PA152: Efektivní využívání DB
6. Zpracování dotazů

Vlastislav Dohnal

Poděkování

- Zdrojem materiálů tohoto předmětu jsou:
  - Přednášky CS245, CS345, CS345
    - Hector Garcia-Molina, Jeffrey D. Ullman, Jennifer Widom
    - Stanford University, California

Vyhodnocení dotazu

- Postup:
  - Dotaz
  - Syntaktická a sémantická kontrola
    - Strom dotazu
  - Logický plán
    - Úpravy plánu
  - Fyzický plán
  - Vyhodnocení

Příklad

- Relace
  - R(A,B,C)
  - S(C,D,E)
- Dotaz
  - select B,D
    from R,S
    where R.C=S.C and R.A=‘c’ and S.E=2

Příklad

R

A	B	C
a	1	10
b	1	20
c	2	10
d	2	35
e	3	45

S

C	D	E
10	x	2
20	y	2
30	z	2
40	x	1
50	y	3

select B,D from R,S where R.C=S.C and R.A='c' and S.E=2

Příklad

R	A	B	C
	a	1	10
	b	1	20
	c	2	10
	d	2	35
	e	3	45

S	C	D	E
	10	x	2
	20	y	2
	30	z	2
	40	x	1
	50	y	3

Odpověď

B	D
2	x

Jak vyhodnotit tento dotaz?

1. způsob

- Kartézský součin
- Výběr záznamů
- Projekce

$R \times S$

R.A	R.B	R.C	S.C	S.D	S.E
a	1	10	10	x	2
a	1	10	20	y	2
.					
.					
c	2	10	10	x	2
.					
.					

R × S

R.A	R.B	R.C	S.C	S.D	S.E
a	1	10	10	x	2
a	1	10	20	y	2
.					
.					
c	2	10	10	x	2
.					
.					

Tento záznam vyhovuje

Výstup – výsledek dotazu

select B,D from R,S where R.C=S.C and R.A='c' and S.E=2

Popis plánů provedení dotazu

- Použití relační algebry
  - $\Pi_{B,D}\,[\,\sigma_{R.A='c' \wedge S.E=2 \wedge R.C = S.C}\,(R \times S)]$
- Příklad plánu 1:
  - Strom dotazu

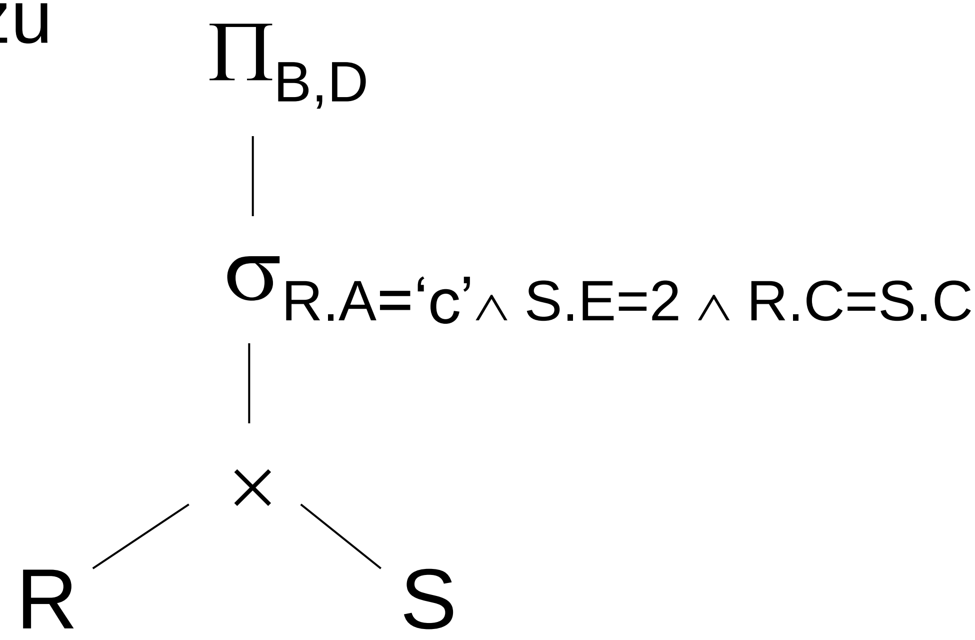

Popis plánů provedení dotazu

- Příklad plánu 2:

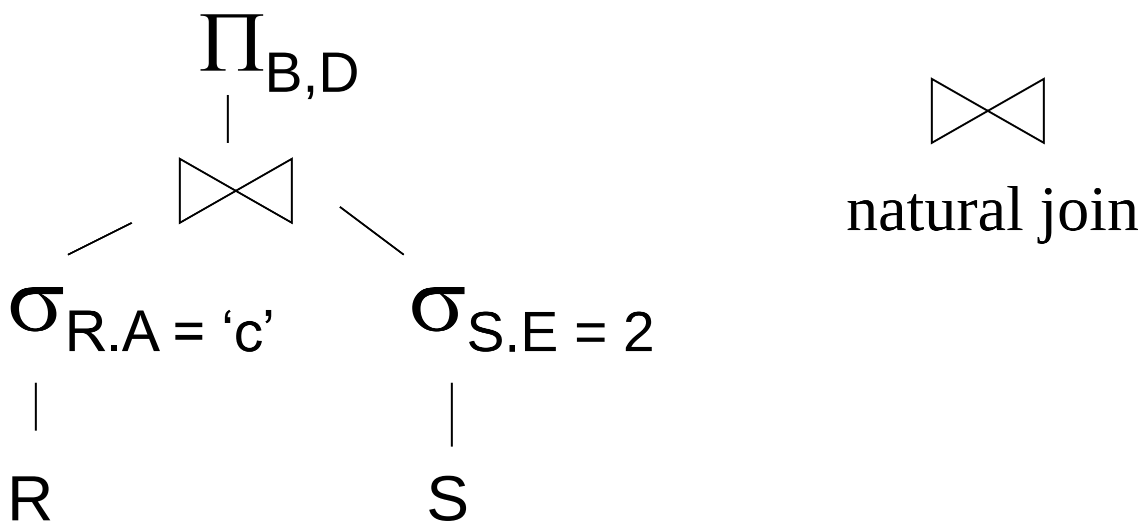

Fyzický plán

- Příklad plánu 2:

R

A	B	C
a	1	10
b	1	20
c	2	10
d	2	35
e	3	45

σ (R)

A	B	C
c	2	10

σ(S)

C	D	E
10	x	2
20	y	2
30	z	2

S

C	D	E
10	x	2
20	y	2
30	z	2
40	x	1
50	y	3

$\bowtie$

Popis plánů provedení dotazu

- Plán 3:
  - Máme indexy pro R.A a S.C
  - Použijeme index R.A k nalezení záznamů R splňující R.A = “c”
    - Pro každou nalezenou hodnotu R.C použijeme index S.C pro nalezení odpovídajících záznamů
    - Vypustíme záznamy S, kde S.E ≠ 2
  - Spojíme odpovídající záznamy R,S
  - Provedeme projekci na atributy B,D

R

A	B	C
a	1	10
b	1	20
c	2	10
d	2	35
e	3	45

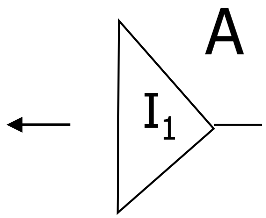

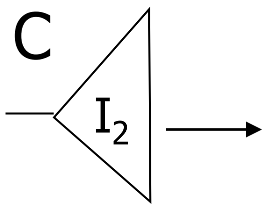

S

C	D	E
10	x	2
20	y	2
30	z	2
40	x	1
50	y	3

R

A	B	C
a	1	10
b	1	20
c	2	10
d	2	35
e	3	45

$\mathbf{A}$ ='c'

I_1

<c,2,10>

$\mathbf{C}$

I_2

S

C	D	E
10	x	2
20	y	2
30	z	2
40	x	1
50	y	3

R

A	B	C
a	1	10
b	1	20
c	2	10
d	2	35
e	3	45

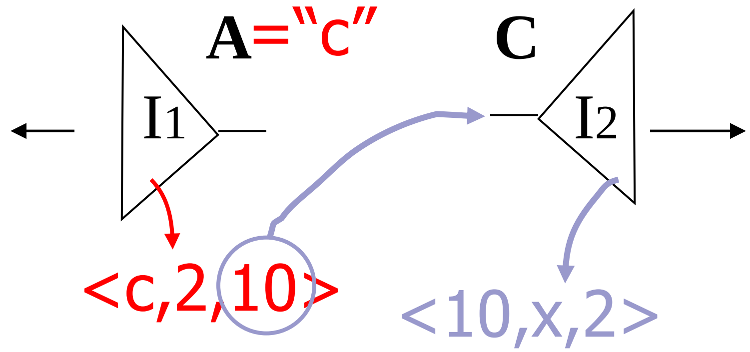

S

C	D	E
10	x	2
20	y	2
30	z	2
40	x	1
50	y	3

R

A	B	C
a	1	10
b	1	20
c	2	10
d	2	35
e	3	45

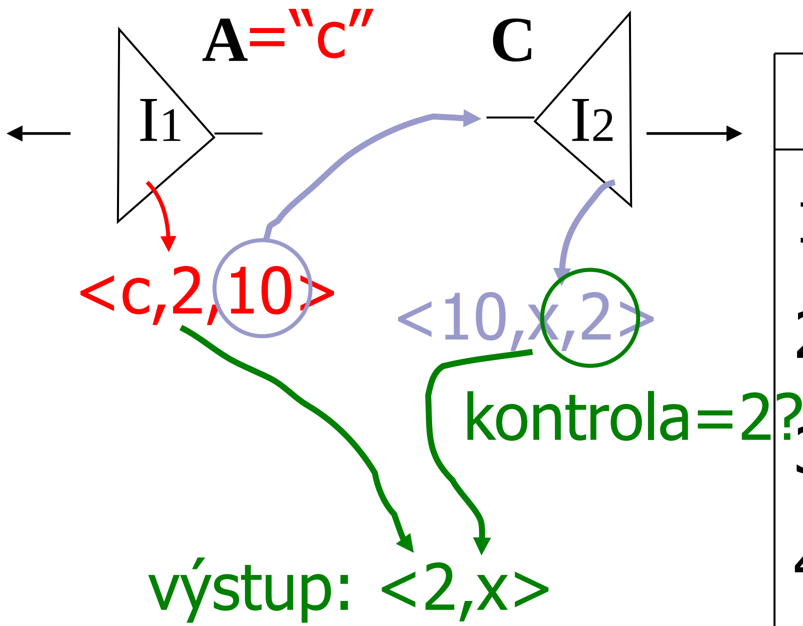

S

C	D	E
10	x	2
20	y	2
30	z	2
40	x	1
50	y	3

R

A	B	C
a	1	10
b	1	20
c	2	10
d	2	35
e	3	45
⋮		

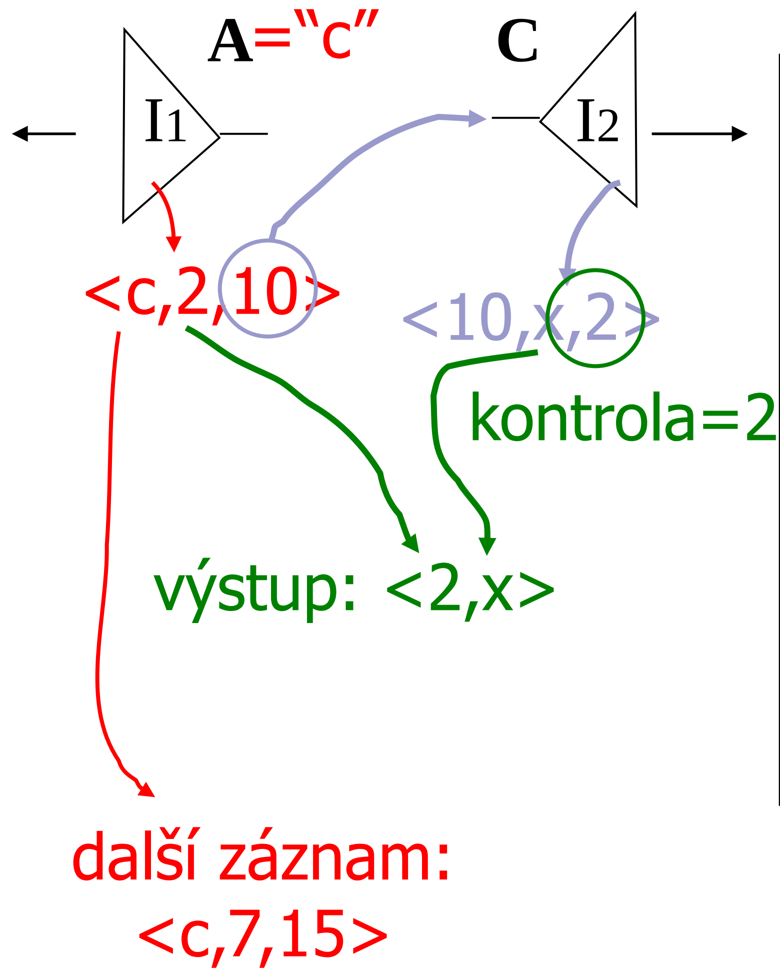

S

C	D	E
10	x	2
20	y	2
30	z	2
40	x	1
50	y	3

Přehled optimalizace dotazů

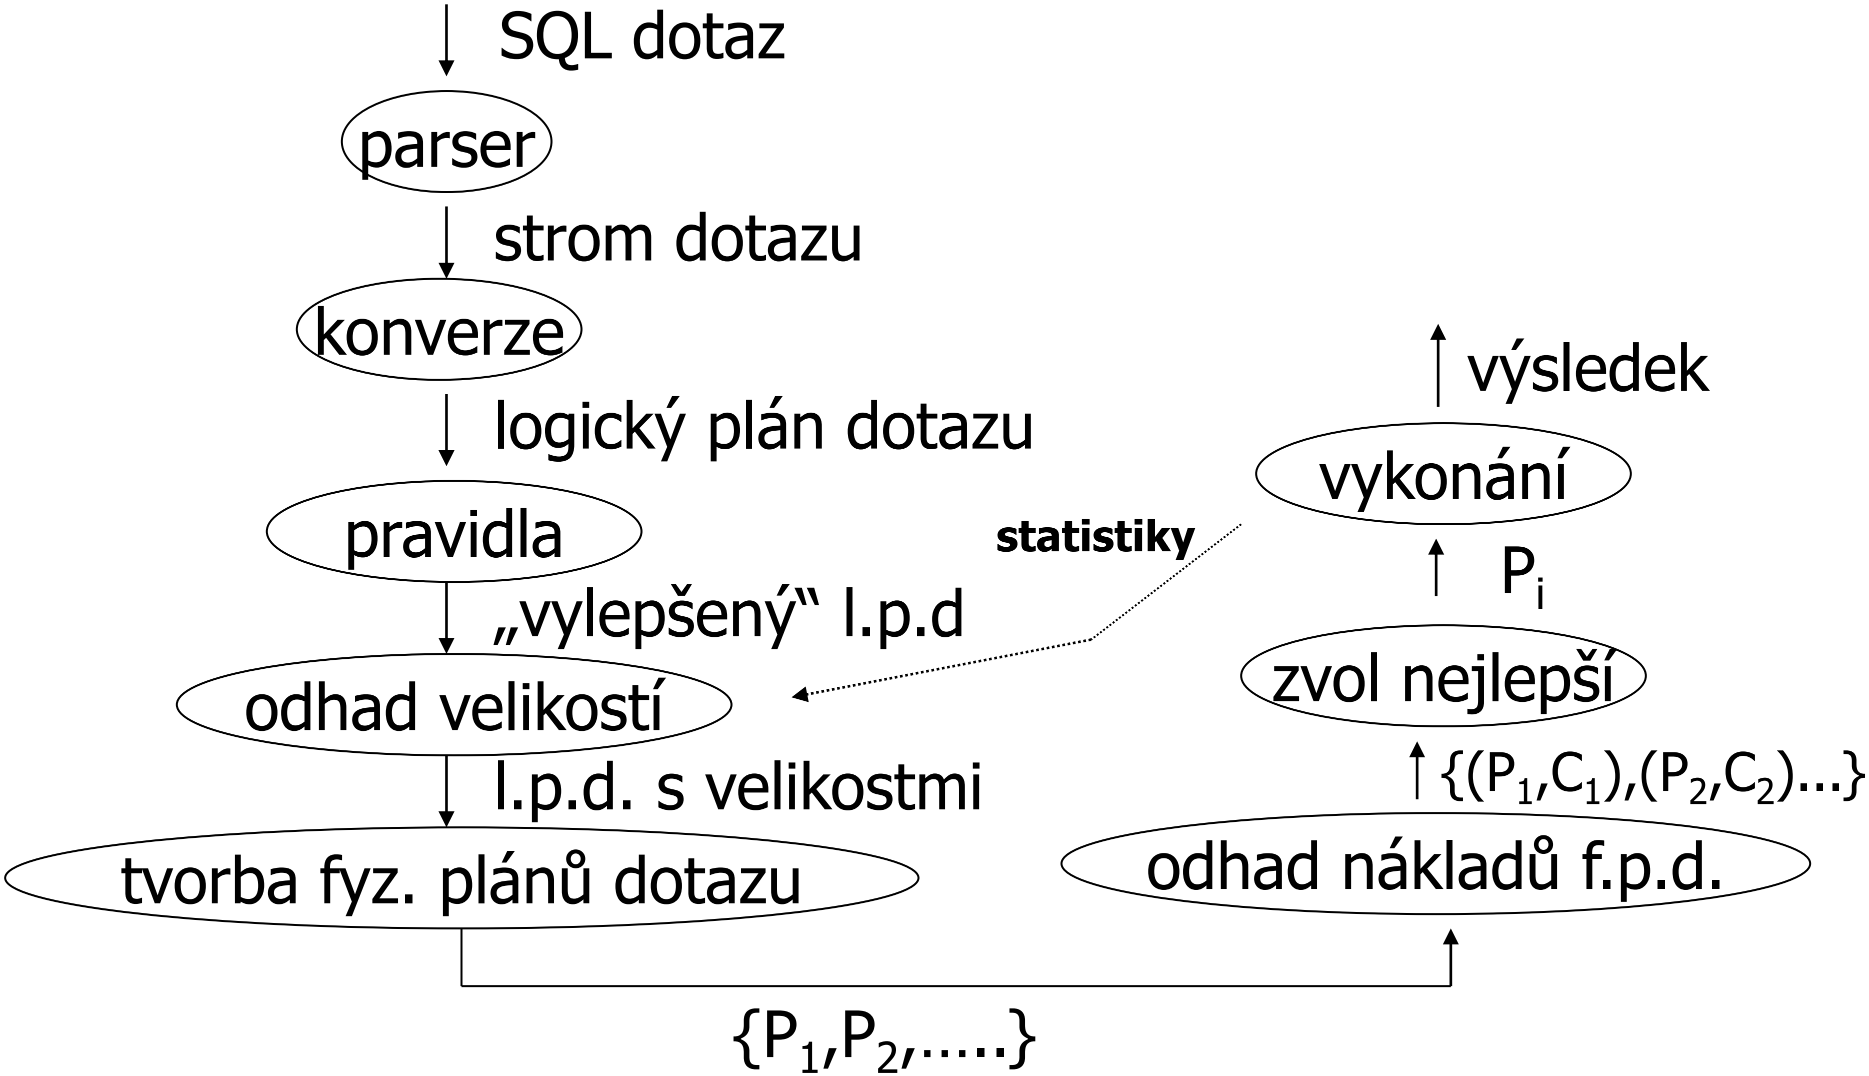

Příklad: SQL dotaz

- Relace
  - StarsIn(title, year, starName)
  - MovieStar(name, birthdate)
- Dotaz
  - Najdi filmy, ve kterých hrají herci narození v roce 1960:
  - ```
    SELECT title
    FROM StarsIn
    WHERE starName IN (
                SELECT name
                FROM MovieStar
                WHERE birthdate LIKE ‘%1960’
    );
    ```
    ```

Příklad: strom dotazu

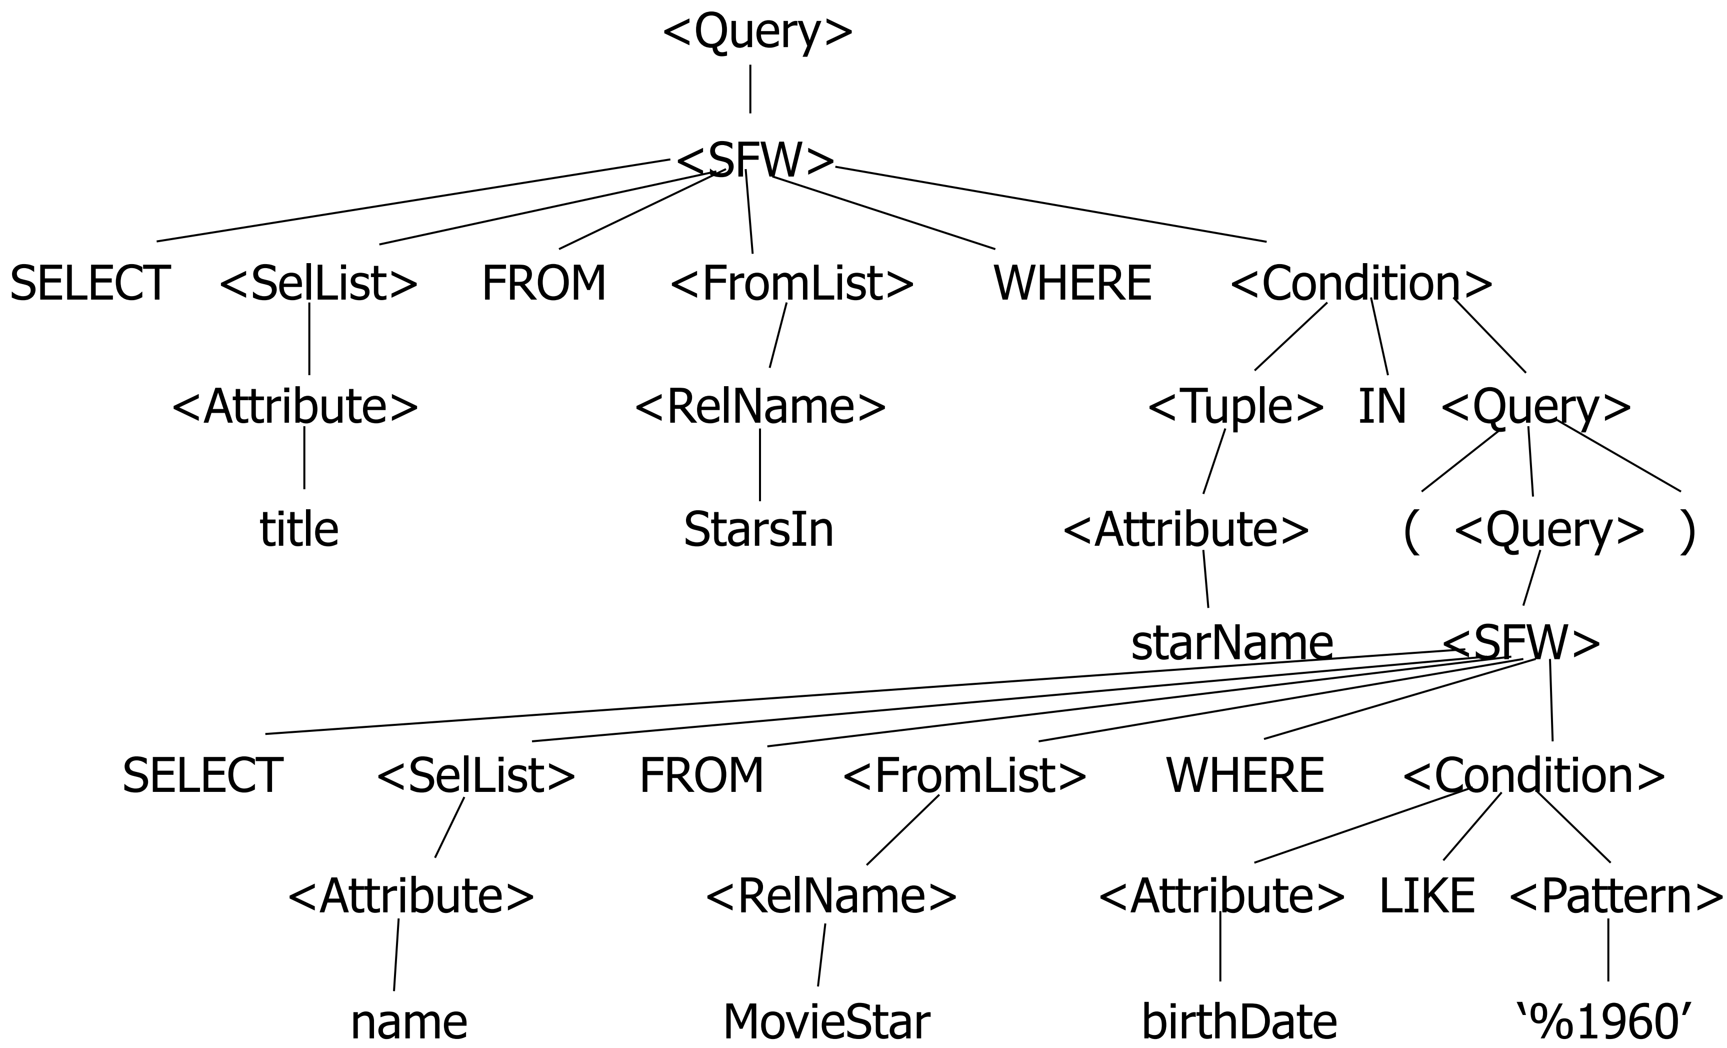

Příklad: převod do relační algebry

- Selekce má dva argumenty
  - Třeba převést…
- Operátor IN
  - Tj. odstranění vnořených dotazů

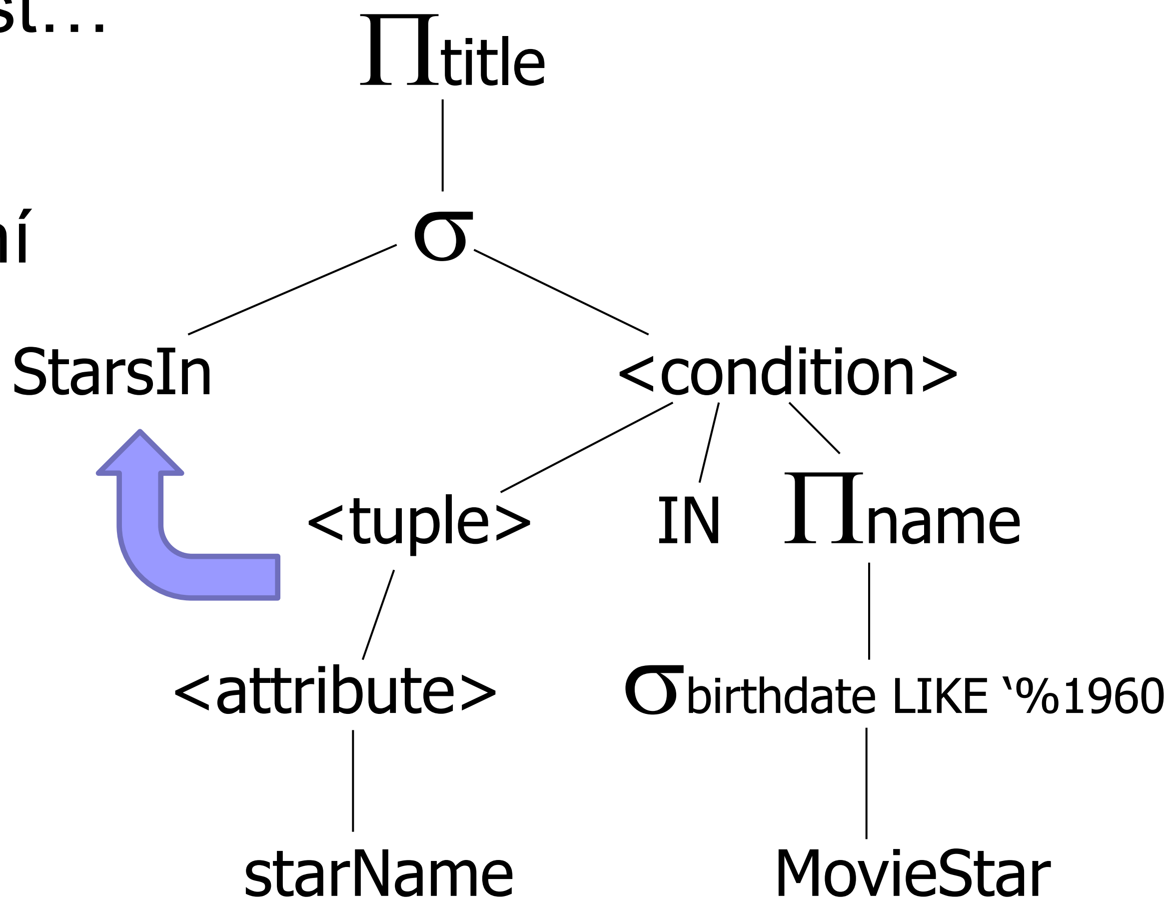

Příklad: logický plán dotazu

- Operátor IN nahrazen součinem

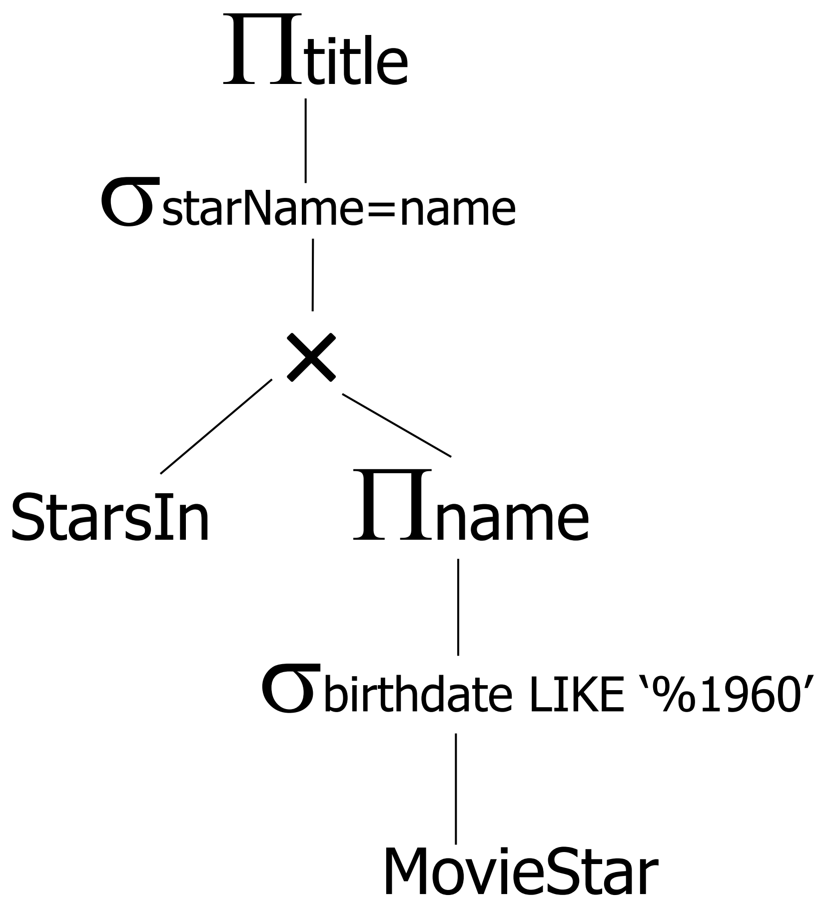

Příklad: vylepšení logického plánu

- Nahrazení součinu a selekce
  - Provedení spojení
- Další možnost
  - Posunout projekci k relaci *StarsIn*?

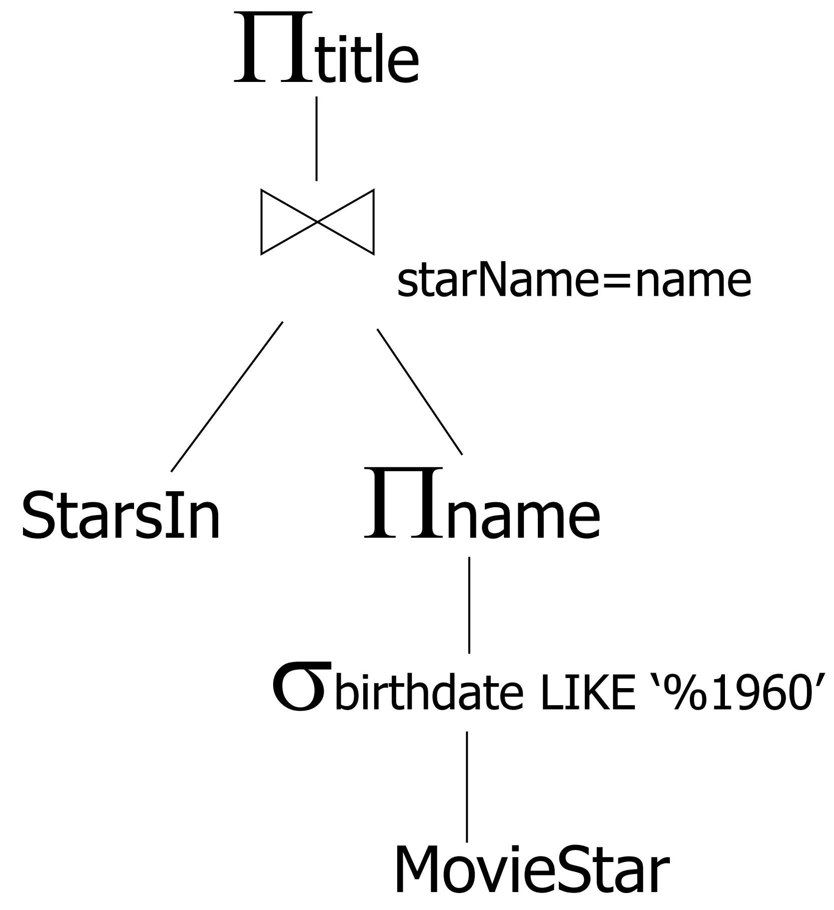

Příklad: odhad velikostí výsledků

- Před generováním fyzických plánů
- Ovlivňují odhad ceny provedení

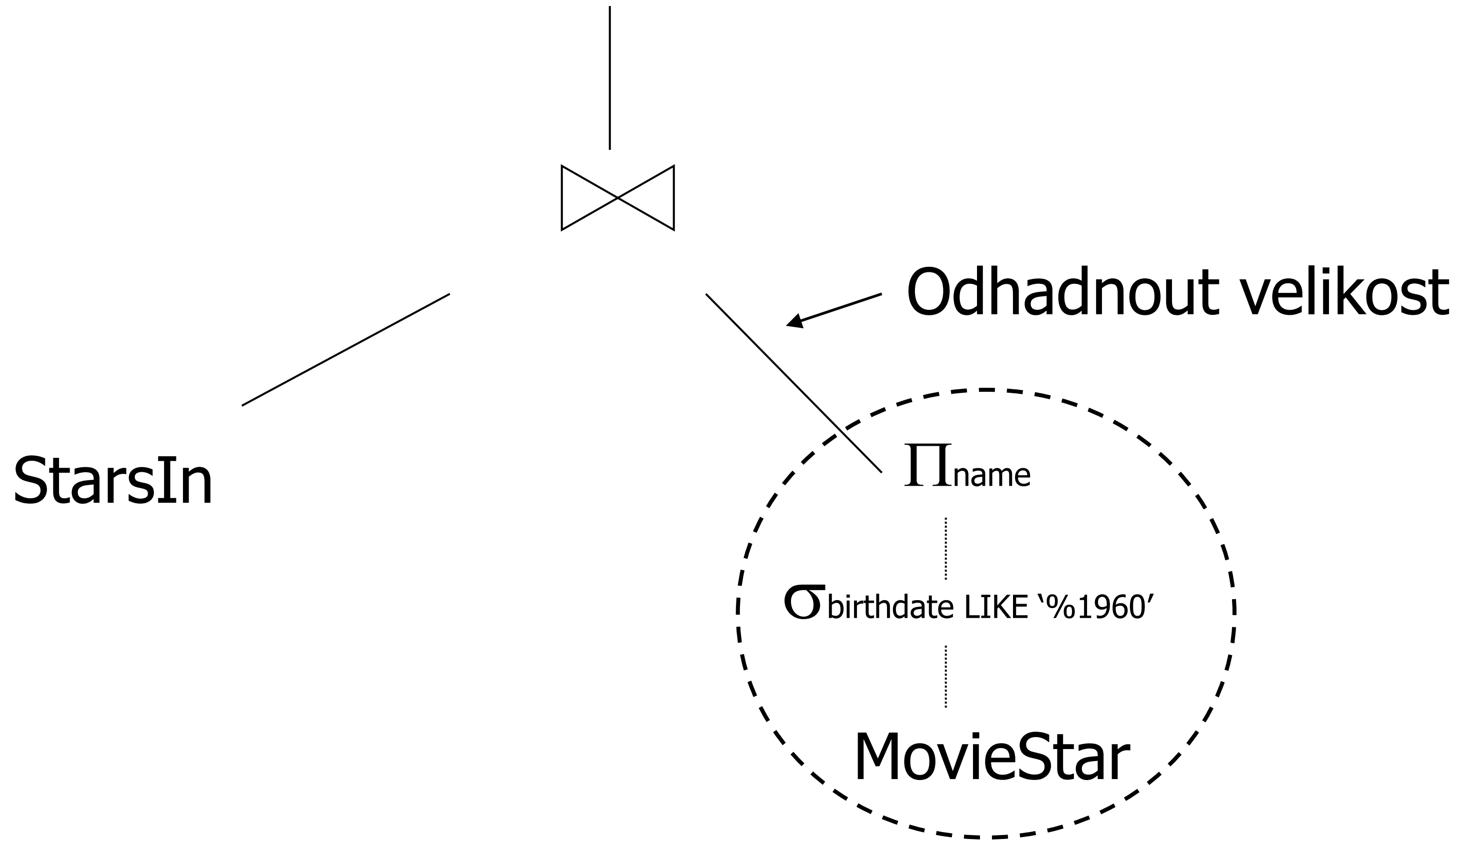

Příklad: jeden fyzický plán

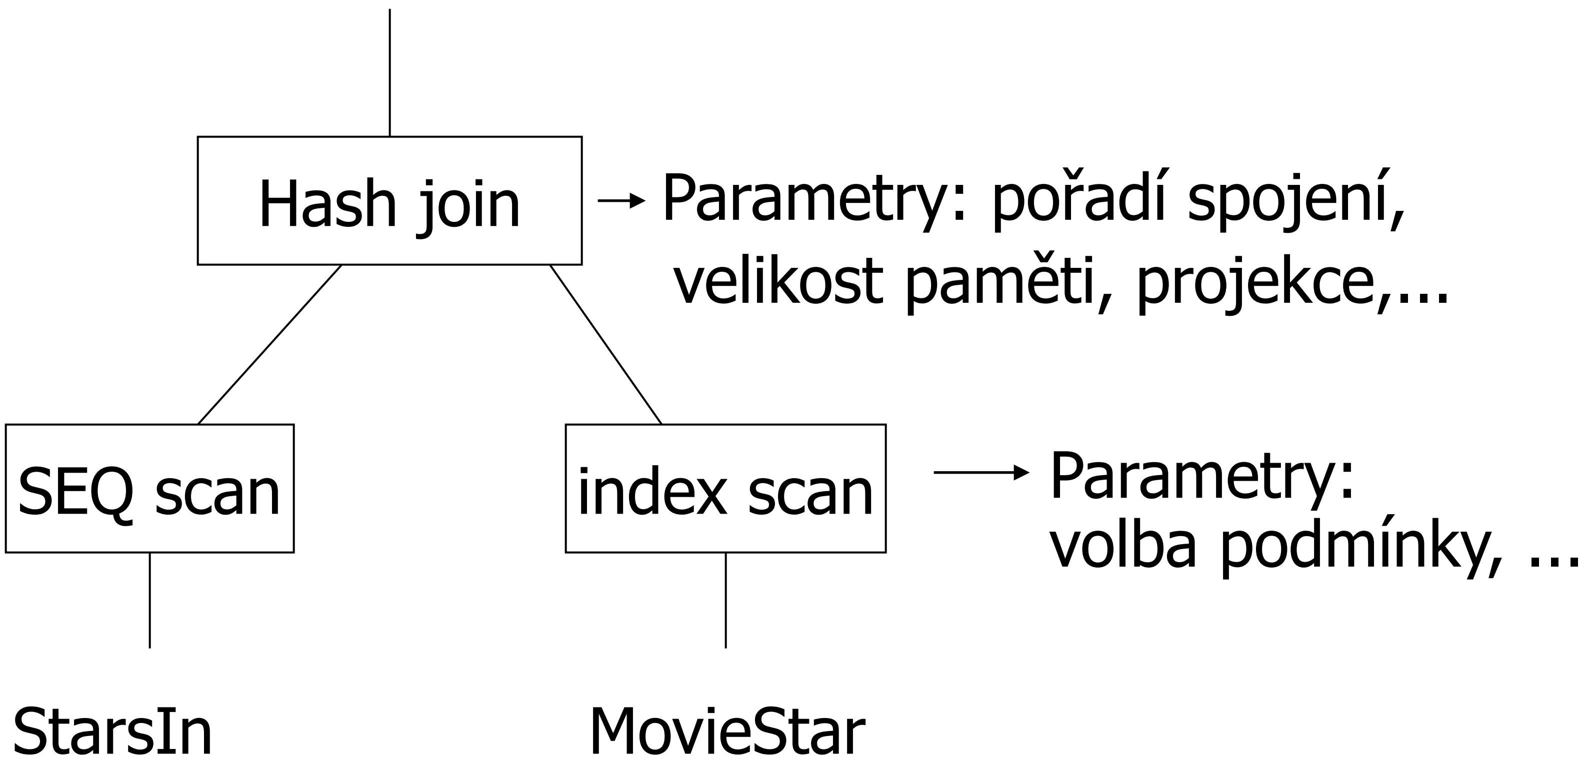

Příklad: ohodnocení plánů cenou

Logický plán dotazu

Plán$_1$ Plán$_2$ …. Plán$_n$

Cena$_1$ Cena$_2$ …. Cena$_n$

Vyber plán s nejnižší cenou!

Optimalizace dotazu

- Úroveň relační algebry
- Úroveň podrobného plánu dotazu
  - Odhad ceny
    - Bez indexů
    - S indexy
  - Vytvoření a porovnání plánů

Optimalizace relační algebry

- Transformační pravidla
  - Musí zajistit ekvivalenci výsledků
  - Jaké transformace jsou vhodné?

Transformační pravidla

- Přirozené spojení
  - Protože jsou všechny atributy zachovány, není pořadí důležité
- Příklad: $R \bowtie S = S \bowtie R$

  $(R \bowtie S) \bowtie T = R \bowtie (S \bowtie T)$

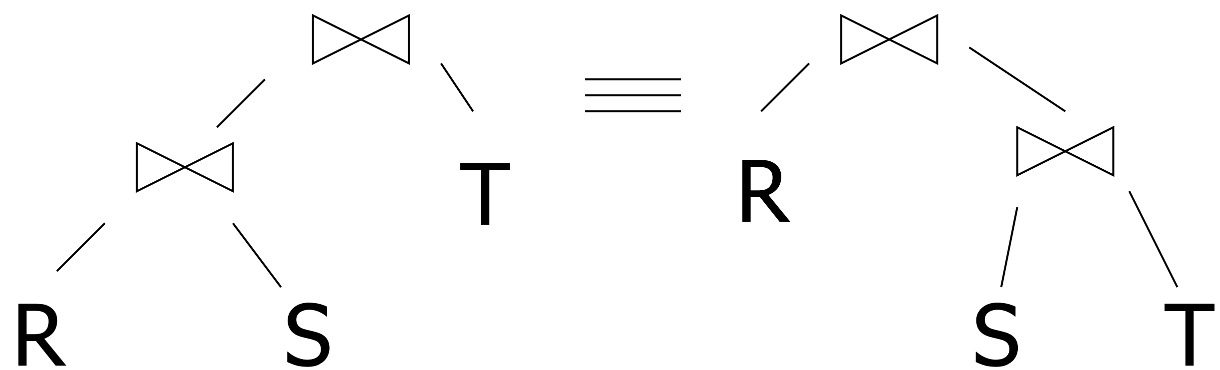

Transformační pravidla

- Stejné pro kartézský součin a sjednocení

$$R \times S = S \times R$$

$$(R \times S) \times T = R \times (S \times T)$$

$$R \cup S = S \cup R$$

$$R \cup (S \cup T) = (R \cup S) \cup T$$

Transformační pravidla

- Selekce

$$\sigma_{p1 \wedge p2}(R) = \sigma_{p1} [\sigma_{p2} (R)]$$

$$\sigma_{p1 \wedge p2}(R) = [\sigma_{p1} (R)] \cap [\sigma_{p2} (R)]$$

$$\sigma_{p1 \vee p2}(R) = [\sigma_{p1} (R)] \cup [\sigma_{p2} (R)]$$

Problém duplicit

- Množiny nebo multimnožiny?
  - Relace jsou multimnožiny
- Příklad
  - $R = \{a,a,b,b,b,c\}$
  - $S = \{b,b,c,c,d\}$
- $R \cup S = ?$
- Možnosti $\cup$
  - SUM: $R \cup S = \{a,a,b,b,b,b,b,c,c,c,d\}$
  - MAX: $R \cup S = \{a,a,b,b,b,c,c,d\}$
- $R \cap S = ?$
  - MIN: $R \cap S = \{b,b,c\}$ v SQL: INTERSECT ALL

Možnost SUM: sjednocení relací

- Sjednocení dvou relací
  - $R \cup S$ v SQL: UNION ALL
- Příklad
  - Poslanci(id, rok, partaj, …)
  - Senátoři(id, rok, partaj, …)
  - $R = \pi_{rok,partaj}(Senátoři)$ $S = \pi_{rok,partaj}(Poslanci)$

rok	partaj
1997	ODS
2003	ČSSD
2007	SZ

rok	partaj
1997	ODS
1998	KDU
1996	ČSSD

Možnost MAX: rozklad selekce

- Rozklad selekce:

$$\sigma_{p_1 \vee p_2}(R) = \sigma_{p_1}(R) \cup \sigma_{p_2}(R)$$

- Příklad: R={a,a,b,b,b,c}
  - p_1 splňují a,b; p_2 splňují b,c

$$\sigma_{p_1 \vee p_2}(R) = \{a,a,b,b,b,c\}$$

$$\sigma_{p_1}(R) = \{a,a,b,b,b\}$$

$$\sigma_{p_2}(R) = \{b,b,b,c\}$$

$$\sigma_{p_1}(R) \cup \sigma_{p_2}(R) = \{a,a,b,b,b,c\}$$

Volba správné možnosti

- Pragmatické rozhodnutí
  - Použití “SUM” pro sjednocení multimnožin
  - Některá pravidla nemůžeme pro multimnožiny použít

Transformační pravidla

- Značení:
  - X = množina atributů
  - Y = množina atributů
  - XY = X ∪ Y
- Projekce

$$\pi_{xy}(R) = \pi_x[\pi_y(R)]$$

Transformační pravidla

- Kombinace selekce a přirozeného spojení
- Nechť

  p = výraz obsahující pouze atributy R

  q = výraz obsahující pouze atributy S

  m = výraz obsahující atributy R i S

$$\sigma_p (R \bowtie S) = [\sigma_p (R)] \bowtie S$$

$$\sigma_q (R \bowtie S) = R \bowtie [\sigma_q (S)]$$

Transformační pravidla

- Kombinace selekce a přirozeného spojení
  - Další pravidla lze odvodit

$$\sigma_{p \wedge q} (R \bowtie S) = [\sigma_p (R)] \bowtie [\sigma_q (S)]$$

$$\sigma_{p \wedge q \wedge m} (R \bowtie S) =$$

$$\sigma_m \left[(\sigma_p (R)) \bowtie (\sigma_q (S))\right]$$

$$\sigma_{p \vee q} (R \bowtie S) =$$

$$\left[(\sigma_p (R)) \bowtie S\right] \cup \left[R \bowtie (\sigma_q (S))\right]$$

Transformační pravidla

- Kombinace selekce a přirozeného spojení
  - Příklad odvození pravidla

$$\sigma_{p \wedge q} (R \bowtie S) =$$

$$\sigma_p \left[\sigma_q (R \bowtie S)\right] =$$

$$\sigma_p \left[R \bowtie \sigma_q (S) \right] =$$

$$[\sigma_p (R)] \bowtie [\sigma_q (S)]$$

Transformační pravidla

- Kombinace selekce a přirozeného spojení
  - Příklad odvození pravidla
  - Nechť

    n = výraz obsahující pouze atributy společné R i S

$$\sigma_n (R \bowtie S) = [\sigma_n (R)] \bowtie [\sigma_n (S)]$$

Transformační pravidla

- Kombinace projekce a selekce
- Nechť

  x = podmnožina atributů R

  z = atributy použité ve výrazu P
  (podmnožina R)

$$\pi_x[\sigma_p(R)] = \pi_x\left(\sigma_p\left[\overset{\pi_{xz}}{\cancel{\pi_x}}(R)\right]\right)$$

Transformační pravidla

- Kombinace projekce a přirozeného spojení
- Nechť
  - x = podmnožina atributů R
  - y = podmnožina atributů S
  - z = průnik atributů R,S

$$\pi_{xy}(R \bowtie S) =$$

$$\pi_{xy}([\pi_{xz}(R)] \bowtie [\pi_{yz}(S)])$$

Transformační pravidla

- Kombinace navíc se selekcí

$$\pi_{xy}\left(\sigma_{p}\ (R \bowtie S)\right) =$$

$$\pi_{xy}\left(\sigma_{p}\ [\pi_{xz'}(R) \bowtie \pi_{yz'}(S)]\right)$$

$$z' = z \cup \{\text{atributy použité v P}\}$$

Transformační pravidla

- Kombinace projekce, selekce a kartézského součinu

$$\pi_{xy}\left(\sigma_{p}\ (R \times S)\right) = ?$$

Transformační pravidla

- Kombinace selekce a sjednocení

  $\sigma_p(R \cup S) = \sigma_p(R) \cup \sigma_p(S)$

- Kombinace selekce a rozdílu

  $\sigma_p(R - S) = \sigma_p(R) - S = \sigma_p(R) - \sigma_p(S)$

  - Selekci je možné aplikovat i na S
    - Může být vhodné pro zmenšení relace před provedením rozdílu
  - Musí *P* něco splňovat?

Vhodné transformace

$$\sigma_{p_1 \wedge p_2} (R) \rightarrow \sigma_{p_1} [\sigma_{p_2} (R)] \rightarrow \sigma_{p_2} [\sigma_{p_1} (R)]$$

$$\sigma_{p} (R \bowtie S) \rightarrow [\sigma_{p} (R)] \bowtie S$$

$$R \bowtie S \rightarrow S \bowtie R$$

$$\pi_{x} [\sigma_{p} (R)] \rightarrow \pi_{x} \left(\sigma_{p} [\pi_{xz} (R)]\right)$$

Vhodné transformace

- Projekce co nejdříve
- Příklad:
  - R(A,B,C,D,E,F,G,H,I,J)   výsledek={E}
  - Filtr P: (A=3) $\wedge$ (B="cat")

$$\pi_E(\sigma_p(R)) \quad \text{vs.} \quad \pi_E\big(\sigma_p(\pi_{ABE}(R))\big)$$

Vhodné transformace

- Máme indexy
  - Pro A i pro B

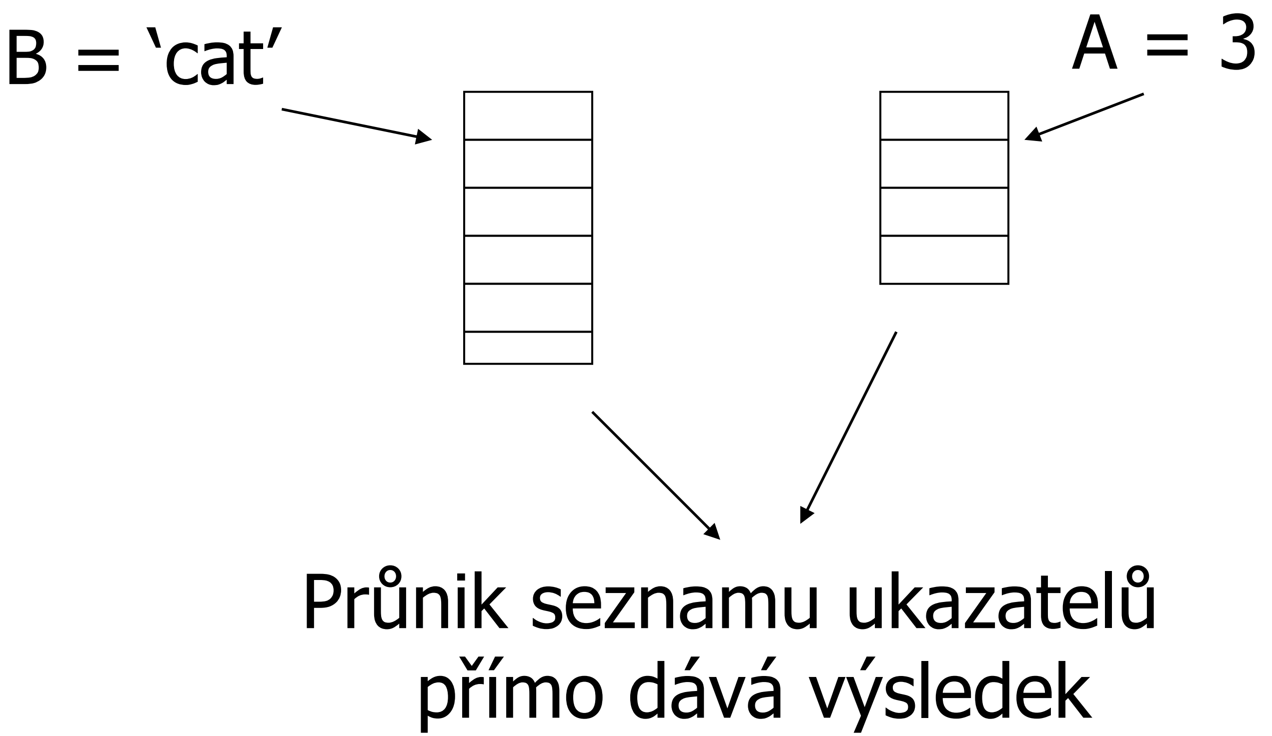

Vhodné transformace

- Obecná pravidla:
  - Bez transformací neuděláme chybu
  - Většinou výhodné
    - Selekce nejblíže relacím

- Eliminace společných podvýrazů
- Eliminace duplicit

Vhodné transformace: příklad

- Přesun selekce co nejblíže relacím → zdánlivě ok
  - Ale: Nejdříve vhodné přesunout co nejdále a pak nejblíže
- Příklad:
  - Relace: *StarsIn*(title, year, starName)
Movie(title, year, studioName)
  - Pohled: create view *MoviesOf1996* as
select * from *Movie* where *year* = 1996;
- Dotaz: select *starName*, *studioName*
from *MoviesOf1996* natural join *StarsIn*;

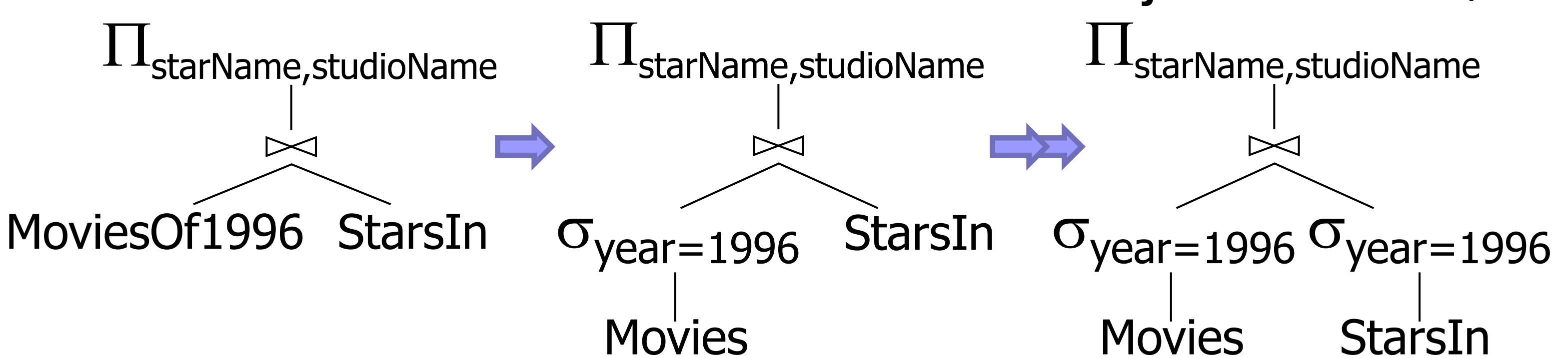

Zpracování dotazu: přehled

- Úroveň relační algebry
  - Transformační pravidla
  - Volba vhodných pravidel
- Úroveň podrobného plánu dotazu
  - Odhad ceny
  - Vytvoření a porovnání plánů

Odhad ceny plánu dotazu

1. Odhad velikosti výsledku operace
2. Odhad počtu V/V operací

Odhad velikosti výsledku

- Statistiky pro relaci R
  - T(R) – počet záznamů
  - S(R) – velikost záznamu v bajtech
    - S(R,A) – velikost atributu (hodnoty) v bajtech
  - B(R) – počet obsazených bloků
  - V(R, A) – počet unikátních hodnot atributu A
- Pro správné odhady
  - Statistiky musí být aktuální

Příklad statistik

- Relace R
  - Atribut A – řetězec, 20 bajtů
    - S(R,A) = 20
  - Atribut B – celé číslo, 4 bajty
  - Atribut C – datum, 8 bajtů
  - Atribut D – řetězec, 5 bajtů

A	B	C	D
cat	1	10.2.98	a
cat	1	20.3.98	b
dog	1	30.4.98	a
dog	1	14.6.98	c
bat	1	15.6.98	d

- Statistiky
  - T(R) = 5 S(R) = 37
  - V(R,A) = 3 V(R,B) = 1
  - V(R,C) = 5 V(R,D) = 4

Odhad velikosti výsledku

- Kartézský součin $W = R_1 \times R_2$
  - $T(W) = T(R_1) \cdot T(R_2)$
  - $S(W) = S(R_1) + S(R_2)$

Odhad velikosti výsledku

- Selekce $W = \sigma_{Z=val}(R)$
  - $S(W) = S(R)$
  - $T(W) = ?$

- $W = \sigma_{A=\text{'cat'}}(R)$

A	B	C	D
cat	1	10.2.98	a
cat	1	20.3.98	b
dog	1	30.4.98	a
dog	1	14.6.98	c
bat	1	15.6.98	d

$$T(W) = \frac{T(R)}{V(R,A)} = 5/3$$

V(R,A)=3
V(R,B)=1
V(R,C)=5
V(R,D)=4

- $W_2 = \sigma_{B=2}(R)$ $T(W_2) = ?$

Odhad velikosti výsledku

- Předpoklad předchozího odhadu
  - Rovnoměrné rozložení hodnot mezi hodnotami v R!
    - $f(val) = 1 / V(R,Z)$
    - $T(\sigma_{Z=val}(R)) = T(R) \cdot f(val)$

- Alternativní předpoklad
  - Rovnoměrné rozložení hodnot v celé doméně
    - Počet hodnot v doméně označujeme DOM(R,Z)
    - $f(val) = 1 / DOM(R,Z)$

Odhad velikosti výsledku: příklad

- Selekce $W = \sigma_{Z=val}(R)$
  - $T(W) = ?$
    - Podle DOM(R,.)
- Odvození
  - $W = \sigma_{C=val}(R)$
    - $T(W) = f(val) \cdot T(R)$
      $= 5/10 = 0,5$
  - $W = \sigma_{B=val}(R)$
    - $T(W) = (1/10)5$
  - $W = \sigma_{A=val}(R)$
    - $T(W) = 0,5$

A	B	C	D
cat	1	10.2.98	a
cat	1	20.3.98	b
dog	1	30.4.98	a
dog	1	14.6.98	c
bat	1	15.6.98	d

V(R,A)=3 DOM(R,A)=10
V(R,B)=1 DOM(R,B)=10
V(R,C)=5 DOM(R,C)=10
V(R,D)=4 DOM(R,D)=10

Odhad velikosti výsledku

- Selekce $W = \sigma_{Z=val}(R)$
  - Původní návrh

$$T(W) = \frac{T(R)}{V(R,Z)}$$

  - Alternativní návrh

$$T(W) = \frac{T(R)}{DOM(R,Z)}$$

A	B	C	D
cat	1	10.2.98	a
cat	1	20.3.98	b
dog	1	30.4.98	a
dog	1	14.6.98	c
bat	1	15.6.98	d

V(R,A)=3 DOM(R,A)=10
V(R,B)=1 DOM(R,B)=10
V(R,C)=5 DOM(R,C)=10
V(R,D)=4 DOM(R,D)=10

Odhad velikosti

- Selekce $W = \sigma_{Z \geq val}(R)$
  - Návrh 1
    - T(W) = T(R) / 2
  - Návrh 2
    - T(W) = T(R) / 3
  - Návrh 3
    - Podle velikosti rozsahu

Odhad velikosti

- Selekce – podle velikosti rozsahu

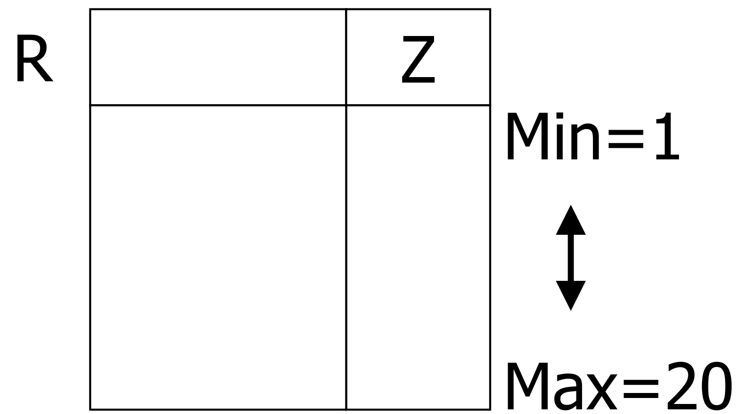

$V(R,Z)=10$

$W = \sigma_{Z \geq 15}(R)$

- Vypočítej podíl hodnot (unikátních)

$$f = \frac{20-15+1}{20-1+1} = \frac{6}{20}$$

  - $T(W) = f \cdot T(R)$

Odhad velikosti

- Selekce $W = \sigma_{Z \neq val}(R)$
  - $T(W) = T(R) \cdot (1 - f(val)) = T(R) / (1 - 1/V(R,Z))$

    $$= T(R) - \frac{T(R)}{V(R,Z)}$$

  - Obvyklé řešení
    - $T(W) = T(R)$

Odhad velikosti

- Přirozené spojení $W = R_1 \bowtie R_2$
  - Značení
    - X – atributy R_1
    - Y – atributy R_2
- Případ 1
  - $X \cap Y = \emptyset$
  - Stejné jako $R_1 \times R_2$
- Případ 2
  - $X \cap Y = Z$
  - Viz dále…

Odhad velikosti: přirozené spojení

$R_1 \bowtie R_2$

R_1

A	B	C

R_2

A	D

- Předpoklad
  - $V(R_1,A) \le V(R_2,A)$
    $\rightarrow$ každá hodnota A z R_1 je i v R_2
  - $V(R_1,A) \ge V(R_2,A)$
    $\rightarrow$ každá hodnota A z R_2 je i v R_1

Odhad velikosti: přirozené spojení

- $V(R_1,A) \leq V(R_2,A)$

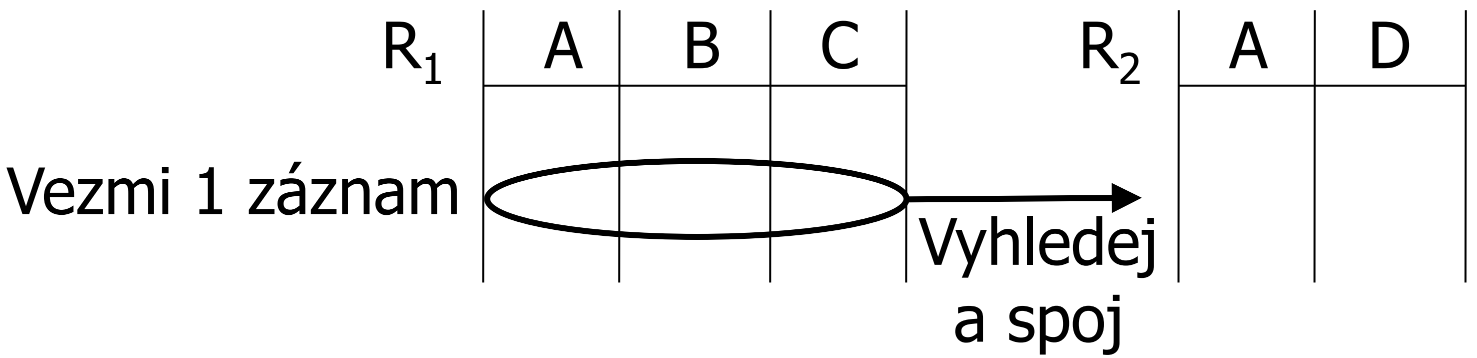

- 1 záznam se spojí s $T(R_2) / V(R_2,A)$ záznamy
  - Opět předpoklad rovnoměrného rozložení
- Výsledek: $T(W) = \dfrac{T(R_2)}{V(R_2,A)} \cdot T(R_1)$

Odhad velikosti: přirozené spojení

- Shrnutí obou variant
  - $V(R_1,A) \leq V(R_2,A)$

$$T(W) = \frac{T(R_2)}{V(R_2,A)} \cdot T(R_1)$$

  - $V(R_2,A) \leq V(R_1,A)$

$$T(W) = \frac{T(R_1)}{V(R_1,A)} \cdot T(R_2)$$

- Rozdíl je pouze ve jmenovateli

Odhad velikosti: přirozené spojení

- Obecný závěr
  - $W = R_1 \bowtie R_2$

$$T(W) = \frac{T(R_1) \cdot T(R_2)}{\max\{ V(R_1,A), V(R_2,A) \}}$$

Odhad velikosti: přirozené spojení

- Alternativní definice
  - Rovnoměrné rozložení v doméně

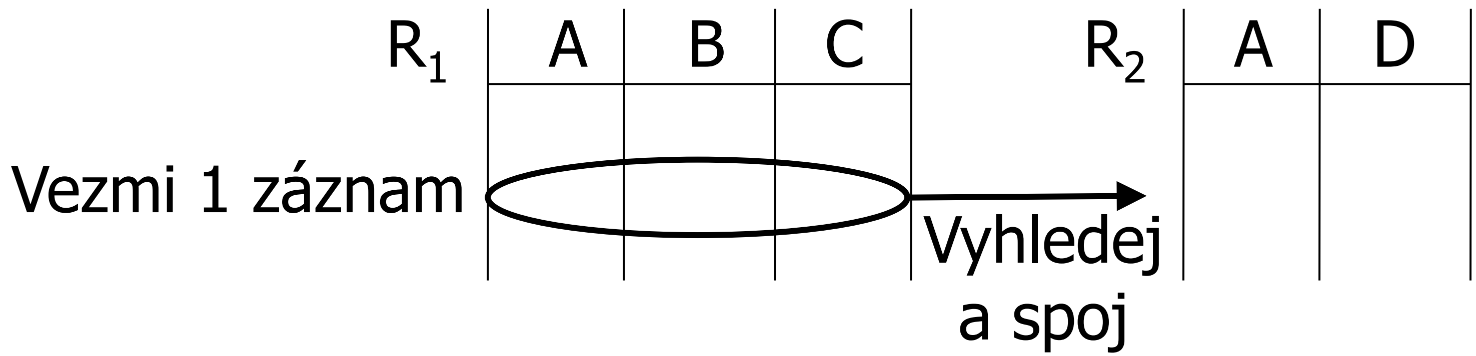

- 1 zázn. se spojí s $T(R_2)/DOM(R_2,A)$ záznamy
- Výsledek:

$$T(W) = \frac{T(R_1) \cdot T(R_2)}{DOM(R_2,A)} = \frac{T(R_1) \cdot T(R_2)}{DOM(R_1,A)}$$

předpokládáme stejné

Odhad velikosti: přirozené spojení

- $W = R_1 \bowtie R_2$
  - $R_1(X)$, $R_2(Y)$, $X \cap Y = Z$
- Velikost záznamu
  - $S(W) = S(R_1) + S(R_2) – S(R_1,Z)$
  - Platí pro všechny varianty

Odhad velikosti: projekce, selekce

- Projekce $\Pi_{AB}(R)$
  - $T(W)=T(R)$
  - $S(W)=S(R, AB)$

- Selekce $\sigma_{A=a \vee B=b}(R)$
  - $S(W)=S(R)$, nechť $n=T(R)$
  - $T(W) = n \cdot (1 - (1-m_1/n) \cdot (1-m_2/n))$
    - $m_1=T(R) / V(R,A)$ $m_2=T(R) / V(R,B)$

Odhad velikosti: množinové operace

- Sjednocení, průnik, rozdíl
  - $\cup$, $\cap$, $-$
    - T(W) – počítá se průměrná velikost
  - Např.
    - $T(R \cup S) = T(R) + T(S)$ … pokud $\cup$ znamená UNION ALL
    - $T(R \cup S) = [\ \max\{T(R), T(S)\}\ ,\ \ T(R) + T(S)\ ]$

Odhad velikosti

- Pro složitější výrazy jsou třeba ostatní statistiky
- Příklad
  - $W = \underbrace{[\sigma_{A=a}(R_1)]}_{\text{označme jako U}} \bowtie R_2$
- $T(U) = T(R_1) / V(R_1,A)$ $S(U) = S(R_1)$
  - Pro odhady pro W potřebujeme i V(U,*) !

Odhad počtu hodnot

- Odhady V(U,*)
  - $U = \sigma_{A=a}(R_1)$
  - Předpokládejme, že $R_1(A,B,C,D)$

Odhad počtu hodnot: příklad

- Relace R_1
- $U = \sigma_{A=a}(R_1)$
- Výsledek
  - V(U,A) = 1
  - V(U,B) = 1
  - V(U,C) = 1 .. ($T(R_1)$ / $V(R_1$,A))
  - V(U,D) = 1 .. ($T(R_1)$ / $V(R_1$,A))

A	B	C	D
cat	1	10.2.98	c
cat	1	20.3.98	b
dog	1	30.4.98	a
dog	1	14.6.98	a
bat	1	15.6.98	d

V(R,A)=3
V(R,B)=1
V(R,C)=5
V(R,D)=4

Odhad počtu hodnot: praxe

- Obvyklé řešení
  - $U = \sigma_{A=a}(R_1)$
  - $V(U,A) = 1$
  - $V(U,*) = V(R,*)$

  - Výjimku tvoří primární klíč K relace R_1
    - $V(U,K) = T(U)$

Odhad počtu hodnot: spojení

- $U = R_1(A,B) \bowtie R_2(A,C)$
- Výsledek:
  - $V(U,A) = \min\{ V(R_1, A), V(R_2, A) \}$
  - $V(U,B) = V(R_1, B)$
  - $V(U,C) = V(R_2, C)$

Odhad počtu hodnot: spojení

- Příklad
  - $Z = R_1(A,B) \bowtie R_2(B,C) \bowtie R_3(C,D)$
  - $T(R_1) = 1000$ $V(R_1,A)=50$ $V(R_1,B)=100$
  - $T(R_2) = 2000$ $V(R_2,B)=200$ $V(R_2,C)=300$
  - $T(R_3) = 3000$ $V(R_3,C)=90$ $V(R_3,D)=500$

Odhad počtu hodnot: spojení

- Mezivýsledek
  - $U = R_1(A,B) \bowtie R_2(B,C)$
  - Výsledek:
    - $T(U) = T(R_1) \cdot T(R_2) / \max\{ V(R_1,B), V(R_2,B) \} =$
      $= 1000 \cdot 2000 / 200$
    - $V(U,A) = 50$
    - $V(U,B) = 100$
    - $V(U,C) = 300$

Odhad počtu hodnot: spojení

- Celkový výsledek
  - $Z = U \bowtie R_3(C,D)$
    - U(A,B,C)
  - Výsledek:
    - $T(Z) = 10\,000 \cdot 3\,000 / 300$
    - $V(Z,A) = 50$
    - $V(Z,B) = 100$
    - $V(Z,C) = 90$
    - $V(Z,D) = 500$

Odhad počtu hodnot: histogram

- Histogram hodnot atributu
  - Místo V(R,A) a DOM(R,A)
  - Zpřesnění odhadů
- Počet různých hodnot
  - Málo → pro každou počet
  - Hodně → kvantizace
    - Stejné intervaly
    - Percentily
    - Pouze pro nejfrekventovanější
      - ostatní dohromady (tj. výsledně rovnoměrně)

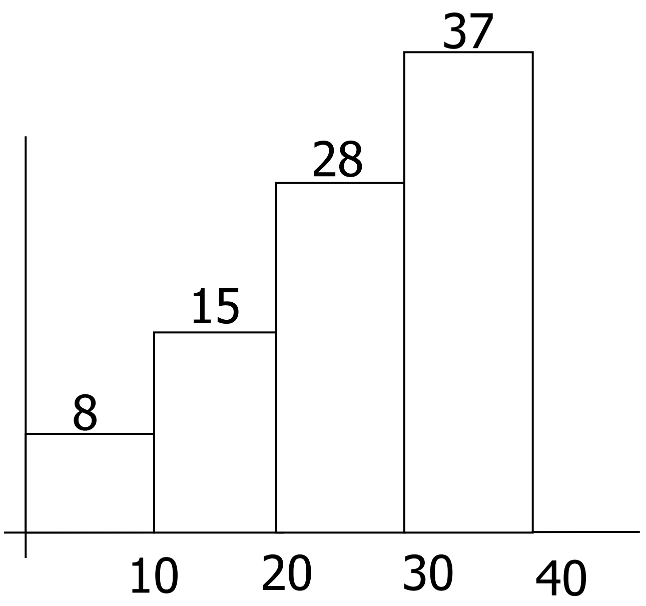

Shrnutí

- Odhad velikosti výsledků je „umění“

- Nezapomeňte:
  - Pro korektní odhad potřebujeme korektní statistiky
    → nutnost udržovat tabulky při modifikacích
  - Jaké jsou náklady takové údržby?

Aktualizace statistik

- Statistiky se příliš nemění
  - v krátkém časovém úseku
- I nepřesné statistiky mohou být užitečné
- Okamžitá aktualizace statistik
  - Může být úzkým místem – statistiky jsou velmi často používány
- $\rightarrow$ Neaktualizuj příliš často

Aktualizace statistik

- Prováděno periodicky
  - Po uplynutí určitého času
  - Po určitém počtu změn
- Pomalé pro V(R,A)
  - Zejména pokud se počítají histogramy
  - $\rightarrow$ Počítáno na vzorku dat
    - Pokud je většina hodnot různých $\rightarrow$ V(R,A)$\approx$T(R)
    - Pokud je málo různých hodnot $\rightarrow$ pravděpodobně jsme většinu ze všech viděli

Odhad ceny plánu dotazu: přehled

- Odhad velikosti výsledku operace
  - Již probráno
- Odhad počtu V/V operací
  - Další přednáška
- Vytvoření a porovnání plánů