

Výpočet rekurzivních dotazov v relačních databázových systémech

Jakub Šmahovský

doc. Mgr. Tomáš Plachetka, Dr.

24. juna 2019

Fakulta matematiky, fyziky a informatiky

- databázové systémy sa skladajú z mnohých odvetví
- zameriavame sa špeciálne na výpočet dotazu
 - máme k dispozícii dotaz a relačné dáta
 - cieľom je vypočítať výsledok dotazu daný sémantikou

Deklaratívne jazyky

- program definuje iba výsledok
- kompilátor zvykne vykonávať optimalizácie
- SQL, Datalog

Procedurálne jazyky

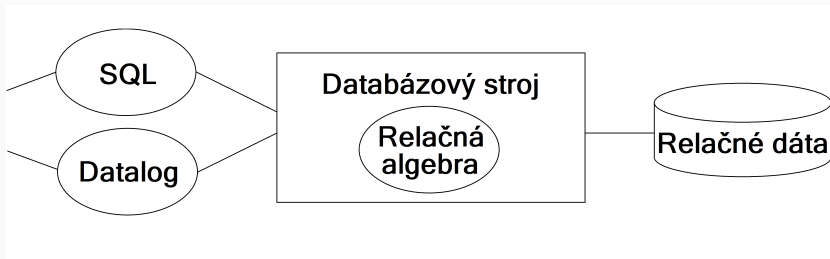
- program definuje postup výpočtu
- interpretér nezvykne vykonávať optimalizácie
- relačná algebra

selekcia	σ_C
projekcia	π_C
zjednotenie	\cup
join	\bowtie_C
antijoin	\triangleright_C
filtrujúce podmienky C	

priradenie	$:=$
cyklus	while begin "telo cyklu" end

Výpočet dotazov

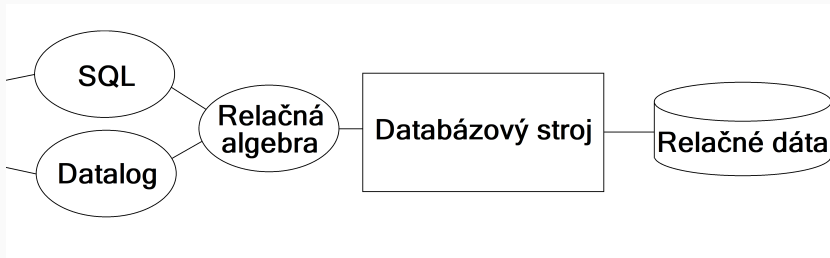
Systemy na výpočet dotazov môžu mať rôznu architektúru



- dotazy v deklaratívnom jazyku môžu byť priamo interpretované databázovým strojom
- databázový stroj iba interne implementuje obdobu relačnej algebrы

Výpočet dotazov

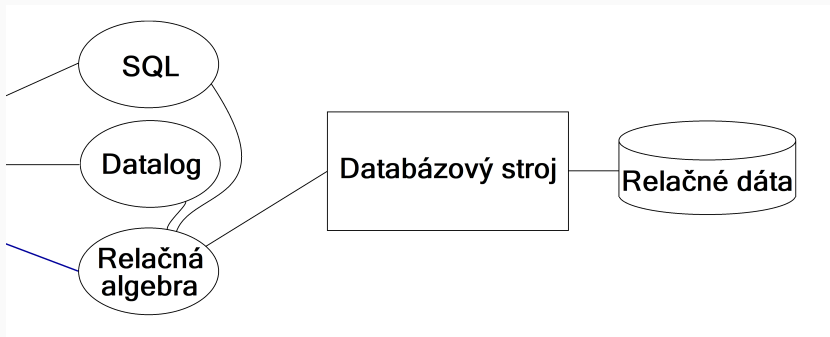
Systémy na výpočet dotazov môžu mať rôznu architektúru



- dotazy môžu byť prekladané do relačnej algebry v samostatnom module systému
- databázový stroj interpretuje iba dotazy v relačnej algebre

Výpočet dotazov

Systémy na výpočet dotazov môžu mať rôznu architektúru




- chceli sme používateľovi umožniť písať dotazy priamo v jazyku relačnej algebry
- zároveň sme chceli zachovať aj možnosť použiť deklaratívny jazyk


Optimalizácie

Niektoré optimalizácie vieme robiť všeobecne

lepšie




horšie




Optimalizácie

Niektoré optimalizácie sa všeobecne robia ťažko

???



???



- súhrn znalostí pre preklad a počítanie rekurzívnych dotazov v Datalogu a relačnej algebre
- návrh a implementácia minimalistického databázového systému, ktorý počíta dotazy v oboch týchto jazykoch
 - operácie relačnej algebry
 - kompilátor datalogu
 - interpretér relačnej algebry
- testy demonštrujúce vybrané možnosti optimalizácie
 - poradie operácií join
 - poradie vstupov pre join
 - vynútenie materializácie

Materializácia versus iterácia

- zasebou nadväzujúce operácie
- operácie si posúvajú záznamy relácií po jednom
- materializácia medzivýsledku môže zaberáť priveľa pamäte
- ukladanie a načítavanie môže zaberáť viac času ako opätovné počítanie

- rekurzívne volať next na odstraňovanie duplikátov je nerealistické

```
interface Operator {  
    public Tuple next();  
    public Operator instance();  
    public void reset();  
}
```

- riešením je interne používať novú metódu

```
Tuple nonDistinctNext();
```

- niekedy je materializácia žiadaná, napríklad na rekurziu
- priradenie do relácie = materializácia

Výpočet Datalogu podľa well-founded sémantiky

- programom udávame význam podľa takzvanej well-founded sémantiky
- dobre odzrkadľuje to, čo mal pravdepodobne programátor na mysli
- dovoľuje nám počítať programy s akoukoľvek rekurziou
- náročnejší výpočet
- relačnú algebru definujeme tak, aby umožňovala vyjadriť programy s rovnakým významom

Výpočet Datalogu podľa well-founded sémantiky

- ako počítame takýto program (s reláciou $e = \{(1)\}$)?
 $r(X) \leftarrow \neg s(X), e(X).$
 $s(X) \leftarrow \neg r(X), e(X).$
- v dvojhodnotovej logike nedostaneme uspokojivý výsledok
 - intuícia: $r(1) \vee s(1)$
 - označiť obe za nepravdivé je sporné
 - žiadnu z iných možností nevieme dokázať
- uvažujeme v trojhodnotovej logike
 - oba výrazy označíme za neznáme (unknown)
 - na otázky $r(1)?$ $s(1)?$ $\neg r(1)?$ $\neg s(1)?$ odpovedáme false
 - odpovede sú iba také, ktoré vieme odvodiť zo zdrojových dát

Výpočet Datalogu podľa well-founded sémantiky

- každé pravidlo preložíme na priradenie

$$r := e \triangleright_{\hat{1}=\hat{2}} s$$

$$s := e \triangleright_{\hat{1}=\hat{2}} r$$

- vnútorný cyklus: pravá strana antijoinu z predošlého pevného bodu, hľadáme nový pevný bod
- vonkajší cyklus: hľadáme alternujúci pevný bod

pevný bod	1.	2.	3.	4.	5.
$r(1)$	false	true	false	true	...
$s(1)$	false	true	false	true	...

po tretej iterácii vieme, že sme našli výsledok

- venovali sme sa Datalogu a relačnej algebre
- zhrnuli sme v práci potrebné znalosti
- implementovali sme operácie relačnej algebry, základný kompilátor datalogu a interpretér relačnej algebry
- vykonali sme a zdokumentovali demonštračné testy, ktoré ukazujú ako sa dá takýto systém využiť