



UNIVERSITETET
I OSLO

Relasjonsdatabasedesign (forts.)

Flerverdiavhengigheter
Høyere normalformer

Flerverdiavhengigheter

- Generalisering av FDer
- Flerverdiavhengigheter gir opphav til en større klasse integritetsregler enn de som kan uttrykkes ved bare FDer

Eksempel: Emnedatabase

Emne(Kode, Lærebok, Foreleser)

Integritetsregler:

- Et emne har et sett av lærebøker
- Et emne kan ha flere forelesere
- Det er ingen sammenheng mellom forelesere og lærebøker

Eksempelekstensjon

Emne

Kode	Lærebok	Foreleser
INF1010	Java-II	Arne
INF1010	OOhefte	Ellen
INF1050	Kjernen	Erik
INF1050	PHP	Tone
INF1050	Web	Gerhard

Emne

Kode	Lærebok	Foreleser
INF1010	Java-II	Arne
INF1010	Java-II	Ellen
INF1010	OOhefte	Arne
INF1010	OOhefte	Ellen
INF1050	Kjernen	Erik
INF1050	Kjernen	Tone
INF1050	Kjernen	Gerhard
INF1050	PHP	Erik
INF1050	PHP	Tone
INF1050	PHP	Gerhard
INF1050	Web	Erik
INF1050	Web	Tone
INF1050	Web	Gerhard

Definisjon flerverdiavhengighet

- Gitt et relasjonsskjema $R(A_1, A_2, \dots, A_n)$
La X, Y være delmengder av $\{A_1, A_2, \dots, A_n\}$
La Z være de attributtene som hverken er med i X eller Y

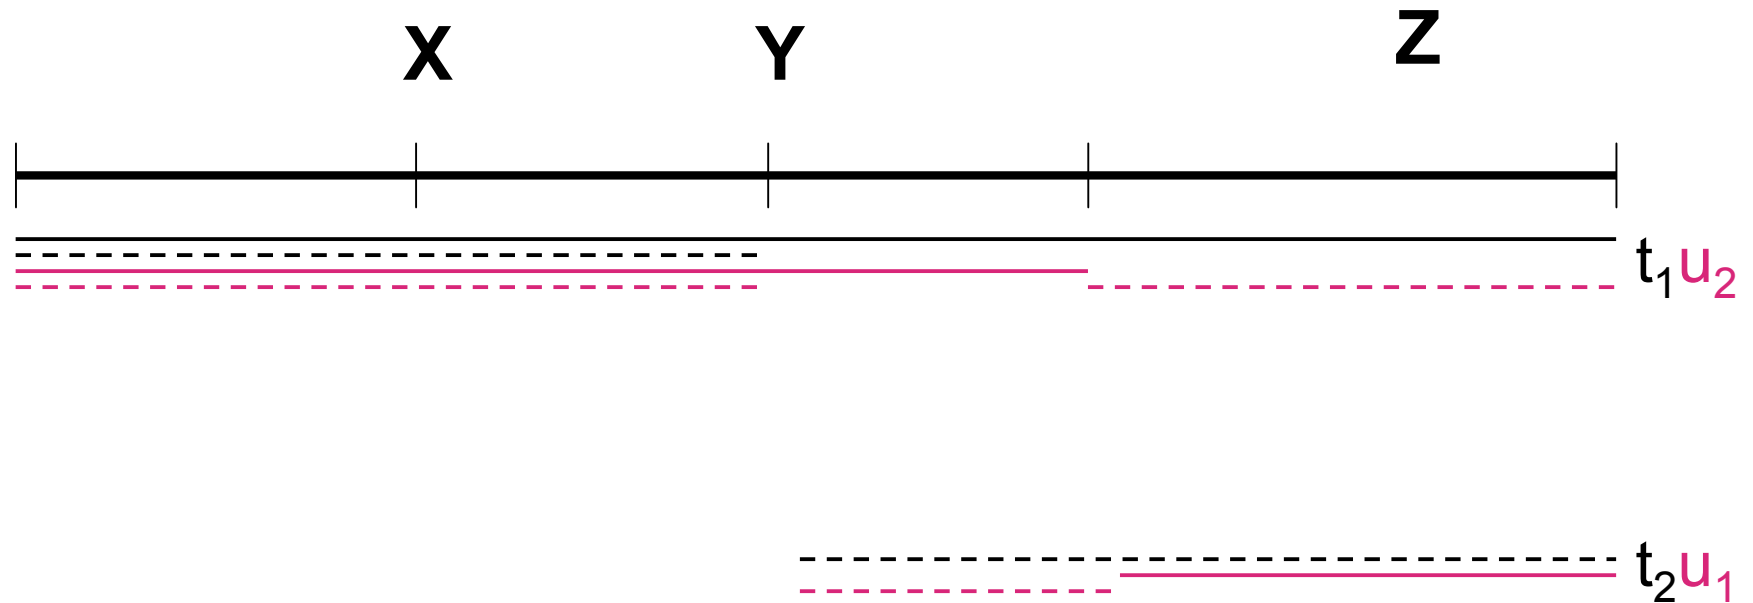
Y **er flerverdiavhengig av** X hvis vi for enhver lovlig instans av R har at hvis instansen inneholder to tupler t_1 og t_2 hvor $t_1[X]=t_2[X]$, så fins det også to tupler u_1 og u_2 hvor

- 1) $u_1[X]=u_2[X]=t_1[X]=t_2[X]$
- 2) $u_1[Y]=t_1[Y], u_2[Y]=t_2[Y]$
- 3) $u_1[Z]=t_2[Z], u_2[Z]=t_1[Z]$

Definisjon på norsk

- Y er flerverdiavhengig av X hvis vi for alle lovlige instanser av R har at hvis instansen inneholder to tupler t_1 og t_2 som er like på X , så må den også inneholde to tupler u_1 og u_2 hvor
 - 1) u_1 er lik t_1 på X og Y og lik t_2 utenfor Y
 - 2) u_2 er lik t_2 på X og Y og lik t_1 utenfor Y

Illustrasjon av flerverdiavhengighet



MVD

- Vi skriver $X \twoheadrightarrow Y$ hvis Y er flerverdiavhengig av X
- Ofte snakker vi for korthets skyld om “MVDen $X \twoheadrightarrow Y$ ” der MVD står for Multi-Valued Dependency
- Hvis $Y \subseteq X$, så $X \twoheadrightarrow Y$

Bevis:

La t_1 og t_2 være to tupler som er like på X

Velg $u_1=t_2$ og $u_2=t_1$

Da er $u_1=t_1$ på X og Y og $u_1=t_2$ utenfor Y ,

mens $u_2=t_2$ på X og Y og $u_2=t_1$ utenfor Y

Det er definisjonen på at $X \twoheadrightarrow Y$

Trivielle MVD-er

- Hvis XY er samtlige attributter i R , så $X \twoheadrightarrow Y$

Bevis:

La t_1 og t_2 være to tupler som er like på X

Velg $u_1=t_1$ og $u_2=t_2$

Da er $u_1=t_1$ på X og Y og $u_1=t_2$ utenfor Y ,

mens $u_2=t_2$ på X og Y og $u_2=t_1$ utenfor Y

Det er definisjonen på at $X \twoheadrightarrow Y$

- **Definisjon av trivielle MVD-er:**

$X \twoheadrightarrow Y$ kalles triviell hvis, og bare hvis,

vi enten har at $Y \subseteq X$

eller at XY er samtlige attributter i R

Ekte MVD-er

- Hvis $X \rightarrow Y$, så $X \twoheadrightarrow Y$
(Bevis følger senere)
- En ikke-triviell $X \twoheadrightarrow Y$ hvor $X \rightarrow Y$ *ikke* holder, kalles en **ekte MVD**
- MVDer benyttes til å uttrykke integritetsregler:
Kode \twoheadrightarrow Lærebok, Kode \twoheadrightarrow Foreleser
- MVDer opptrer hvis man plasserer to m:n-forhold ($m \geq 1$) i samme relasjon, og de to forholdene ikke har avhengigheter seg imellom

Armstrong's slutningsregler utvidet til MVDer (for spesielt interesserte)

1. Refleksivitet FD: Hvis $Y \subseteq X$, så $X \rightarrow Y$
2. Utvidelse FD: Hvis $X \rightarrow Y$, så $XZ \rightarrow YZ$
3. Transitivitet FD: Hvis $X \rightarrow Y$ og $Y \rightarrow Z$, så $X \rightarrow Z$
4. Komplement: Hvis Z er de attributtene som XY ikke omfatter, og $X \twoheadrightarrow Y$, så $X \twoheadrightarrow Z$.
5. Utvidelse MVD: Hvis $X \twoheadrightarrow Y$ og $Z \subseteq W$, så $XW \twoheadrightarrow YZ$
6. Transitivitet MVD:
Hvis $X \twoheadrightarrow Y$ og $Y \twoheadrightarrow Z$, så $X \twoheadrightarrow Z$
7. FDer er MVDer: Hvis $X \rightarrow Y$ så $X \twoheadrightarrow Y$
8. Sammensmeltning:
Hvis $X \twoheadrightarrow Y$, $W \rightarrow Z$, $W \cap Y = \emptyset$ og $Z \subseteq Y$, så $X \rightarrow Z$

Regelsettet er sunt og komplett for MVDer og FDer

Bevis for slutningsregel 7

- Hvis $X \rightarrow Y$, så $X \twoheadrightarrow Y$
- Bevis:
 - Anta at $t_1[X] = t_2[X]$
 - Siden $X \rightarrow Y$, er $t_1[Y] = t_2[Y]$
 - Velg $u_1 = t_2$ og $u_2 = t_1$
 - Da er u_1 lik t_1 på X og Y og lik t_2 utenfor Y , mens u_2 er lik t_2 på X og Y og lik t_1 utenfor Y
 - Men da har vi per def. en MVD $X \twoheadrightarrow Y$


Bevis for slutningsregel 8

Hvis $X \twoheadrightarrow Y$, $W \rightarrow Z$, $W \cap Y = \emptyset$ og $Z \subseteq Y$, så $X \rightarrow Z$

Bevis:

- Anta at $t_1[X] = t_2[X]$
- Siden $X \twoheadrightarrow Y$, finnes u_1 og u_2 der u_1 er lik t_1 på X og Y og lik t_2 utenfor Y , og u_2 er lik t_2 på X og Y og lik t_1 utenfor Y
- Spesielt er $t_1[W] = u_2[W]$, og siden $W \rightarrow Z$, er $t_1[Z] = u_2[Z] = t_2[Z]$ (den siste fordi $Z \subseteq Y$)
- Altså har vi en FD $X \rightarrow Z$

Høyere normalformer, oversikt



Utgangspunkt for normalformen

4NF

- Alle integritetsregler er i form av FDer og MVDer
(foruten domeneskranker og fremmednøkler)

Fjerde normalform

- **Definisjon 4NF** (Fagin 1977):
En relasjon R er på **fjerde normalform** hvis alle ikke-trivielle MVDer $X \twoheadrightarrow Y$ tilfredsstiller følgende:
 - i. X er en supernøkkel i R

Egenskaper ved 4NF

- $4NF \subseteq BCNF$

For å bevise det må vi vise at hvis R er 4NF og $X \rightarrow Y$ er en ikke-triviell FD i R , så er X en supernøkkel (Beviset følger på neste lysark)

- Når er en relasjon BCNF, men ikke 4NF?

Svar:

- Når alle ikke-trivielle FDer $X \rightarrow Y$ er slik at X er en supernøkkel, samtidig som det fins en ekte MVD $Z \twoheadrightarrow W$ der Z ikke er en supernøkkel

Bevis for at $4NF \subseteq BCNF$

- Anta at R er $4NF$ og at vi har en ikke-triviell FD $X \rightarrow Y$ i R
- Siden FD-er er MVD-er, har vi at $X \twoheadrightarrow Y$
- Hvis denne MVD-en er ikke-triviell, er X en supernøkkel (fordi R er $4NF$)
- Hvis MVD-en er triviell, er $R = XY$, så X er en supernøkkel da også
- Altså er R på $BCNF$

Eksempel på brudd på 4NF

Emne

Kode	Lærebok	Foreleser
INF1010	Java-II	Arne
INF1010	Java-II	Ellen
INF1010	OOhefte	Arne
INF1010	OOhefte	Ellen
INF1050	Kjernen	Erik
INF1050	Kjernen	Tone
INF1050	Kjernen	Gerhard
INF1050	PHP	Erik
INF1050	PHP	Tone
INF1050	PHP	Gerhard
INF1050	Web	Erik
INF1050	Web	Tone
INF1050	Web	Gerhard

Emne har ingen ikke-trivielle FD-er,
men en ekte MVD: kode \twoheadrightarrow lærebok

Emne kan dekomponeres slik:

Lærebok

Kode	Lærebok
INF1010	Java-II
INF1010	OOhefte
INF1050	Kjernen
INF1050	PHP
INF1050	Web

Foreleser

Kode	Foreleser
INF1010	Arne
INF1010	Ellen
INF1050	Erik
INF1050	Tone
INF1050	Gerhard

Normalformer utover 4NF

(Kursorisk pensum)

- 5NF (Maier 1983)
- PJNF: Project-Join Normal Form (Fagin 1979)
- DKNF: Domain Key Normal Form (Fagin 1981)

Joinavhengigheter

- La R være en relasjon og la $D=\{R_1,\dots,R_m\}$ være en dekomposisjon av R . Dersom D er tapsfri, sier vi at D tilfredsstillers en **JD** (Join Dependency)
- En JD kalles triviell dersom $R \in D$
- Teorem (Fagin 1977): Hvis $m=2$, dvs $D=\{R_1,R_2\}$, tilfredsstillers D en JD hvis, og bare hvis, vi har en MVD $X \twoheadrightarrow Y$ der $X=R_1 \cap R_2$ og $Y=R_2 - R_1$
- Dette betyr at en MVD er det samme som en JD for en dekomposisjon med 2 komponenter

Ekte dekomposisjoner og 5NF

- En dekomposisjon $D = \{R_1, \dots, R_m\}$ kalles **ekte** hvis det ikke finnes i og j med $i \neq j$ og $R_i \subseteq R_j$ (en slik R_i vil alltid være overflødig fordi den ikke kan bidra til å gjøre D tapsfri)
- En relasjon R er på **5NF** hvis alle ekte tapsfri dekomposisjoner av R bare består av supernøkler
- Hvis vi fortsetter å tapsfritt dekomponere en relasjon på 5NF, så vil ikke dekomposisjonen bety noen reduksjon i antall tupler eller verdier som må lagres, tvert imot vil lagerbehovet *øke*

PJNF (Project/Join Normal Form)

- En relasjon R er på PJNF hvis alle JD-er i R er en konsekvens av kandidatnøkklene
- Mer presist: R er på PJNF hvis alle ekte tapsfri dekomposisjoner D er nøkkelsammenhengende i henhold til følgende algoritme:
 - Så lenge det finnes to komponenter i D hvor snittet er en supernøkkel, så bytt ut de to komponentene med deres union
 - Hvis prosessen terminerer med $D=\{R\}$, er D nøkkelsammenhengende, ellers ikke

DKNF (Domain-Key Normal Form)

- En relasjon R er på DKNF hvis de eneste integritetsreglene i R er nøkkelrestriksjoner og domenerestriksjoner
- DKNF er lett å håndheve, men det er for mange integritetsregler som ikke kan uttrykkes på denne måten til at vi kan begrense oss til å ha komponenter på DKNF

Oppsummering av høye normalformer

- En relasjon R er på 4NF hvis, og bare hvis, alle ekte tapsfri dekomposisjoner med to komponenter består av to supernøkler
(Dette bevises ved å vise at en join av to supernøkler er tapsfri hvis, og bare hvis, deres snitt er en supernøkkel)
- 5NF er (ekte) inneholdt i 4NF
- Både PJNF og DKNF er (ekte) inneholdt i 5NF
- Det finnes relasjoner som er i PJNF, men ikke i DKNF, og omvendt
- Ragnar Normann: “5NF og PJNF burde bytte navn (det burde 3NF og BCNF også, men vi kan ikke forandre historien)”