PA152: Efektivní využívání DB

6. Zpracování dotazů

Vlastislav Dohnal

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

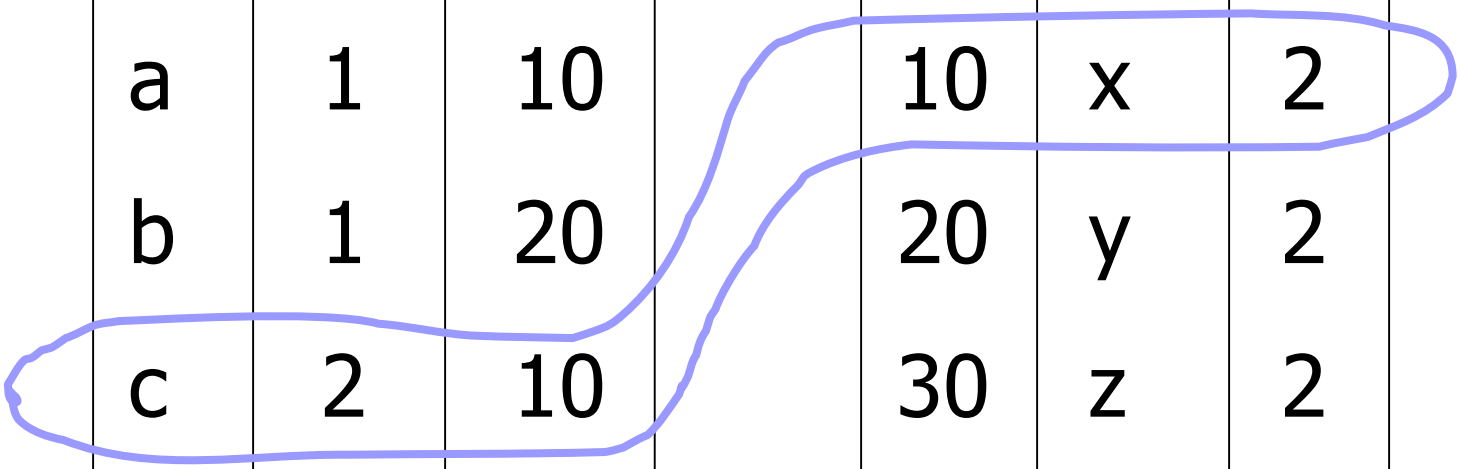

Odpověď

B	D
2	x

Jak vyhodnotit tento dotaz?

1. způsob

1) Kartézský součin
2) Výběr záznamů
3) 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
.					
.					

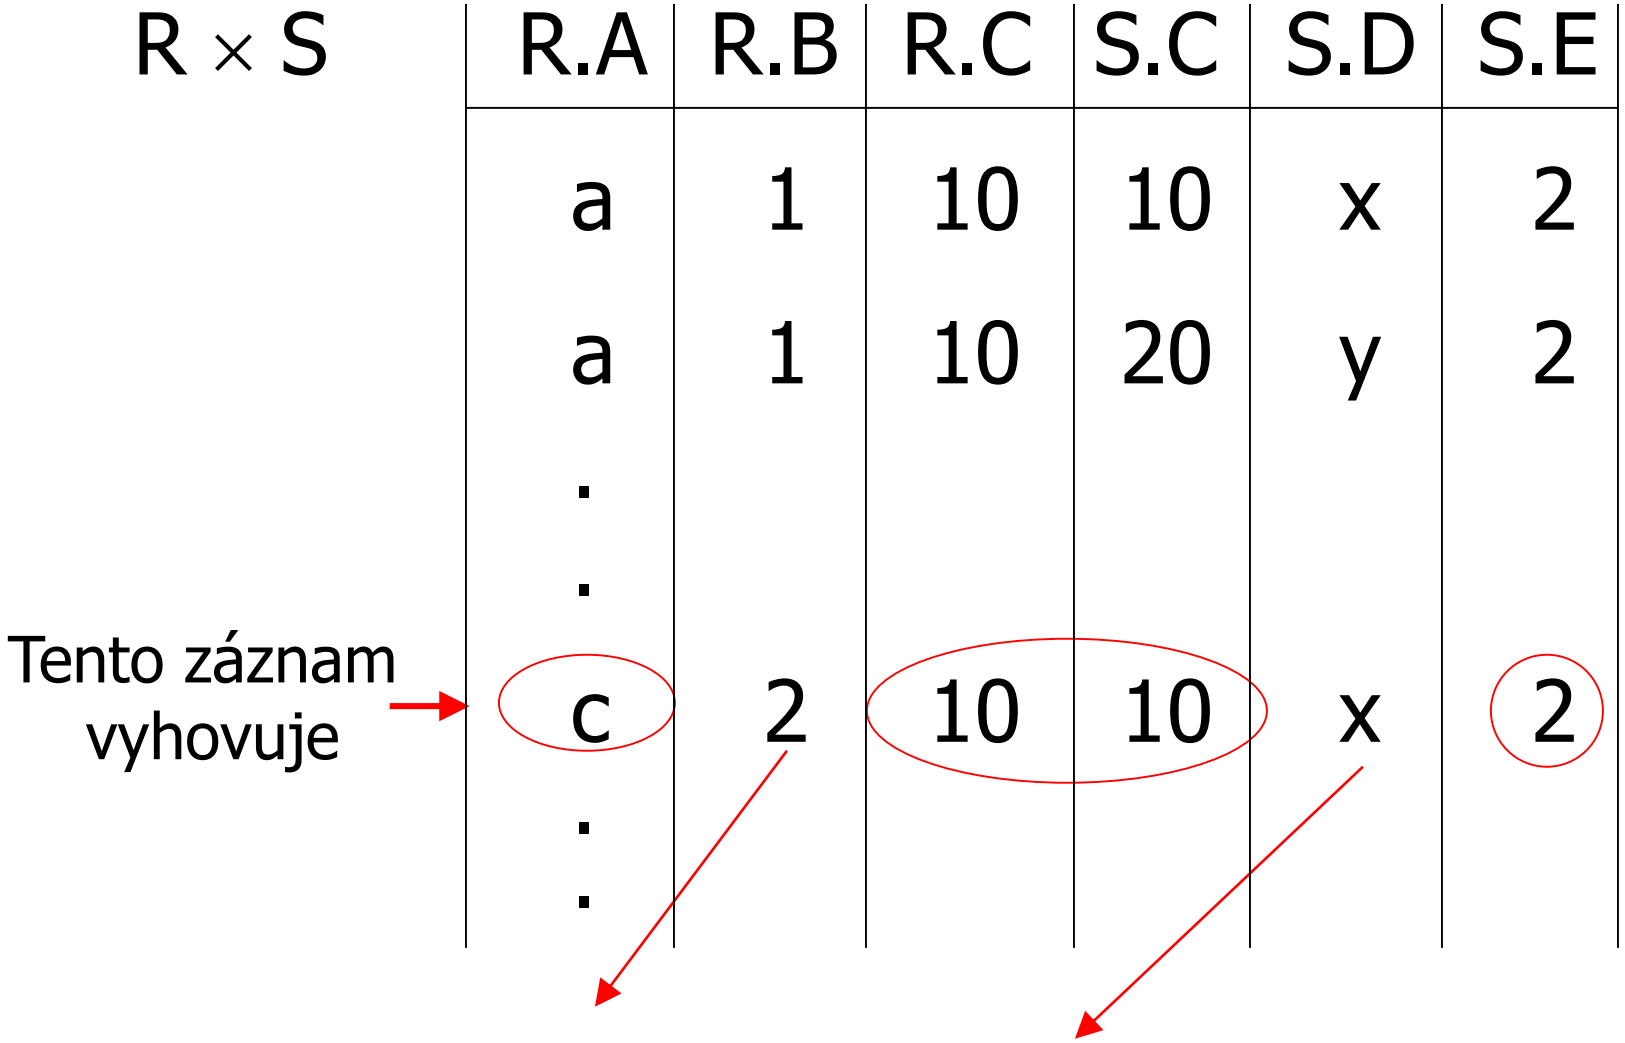

select B,D from R,S where R.C=S.C and R.A='c' and S.E=2

Popis plánů provedení dotazu

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

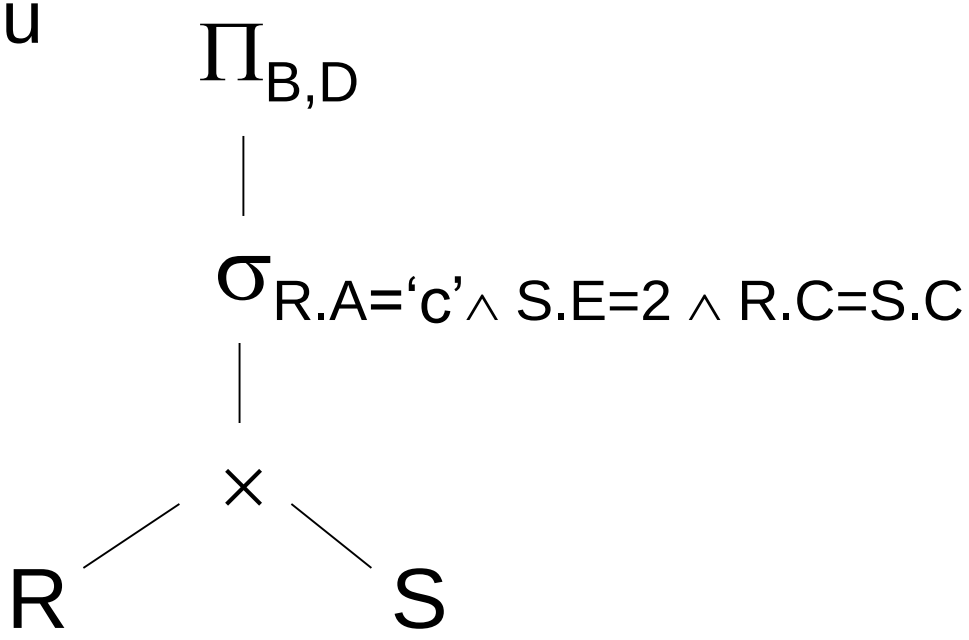

Popis plánů provedení dotazu

- Příklad plánu 2:

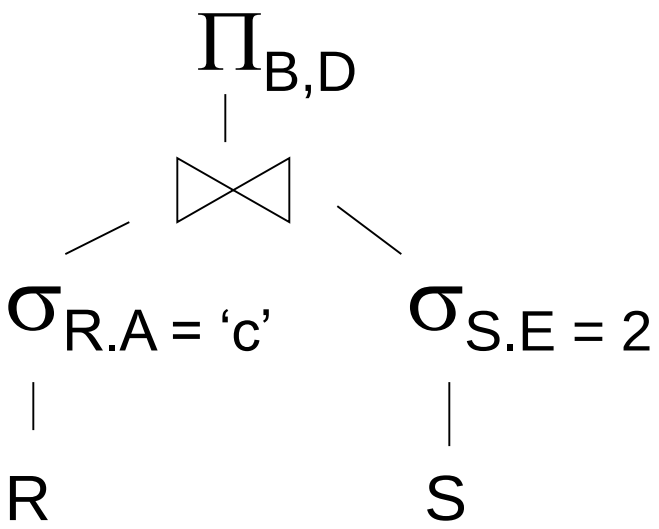

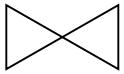

natural join

Fyzický plán

- Příklad pro 2: Table-scan pro selekce

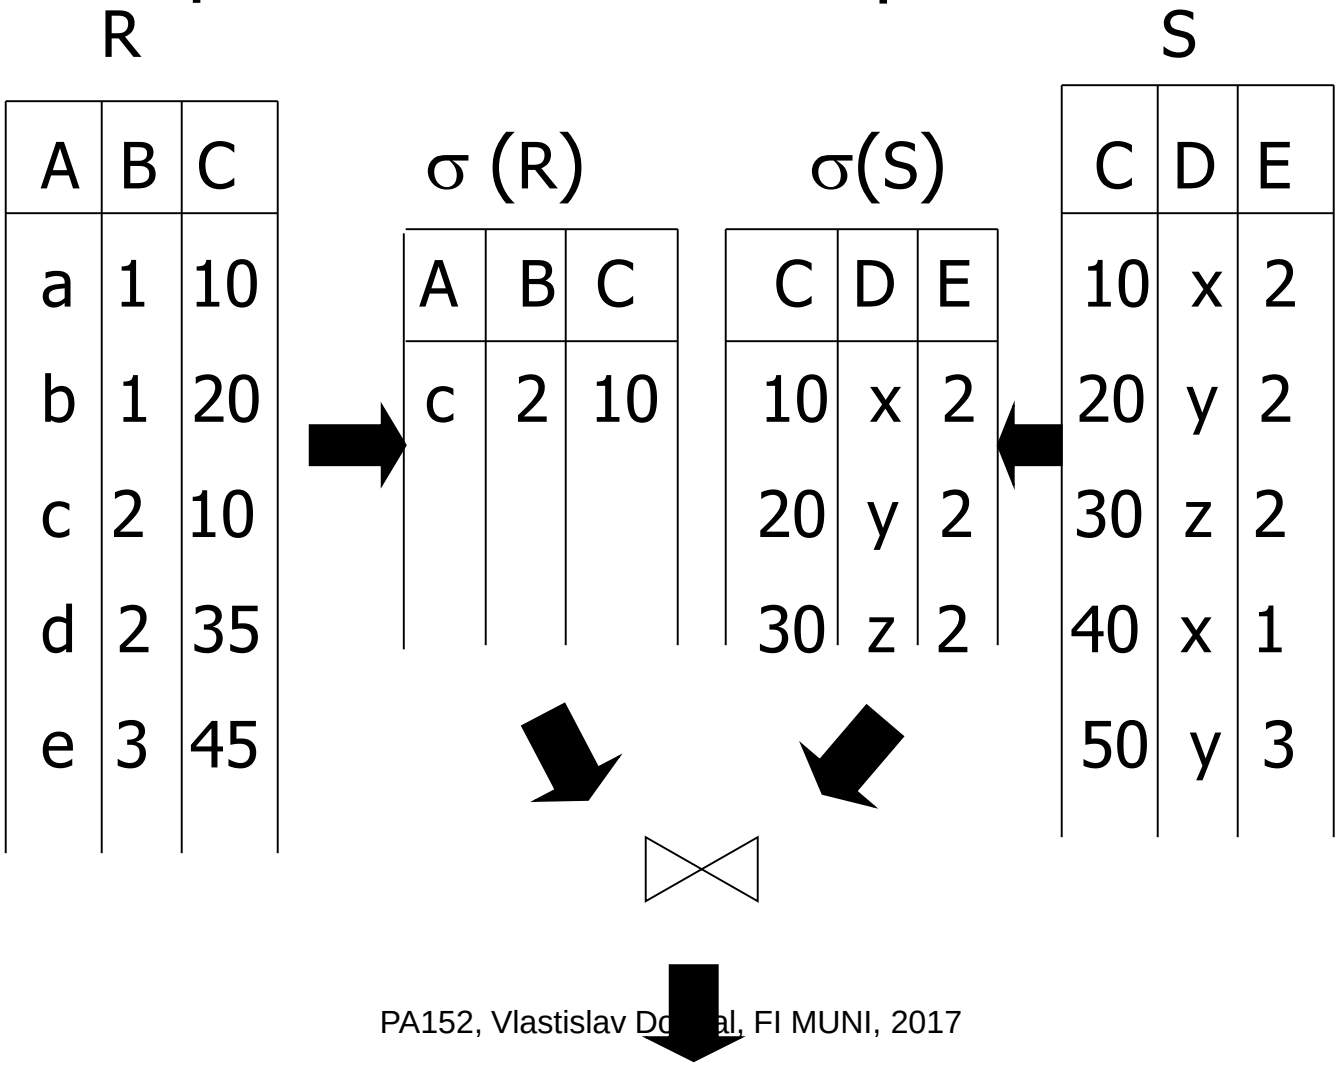

Popis plánů provedení dotazu

- 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

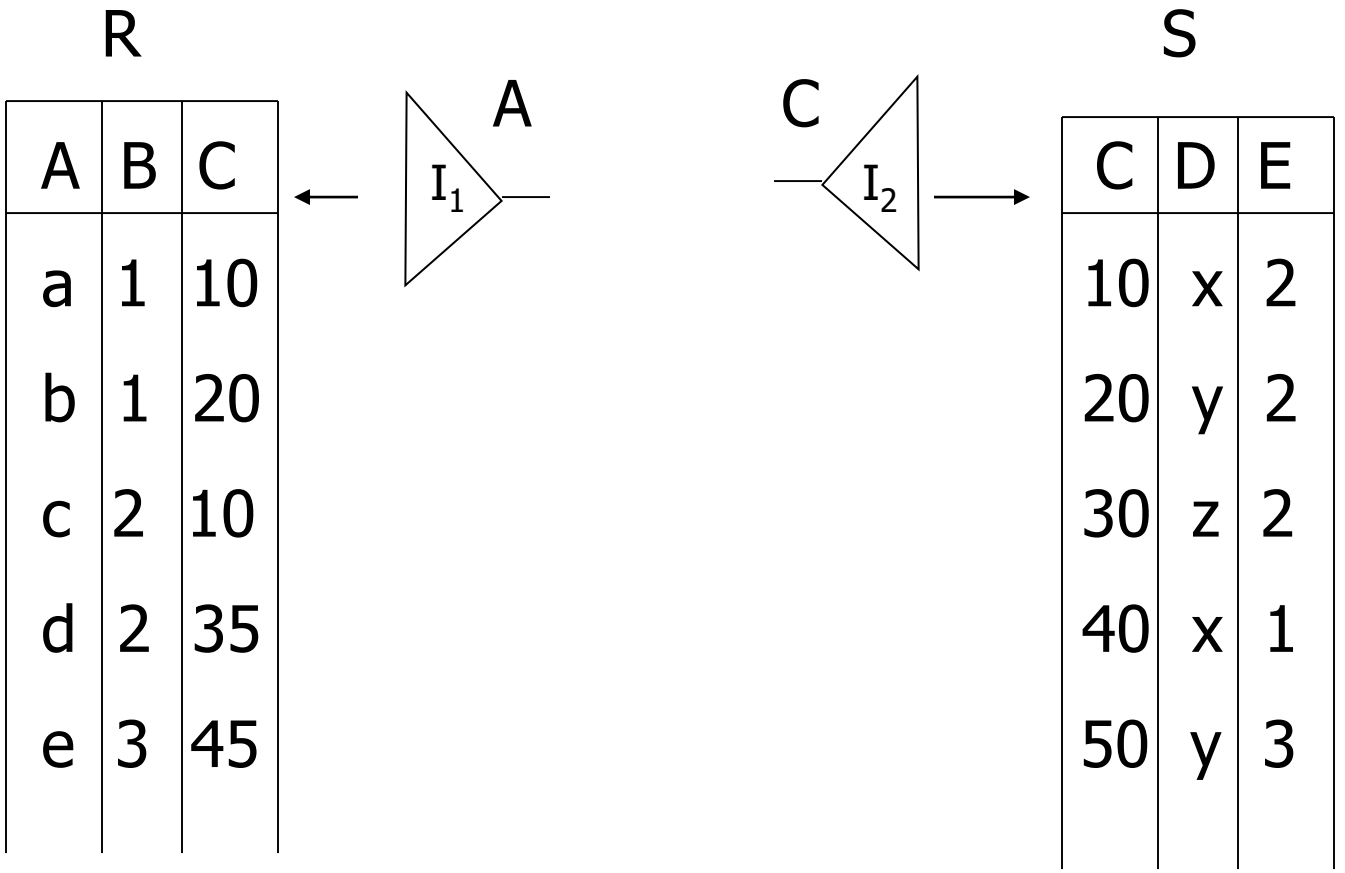
R
A
B
C
a
1
10
b
1
20
c
2
10
d
2
35
e
3
45
A
I_1
C
I_2
S
C
D
E
10
x
2
20
y
2
30
z
2
40
x
1
50
y
3

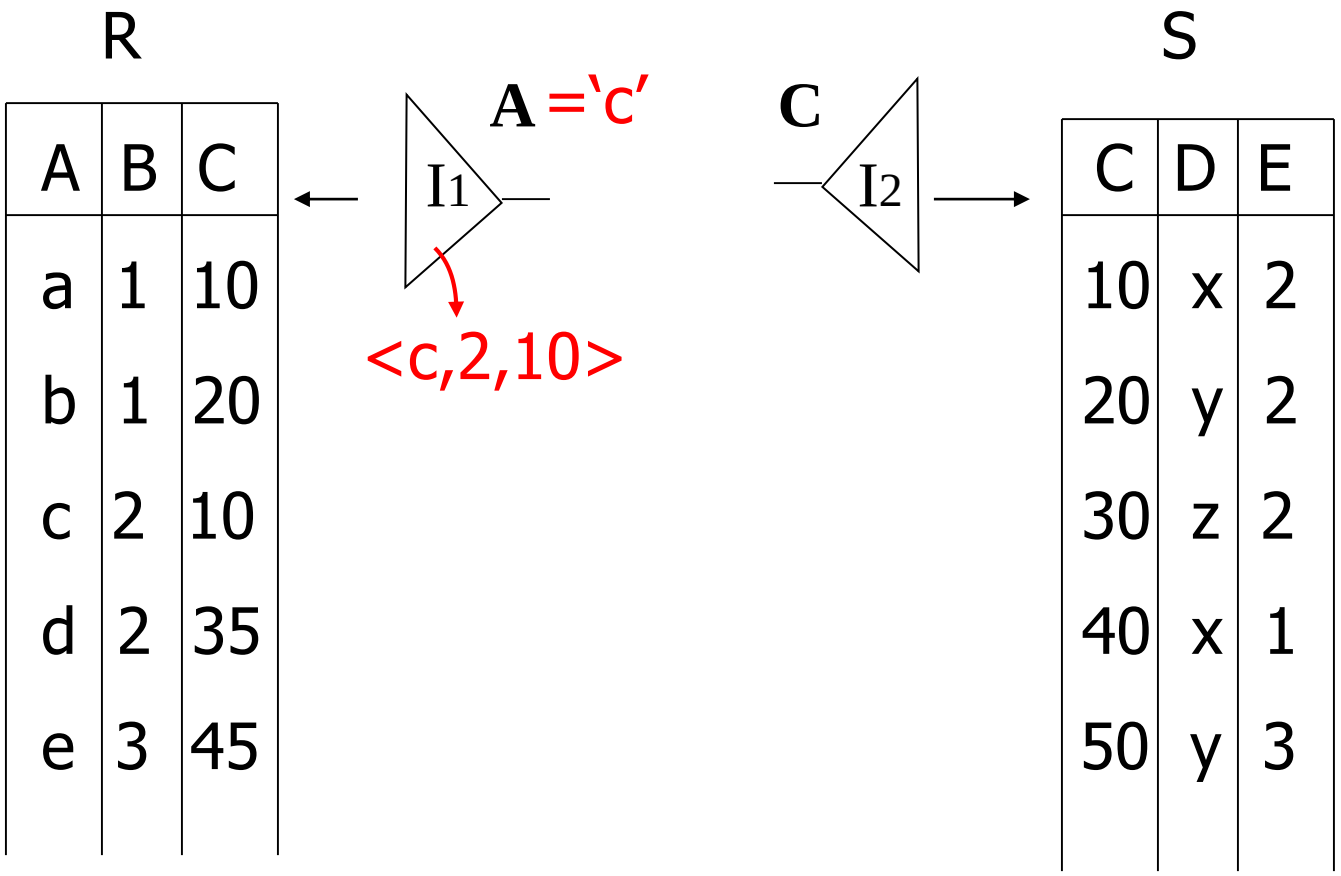
R
A
B
C
a
1
10
b
1
20
c
2
10
d
2
35
e
3
45
A ='c'
I1
<c,2,10>
C
I2
S
C
D
E
10
x
2
20
y
2
30
z
2
40
x
1
50
y
3

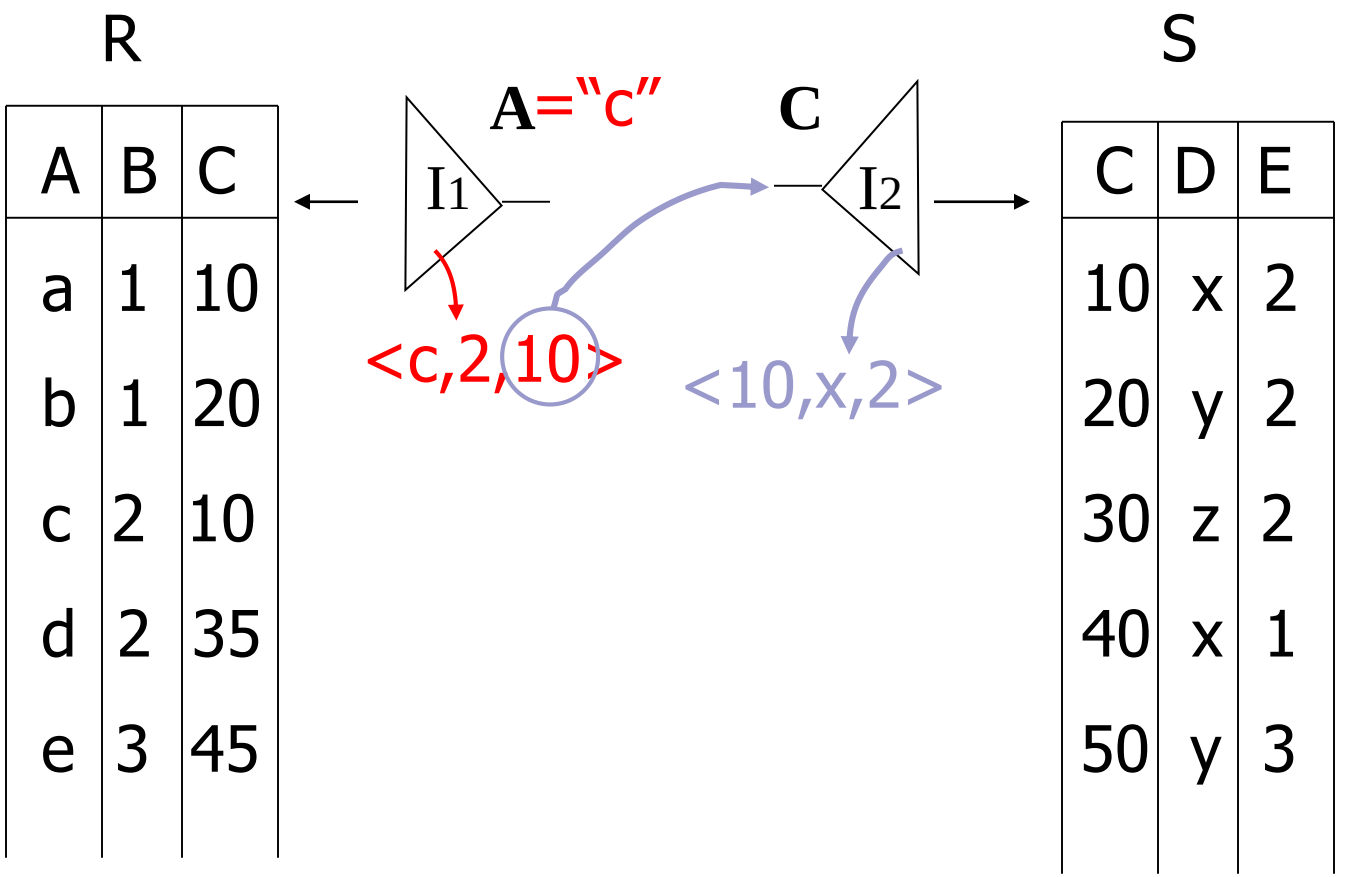
R
A
B
C
a
1
10
b
1
20
c
2
10
d
2
35
e
3
45
A="c"
I1
C
I2
<c,2,10>
<10,x,2>
S
C
D
E
10
x
2
20
y
2
30
z
2
40
x
1
50
y
3

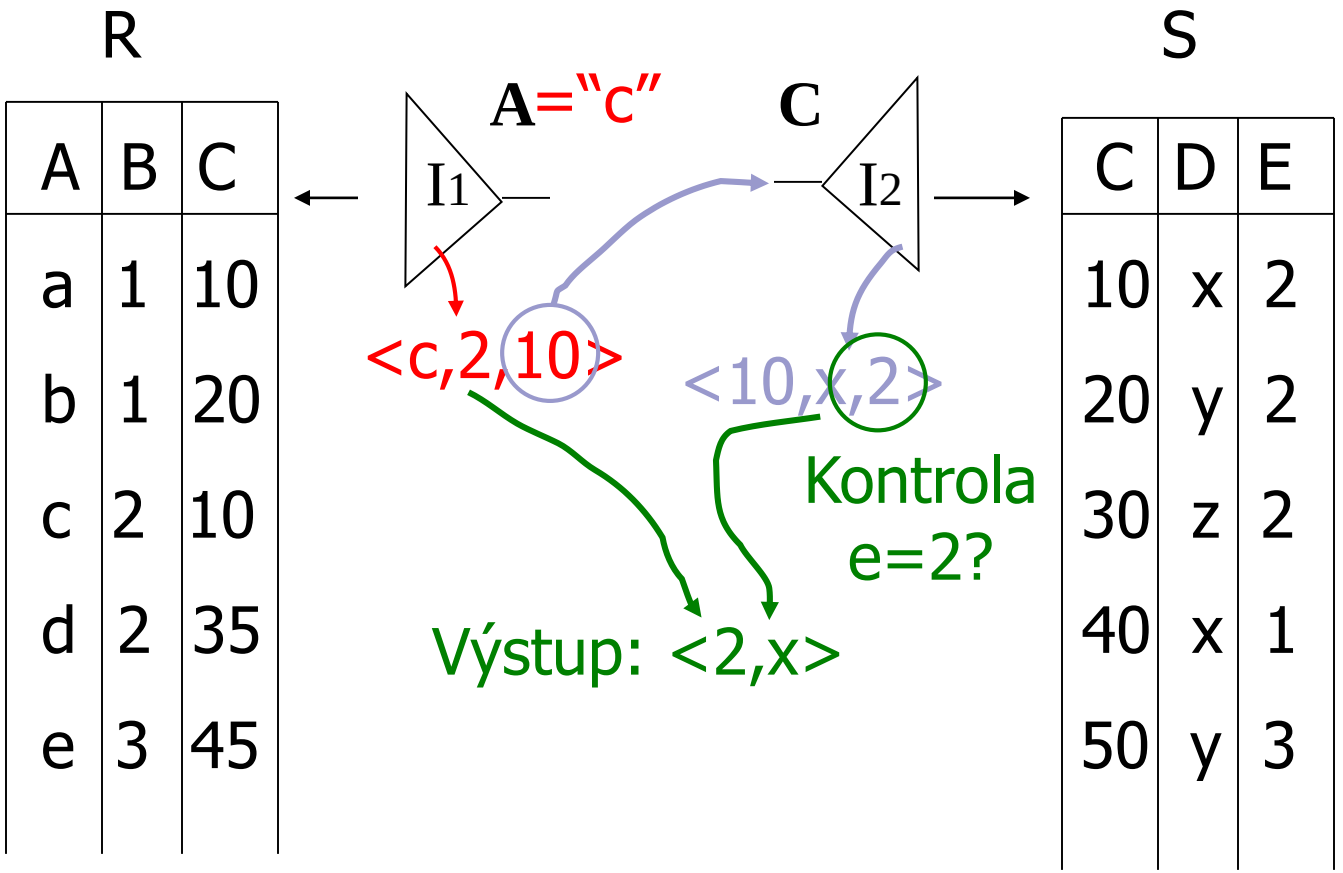
R
A
B
C
a
1
10
b
1
20
c
2
10
d
2
35
e
3
45
A="c"
I1
C
I2
<c,2,10>
<10,x,2>
Kontrola
e=2?
Výstup: <2,x>
S
C
D
E
10
x
2
20
y
2
30
z
2
40
x
1
50
y
3

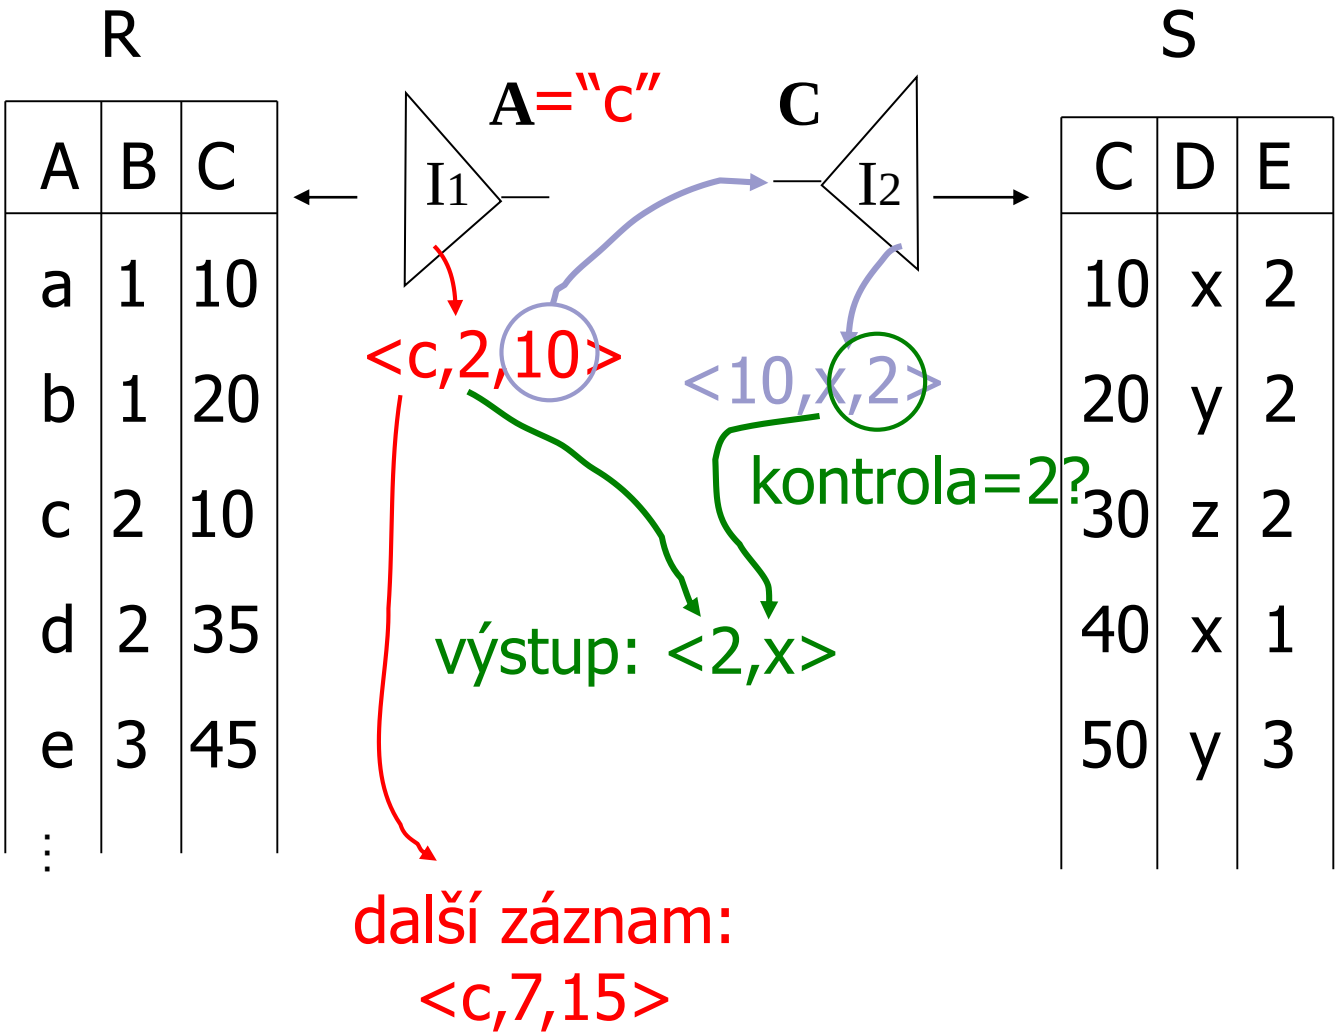
R
S
A="c"
C
I1
I2
A B C
a 1 10
b 1 20
c 2 10
d 2 35
e 3 45
C D E
10 x 2
20 y 2
30 z 2
40 x 1
50 y 3
<c,2,10>
<10,x,2>
kontrola=2?
výstup: <2,x>
další záznam:
<c,7,15>

Schéma optimalizace dotazů

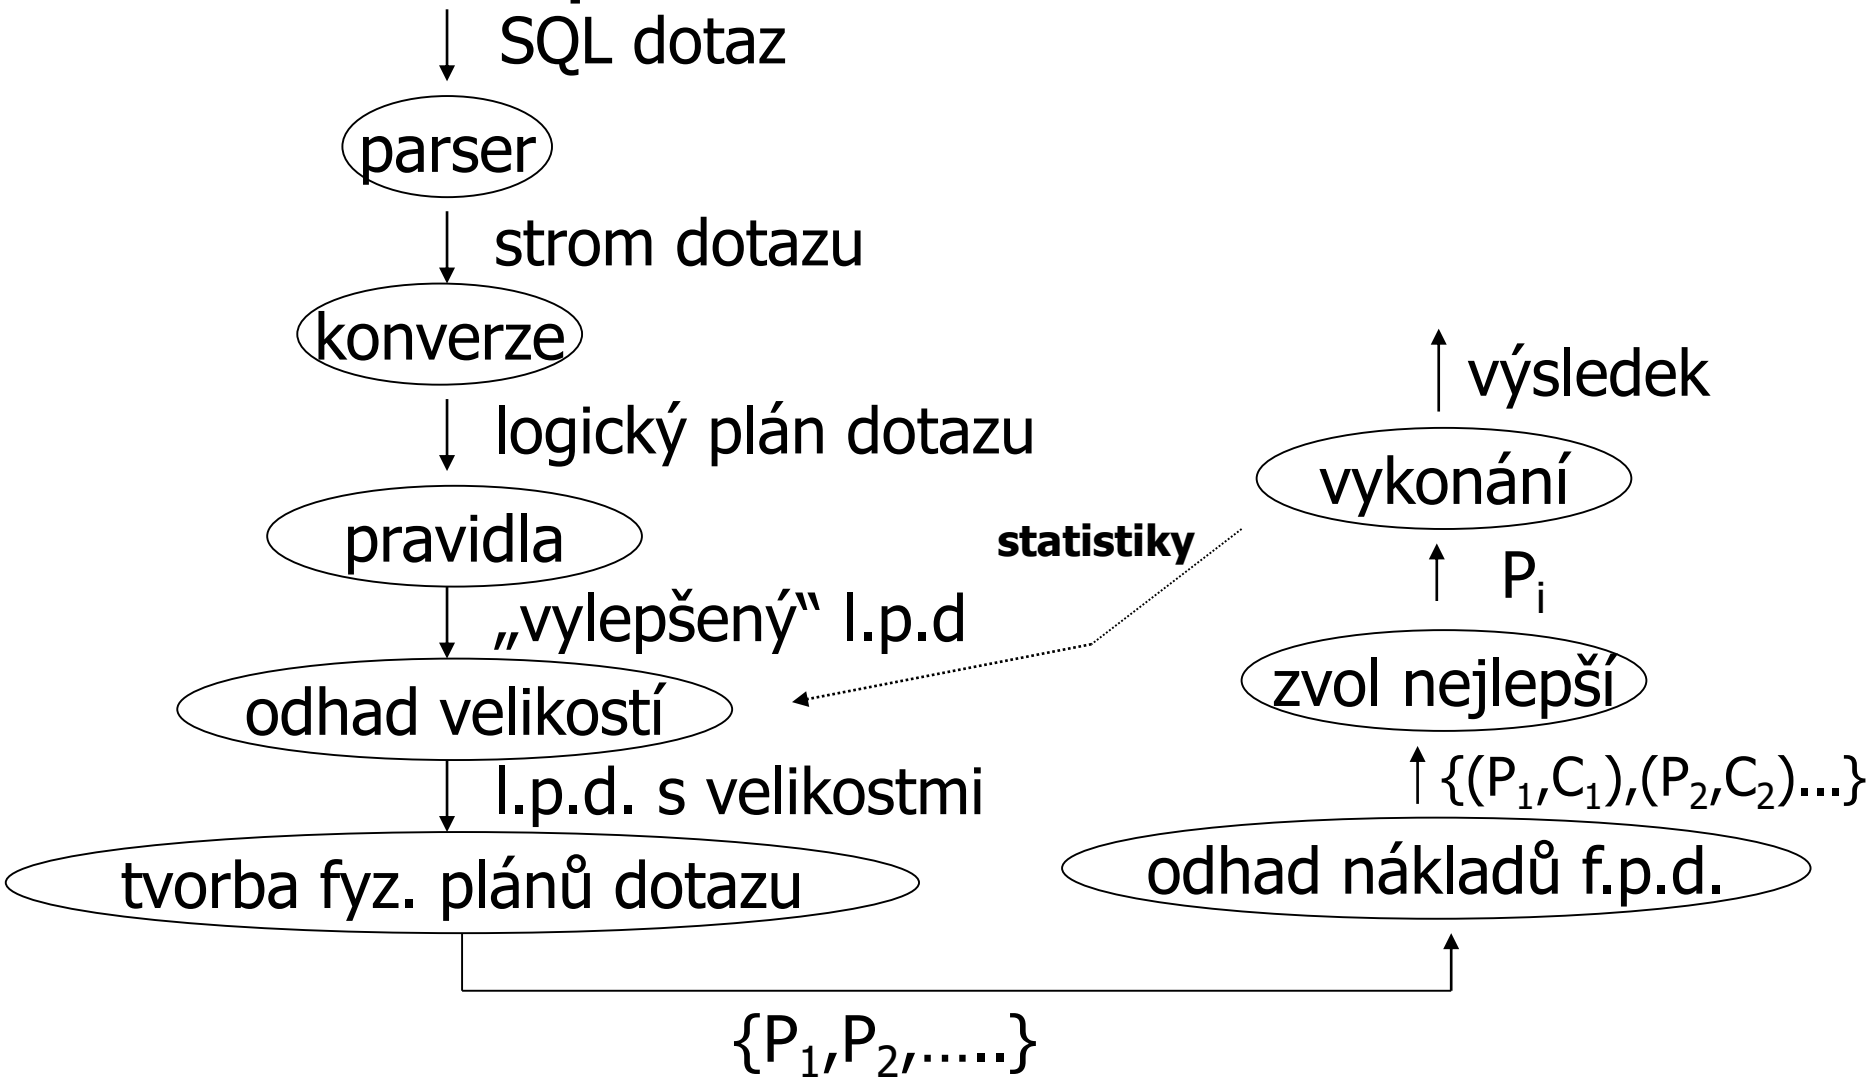

Příklad: SQL dotaz

- 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 extract(year from birthdate) = 1960
);
```

Příklad: strom dotazu

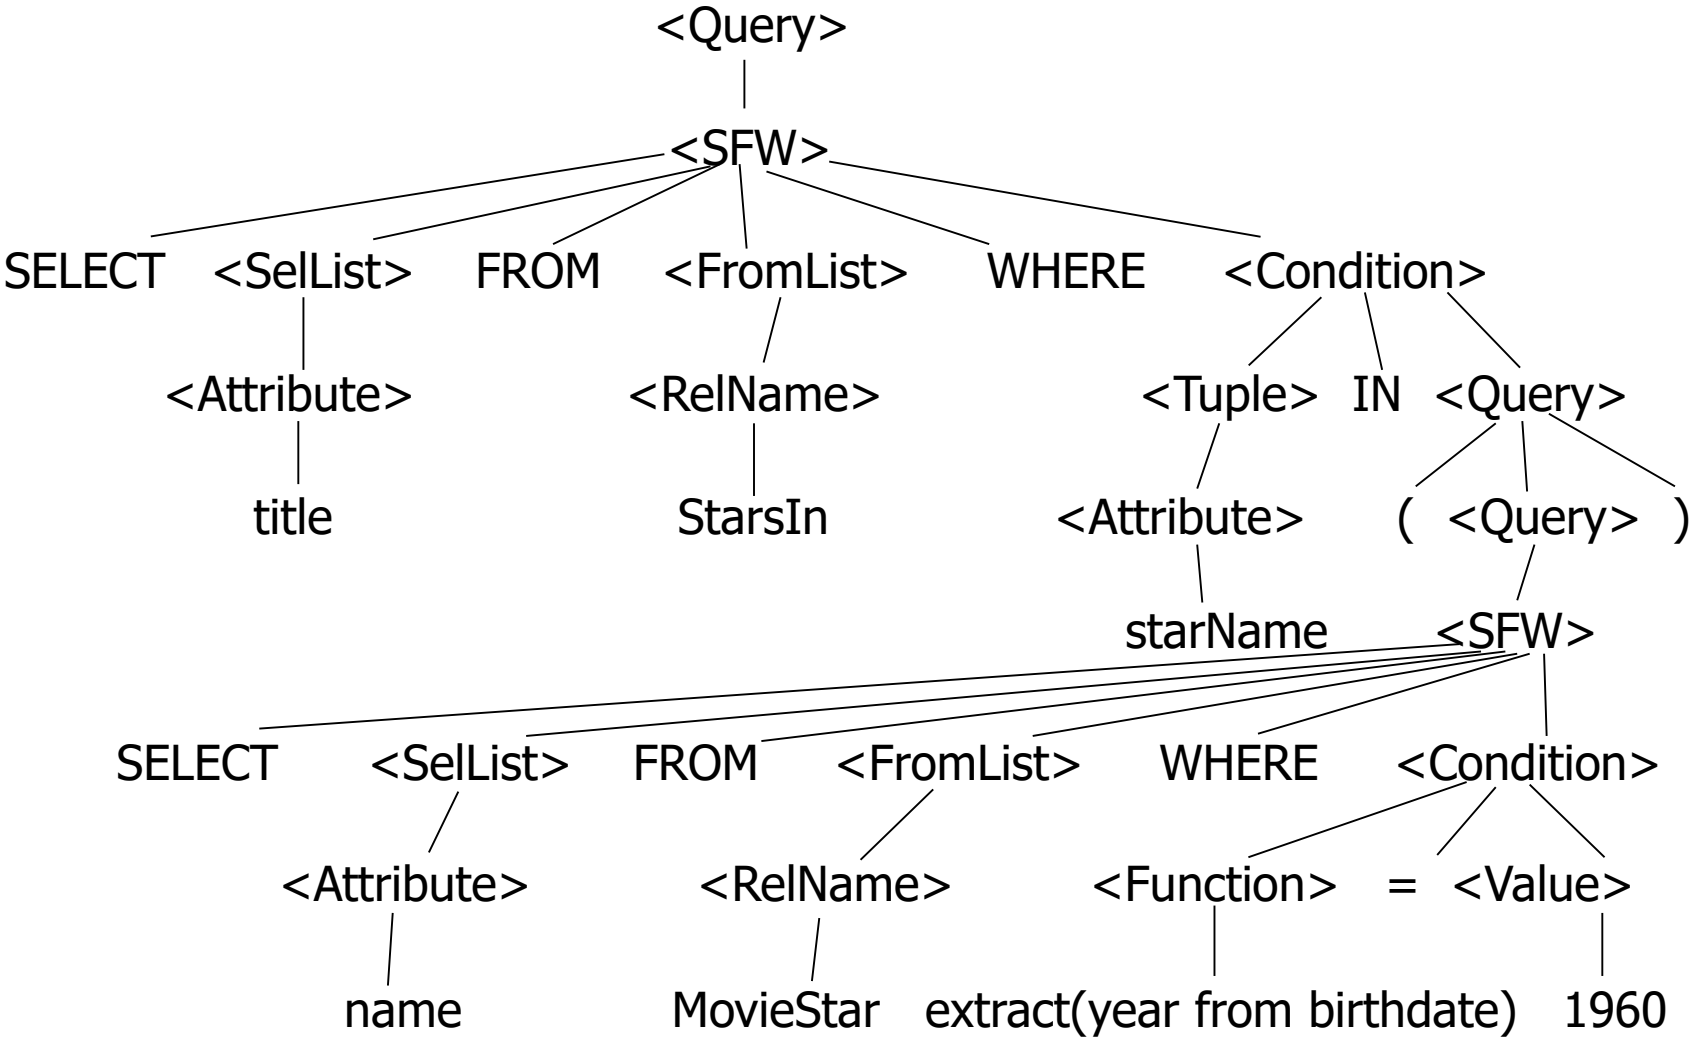

Příklad: převod do relační algebry

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

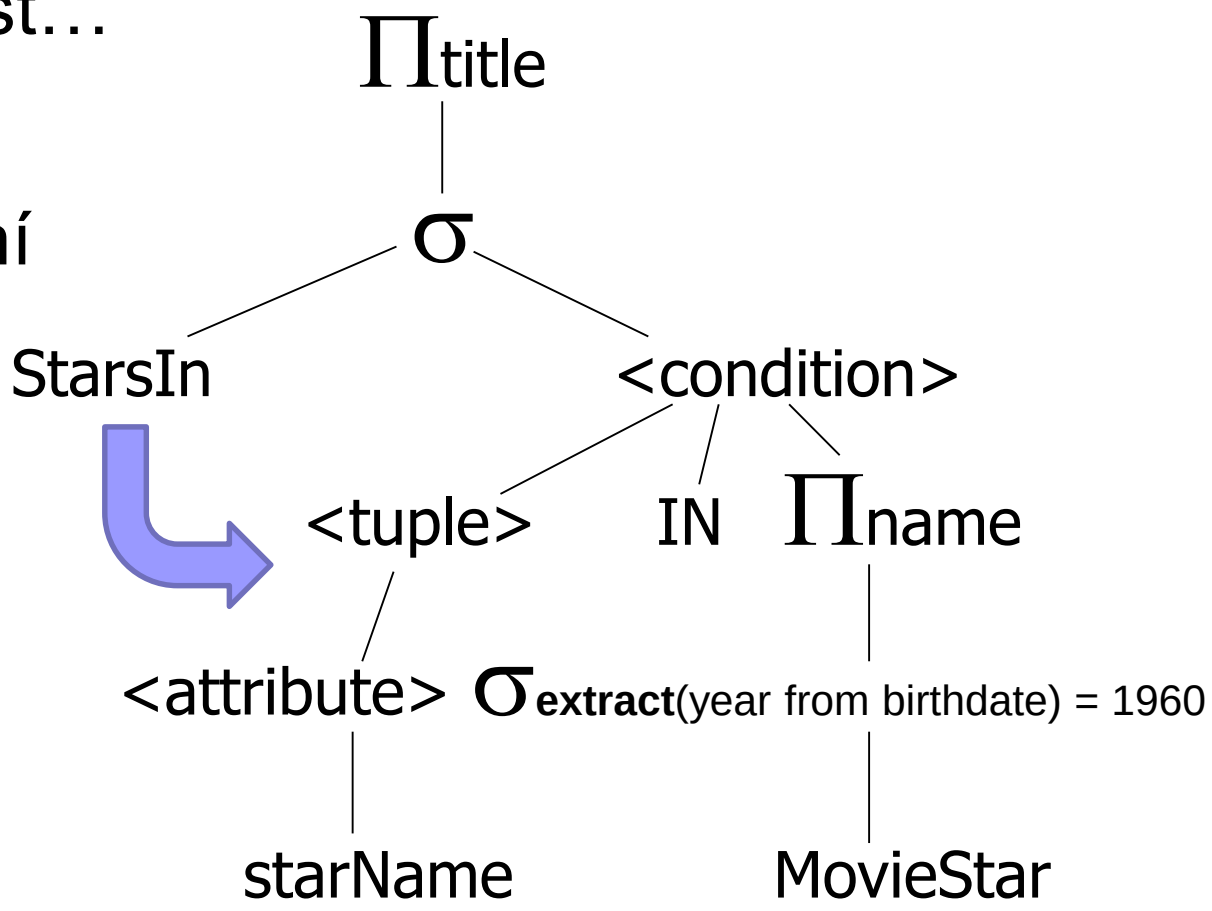

Příklad: logický plán dotazu

- Operátor IN nahrazen součinem

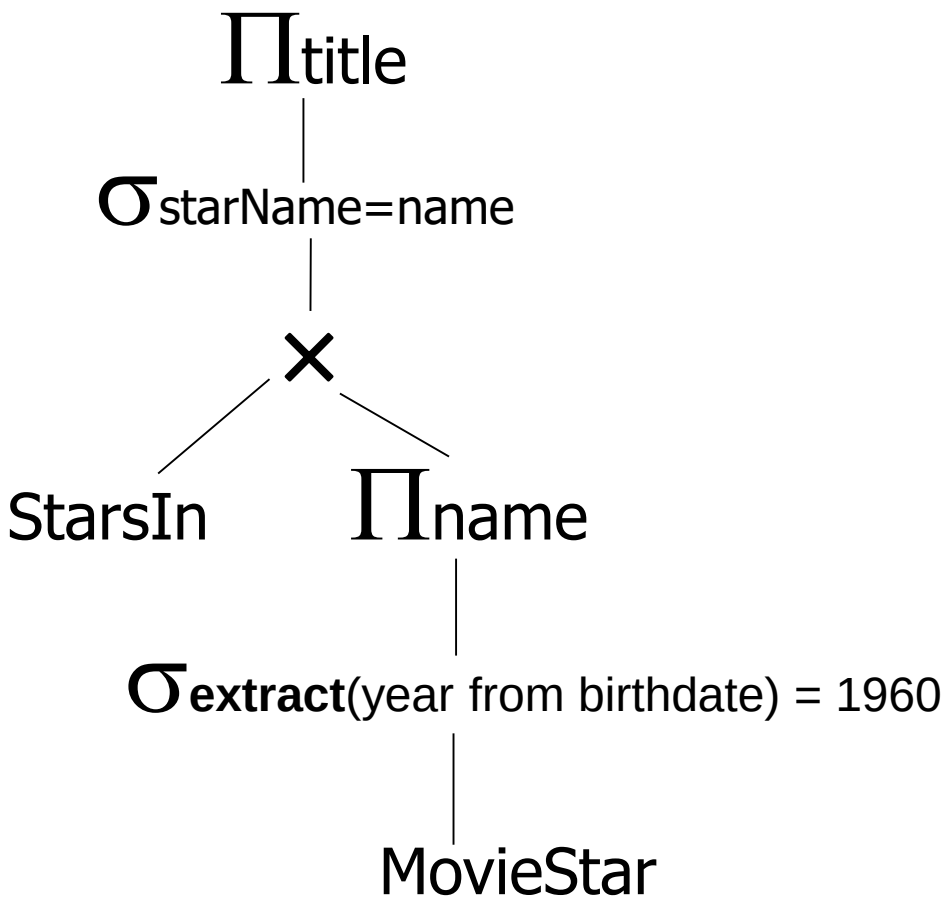

Příklad: vylepšení logického plánu

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

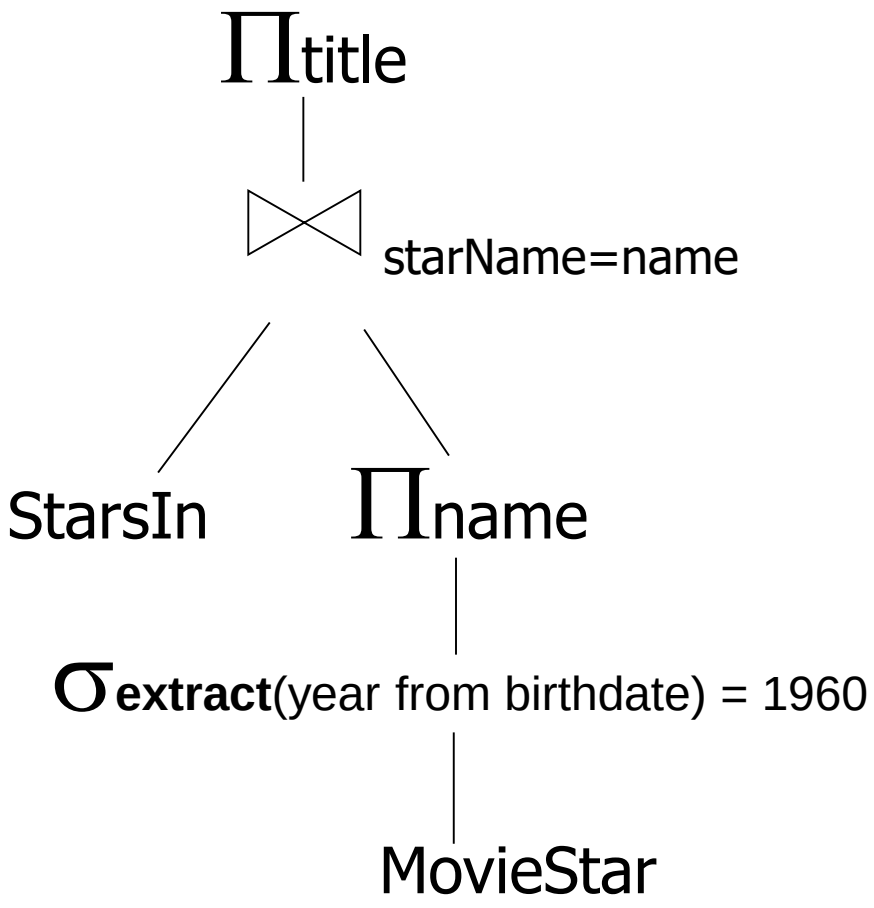

Příklad: odhad velikostí výsledků

- Před generováním fyzických plánů
- Ovlivňují odhad ceny provedení

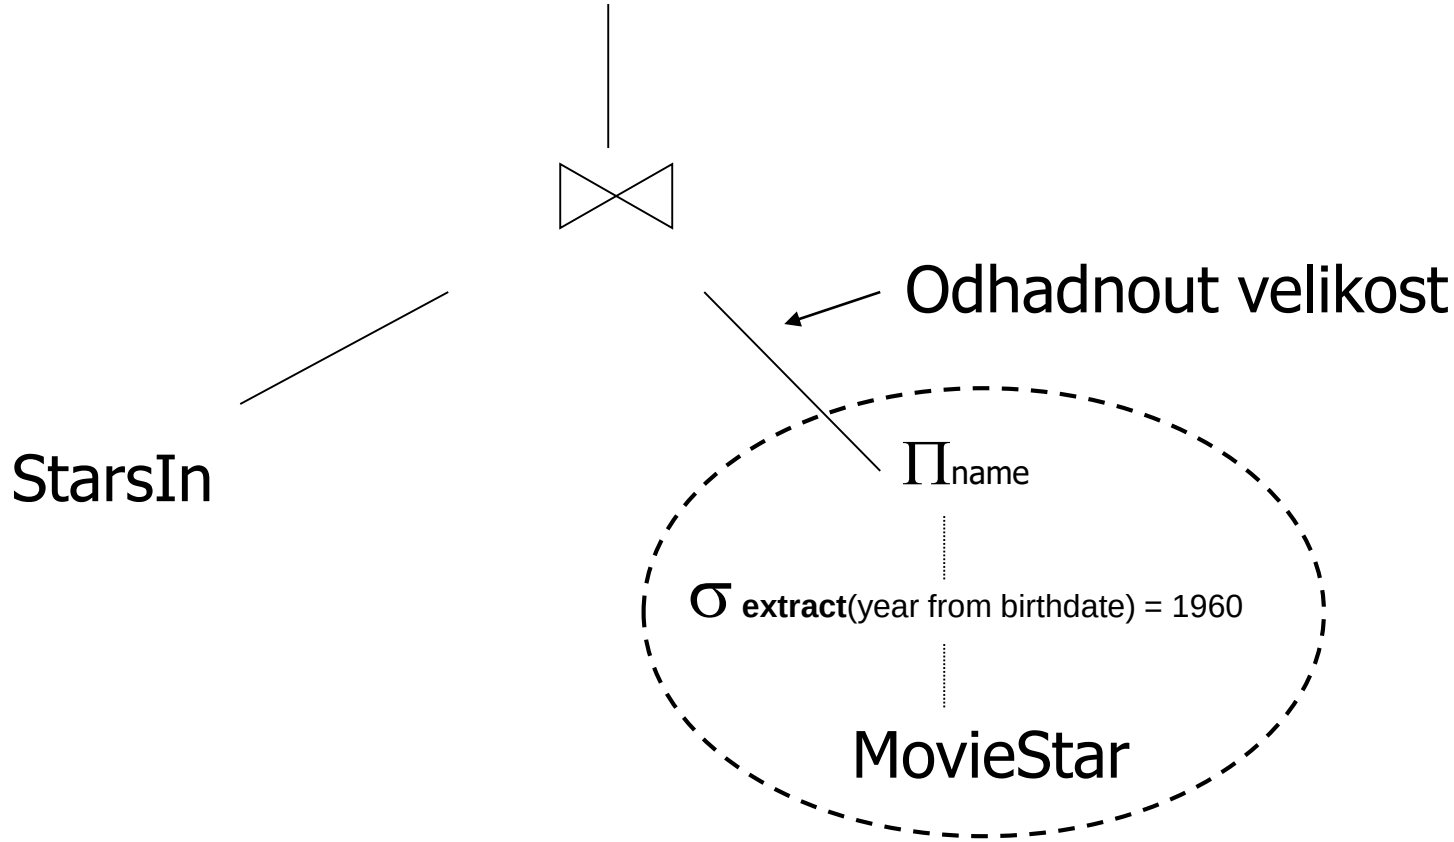

Příklad: jeden fyzický plán

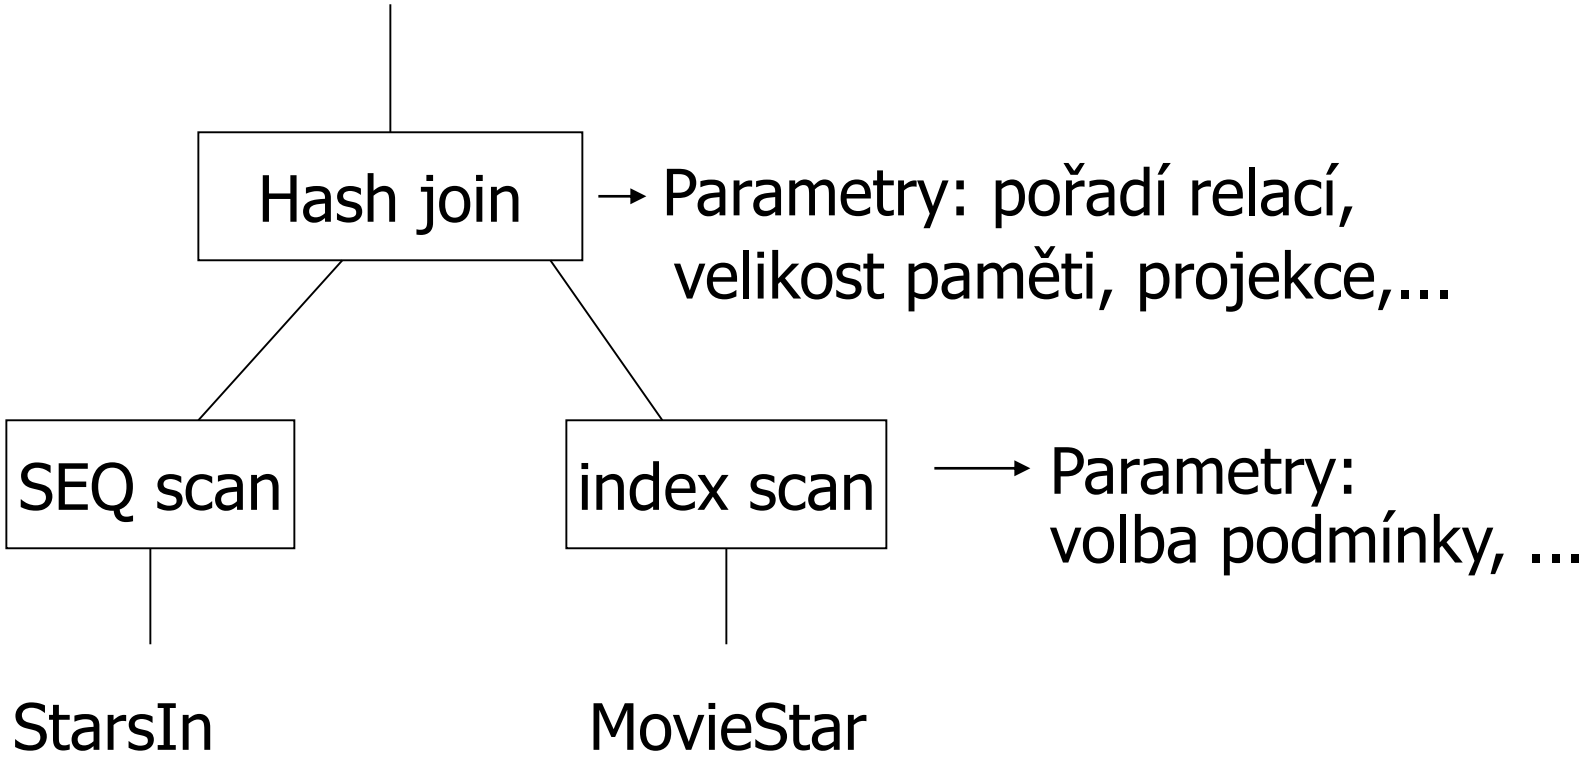

Příklad: ohodnocení plánů cenou

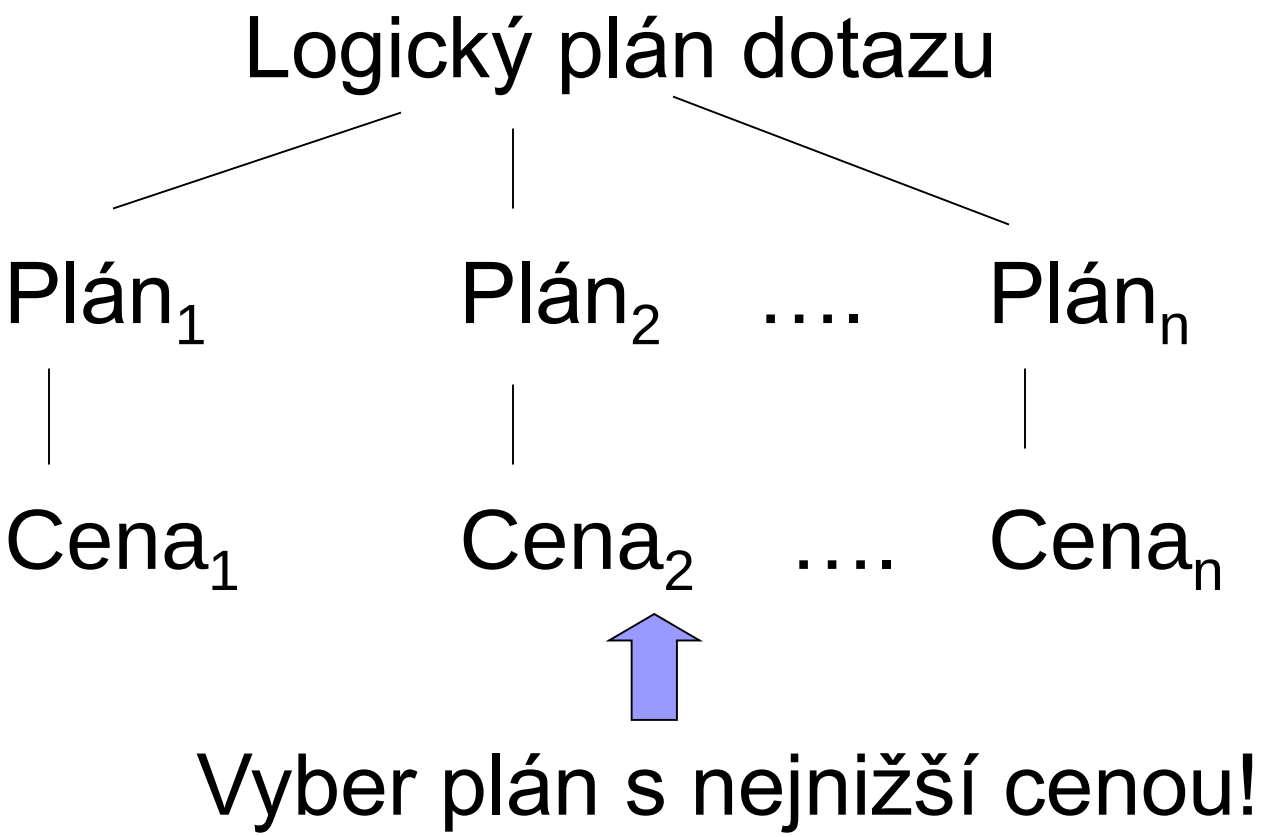

Optimalizace dotazu

- 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: $R \bowtie S = S \bowtie R$

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

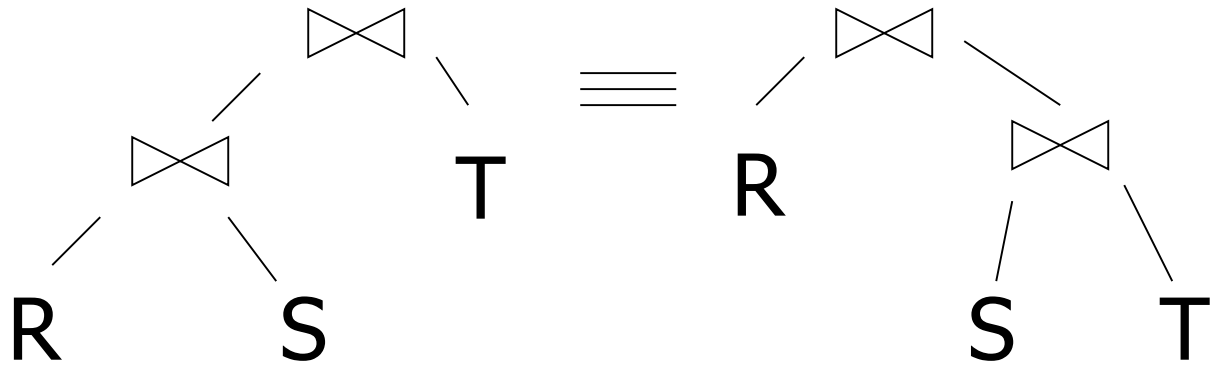

Transformační pravidla

- 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, jméno, …)
  - Senátoři(id, rok, partaj, jméno, …)
  - $R = \pi_{rok,partaj}(Senátoři)$ $S = \pi_{rok,partaj}(Poslanci)$

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

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

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

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

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

Volba správné možnosti

- Pragmatické rozhodnutí pro $\cup$
  - Použití “SUM” pro sjednocení multimnožin
  - „MAX“ pro rozdělení podmínky „*nebo*“ ($\vee$)

- Některá pravidla nelze pro multimnožiny použít
  - Asociativita rozdílu R – (S – T)
  - Distributivita: R $\cap$ (S $\cup$ T)
    != (R $\cap$ S) $\cup$ (R $\cap$ T)

Transformační pravidla

- Značení:
  - X = množina atributů
  - Y = množina atributů
  - XY = $X \cup Y$
- 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

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

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

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

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

$$\left[(\sigma_p(R)) \bowtie S \right] \cup_{max} \left[R \bowtie (\sigma_q(S)) \right]$$

Transformační pravidla

- Kombinace selekce a přirozeného spojení
  - Příklad odvození pravidla

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

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

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

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

Transformační pravidla

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

    m = výraz obsahující pouze atributy společné R i S, ale neporovnává je

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

Transformační pravidla

- Kombinace projekce a selekce
- Nechť

  x = podmnožina atributů R

  z = atributy použité ve výrazu P (podmnožina R)

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

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 (π, σ, $\bowtie$)

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

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

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

Transformační pravidla

- Kombinace projekce, selekce a kartézského součinu

$$\pi_{xy}(\sigma_p\ (R \times S)) \ = \ ?$$

Transformační pravidla

- Kombinace selekce a sjednocení

$$\sigma_p(R \cup_{sum} S) = \sigma_p(R) \cup_{sum} \sigma_p(S)$$

- 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

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

$$\sigma_{p_1 \vee p_2}(R) \rightarrow \sigma_{p_1}(R) \cup_{max} \sigma_{p_2}(R)$$

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

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

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

Vhodné transformace

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

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

Vhodné transformace

- Máme indexy
  - Pro A i pro B

$$\sigma_{(A=3) \wedge (B=\text{“cat”})}(R) = \sigma_{(A=3)}(R) \cap \sigma_{(B=\text{“cat”})}(R)$$

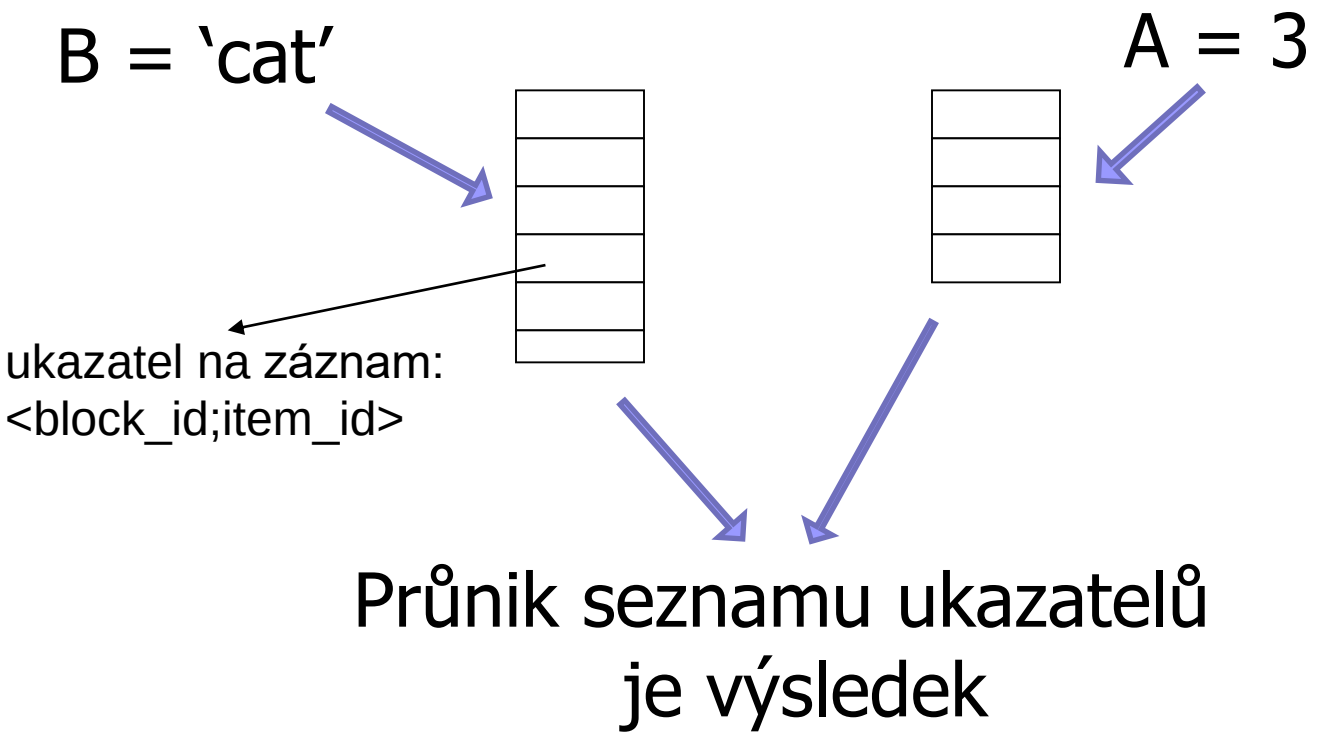

Vhodné transformace

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

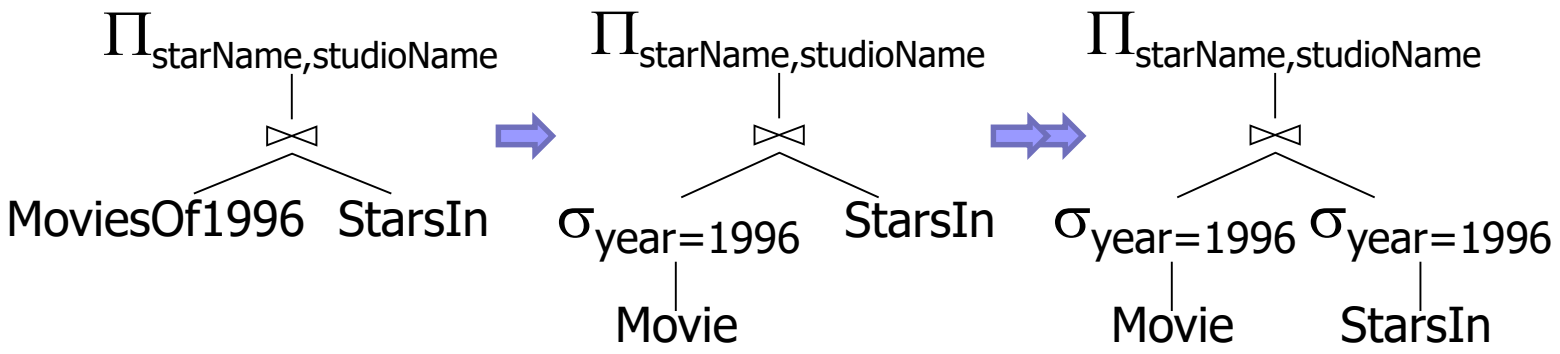

Zpracování dotazu: shrnutí

- Úroveň relační algebry
  - Transformační pravidla
  - Použití doporučených 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
  - Aktuální statistiky nutné!

Příklad statistik

- Relace R
  - Atribut A – řetězec, max. 20 B
    - S(R,A) = 3 ← průměrná délka
  - Atribut B – celé číslo, 4 B
  - Atribut C – datum, 8 B
  - Atribut D – řetězec, 5 B
    - S(R,D) = 1
- Statistiky
  - T(R) = 5 S(R) = 20
  - V(R,A) = 3 V(R,B) = 1
  - V(R,C) = 5 V(R,D) = 4

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

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

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

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

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

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
  - $W = \sigma_{C=val}(R)$
    - $T(W) = f(val) \cdot T(R) = 1/10 * 5 = 0,5$
  - $W = \sigma_{B=val}(R)$
    - $T(W) = (1/10)*5$
  - $W = \sigma_{A=val}(R)$
    - 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

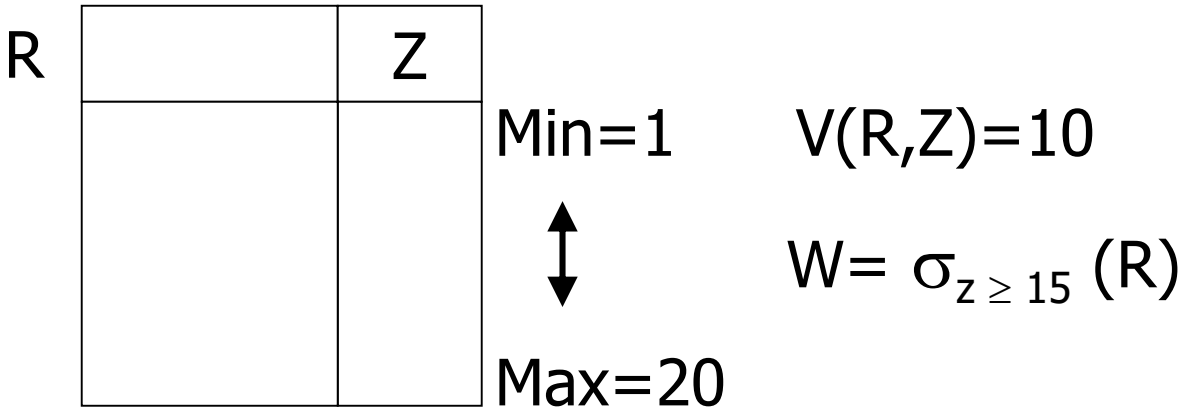

- Vypočítej podíl hodnot (unikátních)

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

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

Odhad velikosti

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

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

  - Obvyklé řešení pro $V(R,Z) \approx T(R)$
    - $T(W) = T(R)$

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

$R_1 \bowtie R_2$

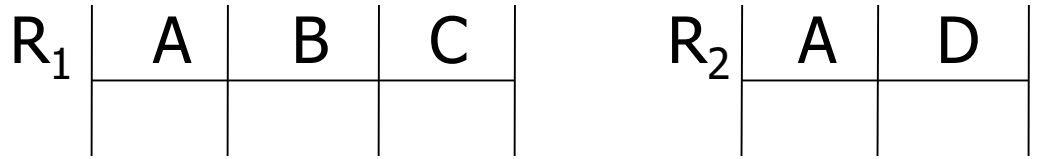

- Předpoklad
  - $V(R_1,A) \leq V(R_2,A)$
    $\rightarrow$ každá hodnota A z R_1 je i v R_2
  - $V(R_1,A) \geq V(R_2,A)$
    $\rightarrow$ každá hodnota A z R_2 je i v R_1

Odhad velikosti: přirozené spojení

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

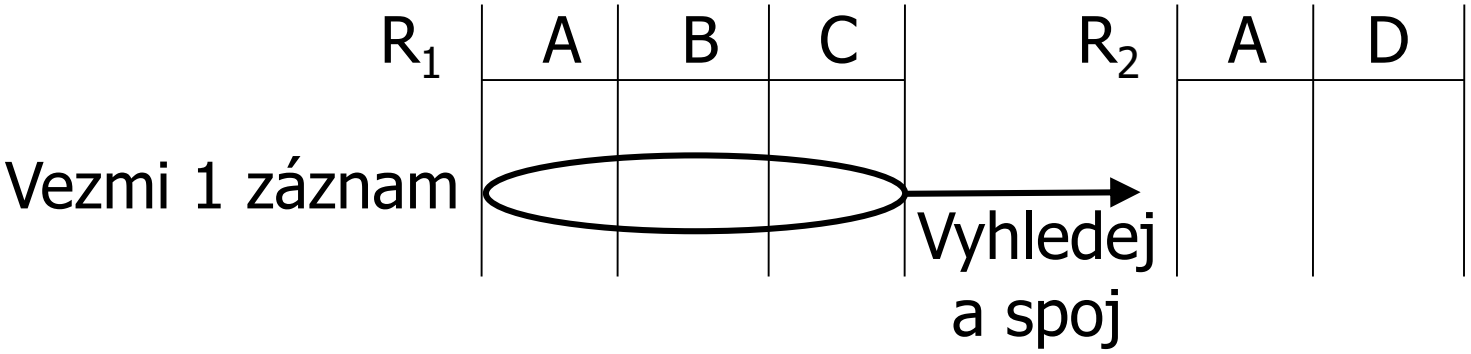

- 1 záznam se spojí s $T(R_2)$ / $V(R_2,A)$ záznamy
  - Opět předpoklad rovnoměrného rozložení
- Výsledek: $T(W) = T(R_1) \cdot \frac{T(R_2)}{V(R_2,A)}$

Odhad velikosti: přirozené spojení

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

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

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

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

- 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

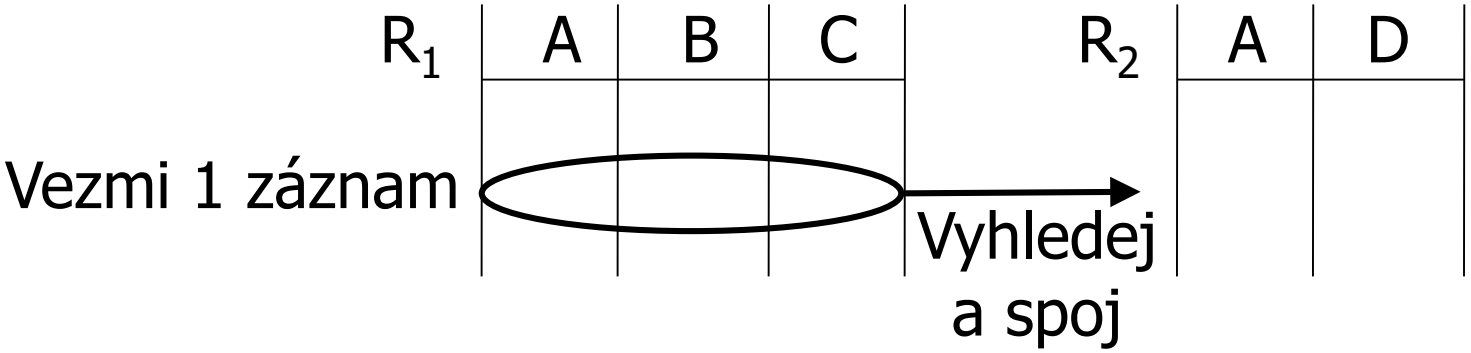

- 1 zázn. se spojí s $T(R_2)/DOM(R_2,A)$ záznamy
- Výsledek:

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

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

- Počet záznamů, když Z má více atributů?
  - Předpokládáme, že jsou nezávislé.

$$T(W) = \frac{T(R_1) \cdot T(R_2)}{\max\{ V(R_1,A_1), V(R_2,A_1) \} \cdot \max\{ V(R_1,A_2), V(R_2,A_2) \}}$$

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) – choose average size
    - $T(R \cup S) = T(R) + T(S)$ … if $\cup$ means UNION ALL here
    - $T(R \cup S) = [\ \max\{T(R), T(S)\}\ ,\ \ T(R) + T(S)\ ]$
      - So use: $T(R \cup S) = \text{avg}\{\ \max\{T(R), T(S)\}\ ,\ \ T(R) + T(S)\ \}$
        - If *set union* is evaluated
    - $T(R - S) = T(R) - ½\ T(S)$
    - $T(R \cap S) = \text{avg}\{\ 0, \min\{T(R), T(S)\}\ \}$
- DISTINCT
  - All attributes
    - min{ 1/2T(R), (V(R,A)*V(R,B)*…) }

Odhad velikosti

- Pro složitější výrazy jsou třeba ostatní statistiky
- Příklad
  - $W = [\underbrace{\sigma_{A=a}(R_1)}_{\text{označme jako U}}] \bowtie R_2$

- $T(U) = T(R_1) / V(R_1,A)$ $\quad S(U) = S(R_1)$
  - 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
- $U = \sigma_{A=a}(R_1)$
  - $T(U) = T(R_1)/V(R_1,A)$
- 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	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
V(R,B)=1
V(R,C)=5
V(R,D)=4

Odhad počtu hodnot: praxe

- Obvyklé řešení
  - $U = \sigma_{A=a}(R_1)$
  - $V(U,A) = 1$
  - $V(U,K) = T(U)$
    - K = primární klíč relace R_1
  - $V(U,*) = V(R,*)$ resp. $V(U,*) = T(U)$
- Výsledně lze využít původní V(R,*)
  - $V(U,*) = \min \{ V(R,*), T(U) \}$

Odhad počtu hodnot: spojení

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

Odhad počtu hodnot: spojení

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

Odhad počtu hodnot: spojení

- Mezivýsledek
  - $U = R_1(A,B) \bowtie R_2(B,C)$
  - Výsledek:
    - $T(U) = T(R_1) \cdot T(R_2) / \max\{ V(R_1,B), V(R_2,B) \} =$
      $= 1000 \cdot 2000 / 200 = 10\,000$
    - $V(U,A) = 50$
    - $V(U,B) = 100$
    - $V(U,C) = 300$

Odhad počtu hodnot: spojení

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

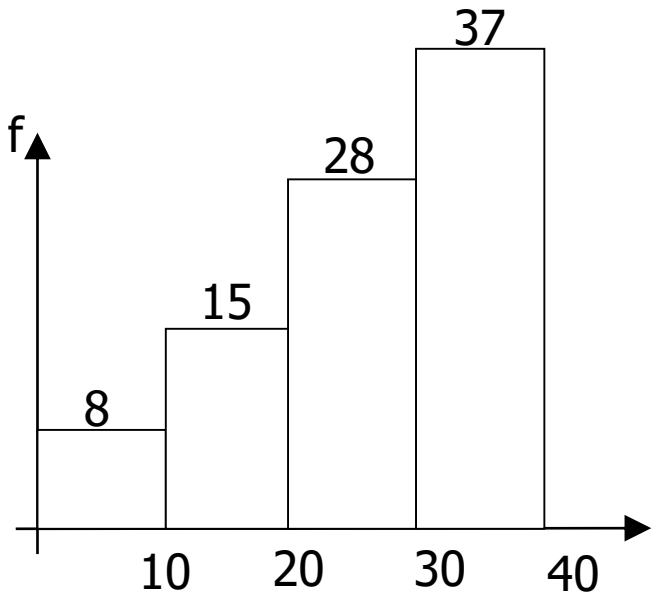

Příklad statistik PostgreSQL

- Připojte se k fakultní DB PostgreSQL
  - Návod viz první přednáška
- Ve schématu *xdohnal* jsou tabulky
  - *predmet*, *skupina, hotel*
    - Statistiky jak na relacích, tak i atributech.
  - Významy jednotlivých polí
    - http://www.postgresql.org/docs/9.6/interactive/view-pg-stats.html

Příklad statistik PostgreSQL

- Tabulka hotel

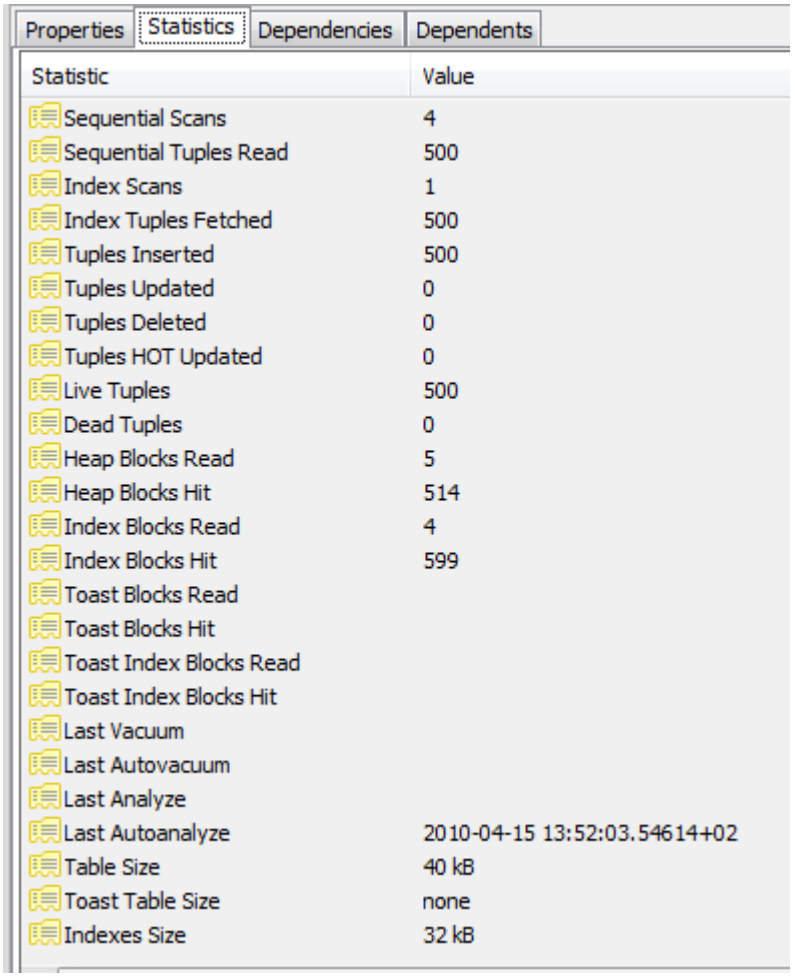

Příklad statistik PostgreSQL

- Atribut hotel.id

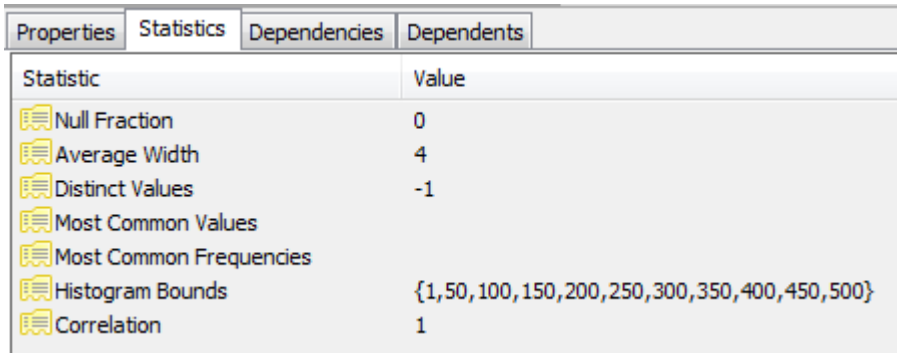

Properties | Statistics | Dependencies | Dependents

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

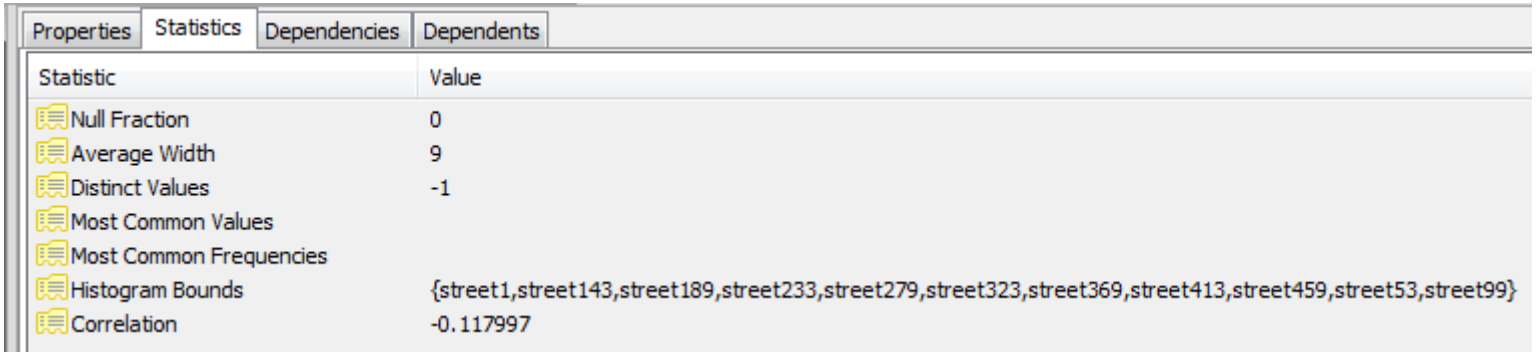

Properties | Statistics | Dependencies | Dependents

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

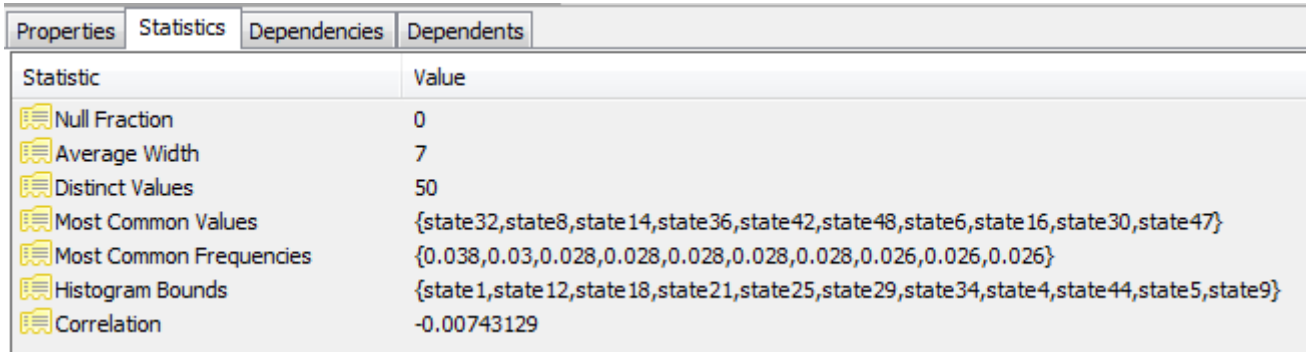

Properties | Statistics | Dependencies | Dependents

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

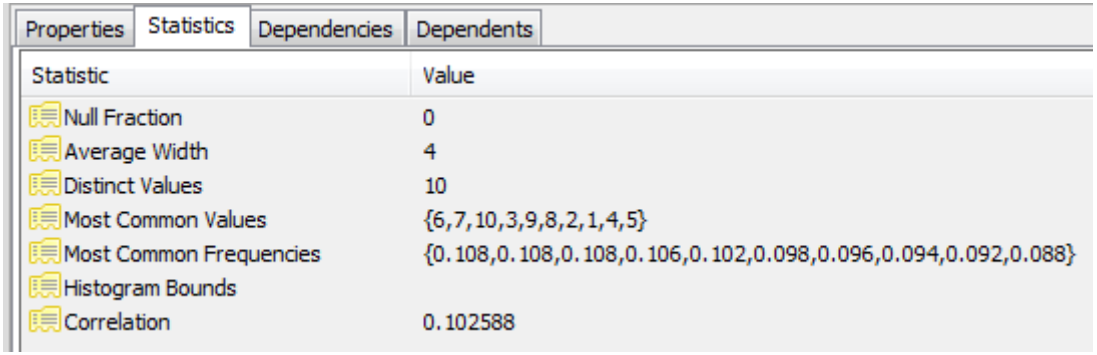

Properties | Statistics | Dependencies | Dependents

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

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: shrnutí

- Odhad velikosti výsledku operace
  - Již probráno
- Odhad počtu V/V operací
  - Další přednáška

- Vytvoření a porovnání plánů