



# EKSAMENSOPPGAVE

Institutt:	<u>IKBM</u>	
Eksamen i:	<u>STAT100</u> <i>emnekode</i>	<u>Statistikk</u> <i>emnenavn</i>
Tid:	<u>Tirsdag 13.12 2016</u> <i>ukedag og dato</i>	<u>09.00 – 12.30 (3.5 timer)</u> <i>kl. fra – til og antall timer</i>
Emneansvarlig:	<u>Solve Sæbø</u> <i>Navn</i>	

## Tillatte hjelpemidler:

**C3: alle typer kalkulatorer, alle andre hjelpemidler**

9

Oppgaveteksten er på: \_\_\_\_\_  
*antall sider inkl. vedlegg*

## Eksamensoppgavene evalueres slik:

Del A: Teller 50 %. Alle flervalgsoppgaver teller likt.

Del B Oppgave 1: Teller 25%

Del B Oppgave 2: Teller 25%. Alle deloppgaver teller likt.

## Merk:

**Vedlegg 2: Svar-ark for Del A - fylles ut og leveres inn sammen med besvarelsen for Del B**

## Del A – Flervalgsoppgaver

### *Krystallsyken (Oppgaver 1 – 4)*

Krystallsyken er en sykdom som gir svimmelhet i visse situasjoner og som skyldes at partikler («krystaller») forviller seg inn i en av buegangene i balanseorganet i det indre øret. Tilstanden kan behandles ved hjelp av en spesiell manøver hvor pasienten beveges etter et visst mønster for å få partiklene til å gli ut igjen. Behandlingen er ganske effektiv og 80% av pasientene blir friske etter én behandling. Anta at et behandlingssenter får inn 10 pasienter med krystallsyken i desember 2016. La  $X$  være antall av disse som blir friske etter én behandling.



### Oppgave 1

Hvilken sannsynlighetsfordeling er det rimelig å anta for  $X$ ?

- a)  $N(5, 0.8)$    b) F-fordelt   c)  $B(10, 0.8)$    d)  $N(8, 0.32)$    e)  $B(8, 0.32)$

### Oppgave 2

Hva er forventningen til  $X$ ?

- a) 10                      b) 4                      c) 5                      d) 8                      e)  $\bar{X}$

### Oppgave 3

Hva er sannsynligheten for at minst 9 blir friske etter én behandling?

- a) 0.376                      b) 0.268                      c) 0.321                      d) 0.893                      e) 0.624

### Oppgave 4

Hvis en pasient ikke blir frisk etter én behandling, prøver man samme behandling igjen.

Sannsynligheten for at en pasient, som ikke ble frisk i første forsøk, faktisk blir frisk i andre forsøk, er lik 0.5. Hva er sannsynligheten for at en tilfeldig pasient *ikke blir frisk* selv etter to behandlinger?

- a) 0.4                      b) 0.1                      c) 0.6                      d) 0.9                      e) 0.05

### *Boligpriser (Oppgaver 5 - 9)*

Etter at Donald Trump vant presidentvalget i USA i november 2016, ble det spekulert i om dette ville ha noen innvirkning på boligprisene her i Norge. I en undersøkelse ble 200 tilfeldige personer spurt om de tror boligprisene vil stige i de neste 6 månedene etter valget. Av disse trodde 122 at prisene vil stige. La  $p$  være sannsynligheten for at en tilfeldig person tror at boligprisene vil stige.

### Oppgave 5

Hva blir det vanlige normal-tilnærmede 90% konfidensintervallet for  $p$ ?

- a) [0.566, 0.654]   b) [0.553, 0.667]   c) [0.577, 0.643]   d) [0.443, 0.557]   e) [0.542, 0.678]

### Oppgave 6

Hvordan kan vi tolke et slikt konfidensintervall som vi fant i forrige oppgave?

- a) Det er 90% sjanse for at vårt estimat av  $p$  ligger inne i intervallet  
b) Det er 90% sjanse for at intervallet dekker den ukjente verdien av  $p$   
c) Det er 90% sjanse for at boligprisene stiger hvis 0.5 ikke er med i intervallet  
d) Det er 90% sjanse for at forventet antall mennesker, som tror prisene vil gå opp, ligger i intervallet  
e) Intervallet er umulig å tolke så lenge  $p$  er ukjent.

### Oppgave 7

Hvis du vil bruke konfidensintervallet du fant i oppgave 5 til å teste om du kan påstå at  $p$  er forskjellig fra en gitt verdi  $p_0$ , hva blir testnivået til denne testen?

- a) 10%                      b) 5%                      c) 1%                      d) 20%                      e) 2.5%



### Oppgave 8

Du vil på basis av resultatene i undersøkelsen gjøre en hypotesetest for å teste om det er et flertall som tror at boligprisene vil gå opp. Hva blir riktige hypoteser for en slik test?

- a)  $H_0 : p = 0.05$  mot  $H_1 : p < 0.05$
- b)  $H_0 : p = 0.61$  mot  $H_1 : p > 0.61$
- c)  $H_0 : p = 0.5$  mot  $H_1 : p < 0.5$
- d)  $H_0 : p = 0.5$  mot  $H_1 : p > 0.5$
- e)  $H_0 : p = 0.61$  mot  $H_1 : p \neq 0.61$

### Oppgave 9

Anta at du vil gjøre en ny undersøkelse (hvor du bruker estimatet 0.6 for  $p$ ) der du vil lage et 90% konfidensintervall for den ukjente  $p$  med maksimal bredde på 0.04, hvor mange personer må du da minst spørre?

- a) 983      b) 1044      c) 1624      d) 2305      e) 1877

### Diverse oppgaver fra sannsynlighetsregning (Oppgaver 10 - 12)

I de følgende tre oppgaver skal vi anta at en tilfeldig variabel  $X$  har sannsynlighetsfordeling:

$x_i$	1	2	3	4	5
$P(X = x_i)$	0.2	0.2	0.3	0.2	0.1

### Oppgave 10

Hva er  $E(X)$ ?

- a) 1      b) 2.5      c) 3.1      d) 2.7      e) 2.8

### Oppgave 11

Hva er  $P(2 < X < 5)$ ?

- a) 0.8      b) 0.7      c) 0.3      d) 0.5      e) 0.4

### Oppgave 12

Hva er  $P(X > 3 | X > 1)$ ?

- a) 0.375      b) 0.245      c) 1.50      d) 0.455      e) 0.445

### Midtvegsevaluering i STAT100 2016 (Oppgaver 13 – 16)

Høsten 2016 ble det utført en kursevaluering midtveis i STAT100. Formålet var å se på hvordan det nye opplegget med «flipped classroom»-undervisning og kollokviegrupper fungerte. Ett av spørsmålene var:

«Hvordan fungerer gruppa sosialt? Svar med en score fra 1 (veldig dårlig) til 5 (veldig godt)»

Fra et nevropsykologisk synspunkt er det forventet at jenter og gutter vil kunne ha ulik oppfatning om dette, og man ønsket derfor å teste om det faktisk er en sammenheng mellom kjønn og poengscore på dette spørsmålet. Antall svar på ulike scorere fordelt på kjønn er gitt i tabellen nedenfor, samt rad og kolonnesummer og totalantall. (Antall svar



for scorer 1, 2 og 3 er slått sammen.)

	1-3	4	5	Sum
Jenter	15	33	53	101
Gutter	14	13	14	41
Sum	29	46	67	142

En analyse i R Commander gav bl.a følgende utskrift (noen tall som det spørres etter er utelatt og erstattet med «?», mens andre tall er skjult):

```
                x^2 df P(> x^2)
Likelihood Ratio 7.0585 ? skjult
Pearson          7.4008 ? skjult

Expected counts:
      <=3      4      5
K 20.626761 32.71831 47.65493
M  8.373239 13.28169      ?

Chi-square components:
      <=3      4      5
K      ? skjult 0.60
M 3.78   0.01  1.48
```

### Oppgave 13

Hva er forventet antall gutter som gir score 5 dersom en nullhypotese om at kjønn og poengscore er uavhengige er sann?

- a) 21.65      b) 15.23      c) 19.35      d) 17.56      e) 27.52

### Oppgave 14

Hvor mange frihetsgrader har testobservatoren  $Q$  som benyttes til å teste om det er uavhengighet mellom kjønn og poengscore?

- a) 6      b) 4      c) 5      d) 1      e) 2

### Oppgave 15

Hva er det minste testnivået blant alternativene som gir forkastning av en slik nullhypotese?

- a) 0.1      b) 0.05      c) 0.025      d) 0.01      e) 0.005

### Oppgave 16

Hva er bidraget til testobservatoren  $Q$  fra kombinasjonen «jenter» og score «1-3»?

- a) 2.01      b) 1.53      c) -1.32      d) 0.27      e) 0.074



### Måling av kroppstemperatur (Oppgaver 17 - 20)

Vi kan måle kroppstemperatur (feber) på ulike måter, noen er sikrere enn andre. Anta at vi har to måter å måle feber på representert med de tilfeldige variablene  $Y \sim N(\mu_y, \sigma_y)$  og  $X \sim N(\mu_x, \sigma_x)$ . Videre lar vi korrelasjonen mellom  $Y$  og  $X$  være lik den foreløpig ukjente parameteren  $\rho$ .

#### Oppgave 17

En sykepleier vil bruke begge målemetoder på et utvalg av  $n=10$  pasienter for å teste om de to målemetodene har forskjellig forventning. Hun finner ut at hvis hun ser på  $D = Y - X$  i utvalget, så blir  $\bar{d} = 0.89$  og  $s_d = 0.46$ . Hva blir verdien av den t-fordelte testobservatoren for å teste om de to målemetodene har forskjellig forventning?

- a) 5.29                      b) 1.28                      c) 6.12                      d) 1.93                      e) 5.80

#### Oppgave 18

Sykepleieren oppdager så at produsentene av måleapparatene har oppgitt kjente (sanne) standardavvik for begge målemetoder hhv lik  $\sigma_y = 0.9$  og  $\sigma_x = 0.8$  (basert på testing på svært mange pasienter). Dermed kan hun *regne ut* og bruke det sanne standardavviket  $\sigma_d$  til  $D = Y - X$  i stedet for sitt eget utvalgsstandardavvik  $s_d$  i hypotesetesten sin. For enkelhets skyld antar hun at  $X$  og  $Y$  er uavhengige variabler (dvs  $\rho = 0$ ). Hva blir da standardavviket  $\sigma_d$  til  $D$ ?

- a) 1.20                      b) 0.10                      c) 1.7                      d) 0.85                      e) 1.13

#### Oppgave 19

Hvis hun finner den sanne  $\sigma_d$  og bruker denne i stedet for  $s_d$  i testobservatoren sin i hypotesetesten som er beskrevet i oppgave 17, hvilken fordeling får testobservatoren da?

- a) t-fordelt med 9 frihetsgrader  
b) t-fordelt med 3 frihetsgrader  
c)  $\chi^2$ -kvadratfordelt med 9 frihetsgrader  
d) standard normalfordelt  
e) t-fordelt med 18 frihetsgrader

#### Oppgave 20

Den sanne korrelasjonen mellom metodene er faktisk ikke 0, men lik  $\rho = 0.83$ . Hva blir da  $\sigma_d$ ?

- a) 0.85                      b) 0.50                      c) 0.04                      d) 0.87                      e) 0.63



## Del B – Tekstoppgaver

### Oppgave 1

Det er antatt at pH-nivået i egg øker jo lenger de lagres, men pH kan også avhenge av hvordan egg vaskes. Fra en masteroppgave ved NMBU har vi lånt  $N=32$  observasjoner fordelt på  $k=4$  grupper definert av en kombinasjon av lagringstid (K=Kort, L=Lang) og vaskevannstemperatur (K=Kaldt, V=Varmt) som gav de fire «TidTemp-gruppene» KK, KV, LK og LV med 8 observasjoner i hver gruppe. For eksempel betyr «KK» at egget er lagret i kort tid og ble vasket med kaldt vann. Formålet med studien var å sammenlikne eggets pH-nivå ( $Y$ ) i de fire gruppene for å se om det var noen forskjeller i forventet pH. Ulike utskrifter fra en analyse gjort i R Commander (Tabell 1) samt et residualplott (Figur 1) er gitt i Vedlegg 1. Bruk utskriften i den grad det er mulig og nødvendig.

Skriv en kort rapport (max 2 sider) der du beskriver resultatene fra analysen. Rapporten skal gi informasjon om modellantagelser, parametre, estimater, modellvurdering (hvor god modelltilpasningen er og om modellantagelser oppfylt), hypotesetest(er) og resultattolkninger.

### Oppgave 2

I en studie av øretermometere fant man ut at sammenhengen mellom kroppens sentraltemperatur ( $Y$ ) og målingene fra et øretermometer ( $X$ ) kunne beskrives ved regresjonslikningen

$$y_i = \alpha + \beta x_i + \epsilon_i, \text{ der } \epsilon_i \sim N(0, \sigma) \text{ for } i = 1, \dots, 237$$

Tabell 2 i vedlegg 1 viser resultater fra en regresjonsanalyse gjort på målinger av  $N=237$  intensivpasienter, der det var mulig å gjøre en nøyaktig måling av sentraltemperaturen. Ekstraopplysninger om dataene: Gjennomsnitt og standardavvik (i °C) var:

$$\bar{x} = 37.11, s_x = 0.83$$

$$\bar{y} = 37.89, s_y = 0.92$$

- Skriv opp de tre ukjente modellparametrene og finn estimatene for disse. Gi en tolkning av de estimerte parametrene i lys av problemstillingen som studeres.
- Finn og tolk  $R^2$
- Finn et 95% prediksjonsintervall for sentraltemperaturen når øretermometeret viser 38 grader. Hvordan tolker vi et slikt intervall?
- Hvorfor er det interessant å teste både om  $\alpha \neq 0$  og  $\beta \neq 1$ ? Utfør begge testene med testnivå 5%. Kommentér resultatet.

Emneansvarlig:

Solve Sæbø

Sensor:

Torfinn Torp

Vedlegg 1

Tabell 1: R Commander utskrift til Del B, Oppgave 1

```

      mean      sd      n
KK  9.02125 0.16805080    8
KV  8.97875 0.06057758    8
LK  9.04375 0.06186102    8
LV  9.21875 0.09538456    8

Anova Table
      Sum Sq Df F value    Pr(>F)
TidTemp  0.26754  3  7.9561 0.0005446 ***
Residuals 0.31385 28

fit.contrast(model=AnovaModel, varname='TidTemp', df=TRUE,
coeff=c(0.5, 0.5, -0.5, -0.5), conf.int=0.95)
      Estimate Std. Error t value  Pr(>|t|) DF lower CI  upper CI
TidTemp -0.13125 0.03743149 -3.506406 0.001550419 28 -0.2079249 -0.05457508

fit.contrast(model=AnovaModel, varname='TidTemp', df=TRUE,
coeff=c(0.5, -0.5, 0.5, -0.5), conf.int=0.95)
      Estimate Std. Error t value  Pr(>|t|) DF lower CI  upper CI
TidTemp -0.06625 0.03743149 -1.7699 0.08763408 28 -0.1429249 0.01042492

```




Figure 1: Residualplott for Del B, Oppgave 1.



Tabell 2: Regresjonsanalyse for Del B, Oppgave 2 (Ett tall er erstattet med «?») )

```
LinearModel <- lm(Sentral ~ øre, data=Temp)

Call:
lm(formula = Sentral ~ øre, data = Temp)

Residuals:
    Min       1Q   Median       3Q      Max
-1.25600 -0.31566 -0.05978  0.28854  1.60031

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  3.74544     1.51257   2.476   0.014 *
øre          0.92017     0.04075  22.580 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

s: 0.5172 on 235 degrees of freedom
Multiple R-squared: ?
F-statistic: 509.9 on 1 and 235 DF, p-value: < 2.2e-16

Anova Table

Response: Sentral
              Sum Sq  Df  F value  Pr(>F)
øre          136.394   1 509.8554 < 2e-16 ***
Residuals    62.866 235
```





## Vedlegg 2 – Svar-ark for Del A

Riv ut arket og levere dette sammen med besvarelsen.

Sett ett kryss i hver rad under det svaralternativet du velger for den aktuelle oppgaven

Oppgave	a)	b)	c)	d)	e)
1					
2					
3					
4					
5					
6					
7					
8					
9					
10					
11					
12					
13					
14					
15					
16					
17					
18					
19					
20					