

7/1/2015 Úvod do databáz, skúškový test, max 25 bodov, 90 min

1. Daná je databáza (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) Nájdite trojice $[P, A1, A2]$ také, že pijan P ľubi oba alkoholy $A1, A2$; a zároveň pri každej návšteve krčmy vypil práve jeden z týchto alkoholov. (Trojice s $A1=A2$ nemajú byť vo výsledku.) Sformulujte tento dotaz v Datalogu (2) a v relačnom kalkule (2).

Datalog:

```
answer(P, A1, A2) ←  
  lubi(P, A1),  
  lubi(P, A2),  
  not A1 = A2,  
  not vypil_zle(P, A1, A2).
```

```
vypil_zle(P, A1, A2) ←  
  navstivil(I, P, _),  
  vypil(I, A1, _),  
  vypil(I, A2, _).
```

```
vypil_zle(P, A1, A2) ←  
  navstivil(I, P, _),  
  lubi(P, A1),      /* safety */  
  lubi(P, A2),      /* safety */  
  not v(I, A1),  
  not v(I, A2).
```

```
v(I, A) ←  
  vypil(I, A, _).
```

Podmienka $A1 \neq A2$ v prvom pravidle ošetruje prípad, keď pijan P nenavštívil žiadnu krčmu. Ak pijan P nenavštívil žiadnu krčmu, chceme aby $\text{answer}(P, A1, A2)$ platil len pre dvojice rôznych alkoholov $A1$ a $A2$, ktoré ten pijan ľubi.

Relačný kalkul:

{[P, A1, A2]:

lubi(P, A1) \wedge lubi(P, A2) \wedge (A1 \neq A2) \wedge

\neg /* vypil_zle(P, A1, A2) */

(

(

$\exists I \exists K \exists M1 \exists M2$

navstivil(I, P, K) \wedge vypil(I, A1, M1) \wedge vypil(I, A2, M2)

)

\vee

(

$\exists I \exists K$

navstivil(I, P, K) \wedge

\neg /* v(I, A1) */

(

$\exists M$

vypil(I, A1, M)

)

\wedge

\neg /* v(I, A2) */

(

$\exists M$

vypil(I, A2, M)

)

)

)

}

b) Nájdite dvojice [K, A] pre ktoré platí: krčmu K, ktorá čapuje alkohol A, navštívilo aspoň 200 (rôznych) pijanov; a zároveň sa alkohol A v krčme K vypil v celkovom množstve najviac 10. Sformulujte tento dotaz v Datalogu (2) a SQL (2).

Datalog:

```
answer(K, A) ←  
  aspon200p(K),  
  najviac10v(K, A).
```

```
aspon200p(K) ←  
  subtotal(n(K, P), [K], [C = count(P)]),  
  C >= 200.
```

```
n(K, P) ←  
  navstivil(_, P, K).
```

```
najviac10v(K, A) ←  
  subtotal(nv(_, K, A, M), [K, A], [S = sum(M)]),  
  M <= 10.
```

/ A sa v K nikdy nevypil */*

```
najviac10v(K, A) ←  
  capuje(K, A),  
  not nv2(K, A).
```

```
nv(I, K, A, M) ←  
  navstivil(I, _, K),  
  vypil(I, A, M).
```

```
nv2(K, A) ←  
  v(_, K, A, _).
```

Alebo:

```
answer(K, A) ←  
  aspon200p(K),  
  capuje(K, A), /* safety */  
  not viac10v(K, A).
```

```
aspon200p(K) ←  
  subtotal(n(K, P), [K], [C = count(P)]),  
  C >= 200.
```

```
n(K, P) ←  
  navstivil(_, P, K).
```

```
viac10v(K, A) ←  
  subtotal(nv(_, K, A, M), [K, A], [S = sum(M)]),  
  M > 10.
```

```
nv(I, K, A, M) ←  
  navstivil(I, _, K),  
  vypil(I, A, M).
```

SQL:

```
create temporary table aspon200p as
select n.Krcma
from navstivil n
group by n.Krcma
having count(distinct n.Pijan) >= 200
```

```
create temporary table navstivil_vypil as
select n.Idn, n.Krcma, v.Alkohol, v.Mnozstvo /* Idn sa dá vynechat' */
from navstivil n, vypil v
where n.Idn = v.Idn
```

```
create temporary table najviac10v as
(select nv.Krcma, nv.Alkohol
from navstivil_vypil nv
group by nv.Krcma, nv.Alkohol
having sum(nv.Mnozstvo) <= 10
)
union
(select c.Krcma, c.Alkohol
from capuje c
where not exists (
    select *
    from navstivil_vypil nv
    where nv.Krcma = c.Krcma and nv.Alkohol = c.Alkohol)
)
```

```
/* answer */
select v10.Krcma, v10.Alkohol
from aspon200p p200, najviac10v v10
where p200.Krcma = v10.Krcma
```

Alebo:

```
create temporary table aspon200p as
select n.Krcma
from navstivil n
group by n.Krcma
having count(distinct n.Pijan) >= 200
```

```
create temporary table viac10v as
select nv.Krcma, nv.Alkohol
from navstivil_vypil nv
group by nv.Krcma, nv.Alkohol
having sum(nv.Mnozstvo) > 10
```

```
/* answer */
select p200.Krcma, c.Alkohol
from aspon200p p200, capuje c
where p200.Krcma = v10.Krcma and not exists (
    select *
    from viac10v v10
    where c.Krcma = p200.Krcma and c.Alkohol = c.Alkohol)
```

2. a) Uved'te definíciu minimálneho pokrytia množiny funkčných závislostí. (Pojem pokrytia množiny funkčných závislostí nemusíte definovať, ten môžete použiť.) (2)

Minimálne pokrytie množiny funkčných závislostí F je také pokrytie G , že G obsahuje len kánonické funkčné závislosti (s 1 atribútom na pravej strane); a zároveň po vynechaní ľubovoľného atribútu z ľavej strany ľubovoľnej funkčnej závislosti z G množina G prestane byť pokrytím F ; a zároveň po vynechaní ľubovoľnej funkčnej závislosti z G množina G prestane byť pokrytím F .

b) Algoritmus dekompozície relačnej schémy $[r, F]$ do tretej normálnej formy obsahuje krok „Ak žiadna z relácií dekompozície r_1, \dots, r_N neobsahuje kľúč relácie r , tak pridaj k dekompozícii r_1, \dots, r_N reláciu s nejakým kľúčom relácie r “. Napíšte algoritmy (stačí pseudokód, resp. ideu) s polynomiálnou časovou zložitou, ktoré tento krok realizujú. (Treba vyriešiť dva problémy: 1.testovanie tej podmienky; 2.nájdenie nejakého kľúča relácie r .) (2)

1.Test, či niektorá z relácií r_1, \dots, r_N obsahuje nejaký kľúč:

for ($i=1; i < N; i++$)

```
{
    if ( $\{r_i\}^+ = r$ ) /* počíta sa uzáver atribútov */
        return TRUE; /* výpočet ďalej nepokračuje */
}
```

return FALSE;

2.Nájdenie nejakého kľúča relácie r :

Minimalizuj ľavú stranu (platnej) funkčnej závislosti $A_1 \dots A_m \rightarrow A_1 \dots A_m$ (kde A_1, \dots, A_m sú všetky atribúty r) vzhľadom na množinu funkčných závislostí $F \cup A_1 \dots A_m \rightarrow A_1 \dots A_m$, tak ako v druhom kroku algoritmu pre konštrukciu (nejakého) minimálneho pokrytia F . Na poradí odstraňovania atribútov nezáleží. Minimalizovaná ľavá strana je (nejakým) kľúčom relácie r .

Výpočet uzáveru atribútov a minimalizácia ľavej strany funkčnej závislosti sú algoritmy s polynomiálnou časovou zložitou.

c) Existuje algoritmus, ktorý ľubovoľnú relačnú schému dekomponuje do Boyce-Coddovej normálnej formy tak, že výsledná dekompozícia je bezstratová (spája sa bezstratovo) a zachováva všetky funkčné závislosti? Svoju odpoveď ÁNO resp. NIE zdôvodnite. (2)

Taký algoritmus (bohužiaľ) neexistuje, lebo v niektorých prípadoch neexistuje ani dekompozícia, ktorá spĺňa tieto požiadavky. Napríklad, relačná schéma $[r(A, B, C), \{AB \rightarrow C; C \rightarrow A\}]$ nie je v BCNF kvôli funkčnej závislosti $C \rightarrow A$ (C nie je nadkľúč r). Akákoľvek dekompozícia zlomí funkčnú závislosť $AB \rightarrow C$.

d) Aký negatívny dôsledok má v databázovej aplikácii použitie dekompozície, ktorá láme (t.j. nezachováva) niektoré funkčné závislosti? (2)

Zlomenie funkčnej závislosti komplikuje automatickú kontrolu konzistencie databázy pri aktualizácii. Integritnú podmienku (constraint) zodpovedajúcu zlomenej funkčnej závislosti nie je možné vyjadriť lokálne v rámci jednej relácie (pri *create table*).

3. Daný je datalogový program

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

$s(X, Y) \leftarrow c(X, Y), \text{not } q(X, Y).$

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

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

a) Zapište výpočet dotazu $?- s(X, Y)$ pre daný program v relačnej algebre. (2)

Univerzálnou metódou výpočtu datalogového programu je (semi-) naivná evaluácia. Ale čiastočné pochopenie programu môže výpočet uľahčiť. Napríklad, druhé pravidlo pre s nevypočíta oproti prvému pravidlu žiadnu ďalšiu dvojicu $[X, Y]$. To prvé pravidlo je všeobecnejšie, o čom sa dá presvedčiť tak, že za prvú anonymnú premennú dosadíme Y a za druhú dosadíme X . Teda druhé pravidlo môžeme ignorovať a uvažovať program

$r1: s(X, Y) \leftarrow c(X, _), c(_, Y), \text{not } q(X, Y).$

$r2: q(X, Y) \leftarrow c(X, _), c(_, Y), \text{not } c(X, Y).$

$r3: q(X, Y) \leftarrow c(X, Y), q(Y, X).$

Idea plánu výpočtu: raz aplikovať $r2$ (telo pravidla $r2$ neobsahuje žiadne intenzionálne predikáty); potom iterovať $r3$ kým do relácie q pribúdajú nové dvojice; potom raz aplikovať pravidlo $r1$.

V relačnej algebre (postupnosť priradení):

$q := (\pi_X(c) \times \pi_Y(c)) - c$

$\emptyset(q := q \cup (c \bowtie P_{q(Y, X)}(q(X, Y))))$ /* iteruj, kým sa q mení */

$s := (\pi_X(c) \times \pi_Y(c)) - q$ /* relácia s obsahuje výsledok dotazu */

Pre daný program stačí jedna iterácia \emptyset pre výpočet výslednej relácie (to platí pre ľubovoľné naplnenie extenzionálnej relácie c), čo umožňuje ďalšiu optimalizáciu výpočtu. Taktiež výsledok spoločného podvýrazu $\pi_X(c) \times \pi_Y(c)$ stačí vypočítať len raz. Ďalej, do výsledku joinu pri výpočte q podľa pravidla $r3$ netreba ukladať dvojice, ktoré boli vypočítané podľa pravidla $r2$ (podobne ako pri seminaiivnej evaluácii). Optimalizovaný plán:

$cxc := \pi_X(c) \times \pi_Y(c)$

$q := cxc - c$

$q := q \cup ((c \bowtie P_{q(Y, X)}(q(X, Y))) - q)$

$s := cxc - q$ /* relácia s obsahuje výsledok dotazu */

b) Vypočítajte výsledok dotazu $?- s(X, Y)$ pre daný program s extenzionálnu databázou

$c = \{[1, 1], [1, 2], [2, 2], [2, 3], [3, 1], [3, 3], [4, 1], [5, 6]\}$. (2)

V tele pravidla $r2$ nie sú žiadne intenzionálne predikáty, preto ho stačí vypočítať len raz:

$q := (\pi_X(c) \times \pi_Y(c)) - c$

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

Ďalej budeme iterovať pravidlo $r3$, kým do relácie q pribúdajú nové dvojice:

$\emptyset(q := q \cup (c \bowtie P_{q(Y, X)}(q(X, Y))))$ /* iteruj, kým sa q mení */

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

(v druhej iterácii už nepribudnú žiadne dvojice)

Pravidlo $r1$ stačí vypočítať raz:

$s := (\pi_X(c) \times \pi_Y(c)) - q$ /* relácia s obsahuje výsledok dotazu */

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

4. Uved'te príklad rozvrhu, v ktorom všetky transakcie končia commitom, a ktorý:

a) je konflikt-sériovateľný a nedá sa generovať dvojfázovým zamykaním; **(1)**

$w1(X), r2(X), r1(X), c1, c2$

Tento rozvrh je sériovateľný, konflikt-ekvivalentný sériovému rozvrhu $T1 \rightarrow T2$.

Pri dvojfázovom zamykaní (uvažujeme jednoduchú verziu 2PL) transakcia T1 nesmie odovzdať svoj write-lock na X až kým sa nevykoná $r1(X)$. Tým pádom nemôže T2 medzi $w1(X)$ a $r1(X)$ držať konfliktný zámok na X.

b) je striktný a nie je konflikt-sériovateľný; **(1)**

$r1(X), w2(X), r2(Y), w1(Y), c1, c2$

Tento rozvrh neobsahuje dirty read ani dirty write, takže je striktný.

Nie je však konflikt-sériovateľný kvôli poradiu konfliktov $r1(X) \rightarrow w2(X)$ a $r2(Y) \rightarrow w1(Y)$.

c) je striktný a je konflikt-sériovateľný a nie je view-sériovateľný; **(1)**

Taký rozvrh neexistuje, lebo každý konflikt-sériovateľný rozvrh je view-sériovateľný.

d) je konflikt-sériovateľný a je obnoviteľný a nevyhýba sa kaskádovým abortom. **(1)**

$w1(X), r2(X), c1, c2$

Tento rozvrh je konflikt-sériovateľný, konflikt-ekvivalentný sériovému rozvrhu $T1 \rightarrow T2$.

Nevyhýba sa kaskádovým abortom kvôli dirty read $w1(X) \rightarrow r2(X)$.

Obnoviteľný je, lebo poradie commitov $c1 \rightarrow c2$ je rovnaké ako poradie operácií v dirty read.

e) je view-sériovateľný a nie je konflikt-sériovateľný a nie je obnoviteľný. **(1)**

$w1(X), r2(X), w2(Y), w1(Y), w2(Y), c2, c1$

Tento rozvrh je view-sériovateľný, view-ekvivalentný sériovému rozvrhu $T1 \rightarrow T2$. Nie je konflikt-sériovateľný, kvôli cyklu v precedenčnom-grafe $T2 \rightarrow T1 \rightarrow T2$. Nie je obnoviteľný kvôli dirty read $w1(X) \rightarrow r2(X)$ a poradiu commitov $c2 \rightarrow c1$.

Zdôvodnite prečo Váš rozvrh má požadované vlastnosti.