



Databázové technologie

# Dotazovací systémy v relačním modelu (dokončení)

Petr Krajča



Katedra informatiky  
Univerzita Palackého v Olomouci



- uvažujme relaci *usedon* s relačním schématem  $R_{usedon} = \{\text{partno}, \text{ptype}, \text{nused}\}$
- pokud některá z domén atributů je nekonečná, pak např. výraz

$$\{x(R_{usedon}) \mid \neg usedon(x) \vee x(\text{ptype}) \neq "707"\}$$

- představuje relaci, která je nekonečná
- řešení: omezení na bezpečné výrazy n-ticového relačního kalkulu

## Rozšířená aktivní doména

- $edom(y, f) \subseteq D_y$
- množina všech hodnot z domény  $D_y$ , které se vyskytují v relaci použité v  $f$  nebo jako konstanty
- pro relační schéma  $R \subseteq Y$  budeme značit

$$edom(R, f) = \Pi_{y \in R} edom(y, f)$$



Výraz  $\{x(R) \mid f(x)\}$  je bezpečný, pokud platí

- 1  $I(f(t/x)) = true$ , pak  $t \in edom(R, f)$ .
- 2 Pro každou podformuli formule  $f$  ve tvaru  $\exists y(S)g(y, z_1, \dots, z_k)$ , z  $I(g(t/y, u_1/z_1, \dots, u_n/z_n)) = true$  plyne  $t \in edom(S, g)$ .
- 3 Pro každou podformuli formule  $f$  ve tvaru  $\forall y(S)g(y, z_1, \dots, z_k)$  a  $t \notin edom(S, g)$  platí  $I(g(t/y, u_1/z_1, \dots, u_n/z_n)) = true$ .

za předpokladu, že  $y, z_1, \dots, z_n$  jsou volné proměnné v  $g$ .

- bod (1) zajišťuje, že hodnota výrazu bude konečná relace
- body (2) a (3) zajišťují, že podvýrazy s kvantifikátory půjde efektivně spočítat.



■ analogické jako pro neomezené výrazy, pro  $f$ , které je dáno jako

- 1  $\exists x(R)g$ ,  $x$  je jediná volná proměnná v  $g$ .  $I(f) = true$  p.k. existuje alespoň jedno  $t \in edom(R, g)$  takové, že  $I(g(t/x)) = true$ , jinak  $I(f) = false$ .
- 2  $\forall x(R)g$ ,  $x$  je jediná volná proměnná v  $g$ .  $I(f) = true$  p.k. pro všechny  $t \in edom(R, g)$  platí,  $I(g(t/x)) = true$ , jinak  $I(f) = false$ .



## Konstantní relace

- RA:  $\{\langle y, a \rangle\}$
- NRK:  $\{t(y) \mid t(y) = a\}$

## Relace

- RA:  $\mathcal{D}$  nad relačním schématem  $R$
- NRK:  $\{t(R) \mid \mathcal{D}(t)\}$

## Restrikce

- RA:  $\sigma_{y\theta c}(E)$  nebo  $\sigma_{y_1\theta y_2}(E)$
- NRK: Pokud  $\{t(R) \mid f(t)\}$  odpovídá  $E$ :  
 $\{t(R) \mid f(t) \wedge t(y)\theta c\}$  nebo  $\{t(R) \mid f(t) \wedge t(y_1)\theta t(y_2)\}$

## Projekce

- RA:  $\pi_S(E)$
- NRK: Pokud  $\{t(R) \mid f(t)\}$  odpovídá  $E$ :  
 $\{t(S) \mid f(t)\}$



## Množinové operace

- RA:  $E_1 \cap E_2$
- NRK: Pokud  $\{t(R) \mid f(t)\}$  odpovídá  $E_1$  a  $\{t(R) \mid g(t)\}$  odpovídá  $E_2$ :  
 $\{t(R) \mid f(t) \wedge g(t)\}$
- ostatní operace analogicky

## Přirozené spojení

- RA:  $E_1 \bowtie E_2$  nad relačními schémáty  $RS$  a  $ST$
- NRK: Pokud  $\{t(RS) \mid f(t)\}$  odpovídá  $E_1$  a  $\{u(ST) \mid g(u)\}$  odpovídá  $E_2$ :

$$\{z(RST) \mid \exists x(RS)\exists y(ST)(f(x) \wedge g(y) \wedge z(RS) = x(RS) \wedge z(ST) = y(ST))\}$$



- velmi podobný n-ticovému rel. kalkulu
- proměnné nabývají hodnot jednotlivých domén (nikoliv ntic)
- formule se skládají z doménových proměnných, relačních proměnných, spojek a pomocných symbolů (závorek)

## Příklady

- $\{x y \mid parts(x, y, z) \wedge y = 206\}$
- $\{x y \mid parts(x, 206, z)\}$

## atomy

- 1  $r(y_1, \dots, y_n)$ , kde  $r$  je relační proměnná nad schématem  $\{y_1, \dots, y_n\}$
- 2  $x\theta y$ ,  $x\theta c$ ,  $c\theta y$ , kde  $x$ ,  $y$  jsou doménové proměnné a  $c$  konstanta
- 3  $true$ ,  $false$  (konstanty pravdivostních hodnot)

## formule

- 1 každý atom je formule
- 2 pokud  $f$  je formule, pak  $\neg f$  je formule
- 3 pokud  $f$  a  $g$  jsou formule, pak  $f \vee g$  a  $f \wedge g$  jsou formule
- 4 pokud  $f$  je formule, pak  $\exists x(y)f$  kde  $y \in Y$  a  $x$  je doménová proměnná, je formule
- 5 pokud  $f$  je formule, pak  $\forall x(y)f$  kde  $y \in Y$  a  $x$  je doménová proměnná, je formule
- 6 pokud  $f$  je formule, pak  $(f)$  je formule





- pro volné a vázané proměnné platí podobné pravidla jako v  $n$ -ticovém relačním kalkulu
- typ doménové proměnné je buď konkrétní doména nebo je nedefinován
- pro validní formule je potřeba, aby použití typů bylo konzistentní (nebudeme formalizovat)
- substituce doménové konstanty  $c$  za doménovou proměnnou  $f(c/x)$  je analogická  $n$ -ticovému kalkulu

Výraz doménového kalkulu má tvar:

$$\{x_1(y_1) x_2(y_2) \dots x_n(y_n) \mid f(x_1, x_2, \dots, x_n)\}$$

- $f$  je validní formule doménového kalkulu, která má právě volné proměnné  $x_1, x_2, \dots, x_n$
- $y_1, y_2, \dots, y_n$  jsou atributy z  $Y$
- typy proměnných odpovídají typům atributů

## hodnota výrazu

Je relace nad schématem  $R = \{y_1, y_2, \dots, y_n\}$ , která obsahuje všechny  $n$ -tice  $\langle c_1, c_2, \dots, c_n \rangle$  takové, že  $c_i \in D_i$  a

$$I(f(c_1/x_1, c_2/x_2, \dots, c_n/x_n)) = true$$



- přímočará
- ve výrazu  $\{x(R) \mid f(x)\}$  má každá n-ticová proměnná  $z$  přiřazené unikátní schéma  $S$ .  
Bud' se  $z$  vyskytuje v podformuli  $\exists z(S)$  nebo  $\forall z(S)$ , nebo  $z = x$  a pak  $S = R$ .
- n-ticová proměnná  $t$  je nahrazena doménovými proměnnými  $t_1, \dots, t_n$
- atom  $r(t)$  je nahrazen  $r(t_1, \dots, t_n)$
- atomy ve tvaru  $t(y_i) \theta c$  jsou nahrazeny  $t_i \theta c$
- podformule  $\exists t(S)g$  je nahrazena  $\exists t_1(y_1)\exists t_2(y_2) \dots \exists t_n(y_n) g$
- analogicky pro  $\forall$
- analogicky první část výrazu  $x(R)$  je nahrazena  $x_1(y_1) x_2(y_2) \dots x_n(y_n)$



## dotazy ve tvaru „některá A jsou B”

- *Studenti, kteří mají zapsaný nějaký předmět.*
- *Součástky, které patří do některého výrobku.*
- *Dodavatelé, kteří dodávají některé výrobky.*
- ...

## dotazy ve tvaru „všechna A jsou B”

- *Studenti, kteří mají splněny všechny vyžadované předměty.*
- *Výrobky, jejichž všechny součástky jsou skladem.*
- *Dodavatelé, kteří dodávají všechny výrobky.*
- ...

Vyjadřování dotazů **existenčního** a **všeobecného** charakteru:

- **existenční** – polospojení (projekce a přirozené spojení)
- **všeobecný** – dělení (množinový rozdíl, přirozené spojení, projekce)

Uvažujme následující relace:  $\mathcal{D}_1$  (dělenec) na schématu  $R$ ,  $\mathcal{D}_2$  (dělitel) na schématu  $S$  a  $\mathcal{D}_3$  (prostředník) na schématu  $T$ . Pak relace

$$\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2 = \{r(R \cap T) \mid r \in \mathcal{D}_1 \text{ tak, že pro každou } s \in \mathcal{D}_2 \text{ splňující podmínku } r(R \cap S \cap T) = s(R \cap S \cap T) \text{ platí, že } r(R \cap T)s(S \cap T) \in \pi_{(R \cup S) \cap T}(\mathcal{D}_3)\}$$

se nazývá **podíl**  $\mathcal{D}_1$  a  $\mathcal{D}_2$  přes  $\mathcal{D}_3$  na schématu  $R \cap T$ .

**Interpretace** pro  $\mathcal{D}_1$  (výrobci),  $\mathcal{D}_2$  (výrobek),  $\mathcal{D}_3$  a (kdo vyrábí co):

- $\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2$  – výrobci vyrábějící všechny výrobky
- ...ještě jinak:  $r$  z dělence (výrobce) je ve výsledném podílu právě tehdy, pokud pro každou  $s$  (výrobek) z dělitele platí, že  $rs$  je v prostředníkově (výrobce-výrobek), tj. výrobce vyrábí každý výrobek.
- $\mathcal{D}_2 \div_{\mathcal{D}_3} \mathcal{D}_1$  – výrobky vyráběné všemi výrobci

# Příklad dat pro relační dělení



NAME
Abbe
Blangis
Curval
Durcet

COURSE
KMI/DATA1
KMI/DATA2
KMI/PAPR1

NAME	COURSE
Abbe	KMI/DATA1
Abbe	KMI/DATA2
Blangis	KMI/DATA1
Blangis	KMI/DATA2
Blangis	KMI/PAPR1
Curval	KMI/DATA1
Curval	KMI/DATA2
Curval	KMI/PAPR1

NAME	MAJOR
Abbe	CS
Blangis	CS
Curval	EE
Durcet	SS

COURSE	VERSION
KMI/DATA1	2
KMI/DATA2	1
KMI/PAPR1	2

NAME	COURSE	YEAR
Abbe	KMI/DATA1	2011
Abbe	KMI/DATA2	2012
Blangis	KMI/DATA1	2012
Blangis	KMI/DATA2	2012
Blangis	KMI/PAPR1	2007
Curval	KMI/DATA1	2011
Curval	KMI/DATA2	2013
Curval	KMI/PAPR1	2008



Pro  $\mathcal{D}_1$  na  $R$ ,  $\mathcal{D}_2$  na  $S$ ,  $\mathcal{D}_3$  na  $T$  platí:

$$\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2 = \pi_{R \cap T}(\mathcal{D}_1) \setminus \pi_{R \cap T}((\pi_{R \cap T}(\mathcal{D}_1) \bowtie \pi_{S \cap T}(\mathcal{D}_2)) \setminus \pi_{(R \cup S) \cap T}(\mathcal{D}_3)).$$

## Neformální skica důkazu

- $\mathcal{D}_a = \pi_{R \cap T}(\mathcal{D}_1) \bowtie \pi_{S \cap T}(\mathcal{D}_2)$  – všechny kombinace hodnot, které můžeme uvažovat v  $\mathcal{D}_3$
- $\mathcal{D}_b = (\mathcal{D}_a \setminus \pi_{(R \cup S) \cap T}(\mathcal{D}_3))$  – všechny n-tice, které mohly být v  $\mathcal{D}_3$ , ale nejsou.
- $\mathcal{D}_c = \pi_{R \cap T}(\mathcal{D}_b)$  – všechny n-tice z  $\mathcal{D}_1$ , které nemají v  $\mathcal{D}_3$  **nějakou** spojitelnou n-tici.
- $\mathcal{D}_d = \pi_{R \cap T}(\mathcal{D}_1) \setminus \mathcal{D}_c$  – ponechá n-tice  $\mathcal{D}_1$ , kterým nechybí spojitelná n-tice v  $\mathcal{D}_3$ .



Pro každou podformuli  $g$  budeme rekurzivně definovat výraz relační algebry  $F_g$ , který bude ekvivalentní výrazu

$$\{x_1 \ x_2 \ \dots \ x_n \mid g(x_1, x_2, \dots, x_n)\}$$

## atomy

Pokud je  $g$  atom ve tvaru  $u \ \theta \ v$ ,  $u \ \theta \ u$ ,  $u \ \theta \ c$  nebo  $c \ \theta \ u$ , pak odpovídající algebraické výrazy jsou

$$\sigma_{A\theta B}([A] \times [B])$$

$$\sigma_{A\theta A}([A])$$

$$\sigma_{A\theta c}([A])$$

$$\sigma_{c\theta A}([A])$$

Kde  $[A]$  označuje relaci se stupněm jedna obsahující všechny hodnoty z domény  $D_A$ , kde  $A$  označuje atribut příslušný  $u$  nebo  $v$ .





Pokud je  $g$  atom ve tvaru  $r(a_1, \dots, a_n)$ , kde  $a_i$  je konstanta nebo doménová proměnná a  $R = \{y_1, \dots, y_n\}$  je relační schéma  $r$ , pak odpovídající algebraický výraz  $F_g$  je tvaru

$$\pi_X(\rho_N(\sigma_C(r)))$$

- $C$  je konjunkce porovnání na rovnost pro každé  $a_i$ , které je konstantou
- $N$  je přejmenování, které každé doménové proměnné přiřadí odpovídající atribut  $y'_i$
- $X$  je množina atributů  $\{y'_i \mid \text{pro kterou je } a_i \text{ proměnná}\}$

## Negace

Pokud  $g$  je podformule  $\neg h$  a  $F_h$  je alg. výraz odpovídající  $h$ , pak

$$F_g = \bar{F}_h.$$



## binární operace

Podformule  $g$  je tvaru  $h_1 \wedge h_2$ , kde

- $h_1$  obsahuje volné proměnné  $z_1, \dots, z_k$  a  $v_1, \dots, v_p$
- $h_2$  obsahuje volné proměnné  $z_1, \dots, z_k$  a  $w_1, \dots, w_q$
- $F_{h_1}$  a  $F_{h_2}$  jsou algebraické výrazy odpovídající  $h_1$  a  $h_2$ , pak

$$F_1 = F_{h_1} \bowtie [C_1] \bowtie \dots \bowtie [C_q]$$

$$F_2 = F_{h_2} \bowtie [B_1] \bowtie \dots \bowtie [B_p]$$

$$F_g = F_1 \cap F_2$$

- $[C_1], \dots, [C_q]$  odpovídají relačním proměnným  $w_1, \dots, w_q$
- $[B_1], \dots, [B_p]$  odpovídají relačním proměnným  $v_1, \dots, v_p$
- smyslem je doplnit relační schémata, aby byla kompatibilní
- analogicky pro  $\vee$



## existenční kvantifikátor

Podformule  $g$  je tvaru  $\exists x(y)h$  a  $F_h$  je alg. výraz na relačním schématu  $R$  pro  $h$ , pak odpovídající výraz má tvar

$$F_g = \pi_{R \setminus \{y\}}(F_h)$$

## univerzální kvantifikátor

Podformule  $g$  je tvaru  $\forall x(y)h$  a  $F_h$  je alg. výraz na relačním schématu  $R$  pro  $h$ , pak odpovídající výraz má tvar

$$F_g = F_h \div [y]$$



- ukázali jsme převoditelnost jednotlivých dotazovacích systémů
- ukazuje vztah mezi deklarativním a operativním zpracováním dotazů
- důležité pro studium vyjadřovací síly dotazovacích jazyků
- některé dotazy ale i tak neuchopitelné (např. hierarchická data)
- možné další aplikace

## Restrikce

*instock:*

partno	location	amount
	NYC	> 20

## Spojení

*instock:*

partno	location	amount
_PN	NYC	

*parts:*

partno	supbartof	partname
_PN		bolt M3