



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

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

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 schematy 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

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

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

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

- 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

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

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 prostředníkovi (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:

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

Neformální skica důkazu

- a $\mathcal{D}_a = \pi_{R \cap T}(\mathcal{D}_1) \bowtie \pi_{S \cap T}(\mathcal{D}_2)$ – všechny kombinace hodnot, které můžeme uvažovat v \mathcal{D}_3
- b $\mathcal{D}_b = (\mathcal{D}_a \setminus \pi_{(R \cup S) \cap T}(\mathcal{D}_3))$ – všechny n-tice, které mohly být v \mathcal{D}_3 , ale nejsou.
- c $\mathcal{D}_c = \pi_{R \cap T}(\mathcal{D}_b)$ – všechny n-tice z \mathcal{D}_1 , které nemají v \mathcal{D}_3 **nějakou** spojitelnou n-tici.
- d $\mathcal{D}_d = \pi_{R \cap T}(\mathcal{D}_1) \setminus \mathcal{D}_c$ – 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 $\{y'_i \mid$ pro kterou je a_i 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

$$\begin{aligned} F_1 &= F_{h_1} \bowtie [C_1] \bowtie \cdots \bowtie [C_q] \\ F_2 &= F_{h_2} \bowtie [B_1] \bowtie \cdots \bowtie [B_p] \\ F_g &= F_1 \cap F_2 \end{aligned}$$

- $[C_1], \dots, [C_q]$ 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

Query-by-Example (QBE)



- dotazovací jazyk založený na relačním kalkulu
- dotazy jsou vkládány do tabulek se stejným záhlavím, jako mají datové tabulky
- uživatel zadává hodnoty, které musí výsledek splňovat

Restrikce

instock:

partno	location	amount
	NYC	> 20

Spojení

instock:

partno	location	amount
_PN	NYC	

parts:

partno	supbartof	partname
_PN		bolt M3