NTNU
Det skapende universitet

Institutt for datateknikk og informasjonsvitenskap

# Løsningsskisse til Eksamensoppgave i TDT4145 Datamodellering og databasesystemer

**Eksamensdato: 1. juni 2015**

**Eksamenstid (fra-til): 09:00 - 13:00**

**Hjelpemiddelkode/Tillatte hjelpemidler:**

D – Ingen trykte eller håndskrevne hjelpemidler tillatt. Bestemt, enkel kalkulator tillatt.

Versjon 18. juni 2015.

# Oppgave 1 – Datamodeller (20 %)

a) **Foretrukket løsning:**

**Vehicle**(RegNo, Producer, Model, Weight, Length, Height)

**PassengerCar**(RegNo, Seats)

**Bus**(RegNo, PassengerSeats, DriversLicenceRequirement, CargoVolume)

**Truck**(RegNo,CargoVolume, MaxCargoWeight, Class)

**Alternativ løsning:**

**Vehicle**(RegNo, , Producer, Model, Weight, Length, Height, Seats, PassengerSeats, DriversLicenceRequirement, CargoVolume, MaxCargoWeight, Class, TypeOfVehicle)

I denne løsningen vil attributtet TypeOfVehicle kunne ha verdiene: 'Car', 'Bus', 'Truck' eller NULL.

Vi anser at den alternative løsningen er dårligere fordi det er vanskelig å holde oversikt over hvilke attributter som hører til hvilken underklasse av kjøretøy og fordi det nødvendigvis vil bli mange NULL-verdier i tabellen.

Siden spesialiseringen er delvis kan vi *ikke* bruke en løsning uten en egen tabell for superklassen Vehicle, med overføring av de felles attributtene til underklasse-tabellene.

b) ER-diagrammet under viser en mulig datamodell. Det vil være like riktig å spesifisere attributtene inne i boksene.

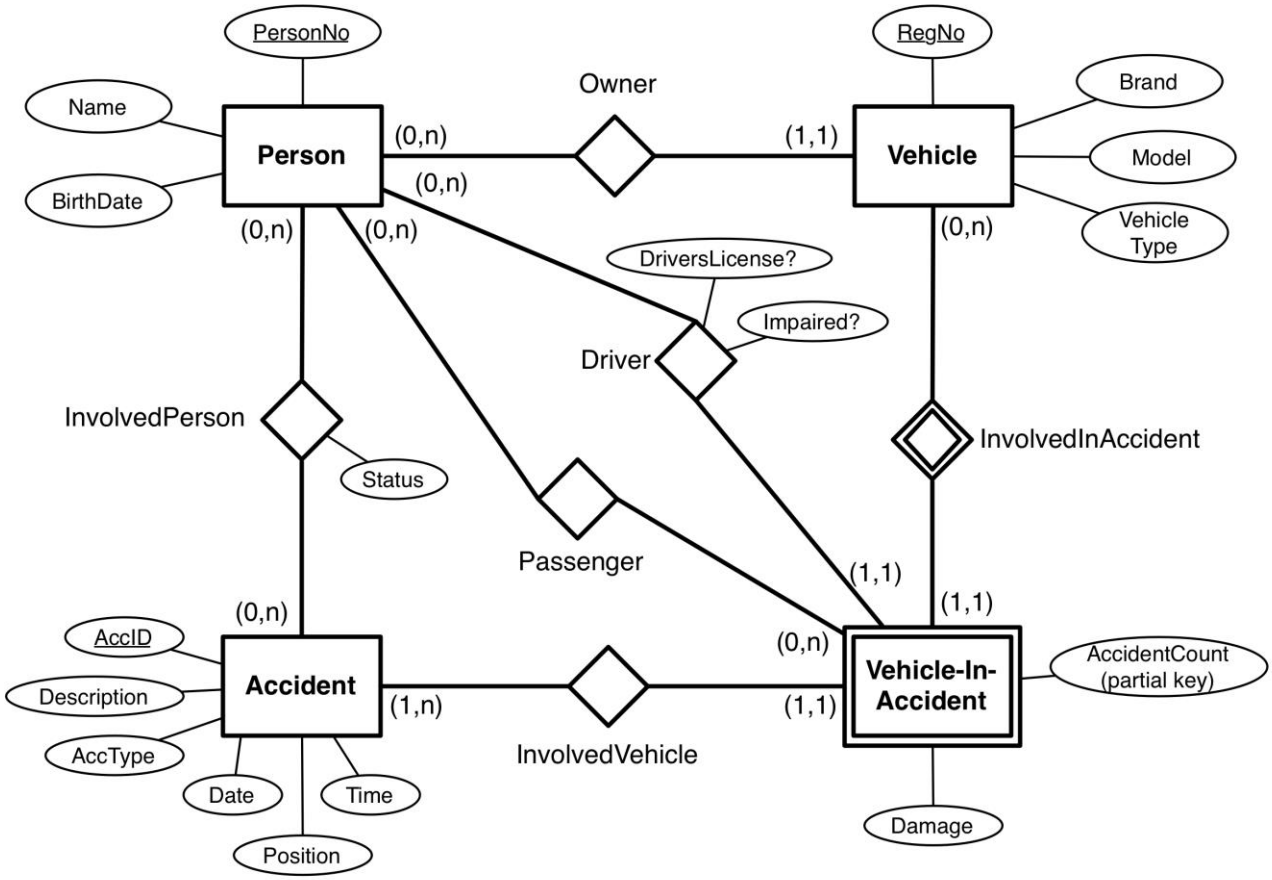


# Oppgave 2 – Relasjonsalgebra og SQL (20 %)

I SQL-oppgavene er svarene gitt med join spesifisert i FROM-delen. Det skal ikke trekkes for løsninger som spesifiserer join-betingelser i WHERE-delen.

a) Relasjonsalgebra:

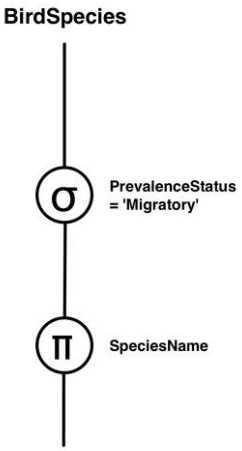

b) Relasjonsalgebra:

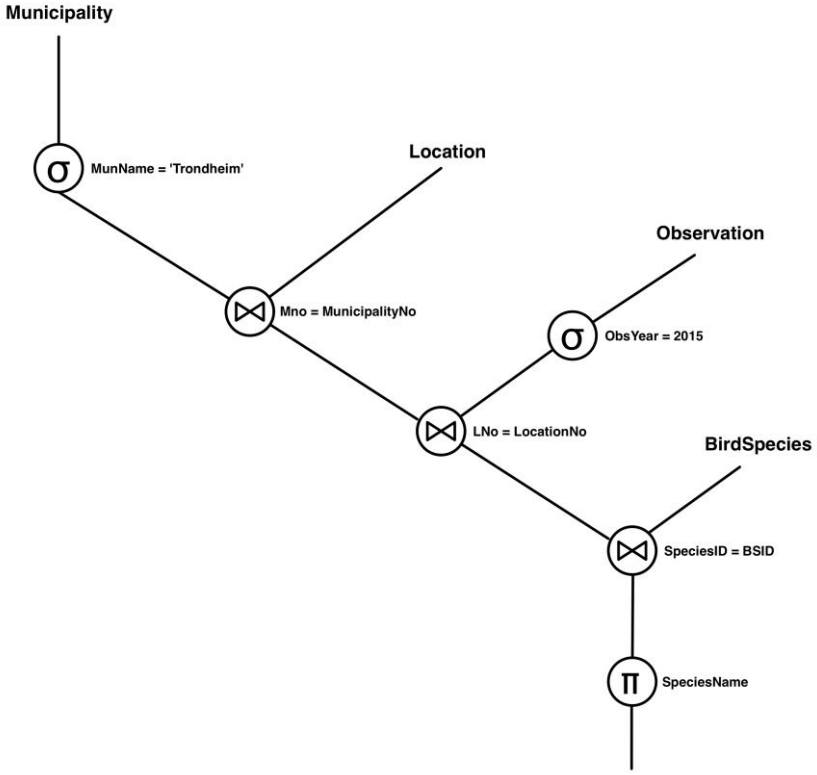


c)
```
SELECT SpeciesName
FROM BirdGroups INNER JOIN BirdSpecies ON BGID = BirdGroupID
WHERE GroupName = 'Thrushes'
ORDER BY SpeciesName ASC;
```

d)
```
SELECT SpeciesName, count(ObsNo), sum(BirdCount)
FROM BirdSpecies INNER JOIN Observation ON BSID = SpeciesID
WHERE ObsYear = 2015
GROUP BY SpeciesName
ORDER BY sum(BirdCount) DESC;
```

e)
```
SELECT SpeciesName
FROM BirdSpecies
WHERE BSID IN (SELECT SpeciesID
               FROM Observation INNER JOIN Location
                    ON LocationNo = LNo INNER JOIN
                    Municipality ON MunicipalityNo = Mno
               WHERE MunName = 'Trondheim')
  AND BSID NOT IN (SELECT SpeciesID
               FROM Observation INNER JOIN Location
                    ON LocationNo = LNo INNER JOIN
                    Municipality ON MunicipalityNo = Mno
               WHERE MunName = 'Trondheim'
                 AND ObsYear = 2015);
```

# Oppgave 3 – Teori (20 %)

a) F = {SpeciesID -> SpeciesName, BirdGroup, Status; SpeciesName -> SpeciesID }

Forutsetninger:

- SpeciesId er en unik identifikator for en fugleart.
- En fugleart tilhører bare en fuglegruppe (BirdGroup) og har bare en forekomststatus (Status).
- Det er ikke flere fuglearter med samme navn (SpeciesName).

b) Siden attributtene A og D ikke er på noen høyreside i F, må de være med i alle kandidatnøkler. Bare AD er en nøkkel ($AD^+ = ABCDE = R$, $A^+ = ABC \subset R$ og $D^+ = D \subset R$) og det er derfor den eneste kandidatnøkkelen for tabellen.

c) Ikke-nøkkel-attributtene B og C er delvis avhengige av nøkkelen AD, siden A -> B og A -> C (kan utledes). Tabellen oppfyller derfor ikke kravene til 2. Normalform. Den høyeste normalformen som oppfylles av tabellen er derfor 1. normalform.

d) En mulig dekomponering er: $R_1$(A, B), $R_2$(B, C) og $R_3$(C, D, E). A er primærnøkkel i $R_1$. AC er primærnøkkel i $R_2$. C og D er kandidatnøkler i $R_3$. Dekomponeringer vurderes etter fire forhold:

- **Attributtbevaring:** $R = R_1 \cup R_2 \cup R_3$ så det er ivaretatt.
- **FD-bevaring:** A -> B ivaretas i $R_1$, B - > C ivaretas i $R_2$ og CD -> E ivaretas i $R_3$. Det betyr at alle FD-er i F er ivaretatt og vi har FD-bevaring.
- **Tapsløst-join:** $R_1$ og $R_2$ joiner tapsløst fordi det felles attributtet B er (super-)nøkkel i $R_2$. Resultatet joiner ikke tapsløst med $R_3$ til utgangspunktet (R) siden det felles attributtet (C) ikke er en (super-)nøkkel i noen av operandtabellene. Vi har med andre ord ikke oppfylt kravene til tapsløst-join-egenskapen. Egenskapen kan alternativt vises ved å bruke matrisemetoden (algoritme 15.3 i læreboken).
- **Normalform:** $R_1$ har $F_1$ = {A -> B} og er på BCNF siden A er en (super-)nøkkel i $R_1$. $R_2$ har $F_2$ = {B->C} og er på BCNF siden B er en (super-)nøkkel i $R_2$. $R_3$ har $F_3$ = {CD -> E} og er på BCNF siden CD er (super-)nøkkel i $R_3$.

Dekomponeringen kan *ikke* brukes siden den ikke har tapsløst-join-egenskapen.

e) Tabellen trenger bare å inneholde de fire oppgitte tuplene (radene).

| Lecturer | Subject | Campus |
|---|---|---|
| svein | db | gløs |
| rune | db | gjøvik |
| tore | db | kalvskinnet |
| mads | os | gløs |

# Oppgave 4 – Lagring og skalering (5 %)

Det er to sentrale opplysninger i oppgaven:
1. Antall poster er usikkert og kan bli stort.
2. All aksess skjer via primærnøkler
Hashing er bra når aksess er via primærnøkler. **Extendible hashing** er bra når datamengden er usikker. Clustered, extendible hasing høres bra ut når du bare skal ha tak i enkeltposter. B+-trær kan også være brukbare, men ikke så bra altermativ her.

# Oppgave 5 – B+-trær og queryutføring (15 %)

a) (10 %) Gjør et estimat på hvor mange blokker som leses og skrive ved de følgende SQL-setningene:

i) INSERT INTO Ansatt VALUES
(123123,'Hansen','Hans','hans@email.org',2015,100000);
**Løsningforslag**: 3 blokker leses på vei nedover B+-treet. 1 blokk skrives etter innsetting. **Til sammen 4**. Ved blokksplitt (hver 30ende innsetting gir blokksplitt og litt flere aksessser).

ii) SELECT lastname, firstname, email, startyear,salary FROM Employee WHERE empno=12123;
**Løsningsforslag**: **3 blokker** på vei ned B+-treet.

iii) SELECT * FROM Employee;
**Løsningsforslag**: 3 blokker på vei nedover og 1499 bortover, **til sammen 1502**.

iv) SELECT COUNT(*) FROM EMPLOYEE WHERE empno>100000.
**Løsningsforslag**: Her kan vi navigere ned til empno 100000 og så gå bortover til stigende nøkler i B+-treet. Det er altså 3 aksesser nedover. Hvis vi da sier at andelen av blokker er (123123-100000)/(123123-10000) = 0.2044. Når dette ganges med antall blokker på løvnivå, dvs. 1500 får vi 307 blokker. Til sammen ca **310 blokker**.

b) (5 %) Her er det fristende å anta at stigende empno gir stigende startyear og at vi derfor kan få til optimal aksess via det eksisterende B+-treet, ved å starte på slutten og gå baklengs inntil startyear<2015. Men det er en skummel antagelse.
Startyear er neppe selektivt nok til at en separat indeks vil lønne seg, derfor sier vi **nei**, **bruk den eksisterende lagringen**.
Noen studenter har foreslått å lage en sammensatt nøkkel (startyear, empno). Kanskje ikke så dumt?

# **Oppgave 6** – Transaksjoner - gjenopprettbarhet (10 %)

H1: r1(A); w1(A); r2(B); c1; r2(A); w2(A); c2; *H1 er **strict** fordi det er ingen lesing eller skriving av ikke-committede endringer.*

H2: r1(A); w1(A); w2(A); c2; c1; *H2 er **ACA** fordi det er ingen lesing av ikke-committede endringer, men det er derimot en skriving w2(A) skriver over w1(A). Derfor er den ikke strict.*

H3: r1(A); r2(C); r1(C); r3(A); r3(B); w1(A); w3(B); r2(B); w2(C); w2(B); c1; c2; c3; *H3 er **ikke-recoverable** fordi r2(B) leser endringen til w3(B) og de committer i motsatt rekkefølge.*

# **Oppgave 7** – Transaksjoner - recovery (10 %)

a) Løsning: Vi går forover i loggen og oppdaterer de to tabellene. Da får vi transtabellen:

| **Transaction** | **Last_lsn** | **Status** |
|---|---|---|
| T1 | 103 | Commit |
| T2 | 108 | Commit |
| T3 | 106 | In progress |

Og vi får denne DPTen:

| **Page_id** | **Rec_lsn** |
|---|---|
| C | 101 |
| B | 102 |
| A | 106 |

Det er viktig at Rec_lsn **ikke** oppdateres av nye loggposter, dvs. at 101 erstattes med 107.

b) Hvilke loggposter vil legges til loggen under **undofasen** av recovery her?

| **LSN** | **Last_lsn** | **Transaction** | **OpType** | **Page_id** | **Other_info** |
|---|---|---|---|---|---|
| 101 | 0 | T1 | Update | C | … |
| 102 | 0 | T2 | Update | B | … |
| 103 | 101 | T1 | Commit | | … |
| 104 | | | Begin_ckpt | | |
| 105 | | | End_ckpt | | |
| 106 | 0 | T3 | Update | A | … |
| 107 | 102 | T2 | Update | C | … |
| 108 | 107 | T2 | Commit | | … |
| 109 | 106 | T3 | CLR | A | |
| 110 | 109 | T3 | Abort | | |

Nye loggposter er vist med gult. Det er viktig at CLRen (compensating log record) kommer med her. Noen har skrevet kun en update-loggpost i stedet for CLR. Det må også godtas. Abort kan også komme før CRLen hvis systemet logger at den beynner å abortere.