{14}		$w[B]$		W_B
t_{15}		$wu(B)$		

La prima transazione a partire è T_1 dunque si avrà che, in caso di richieste di blocco non soddisfacibili, T_2 , la più giovane, potrà aspettare, mentre, se il fatto dovesse capitare a T_1 sarebbe T_2 ad essere interrotta. Al tempo t_3 abbiamo la prima richiesta di blocco non soddisfacibile, infatti il blocco in scrittura su A richiesto da T_2 è posseduto da T_1 : il protocollo *wait-die* entra in funzione e mette in attesa T_2 . T_1 da parte sua va avanti con la sua esecuzione e al tempo t_5 rilascia il blocco su A che viene passato a T_2 . Di nuovo T_2 fa una richiesta non soddisfacibile e viene posta nuovamente in attesa fino al tempo t_{11} . Come per il protocollo precedente, la priorità di esecuzione viene data alla transazione più vecchia, che si suppone abbia svolto una maggiore quantità di lavoro.

f) Sì, il protocollo 2PL ammette cascate di abort.

Esercizio 3


Vedi soluzione esercizio numero 3 del 10.7.2001.

Appello del 14.2.2002

1. Si consideri la relazione `Studenti(Matricola, Nome, AnnoNascita)`, ordinata sulla chiave primaria `Matricola`, e l'interrogazione:

```
SELECT    DISTINCT Matricola, COUNT(*)
FROM      Studenti
WHERE     AnnoNascita = 1974
GROUP BY  Matricola
ORDER BY  Matricola;
```

Si dica se il seguente piano d'accesso produce il risultato cercato. Se non va bene, lo si modifichi aggiungendo le parti mancanti:



Si semplifichi il piano di accesso eliminando gli operatori inutili e si dia una stima del suo costo. Come cambia il piano di accesso e il suo costo se la relazione non è ordinata su `Matricola`?

2. Siano S_1 e S_2 due storie sullo stesso insieme di transazioni. Si supponga che S_1 sia c-serializzabile e che i grafi di serializzabilità delle due storie $GS(S_1)$ e $GS(S_2)$ siano uguali. Si considerino le seguenti affermazioni su S_2 :

- (a) S_2 è seriale
- (b) S_2 è c-equivalente a S_1
- (c) S_2 è c-serializzabile.

Giustificare quali delle seguenti conclusioni sono vere:

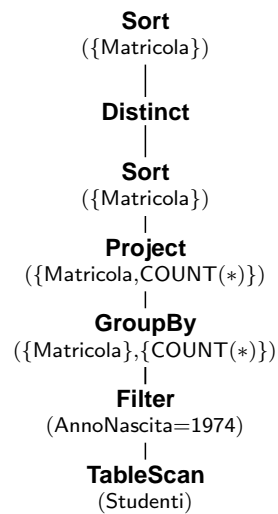
- (a) sono vere 1, 2 e 3; (b) solo 2 e 3 sono vere; (c) solo 2; (d) solo 3; (e) nessuna.

3. Come viene garantita l'atomicità e la persistenza delle transazioni dal gestore dell'affidabilità ?


Soluzione Appello del 14.2.2002

Esercizio 1

Completiamo il piano di accesso aggiungendo le parti mancanti, che sono il filtro su AnnoNascita e la funzione di aggregazione COUNT(*):



Adesso eliminiamo gli operatori superflui:




Partendo dal basso in ordine abbiamo eliminato:

1. GroupBy: l'attributo di raggruppamento è chiave, e quindi non serve raggruppare.
2. Project: l'operatore GroupBy restituisce record aventi solamente i campi passati come argomento, non c'è bisogno di proiettare ancora,
3. Sort: la tabella è memorizzata ordinata sulla chiave Matricola, non è necessario ordinare ancora,

4. Distinct: tra gli attributi presenti nei record che arrivano all'operatore Distinct è compresa una chiave, dunque non possono esistere record uguali,
5. Sort: non serviva prima, non serve adesso

Con queste semplificazioni il costo si riduce a $N_{pag}(Studenti)$.

Se la relazione non fosse ordinata su Matricola, si dovrebbe procedere ad un ordinamento finale:



$$\begin{aligned}
 C_{Sort} &= C_O + 6 \times N_{pag}(T) \\
 &= N_{pag}(Studenti) + 6 \times \\
 &\quad \left(\frac{L_k(Matricola) \times f_s(AnnoNascita = 1974) \times N_{reg}(Studenti)}{D_{pag}} \right)
 \end{aligned}$$

Esercizio 2

Valutiamo le affermazioni:

1. S_2 è seriale
(Falsa) Non ci sono né prove né indizi che S_2 sia seriale.
2. S_2 è c-equivalente a S_1
(Vera) Se S_1 e S_2 hanno lo stesso grafo di serializzazione vuol dire che hanno nello stesso ordine le operazioni in conflitto, dunque sono c-equivalenti (Nitto).
3. S_2 è c-serializzabile
(Vera) Il grafo di serializzazione di una storia c-serializzabile non ha cicli, S_2 ha lo stesso grafo di serializzabilità di S_1 , S_1 è c-serializzabile dunque il grafo di S_2 è privo di cicli, S_2 è c-serializzabile.

Oppure: S_2 è c-equivalente a S_1 , la c-equivalenza è transitiva ed S_1 è c-equivalente ad una storia seriale (Nitto).

In conclusione la risposta corretta è la (b).

Esercizio 3

Vedi soluzione n°3 dell'appello del 1.6.2001.

Appello del 27.5.2002

1. Si consideri lo schema:

Fornitori(Fid, FNome, Città)
Parti(Pid, PNome, Colore, Peso)
Ordini(Fid*, Pid*, PGid*, Qta)

e l'interrogazione:

```
SELECT      DISTINCT FNome, sum(Qta)
FROM        Ordini O, Fornitori F
WHERE       O.Fid = F.Fid AND O.Pid < 'P5' AND F.Città = 'Pisa'
GROUP BY   FNome
ORDER BY   FNome
```

Si fornisca un piano di accesso usando indici a vostra scelta e si dia una stima del suo costo.

2. Si definiscano le nozioni di grafo di serializzabilità e di storia c-serializzabile. Si considerino le storie:

$$S_1 = \{r_1[A], w_1[B], r_2[B], w_2[C], r_3[C], w_3[A]\}$$

$$S_2 = \{r_1[A], r_2[A], w_1[B], w_2[B], r_1[B], r_2[B], w_2[C], w_1[D]\}$$

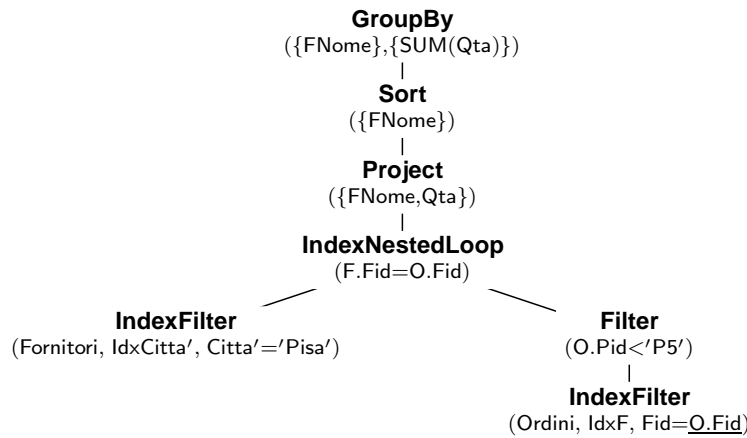
Si dica se sono c-serializzabili. Se lo sono, si dica quali sono le storie seriali equivalenti.

3. Spiegare come viene eseguito dal gestore del buffer il comando di lettura di una pagina. Quando il gestore del buffer scrive una pagina nella memoria permanente?

Soluzione Appello del 27.5.2002 (Igor Nitto)

Esercizio 1

Supponiamo l'esistenza di indici a B⁺-albero sugli attributi Fornitori.Città e Ordini.Fid. Piano d'accesso:



Stima del costo: valutiamo prima costo e cardinalità dell'IndexNestedLoop:

$$C_{INL} = C_A(F) + E_{reg}(F) \times C_A(O)$$

$$E_{reg}(INL) = f_s(F.Fid = O.Fid) \times E_{reg}(F) \times E_{reg}(O)$$

con

$$f_s(F.Fid = O.Fid) = 1/\max\{N_{key}(F.Fid), N_{key}(O.Fid)\}$$

$$C_A(F) = C_I + C_D$$

$$C_I = (1/N_{key}(F.Citta')) \times N_{leaf}(idxCitta')$$

$$C_D = \Phi(N_{reg}(F)/N_{key}(F.Citta'), N_{pag}(F))$$

$$E_{reg}(F) = N_{reg}(F)/N_{key}(F.Citta')$$

$$C_A(O) = C_I + C_D$$

$$C_I = (1/N_{key}(O.F)) \times N_{leaf}(idxF)$$

$$C_D = \Phi(N_{reg}(O)/N_{key}(O.F), N_{pag}(O))$$

$$E_{reg}(O) = f_s(O.Pid < 'P5') \times N_{reg}(O)$$

A partire dal costo dell'IndexNestedLoop forniamo la stima del costo di tutto il piano d'accesso, che sarà uguale al costo di visitare i record del risultato dalla proiezione della giunzione sui due

attributi FNome e Qta, di ordinarli su FNome e applicare il GroupBy (che ha costo nullo):

$$C = C_{INL} + 6 \times N_{pag}(T)$$

dove T è la relazione che risulta dalla proiezione della giunzione su FNome e Qta:

$$N_{reg}(T) = (E_{reg}(INL) \times (L(FNome) + L(Qta))) / D_{pag}$$
$$N_{pag}(T) = N_{reg}(T) / D_{pag}$$

Esercizio 2

1. Il grafo di serializzabilità di una storia è il grafo orientato nel quale i nodi sono le transazioni non abortite ed esiste un arco da T_i a T_j sse T_i contiene un'operazione che precede e va in conflitto con una di T_j .

Una storia è c-serializzabile sse è c-equivalente ad una storia seriale. Due storie su uno stesso insieme di operazioni sono c-equivalenti sse hanno nello stesso ordine le operazioni in conflitto di transazioni terminate regolarmente.

2. S_1 è già una storia seriale. S_2 ha il grafo di serializzazione in figura:



di conseguenza la storia non è c-serializzabile.

Esercizio 3

Vedere soluzione appello 10.1.2002.

Appello del 18.6.2002

1. Si consideri lo schema $R(\underline{K}, A)$, $S(\underline{KE}, B)$, e l'interrogazione:

```
SELECT    *
FROM      R, S
WHERE     K = KE;
```

Si dia il piano di accesso per eseguire l'interrogazione con il metodo MergeJoin senza uso di indici, oppure usando gli indici su K e KE , e si dia una stima del costo dei due piani. Spiegare in quali dei due casi seguenti non conviene usare gli indici:

- (a) R e S hanno un record per pagina,
- (b) R e S hanno molti record per pagina.

2. In figura sono mostrate le operazioni di una transazione con la notazione:

- START inizio transazione
- END fine transazione
- READ(X, t) copia il valore dell'elemento X della BD nella variabile t
- WRITE(X, t) copia il valore della variabile t nell'elemento X della BD che si trova nel buffer
- FLUSH(X) trasferisce X dal buffer al disco
- X Buf, valore di X nel buffer
- X disco, valore di X nel disco

Si completi la seguente tabella con le operazioni di FLUSH(X) e i valori delle colonne supponendo che la transazione sia gestita con l'algoritmo *Disfare-NonRifare*:


Azione	t	A Buf	B Buf	A disco	B disco	Log
START	–	–	–	8	8	(Begin T)
READ(A,t)	8	8	–	8	8	
$t = t*2$	16	8	–	8	8	
WRITE(A,t)						
READ(B,t)						
$t = t*2$						
WRITE(B,t)						
END						

3. Si definiscano le nozioni di grafo di serializzabilità e di grafo di attesa. Si dica come vengono usati nella realizzazione di un DBMS.

Soluzione Appello del 18.6.2002 (Igor Nitto)


Esercizio 1

Piano di accesso senza uso di indici:



$$C_{SM} = 5 \times (N_{pag}(R) + N_{pag}(S))$$

Piano d'accesso con uso di indici:



$$C_{SM} = N_{leaf}(IdxR.K) + N_{reg}(R) + N_{leaf}(IdxS.KE) + N_{reg}(S)$$

Supponiamo che il numero delle foglie di un indice sia minore del numero delle pagine dei dati. Se le relazioni hanno un solo record per pagina, il piano con gli indici ha costo sempre inferiore. Se le relazioni hanno molti record per pagina, il piano con gli indici ha in generale costo superiore. In particolare, se le due relazioni hanno la stessa cardinalità e record piccoli di uguale lunghezza, il piano con gli indici ha costo inferiore se la capacità della pagina dei dati è inferiore a 4.

Esercizio 3

Il grafo di serializzabilità associato ad una storia è il grafo orientato nel quale i nodi sono le transazioni terminate regolarmente ed esiste un arco da T_i a T_j sse T_i contiene un'operazione che precede e va in conflitto con una di T_j . Il grafo di attesa è il grafo nel quale i nodi sono le transazioni correntemente attive ed esiste un nodo tra T_i e T_j sse T_i è in attesa di un dato bloccato da T_j .

Il grafo di serializzabilità è legato ad una teoria generale che consente di dimostrare la correttezza di un serializzatore. Risultato principale della teoria è che una storia è c-serializzabile se e solo se il suo grafo di serializzabilità è aciclico.

Il grafo di attesa è legato invece al controllo degli stalli: per stabilire se un insieme di transazioni attive sono in stallo è sufficiente che nel grafo di attesa vi sia un ciclo.

Esercizio 2

Azione	t	A Buf	B Buf	A disco	B disco	Log
START	–	–	–	8	8	(begin T)
READ(A,t)	8	8	–	8	8	
t = t*2	16	8	–	8	8	
WRITE(A,t)	16	16	–	16	8	(Write, A, 8)
READ(B,t)	8	16	8	16	8	
t = t*2	16	16	8	16	8	
WRITE(B,t)	16	16	16	16	16	(Write, B, 8)
FLUSH(A)	16	16	16	16	16	
FLUSH(B)	16	16	16	16	16	
END					16	

Appello del 15.7.2002

1. Si consideri la relazione Impiegati(Codice, Nome, AnnoNascita). Per le seguenti interrogazioni si dia un piano di accesso (supponendo di eliminare i duplicati e di eseguire il GroupBy con l'algoritmo di ordinamento) e si giustifichi in quali casi non occorre l'operatore fisico Sort. Si stimi il costo del piano di accesso che ritenete più costoso.

```
SELECT    DISTINCT AnnoNascita
FROM      Impiegati
WHERE     AnnoNascita > 1950;
```

```
SELECT    DISTINCT AnnoNascita
FROM      Impiegati
WHERE     AnnoNascita = 1950;
```

```
SELECT    AnnoNascita
FROM      Impiegati
WHERE     AnnoNascita = 1950
ORDER BY  AnnoNascita;
```

```
SELECT    COUNT(*)
FROM      Impiegati
WHERE     AnnoNascita = 1950
GROUP BY  AnnoNascita;
```

2. Si consideri la storia:

$$S = \{r_1[A], w_1[B], r_2[A], w_2[B], r_3[A], w_3[B]\}$$

Quante storie si possono definire con le stesse operazioni e c-equivalenti a S ?

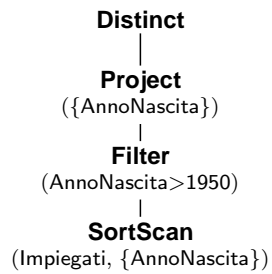
3. Descrivere il protocollo 2PL stretto e la tecnica di gestione dei blocchi.

Soluzione Appello del 15.7.2002 (Igor Nitto)


Esercizio 1

Piani d'accesso:

a)




b)




Si noti che non è necessario ordinare i dati su AnnoNascita perché una volta applicato il filtro tutti record avranno lo stesso valore di AnnoNascita.

c)



d)




Si stimerà il costo del primo piano d'accesso:

$$C_a = 5 \times N_{pag}(Impiegati)$$

Esercizio 2 (Del Rio)

Costruiamo, per iniziare, il grafo di serializzazione di S :



Osservando la storia, notiamo come siano solamente le operazioni di scrittura a determinare gli archi del grafo, cioè siamo di fronte solamente a conflitti di tipo WW. Poiché ogni storia c-equivalente ad S deve avere nello stesso ordine di S le operazioni in conflitto, da un semplice ordinamento topologico del grafo otteniamo che $w_1[B]$ deve precedere $w_2[B]$ che a sua volta deve precedere $w_3[B]$:

$$w_1[B] \quad w_2[B] \quad w_3[B]$$

Dobbiamo adesso piazzare le operazioni di lettura, con l'unica accortezza di rispettare l'ordine relativo delle operazioni di ciascuna transazione. Per quanto riguarda $r_1[A]$ non abbiamo molte scelte, deve necessariamente precedere $w_1[B]$:

$$r_1[A] \quad w_1[B] \quad w_2[B] \quad w_3[B]$$

Per piazzare $r_2[A]$ abbiamo 3 possibilità:

$$\begin{array}{l}
 r_2[A] \quad r_1[A] \quad w_1[B] \quad w_2[B] \quad w_3[B] \\
 r_1[A] \quad r_2[A] \quad w_1[B] \quad w_2[B] \quad w_3[B] \\
 r_1[A] \quad w_1[B] \quad r_2[A] \quad w_2[B] \quad w_3[B]
 \end{array}$$

Per finire, per ciascuna delle 3 possibilità precedenti, $r_3[A]$ può essere piazzato in 5 modi differenti. Otteniamo quindi che in totale esistono $3 \times 5 = 15$ storie c-equivalenti a S (S compresa).

Esercizio 3

Il protocollo 2PL-stretto è una variante del 2PL nella quale si impone che i blocchi ottenuti da una transazione vengano tutti quanti rilasciati al momento del commit e che nessun blocco possa essere rilasciato prima.

Alla base della tecnica di gestione dei blocchi c'è una tabella hash che mantiene le associazioni tra dati e descrittori di blocco sui dati. Ogni descrittore di blocco contiene le seguenti informazioni: identificatore del dato bloccato D , il modo del gruppo delle richieste accolte M che riassume i modi di blocco attivi sul dato, la lista delle richieste accolte, la coda delle richieste in attesa. Quando una transazione richiede un blocco su D , allora si distinguono due casi:

1. Se il modo della richiesta è incompatibile con il modo del gruppo delle richieste accolte allora la richiesta viene messa nella coda delle richieste in attesa.
2. Se il modo della richiesta è compatibile con il modo del gruppo delle richieste accolte e la coda delle richieste in attesa è vuota allora la richiesta viene accolta e inserita nella lista delle richieste accolte, se invece la coda delle richieste in attesa non è vuota allora la nuova richiesta va in attesa e viene inserita nella coda delle richieste in attesa.

Quando una transazione rilascia un blocco allora si aggiornano la lista delle richieste accolte e il modo del gruppo, poi si visita la coda delle richieste accolte a partire dalla prima richiesta entrata spostando le richieste che possono essere accolte nella lista delle richieste accolte, la visita procede fino a che non si trova la prima richiesta che non può essere accolta.

Appello dell'11.9.2002

1. Si definiscano le nozioni di grafo di serializzabilità e di grafo di attesa. Si dica come vengono usati nella realizzazione di un DBMS.
2. Si consideri la base di dati

Impiegati(CodiceI, Nome, Stipendio, Età, Dipartimento*)
Dipartimenti(CodiceD, Budget, Università, Direttore*)

Stipendio ha valori fra 10M e 100M, Età ha valori fra 20 e 80, Budget ha valori fra 10 e 100M, ogni dipartimento ha in media 30 impiegati e ci sono 30 Università. Si supponga una distribuzione uniforme dei valori.

Per ognuna delle seguenti interrogazioni, quali degli indici proposti definireste per agevolare l'esecuzione dell'interrogazione? Dare il piano di accesso e una stima del suo costo. Se il DBMS non considera la possibilità di usare solo indici per rispondere all'interrogazione (ovvero, proceda sempre con accessi agli indici e poi ai dati, pur avendo tutte le informazioni necessarie per la risposta nell'indice), come cambierebbe la vostra risposta?

- a) Trovare Nome, Età e Stipendio di tutti gli impiegati
 - a1) nessun indice
 - a2) indice a B^+ -albero su (Nome, Età, Stipendio)
 - a3) indice a B^+ -albero su (Nome, Età)
 - b) Trovare i codici dei dipartimenti dell'Università di Pisa con un budget inferiore a 30
 - b1) nessun indice
 - b2) indice di ordinamento a B^+ -albero su (Università, Budget)
 - b3) indice a B^+ -albero su (Università, Budget)
 - b4) indice di ordinamento a B^+ -albero su Budget
 - c) Trovare i nomi degli impiegati che dirigono dipartimenti ed hanno uno stipendio maggiore di 80M
 - c1) nessun indice
 - c2) indice a B^+ -albero su CodiceD
 - c3) indice a B^+ -albero su CodiceI
 - c4) indice di ordinamento a B^+ -albero su Stipendio
3. Dire quali delle seguenti affermazioni è vera o falsa e giustificate la risposta:
 - (a) Il costo di una ricerca per intervallo della chiave K con l'uso di un indice su K è sempre inferiore alla scansione del file.

- (b) Con il metodo rifare, tutte le modifiche di una T devono essere riportate nella BD prima che il record di commit sia scritto nel giornale.
- (c) Tutte le storie prodotte dal 2PL-stretto sono seriali.

Soluzione Appello dell'11.9.2002 (Igor Nitto)

Esercizio 1

Vedi esercizio 3 dell'appello del 18.6.2002.

Esercizio 2

1. a2) indice denso a B^+ -albero su (Nome, Età, Stipendio)

IndexOnlyFilter
(Impiegati, idxNES, {Nome, Età, Stipendio}, True)

$$C = N_{leaf}(idxNES)$$

Se il DBMS non prevede l'IndexOnlyFilter allora la risposta è

a1) nessun indice:

Project
({Nome, Età, Stipendio})
|
TableScan
(Impiegati)

$$C = N_{pag}(Impiegati)$$

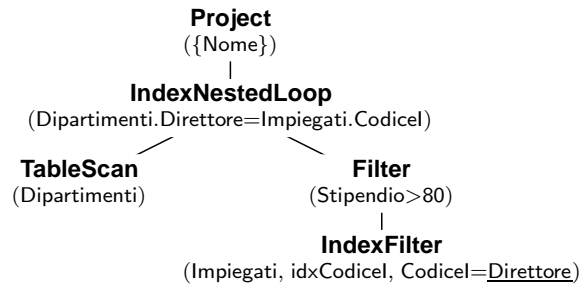
2. b2) indice su Università, Budget:

Project
({CodiceD})
|
IndexFilter
(Dipartimenti, idxUB, Università='PI' AND Budget<30)

$$C = f_s(Universita' = 'PI' \wedge Budget < 30)(N_{leaf}(idxUB) + N_{pag}(Dipartimenti))$$

$$C = 1/30 \times 20/90 \times (N_{leaf}(idxUB) + N_{pag}(Dipartimenti))$$

3. c3) indice su Codicel:



$$C = C_{O_E} + E_{reg}(O_E) \times C_{O_I} = N_{pag}(Dipartimenti) + N_{reg}(Dipartimenti) \times 2$$

Esercizio 3

1. Falso. Il costo di una ricerca per intervallo non è sempre inferiore al costo della scansione del file. Ad esempio se l'indice non è di ordinamento e K è chiave primaria il costo della ricerca con indice si può stimare come $f_s(C) \times N_{leaf} + f_s(C) \times N_{reg}(R)$ che non è assolutamente detto essere più piccolo di $N_{pag}(R)$.
2. Falso. Con il metodo rifare non è necessario che le transazioni terminate abbiano già apportato modifiche alla BD, cioè non vale la regola del commit anticipato. Se si verifica un fallimento di sistema, alla ripartenza le operazioni delle transazioni terminate saranno ripetute con la procedura rifare.
3. Falso. Il serializzatore garantisce solamente che le storie prodotte siano c-serializzabili ma non seriali, infatti operazioni di transazioni differenti non in conflitto possono benissimo intercalarsi.