

# UNIVERSITETET I OSLO

## Det matematisk-naturvitenskapelige fakultet

Eksamen i:	STK1110 — Statistiske metoder og dataanalyse 1.
Eksamensdag:	Onsdag 3. desember 2008.
Tid for eksamen:	9.00 – 12.00.
Oppgavesettet er på	4 sider.
Vedlegg:	Tabell for normal, $\chi^2$ - og $t$ -fordelingen.
Tillatte hjelpemidler:	Godkjent lommeregner og Formelsamling for STK1100 og STK1110.

Kontroller at oppgavesettet er komplett før du begynner å besvare spørsmålene.

### Oppgave 1.

For å bestemme usikkerheten til et måleinstrument for hastighet måler man flere ganger hastigheten til en gjenstand som beveges med en kjent hastighet. Målingene nedenfor angir resultatet fra 5 slike forsøk der gjenstanden hadde en hastighet på 100 km per time

102.93, 99.27, 102.67, 99.82, 98.24.

En rimelig modell er her at målingene er realisasjoner av uavhengige normalfordelte variable,  $X_1, \dots, X_5$ , som alle er normalfordelt  $N(\mu_0, \sigma^2)$ , der  $\mu_0 = 100$  er kjent.

- Vis at fordelingen til  $\frac{1}{\sigma^2} \sum_{i=1}^5 (X_i - \mu_0)^2$  er  $\chi^2$ -fordelt med 5 frihetsgrader. Finn en forventningsrett estimator for  $\sigma^2$ . Hva er variansen?
- Bruk resultater fra punkt a) til å utlede en test med nivå  $\alpha$  for nullhypotesen

$$H_0 : \sigma^2 = \sigma_0^2 \text{ mot alternativet } H_A : \sigma^2 > \sigma_0^2$$

der  $\sigma_0^2$  er kjent.

(Fortsettes side 2.)

- c) Angi en øvre og nedre grense for p-verdien til testen basert på observasjonene i begynnelsen av oppgaven når  $\sigma_0^2 = 2$ . Forklar omhyggelig hva p-verdier er og hvordan resultatet du fant skal tolkes.

## Oppgave 2.

Følgende tabell viser et utsnitt av vektene,  $y_i$ , til 12 barn med en spesiell type spiseforstyrrelse samt deres høyde,  $x_i$ , og alder,  $z_i$ .

Table 1: Vekt i kg,  $y_i$ , høyden i meter,  $x_i$ , og alder i år,  $z_i$ , for 12 barn med spiseforstyrrelser.

Vekt, $y_i$	Høyde, $x_i$	Alder, $z_i$
23.9	1.44	8
26.5	1.50	10
19.8	1.24	6
$\vdots$		$\vdots$
28.3	1.55	12
25.4	1.45	9

Her er vekt respons, og høyde og alder er uavhengige variable. Betrakt først situasjonen der sammenhengen mellom vekt og høyde beskrives med en enkel lineær regresjonsmodell:

$$Y_i = \beta_0 + \beta_1 x_i + e_i, i = 1, \dots, 12.$$

- a) Forklar hvilke forutsetninger en slik modell bygger på. Hvilke egenskaper til estimatorene for parametrene  $\beta_0$  og  $\beta_1$  kan utledes av det som i læreboka kalles "standard statistisk modell", det vil si uten å anta at feilleddene  $e_1, \dots, e_{12}$  er normalfordelte?
- b) Finn et estimat for  $\beta_1$  og bestem et 95% konfidensintervall for  $\beta_1$ . Her kan du bruke at  $\sum_{i=1}^{12} y_i = 280.869$ ,  $\sum_{i=1}^{12} x_i = 16.078$ ,  $\sum_{i=1}^{12} x_i^2 = 21.873$  og  $\sum_{i=1}^{12} x_i y_i = 381.526$ . Residual kvadratsum er  $RSS_1 = \sum_{i=1}^{12} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2 = 41.645$ , der  $\hat{\beta}_0$  og  $\hat{\beta}_1$  er estimater for parametrene  $\beta_0$  og  $\beta_1$ .

En lineær regresjonsmodell uten konstantledd der høyde og alder er uavhengige variable kan formuleres som

$$Y_i = \alpha_1 x_i + \alpha_2 z_i + e_i, i = 1, \dots, 12.$$

(Fortsettes side 3.)

- c) Forklar hvordan modellen kan uttrykkes på matriseform,

$$\mathbf{Y} = \mathbf{X}\alpha + \mathbf{e},$$

der  $\mathbf{X}$  er en matrise av kjente tall og  $\mathbf{Y}$  og  $\mathbf{e}$  er vektorer av tilfeldige variable.

- d) Finn et estimat for  $\alpha_2$ . Her kan du i tillegg til de størrelsene som er oppgitt i punkt b), bruke at  $\sum_{i=1}^{12} z_i^2 = 976$ ,  $\sum_{i=1}^{12} x_i z_i = 144.247$  og  $\sum_{i=1}^{12} z_i y_i = 2534.908$ . Du kan også trenge

$$\begin{pmatrix} 21.873 & 144.247 \\ 144.247 & 976.0 \end{pmatrix}^{-1} = \begin{pmatrix} 1.804 & -0.267 \\ -0.267 & 0.040 \end{pmatrix}.$$

Residual kvadratsum er  $RSS_2 = \sum_{i=1}^{12} (y_i - \hat{\alpha}_1 x_i - \hat{\alpha}_2 z_i)^2 = 28.3$ , der  $\hat{\alpha}_1$  og  $\hat{\alpha}_2$  er estimater for koeffesientene  $\alpha_1$  and  $\alpha_2$ . Hva blir den estimerte standardfeilen til estimatoren for  $\alpha_2$ ?

### Oppgave 3.

Tabellen nedenfor viser antall ulykker per måned på en bestemt veistrekning i løpet av en 20-måneders periode. I 9 av månedene var det altså ingen ulykker, i 7 av månedene var det en ulykke osv.

Table 2: Antall ulykker per måned i en periode på 20 måneder.

Antall ulykker	Antall måneder
0	9
1	7
2	3
3	1

En rimelig modell i denne situasjonen er at antall ulykker antas å være realisasjoner av uavhengige Poisson fordelte variable  $X_1, \dots, X_{20}$  med samme punktsannsynlighet

$$P(X = x) = \frac{\lambda^x}{x!} \exp(-\lambda), \quad x = 0, 1, \dots$$

- a) Finn moment- og sannsynlighetsmaksimeringsestimatorene til  $\lambda$ . Beregn estimatene ved å bruke observasjonene fra tabellen i begynnelsen av oppgaven.

(Fortsettes side 4.)

- b) Utled et tilnærmet 95% konfidensintervall for  $\lambda$ . Beregn intervallet på grunnlag av observasjonene i tabellen.

Se nå på en situasjon der en bare bruker opplysninger om det har funnet sted ulykker i hver av de 20 månedene eller ikke. La  $Y_i = 1$  hvis  $X_i = 0$  og  $Y_i = 0$  ellers. Da er  $Y = \sum_{i=1}^{20} Y_i$  antallet ulykkesfrie måneder.

- c) Begrunn at antallet måneder der det ikke skjer ulykker, det vil si  $Y$ , er binomisk fordelt og angi punktsannsynligheten til  $Y$ . Bestem moment- og sannsynlighetsmaksimeringsestimatorene til  $\lambda$  i dette tilfellet. Hva blir estimatene?
- d) Utled og beregn et tilnærmet 95% konfidensintervall for  $\lambda$  på grunnlag av antall ulykkesfrie måneder.

SLUTT