


Relációs adatbázisok tervezése

3.rész (normálformák)



Ullman-Widom: Adatbázisrendszerek Alapvetés. Második, átdolgozott kiadás, Panem Kiadó, 2009

3.3. Relációs adatbázissémák tervezése
- Boyce-Codd normálforma (BCNF)
3.5. Harmadik normálforma (3NF)

(Jeffrey D. Ullman 2007 előadásdiái alapján, Benczúr András, Kiss Attila és Kósa Balázs előadásainak felhasználásával, Hajas Csilla)

Boyce-Codd normálforma

- ◆ R reláció *BCNF* normálformában van, ha minden $X \rightarrow Y$ nemtriviális FF-re R -ben X superkulcs.
 - ▶ *Nemtriviális*: Y nem része X -nek.
 - ▶ *Szuperkulcs*: tartalmaz kulcsot (ő maga is lehet kulcs).

Példa

Sörivók(név, cím, kedveltSörök, gyártó, kedvencSör)

FF-ek: név->cím kedvencSör, kedveltSörök->gyártó

- ◆ Itt egy kulcs van: {név, kedveltSörök}.
- ◆ A baloldalak egyik FF esetén sem szuperkulcsok.
- ◆ Emiatt az *Sörivók* reláció nincs BCNF normálformában.

Még egy példa

Sörök(név, gyártó, gyártóCím)

FF-ek: $\text{név} \rightarrow \text{gyártó}$, $\text{gyártó} \rightarrow \text{gyártóCím}$

- ◆ Az egyetlen kulcs $\{\text{név}\}$.
- ◆ $\text{név} \rightarrow \text{gyártó}$ nem sérti a BCNF feltételét, de a $\text{gyártó} \rightarrow \text{gyártóCím}$ függőség igen.


BCNF-re való felbontás

- ◆ Adott R reláció és F funkcionális függőségek.
- ◆ Van-e olyan $X \rightarrow Y$ FF, ami sérti a BCNF-t?
 - ▶ Ha van olyan következmény FF F -ben, ami sérti a BCNF-t, akkor egy F -beli FF is sérti.
- ◆ Kiszámítjuk X^+ -t:
 - ▶ Ha itt nem szerepel az összes attribútum, X nem superkulcs.

R dekomponálása $X \rightarrow Y$ felhasználásával

- ◆ R -t helyettesítsük az alábbiakkal:
 1. $R_1 = X^+$.
 2. $R_2 = R - (X^+ - X)$.
- ◆ *Projektáljuk* a meglévő F -beli FF-eket a két új relációsémára.

Dekomponálási kép



Példa: BCNF dekompozíció

Sörivók(név, cím, kedveltSörök, gyártó, kedvencSör)

$F = \text{név} \rightarrow \text{cím}, \text{név} \rightarrow \text{kedvencSör},$
 $\text{kedveltSörök} \rightarrow \text{gyártó}$

- ◆ Vegyük $\text{név} \rightarrow \text{cím}$ FF-t:
- ◆ $\{\text{név}\}^+ = \{\text{név}, \text{cím}, \text{kedvencSör}\}$.
- ◆ A dekomponált relációsémák:
 1. Sörivók1(név, cím, kedvencSör)
 2. Sörivók2(név, kedveltSörök, gyártó)

Példa -- folytatás

- ◆ Meg kell néznünk, hogy az Sörivók1 és Sörivók2 táblák BCNF-ben vannak-e.
- ◆ Az FF-ek projektálása könnyű.
- ◆ A $Sörivók1(\underline{név}, cím, kedvenSör)$, az FF-ek $név \rightarrow cím$ és $név \rightarrow kedvencSör$.
 - ▶ Tehát az egyetlen kulcs: $\{név\}$, azaz az Alkeszek1 BCNF-ben van.

Példa -- folytatás

- ◆ Az $Sörivók2(\underline{név}, \underline{kedveltSörök}, gyártó)$ esetén az egyetlen FF $kedveltSörök \rightarrow gyártó$, az egyetlen kulcs: $\{név, kedveltSörök\}$.
 - ◆ Sérül a BCNF.
- ◆ $kedveltSörök^+ = \{kedveltSörök, gyártó\}$, a $Sörivók2$ felbontása:
 1. $Sörivók3(\underline{kedveltSörök}, gyártó)$
 2. $Sörivók4(\underline{név}, \underline{kedveltSörök})$

Példa -- befejezés

- ◆ Az *Sörivók* dekompozíciója tehát:
 1. *Sörivók1*(név, cím, kedvencSör)
 2. *Sörivók 3*(kedveltSörök, gyártó)
 3. *Sörivók 4*(név, kedveltSörök)
- ◆ A *Sörivók1* a sörivókról, a *Sörivók3* a sörökről, az *Sörivók4* a sörivók és kedvelt söreikről tartalmaz információt.

Miért működik a BCNF?

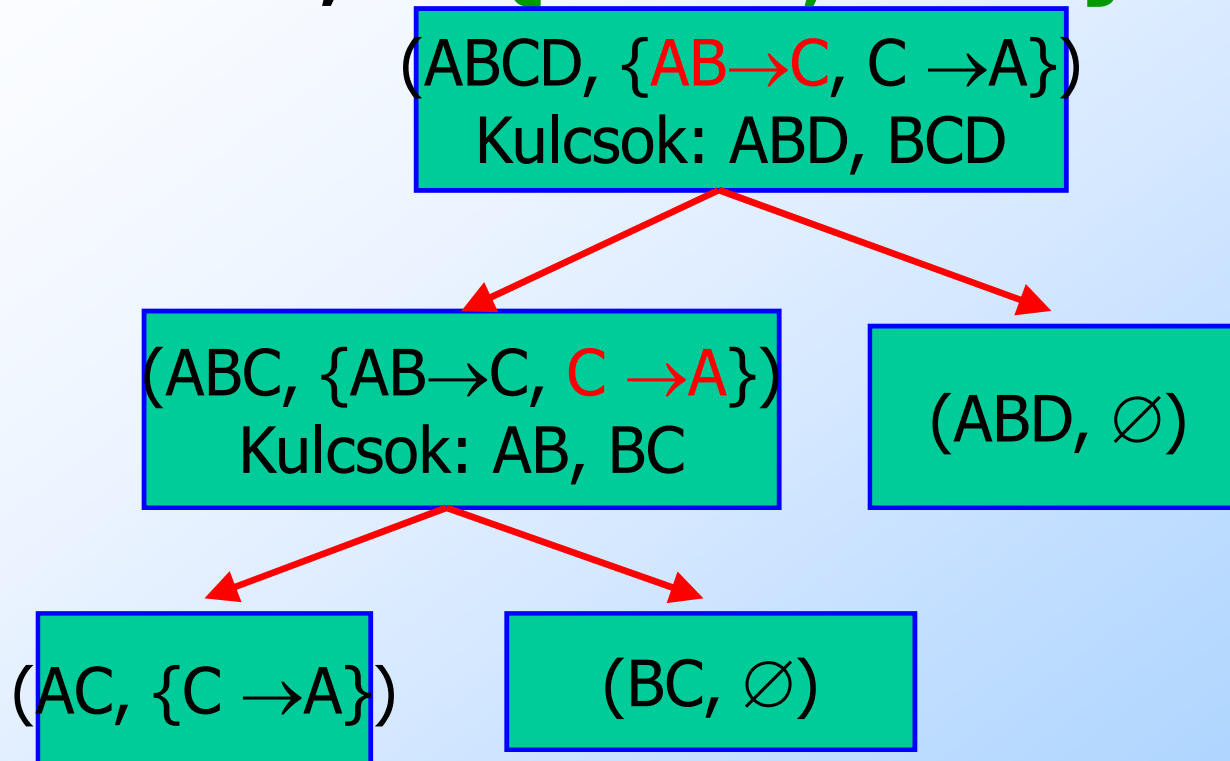
- (R, F) esetén ha R_1, \dots, R_k egy veszteségmentes felbontás, S_1, S_2 pedig R_1 veszteségmentes felbontása, akkor $S_1, S_2, R_2, \dots, R_k$ is veszteségmentes felbontás.
- Könnyen ellenőrizhető, hogy a fenti R_1, R_2 veszteségmentes. (Miért?)
- Minden két attribútumú séma BCNF normálformában van.

Feladat: bizonyítsuk be, hogy ha a fenti $R(A, B, C)$ reláció esetén $B \rightarrow C$ teljesül, akkor az $R_1(A, B), R_2(B, C)$ felbontás mindig veszteségmentes.

- Az algoritmus tehát valóban veszteségmentes felbontást ad, ám sajnos **exponenciális** lépésszámú is lehet a függőségek vetítése miatt.

Példa: BCNF-ra való felbontás

R=ABCD, F={AB→C, C→A}



Tehát $d=(AC,BC,ABD)$ veszteségmentes BCNF dekompozíció.
(\emptyset azt jelenti, hogy csak a triviális függőségek teljesülnek a sémában.)

Tankönyv 3.5.2. feladata (111.o.)

◆ **Órarend adatbázis:** Kurzus(K), Oktató(O),
Időpont(I), Terem(T), Diák(D), Jegy(J)

◆ **Feltételek:**

Egy kurzust csak egy oktató tarthat: $K \rightarrow O$.

Egy helyen egy időben egy kurzus lehet: $IT \rightarrow K$.

Egy időben egy tanár csak egy helyen lehet: $IO \rightarrow T$.

Egy időben egy diák csak egy helyen lehet: $ID \rightarrow T$.

Egy diák egy kurzust egy végső jeggyel zár: $KD \rightarrow J$.

◆ **R=KOITDJ** $F = \{K \rightarrow O, IT \rightarrow K, IO \rightarrow T, ID \rightarrow T, KD \rightarrow J\}$

◆ **Feladat:** Adjuk meg az algoritmussal egy BCNF
dekompozícióját!

A 3normálforma -- motiváció

- ◆ Bizonyos FF halmazok esetén a felbontáskor elveszíthetünk függőségeket.
- ◆ $AB \rightarrow C$ és $C \rightarrow B$.
 - ▶ Példa1: $A =$ utca, $B =$ város, $C =$ irányítószám.
 - ▶ Példa2: $A =$ oktató, $B =$ időpont, $C =$ kurzus.
- ◆ Két kulcs van: $\{A, B\}$ és $\{A, C\}$.
- ◆ $C \rightarrow B$ megsérti a BCNF-t, tehát AC , BC -re dekomponálunk.
- ◆ A probléma az, hogy AC és BC sémákkal nem tudjuk kikényszeríteni $AB \rightarrow C$ függőséget.

A probléma megoldása: 3NF

- ◆ 3. normálformában (3NF) úgy módosul a BCNF feltétel, hogy az előbbi esetben nem kell dekomponálnunk.
- ◆ Egy attribútum *prím*, ha legalább egy kulcsnak eleme.
- ◆ $X \rightarrow A$ megsérti 3NF-t akkor és csak akkor, ha X nem szuperkulcs és A nem prím.

Példa: 3NF

- ◆ A problematikus esetben az $AB \rightarrow C$ és $C \rightarrow B$ FF-ek esetén a kulcsok AB és AC .
- ◆ Ezért A , B és C mindegyike prím.
- ◆ Habár $C \rightarrow B$ megsérti a BCNF feltételét, 3NF feltételét már nem sérti meg.

Miért hasznos 3NF és BCNF?

- ◆ A dekompozícióknak két fontos tulajdonsága lehet:
 1. *Veszteségmentes összekapcsolás* : ha a projektált relációkat összekapcsoljuk az eredetit kapjuk vissza.
 2. *Függőségek megőrzése* : a projektált relációk segítségével is kikényszeríthetőek az előre megadott függőségek.

3NF és BCNF -- folytatás

- ◆ Az (1) tulajdonság teljesül a BCNF esetében.
- ◆ A 3NF (1) és (2)-t is teljesíti.
- ◆ A BCNF esetén (2) sérülhet.
 - ▶ Az *utca-város-iSzám* erre volt egy példa.

A veszteségmentes összekapcsolás ellenőrzése

- ◆ Ha R -t R_1, R_2, \dots, R_k relációkra bontjuk, visszacapjuk-e R -t összekapcsolással?
- ◆ Az összekapcsoltban R minden sora benne lesz majd.
- ◆ A kérdés tehát: **nem kerül-e be az eredménybe olyan sor, ami eredetileg nem volt ott?**

Minimális bázis létrehozása

1. Jobboldalak szétvágása.
2. Próbáljuk törölni az FF-eket egymás után. Ha a megmaradó FF-halmaz nem ekvivalens az eredetivel, akkor nem törölhető az épp aktuális FF.
3. Egymás után próbáljuk csökkenteni a baloldalakat, és megnézzük, hogy az eredetivel ekvivalens FF-halmazt kapunk-e.

3NF-re bontás – (2)

- ◆ A minimális bázis minden FF-e megad egy sémát a felbontásban.
 - ▶ A séma a jobb- és baloldalak uniója lesz.
- ◆ Ha a minimális bázis FF-jei között nincs kulcs, akkor hozzáadunk a felbontáshoz egy olyan sémát, amelyet egy kulcs ad meg.

Példa: 3NF felbontás

- ◆ A reláció: $R = ABCD$.
- ◆ FF-ek: $A \rightarrow B$ és $A \rightarrow C$.
- ◆ **Felbontás**: AB és AC az FF-ekből és AD -t is hozzá kell venni, mert AB , AC egyike sem kulcs.

Miért működik?

- ◆ **Megőrzi a függőségeket:** minden FF megmarad a minimális bázisból.
- ◆ **Veszteségmentes összekapcsolás:** a CHASE algoritmussal ellenőrizhető (a kulcsból létrehozott séma itt lesz fontos).
- ◆ **3NF:** a minimális bázis tulajdonságaiból következik.

Minimális bázist kiszámító algoritmus

1. Kezdetben G az üreshalmaz.
 2. Minden $X \rightarrow Y \in F$ helyett vegyük az $X \rightarrow A$ függőségeket, ahol $A \in Y - X$.
Megj.: Ekkor minden G -beli függőség $X \rightarrow A$ alakú.
 3. Minden $X \rightarrow A \in G$ -re, amíg van olyan $B \in X$ -re $A \in (X - B)^+$ a G -szerint, vagyis $(X - B) \rightarrow A$ teljesül, akkor $X := X - B$.
Megjegyzés: E lépés után minden baloldal minimális lesz.
 4. Minden $X \rightarrow A \in G$ -re, ha $X \rightarrow A \in (G - \{X \rightarrow A\})^+$, vagyis ha elhagyjuk az $X \rightarrow A$ függőséget G -ből, az még mindig következik a maradékból, akkor $G := G - \{X \rightarrow A\}$.
Megjegyzés: Végül nem marad több elhagyható függőség.
- ◆ Példa: $F = \{ H \rightarrow T, U \rightarrow HS, HD \rightarrow KU \}$.
Mi a minimális bázis?

Normálformák (3NF)

- ◆ **Definíció:** $F^* := \{X \rightarrow Y \mid F \vdash X \rightarrow Y\}$ F-ből levezethető összes függőség (F levezethetőség szerinti lezártja).
- ◆ Nézzük meg, hogy lehet minimálisra csökkenteni egy F függőségi halmazt.
- ◆ **G az F minimális bázisa (másképpen minimális fedése), ha**
 - $F^* = G^*$ (bázis, vagy másképpen fedés),
 - G minden függőségében a jobb oldalak egyeleműek, (jobb oldalak minimálisak)
 - G-ből nem hagyható el függőség, hogy F bázisa maradjon, (minimális halmaz)
 - G függőségeinek bal oldala nem csökkenthető, hogy F bázisa maradjon (bal oldalak minimálisak).
- ◆ **Kérdések:**
 - ▶ Minden F-nek létezik minimális bázisa?
 - ▶ Egyértelmű-e a minimális bázis?
 - ▶ Hogyan lehet adott F esetén meghatározni egy minimális bázist, lehetőleg hatékonyan?

Normálformák (3NF)

Mohó algoritmus minimális bázis előállítására:

1. Jobb oldalak minimalizálása:

$X \rightarrow A_1, \dots, A_k$ függőséget cseréljük le az
 $X \rightarrow A_1, \dots, X \rightarrow A_k$ k darab függőségre.

2. A halmaz minimalizálása:

Hagyjuk el az olyan $X \rightarrow A$ függőségeket, amelyek a bázist nem befolyásolják, azaz

while F változik

if $(F - \{X \rightarrow A\})^* = F^*$ then $F := F - \{X \rightarrow A\}$;

3. Bal oldalak minimalizálása:

Hagyjuk el a bal oldalakból azokat az attribútumokat, amelyek a bázist nem befolyásolják, azaz

while F változik

for all $X \rightarrow A \in F$

for all $B \in X$

if $((F - \{X \rightarrow A\}) \cup \{(X - \{B\}) \rightarrow A\})^* = F^*$ then $F := (F - \{X \rightarrow A\}) \cup \{(X - \{B\}) \rightarrow A\}$

- ◆ Belátható, hogy a 3. lépés nem rontja el a halmaz minimalizálást, így minimális bázist kapunk.

Normálformák (3NF)

- ◆ Az algoritmusban különböző sorrendben választva a függőségeket, illetve attribútumokat, különböző minimális bázist kaphatunk.
- ◆ $F = \{A \rightarrow B, B \rightarrow A, B \rightarrow C, A \rightarrow C, C \rightarrow A\}$
 $(F - \{B \rightarrow A\})^* = F^*$, mivel $F - \{B \rightarrow A\} \mid\!\!\! \dashv B \rightarrow A$
 $F := F - \{B \rightarrow A\}$
 $(F - \{A \rightarrow C\})^* = F^*$, mivel $F - \{A \rightarrow C\} \mid\!\!\! \dashv A \rightarrow C$
 $F := F - \{A \rightarrow C\} = \{A \rightarrow B, B \rightarrow C, C \rightarrow A\}$ **minimális bázis**,
mert több függőség és attribútum már nem hagyható el.
- ◆ $F = \{A \rightarrow B, B \rightarrow A, B \rightarrow C, A \rightarrow C, C \rightarrow A\}$
 $(F - \{B \rightarrow C\})^* = F^*$, mivel $F - \{B \rightarrow C\} \mid\!\!\! \dashv B \rightarrow C$
 $F := F - \{B \rightarrow C\} = \{A \rightarrow B, B \rightarrow A, A \rightarrow C, C \rightarrow A\}$ **is minimális bázis**,
mert több függőség és attribútum már nem hagyható el.

Normálformák (3NF)

- ◆ Az algoritmusban különböző sorrendben választva a függőségeket, illetve attribútumokat, különböző minimális bázist kaphatunk.

- ◆ $F = \{AB \rightarrow C, A \rightarrow B, B \rightarrow A\}$

$(F - \{AB \rightarrow C\} \cup \{A \rightarrow C\})^* = F^*$, mivel

$(F - \{AB \rightarrow C\}) \cup \{A \rightarrow C\} \models AB \rightarrow C$ és $F \models A \rightarrow C$.

$F := (F - \{AB \rightarrow C\} \cup \{A \rightarrow C\}) = \{A \rightarrow C, A \rightarrow B, B \rightarrow A\}$

minimális bázis, mert több függőség és attribútum már nem hagyható el.

- ◆ $F = \{AB \rightarrow C, A \rightarrow B, B \rightarrow A\}$

$(F - \{AB \rightarrow C\} \cup \{B \rightarrow C\})^* = F^*$, mivel

$(F - \{AB \rightarrow C\}) \cup \{B \rightarrow C\} \models AB \rightarrow C$ és $F \models B \rightarrow C$.

$F := (F - \{AB \rightarrow C\} \cup \{B \rightarrow C\}) = \{B \rightarrow C, A \rightarrow B, B \rightarrow A\}$ is

minimális bázis, mert több függőség és attribútum már nem hagyható el.

Normálformák (3NF)

◆ Algoritmus **függőségörző 3NF dekompozíció** előállítására:

◆ **Input: (R,F)**

▶ Legyen $G := \{X \rightarrow A, X \rightarrow B, \dots, Y \rightarrow C, Y \rightarrow D, \dots\}$ az **F** **minimális bázisa**.

▶ Legyen **S** az R sémának G-ben nem szereplő attribútumai.

▶ Ha van olyan függőség G-ben, amely R összes attribútumát tartalmazza, akkor legyen $d := \{R\}$, különben legyen

$d := \{S, XA, XB, \dots, YC, YD, \dots\}$.

Normálformák (3NF)

◆ Algoritmus függőségörző és **veszteségmentes** 3NF dekompozíció előállítására:

◆ Input: **(R,F)**

▶ Legyen $G := \{X \rightarrow A, X \rightarrow B, \dots, Y \rightarrow C, Y \rightarrow D, \dots\}$ az **F** minimális bázisa.

▶ Legyen **S** az R sémának G-ben nem szereplő attribútumai.

▶ Ha van olyan függőség G-ben, amely R összes attribútumát tartalmazza, akkor legyen $d := \{R\}$, különben **legyen K az R egy kulcsa**, és legyen

$d := \{K, S, XA, XB, \dots, YC, YD, \dots\}$.

Normálformák (3NF)

- ◆ Algoritmus függőségörző és veszteségmentes 3NF redukált (kevesebb tagból álló) dekompozíció előállítására:
- ◆ Input: (R, F)
 - ▶ Legyen $G := \{X \rightarrow A, X \rightarrow B, \dots, Y \rightarrow C, Y \rightarrow D, \dots\}$ az F minimális bázisa.
 - ▶ Legyen S az R sémának G -ben nem szereplő attribútumai.
 - ▶ Ha van olyan függőség G -ben, amely R összes attribútumát tartalmazza, akkor legyen $d := \{R\}$, különben legyen K az R egy kulcsa, és legyen $d := \{K, S, XAB \dots, \dots, YCD \dots, \dots\}$.
 - Ha K része valamelyik sémának, akkor K -t elhagyhatjuk.