

18/1/2018 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 relačnom kalkule (6) a Datalogu (6) na dvojice  $[P, K]$  také, že pijan P počas niektorej návštevy krčmy K vypil všetky svoje obľúbené alkoholy.

Relačný kalkul:

$\{[P, K]:$

```
    ∃I
    navstivil(I, P, K) ∧
    ¬
    (
        ∃A
        lubi(P, A) ∧
        ¬
        (
            ∃M
            vypil(I, A, M)
        )
    )
}
```

Datalog:

```
answer(P, K) ←
    navstivil(I, P, K),
    not lubi_nevypil(P, I).
```

```
lub_i_nevypil(P, I) ←
    navstivil(I, P, _),
    lubi(P, A),
    not v(I, A).
```

```
v(I, A) ←
    vypil(I, A, _).
```

b) Sformulujte bezpečný dotaz v Datalogu (6) a SQL (6) na krčmy K také, že viacej než polovica pijanov, ktorí K navštívili, v K nikdy nič nevpila.

Datalog:

```
answer(K) ←  
    subtotal(navstevnici(P, K), [K], TN = count(P)),  
    subtotal(pijani(P, K), [K], TP = count(P)),  
    2 * TP < TN. /* TP2 is 2 * TP, TP2 < TN */
```

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

```
pijani(P, K) ←  
    navstivil(I, P, K),  
    vypil(I, _, _).
```

SQL:

```
with  
navstevnici as (  
    select n.Krcma, count(distinct n.Pijan) as TN  
    from navstivil n  
    group by n.Krcma  
)
```

```
pijani as (  
    select n.Krcma, count(distinct n.Pijan) as TP  
    from navstivil n, vypil v  
    where n.Idn = v.Idn  
    group by n.Krcma  
)
```

```
select n.Krcma  
from navstevnici n, pijani p  
where n.Krcma = p.Krcma and 2 * p.TP < n.TN
```

2. SQL príkaz *create assertion* definuje integritné obmedzenie na databázu. Systém dovolí aktualizáciu databázy len keď sa podmienka v klauze *check* vyhodnotí po aktualizácii ako *true* (vyhodnocuje sa rovnako ako podmienka v klauze *where* príkazu *select*); inak abortuje transakciu, ktorá tú aktualizáciu robí. Napríklad, integritné obmedzenie  $Mnozstvo > 0$  pre databázu z úlohy 1 sa vyjadří takto:

```
create assertion asrt_mn_positive check (  
not exists (select * from vypil v where v.Mnozstvo <= 0))
```

a) Uvažujte databázu z úlohy 1. Vyjadrite funkčnú závislosť  $Idn, Alkohol \rightarrow Mnozstvo$  príkazom *create assertion*. (6)

```
create assertion asrt_fd_idn_a_m check (  
  not exists (  
    select *  
    from vypil v1, vypil v2  
    where v1.Idn = v2.Idn and v1.Alkohol = v2.Alkohol and v1.Mnozstvo <> v2.Mnozstvo  
  )  
)
```

b) Každá hodnota *Idn*, ktorá sa vyskytuje v relácii *vypil*, sa musí vyskytovať aj v relácii *navstivil*. Vyjadrite toto prirodzené integritné obmedzenie príkazom *create assertion*. (6)

```
create assertion asrt_foreign_key_idn (  
  not exists (  
    select *  
    from vypil v  
    where not exists (  
      select *  
      from navstivil n  
      where n.Idn = v.Idn  
    )  
  )  
)
```

3. Uvažujte Datalogový program nad extenzionálnou databázou  $a(X)$ ,  $b(X, Y)$ ,  $c(X)$ :

$p(X) \leftarrow a(X), \neg r(X)$ .

$r(X) \leftarrow b(X, Y), \neg r(Y)$ .

$r(X) \leftarrow c(X)$ .

a) Zapište výpočet dotazu  $?- p(X)$  naivnou evaluáciou v relačnej algebre. (6)

Dôsledná naivná evaluácia:

$p = \{ \}$ ;

$r = \{ \}$ ;

$\varphi($

$p = a - r;$

$r = \pi_X (b \triangleright \rho_{r(Y)}(r)) \cup c;$

)

*Predikát  $r$  nie je závislý na predikáte  $p$ . Tým pádom je možné najskôr (iteratívne) vypočítať  $r$  a až následne  $p$ .*

*Optimalizovaná verzia:*

$r = \{ \}$ ;

$\varphi($

$r = \pi_X (b \triangleright \rho_{r(Y)}(r)) \cup c;$

)

$p = a - r;$

b) Okomentujte postup výpočtu dotazu  $?- p(X)$  naivnou evaluáciou pre databázu

$a(X) = \{1, 2, 3, 4\}$ ,  $b(X, Y) = \{[1, 2], [2, 3]\}$ ,  $c(X) = \{3\}$ .

Rozhodnite či výpočet skončí. Ak nie, vysvetlite prečo. Ak áno, uveďte výsledok dotazu. (6)

Počítajme podľa optimalizovanej verzie (ušetříme niekoľko priradení do relácie  $p$ , lebo zaujímavé je len to posledné):

Po prvom priradení je  $r$  prázdna relácia:

$r = \{ \}$

Po 1. iterácii  $\varphi$  obsahuje  $r$  všetky hodnoty  $b.X$  a  $c.X$ :

$r = \{1, 2, 3\}$

Po 2. iterácii  $\varphi$  obsahuje  $r$  všetky hodnoty  $b.X$  a  $c.X$ , okrem 1 a 2 (lebo  $b(1, 2)$  sa joinuje s  $r(2)$  a  $b(2, 3)$  sa joinuje s  $r(3)$ ):

$r = \{3\}$

Po 3. iterácii  $\varphi$  obsahuje  $r$  všetky hodnoty  $b.X$  a  $c.X$  okrem 2 (lebo  $b(2, 3)$  sa joinuje s  $r(3)$ ):

$r = \{1, 3\}$

Po 4. iterácii  $\varphi$  obsahuje  $r$  všetky hodnoty  $b.X$  a  $c.X$  okrem 2 (lebo  $b(2, 3)$  sa joinuje s  $r(3)$ ):

$r = \{1, 3\}$

Relácia  $r$  sa nezmenila, operátor  $\varphi$  dosiahol pevný bod.

Po finálnom priradení do relácie  $p$  obsahuje  $p$  všetky hodnoty  $z$  a, ktoré nie sú v  $r$ :

$p = \{2, 4\}$

**Výpočet dotazu  $?- p(X)$  skončí, výsledkom je  $\{2, 4\}$ .**

4. a) Dokážte, že scheduler používajúci dvojfázový zamykací protokol generuje len rozvrhy, ktoré sú konflikt-sériovateľné. (6)

Dôkaz (nepriamo). Uvažujme rozvrh, ktorý je generovaný 2PL schedulerom a ktorý nie je konflikt-sériovateľný. To znamená, že graf konfliktov transakcií pre tento (výstupný) rozvrh obsahuje nejaký cyklus  $T_1 \rightarrow T_2 \rightarrow \dots \rightarrow T_n \rightarrow T_1$ . Vrcholy uzlov resp. identifikátory príslušných (navzájom rôznych) transakcií v tom cykle sme bez ujmy na všeobecnosti označili  $T_1, \dots, T_n$ , kde  $n > 1$ . Každá z transakcií  $T_1, \dots, T_n$  je v tom rozvrhu commitovaná. Hrana  $T_i \rightarrow T_j$  je v grafe konfliktov práve vtedy, keď niektorá operácia  $T_i$  je v tom rozvrhu skôr než niektorá konfliktná operácia od  $T_j$ .

Z 2PL vyplýva (v 2PL transakcia pri čítaní/zápise dátového objektu drží príslušný zámok; a kým ho drží, nemôže iná transakcia vykonať konfliktnú operáciu na tom dátovom objekte), že transakcia  $T_2$  sa mohla dostať do konfliktu s  $T_1$  až po tom, čo  $T_1$  uvoľnila zámok na nejaký dátový objekt (ktorý predtým s prideleným zámkom čítala resp. zapisovala). Až po uvoľnení tohto zámku musela  $T_2$  ten zámok získať, aby čítaním resp. zápisom do rovnakého dátového objektu spôsobila konflikt.

Tvrdenie z predošlého odstavca platí aj pre dvojicu transakcií  $T_n$  a  $T_1$ .

To však znamená, že  $T_1$  musela nejaký zámok (pre ten objekt, ktorý spôsobil konflikt  $T_n \rightarrow T_1$ ) získať po tom, čo uvoľnila iný zámok (pre ten objekt, ktorý spôsobil konflikt  $T_1 \rightarrow T_2$ ). Toto je v spore s dvojfázovosťou schedulera (lebo 2PL scheduler nepridelí zámok transakcii po tom, čo tá transakcia nejaký zámok predtým uvoľnila).

b) Vysvetlite metódu wait-die na prevenciu deadlockov pri dvojfázovom zamykaní. Uvedte príklad striktného a konflikt-sériovateľného vstupného rozvrhu (doplneného o operácie read-lock, write-lock, unlock), na ktorom metóda wait-die zbytočne abortuje niektorú transakciu. Okomentujte akcie schedulera po prečítaní každej vstupnej operácie. (6)

Wait-die metóda spočíva v nasledujúcich rozšíreniach 2PL schedulera:

Každá transakcia  $T$  dostane pri vykonaní  $start_T$  časovú pečiatku  $TS(T)$ .

Keď transakcia  $T$  žiada o zámok (t.j. scheduler vykonáva  $read-lock_T$  alebo  $write-lock_T$ ), ktorý nemôže byť ihneď pridelený lebo je v konflikte so zámkom prideleným inej transakcii  $T_2$ , tak scheduler spustí nasledujúcu procedúru:

if ( $TS(T) < TS(T_2)$ )

... pozdrž vykonávanie  $T$ , kým sa príslušný zámok uvoľní;

else

abort  $T$ ;

Inak povedané, čakať na uvoľnenie zámku smie len transakcia, ktorá je staršia (začala skôr) než transakcia, ktorá ten zámok drží.

Príklad striktného a konflikt-sériovateľného vstupného rozvrhu, na ktorom wait-die zbytočne abortuje niektorú transakciu:

**$start_1, read-lock_1(X), read_1(X), start_2, write-lock_2(X), commit_1, write_2(X), commit_2$**

(Tento rozvrh je striktný, lebo neobsahuje dirty-read ani dirty-write. Je konflikt-sériovateľný, lebo je konflikt-ekvivalentný sériovému rozvrhu  $T_1 \rightarrow T_2$ .)

Pri čítaní tohto rozvrhu robí 2PL scheduler s wait-die toto:

$start_1$  prideliť  $TS(T_1)$  transakcii  $T_1$

$read-lock_1(X)$  prideliť read-lock na  $X$  transakcii  $T_1$

$read_1(X)$  prečíta  $X$  pre transakciu  $T_1$

$start_2$  prideliť  $TS(T_2)$  transakcii  $T_2$

$write-lock_2(X)$  zistí, že nemôže prideliť  $write-lock_2(X)$  kvôli už pridelenému  $read-lock_1(X)$ , porovná  $TS(T_1)$  a  $TS(T_2)$  a abortuje  $T_2$