

Normalisering

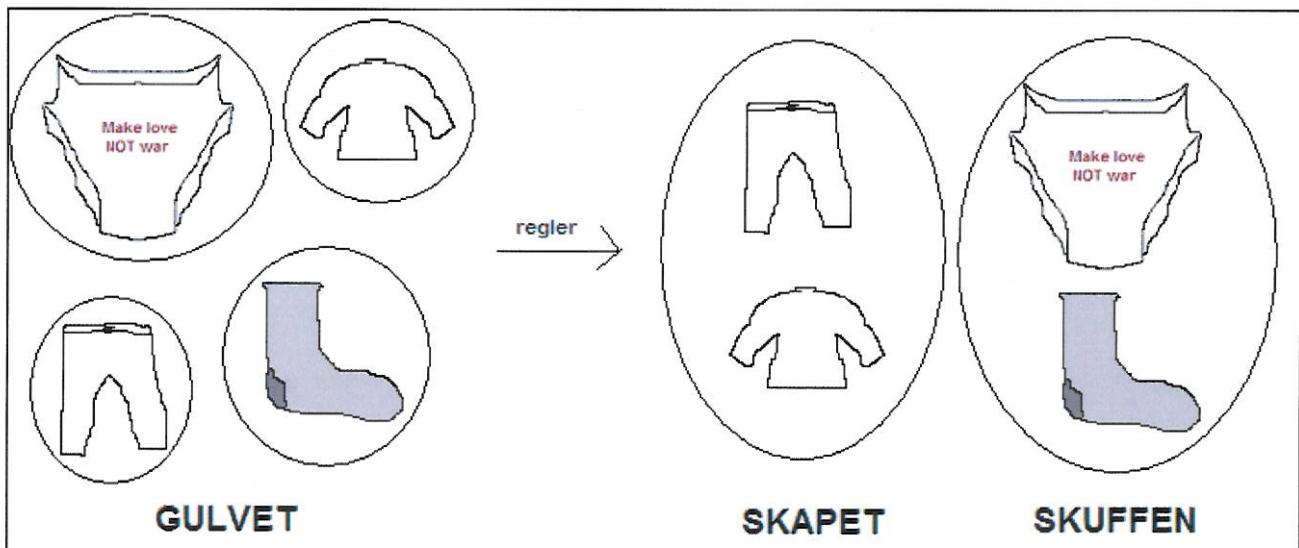
Elin K. Ajer Andreassen, 2009

Hva er normalisering?

Normalisering er en prosess en samling data må gjennom for å bli en god database eller en god datamodell. Med en god database menes her en samling tabeller som er godt strukturert slik at man i minst mulig grad dupliserer data.

Prosessens starter med et avgrenset, definert kaos og ender opp som en ordnet struktur.

Som en del av prosessen inngår også å sette opp hvilke forutsetninger datamodellen må forholde seg til. For å gjennomføre normaliseringss prosessen, har man et sett med regler for hvordan man steg for steg skal komme seg fram til målet.



Hvorfor er det viktig å normalisere en datamodell eller en database?

Det er mange viktige grunner til hvorfor man må normalisere datamodeller eller databaser. Det viktigste er effektivitet. Med effektivitet menes at man må kunne oppdatere, legge inn og slette data med færrest mulig operasjoner, samtidig som mulighetene for feil i forbindelse med slike operasjoner blir redusert til et minimum. Det er også viktig med normalisering for å redusere størrelsen på en database(lagringsplass for data - kosteffektivitet) ved å forhindre overflødig data(duplisering) i databasen.

Før jeg går løs på selve normaliseringsprosessen, er det en del begreper det er viktig å kjenne til og forstå. Noen av disse begrepene er repetisjon fra tidligere, mens annet er helt nytt.
Jeg vil bruke følgende ikke-normaliserte tabell for å eksemplifisere noen av begrepene:

Barnehage

id	navn	adresse	postnr	poststed	telefon_nr	avd_id	avd_navn
1	Dyreskogen	Torvildtoppen 3	1752	Halden	69 188888	1	Rev
1	Dyreskogen	Torvildtoppen 3	1752	Halden	69 188888	2	Ulv
2	Blomsterenga	Ertemoen 3	1781	Halden	69 177777	1	Fjellfiol
3	Solgløttheimen	Solgløttveien 32	1767	Halden	69 178888	1	Lilla
3	Solgløttheimen	Solgløttveien 32	1767	Halden	69 178888	2	Oransj
3	Solgløttheimen	Solgløttveien 32	1767	Halden	69 178888	3	Turkis
4	Veivalget	Prærieheia	1782	Halden	69 185555	1	Høyre
4	Veivalget	Prærieheia	1782	Halden	69 185555	2	Venstre
5	Tittetua	Folkeveien 32	1792	Tistedal	69 199999	1	Tyttebær
6	Ysteråsen	Ysteråsen 543	1777	Halden	69 198888	1	Elg
6	Ysteråsen	Ysteråsen 543	1777	Halden	69 198888	2	Rev

Forutsetninger:

- flere barnehager kan ha samme navn, men ikke samme id
- flere barnehager kan ha samme adresse, men ikke samme telefonnr
- en barnehage kan ikke ha flere telefonnumre
- flere avdelinger innen samme barnehage kan ikke ha samme navn eller id, men det kan finnes avdelinger i andre barnehager med samme avdelingsnavn og/eller avdelings-id.

Noen viktige begreper om verdier og relasjoner

Atomær verdi:

Et attributt som ikke inneholder delverdier (det kan ikke deles opp noe mer).

Fra vårt eksempel: **adresse** kan i noen tilfeller ses på som en ikke-atomær verdi.

Repeterende grupper:

At det finnes mer enn en verdi i krysset mellom rad og kolonne i en tabell.

Universalrelasjon:

Det halvordnede kaos som vi skal rydde opp i gjennom normaliseringsprosessen. I universalrelasjonen er alle data samlet i en tabell, og det finnes ingen regler annet enn at man har rader og kolonner.

Noen viktige begreper om nøkler



Supernøkkel: Ett eller flere attributter som sammen identifiserer en entitet unikt.

Eksemplet vårt inneholder blant annet følgende supernøkler:

(**id, navn, adresse, postnr, poststed, telefon_nr, avd_id, avd_navn**)
(**id, navn, telefon_nr, avd_id, avd_navn**)
(**id, navn, avd_id, avd_navn**)
(**id, navn, avd_id**)
(**id, telefon_nr, avd_id**)
(**navn, telefon_nr, avd_id**)
(**navn, telefon_nr, avd_navn**)
(**id, avd_id**)
(**id, avd_navn**)
(**telefon_nr, avd_id**)
(**telefon_nr, avd_navn**)



Kandidatnøkkel: Minimalistisk supernøkkel.
Har kun det antall attributter som er nødvendig for å være unik.

Eksemplet vårt inneholder følgende kandidatnøkler:

(**id, avd_id**)
(**id, avd_navn**)
(**telefon_nr, avd_id**)
(**telefon_nr, avd_navn**)



Primærnøkkel: En kandidatnøkkel som velges som *hovednøkkel* for en tabell. (dersom en tabell har flere kandidatnøkler)

Eksemplet vårt inneholder følgende primærnøkkel:

(**id, avd_id**)



Fremmednøkkel: Ett eller flere attributter i en tabell som *peker på* en primærnøkkel(som også er ett eller flere attributter) i en annen tabell.

Noen viktige begreper om avhengighet

- Funksjonell avhengighet: Det at ett eller flere attributter entydig bestemmer verdien av ett eller flere andre attributter.
- Eksemplet vårt inneholder følgende funksjonelle avhengigheter:
(navn, adresse, postnr, poststed, telefon_nr, avd_id, avd_navn) er funksjonelt avhengig av id
(navn, adresse, postnr, poststed, telefon_nr) er funksjonelt avhengig av id
navn er funksjonelt avhengig av id
adresse er funksjonelt avhengig av id
telefon_nr er funksjonelt avhengig av id
postnr er funksjonelt avhengig av id
poststed er funksjonelt avhengig av id
poststed er funksjonelt avhengig av postnr
avd_navn er funksjonelt avhengig av (id, avd_id)
- Full funksjonell avhengighet: Det at ett eller flere attributter er avhengig av hele primærnøkkelen.
- Eksemplet vårt inneholder følgende fulle funksjonelle avhengigheter:
avd_navn er fullt funksjonelt avhengig av (id, avd_id)
- Determinant/Determinering: Attributt eller gruppe attributter som et annet attributt(eller en gruppe attributter) er fullt funksjonelt avhengig av.
- Determinering uttrykkes med tegnet →
- Eksemplet vårt inneholder følgende determineringer:
- id → (navn, adresse, postnr, poststed, telefon_nr, avd_id, avd_navn)**
id → (navn, adresse, postnr, poststed, telefon_nr)
id → navn
id → adresse
id → telefon_nr
id → postnr
id → poststed
postnr → poststed
(id, avd_id) → avd_navn
(id, avd_navn) → avd_id
(telefon_nr, avd_id) → avd_navn
(telefon_nr, avd_navn) → avd_id
telefon_nr → id
- Partiell avhengighet: Det at ett eller flere attributter er avhengig av kun deler av primærnøkkelen.
- Eksemplet vårt inneholder følgende partielle avhengigheter:
(navn, adresse, postnr, poststed, telefon_nr) partielt avhengig av id
navn er partielt avhengig av id
adresse er funksjonelt avhengig av id
telefon_nr er partielt avhengig av id
postnr er partielt avhengig av id
poststed er partielt avhengig av id
- Transitiv avhengighet: Det at et attributt er avhengig av et annet ikke-primærnøkkel-attributt.
- Eksemplet vårt inneholder følgende partielle avhengigheter:
poststed er transitivt avhengig av postnr (skrives: id → postnr → poststed)

Fra Universalrelasjon til Boyce-Codd: Normalisering i praksis

Eksempel 1: Legekontor

- Forutsetningene:
- En lege kan bare være tilknyttet et legekontor av gangen
 - En leges spesialitet følger legekontor
 - Det kan ikke flere legekontor på samme adresse
 - Alle leger på et legekontor har telefonnummer (sentralborddame)
 - Det kan finnes flere legekontor med samme navn

Universellrelasjon

Prinsipperne:

lege_id	legename	lege_spesialitet	tilknyttet_legekontor_id	legekontor	legekontor_adr	legekontor_tlf	legekontor_periode
1	Olav Kriven		1	Ulvaseien legekontor	Ulvaseien 79, 1765 Halden	69 218743	1.1.2009 - 31.12.2012
2	Solveig Skrue	gynekolog, sexologi, eurologi	4	Storgata 543, 1751 Halden	69 215454	1.1.2006 - 31.12.2008	
3	Sune Skogmann		3	Summerasen 4, 1792 Tistedal	69 184564	1.1.2006 - 31.12.2010	
4	Pingelius Pang	neurolog, indremedisin	2	Bakke, 1765 Halden	69 215454	1.1.2005 - 31.12.2008	
			3	Iddelforden naturgesæter	Summerasen 4, 1792 Tistedal	69 184564	1.1.2008 - 31.12.2011

Definition av 1. normalform:

"For at en tabell skal være i 1. normalform(NF), må den ikke inneholde repeterende grupper eller ikke-atomære verdier"

Finn som brettet mot 1. normalform:

Repetende grupper: tilknyttet_legekontor_id, legekontor, legekontor_adresse, legekontor_tlf, legekontor_periode

Ikke-atomære verdier: lege_spesialitet, legekontor_id, legekontor_adr, legekontor_periode
der er et spørsmål om også legens navn er en ikke-atomær verdi, men dette avhenger av hva som er mest praktisk for den enkelte database eller datamodell

Hva må vi gjøre for å få universellrelasjonen over på 1NF?

Dat er to matér å gjøre det på:

Metode 1: Flate ut tabellen ved å spille alle rader som inneholder repeterende verdier

Metode 2: Opprette en ny tabell som inneholder de repeterende verdiene. Primærnøkkelen i den nye tabellen, blir fremmednøkkelen i den gamle tabellen

Vi holder oss til metode 1!

1. Normalform

Lesning 1

lege_id	legename	lege_spesialitet	tilknyttet_legekontor_id	legekontor	legekontor_adr	legekontor_poststed	legekontor_tlf	legekontor_periode_fra	legekontor_periode_til
1	Olav Kriven	kirurg	1	Ulvaseien 79	1765	Halden	69 218743	31.12.2013	01.01.2009
1	Olav Kriven	gynekolog	4	Storgata 543	1751	Halden	69 215452	31.12.2008	01.01.2006
2	Solveig Skrue	gynekolog	2	Summerasen 4	1792	Tistedal	69 215454	01.01.2006	31.12.2010
2	Solveig Skrue	sexologi	2	Summerasen 4	1792	Tistedal	69 215454	01.01.2006	31.12.2010
2	Solveig Skrue	eurologi	2	Summerasen 4	1792	Tistedal	69 215454	01.01.2006	31.12.2010
2	Solveig Skrue	gynekolog	3	Bakke	1765	Halden	69 184564	01.01.2002	31.12.2005
2	Solveig Skrue	sexologi	3	Bakke	1765	Halden	69 184564	01.01.2002	31.12.2005
2	Solveig Skrue	eurologi	3	Bakke	1765	Halden	69 184564	01.01.2002	31.12.2005
3	Sune Skogmann	neurolog, indremedisin	2	Summerasen 4	1792	Tistedal	69 184564	01.01.2005	31.12.2008
4	Pingelius Pang	indremedisin	3	Bakke	1765	Halden	69 184564	01.01.2008	31.12.2011

Lesning 2

lege_id	legename	lege_spesialitet	lege_spesialitet2	lege_spesialitet3	tilknyttet_legekontor_id	legekontor	legekontor_adr	legekontor_poststed	legekontor_tlf	legekontor_periode_fra	legekontor_periode_til
1	Olav Kriven	kirurg	NULL	4	1	Ulvaseien 79	1765	Halden	69 218743	31.12.2013	01.01.2009
1	Olav Kriven	gynekolog	NULL	2	Summerasen 4	1792	Tistedal	Halden	69 215452	31.12.2008	01.01.2006
2	Solveig Skrue	gynekolog	sexologi	3	4	Santum legekontor	1765	Tistedal	69 215454	31.12.2010	01.01.2006
2	Solveig Skrue	gynekolog	sexologi	3	2	Hayresvingen legekontor	1765	Halden	69 184564	31.12.2005	01.01.2002
3	Sune Skogmann	neurolog, indremedisin	NULL	NULL	2	Iddelforden naturgesæter	1765	Tistedal	69 215454	31.12.2005	01.01.2002
4	Pingelius Pang	indremedisin	NULL	3	4	Iddelforden naturgesæter	1765	Halden	69 184564	31.12.2008	01.01.2011

Hvorfor er lesning 2 en dårlig lesning?

Slik korder er ikke godt og redusert.

- Det blir mange tomme rader for leger med fire eller mer enn tre spesialiteter.

- Det er ikke god struktur, dersom en lege har mer enn tre spesialiteter.

V holdes oss til lesning 1!

Definition av 2. normalform:

"For at en tabell skal være i 2. normalform(2NF), må alle attributter være fullt funksjonelt avhengig av primærnøkkelen"

Finn som brettet mot 2. normalform:

På samme måte som før, men med en ekstra spesialitet:

Ideeltiden legekontor_id paa tilknyttet_legekontor_id

Ideeltiden legekontor_id paa legekontor_id

Hvorfor er ikke legekontor_id parallelt avhengig av legekontor_id mens legekontor_id er samme legekontor?

Det kan finnes flere legekontor på samme adresse, men ikke flere legekontor med samme legekontor_id

Hva må vi gjøre for å få tabellen over fra 2NF?

Vi må spille tabellen i flere tabeller, slik at det ikke er noen partielle avhengigheter igjen

2. Normalform

Legekontor	
legekontor_id	Legekontor
1	Ullevålen legekontor
4	Sæntum legekontor
2	Hayresvingen legekontor
3	Iddefjordens naturlegesenter

Supermøkter:
 (legekontor_id, legekontor, legekontor_adr, legekontor_postnr, legekontor_poststed, legekontor_tlf)
 (legekontor_id, legekontor, legekontor_adr, legekontor_postnr, legekontor_poststed, legekontor_tlf)
 (legekontor_id, legekontor, legekontor_adr, legekontor_postnr, legekontor_poststed, legekontor_tlf)

Kandidatenkoker:

legekontor_id

Prømøkter:

legekontor_id

Lege

lege_id	legesnavn
1	Odar Kriven
2	Solve Skruve
3	Sune Skogmann
4	Pingelin Pang

Supernøkter:

(lege_id, legesnavn)

lege_id

Prømøkter:

lege_id

Kandidatenkoker:

(lege_id, legesnavn)

Prømøkter:

(lege_id, legesnavn)

Legespesialfelt

lege_id	lege_spesialfelt
1	kunngj.
2	gynækolog
2	syrologi
3	eurologi
3	neurologi
4	indremedisin

Supernøkter:

(lege_id, legespesialfelt)

Prømøkter:

(lege_id, legespesialfelt)

Kandidatenkoker:

(lege_id, legesnavn)

Prømøkter:

(lege_id, legesnavn)

Legeløgekontor

lege_id	legekontor_periode_fra	legekontor_periode_til	tilknyttet_legekontor
1	01.01.2009	31.12.2013	1
1	01.01.2008	31.12.2008	4
2	01.01.2006	31.12.2010	2
2	01.01.2002	31.12.2005	3
3	01.01.2005	31.12.2008	2
4	01.01.2008	31.12.2011	3

Supernøkter:

(lege_id, legekontor_periode_fra, legekontor_periode_til, tilknyttet_legekontor)

(lege_id, legekontor_periode_fra)

(lege_id, legekontor_periode_til)

(lege_id, legekontor_periode_fra)

(lege_id, legekontor_periode_til)

Kandidatenkoker:

(lege_id, legekontor_periode_fra)

(lege_id, legekontor_periode_til)

Prømøkter:

(lege_id, legekontor_periode_fra)

(lege_id, legekontor_periode_til)

Fordi må vægne en av kandidatenkokerne

Definisjon av 3. normalform:
 «For at en tabell skal være i 3. normalform(3NF), må det ikke forekomme noen transitive avhengigheter»

Determineringer/Funksjonell avhengighet

Legekontor:

legekontor_id → legekontor

legekontor_id → legekontor_periode_fra

legekontor_id → legekontor_periode_til

Lege:

lege_id → legesnavn

LegeSpesialfelt:

(lege_id, legesnavn) → (lege_id, legespesialfelt)

LegeLegekontor:

(lege_id, legekontor_periode_fra) → (lege_id, legekontor_periode_til)

(lege_id, legekontor_periode_til) → (lege_id, legekontor_periode_fra)

Funn som brøter mot 3. normalform:
 $(\text{lege_id}, \text{legekontor_periode_fra}) \rightarrow \text{tilknyttet_legekontor}$
 $(\text{lege_id}, \text{legekontor_periode_til}) \rightarrow \text{tilknyttet_legekontor}$

Hva må vi gjøre for å få tabellen over på 3NF?

Vi må spille tabellen i flere tabeller, slik at det ikke er noen transitive avhengigheter igjen

3. Normalform

Legekontor

legekontor_id	legekontor
1	Ulvassæter legekontor
4	Sentrums legekontor
2	Høyresiden naturlegekontor
3	Iddafjorden naturgesenter

Determinanter: legekontor_id → (legekontor, legekontor_periode_fra, legekontor_periode_til)

Kandidatenkér: legekontor_id

Fremmedenkér: posteNr

Poststed

postnr	poststed
1765	Haalen
1751	Haalen
1792	Tistedal

Determinanter: posteNr → poststed

Kandidatenkér: posteNr

Fremmedenkér: ingen

Lege

lege_id	legesnavn
1	Oscar Kriien
2	Solveig Stue
3	Sune Skogmann
4	Prajillius Pang

Determinanter: lege_id → legesnavn

Kandidatenkér: lege_id

Fremmedenkér: ingen

LægeSpesialfelt

lege_id	lege_spesialfelt
1	Krurgi
2	Gynekolog
2	senolog
2	eurologi
3	neurologi
4	Indremedisin

Determinanter: (lege_id, lege_spesialfelt) → (lege_id, lege_spesialfelt)

Kandidatenkér: (lege_id, lege_spesialfelt)

Fremmedenkér: lege_id

LægeLegkontor

lege_id	legekontor_periode_fra	legekontor_periode_til	tilknyttet_legekontor
1	01.01.2009	31.12.2013	1
1	01.01.2006	31.12.2008	4
2	01.01.2006	31.12.2010	2
2	01.01.2002	31.12.2005	3
3	01.01.2005	31.12.2008	2
4	01.01.2008	31.12.2011	3

Determinanter: (lege_id, legekontor_periode_fra) → legekontor_periode_til og (lege_id, legekontor_periode_til) → tilknyttet_legekontor
 $(\text{lege_id}, \text{legekontor_periode_til}) \rightarrow \text{legekontor_periode_til}$
 $(\text{lege_id}, \text{legekontor_periode_til}) \rightarrow \text{tilknyttet_legekontor}$

Kandidatenkér: (lege_id, legekontor_periode_fra)

Fremmedenkér: lege_id

tilknyttet_legekontor

Definisjon av Boyce-Codd normalform.
"For at en tabel skal være i Boyce-Codd normalform(BCNF), må alle determinanter være kandidatnøkkler"

Vi har ingen brudd på BCNF

Det er yttersiden at det er brudd på BCNF, men det er viktig å sjekke det likevel!
Her er et tilfelle som KAN føre til brudd på BCNF:
- En relasjon som inneholder to eller flere kombinerte kandidatnøkkler
- Kandidatnøkkelen har minst ett felles attributt

Litt SQL

Ved hjelp av SQL kan man lage en sperring som viser data i 1. normalform.

```
SELECT lege_id, Legenavn, IsLege, spesialitet, lk_tilknyttet_legekontor, lk_legekontor, lk_legekontor_adr, lk_legekontor_periode_fra, lk_legekontor_periode_til
FROM Legekontor lk, Lega l, LegaSpesialFelt lsf, Lega_legekontor lk, Poststed p
WHERE lege_id = lk_lege_id
AND lk_lege_id = lsf_lege_id
AND lk_legekontor_id = lk_tilknyttet_legekontor
AND lk_legekontor_postnr = p.postnr;
```

Noen siste ord

Det er ikke så ofte man behøver å være så omstendelig i sin normaliseringss prosess.
Oftest ser man idig strukturen for databasen eller datamodellen, og kan opppe rett fra 1. normalform til 3. normalform.
Den omstendelige versjonen er viktig for å forstå prosessen, og for å bli fortrolig med normaliseringens verktøy/kasse.
Det er uansett viktig å sjekke slutproduket sett for eventuelle brudd på de forskjellige normalformene.

OPPSUMMERING

Mål:
Lage DB

Lage en nøyaktig
representasjon av:
-data
-forhold mellom data
-krav / begrensninger til data

En måte å tegne funksjonelle
avhengigheter

id	lnavn	adresse	aud-id	aud-navn
				↑
			↑	↑
		↑	↑	↑
				↑

Modellering



Datastruktur



Normalisering
(kontroll)

Normalisering



Datastrukturer

En god relasjon =

* minimalt antall
attributter nødvendig
for å oppfylle krav
til data i systemet.

* attributter m/nær
relasjon (logisk sett)
ligger i samme
tabell

* minimalt med redundans.
helst kun fremmednøkler
(for sammenkobling) > 1 gang

Denormalisering: "Kontrollert redundans".
Kan i noen tilfeller forsvarer
av effektivitetshensyn.

Det finnes flere normalformer etter BCNF,
men vi stopper på 3NF eller BCNF.

Bibliografi

Connolly Thomas, and Carolyn Begg. Database Systems. A Practical Approach to Design, Implementation, and Management. 4th ed. Harlow: Addison-Wesley, 2005.

Bostrøm, Edgar. Databaser – noen temaer. MetodeData a.s., 2008.