

Data Science e Tecnologie per le Basi di Dati

Esercitazione 5 – Ottimizzatore di Oracle

Obiettivo dell'esercitazione

Calcolare il piano di esecuzione per alcune query SQL analizzando i seguenti aspetti:

1. metodo di accesso alle tabelle
2. metodo di join
3. ordine in cui vengono eseguite le operazioni
4. uso di indici definiti dall'utente.

Lo studio verrà effettuato con Oracle Database 10g Express Edition (Oracle XE).

Struttura della base di dati

La base di dati di riferimento è composta da 3 tabelle (EMP, DEPT e SALGRADE). In seguito viene riportato lo schema delle tabelle ed alcuni record di esempio. Il contenuto delle tabelle riportato è solo di esempio, in quanto nella realtà la base di dati è composta da un numero elevato di record.

Table **EMP**

EMPNO	ENAME	JOB	MGR	HIREDATE	SAL	COMM	DEPT NO
1	COZZA MARIA	PROFESSOR	0	09-JUN-81	1181		126
2	ECO LUIGI	PHDSTUDENT	0	09-JUN-81	1360		189
3	CORONA CLARA	PHDSTUDENT	2	09-JUN-81	624		15

Table **DEPT**

DEPTNO	DNAME	LOC
1	INFORMATION	BARI
2	CHAIRMANSHIP	FOGGIA
3	ENVIRONMENT	BRINDISI
4	PHYSICS	FOGGIA


Table **SALGRADE**

GRADE	LOSAL	HISAL
1	478	1503
2	661	1346
3	489	1358
4	942	1320

Passi preliminari per lo svolgimento dell'esercitazione

Connessione alla base di dati

Aprire il programma Oracle SQL Developer. Cliccare su crea nuova connessione:

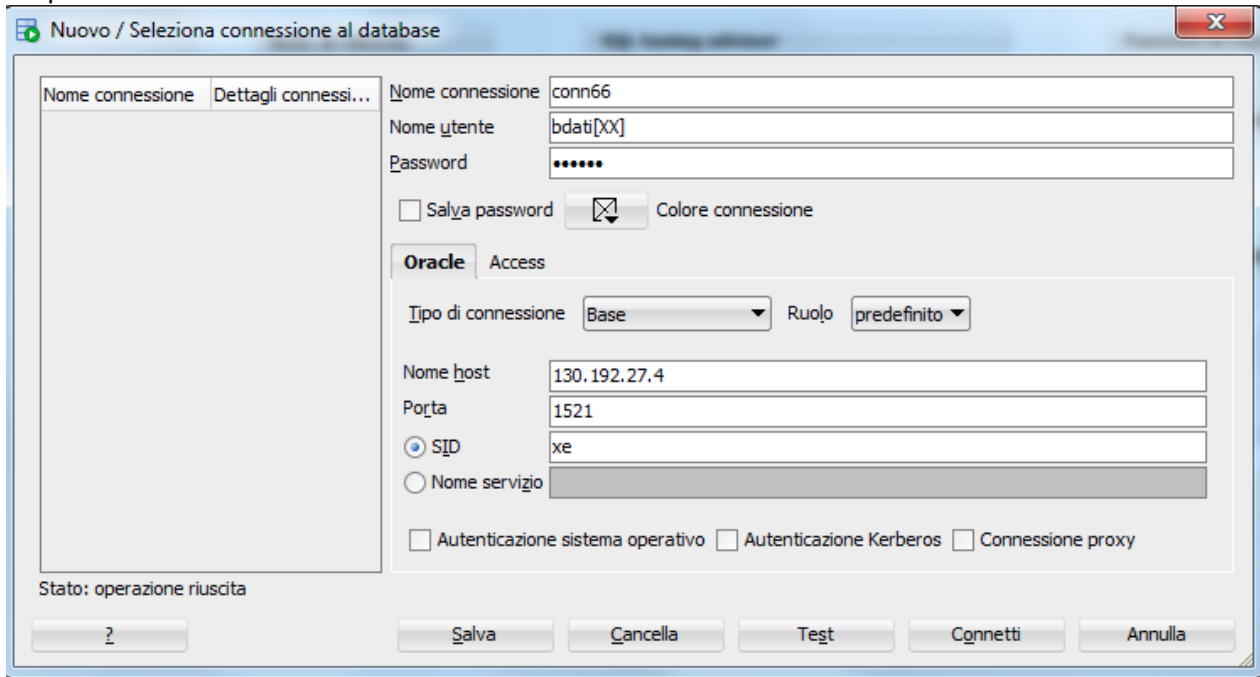


Login

Per autenticarsi inserire i seguenti parametri.

- Nome utente: bdati[scegliere un valore compreso tra 1-100]
- Password: orac[scegliere un valore compreso tra 1-100]
- Nome host: 130.192.27.4
- Porta: 1521
- SID: xe

Ad esempio, collegandosi dalla macchina numero 23 del laboratorio, usare come username **bdati23** e come password **orac23**.



Materiale disponibile


Sono disponibili alcuni script contenenti istruzioni SQL per svolgere le seguenti operazioni:

1. creare un indice su un campo della base di dati
2. calcolare le statistiche per la base di dati

Gli script sono disponibili:

- sul sito web del corso, alla sezione Laboratori (esercitazione 5) nell'archivio `scriptsOPT.zip`
<http://dbdmg.polito.it/wordpress/teaching/data-science-e-tecnologie-per-basi-dati/>

Gli script possono essere caricati aprendo File->Apri e selezionando il file `.sql` e successivamente cliccando il pulsante "Esegui Script"



Per visualizzare le statistiche sugli indici, eseguire lo script `show_indexes.sql` (oppure copiare il contenuto dello script e incollarlo come comando SQL).

Definizione dell'ambiente di analisi

All'inizio della sessione di lavoro è necessario svolgere i seguenti passi:

1. calcolare le statistiche delle tabelle usando lo script `comp_statistics_tables.sql`
Questa operazione è necessaria per aggiornare le statistiche sulle tabelle (es. numero record, distribuzione attributi, ...). Le statistiche generate verranno utilizzate dall'ottimizzatore per creare i piani di esecuzione. E' sufficiente un'esecuzione dello script per tutta l'esercitazione.
2. controllare che non siano presenti altri indici riguardanti le 3 tabelle (EMP, DEPT, SALGRADE), oltre a quelli di sistema (il cui nome inizia con `sys`). In particolare per le tre tabelle eseguire:

```
select INDEX_NAME from USER_INDEXES where TABLE_NAME=nometabella;
```
3. cancellare gli indici (non di sistema) trovati al passo 2:

```
DROP INDEX nomeindice;
```

Calcolo del piano di esecuzione per una query

Per ottenere il piano di esecuzione di una data query è necessario **eseguire la query e successivamente** cliccare il pulsante "Piano di esecuzione" indicato in figura



Il comando per visualizzare il piano di esecuzione esegue delle query alla tabella `PLAN_TABLE`.

Se questa esiste già verrà mostrato un errore ("Nome colonna non valido"). In questo caso cancellare la tabella (`drop table PLAN_TABLE;`) e rieseguire il comando.

Verrà mostrato il piano di esecuzione con il seguente formato:

OPERATION	OBJECT_NAME	OPTIONS	CARDINALITY	COST
SELECT STATEMENT			50012	124
HASH JOIN			50012	124
Access Predicates				
EMP.DEPTNO=DEPT.DEPTNO				
TABLE ACCESS	DEPT	FULL	507	3
TABLE ACCESS	EMP	FULL	50111	120

OPERATION: operazione da eseguire sulle tabelle/indici.

CARDINALITY: dimensione tabella/indice.

COST: costo dell'operazione, valore stimato proporzionale alle risorse utilizzate (CPU, I/O, memoria). Il costo si riferisce ad uno specifico nodo dell'albero algebrico ed è **cumulativo**. Ciò significa che il costo di un nodo include, oltre al costo dell'operazione considerata, i costi di tutti i suoi nodi figli.

Nella foto di esempio viene eseguita una hash join tra le due tabelle DEPT ed EMP. Il costo dell'accesso alla tabella EMP è 120, quello della tabella DEPT è 3. Il nodo di hash join tra le due tabelle ha costo cumulativo pari a 124 ($120+3+1$). Si deduce quindi che la singola operazione di hash join ha costo 1. La select ha costo cumulativo 124 perché non introduce operazioni aggiuntive dopo la hash join.

Tipi di operazioni che si possono trovare nel piano di esecuzione:

- **JOIN, GROUP BY, TABLE ACCESS, INDEX SCAN**
- **Access Predicates:** indicano una o più condizioni che devono soddisfare i record per poter essere selezionati. Vengono usati su dati **indicizzati** (ordinati). Permettono di specificare il **range (start, stop)** di record ordinati che soddisfa la condizione.
E' possibile trovare questo nodo in una join (specifica le condizioni di join, come nell'immagine di esempio) o nelle operazioni di filtro sugli attributi di una tabella (condizioni WHERE).
- **Filter Predicates:** indicano una o più condizioni che devono soddisfare i record per poter essere selezionati. A differenza degli access predicates l'operazione di filter viene eseguita man mano che si scorrono i record ordinati. Se sono presenti sia access sia filter predicates, i primi specificano un range di record indicizzati, i secondi permettono di filtrare in quel range.
E' possibile trovare questo nodo nelle operazioni di filtro sugli attributi di una tabella (condizioni WHERE).

Comandi utili

- Per leggere quali campi compongono una tabella:
`DESCRIBE NomeTabella;`
- Per creare un indice su un campo di una tabella:
`CREATE INDEX NomeIndice ON NomeTabella (NomeCampo);`
- Per aggiornare le statistiche relative ad un indice esistente:
`ANALYZE INDEX NomeIndice COMPUTE STATISTICS;`
- Per rimuovere un indice:
`DROP INDEX NomeIndice;`
- Per visualizzare l'elenco degli indici relativi ad una tabella:
`SELECT INDEX_NAME FROM USER_INDEXES
WHERE table_name='nome tabella in maiuscolo';`
- Per visualizzare le statistiche relative agli indici:
`SELECT USER_INDEXES.INDEX_NAME as INDEX_NAME, INDEX_TYPE,
USER_INDEXES.TABLE_NAME, COLUMN_NAME||'('||COLUMN_POSITION||')' as
COLUMN_NAME, BLEVEL, LEAF_BLOCKS, DISTINCT_KEYS, AVG_LEAF_BLOCKS_PER_KEY,
AVG_DATA_BLOCKS_PER_KEY, CLUSTERING_FACTOR
FROM user_indexes, user_ind_columns
WHERE user_indexes.index_name=user_ind_columns.index_name and
user_indexes.table_name=user_ind_columns.table_name;`
- Per visualizzare le statistiche relative alle tabelle:
`SELECT TABLE_NAME, NUM_ROWS, BLOCKS, EMPTY_BLOCKS, AVG_SPACE, CHAIN_CNT,
AVG_ROW_LEN
FROM USER_TABLES;`
- Per visualizzare le statistiche sugli attributi delle tabelle:
`SELECT COLUMN_NAME, NUM_DISTINCT, NUM_NULLS, NUM_BUCKETS, DENSITY
FROM USER_TAB_COL_STATISTICS
WHERE TABLE_NAME = 'NomeTabella' ORDER BY COLUMN_NAME;`
- Per visualizzare gli istogrammi (distribuzione valori degli attributi):
`SELECT *
FROM USER_HISTOGRAMS;`

Query da analizzare

Le seguenti query dovranno essere analizzate durante l'esercitazione, eseguendo i passi:

1. espressione algebrica ad albero della query
2. piano di esecuzione di Oracle della query originale senza strutture secondarie
3. Per le query da #4 a #7, scegliere una o più strutture fisiche accessorie per migliorare le prestazioni dell'interrogazione.

Richiamo alla struttura delle tabelle

EMP (EMPNO, ENAME, JOB, MGR, HIREDATE, SAL, COMM, DEPTNO)

DEPT (DEPTNO, DNAME, LOC)

SALGRADE (GRADE, LOSAL, HISAL)

Query #1

```
SELECT *
FROM emp, dept
WHERE emp.deptno = dept.deptno AND emp.job = 'ENGINEER';
```

Cambiare l'obiettivo di ottimizzazione dalla modalità ALL ROWS (best throughput) alla modalità FIRST_ROWS (best response time) attraverso l'uso di hint (`/*+ FIRST_ROWS (n) */`). n è una variabile numerica intera che può assumere valori maggiori o uguali a 1. Assegnare diversi valori ad n e verificare come variano il piano d'esecuzione e i costi delle diverse operazioni.

ALL ROWS: piano esecuzione ottimizzato in modo da minimizzare il tempo di esecuzione di tutta la query.

FIRST_ROWS(n): piano esecuzione ottimizzato in modo da minimizzare il tempo di esecuzione per i primi n record del risultato.

```
SELECT /*+ FIRST_ROWS (n) */ *
FROM emp, dept
WHERE emp.deptno = dept.deptno AND emp.job = 'ENGINEER';
```

Query #2

Confrontare i costi di hash join e nested loop usando l'hint USE / NO_USE_HASH

```
SELECT /*+ NO_USE_HASH(e d) */ d.deptno, AVG(e.sal)
FROM emp e, dept d
WHERE d.deptno = e.deptno
GROUP BY d.deptno;
```

Query #3

Disabilitare il metodo hash join mediante l'uso di hint (`/*+ NO_USE_HASH(e d) */`)

```
SELECT /*+ NO_USE_HASH(e d) */ ename, job, sal, dname
FROM emp e, dept d
WHERE e.deptno = d.deptno
AND NOT EXISTS
  (SELECT * FROM salgrade WHERE e.sal = hisal);
```

Query #4

Si definiscano una o più strutture secondarie (indici) che permettano l'ottimizzazione della seguente query. Si analizzi con particolare attenzione il cambiamento nel piano di esecuzione creando due indici sugli attributi interessati dall'interrogazione.

```
select avg(e.sal)
from emp e
where e.deptno < 10 and
e.sal > 100 and e.sal < 200;
```

Query #5

Si definiscano una o più strutture secondarie (indici) che permettano l'ottimizzazione della seguente query:

```
select dname
from dept
where deptno in (select deptno
                 from emp
                 where job = 'PHILOSOPHER');
```

Query #6

Si definiscano una o più strutture secondarie (indici) che permettano l'ottimizzazione della seguente query (rimuovere eventuali indici già esistenti per confrontare le performance della query con e senza indici):

```
select e1.ename, e1.empno, e1.sal, e2.ename, e2.empno, e2.sal
from emp e1, emp e2
where e1.ename <> e2.ename and e1.sal < e2.sal
and e1.job = 'PHILOSOPHER' and e2.job = 'ENGINEER';
```