

29/1/2024 Úvod do databáz, skúškový test, max 60 bodov

1. Uvažujte databázu bez duplikátov a null hodnôt: $\text{capuje}(\text{Krcma}, \text{Alkohol})$, $\text{lubi}(\text{Pijan}, \text{Alkohol})$, $\text{navstivil}(\text{Idn}, \text{Pijan}, \text{Krcma})$, $\text{vypil}(\text{Idn}, \text{Alkohol}, \text{Mnozstvo})$.

Platí: $\text{Idn Pijan}, \text{Krcma}; \text{Idn}, \text{Alkohol} \rightarrow \text{Mnozstvo}; \text{Mnozstvo} > 0$.

a) Sformulujte bezpečný dotaz v Datalogu (6) a relačnej algebre (6) na dvojice $[P, K]$ také, že pijan P pri každej návšteve krčmy K vypil niektorý zo svojich obľúbených alkoholov. Predpokladajte, že P navštívil K aspoň raz.

Datalog:

```
answer(P, K) ←  
  navstivil(_, P, K),  
  not niekedy_nevypil(P, K).
```

```
niekedy_nevypil(P, K) ←  
  navstivil(I, P, K),  
  not vypil_oblubeny(I).
```

```
vypil_oblubeny(I) ←  
  vypil(I, A, _),  
  lubi(P, A).
```

Relačná algebra:

```
vypil_oblubeny =  $\pi_{\text{Idn}}$  (vypil  $\bowtie$  lubi);  
niekedy_nevypil =  $\pi_{\text{Pijan}, \text{Krcma}}$  (navstivil  $\triangleright$  vypil_oblubeny);  
/* answer */
```

```
 $\pi_{\text{Pijan}, \text{Krcma}}$  (navstivil)  $\triangleright$  niekedy_nevypil;
```

b) Sformulujte bezpečný dotaz v Datalogu (6) a SQL (6) na štvorice $[P, K, C, T]$, kde C je počet druhov alkoholov a T je celkové množstvo alkoholov, ktoré pijan P ľúbi a vypil ich v krčme K. Výsledok nemá obsahovať štvorice s $C = T = 0$.

Datalog:

```
answer(P, K, C, T) ←  
  subtotal(pocet(P, K, A), [P, K], [C = count(A)]),  
  subtotal(mnozstvo(_, P, K, M), [P, K], [T = sum(M)]).
```

```
pocet(P, K, A) ←  
  lubi(P, A),  
  navstivil(I, P, K),  
  vypil(I, A, _).
```

```
mnozstvo(I, P, K, M) ←  
  lubi(P, A),  
  navstivil(I, P, K),  
  vypil(I, A, M).
```

SQL:

```
select n.Pijan, n.Krcma, count(distinct v.Alkohol) as C, sum(v.Mnozstvo) as T  
from lubi l, navstivil n, vypil v  
where l.Pijan = n.Pijan and l.Alkohol = v.Alkohol and n.Idn = v.Idn  
group by n.Pijan, n.Krcma
```

2. Uvažujte relačnú schému $r(A, B, C, D, E, F)$ s funkčnými závislosťami
 $AB \rightarrow CDF$, $ACF \rightarrow B$, $AE \rightarrow B$, $CD \rightarrow ABF$, $CE \rightarrow D$, $CEF \rightarrow ABD$.

a) Dekomponujte r do tretej normálnej formy, bezstratovo a so zachovaním všetkých funkčných závislostí.
(6)

Nájdime nejaké minimálne pokrytie vstupnej množiny funkčných závislostí.

Kánonické funkčné závislosti:

$AB \rightarrow C$, $AB \rightarrow D$, $AB \rightarrow F$, $ACF \rightarrow B$, $AE \rightarrow B$, $CD \rightarrow A$, $CD \rightarrow B$, $CD \rightarrow F$, $CE \rightarrow D$, $CEF \rightarrow A$,
 $CEF \rightarrow B$, $CEF \rightarrow D$

Po minimalizácii ľavých strán funkčných závislostí:

$AB \rightarrow C$, $AB \rightarrow D$, $AB \rightarrow F$, $ACF \rightarrow B$, $AE \rightarrow B$, $CD \rightarrow A$, $CD \rightarrow B$, $CD \rightarrow F$, $CE \rightarrow D$, $CE \rightarrow A$,
 $CE \rightarrow B$, $CE \rightarrow D$

Po vynechaní redundantných funkčných závislostí:

$AB \rightarrow C$, $AB \rightarrow D$, $ACF \rightarrow B$, $AE \rightarrow B$, $CD \rightarrow A$, $CD \rightarrow F$, $CE \rightarrow D$

Toto je nejaké minimálne pokrytie.

Syntéza 3NF z tohto minimálneho pokrytia:

$r_1(A, B, C, D)$,

$r_2(A, B, C, F)$,

$r_3(A, B, E)$ /* ABE je nadkľúč v r */

$r_4(A, C, D, F)$,

$r_5(C, D, E)$

Táto dekompozícia je v 3NF, je bezstratová a zachováva všetky funkčné závislosti.

b) Dekomponujte r do Boyce-Coddovej normálnej formy, bezstratovo. Vyhnite sa zbytočnému rozbitiu funkčných závislostí. (6)

Začnime s 3NF dekompozíciou z úlohy a).

Všetky platné netriviálne funkčné závislosti v r majú aspoň 2 atribúty na ľavej strane.

Tým pádom r_3 a r_5 sú v BCNF,

V r_1 žiadna platná netriviálna funkčná závislosť s atribútmi AB na ľavej strane neohrozuje BCNF, lebo AB je nadkľúč v r_2 . Iné netriviálne funkčné závislosti v r_1 neplatia.

V r_2 je AB nadkľúč, a tiež ACF . Netriviálne funkčné závislosti s inými ľavými stranami v r_2 neplatia.

V r_4 je CD nadkľúč, a tiež ACF . Netriviálne funkčné závislosti s inými ľavými stranami v r_2 neplatia.

3NF dekompozícia z úlohy a) je zároveň v BCNF.

Alternatívna BCNF dekompozícia, bezstratová a zachováajúca všetky funkčné závislosti:

$r_1(A, B, E)$

$r_2(A, B, C, D, F)$ /* AB je kľúč v r_2 */

3. Uvažujte Datalogový program nad extenzionálnou reláciou $r(X, Y)$:


$\text{answer}(X, Y) \leftarrow r(X, Y), \text{not } q(X, Y).$

$q(X, Y) \leftarrow r(X, _), r(_, Y), \text{not } r(X, Y).$

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

a) Rozhodnite či výpočet dotazu $?- \text{answer}(1, Y)$ naivnou evaluáciou skončí pre ľubovoľné naplnenie relácie r . (6)

Graf závislostí IDB predikátov (predikátov, ktoré sú definované v programe):



Graf závislostí IDB predikátov neobsahuje cyklus s negovanou hranou. Tým pádom daný program je stratifikovateľný. Naivná evaluácia skončí pre akékoľvek naplnenie relácie r . (Stratum q je 1, stratum answer je 2.)

b) Zapište výpočet dotazu $?- \text{answer}(1, Y)$ naivnou evaluáciou v relačnej algebre, a vypočítajte výsledok dotazu pre reláciu

$r(X, Y) = \{[0, 0], [0, 1], [1, 1], [2, 2], [2, 0], [3, 0], [4, 5]\}$. (6)

$\text{answer} = \{ \};$

$q = \{ \};$

$\phi ($

$q = (\pi_{r1.X, r2.Y} (\rho_{r1} (r) \times \rho_{r2} (r)) - r) \cup (r \bowtie \rho_{q(Y, X)} (q));$

$\text{answer} = r \triangleright q;$

$);$

/ query */*

$\pi_Y (\sigma_{X=1} (\text{answer}));$

Tento výpočet sa dá optimalizovať tak, že pred cyklus sa predradí konštantná časť q ; a answer sa vypočíta raz, mimo cyklu:

$q = (\pi_{r1.X, r2.Y} (\rho_{r1} (r) \times \rho_{r2} (r)) - r);$

$\phi ($

$q = q \cup (r \bowtie \rho_{q(Y, X)} (q));$

$);$

$\text{answer} = r \triangleright q;$

/ query */*

$\pi_Y (\sigma_{X=1} (\text{answer}));$

Simulácia optimalizovaného výpočtu pre dané naplnenie r :

Po inicializácii:

$q = \{[0, 2], [0, 5], [1, 0], [1, 2], [1, 5], [2, 1], [2, 5], [3, 1], [3, 2], [3, 5], [4, 0], [4, 1], [4, 2]\}$

Po prvej iterácii ϕ :

$q = \{[0, 1], [0, 2], [0, 5], [1, 0], [1, 2], [1, 5], [2, 0], [2, 1], [2, 5], [3, 1], [3, 2], [3, 5], [4, 0], [4, 1], [4, 2]\}$

Po druhej iterácii ϕ :

$q = \{[0, 1], [0, 2], [0, 5], [1, 0], [1, 2], [1, 5], [2, 0], [2, 1], [2, 5], [3, 1], [3, 2], [3, 5], [4, 0], [4, 1], [4, 2]\}$

Po priradení do answer :

$\text{answer} = \{[0, 0], [1, 1], [2, 2], [3, 0], [4, 5]\}$

Po finálnej selekcii a projekcii dostávame **odpoveď na dotaz: $\{[1]\}$.**

4. Neutriedená relácia r je uložená na disku v B blokoch, všetky bloky sú maximálne naplnené. Bloky na disku sú rovnako veľké ako bloky v RAM. Na sekvenčné médium treba uložiť súbor s utriedenou reláciou r .

a) Vyjadrite ako funkciu B minimálny počet blokov, ktoré treba v RAM rezervovať pre externý merge-sort, aby celkový počet vstupno-výstupných diskových operácií nepresiahol $2B$. Vysvetlite. (6)

Keď sa v RAM rezervuje B blokov, tak sa do RAM zmestí celá relácia r . Každý blok r sa raz prečíta, a po utriedení v RAM (prvá fáza merge-sort) sa rovnaký počet blokov zapíše do výsledného behu. To je $2B$ vstupno-výstupných operácií.

S menšou RAM sa to v danom limite urobiť nedá, lebo po prvej fáze (s $2B$ vstupno-výstupnými operáciami) vzniknú aspoň dva behy, ktoré treba spojiť v druhej fáze. To znamená dodatočné vstupno-výstupné operácie.

Minimálny požadovaný počet blokov RAM je B .

b) Vyjadrite ako funkciu B minimálny počet blokov, ktoré treba v RAM rezervovať pre externý merge-sort, aby celkový počet vstupno-výstupných diskových operácií nepresiahol $4B$. Vysvetlite. (6)

So $4B$ vstupno-výstupnými diskovými operáciami si môžeme dovoliť okrem prvej fázy merge-sort aj druhú fázu. Druhá fáza smie bežať nanajvýš raz, lebo každé jej opakovanie znamená aspoň $2B$ operácií (každý beh treba načítať, a zapísať rovnaký počet blokov do výstupného behu resp. behov).

Ak R je veľkosť rezervovanej RAM, po prvej fáze sa vytvorí $\lceil B / R \rceil$ behov. Tento počet behov smie byť nanajvýš $R - 1$, lebo ich treba zlúčiť v jednej iterácii druhej fázy:

$$\lceil B / R \rceil \leq R - 1$$

Zanedbáme to zaokrúhlenie nahor:

$$B / R \leq R - 1$$

$$R(R - 1) - B \geq 0$$

Toto je kvadratická nerovnica s neznámou R . Jej prípustné riešenie je $R \geq 1/2 + \sqrt{1 + 4B} / 2$.

Zaujímá nás minimálne R , pri ktorom nastáva rovnosť. Keďže R má byť celé číslo, a keďže predtým sme optimisticky zanedbali zaokrúhlenie, zaokrúhlime R konzervatívne nahor:

$$R = 1 + \lceil \sqrt{1 + 4B} / 2 \rceil$$

Toto je veľkosť RAM, s ktorou externý merge-sort urobí nanajvýš $4B$ vstupno-výstupných operácií. Kvôli tým zaokrúhľováním môže byť možno o 1 blok väčšia než nutné minimum.