

Relasjonsdatabasedesign

Normalformer

Hvordan dekomponere tapsfritt

Fagins teorem

Gitt et relasjonsskjema $R(XYZ)$ med FDer F .
En dekomposisjon $D=\{XY, YZ\}$ er tapsfri mhp. F
hvis og bare hvis minst en av følgende holder:

1) $Y \rightarrow X \in F^+$

2) $Y \rightarrow Z \in F^+$

Her er F^+ mengden av alle FDer som kan avledes
av F

Eksempel: $R(A,B,C,D)$, $F=\{C \rightarrow AD\}$

Dekomposisjon: $R_1(A,C,D)$, $R_2(B,C)$

Normalformer

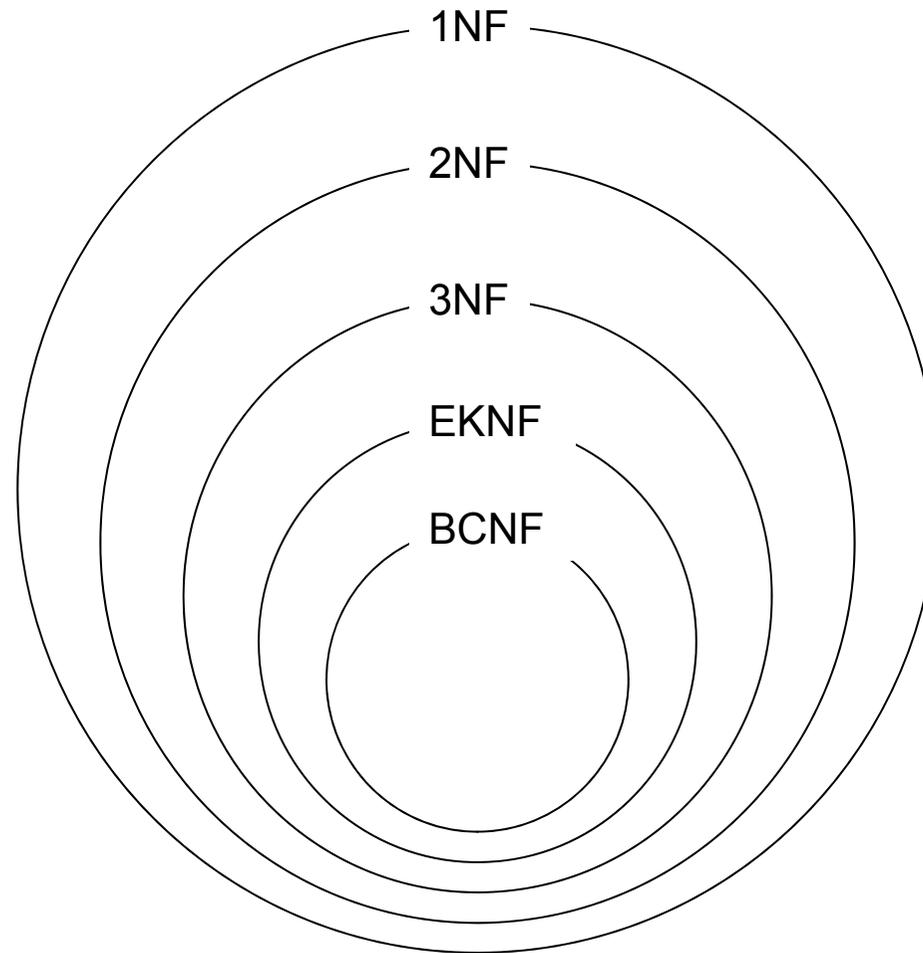
- Normalformer er et uttrykk for hvor godt vi har lykket i en dekomposisjon
- Jo høyere normalform, jo færre oppdateringsanomalier
- Det fins algoritmer for å omforme fra lavere til høyere normalformer

Utgangspunkt for normalformene

1NF-BCNF

- Alle integritetsregler er i form av FDer
(i tillegg til domeneskranker og fremmednøkler)

Normalformer, oversikt



Første normalform

- **Definisjon 1NF** (Codd 1972):
 - Alle domener består av atomære verdier
 - Funksjonsverdien til et tuppel for et gitt attributt skal være en slik atomær verdi (eller nil)
- Alle relasjoner er automatisk på 1NF

Andre normalform

- Repetisjon: En FD $X \rightarrow Y$ er ikke-triviell hvis Y ikke er inneholdt i X , dvs. hvis $Y - X \neq \emptyset$
- **Definisjon 2NF** (Codd 1972):
En relasjon R er på **andre normalform** hvis alle ikke-trivielle FDer i R på formen $X \rightarrow A$, der X er en mengde attributter og A et attributt i R , tilfredsstiller minst ett av følgende:
 - i. X er en supernøkkel i R
 - ii. A er et nøkkelattributt i R
 - iii. $X \not\subseteq K$ for noen kandidatnøkkel K i R

Egenskaper ved 2NF

- $2NF \subseteq 1NF$ siden alle relasjoner er 1NF
- Når er en relasjon 1NF, men ikke 2NF?

Svar: Når det fins en ikke-triviell FD $X \rightarrow A$ og en kandidatnøkkel K hvor $X \subset K$, $X \neq K$ og A ikke er et nøkkelattributt

Eksempel: $R(A, B, C, D)$, $F = \{BC \rightarrow D, C \rightarrow A\}$

Dekomposisjon: $R_1(A, \underline{C})$, $R_2(\underline{B}, \underline{C}, D)$

- 2NF er mest av historisk interesse; vi gjør sjelden feil som bryter 2NF

Tredje normalform

- **Definisjon 3NF** (Codd 1972):
En relasjon R er på **tredje normalform** hvis alle ikke-trivielle FDer i R på formen $X \rightarrow A$ tilfredsstiller minst ett av følgende:
 - i. X er en supernøkkel i R
 - ii. A er et nøkkelattributt i R

Egenskaper ved 3NF

- $3NF \subseteq 2NF$ fordi kravene til 3NF er en skjerping av kravene til 2NF

- Når er en relasjon 2NF, men ikke 3NF?

Svar: Når det fins en ikke-triviell FD $X \rightarrow A$ hvor X ikke er en supernøkkel og A ikke er et nøkkelattributt og $X \not\subseteq K$ for noen kandidatnøkkel K

Eksempel: $R(A, B, C)$, $F = \{A \rightarrow BC, B \rightarrow C\}$

Dekomposisjon: $R_1(\underline{A}, B)$, $R_2(\underline{B}, C)$

- Også 3NF er lett å oppnå

Elementære FDer og nøkler

- En FD $X \rightarrow A$ kalles *elementær* dersom
 - A er ett attributt
 - $X \rightarrow A$ er ikke-triviell
 - X er minimal
(dvs. at hvis $Y \subseteq X$ og $Y \rightarrow A$, så er $Y = X$)
- En kandidatnøkkel K kalles *elementær* hvis det finnes en elementær FD $K \rightarrow B$ i R

Elementary Key Normal Form

- **EKNF** (Zaniolo 1982) (kursorisk pensum)
- **Definisjon EKNF**: En relasjon R er på **elementary key normal form** hvis alle ikke-trivielle FDer i R på formen $X \rightarrow A$ tilfredsstiller minst ett av følgende:
 - i. X er en supernøkkel i R
 - ii. A er et attributt i en elementær kandidatnøkkel i R

Egenskaper ved EKNF

- $EKNF \subseteq 3NF$ fordi kravene til EKNF er en skjerping av kravene til 3NF
- Når er en relasjon 3NF, men ikke EKNF?

Svar: Når det fins en ikke-triviell FD $X \rightarrow A$ hvor X ikke er en supernøkkel og A er et attributt i en ikke-elementær kandidatnøkkel

Eksempel: $R(A,B,C)$, $F = \{C \rightarrow A, A \rightarrow C\}$

(Her kan A =epostadresse, B =emnekode og C =fødselsnummer på studenter)

Mulig dekomposisjon: $R_1(\underline{A}, \underline{B})$, $R_2(\underline{A}, \underline{C})$

Boyce-Codd Normalform

- **Definisjon BCNF** (Boyce & Codd 1974):
En relasjon R er på **Boyce-Codd normalform** hvis alle ikke-trivielle FDer i R på formen $X \rightarrow A$ tilfredsstiller følgende:
 - i. X er en supernøkkel i R

Egenskaper ved BCNF

- $BCNF \subseteq EKNF$ fordi kravene til BCNF er en skjerping av kravene til EKNF
- Når er en relasjon EKNF, men ikke BCNF?
- Svar: Når det fins en ikke-triviell FD $X \rightarrow A$ hvor X ikke er en supernøkkel og A er et attributt i en elementær kandidatnøkkel

Egenskaper ved BCNF (forts.)

- Eksempel: $R(A,B,C)$, $F=\{AB \rightarrow C, C \rightarrow A\}$
Dekomposisjon til BCNF: $R_1(\underline{B}, \underline{C})$, $R_2(\underline{A}, \underline{C})$
- Merk: FDen $AB \rightarrow C$ kan ikke sjekkes i R_1 eller R_2 alene: Vi må ta en join av R_1 og R_2 før vi kan teste om $AB \rightarrow C$.
- Hvis alle FDer etter dekomposisjonen kan sjekkes lokalt i en av de nye relasjonene, sier vi at dekomposisjonen er **FD-bevarende**.
 - I eksempelet over er dekomposisjonen **ikke FD-bevarende**.
- Man kan alltid dekomponere til BCNF, men ikke alltid FD-bevarende.
- Man kan alltid dekomponere FD-bevarende til EKNF.

Eksempel: Studenter

Student(Stud#, Brukernavn, Emnekode, Karakter)

FDer: Stud# \rightarrow Brukernavn

Brukernavn \rightarrow Stud#

Stud# Emnekode \rightarrow Karakter

Hvilke av normalformene 1NF-BCNF tilfredsstiller denne?

Hvorfor BCNF ikke alltid er gunstig

- Dersom vi har en dekomposisjon som ikke er FD-bevarende, må vi foreta en join mellom relasjonsskjemaene i forbindelse med oppdateringer for å sjekke at integritetsreglene overholdes
- Vi har valget mellom
 - Enten:* Gå tilbake til EKNF (3NF) og bryte BCNF og godta dobbeltlagring som vi må ta hensyn til ved oppdateringer slik at FDene overholdes
 - Eller:* Beholde BCNF og foreta join mellom relasjoner for å sjekke at FDer overholdes ved oppdateringer

Oppsummering normalisering

- Brudd på normalformer gir opphav til dobbeltlagring
 - Jo høyere normalform, desto mindre dobbeltlagring
- BCNF: Alle FDer er i form av kandidatnøkler.
Dvs. ingen dobbeltlagring *innen relasjonsskjemaet*.
Men: Noen FDer kan gå på tvers av relasjonsskjemaer
- EKNF (3NF): Ingen FDer går på tvers av relasjonsskjemaer, men det kan være noen FDer innen et relasjonsskjema som gir opphav til dobbeltlagring
- Krav til dekomposisjon: Den må være **tapsfri**, dvs. aldri kunne gi opphav til falske tupler
 - Det er en fordel om dekomposisjonen også er **FD-bevarende** (dvs. at ingen FDer går på tvers av relasjonsskjemaer)

Det fins algoritmer som...

- Tester om en dekomposisjon er tapsfri (Chasealgoritmen)
- Tester om en dekomposisjon er FD-bevarende
- Dekomponerer relasjonsskjemaer tapsfritt og FD-bevarende
 - Garanterer EKNF, men gir ikke alltid BCNF
- Dekomponerer relasjonsskjemaer tapsfritt til BCNF
 - Er ikke alltid FD-bevarende

Tapsfri dekomposisjon til BCNF

Gitt en relasjon R med et sett F Der F

1. Hvis $X \rightarrow Y$ er et brudd på BCNF:

1. Beregn X^+

2. Dekomponer R i R_1 og R_2 der R_1 er lik X^+ og R_2 er lik X samt alle attributtene i R som ikke er i X^+

2. Fortsett på samme måte med R_1 og R_2 inntil alle relasjonene i dekomposisjonen tilfredsstillers BCNF.

Eksempel: Studenter

Student(Stud#, Brukernavn, Emnekode, Karakter)

FDer: Stud# → Brukernavn

Brukernavn → Stud#

Stud# Emnekode → Karakter

Hvordan dekomponere denne til BCNF?

Minimale overdekninger

La F være en mengde FDer over relasjon R .
En **minimal overdekning** for F er en mengde FDer G som er ekvivalent med F og som tilfredsstiller følgende krav:

- Alle høyresidene i G er atomære
- Venstresidene er minst mulige
- Ingen av FDene i G er overflødige

Algoritme for å finne minimale overdekninger

1. Initialiser G til F .
2. Lag atomære høyresider ved hjelp av splitting.
3. Gjør venstresidene minimale:
For hver $X \rightarrow A$ i G og hver $B \in X$:
 1. Beregn $(X-B)^+$ med hensyn på G .
 2. Hvis $A \in (X-B)^+$, erstatt $X \rightarrow A$ med $(X-B) \rightarrow A$ i G .
4. Fjern overflødige FDer:
For hver $X \rightarrow A$ i G :
 1. Beregn X^+ med hensyn på G uten å bruke $X \rightarrow A$.
 2. Hvis $A \in X^+$, fjern $X \rightarrow A$ fra G .

Tapsfri FD-bevarende dekomposisjon til EKNF

Gitt en relasjon R med et sett F Der F .

1. Finn en minimal overdekning G for F .
2. For hver X som opptrer som venstreside i G , finn alle $X \rightarrow A_i$ i G og lag en relasjon R_X som inneholder X samt alle høyresidene A_i .
3. Hvis det finnes attributter som ikke er med i noen R_X , lag en egen relasjon R_0 med disse.
4. Hvis hverken R_0 eller noen R_X er en supernøkkel, utvid R_0 til en kandidatnøkkel.

Eksempel

- $R(A,B,C,D,E,F,G,H)$
- FDer: $AB \rightarrow CH$, $DE \rightarrow FG$, $D \rightarrow H$, $H \rightarrow G$
- Hva er høyeste normalform som R tilfredsstiller?
- Dekomponer R tapsfritt og FD-bevarende til EKNF.

Høyere normalformer

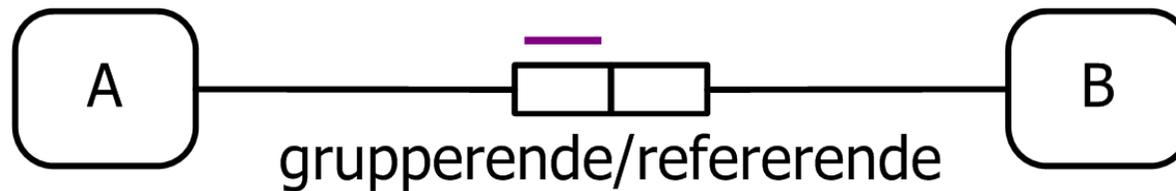
- Det finnes relasjoner som tilfredsstillter BCNF, men likevel kan gi oppdateringsanomalier.
- Dette skyldes blant annet flerverdiavhengigheter (MVDer), som er en generalisering av FDer.
- Høyere normalformer kan eliminere også noen av disse oppdateringsanomaliene.

Ekstramateriale og repetisjon fra INF1300 (kursorisk pensum)

ORM og normalisering

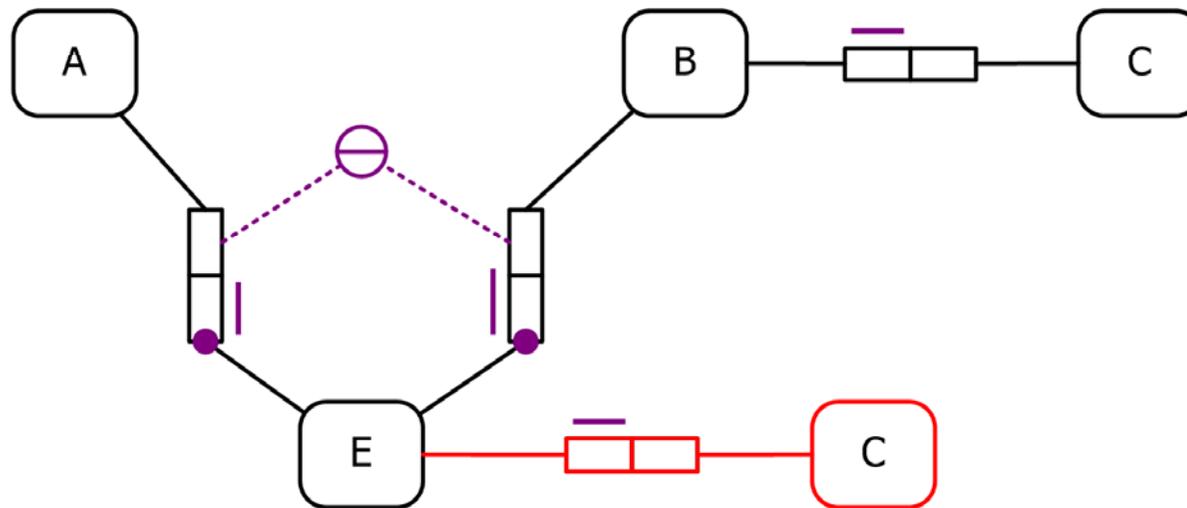
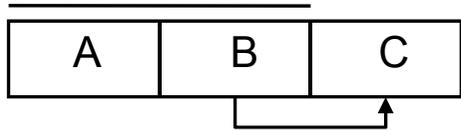
- Gruppering av "korrekte" ORM-diagrammer gir **alltid** 3NF
- Gruppering av "korrekte" ORM-diagrammer gir **som regel** BCNF. Unntak skyldes alltid problemer knyttet til ekvivalente stier.
 - Det samme gjelder EKNF: Gruppering der EKNF er brutt, skyldes alltid problemer knyttet til ekvivalente stier.

ORM og 1NF



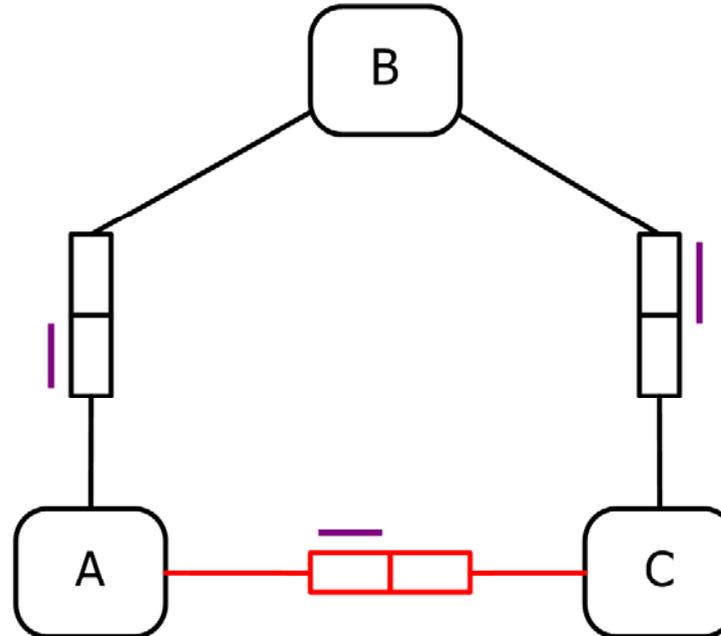
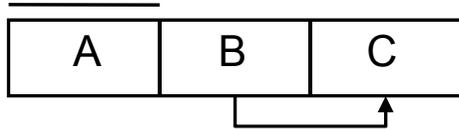
Den grupperende rollen er altid entydig.
Datamodellen blir altid 1NF.

ORM og 2NF



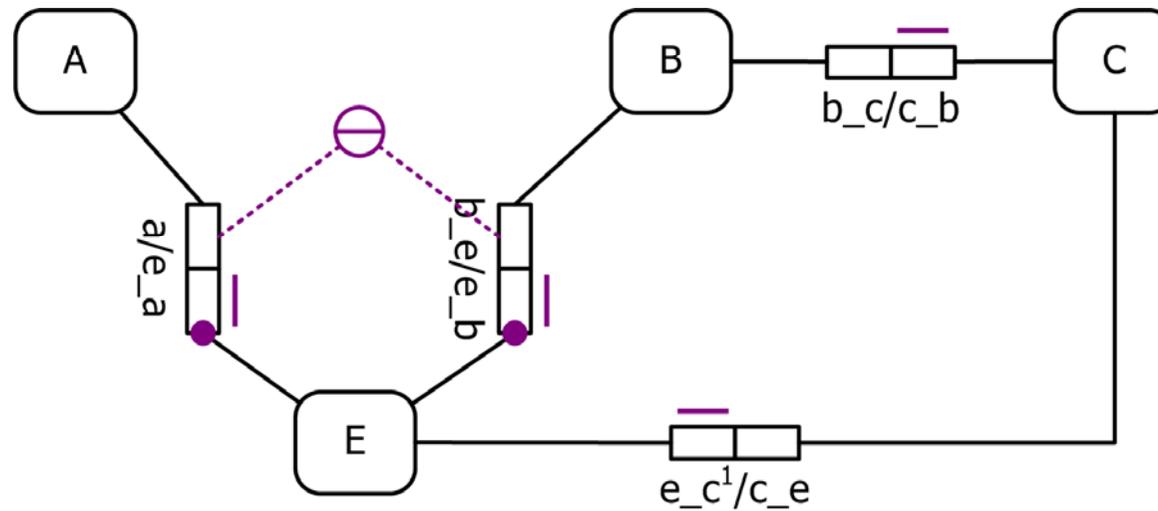
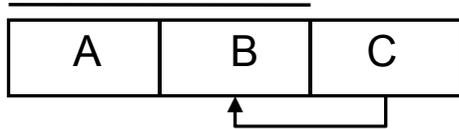
Hvis $B \rightarrow C$ plasseres på E også, vil 2NF bli brutt.

ORM og 3NF



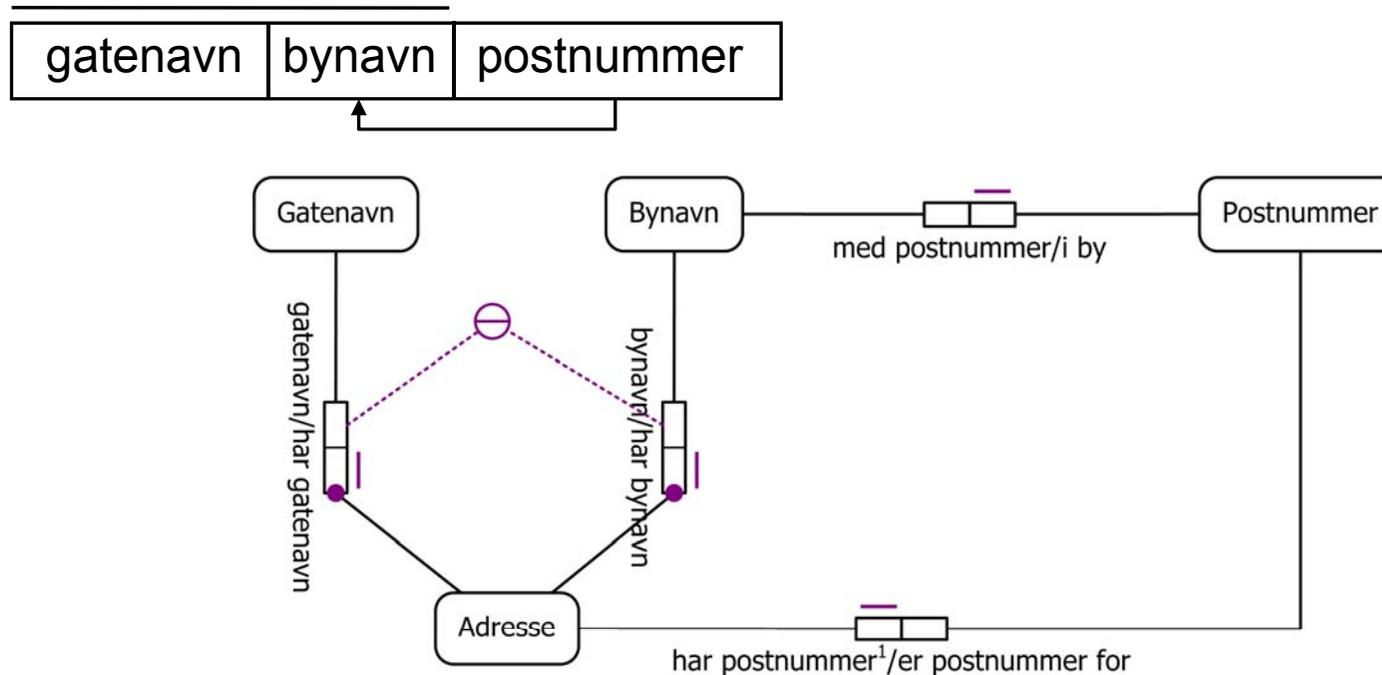
Hvis $A \rightarrow C$ representeres i tillegg til $A \rightarrow B$, $B \rightarrow C$, vil 3NF bli brutt

ORM og BCNF



¹if an $E e_c C c_b$ a B
 then that $E e_b$ that B

ORM og BCNF – eksempel



¹hvis en Adresse har postnummer et Postnummer i by et Bynavn
så skal det være slik at samme Adresse har bynavn samme Bynavn

Gruppert ORM-modell:



pluss en "ekkel" integritetsregel som ivaretar sjekk av de ekvivalente stiene