

# Relačná algebra pre výpočet rekurzívnych dotazov

Matúš Hedera  
školiťel': doc. Dr. Tomáš Plachetka

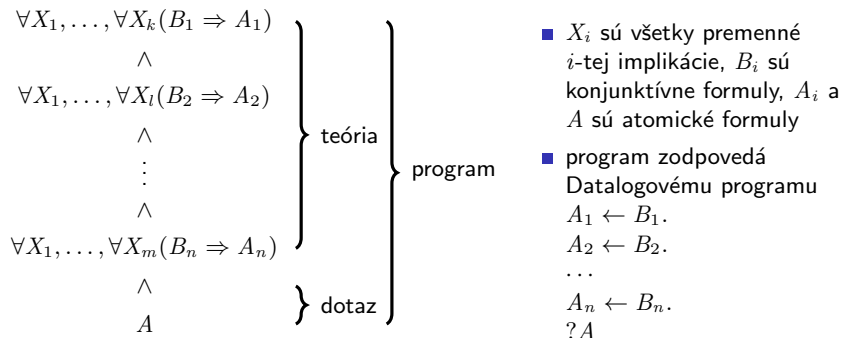
KI FMFI UK v BA

Jún 2022

## Ciel' práce

- navrhnuť relačnú algebru rozšírenú o operátory rekurzie
- minimalizovať počet operátorov
- minimalizovať parametre operátorov
- dať do súvisu rôzne abstrakcie (logika, sémantika, výpočet)


- definujeme zúženie logiky 1. rádu tak, aby zodpovedalo jazyku Datalog
- z jednoduchých—atomických formúl vznikajú zložené formuly
- ak  $A$  je jednoduchá formula, tak  $\neg A$  je formula
- ak  $B, C$  sú formuly, tak  $B \wedge C$  je formula
- implikácia sa používa výhradne na definíciu predikátu



- atomická formula  $A$  môže mať premenné  $X_1, \dots, X_r$
- $r$ -tica konštánt  $[k_1, \dots, k_r]$  je vo výsledku, ak  $A[X_1|k_1, \dots, X_r|k_r]$  je *true*
- dotaz je otázka na *true* logické objekty
- otázky na *false* a *unknown* nie sú (syntakticky) povolené

# Trojhodnotová logika

- logický objekt  $p(k_1, \dots, k_n)$  pozostáva z predikátu  $p$  a konštánt  $k_1, \dots, k_n$
- každý logický objekt nadobúda jednu z hodnôt:  $true, false, unknown$
- interpretácia  $\mathcal{I}$  priradí každému predikátu  $p$  3 relácie.



- sémantika je interpretácia, od ktorej požadujeme existenciu, jednoznačnosť, stabilitu, úplnosť (samozrejme požadujeme, aby sémantika bola modelom)
- well-founded sémantika (minimálny stabilný 3-hodnotový model) má všetky požadované vlastnosti

## Prečo nestačia 2 hodnoty

- v klasickej 2-hodnotovej sémantike sa považuje za pravdivé (len) to, čo je pravdivé vo všetkých modeloch danej teórie. To nepostačuje, lebo prienik všetkých modelov nemusí byť modelom danej teórie. Napríklad, pre:

$$p(1).$$

$$p(2) \leftarrow \neg p(3).$$

$$p(3) \leftarrow \neg p(2).$$

$\mathcal{M}_1, \mathcal{M}_2, \mathcal{M}_3$  sú všetky modely teórie,  $\mathcal{M}_1 \cap \mathcal{M}_2 \cap \mathcal{M}_3$  nemusí byť modelom

	$p(1)$	$p(2)$	$p(3)$
$\mathcal{M}_1$	<i>T</i>	<i>T</i>	<i>F</i>
$\mathcal{M}_2$	<i>T</i>	<i>F</i>	<i>T</i>
$\mathcal{M}_3$	<i>T</i>	<i>T</i>	<i>T</i>
$\mathcal{M}_1 \cap \mathcal{M}_2 \cap \mathcal{M}_3$	<b><i>T</i></b>	<b><i>F</i></b>	<b><i>F</i></b>

# Výpočet rekurzívnych Datalogových programov

súčasný stav:

- relácia  $p_{true}$  je počítaná "intuitívne", od čoho sa odvíja sémantika
- zastavenie nie je garantované

```
1 Každému predikátu prirad' prázdnu reláciu;
2 do
  | // Urob 1 krok iterácie
3   Aplikuj raz každé pravidlo programu;
4   Výsledok prirad' do príslušných relácií;
5 while Nejaká relácia sa zmenila;
```

---

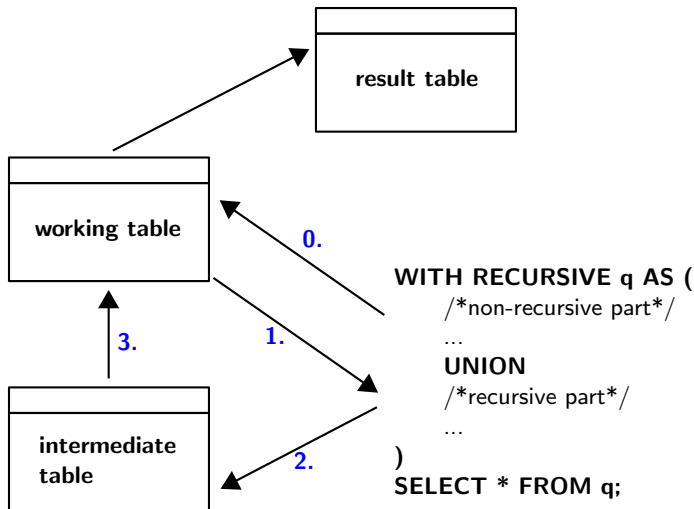
naše zlepšenie:

- relácia  $p_{true}$  je počítaná podľa vopred dohodnutej well-founded sémantiky
- relácie  $p_{false}$  a  $p_{unknown}$  sa nepočítajú a neukladajú

```
1 Každému predikátu prirad' prázdnu reláciu;
2 do
3   do
  | // Urob 1 krok iterácie
4   Aplikuj raz každé pravidlo programu;
5   Výsledok prirad' do príslušných relácií;
6   while Nejaká relácia sa zmenila;
7 while NOT ukončené;
```

## Rekurzia v SQL

- súčasný stav: SQL systémy ukladajú medzivýsledky rekurzie do tabuliek
- naše zlepšenie: každá tabuľka je nahradená iterátorom, t.j. v danej chvíli sa počíta len 1 výstupný riadok







# Relačná algebra, motivácia

- nezávislosť výpočtu dotazov od procedurálnych jazykov
- výpočet má štruktúru (algebraické operátory)
- kontrola nad výpočtom (optimalizácie algebraických výrazov)

súčasný stav:



naše zlepšenie:



## Rekurzia v relačnej algebre

- všetky dvojice vrcholov spojené cestou v grafe  $r$ :

$$p(X, Y) \leftarrow r(X, Y).$$

$$p(X, Y) \leftarrow r(X, Z), p(Z, Y).$$

$$?p(X, Y)$$


- výpočet rekurzie ako cyklus:

```
1  $p_{true} = \emptyset$ ;  
2 do  
3 |  $p'_{true} = p_{true}$ ;  
4 |  $p = r \cup \pi_{X,Y}(r \bowtie p)$ ;  
5 while  $p'_{true} \neq p_{true}$ ;
```

- výpočet rekurzie ako operátor:

$$\Psi(r \cup \pi_{X,Y}(r \bowtie p))$$

graf relácie  $r$ :




	X	Y
1. iterácia	a	b
	b	c
	c	d
	d	e
2. iterácia	a	c
	a	d
	b	e
3. iterácia	a	e

## Funkčné symboly

- $p_{true} = \{1, s(1), s(s(1)), s(s(s(1))), \dots\}$
- rekurzívny operátor je smerník na algebraický výraz
- výpočet je popísaný aj v jazyku logiky ( $\Psi$  a  $\Gamma^*$ )
- SQL neumožňuje výpočet s funkčnými symbolmi
- výpočet  $?p(X)$  je nekonečný, ale napríklad výpočet  $?p(s(s(1)))$  skončí v konečnom čase


$p(1)$ .

$p(s(X)) \leftarrow p(X)$ .




# Príklad iteratívneho výpočtu


“šablóna” rekurzívneho výpočtu:




strom pre hĺbku 1:



strom pre hĺbku 2:




strom pre hĺbku 3:



## Príklad iteratívneho výpočtu

strom pre hĺbku 3:



$p(1).$

$p(s(X)) \leftarrow p(X).$

$?p(s(s(1)))$

- rekurziu sme popísali deklaratívne (v jazyku logiky) aj imperatívne (relačná algebra, Java)
- v porovnaní so súčasnými systémami sa náš výpočet zastaví pre väčšiu triedu dotazov (garantované pre všetky dotazy bez funkčných symbolov), výsledok sa počíta podľa well-founded sémantiky
- minimalizovali sme počet algebraických operátorov a ich parametre
- z relačnej algebry sme eliminovali príkazy externého programovacieho jazyka (cykly, priradenia, ...)
- pamäťová zložitosť výpočtu dotazu nezávisí od veľkostí vstupných relácií
- vďaka integrácii s predošlými projektami vieme počítať aj dotazy s funkčnými symbolmi