

30/1/2014 Úvod do databáz, **skúškový** test, max 25 bodov, 90 min

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

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

a) Sformulujte nasledujúci dotaz v relačnom kalkule, (2), Datalogu (2), SQL (2) a relačnej algebre (2). Nájdite dvojice $[A, K]$ také, že alkohol A čapovaný v krčme K vypil (pri aspoň jednej návšteve) každý pijan, ktorý K niekedy navštívil.

Relačný kalkul:

```
{[A, K]:
  capuje(K, A) ∧ ¬ (
    /* navstivil_nevypil(K, A) */
    ∃I ∃P
    navstivil(I, P, K) ∧ ¬ (
      /* niekedy_vypil(P, K, A) */
      ∃I2 ∃M
      navstivil(I2, P, K) ∧ vypil(I2, A, M)
    )
  )
}
```

Datalog:

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

```
navstivil_nevypil(K, A) ←
  capuje(K, A), /* safety */
  navstivil(_, P, K),
  not niekedy_vypil(P, K, A).
```

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

SQL:

```
create temporary table niekedy_vypil as
select n.Pijan, n.Krcma, v.Alkohol
from navstivil n, vypil v
where n.Idn = v.Idn
```

```
create temporary table navstivil_nevypil as
select
from capuje c, navstivil n
where c.Krcma = n.Krcma and not exists (
  select *
  from niekedy_vypil nv
  where nv.Pijan = n.Pijan and nv.Krcma = c.Krcma and nv.Alkohol = c.Alkohol)
```

```
/* answer */
select c.Alkohol, c.Krcma
from capuje c
where not exists (
  select *
  from navstivil_nevypil nn
  where nn.Krcma = c.Krcma and nn.Alkohol = c.Alkohol)
```

Relačná algebra:

```
niekedy_vypil :=  $\pi_{Pijan, Krcma, Alkohol}(\text{navstivil} \bowtie \text{vypil})$ 
navstivil_nevypil :=  $\pi_{Krcma, Alkohol}(\pi_{Pijan, Krcma, Alkohol}(\text{capuje} \bowtie \text{navstivil}) - \text{niekedy\_vypil})$ 
answer :=  $\text{capuje} - \text{navstivil\_nevypil}$ 
```

b) Sformulujte nasledujúci dotaz v Datalogu (2) a SQL (2). Nájdite dvojice [P, K] také, že v krčme K pijan P vypil viacej druhov alkoholov než ktorýkoľvek iný pijan.

Datalog:

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

```
iny_majster(P, K) ←  
  subtotal(data(P, K, A), [P, K], [C = count(A)]).  
  subtotal(data(P2, K, A), [P2, K], [C2 = count(A)]).  
  C2 >= C,  
  not P = P2.
```

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

SQL:

```
create temporary table pocet_alkoholov as  
select n.Pijan, n.Krcma, count(distinct Alkohol) as C  
from navstivil n, vypil v  
where n.Idn = v.Idn  
group by n.Pijan, n.Krcma
```

```
/* answer */  
select pa1.Pijan, pa1.Krcma  
from pocet_alkoholov pa1  
where not exists (  
  select *  
  from pocet_alkoholov pa2  
  where pa1.Krcma = pa2.Krcma and pa1.Pijan <> pa2.Pijan and pa2.C >= pa1.C)
```

2. Daná je relácia $r(A, B, C, D, E, F, G)$ s funkčnými závislosťami
 $AB \rightarrow C, ACEF \rightarrow G, BC \rightarrow AD, D \rightarrow E, DE \rightarrow F, DF \rightarrow C, F \rightarrow DE, G \rightarrow F$.

a) Nájdite všetky kľúče relácie r . (1)

Atribút B je v každom kľúči, lebo nie je na pravej strane žiadnej funkčnej závislosti. Všetky kľúče nájdeme úplným prehľadávaním podmnožín $\{A, B, C, D, E, F, G\}$.

ABCDEFG

-A: BCDEFG

-C: BDEFG

-D: BEFG

-E: BFG

-F: BG

+F: BF

+E: BE

+D: BD

+C: BC

+A: AB

Kľúčmi v r sú **AB, BC, BD, BF, BG**. Iné kľúče nie sú.

b) Nájdite minimálne pokrytie funkčných závislostí. (1)

Po minimalizácii ľavých strán kánonických funkčných závislostí:

$AB \rightarrow C, AF \rightarrow G, BC \rightarrow A, BC \rightarrow D, D \rightarrow E, D \rightarrow F, D \rightarrow C, F \rightarrow D, F \rightarrow E, G \rightarrow F$

Po odstránení redundantných funkčných závislostí získavame jedno z minimálnych pokrytí:

$AB \rightarrow C, AF \rightarrow G, BC \rightarrow A, BC \rightarrow D, D \rightarrow F, D \rightarrow C, F \rightarrow D, F \rightarrow E, G \rightarrow F$

Iné minimálne pokrytia (možno sú aj ďalšie):

$AB \rightarrow C, AF \rightarrow G, BC \rightarrow A, BC \rightarrow D, D \rightarrow F, D \rightarrow C, F \rightarrow D, D \rightarrow E, G \rightarrow F$

$AB \rightarrow C, AF \rightarrow G, BC \rightarrow A, BC \rightarrow D, D \rightarrow E, D \rightarrow F, F \rightarrow C, F \rightarrow D, G \rightarrow F$

c) Dekomponujte r do tretej normálnej formy, bezstratovo a so zachovaním všetkých funkčných závislostí. (1)

3NF dekompozícia (z toho prvého minimálneho pokrytia):

$\{A, B, C\}, \{A, F, G\}, \{B, C, D\}, \{D, F\}, \{E, F\}$

Alebo (všetky atribúty vo funkčných závislostiach minimálneho pokrytia s rovnakou ľavou stranou môžeme dať do jednej relácie):

$\{A, B, C, D\}, \{A, F, G\}, \{D, E, F\}$

Alebo (všetky kľúčové atribúty môžeme dať do jednej relácie):

$\{A, B, C, D, F, G\}, \{B, E, F\}$

d) Dekomponujte r do Boyce-Coddovej normálnej formy, bezstratovo. Snažte sa vyhnúť zbytočnému rozbitiu funkčných závislostí. (2)

Začnime s 3NF dekompozíciou $\{A, B, C, D\}, \{A, F, G\}, \{D, E, F\}$.

V $\{A, F, G\}$ porušuje BCNF $G \rightarrow F$. V $\{A, B, C, D\}$ porušuje BCNF $D \rightarrow C$.

BCNF dekompozícia:

$\{A, B, D\}, \{A, G\}, \{C, D\}, \{D, E, F\}, \{F, G\}$

3. a) Definujte pojem zachovania funkčnej závislosti pri dekompozícii rel. schémy. (1)

Funkčná závislosť f je zachovaná v dekompozícii relačnej schémy (r, F) do

$(r_1, F_1), \dots, (r_N, F_N)$, ak f je dôsledkom zjednotenia funkčných závislostí $\cup_{i=1, \dots, N} F_i$, t.j. ak $f \in (\cup_{i=1, \dots, N} F_i)^+$, kde F_i označuje množinu funkčných závislostí, ktoré platia lokálne v r_i .

b) Vysvetlite, prečo je pri dekompozícii relačnej schémy rozumné zachovať funkčné závislosti. (1)

Funkčné závislosti je rozumné zachovať kvôli automatickej ochrane integrity (konzistencie) databázy.

Funkčná závislosť je integritné obmedzenie na databázu. Hoci norma SQL nepodporuje v DDL koncept funkčnej závislosti priamočiaro, funkčná závislosť sa dá v súčasných systémoch vyjadriť v podmienkach konštruktov CHECK, ASSERTION, TRIGGER a pod. Systém pri modifikácii databázy nedovolí integritu databázy porušiť (abortuje transakciu, ktorá sa o to pokúsi). Pri zachovaní funkčných závislostí je možné kontrolu robiť lokálne pre jednu reláciu. O čo lokálnejšia je kontrola, o to efektívnejšia môže byť.

c) Uvažujte relačnú schému z úlohy 2. Zapište funkčnú závislosť $BC \rightarrow AD$ ako formulu relačného kalkulu. (2)

$\forall B \forall C \forall A1 \forall D1 \forall E1 \forall F1 \forall G1 \forall A2 \forall D2 \forall E2 \forall F2 \forall G2$

$(r(A1, B, C, D1, E1, F1, G1) \wedge r(A2, B, C, D2, E2, F2, G2)) \Rightarrow (A1=A2 \wedge D1=D2)$

Ekvivalentne,

$\neg ($
 $\exists B \exists C \exists A1 \exists D1 \exists E1 \exists F1 \exists G1 \exists A2 \exists D2 \exists E2 \exists F2 \exists G2$
 $r(A1, B, C, D1, E1, F1, G1) \wedge r(A2, B, C, D2, E2, F2, G2) \wedge \neg (A1=A2 \wedge D1=D2)$
 $)$

V SQL sa dá táto funkčná závislosť vyjadriť napríklad takto:

```
create assertion r_fd_BC_AD
```

```
check not exists (
```

```
select *
```

```
from r r1, r r2
```

```
where r1.B = r2.B and r1.C = r2.C and not (r1.A = r2.A and r1.D = r2.D)
```

```
)
```

4. a) Definujte triedu konflikt-sériovateľných rozvrhov. (1)

Rozvrh je konflikt-sériovateľný, ak jeho projekcia na commitované transakcie je konflikt-ekvivalentná niektorému sériovému rozvrhu tých commitovaných transakcií.

Dva rozvrhy sú konflikt-ekvivalentné, ak (obsahujú rovnaké operácie a zároveň) relatívne poradie všetkých konfliktných dvojíc operácií je v oboch rozvrhoch rovnaké.

Dve operácie (uvažujeme len kombinácie read a write) v rozvrhu sú konfliktné, ak sa týkajú rôznych transakcií, rovnakého objektu, a aspoň jedna z tých dvoch operácií je write.

b) Uvažujte triedu rozvrhov alt-serialisable definovanú takto: Rozvrh R patrí do triedy alt-serialisable, ak po jeho vykonaní je stav databázy rovnaký ako po vykonaní niektorého sériového rozvrhu S, pričom (S obsahuje rovnaké transakcie ako R a zároveň) transakcie v S sú vzostupne usporiadané podľa relatívneho poradia (t.j. časovej následnosti) ich prvých operácií v R. Porovnajte triedu konflikt-sériovateľných rozvrhov s triedou alt-serialisable (v zmysle množinovej inklúzie). Zdôvodnite. (1)

Uvažujme rozvrh R1: w1(X), w2(X), w1(X), c1, c2. Tento rozvrh nie je konflikt-sériovateľný, avšak po jeho vykonaní je stav databázy rovnaký ako po vykonaní sériového rozvrhu T2→T1. Teda $R1 \in \text{alt-serialisable}$, avšak $R1 \notin \text{conflict-serialisable}$. Teda neplatí $\text{alt-serialisable} \subseteq \text{conflict-serialisable}$.

Uvažujme rozvrh R2: r1(X), w2(Y), w1(Y), c1, c2. Tento rozvrh je konflikt-sériovateľný, lebo je konflikt-ekvivalentný sériovému rozvrhu T2→T1. Avšak R2 nepatrí do triedy alt-serialisable, lebo R2 začína operáciou od T1 a po vykonaní sériového rozvrhu T1→T2 nie je stav databázy vo všeobecnosti rovnaký ako po vykonaní rozvrhu R2. Teda neplatí $\text{conflict-serialisable} \subseteq \text{alt-serialisable}$.

Triedy conflict-serialisable a alt-serialisable sú neporovnateľné.

c) Vysvetlite metódu časových pečiatok na implementáciu izolácie transakcií. (2)

Každá transakcia T dostane pri vykonaní svojej prvej operácie časovú pečiatku TS(T). Každý objekt X má 2 časové pečiatky, TS_R(X) a TS_W(X).

Keď T číta X, systém najskôr porovná TS(T) s TS_W(X). Ak $TS(T) < TS_W(X)$, tak systém abortuje T. Inak, ak $TS(T) > TS_R(X)$, tak TS_R(X) sa aktualizuje na hodnotu TS(T).

Keď T píše do X, systém najskôr porovná TS(T) s TS_W(X) aj s TS_R(X). Ak $TS(T) < TS_W(X)$ alebo $TS(T) < TS_R(X)$, tak systém abortuje T. Inak sa TS_W(X) sa aktualizuje na hodnotu TS(T).

Táto základná verzia metódy časových pečiatok generuje podtriedu konflikt-sériovateľných rozvrhov, ktorá sa dá rozšíriť opatrným zoslabením horeuvedených pravidiel (samozrejme, so zachovaním garancie izolácie transakcií).