Databázové technologie

Provádění dotazů

Petr Krajča

Katedra informatiky
Univerzita Palackého v Olomouci

Zpracování dotazů

- query processor – klíčová část SŘBD
- dotazy zpracovávány ve dvou krocích
  1. dotaz je přeložen na prováděcí plán
  2. data jsou zpracována podle prováděcího plánu

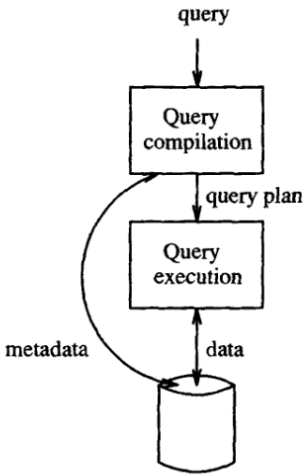

Překlad dotazu

- dotazy překládány v několika krocích
  1. parsování – text je převed na syntaktický strom
  2. prvotní sestavení prováděcí plánu – ze syntaktického stromu je vytvořen **logický prováděcí plán** (blízký rel. algebře)
  3. vytvoření **fyzického prováděcího plánu** (operace pracující s daty)
- interní reprezentace jako strom operací
- využití algebraických vlastnostní operací
- nutné brát v potaz efektivitu jednotlivých operací (zavisí na datech, jejich velikosti, dostupné paměti, indexech, hodnotách atributu, . . .)

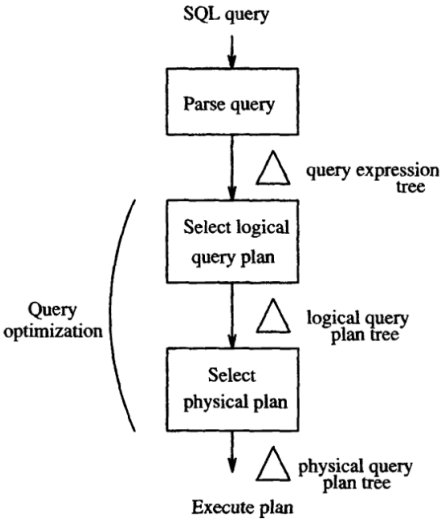

Teorie vs. (inženýrská) realita

- praktické relační databázové systémy se odchylují od teoretického modelu
  - umožňují duplicitní řádky
  - přidávají operace, které nemají oporu/smysl v rel. modelu (řazení, eliminace duplicitních řádků)
- alternativní teoretický základ
  - relace je multimnožina (bag) ntic
  - přidány nutné a praktické operace
- reálně se používá množinový i multimnožinový pohled (současně)

Multimnožina

- jednotlivé prvky se v množině mohou vyskytovat vícekrát
- tomu uzpůsobéne operace (počty prvků se sčítají, odčítají, atp.)
- pro $R = \{A, B, B\}, S = \{C, A, B, C\}$
  - $R \cup S = \{A, A, B, B, B, C, C\}$ (součet, liší se od standardní operace $\cup$ na multimnožinách)
  - $R \cap S = \{A, B\}$ (minimum)
  - $R - S = \{B\}$ (rozdíl)
- alternativní pohled na relace $\mathcal{D} : \Pi_{y \in R} D_t \to \mathbb{N}_0$

Sada operací

- většina operací rel. algebry snadno převoditelná i na multimnožiny
- σ, π, $\bowtie$, $\times$, $\cap$, $\cup$, $-$
- další operace plynoucí z vlastností SQL

Aggregace a seskupení

- tyto dvě operace z pohledu SQL spolu úzce souvisí
- pro relaci $\mathcal{D}$ na relačním schématu R
- budeme $\gamma_L(\mathcal{D})$ značit operaci seskupení, kde L obsahuje
  - atributy z R (dle kterých dochází k seskupení), nebo
  - dvojice $f_A(y_i) \to y'_i$, kde $y_i \in R$, $y'_i \in Y$ a f_A je agregační funkce (min, max, sum, ...)

Eliminace duplicit

- operaci eliminující duplicitní ntice v relaci budeme značit $\delta(\mathcal{D})$
- redundantní, lze nahradi γ

Řazení ntic

- pro řazení ntic se zavádí operace $\tau_L(\mathcal{D})$, kde $L \subseteq R$

Základní operátory pro čtení dat

table scan

- nejzákladnější operací je přečtení všech dat dané tabulky
- předpokládá se, že data jsou v blocích (rozděleny podle tabulek)
- data načítána po jednotlivých blocích

index scan

- pokud je k dispozici index, je možné získat řádky splňující danou podmínku
- získat řádky v seřazené podobě vzhledem k danému indexu

řazení při čtení dat

- buď součást dotazu (`ORDER BY`) nebo jako předpoklad jiné operace
- několik možností
  1. pro malá data přímo v paměti
  2. s využitím indexu
  3. vhodný řadící algoritmus (dvoufázový, vícecestný mergesort)

Dvoufázový, vícecestný mergesort

- vhodný v situacích, kdy dostupná paměť je menší než data
- fáze 1: rozdělení dat na menší části a jejich seřazení
  1. do dostupné paměti je načtená část bloků tabulky
  2. řádky tabulky jsou seřazeny (v paměti)
  3. seřazené části jsou uloženy na disk
- fáze 2: sloučení seřazených částí
  1. pro každou samostatně seřazenou část se načte do paměti jeden blok
  2. je vybrán nejmenší dosud neuvažovaný řádek
  3. ten je zapsán na první volné místo výstupního bloku (bufferu)
  4. pokud je výstupní buffer zaplněn, je zapsán na disk a v paměti vynulován
  5. pokud je blok dané části zcela zpracován, načte se další (pokud je k dispozici)
  6. opakuje se od kroku 2, dokud nejsou zpracovány všechny řádky

Dvoufázový, vícecestný mergesort

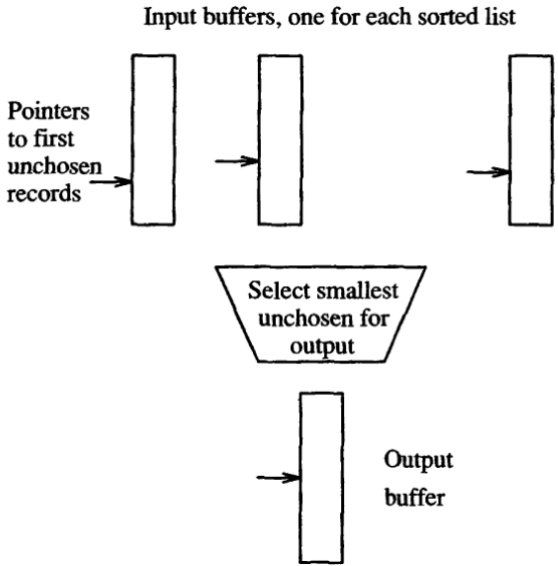

Model pro hodnocení náročnosti operací

- pro hodnocení náročnosti jednotlivých operací je důležité zavést model
- určuje, který fyzický prováděcí plán bude zvolen
- nejnáročnější I/O operace (operace v paměti budeme zanedbávat)
- budeme předpokládat:
  - všechna vstupní data jsou na disku (v praxi nemusí platit)
  - I/O operace pro výstup lze zanedbat (obvykle předány dál)

- základní odhad náročnosti operací lze udělat na základě
  - počtu bloků dané tabulky, budeme značit $B(R)$
  - dostupného počtu bufferů v paměti, které lze použít pro zpracování dotazu, budeme značit M (buffer má stejnou velikost jako blok)

- dále lze využít počet:
  - počet řádek tabulky $T(R)$
  - počet různých hodnot daného atributu v tabulce $V(R, a)$

Model pro hodnocení náročnosti operací, příklady

- table scan, řazení tabulky v paměti: $B(R)$
- index scan: více než $B(R)$ (samostatné vyhledání řádků, může být rychlejší)
- dvoufázový, více cestný mergesort: $3 \cdot B(R)$
  - načtení dat v první fázi: $B(R)$
  - uložení dat v první fázi: $B(R)$
  - postupné načítání dat v druhé fázi: $B(R)$
  - uložení výsledku: zanedbáváme

Realizace operátorů

- operátory typicky realizovány formou iterátorů
- operace:
  - `open` – inicializace iterátoru
  - `getNext` – vrátí další řádek, nebo signalizuje konec dat
  - `close` – ukončí práci s iterátorem (typicky použije operaci close na své argumenty)
- v ideálním případě umožňují proudové zpracování dat
- ,,data tečou" z listů ke kořenu (uzly představují operace s daty)
- někdy nutné logiku operátoru z velké části realizovat v operaci `open` (např. řazení)

Table scan jako iterátor

```
def open(R):
   B := prvni blok R
   T := prvni radek v bloku B
   Found := true

def getNext(R):
   If (T ukazuje za posledni radek v B):
      B := dalsi blok R
      If (dalsi blok neexistuje):
         Found := false
         Return None
      Else: // dalsi blok nacten
         T := prvni radek bloku B
   U := T
   T := posun na dalsi radek v bloku B
   return U

def close(R):
   pass
```

Typy operátorů

- široká paleta operátorů pro práci s daty
- liší se použitým stylem práce s daty
- počtem průchodů

dle typu práce s daty

- algoritmy využívající řazení (sorting-based)
- algoritmy využívají hash tabulky (hash-based)
- algoritmy využívají indexy (index-based)

dle počtu průchodů

- jednoprůchodové – vhodné pro operace σ, π nebo pokud se data vejdou do paměti
- dvouprůchodové – data jsou načtena, částečně zprácována a uložena zpět na disk, aby mohla být načtena transformována do finální podoby
- víceprůchodová – obvykle zobecnění dvouprůchodových algoritmů pro větší data

Jednoprůchodové operátory

1. unární operace postupně zpracovávající jednotlivé řádky
   - restrikce a projekce nevyžadují mít v paměti celou tabulku (neřeší se duplicity)
   - lze načítat jednotlivé bloky a v nich zpracovávat řádky (přímočará implementace)
   - vyžadují jeden paměťový buffer
   - náročnost operace dána čistě čtením dat

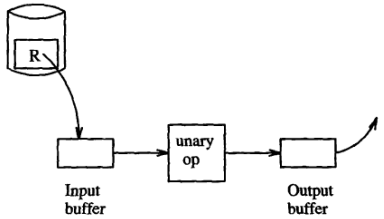

2. unární operace pracující s celou tabulkou
   - omezení na tabulky $B(R) \leq M$
   - operace seskupení/aggregace, eliminace duplicitních řádků
3. binární operace pracující s celou tabulkou
   - zbývající operace (množinové operace, spojení, ...)
   - vyžadují, aby velikost alespoň jednoho argumentu byla menší nebo rovna M

Eliminace duplicitních řádků

1. Načte se jeden řádek ze vstupu,
2. pokud se řádek na vstupu vyskytl poprvé zapíšeme jej na výstup a uložíme si tuto informaci,
3. pokračuje se dalším řádkem.

- jeden paměťový buffer potřebujeme pro načtení vstupu, $M - 1$ bufferů můžeme využít pro evidenci zpracovaných řádků
- vhodná datová struktura? (hash tabulka, vyvážený vyhledávací strom)
- tyto struktury mají svou režii (můžeme zanedbat)
- pro velikost by mělo platit $B(\delta(R)) < M$, jinak hrozí thrashing

Eliminace duplicitních řádků

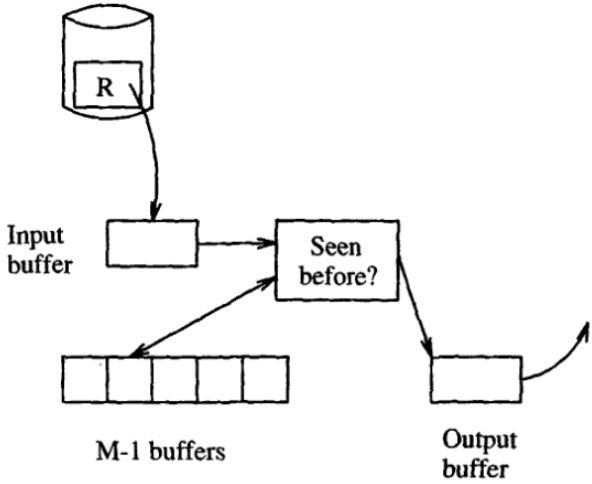

Seskupení

- parametr L operace γ_L udává žádný, jeden nebo více atributů, dle kterých má dojít k seskupení
- pro každou skupinu řádků evidujeme v paměti jeden záznam, tj. hodnoty atributů + průběžné hodnoty jednotlivých agregačních funkcí (např. počet hodnot, minimální/maximální hodnotu, ...)
- nelze zapsat data na výstup, dokud nejsou zpracovány všechny řádky vstupu
- nezapadá do konceptu iterátorů
- není snadné určit velikost dat v paměťovém bufferu

Binární operace (1/4)

- s výjimkou sjednocení multimnožin je nutné načíst menší operand do paměti
- tj. $\min(B(R), B(S)) \leq M$, I/O operace: $B(R) + B(S)$
- v popisu operací budeme předpokládat, že $B(R) > B(S)$

Sjednocením množin

- do $M - 1$ paměťových bufferů se načte S a vytvoří se vhodná vyhledávací datová struktura (kde klíčem jsou celé řádky)
- obsah S je zapsán na výstup
- do zbývajícího bufferu se postupně načítají jednotlivé bloky R
- pro každý řádek v R se ověří, zda je v S, a pokud ne, je zapsán do výstupního bufferu

Sjednocením multimnožin

- lze spočítat prostým překopírováním operandů na výstup
- postačuje $M = 1$

Binární operace (2/4)

Průnik množin

- do $M - 1$ paměťových bufferů se načte S a vytvoří se vhodná vyhledávací datová struktura (kde klíčem jsou celé řádky)
- do zbývajícího bufferu se postupně načítají jednotlivé bloky R
- pro každý řádek v R se ověří, zda je v S, a pokud ano, je zapsán do výstupního bufferu

Průnik multimnožin

- do $M - 1$ uložíme unikátní řádky z S a počet jejich vyskytů
- do zbývajícího bufferu se postupně načítají jednotlivé bloky R
- pro každý řádek t z R buď
  - t není v S, v takovém případě jej ignorujeme,
  - t je v S a má kladný počet výskytů, pak jej zapíšeme do výstupního bufferu a snížíme počet výskytů o jedna,
  - t je v S a má 0 výskytů, a ignorujeme jej.

Binární operace (3/4)

Rozdíl množin

- nekomutativní operace
- (pro obě varianty) do $M - 1$ paměťových bufferů se načte S a vytvoří se vhodná vyhledávací datová struktura (kde klíčem jsou celé řádky)
- pro $R - S$: pro každý řádek v R se ověří, zda je v S, pokud ne, je uložen do výstupního bufferu, jinak je ignorován
- pro $S - R$: pro každý řádek v R se ověří, zda je v S, pokud ano, je z S odstraněn; po zpracování všech řádků je obsah bufferů s S překopírován do výstupníhu bufferu.

Rozdíl multimnožin

- (pro obě varianty) do $M - 1$ uložíme unikátní řádky z S a počet jejich vyskytů
- pro $S - R$: pro každý řádek v R v S se sníží počet výskytů o 1, po zpracování všech řádků jsou řádky s kladným počtem výskytů překopírovány právě tolikrát do výstupníhu bufferu.
- pro $R - S$: pro každý řádek R se ověří, zda je v S, pokud ne nebo je počet výskytů 0, je zapsán do výstupního bufferu. V opačném případě se počet výskytu sníží o 1.

Binární operace (4/4)

Kartézský součin

- není potřeba žádná vyhledávácí datová struktura
- do $M - 1$ paměťových bufferů se načte S
- pro každý řádek t z R se vytvoří spojení řádků z S s t a zapíše se do výstupního bufferu

Přirozené spojení

- do $M - 1$ paměťových bufferů se načte S, vytvoří se vhodná vyhledávací datová struktura (kde klíčem jsou společné atributy)
- pro každý řádek t z R se vyhledají spojitelné řádky (shodující se v hodnotách společných atributů) a spojení těchto řádků se zapíše do výstupního bufferu

Poznámka

Všechny obrázky:
Hector Garcia-Molina, Jeffrey D. Ullman, Jennifer Widom. Database System Implementation.