



PA152: Efektivní využívání DB  
9. Ladění dotazů

Vlastislav Dohnal

# Poděkování

- Zdrojem materiálů tohoto předmětu jsou:
  - Přednášky CS245, CS345, CS345
    - Hector Garcia-Molina, Jeffrey D. Ullman, Jennifer Widom
    - Stanford University, California
  - Database Tuning (slides)
    - Dennis Shasha, Philippe Bonnet
    - Morgan Kaufmann, 1<sup>st</sup> edition, 440 pages, 2002
    - ISBN-13: 978-1558607538
    - <http://www.databasetuning.org/>

# Příklad statistik PostgreSQL

- Připojte se k fakultní DB PostgreSQL
  - Návod viz první přednáška
- Ve schématu *xdohnal* jsou tabulky
  - *predmet, skupina, hotel*
    - Statistiky jak na relacích, tak i attributech.
  - Významy jednotlivých polí
    - <http://www.postgresql.org/docs/8.1/interactive/view-pg-stats.html>

# Příklad statistik PostgreSQL

## ■ Tabulka hotel

Statistic	Value
Sequential Scans	4
Sequential Tuples Read	500
Index Scans	1
Index Tuples Fetched	500
Tuples Inserted	500
Tuples Updated	0
Tuples Deleted	0
Tuples HOT Updated	0
Live Tuples	500
Dead Tuples	0
Heap Blocks Read	5
Heap Blocks Hit	514
Index Blocks Read	4
Index Blocks Hit	599
Toast Blocks Read	
Toast Blocks Hit	
Toast Index Blocks Read	
Toast Index Blocks Hit	
Last Vacuum	
Last Autovacuum	
Last Analyze	
Last Autoanalyze	2010-04-15 13:52:03.54614+02
Table Size	40 kB
Toast Table Size	none
Indexes Size	32 kB

# Příklad statistik PostgreSQL

## ■ Atribut hotel.id








Statistic	Value
Null Fraction	0
Average Width	4
Distinct Values	-1
Most Common Values	
Most Common Frequencies	
Histogram Bounds	{1,50,100,150,200,250,300,350,400,450,500}
Correlation	1

## ■ Atribut hotel.name








Statistic	Value
Null Fraction	0
Average Width	9
Distinct Values	-1
Most Common Values	
Most Common Frequencies	
Histogram Bounds	{street1,street143,street189,street233,street279,street323,street369,street413,street459,street53,street99}
Correlation	-0.117997

# Příklad statistik PostgreSQL

## ■ Atribut hotel.state

Properties	Statistics	Dependencies	Dependents
Statistic		Value	
 Null Fraction		0	
 Average Width		7	
 Distinct Values		50	
 Most Common Values		{state32,state8,state14,state36,state42,state48,state6,state16,state30,state47}	
 Most Common Frequencies		{0.038,0.03,0.028,0.028,0.028,0.028,0.028,0.026,0.026,0.026}	
 Histogram Bounds		{state1,state12,state18,state21,state25,state29,state34,state4,state44,state5,state9}	
 Correlation		-0.00743129	

## ■ Atribut hotel.distance\_to\_center

Properties	Statistics	Dependencies	Dependents
Statistic		Value	
 Null Fraction		0	
 Average Width		4	
 Distinct Values		10	
 Most Common Values		{6,7,10,3,9,8,2,1,4,5}	
 Most Common Frequencies		{0.108,0.108,0.108,0.106,0.102,0.098,0.096,0.094,0.092,0.088}	
 Histogram Bounds			
 Correlation		0.102588	

# Ladění dotazů

```
SELECT s.RESTAURANT_NAME, t.TABLE_SEATING, to_char(t.DATE_TIME,'Dy, Mon FMDD') AS THEDATE,
to_char(t.DATE_TIME,'HH:MI PM') AS THETIME,to_char(t.DISCOUNT,'99') || '%' AS AMOUNTVALUE,t.TABLE_ID,
s.SUPPLIER_ID, t.DATE_TIME, to_number(to_char(t.DATE_TIME,'SSSS')) AS SORTTIME
FROM TABLES_AVAILABLE t, SUPPLIER_INFO s,
(SELECT s.SUPPLIER_ID, t.TABLE_SEATING, t.
FROM TABLES_AVAILABLE t, SUPPLIER_INFO
WHERE t.SUPPLIER_ID = s.SUPPLIER_ID
and (TO_CHAR(t.DATE_TIME, 'MM/DD/YYYY')
or TO_NUMBER(TO_CHAR(sysdate, 'SSSS')
and t.NUM_OFFERS > 0 and t.DATE_TIME
and t.TABLE_SEATING = '2' and t.DATE_TIME between sysdate and (sysdate + 7)
and to_number(to_char(t.DATE_TIME, 'SSSS')) between 39600 and 82800
and t.OFFER_TYPE = 'Discount'
GROUP BY s.SUPPLIER_ID, t.TABLE_SEATING, t.DATE_TIME, t.OFFER_TYP) u
WHERE t.SUPPLIER_ID=s.SUPPLIER_ID and u.SUPPLIER_ID=s.SUPPLIER_ID and t.SUPPLIER_ID=u.SUPPLIER_ID
and t.TABLE_SEATING = u.TABLE_SEATING and t.DATE_TIME = u.DATE_TIME
and t.DISCOUNT = u.AMOUNT and t.OFFER_TYPE = u.OFFER_TYPE
and (TO_CHAR(t.DATE_TIME, 'MM/DD/YYYY') != TO_CHAR(sysdate, 'MM/DD/YYYY')
or TO_NUMBER(TO_CHAR(sysdate, 'SSSS')) < s.NOTIFICATION_TIME - s.TZ_OFFSET)
and t.NUM_OFFERS > 2 and t.DATE_TIME > SYSDATE and s.CITY = 'SF'
and t.TABLE_SEATING = '2' and t.DATE_TIME between sysdate and (sysdate + 7)
and to_number(to_char(t.DATE_TIME, 'SSSS')) between 39600 and 82800 and t.OFFER_TYPE = 'Discount'
ORDER BY AMOUNTVALUE DESC, t.TABLE_SEATING ASC, upper(s.RESTAURANT_NAME) ASC,
SORTTIME ASC, t.DATE_TIME ASC
```

Provedení je příliš pomalé ...

- 1) Jak je dotaz vyhodnocován?
- 2) Jak jej lze urychlit?

# Plán dotazu

## Výstup příkazu EXPLAIN v Oracle

Execution Plan

```
-----  
0  SELECT STATEMENT Optimizer=CHOOSE (Cost=165 Card=1 Bytes=106)  
1  0  SORT (ORDER BY) (Cost=165 Card=1 Bytes=106)  
2  1  NESTED LOOPS (Cost=164 Card=1 Bytes=106)  
3  2  NESTED LOOPS (Cost=155 Card=1 Bytes=83)  
4  3  TABLE ACCESS (FULL) OF 'TABLES_AVAILABLE' (Cost=72 Card=1 Bytes=28)  
5  3  VIEW  
6  5  SORT (GROUP BY) (Cost=83 Card=1 Bytes=34)  
7  6  NESTED LOOPS (Cost=81 Card=1 Bytes=34)  
8  7  TABLE ACCESS (FULL) OF 'TABLES_AVAILABLE' (Cost=72 Card=1 Bytes=24)  
9  7  TABLE ACCESS (FULL) OF 'SUPPLIER_INFO' (Cost=9 Card=20 Bytes=200)  
10 2  TABLE ACCESS (FULL) OF 'SUPPLIER_INFO' (Cost=9 Card=20 Bytes=460)
```

Operátor

Přístupová metoda

Cena provedení



# Monitorování dotazů

- Možnosti, jak objevit pomalý dotaz:
  - Vyžaduje příliš mnoho přístupů na disk
    - Např. dotaz na přesnou shodu používá table-scan.
  - Nevhodný plán dotazu
    - Vhodné (existující) indexy nejsou použity
  - Databáze umožňují logování „dlouhých“ dotazů

# Ladění dotazu

- První přístup ke zrychlení jsou lokální změny
- Globální změna
  - Vytvoření indexu
  - Změna schéma
  - Rozdělení transakcí
  - ...
- Lokální změna
  - Přepsání dotazu ovlivní pouze daný dotaz

# Přepisování dotazů

## ■ Příklad:

□ Employee(ssnum, name, manager, dept, salary, numfriends)

■ Shlukovaný index na *ssnum*

□ Tj. určuje uspořádání souboru

■ Neshlukované indexy: (i) *name* a (ii) *dept*

□ Student(ssnum, name, degree\_sought, year)

■ Shlukovaný index na *ssnum*

■ Neshlukovaný index na *name*

□ Tech(dept, manager, location)

■ Shlukovaný index na *dept*

# Přepisování dotazů

## ■ Techniky

- Použití indexů
- Rušení nadbytečných DISTINCT
- (Korelované) poddotazy
- Dočasné tabulky
- Podmínky spojení
- Používání HAVING
- Používání pohledů (VIEW)
- Uložené pohledy (materialized views)

# Používání indexů

- Optimalizace dotazů nemusí použít index pokud jsou používány:

- Aritmetické výrazy

```
WHERE salary/12 >= 4000;
```

- Podřetězce

```
SELECT * FROM employee  
WHERE SUBSTR(name, 1, 1) = 'G';
```

- Porovnávání atributů různých datových typů
- Víceatributové indexy
- Porovnání na NULL

# Rušení nadbytečných DISTINCT

## ■ Dotaz:

- Najdi zaměstnance pracující v oddělení *informační systémy*. Ve výsledku nechme duplicity.

- `SELECT DISTINCT ssn  
FROM employee  
WHERE dept = 'information systems'`

## ■ DISTINCT není nutný

- *ssn* je primární klíč v *employee*

# Rušení nadbytečných DISTINCT

## ■ Dotaz:

- Vypiš čísla *ssnum* všech zaměstnanců z technického oddělení. Ve výsledku nechme opakování.
- `SELECT DISTINCT ssnum  
FROM employee, tech  
WHERE employee.dept = tech.dept`

## ■ Je DISTINCT nutný?

# Rušení nadbytečných DISTINCT

## ■ Dotaz:

```
□ SELECT DISTINCT ssn  
FROM employee, tech  
WHERE employee.dept = tech.dept
```

## ■ Je DISTINCT nutný?

- *ssnum* je primární klíč v *employee*
- *dept* je primární klíč v *tech*
- → každý zaměstnanec se spojí s nejvýše jedním záznamem z relace *tech*.
- → DISTINCT není potřeba



# Rušení nadbytečných DISTINCT

- Vztah mezi DISTINCT, primárními klíči a spojeními lze popsat:
  - Relace  $T$  je *privilegovaná*, pokud atributy vrácené příkazem SELECT obsahují primární klíč.
  - Necht'  $R$  není privilegovaná relace.
  - Když  $R$  je spojena s relací  $S$  podle rovnosti primárního klíče  $R$  a nějakého atribut(ů) z  $S$ , pak  $R$  je *závislá na  $S$* .
  - Relace „záviset na“ je tranzitivní:
    - $R_1$  závisí na  $R_2$  a  $R_2$  závisí na  $R_3$ , pak  $R_1$  závisí na  $R_3$ .

# Rušení nadbytečných DISTINCT

- Ve výsledku příkazu SELECT nebudou duplicity (bez DISTINCT), pokud platí alespoň jedno z:
  - Každá relace ve FROM je privilegovaná.
  - Každá neprivilegovaná relace závisí na nějaké privilegované.

# Nadbytečný DISTINCT (1)

- Dotaz:

- SELECT snum  
FROM employee, tech  
WHERE employee.manager = tech.manager

- *Employee* je privilegovaná

- Je *tech* privilegovaná?

- Ne.

- Závisí *tech* na *employee*?

- Ne, protože atribut *manager* není primárním klíčem *tech*.

# Nadbytečný DISTINCT (2)

- Dotaz:

- SELECT ssnum, tech.dept  
FROM employee, tech  
WHERE employee.manager = tech.manager

- *Employee* je privilegovaná

- Je *tech* privilegovaná?

- Ano.

- Výsledky se neopakují

# Nadbytečný DISTINCT (3)

- Dotaz:

- SELECT student.ssnum  
FROM student, employee, tech  
WHERE student.name = employee.name  
AND employee.dept = tech.dept;

- *Student* je privilegovaná

- *Employee* není privilegovaná a nezávisí na žádné z ostatních relací.

- → DISTINCT je nutný.

# Typy vnořených dotazů

- Nekorelované dotazy s agregační funkcí uvnitř
  - `SELECT snum FROM employee WHERE salary > (SELECT avg(salary) FROM employee)`
- Nekorelované dotazy bez agregační funkce
  - `SELECT snum FROM employee WHERE dept in (SELECT dept FROM tech)`

# Typy vnořených dotazů

- Korelované s agregační funkcí

- SELECT ssnun FROM employee e1  
WHERE salary =  
(SELECT avg(e2.salary)  
FROM employee e2, tech  
WHERE e2.dept = e1.dept  
AND e2.dept = tech.dept)


- Korelované bez agregační funkce

- Neobvyklé (resp. lze napsat pomocí spojení)

# Přepsání nekorelovaných dotazů bez agregace

1. Relace z obou FROM dej dohromady
2. IN nahrad' rovností (=)
3. Vybírané atributy se nemění

```
SELECT ssnun FROM employee  
WHERE dept in (select dept from tech)
```



```
SELECT ssnun  
FROM employee, tech  
WHERE employee.dept = tech.dept
```



# Přepsání nekorelovaný dotazů bez agregace

## ■ Problém s duplicitami:

- `SELECT avg(salary) FROM employee WHERE manager in (select manager from tech)`
- `SELECT avg(salary) FROM employee, tech WHERE employee.manager = tech.manager`

## ■ Druhý dotaz může vrátet zaměstnance vícekrát

- Pokud stejný manažer vede více oddělení.

## ■ Řešením je pomocná tabulka

- Kde pomocí `DISTINCT` eliminujeme duplicitu.

# Přepsání korelovaných dotazů

## ■ Dotaz:

- Najdi zaměstnance technických oddělení, kteří vydělávají průměrnou mzdu svého oddělení.

```
SELECT snum
FROM employee e1
  WHERE salary = (SELECT avg(e2.salary
                          FROM employee e2, tech
                          WHERE e2.dept = e1.dept
                          AND e2.dept = tech.dept);
```

# Přepsání korelovaných dotazů

```
INSERT INTO temp
  SELECT avg(salary) as avsalary, employee.dept
  FROM employee, tech
  WHERE employee.dept = tech.dept
  GROUP BY employee.dept;
```

```
SELECT snum
  FROM employee, temp
  WHERE salary = avsalary
  AND employee.dept = temp.dept
```

# Přepsání korelovaných dotazů

## ■ Dotaz:

- Najdi zaměstnance technických oddělení, kteří mají stejně kamarádů jako kolegů ve svém oddělení.

```
SELECT ssnum
FROM employee e1
WHERE numfriends = COUNT(
    SELECT e2.ssnum
    FROM employee e2, tech
    WHERE e2.dept = tech.dept
    AND e2.dept = e1.dept);
```

# Přepsání korelovaných dotazů

```
INSERT INTO temp
  SELECT COUNT(ssnum) as numcolleagues,
         employee.dept
  FROM employee, tech
 WHERE employee.dept = tech.dept
 GROUP BY employee.dept;
```

```
SELECT ssnum
  FROM employee, temp
 WHERE numfriends = numcolleagues
        AND employee.dept = temp.dept;
```

Vznikl zde problém v COUNT?

# Problém v COUNT?

## ■ Příklad:

- Helena nepracuje v technickém oddělení.
- V původním dotazu by se její přátelé porovnávali s  $\text{COUNT}(\emptyset)=0$ . V případě, že Helena nemá přátele, zůstane ve výběru.
- V přeepsaném dotazu by se záznam Heleny ve výsledku neobjevil.
  - Pomocná tabulka bude obsahovat pouze počty pro technická oddělení.
- Toto je omezení při přepisování korelovaných dotazů s COUNT.

# Používání pomocných tabulek

## ■ Dotaz:

- Pro zaměstnance oddělení informačních systémů, kteří mají plat > 40000, vypiš jejich číslo *ssnum* a umístění.
- INSERT INTO temp  
    SELECT \*  
    FROM employee  
    WHERE salary >= 40000
- SELECT *ssnum*, location  
    FROM temp  
    WHERE temp.dept = 'information systems'

## ■ Toto řešení nebude optimální

- Nelze využít index na *dept*
- Optimalizátor dotazů takový index na *temp* nemá.

# Používání HAVING

## ■ Důvod zavedení

- Zkrácení dotazů, které filtrují podle výsledku agregačních funkcí
- Ve WHERE nelze použít agregační funkci
- V klauzuli HAVING ano

## ■ Příklad

- ```
SELECT avg(salary), dept
FROM employee
GROUP BY dept
HAVING avg(salary) > 10 000;
```



# Používání HAVING

## ■ Jiný příklad


```
SELECT avg(salary), dept  
FROM employee  
GROUP BY dept  
HAVING count(ssnum) > 100;
```

# Používání HAVING

## ■ Nepoužívat HAVING

- Pokud lze zapsat ve WHERE.

```
SELECT avg(salary) as avgsalary, dept
FROM employee
GROUP BY dept
HAVING dept = 'information systems';
```



```
SELECT avg(salary) as avgsalary, dept
FROM employee
WHERE dept= 'information systems'
GROUP BY dept;
```

# Používání pohledů

```
CREATE VIEW techlocation AS
  SELECT ssn, tech.dept, location
  FROM employee, tech
  WHERE employee.dept = tech.dept;
```

```
SELECT location
FROM techlocation
WHERE ssn = 43253265;
```

- Optimalizátor dotazů provede nahrazení pohledu jeho definicí

# Používání pohledů

- Výsledkem dostaneme:

```
SELECT location  
FROM employee, tech  
WHERE employee.dept = tech.dept  
      AND ssnun = 43253265;
```

# Používání pohledů

## ■ Příklad v PostgreSQL:

```
□ CREATE VIEW hotels_in_city AS  
  SELECT city, COUNT(*) AS count  
  FROM hotel  
  GROUP BY city;
```

## ■ Použití pohledu

```
□ SELECT * FROM hotels_in_city  
  WHERE count > 8;
```

# Používání pohledů

## ■ Příkaz EXPLAIN


□ EXPLAIN SELECT \* FROM hotels\_in\_city;

□ EXPLAIN SELECT \* FROM hotels\_in\_city  
WHERE count > 8;

### ■ Porovnejte s

```
EXPLAIN SELECT city, COUNT(*)  
FROM hotel GROUP BY city  
HAVING COUNT(*) > 8;
```

# Přepisování dotazů: výkonnostní vliv



100k zaměstnanců, 100k studentů, 10 tech. oddělení

# Optimalizace agregačních funkcí

## ■ Příklad:

- Evidence objednávek obchodního řetězce
  - Order(ordernum, itemnum, quantity, purchaser, vendor)
  - Item(itemnum, description, price)
  - Shlukované indexy nad *itemnum* pro *Order* a *Item*
- Každých 5 minut se provádí dotazy:
  - Celková cena objednaného zboží jistého výrobce (vendor).
  - Celková cena objednaného zboží nějakým obchodem (purchaser).



# Optimalizace agregačních funkcí

## ■ Dotazy:

- SELECT vendor, sum(quantity\*price)  
FROM order, item  
WHERE order.itemnum = item.itemnum  
GROUP BY vendor;
- SELECT purchaser, sum(quantity\*price)  
FROM order, item  
WHERE order.itemnum = item.itemnum  
GROUP BY purchaser;

## □ Cena dotazů?

- → jsou drahé

# Optimalizace agregáčníc funkcí

## ■ Jak zrychlit?

Definice pohledů?

■ → nepomůže

Ukládat výsledky do pomocných tabulek?

■ → pomůže

# Optimalizace agregáčníc funkcí

## ■ Vytvoříme tabulky

- OrdersByVendor(vendor, amount)
- OrdersByPurchaser(purchaser, amount)

## ■ Tabulky se musí aktualizovat

### □ Kdy aktualizovat?

#### ■ Po každé změně *order*, popř. *item*?

- Realizovat pomocí triggerů (spouští)

#### ■ Periodicky po určitém čase znovu vytvořit

### □ Náklady na aktualizaci

#### ■ Musí být menší než náklady na původní dotazy.

# Uložené (materializované) pohledy

- Výsledek pohledu je uložený v tabulce
  - Automatická aktualizace databází
    - Obvykle...
  - Použití i v dotazech, které daný pohled nepoužívají
    - Optimalizátor dotazů přepisuje dotaz

# Uložené (materializované) pohledy

## ■ Např. Oracle

- CREATE MATERIALIZED VIEW

OrdersByVendor

BUILD IMMEDIATE REFRESH COMPLETE

ENABLE QUERY REWRITE

AS

SELECT vendor, sum(quantity\*price) AS amount

FROM order, item

WHERE order.itemnum = item.itemnum

GROUP BY vendor;

# Uložené (materializované) pohledy

## ■ Příklad

### □ QUERY REWRITE


### □ Dotaz:

- SELECT vendor, sum(quantity\*price) AS amount  
FROM order, item  
WHERE order.itemnum = item.itemnum  
          AND vendor='Apple'  
GROUP BY vendor;
- Použije se pohled OrdersByVendor
  - SELECT vendor, amount FROM OrdersByVendor  
WHERE vendor='Apple';

# Uložené (materializované) pohledy

## ■ Příklad

- SQLServer, implementováno pomocí triggerů
- 1m objednávek – 5 obchodů, 20 výrobců
- 10k položek



# Databázové spouště (triggers)

- Spoušť je uložené procedura
  - Kód používající SQL příkazy prováděný při výskytu nějaké události.
- Události:
  - DML – insert, update, delete
  - Časové (nebývá časté)
  - DDL – definice tabulek, ...



# Databázové spouště (triggers)

- Nezávislé na aplikaci
  - Protože jsou prováděny samotným DB serverem.
- Bez spouští musí být vše řešeno aplikací
- Přinášejí dodatečné náklady
  - Mohou vkládat do dalších tabulek, ...
  - Spouštění omezovat podmínkami
    - Např. při aktualizaci ceny, počtu objednaných položek
    - Ne při aktualizaci popisu položky, ...

# Globální změny

- Vytvoření indexu
- Změna schéma
  - Viz další přednáška
- Rozdělení relací
  - Viz další přednáška
- ...

# Používání indexů

## ■ Malá tabulka

- Indexy jsou vytvořeny
- Přesto nejsou používány

## ■ Příklad

- `predmet(kod, nazev, kredity)`
- `SELECT COUNT(*) FROM predmet;`
  - Výsledek 3
- `SELECT * FROM predmet  
WHERE kod='MA102';`
  - Použije se table-scan.

# Vytváření indexů

## ■ Sekvenční čtení tabulky

- Všechny záznamy jsou kontrolovány
- → pomalé

## ■ Vytvoření indexu

- Zrychlí SELECT
- Zpomalí INSERT, UPDATE, DELETE
  - Index se musí aktualizovat

# Vliv indexu na náklady

- Neplatí:

- Čím více indexů, tím rychlejší zpracování!

- Teoreticky platné pouze pro SELECT.

- Každý index zpomaluje aktualizace

- Nutné aktualizovat kromě relace i index

- Pozor:

- INSERT INTO tabulka SELECT ...

- DELETE FROM tabulka WHERE ...

# Příklad odhadu nákladů

## ■ Relace

- StarsIn(movieTitle, movieYear, starName)

## ■ $Q_{\text{movies}}$

- SELECT movieTitle, movieYear FROM StarsIn WHERE starName='jméno';

## ■ $Q_{\text{stars}}$

- SELECT starName FROM StarsIn WHERE movieTitle='název' AND movieYear='rok';

## ■ Insert

- INSERT INTO StarsIn VALUES ('název', 'rok', 'jméno');

# Příklad odhadu nákladů

## ■ Předpoklady:

- $B(\text{StarsIn}) = 10$  bloků
- Každá hvězda hraje průměrně ve 3 filmech.
- Každý film má průměrně 3 hvězdy.
- Relace není nijak uspořádaná.
  - Pokud je index, pak 3 čtení z disku.
- Aktualizace indexu – 1 čtení a 1 zápis bloku
- Vkládání do relace – 1 čtení a 1 zápis bloku
  - I bez indexu nehledáme volný blok.

# Příklad odhadu nákladů

- Počty čtení a zápisů pro jednotlivé situace
  - Pravděpodobnost provádění operací
    - $Q_{\text{movies}}=p_1$ ,  $Q_{\text{stars}}=p_2$ ,  $\text{Insert}=1 - p_1 - p_2$
  - Situace1:  $p_1 = p_2 = 0.1 \rightarrow$  bez indexů
  - Situace2:  $p_1 = p_2 = 0.4 \rightarrow$  oba indexy

| Akce                | Žádný index       | Index <i>starName</i> | Index <i>movieTitle, movieYear</i> | Oba indexy        |
|---------------------|-------------------|-----------------------|------------------------------------|-------------------|
| $Q_{\text{movies}}$ | 10                | 4                     | 10                                 | 4                 |
| $Q_{\text{stars}}$  | 10                | 10                    | 4                                  | 4                 |
| Insert              | 2                 | 4                     | 4                                  | 6                 |
| Prům. náklady       | $2 + 8p_1 + 8p_2$ | $4 + 6p_2$            | $4 + 6p_1$                         | $6 - 2p_1 - 2p_2$ |



# Optimalizace indexů

1. Stanovit dávku příkazů
  - Tj. způsob vytížení
  - Analýzou logů zjistit typy dotazů, aktualizací a jejich četnosti
2. Navrhnout různé indexy
  - Optimalizátor nechat odhadnou cenu vyhodnocení dávky příkazů
  - Vybrat konfiguraci s nejmenší cenou
3. Vytvořit indexy, které minimalizují cenu

# Optimalizace indexů

## ■ Ad bod 2

- Mám sadu možných indexů
- Začni bez indexů
- Opakuj
  - Pro každý navrhovaný index, vypočítej cenu
  - Vytvoř index s nejvyšším vylepšením ceny
    - A používej jej v další iteraci
  - Opakuj, dokud byl nějaký index vytvořený.

## ■ Celý proces lze dělat i automaticky

- MS AutoAdmin (<http://research.microsoft.com/en-us/projects/autoadmin/default.aspx>)
- MS Index Tuning Wizard (S. Chaudhuri, V. Narasayya: *An efficient, Cost-Driven Index Selection Tool for Microsoft SQL Server*. Proceedings of VLDB Conference, 1997)
- Oracle 10g (<http://www.oracle-base.com/articles/10g/AutomaticSQLTuning10g.php>)

# Referenční integrita

- Vytvoření cizího klíče neznamena index na attributech
- Příklad v PostgreSQL (db.fi.muni.cz)
  - Hotel – primární klíč *id*
  - Room – primární klíč *id*, cizí klíč *hotel\_id*
    - $V(\text{Room}, \text{hotel\_id}) = 6$
- Dotazy (zajímá nás výsledek EXPLAIN)

```
SELECT * FROM hotel WHERE id=2;
```

```
SELECT * FROM room WHERE hotel_id=2 AND number=1;
```

# Referenční integrita

## ■ Dotaz

```
SELECT * FROM room WHERE hotel_id=2 AND number=1;
```

## ■ Bez indexu

```
Seq Scan on room (cost=0.00..6741.89 rows=103 width=22)  
Filter: ((hotel_id = 2) AND (number = 1))
```

## ■ Vytvoříme index nad *hotel\_id*

```
CREATE INDEX hotel_id_fkey ON room (hotel_id);
```

```
Bitmap Heap Scan on room (cost=981.00..3784.38 rows=103 width=22)
```

```
Recheck Cond: (hotel_id = 2)
```

```
Filter: (number = 1)
```

```
-> Bitmap Index Scan on hotel_id_fket (cost=0.00..980.97 rows=52892 width=0)
```

```
Index Cond: (hotel_id = 2)
```

# Referenční integrita

- Cizí klíče mohou velmi zpomalit i mazání
- Příklad:
  - DELETE FROM hotel WHERE id=500;
  - Cizí klíč v *room* odkazuje na tabulku *hotel*
  - Při mazání se musí v tabulce *room* kontrolovat přítomnost záznamů *hotel\_id=500*
- Doporučení
  - Vytvářet na cizích klíčích indexy