


# Relációs adatbázisok tervezése

## 5.rész (Többértékű függőségek)



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

### 3.6. Többértékű függőségek - Negyedik normálforma

(Jeffrey D. Ullman, 2007 slides alapján  
Dr. Kiss Attila előadásainak felhasználásával )

# Többértékű függőségek

◆ Dolgozó adatbázis: Név(**N**), Diploma(**D**), Telefon(**T**)

◆ **R=NDT**


<b>N</b>	<b>D</b>	<b>T</b>
Kovács	{programozó, közgazdász}	{1234567, 7654321, 1212123}
Szabó	{programozó, jogász}	{1234123, 1234512}

**0. normálforma:** az értékek halmazok is lehetnek.

# Többértékű függőségek

## ◆ Átírás 1. normálformára (az értékek atomi értékek)

N	D	T
Kovács	{programozó, közgazdász}	{1234567, 7654321, 1212123}
Szabó	{programozó, jogász}	{1234123, 1234512}



N	D	T
Kovács	programozó	1234567
Kovács	programozó	7654321
Kovács	programozó	1212123
Kovács	közgazdász	1234567
Kovács	közgazdász	7654321
Kovács	közgazdász	1212123
Szabó	programozó	1234123
Szabó	programozó	1234512
Szabó	jogász	1234123
Szabó	jogász	1234512

- Adott névhez diplomák halmaza és telefonszámok halmaza tartozik, egymástól függetlenül.

- Név →→ Diploma
- Név →→ Telefon

30 értéket tárolunk  
(redundancia)!

# Többértékű függőségek

## ◆ Dekomponáljuk 2 táblára veszteségmentesen:

N	D
Kovács	programozó
Kovács	közgazdász
Szabó	programozó
Szabó	jogász

N	T
Kovács	1234567
Kovács	7654321
Kovács	1212123
Szabó	1234123
Szabó	1234512

18 értéket  
tárolunk  
(csökkent a  
redundancia  
)

- A 2 tábla összekapcsolása visszaadná az eredeti (redundáns) táblát, vagyis **veszteségmentes** lenne a dekompozíció.
- A **funkcionális függőség speciális többértékű függőség**, például **Név → Telefon** esetén 1 elemű halmaz ( 1 telefonszám) tartozik minden névhez, azaz **Név →→ Telefon**.

# Többértékű függőségek

- ◆ **Definíció:**  $X, Y \subseteq R$ ,  $Z := R - XY$  esetén  $X \twoheadrightarrow Y$  **többértékű függőség. (tf)**
- ◆ A függőség akkor teljesül egy táblában, ha bizonyos mintájú sorok létezése garantálja más sorok létezését.
- ◆ A formális definíciót az alábbi ábra szemlélteti.
- ◆ Ha létezik **t** és **s** sor, akkor **u** és **v** soroknak is létezniük kell, ahol az azonos szimbólumok azonos értékeket jelölnek.

	<b>X</b>	<b>Y</b>	<b>Z</b>
t	x	y1	z1
s	x	y2	z2
$\exists u$	x	y1	z2
$\exists v$	x	y2	z1

# Többértékű függőségek

**Definíció (Formálisan):** Egy R sémájú  $r$  reláció kielégíti az  $X \twoheadrightarrow Y$  függőséget, ha  $t, s \in r$  és  $t[X] = s[X]$  esetén létezik olyan  $u, v \in r$ , amelyre  $u[X] = v[X] = t[X] = s[X]$ ,  $u[Y] = t[Y]$ ,  $u[Z] = s[Z]$ ,  $v[Y] = s[Y]$ ,  $v[Z] = t[Z]$ .

**Állítás:** Elég az  $u, v$  közül csak az egyik létezését megkövetelni.

	X	Y	Z
t	x	y1	z1
s	x	y2	z2
$\exists u$	x	y1	z2

# Többértékű függőségek

- ◆ Hasonló utat járunk be, mint a funkcionális függőségek esetén:
  - ▶ implikációs probléma
  - ▶ axiomatizálás
  - ▶ levezethető függőségek hatékony meghatározása (lezárás helyett a séma partíciója (másképpen függőségi bázisa))
  - ▶ veszteségmentes dekompozíció
  - ▶ 4. normálforma
  - ▶ veszteségmentes **4NF** dekompozíció előállítás
- ◆ Mivel kijön majd, hogy minden 4NF egyben BCNF is, amire nincs egyszerre függőségőrző és veszteségmentes dekompozíció, így 4NF-re sincs mindig.

# Többértékű függőségek

## ◆ Axiomatizálás

Funkcionális függőségek	Többértékű függőségek	Vegyes függőségek
<p><b>A1 (reflexivitás):</b>  <math>Y \subseteq X</math> esetén <math>X \rightarrow Y</math>.</p>	<p><b>A4 (komplementer):</b>  <math>X \rightarrow Y</math> és <math>Z = R - XY</math> esetén  <math>X \rightarrow Z</math>.</p>	<p><b>A7 (funkcionálisból többértékű):</b>  <math>X \rightarrow Y</math> esetén <math>X \rightarrow Y</math>.</p>
<p><b>A2 (tranzitivitás):</b>  <math>X \rightarrow Y</math> és <math>Y \rightarrow Z</math> esetén  <math>X \rightarrow Z</math>.</p>	<p><b>A5 (tranzitivitás):</b>  <math>X \rightarrow Y</math> és <math>Y \rightarrow S</math> esetén  <math>X \rightarrow S - Y</math>.</p>	<p><b>A8 (többértékűből és funkcionálisból funkcionális):</b>  <math>X \rightarrow Y</math> és <math>W \rightarrow S</math>,            ahol <math>S \subseteq Y</math>, <math>W \cap Y = \emptyset</math>            esetén <math>X \rightarrow S</math>.</p>
<p><b>A3 (bővíthetőség):</b>  <math>X \rightarrow Y</math> és tetszőleges  <math>Z</math> esetén <math>XZ \rightarrow YZ</math>.</p>	<p><b>A6 (bővíthetőség):</b>  <math>X \rightarrow Y</math> és tetszőleges  <math>V \subseteq W</math> esetén <math>XW \rightarrow YV</math>.</p>	



# Többértékű függőségek

## ◆ Jelölés a továbbiakban:

- ▶ **F** funkcionális függőségek halmaza
- ▶ **M** többértékű függőségek halmaza
- ▶ **D** vegyes függőségek (funkcionális és többértékű függőségek) halmaza

## ◆ **Tétel (helyes és teljes axiómarendszerek):**

- ▶ **A1,A2,A3 helyes és teljes a funkcionális függőségekre,**
- ▶ **A4,A5,A6 helyes és teljes a többértékű függőségekre,**
- ▶ **A1,A2,A3,A4,A5,A6,A7,A8 helyes és teljes a vegyes függőségekre.**

# Többértékű függőségek

## ◆ **Állítás** (további levezetési szabályok):

1.  $X \twoheadrightarrow Y$  és  $X \twoheadrightarrow V$  esetén  $X \twoheadrightarrow YV$ .

2.  $X \twoheadrightarrow Y$  és  $WX \twoheadrightarrow V$  esetén  $WX \twoheadrightarrow V-WY$ .

3.  $X \twoheadrightarrow Y$  és  $XY \twoheadrightarrow V$  esetén  $X \twoheadrightarrow V-Y$ .

4.  $X \twoheadrightarrow Y$  és  $X \twoheadrightarrow V$  esetén  $X \twoheadrightarrow Y \cap V$

és  $X \twoheadrightarrow V-Y$

és  $X \twoheadrightarrow Y-V$ .

## Többértékű függőségek

- ◆ **Állítás:**  $X \twoheadrightarrow Y$ -ből **nem következik**, hogy  $X \twoheadrightarrow A$ , ha  $A \in Y$ . (A jobb oldalak nem szedhetők szét!)
- ◆ **Bizonyítás:** A következő r tábla kielégíti az  $X \twoheadrightarrow AB$ -t, de nem elégíti ki az  $X \twoheadrightarrow A$ -t. q.e.d.

X	A	B	C
x	a	b	c
x	e	f	g
x	a	b	g
x	e	f	c

$X \twoheadrightarrow A$  esetén  
ennek a  
sornak is  
benne kellene  
lenni a  
táblában.

x	a	f	g
---	---	---	---

## Többértékű függőségek

- ◆ **Állítás:**  $X \twoheadrightarrow Y$  és  $Y \twoheadrightarrow V$ -ből **nem következik**, hogy  $X \twoheadrightarrow V$ . (A szokásos tranzitivitás nem igaz általában!)
- ◆ **Bizonyítás:** A következő r tábla kielégíti az  $X \twoheadrightarrow AB$ -t,  $AB \twoheadrightarrow BC$ -t, de nem elégíti ki az  $X \twoheadrightarrow BC$ -t. q.e.d.

X	A	B	C
x	a	b	c
x	e	f	g
x	a	b	g
x	e	f	c

x	e	b	c
---	---	---	---

$X \twoheadrightarrow BC$  esetén ennek a sornak is benne kellene lenni a táblában.

# Többértékű függőségek

- ◆ A **veszteségmentesség**, **függőségörzés** definíciójában most **F** funkcionális függőségi halmaz helyett **D** függőségi halmaz többértékű függőségeket is tartalmazhat.
- ◆ Így például  **$d=(R_1, \dots, R_k)$**  veszteségmentes dekompozíciója **R**-nek **D**-re nézve, akkor és csak akkor, ha minden **D**-t kielégítő **r** tábla esetén  
 **$r = \Pi_{R_1}(r) \mid \dots \mid \Pi_{R_k}(r)$**
- ◆ A következő tétel miatt a **veszteségmentesség implikációs problémára vezethető vissza**, így hatékonyan eldönthető.
- ◆ **Tétel:** A  **$d=(R_1, R_2)$**  akkor és csak akkor **veszteségmentes** dekompozíciója **R**-nek, ha  **$D \mid \text{--- } R_1 \cap R_2 \rightarrow \rightarrow R_1 - R_2$** .

## Többértékű függőségek

- ◆ A 4. normálforma definiálása előtt foglaljuk össze, hogy melyek a **triviális többértékű függőségek**, vagyis amelyek **minden relációban teljesülnek**.
- ◆ Mivel minden funkcionális függőség többértékű függőség is, így a triviális funkcionális egyben triviális többértékű függőség is.
  1.  $Y \subseteq X$  esetén  $X \twoheadrightarrow Y$  **triviális többértékű függőség**.
- ◆ Speciálisan  $Y = \emptyset$  választással  $X \twoheadrightarrow \emptyset$  függőséget kapjuk, és alkalmazzuk a komplementer szabályt, azaz  $Z = R - X\emptyset$ , így az  $X \twoheadrightarrow R - X$  függőség is mindig teljesül, azaz:
  2.  $XY = R$  esetén  $X \twoheadrightarrow Y$  **triviális többértékű függőség**.
- ◆ A superkulcs, kulcs definíciója változatlan, azaz  $X$  **superkulcsa**  $R$ -nek  $D$ -re nézve, ha  $D \mid\!\!\!\! \dashv X \rightarrow R$ .
- ◆ A minimális superkulcsot **kulcsnak** hívjuk.

## Többértékű függőségek

- ◆ A 4.normálforma hasonlít a BCNF-re, azaz minden nem triviális többértékű függőség bal oldala szuperkulcs.
- ◆ **Definíció:** R **4NF**-ben van D-re nézve, ha  $XY \neq R$ ,  $Y \not\subseteq X$ , és  $D \models X \twoheadrightarrow Y$  esetén  $D \models X \rightarrow R$ .
- ◆ **Definíció:**  $d = \{R_1, \dots, R_k\}$  dekompozíció **4NF**-ben van D-re nézve, ha minden  $R_i$  **4NF**-ben van  $\Pi_{R_i}(D)$ -re nézve.
- ◆ **Állítás:** Ha R **4NF**-ben van, akkor **BCNF**-ben is van.
- ◆ **Bizonyítás.** Vegyünk egy nem triviális  $D \models X \rightarrow A$  **funkcionális** függőséget. Ha  $XA = R$ , akkor  $D \models X \rightarrow R$ , ha  $XA \neq R$ , akkor a  $D \models X \twoheadrightarrow A$  nem triviális többértékű függőség és a **4NF** miatt  $D \models X \rightarrow R$ . q.e.d.
- ◆ **Következmény:** Nincs mindig **függőségörző** és **veszteségmentes 4NF** dekompozíció.

## Többértékű függőségek

- ◆ **Veszteségmentes 4NF** dekompozíciót mindig tudunk készíteni a naiv BCNF dekomponáló algoritmushoz hasonlóan.
- ◆ Naiv algoritmus **veszteségmentes 4NF** dekompozíció előállítására:  
Ha **R 4NF-ben** van, akkor megállunk,  
egyébként  
**van olyan** nem triviális  $X \twoheadrightarrow Y$ , amely R-ben teljesül, de **megsérti a 4NF-et**, azaz X nem superkulcs.  
Ekkor **R helyett vegyük az (XY, R-Y)** dekompozíciót.  
A kettévágásokat addig hajtjuk végre, amíg minden tag 4NF-ben nem lesz. **ALGORITMUS VÉGE.**
- ◆ Az is feltehető, hogy X és Y diszjunkt, mert különben Y helyett az Y-X-et vehettük volna jobb oldalnak.
- ◆  $XY \neq R$ , így *mindkét tagban csökken az attribútumok száma.*
- ◆  $XY \cap (R-Y) = X \twoheadrightarrow Y = XY - (R-Y)$ , azaz a kéttagú dekompozícióknál bizonyított állítás miatt *veszteségmentes kettévágást kaptunk.*
- ◆ Legrosszabb esetben a 2 oszlopos sémáig kell szétbontani, amelyek mindig 4NF-ben vannak, mivel nem lehet bennük nem triviális többértékű függőség.



# Definition of MVD

- ◆ A *multivalued dependency* (MVD) on  $R$ ,  $X \twoheadrightarrow Y$ , says that if two tuples of  $R$  agree on all the attributes of  $X$ , then their components in  $Y$  may be swapped, and the result will be two tuples that are also in the relation.
- ◆ i.e., for each value of  $X$ , the values of  $Y$  are independent of the values of  $R-X-Y$ .

# Example: MVD

Drinkers(name, addr, phones, beersLiked)

- ◆ A drinker's phones are independent of the beers they like.
  - ▶ name->->phones and name ->->beersLiked.
- ◆ Thus, each of a drinker's phones appears with each of the beers they like in all combinations.
- ◆ This repetition is unlike FD redundancy.
  - ▶ name->addr is the only FD.


# Tuples Implied by $\text{name} \twoheadrightarrow \text{phones}$

If we have tuples:

name	addr	phones	beersLiked
sue	a	p1	b1
sue	a	p2	b2
sue	a	p2	b1
sue	a	p1	b2

Then these tuples must also be in the relation.

# Picture of MVD $X \dashrightarrow \dashrightarrow Y$



# MVD Rules

- ◆ Every FD is an MVD (*promotion*).
  - ▶ If  $X \rightarrow Y$ , then swapping  $Y$ 's between two tuples that agree on  $X$  doesn't change the tuples.
  - ▶ Therefore, the "new" tuples are surely in the relation, and we know  $X \twoheadrightarrow Y$ .
- ◆ *Complementation* : If  $X \twoheadrightarrow Y$ , and  $Z$  is all the other attributes, then  $X \twoheadrightarrow Z$ .

# Splitting Doesn't Hold

- ◆ Like FD's, we cannot generally split the left side of an MVD.
- ◆ But unlike FD's, we cannot split the right side either --- sometimes you have to leave several attributes on the right side.

# Example: Multiattribute Right Sides

Drinkers(name, areaCode, phone,  
beersLiked, manf)

- ◆ A drinker can have several phones, with the number divided between areaCode and phone (last 7 digits).
- ◆ A drinker can like several beers, each with its own manufacturer.

## Example Continued

- ◆ Since the areaCode-phone combinations for a drinker are independent of the beersLiked-manf combinations, we expect that the following MVD's hold:

name  $\twoheadrightarrow$  areaCode phone

name  $\twoheadrightarrow$  beersLiked manf



# Example Data

Here is possible data satisfying these MVD's:

name	areaCode	phone	beersLiked	manf
Sue	650	555-1111	Bud	A.B.
Sue	650	555-1111	WickedAle	Pete's
Sue	415	555-9999	Bud	A.B.
Sue	415	555-9999	WickedAle	Pete's

But we cannot swap area codes or phones by themselves. That is, neither  $\text{name} \twoheadrightarrow \text{areaCode}$  nor  $\text{name} \twoheadrightarrow \text{phone}$  holds for this relation.

# Fourth Normal Form

- ◆ The redundancy that comes from MVD's is not removable by putting the database schema in BCNF.
- ◆ There is a stronger normal form, called 4NF, that (intuitively) treats MVD's as FD's when it comes to decomposition, but not when determining keys of the relation.

# 4NF Definition

- ◆ A relation  $R$  is in *4NF* if: whenever  $X \twoheadrightarrow Y$  is a nontrivial MVD, then  $X$  is a superkey.
  - ◆ *Nontrivial MVD* means that:
    1.  $Y$  is not a subset of  $X$ , and
    2.  $X$  and  $Y$  are not, together, all the attributes.
  - ◆ Note that the definition of “superkey” still depends on FD’s only.

# BCNF Versus 4NF

- ◆ Remember that every FD  $X \rightarrow Y$  is also an MVD,  $X \twoheadrightarrow Y$ .
- ◆ Thus, if  $R$  is in 4NF, it is certainly in BCNF.
  - ◆ Because any BCNF violation is a 4NF violation (after conversion to an MVD).
- ◆ But  $R$  could be in BCNF and not 4NF, because MVD's are "invisible" to BCNF.

# Decomposition and 4NF

- ◆ If  $X \twoheadrightarrow Y$  is a 4NF violation for relation  $R$ , we can decompose  $R$  using the same technique as for BCNF.
  1.  $XY$  is one of the decomposed relations.
  2. All but  $Y - X$  is the other.

# Example: 4NF Decomposition

Drinkers(name, addr, phones, beersLiked)

FD:            name -> addr

MVD's:        name ->-> phones

                 name ->-> beersLiked

◆ Key is {name, phones, beersLiked}.

◆ All dependencies violate 4NF.

# Example Continued

- ◆ Decompose using  $name \rightarrow addr$ :
  1. Drinkers1(name, addr)
    - ◆ In 4NF; only dependency is  $name \rightarrow addr$ .
  2. Drinkers2(name, phones, beersLiked)
    - ◆ Not in 4NF. MVD's  $name \twoheadrightarrow phones$  and  $name \twoheadrightarrow beersLiked$  apply. No FD's, so all three attributes form the key.

# Example: Decompose Drinkers2

- ◆ Either MVD  $\text{name} \twoheadrightarrow \text{phones}$  or  $\text{name} \twoheadrightarrow \text{beersLiked}$  tells us to decompose to:
  - ▶ Drinkers3(name, phones)
  - ▶ Drinkers4(name, beersLiked)



# Reasoning About MVD's + FD's

- ◆ **Problem:** given a set of MVD's and/or FD's that hold for a relation  $R$ , does a certain FD or MVD also hold in  $R$ ?
- ◆ **Solution:** Use a tableau to explore all inferences from the given set, to see if you can prove the target dependency.

# Why Do We Care?

1. 4NF technically requires an MVD violation.
  - ▶ Need to infer MVD's from given FD's and MVD's that may not be violations themselves.
2. When we decompose, we need to project FD's + MVD's.

## Example: Chasing a Tableau With MVD's and FD's

- ◆ To apply a FD, equate symbols, as before.
- ◆ To apply an MVD, generate one or both of the tuples we know must also be in the relation represented by the tableau.
- ◆ We'll prove: if  $A \twoheadrightarrow BC$  and  $D \rightarrow C$ , then  $A \rightarrow C$ .

# The Tableau for $A \rightarrow C$

Goal: prove that  $c_1 = c_2$ .

$A$	$B$	$C$	$D$
$a$	$b_1$	<del><math>c_1</math></del> $c_2$	$d_1$
$a$	$b_2$	$c_2$	$d_2$
$a$	$b_2$	$c_2$	$d_1$

Use  $A \rightarrow - \rightarrow BC$  (first row's  $D$  with second row's  $BC$ ).

Use  $D \rightarrow C$  (first and third row agree on  $D$ , therefore agree on  $C$ ).

# Example: Transitive Law for MVD's

- ◆ If  $A \twoheadrightarrow B$  and  $B \twoheadrightarrow C$ , then  $A \twoheadrightarrow C$ .
  - ▶ Obvious from the complementation rule if the Schema is  $ABC$ .
  - ▶ But it holds no matter what the schema; we'll assume  $ABCD$ .

# The Tableau for $A \rightarrow B \rightarrow C$

Goal: derive tuple  $(a, b_1, c_2, d_1)$ .

<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
<i>a</i>	<i>b</i> <sub>1</sub>	<i>c</i> <sub>1</sub>	<i>d</i> <sub>1</sub>
<i>a</i>	<i>b</i> <sub>2</sub>	<i>c</i> <sub>2</sub>	<i>d</i> <sub>2</sub>
<i>a</i>	<i>b</i> <sub>1</sub>	<i>c</i> <sub>2</sub>	<i>d</i> <sub>2</sub>
<i>a</i>	<i>b</i> <sub>1</sub>	<i>c</i> <sub>2</sub>	<i>d</i> <sub>2</sub>

Use  $A \rightarrow B$  to swap  $B$  from the first row into the second.

Use  $B \rightarrow C$  to swap  $C$  from the third row into the first.

# Rules for Inferring MVD's + FD's

- ◆ Start with a tableau of two rows.
  - ▶ These rows agree on the attributes of the left side of the dependency to be inferred.
  - ▶ And they disagree on all other attributes.
  - ▶ Use unsubscripted variables where they agree, subscripts where they disagree.

# Inference: Applying a FD

- ◆ Apply a FD  $X \rightarrow Y$  by finding rows that agree on all attributes of  $X$ . Force the rows to agree on all attributes of  $Y$ .
  - ▶ Replace one variable by the other.
  - ▶ If the replaced variable is part of the goal tuple, replace it there too.



# Inference: Applying a MVD

- ◆ Apply a MVD  $X \twoheadrightarrow Y$  by finding two rows that agree in  $X$ .
  - ▶ Add to the tableau one or both rows that are formed by swapping the  $Y$ -components of these two rows.

# Inference: Goals

- ◆ To test whether  $U \rightarrow V$  holds, we succeed by inferring that the two variables in each column of  $V$  are actually the same.
- ◆ If we are testing  $U \rightarrow \neg \rightarrow V$ , we succeed if we infer in the tableau a row that is the original two rows with the components of  $V$  swapped.

# Inference: Endgame

- ◆ Apply all the given FD's and MVD's until we cannot change the tableau.
- ◆ If we meet the goal, then the dependency is inferred.
- ◆ If not, then the final tableau is a counterexample relation.
  - ▶ Satisfies all given dependencies.
  - ▶ Original two rows violate target dependency.