

1/2/2023 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: $\text{Idn} \rightarrow \text{Pijan}, \text{Krcma}$; $\text{Idn}, \text{Alkohol} \rightarrow \text{Mnozstvo}$; $\text{Mnozstvo} > 0$.

a) Sformulujte bezpečný dotaz v Datalogu **(6)** a relačnej algebre **(6)** na dvojice $[\text{K}, \text{A}]$ také, že krčma K čapuje alkohol A , a zároveň A bol pri každej návšteve krčmy K vypitý v množstve aspoň 5.

Datalog:

```
answer(K, A) ←  
    capuje(K, A),  
    not niekedy_malo(K, A).
```

```
niekedy_malo(K, A) ←  
    capuje(K, A),  
    navstivil(I, _, K),  
    not aspon5(I, A).
```

```
aspon5(I, A) ←  
    navstivil(I, _, _),  
    vypil(I, A, M),  
    M >= 5.
```

Relačná algebra:

```
aspon5 =  $\pi_{\text{Idn}, \text{Alkohol}} (\sigma_{\text{Mnozstvo} \geq 5} (\text{navstivil} \bowtie \text{vypil}))$   
niekedy_malo =  $\pi_{\text{Krcma}, \text{Alkohol}} ((\text{capuje} \bowtie \text{navstivil}) \ltimes \text{aspon5})$   
/* answer */  
capuje - niekedy_malo
```

b) Sformulujte bezpečný dotaz v Datalogu **(6)** a SQL **(6)** na trojice [K, A, C], kde C je počet pijanov, ktorí alkohol A ľúbia a vypili ho v krčme K v celkovom množstve aspoň 100. (Vo výsledku majú byť len trojice s $C > 0$.)

Datalog:

```
answer(K, A, C) ←  
    subtotal(lubi100(P, K, A), [K, A], [C = count(P)]).
```

```
lubi100(P, K, A) ←  
    lubi(P, A),  
    subtotal(v(⌊, P, K, A, M), [P, K, A], [S = sum(M)]),  
    S >= 100.
```

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

SQL:

```
with lubi100 as  
(  
    select l.Pijan, n.Krcma, v.Alkohol  
    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, v.Alkohol  
    having sum(v.Mnozstvo) >= 100  
)  
select l100.Krcma as K, l100.Alkohol as A, count(distinct l100.Pijan) as P  
from lubi100 l100  
group by l100.Krcma, l100.Alkohol
```

2. Uvažujte relačnú schému s atribútmi $A_1, \dots, A_N$.

a) Rozhodnite či platí

„Ak $\exists i \exists j \ 1 \leq i \leq N \wedge 1 \leq j \leq N \wedge i \neq j \wedge \{A_1, \dots, A_N\} - \{A_i\} - \{A_j\} \rightarrow \{A_j\}$, tak daná relačná schéma nie je v Boyce-Coddovej normálnej forme.“

Ak ÁNO, dokažte. Ak NIE, uveďte definíciu BCNF a vysvetlite rozpor na konkrétnom príklade. (6)

NIE. Toto neplatí.

Uvažujme relačnú schému s atribútmi A_1, A_2, A_3 , s množinou funkčných závislostí $A_1 \rightarrow A_2, A_1 \rightarrow A_3$. Platí (pre $i=2, j=3$), že $\{A_1, A_2, A_3\} - \{A_2\} - \{A_3\} \rightarrow \{A_3\}$ (keďže $A_1 \rightarrow A_3$). Zároveň táto schéma je v BCNF (jediné platné netriviálne funkčné závislosti sú tie uvedené dve, A_1 je kľúč).

b) Uvažujte množiny funkčných závislostí C, S nad atribútmi $A_1, \dots, A_N$. Definujte čo znamená, že C pokrýva S ; a rozhodnite či existuje algoritmus s polynomiálnou časovou zložitou, ktorý rozhodne, či C pokrýva S . Ak NIE, zdôvodnite. Ak ÁNO, popíšte ten algoritmus (napíšte pseudokód a zdôvodnite jeho časovú zložitost'). (6)

Definícia. Množina funkčných závislostí C pokrýva množinu funkčných závislostí S , ak $C^+ \supseteq S^+$ (kde M^+ označuje uzáver množiny funkčných závislostí M).

Množiny C^+ a S^+ v tejto definícii môžu byť exponenciálne veľké vzhľadom na veľkosť C a S . Napriek tomu je možné testovať pokrytie v polynomiálnom čase, t.j. odpoveď je **ÁNO**.

Algoritmus:

Vstup: $A_1, \dots, A_N, C, S$.

for (funkčná závislosť z S tvaru $X \rightarrow Y$)

 if (not $Y \subseteq X^{C^+}$)

 výstup „C nepokrýva S“;

výstup „C pokrýva S“;

V tomto algoritme X^{C^+} označuje uzáver množiny atribútov X vzhľadom na množinu funkčných závislostí C . Uzáver množiny atribútov je možné vypočítať v polynomiálnom čase. Pre každú funkčnú závislosť z S stačí raz vypočítať uzáver ľavej strany a porovnať s pravou stranou. Tým pádom má uvedený algoritmus polynomiálnu časovú zložitost' (vzhľadom na veľkosť C a S).

3. Uvažujte Datalogový program nad extenzionálnou databázou $\{e(., .)\}$:

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

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

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

a) Zapište výpočet dotazu $? q(X, Y, 2)$ v relačnej algebre. (6)

Naivná evaluácia:

/ inicializácia */*

$p(X, Y) = \{\};$

$q(X, Y, Z) = \{\};$

/ fixpoint */*

$\phi($

$p = e \cup \pi_{p1.X, p2.Y} (\rho_{p1} (p) \bowtie_{p1.Y = p2.X} \rho_{p2} (p));$

$q = \pi_{p1.X, p3.Y, p1.Y} ((\rho_{p1} (p) \bowtie_{p1.Y = p2.X \wedge p2.X = p2.Y} \rho_{p2} (p)) \bowtie_{p2.X = p3.X} \rho_{p3} (p));$

$);$

/ answer */*

$\pi_{X, Y} (\sigma_{Z=2} (q))$

b) Vypočítajte výsledok dotazu z úlohy a) pre reláciu
 $e(., .) = \{[0, 1], [1, 3], [2, 4], [3, 5], [4, 2], [5, 4]\}$. (6)

Výpočet uvedený v a) budeme trošku optimalizovať. Keďže p závisí len od p , a tiež q závisí len od p , môžeme najskôr vypočítať celú reláciu p a následne celú reláciu q :

```
/* inicializácia */
p(X, Y) = {};
q(X, Y, Z) = {};
/* fixpoint */
phi(
  p = e ∪ πp1.X, p2.Y (ρp1 (p) ⋈p1.Y = p2.X ρp2 (p));
);
q = πp1.X, p3.Y, p1.Y ((ρp1 (p) ⋈p1.Y = p2.X ∧ p2.X = p2.Y ρp2 (p)) ⋈p2.X = p3.X ρp3 (p));
/* answer */
πX, Y (σZ=2 (q))
```

Po inicializácii:

```
p(X, Y) = {};
q(X, Y, Z) = {};
```

Po 1. iterácii ϕ :

```
p = {[0, 1], [1, 3], [2, 4], [3, 5], [4, 2], [5, 4]}
```

Po 2. iterácii ϕ :

```
p = {[0, 1], [0, 3], [1, 3], [1, 5], [2, 2], [2, 4], [3, 4], [3, 5], [4, 2], [4, 4], [5, 2], [5, 4]}
```

Po 3. iterácii ϕ :

```
p = {[0, 1], [0, 3], [0, 4], [0, 5], [1, 2], [1, 3], [1, 4], [1, 5], [2, 2], [2, 4], [3, 2], [3, 4], [3, 5], [4, 2], [4, 4], [5, 2], [5, 4]}
```

Po 4. iterácii ϕ :

```
p = {[0, 1], [0, 2], [0, 3], [0, 4], [0, 5], [1, 2], [1, 3], [1, 4], [1, 5], [2, 2], [2, 4], [3, 2], [3, 4], [3, 5], [4, 2], [4, 4], [5, 2], [5, 4]}
```

Po 5. iterácii ϕ :

```
p = {[0, 1], [0, 2], [0, 3], [0, 4], [0, 5], [1, 2], [1, 3], [1, 4], [1, 5], [2, 2], [2, 4], [3, 2], [3, 4], [3, 5], [4, 2], [4, 4], [5, 2], [5, 4]}
```

Po výpočte $q(X, Y, Z)$:

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

Po finálnej selekcii a projekcii:

```
/* answer */
.(X, Y) = {[0, 2], [0, 4], [1, 2], [1, 4], [2, 2], [2, 4], [3, 2], [3, 4], [4, 2], [4, 4], [5, 2], [5, 4]}
```

4.

a) Vysvetlite validačnú metódu pre izoláciu transakcií, ktorá validáciu aj zápisy transakcie robí súčasne, v jednom atomickom kroku. (6)

Scheduler používajúci validačnú metódu, kde validácia prebehne súčasne so všetkými zápsmi transakcie, udržiava pre každú začatú transakciu T množinu identifikátorov objektov $RS(T)$ (objekty, ktoré T čítala), množinu identifikátorov objektov $WS(T)$ (objekty, ktoré T aktualizovala), privátnu kópiu objektov, ktoré T aktualizuje, a niekoľko časových pečiatok.

Po prečítaní operácie s_T prideli transakcii T časovú pečiatku $TS(T)$.

Operácie $r_T(D)$ a $w_T(D)$ vykonáva v takom poradí, ako prichádzajú (hneď ako ich prečíta). Zápisy robí do privátnej kópie objektu D prislúchajúcom transakcii T, nie do databázy. Pri čítaní preferuje privátnu kópiu objektu D, ak existuje; inak číta hodnotu z databázy.

Po prečítaní operácie a_i zahodí všetky údaje o transakcii T.

Po prečítaní operácie c_T prideli T časovú pečiatku $TVAL(T)$ a otestuje validačnú podmienku. Ak validačná podmienka nie je splnená, tak abortuje T (tak, ako po prečítaní operácie a_T). Inak zapíše privátnu kópiu všetkých objektov modifikovaných transakciou T do databázy, zapíše do logu commit T a zahodí všetky údaje o T.

Validačná podmienka pre transakciu T je (všetky časové pečiatky, ktoré neboli pridelené, majú hodnotu ∞):

$\neg (\exists T2 \ TS(T) < TVAL(T2) < TVAL(T) \wedge WS(T2) \cap RS(T) \neq \emptyset)$.

Transakcie sú commitované v poradí, v ktorom sa validujú. Vďaka atomickosti validácie a finalizácie sa write-write konfliktami netreba zapodievať. Uvedená validačná podmienka (možno sa dá zoslabiť) zaručuje, aby v prípade write-read konfliktov validovaná transakcia čítala len hodnoty objektov zapísané (sebou, alebo) poslednou commitovanou transakciou.

b) Uvažujte systém s validačnou metódou z úlohy a). Do systému vstupuje rozvrh (v systéme sú len tieto dve transakcie)

$s2, r2(Z), s1, r1(X), w2(Y), r1(Y), r2(X), w1(X), c1, w2(Z), c2$.

Po každej prečítanej operácii popíšte akciu, ktorú scheduler vykoná. Uveďte výstupný rozvrh. (6)

$s2$ prideli časovú pečiatku $TS(T2)$

$r2(Z)$ prečíta hodnotu Z z databázy pre T2, pridá Z do $RS(T2)$

$s1$ prideli časovú pečiatku $TS(T1)$

$r1(X)$ prečíta hodnotu X z databázy pre T1, pridá X do $RS(T1)$

$w2(Y)$ zapíše novú hodnotu Y do privátnej kópie T2, pridá Y do $WS(T2)$

$r1(Y)$ prečíta hodnotu Y z databázy pre T1, pridá Y do $RS(T1)$

$r2(X)$ prečíta hodnotu X z databázy pre T2, pridá X do $RS(T2)$

$w1(X)$ zapíše novú hodnotu X do privátnej kópie T1, pridá X do $WS(T1)$

$c1$ otestuje validačnú podmienku pre T1; keďže je splnená, zapíše objekty z $WS(T1)$ z privátnej kópie T1 do databázy, commituje T1 a zruší všetky údaje o T1

$w2(Z)$ zapíše novú hodnotu Z do privátnej kópie T2, pridá Z do $WS(T2)$

$c2$ otestuje validačnú podmienku pre T2; keďže nie je splnená, abortuje T2 a zruší všetky údaje o T2

Výstupný rozvrh:

$s2, r2(Z), s1, r1(X), r1(Y), r2(X), w1(X), c1, a2$