

# UNIVERSITETET I OSLO

## Det matematisk-naturvitenskapelige fakultet

- Eksamen i: ST 102 — Videregående kurs i statistikk.
- Eksamensdag: Onsdag 31. mai 1995.
- Tid for eksamen: 09.00 – 15.00.
- Oppgavesettet er på 5 sider.
- Vedlegg: 2 tabeller.
- Tillatte hjelpemidler: Formelsamling for ST 101, ST 102, lommekalkulator.

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

### Oppgave 1.

Anta at  $Y_1, Y_2, \dots, Y_n$  er uavhengige og normalfordelte med forventning  $\mu$  og varians  $\sigma^2$ .

- a) Anta at  $\sigma^2$  er kjent. Vis at

$$\hat{\mu} = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$$

er sannsynlighetsmaksimeringsestimatoren (SME) for  $\mu$ .  
Hvorfor kan vi også betegne  $\hat{\mu}$  som en momentestimator?

- b) Anta at både  $\mu$  og  $\sigma^2$  er ukjente. Finn simultan SME for  $(\mu, \sigma^2)$ .  
Er denne estimatoren også en momentestimator?  
Er SME forventningsrett i dette tilfellet?
- c) Foreslå en testobservator for hypotesetestingsproblemet  $H_0 : \mu = \mu_0$  mot  $H_1 : \mu \neq \mu_0$  med signifikansnivå  $\alpha$  når  $\sigma^2$  er ukjent.  
Argumenter for testobservatorens fordeling når  $\mu = \mu_0$ .

(Fortsettes side 2.)

Testen kan gjennomføres både ved hjelp av forkastningsgrenser og  $p$ -verdi (signifikanssannsynlighet). Angi for begge måter hvordan og diskuter kort sammenhengen.

d) Angi et 95% konfidensintervall for  $\mu$ .

Forklar hva det betyr at dette er et konfidensintervall.

Utled at intervallet du oppga faktisk er et 95% konfidensintervall.

Diskuter kort sammenhengen mellom konfidensintervaller og hypotesetesting.

e) Benytt BLSS-utskriften under samt vedlagt tabell over Student's  $t$ -fordeling til å svare på følgende spørsmål.

- 1) Hva blir de forventningsrette estimatorene for  $\mu$  og  $\sigma^2$ ? Hva blir SME?
- 2) Kan man forkaste  $H_0 : \mu = 0$  mot  $H_1 : \mu \neq 0$  med nivå  $\alpha = 0.001$ ?
- 3) Kan man forkaste  $H_0 : \mu = 1$  mot  $H_1 : \mu \neq 1$  med nivå  $\alpha = 0.05$ ?
- 4) Hva blir et 99% konfidensintervall for  $\mu$ ?

stat x

Statistics: x

Col	N	Mean	SD	Min	25%	50%	75%	Max
1	25	1.623	1.486	-2.162	0.7543	1.648	2.662	4.018

ht x

Hypothesis Test: one-sample, two-tail t. Data: x.

Col	N	null mean	sample mean	sample SE	df	test stat	P value	alpha	crit value
1	25	0.0000	1.6232	0.29722	24.0	5.46	.0000	.0500 .0100 .0010	2.06 2.80 3.75

## Oppgave 2.

Du skal i denne oppgaven undersøke om hvorvidt tvillingpar er eneggede eller toeggede har noen sammenheng med mors alder. Dataene du skal regne på er angitt i tabellen under. Dataene er konstruert, men de er i samsvar med hva man kunne observere hvis man velger ut  $n = 200$  tvillingpar tilfeldig. Tabellen angir antall tvillingpar etter mors alder og om de er eneggede/toeggede.

(Fortsettes side 3.)

Mors alder	Eneggede	Toeggede
$\leq 25$ år	30	30
26–34 år	40	80
$\geq 35$ år	5	15

La  $X_{1j}$  = antall eneggede tvillingpar og  $X_{2j}$  = antall toeggede tvillingpar med mor i alderskategori nr.  $j$ ,  $j = 1, 2, 3$ . La videre  $p_{1j}$  være sannsynligheten for at et tilfeldig utvalgt tvillingpar er enegget og har mor i alderskategori nr.  $j$  og la  $p_{2j}$  betegne den tilsvarende sannsynligheten for toeggede tvillingpar.

- a) Foreslå en sannsynlighetsmodell for  $(X_{11}, X_{12}, X_{13}, X_{21}, X_{22}, X_{23})$  og argumenter kort for dens gyldighet.

Hvor mange parametre er det i modellen?

Sannsynlighetsmaksimeringsestimatorene (SME) for  $p_{ij}$ -ene er gitt ved  $\hat{p}_{ij} = X_{ij}/200$ . (Dette skal du ikke vise.)

Finn forventninger, varianser og kovarianser for SME.

Definer nå  $p_i$  som sannsynligheten for at tvillingpar er enegget ( $i = 1$ ) eller toegget ( $i = 2$ ) og tilsvarende  $p_{.j}$  som sannsynligheten for at tvillingparets mor er i alderskategori nr.  $j$ .

Anta at morens alder er uavhengig av om tvillingparet er enegget eller toegget.

- b) Hva blir da sammenhengen mellom  $p_{ij}$ ,  $p_i$  og  $p_{.j}$ ?

Hvor mange parametre er det i modellen under uavhengighetsantagelsen?

SME for  $p_i$  blir nå  $p_i^* = (X_{i1} + X_{i2} + X_{i3})/200$ . Tilsvarende blir SME for  $p_{.j}$  lik  $p_{.j}^* = (X_{1j} + X_{2j})/200$ . (Dette skal du ikke vise.)

Hva blir SME for  $p_{ij}$  under uavhengighetsantagelsen?

Man kan teste nullhypotesen

$H_0$ : Hvorvidt tvillingparet er enegget eller toegget er uavhengig av mors alder

(mot alternativet at det er avhengighet) ved en kji-kvadratobservator oppgitt på generell form i Formelsamlingen for ST 102.

- c) Hvordan blir kji-kvadratobservatoren seende ut i dette tilfellet?

Hva er dens tilnærmede fordeling under nullhypotesen?

Argumenter for at avhengighet rimeligvis skal resultere i en stor kji-kvadratobservator.

Utfør testen og konkluder om dataene i tabellen tyder på avhengighet.

(Fortsettes side 4.)

- d) Man kan også teste nullhypotesen i punkt c) ved en sannsynlighetskvotetest. Forklar ideen i en slik test og definer sannsynlighetskvoten  $\Lambda$ .

Utled et uttrykk for  $\Lambda$  i den konkrete situasjonen.

Beregn  $2 \ln \Lambda$  og sammenlign med kji-kvadratobservatoren fra punkt c).  
Kommenter.

- e) 1) Man kan vise at dersom man hadde valgt ut et på forhånd bestemt antall tvillingmødre i hver alderskategori så kan likevel testene i punktene c) og d) benyttes til å undersøke om det er en sammenheng. Hvilken fordel kan en slik utvalgsplan ha?
- 2) Hva tyder resultatene i denne oppgaven på om sammenhengen mellom en tvillingmors alder og sannsynligheten for at tvillingen er toegget?

### Oppgave 3.

I denne oppgaven behandles et spesialtilfelle av den multiple lineære regresjonsmodellen  $Y_i = b_1 + b_2 x_{i2} + b_3 x_{i3} + \dots + b_p x_{ip} + \varepsilon_i$  der  $x_{ij}$ -ene er gitte forklaringsvariable,  $b_1, \dots, b_p$  regresjonskoeffisienter og feilleddene  $\varepsilon_i$  uavhengige og normalfordelte med forventning  $E\varepsilon_i = 0$  og varians  $\text{Var } \varepsilon_i = \sigma^2$ . Vi lar altså  $x_{i1} = 1$  for alle  $i$ .

Spesialtilfellet består i at  $x_{ij}$ -ene er sentrerte, dvs.

$$\sum_{i=1}^n x_{ij} = n\bar{x}_j = 0$$

og ukorrelerte, dvs.

$$\sum_{i=1}^n x_{ij} x_{ik} = \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k) = 0$$

for  $j, k = 2, 3, \dots, p$  og  $j \neq k$ .

- a) Vis at minste kvadratens estimatorene for  $b_1, b_2, \dots, b_p$  gis ved

$$\hat{b}_1 = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$$

og

$$\hat{b}_j = \frac{\sum_{i=1}^n x_{ij} Y_i}{S_j^2} \quad j = 2, 3, \dots, p$$

der  $S_j^2 = \sum_{i=1}^n x_{ij}^2$ .

(Fortsettes side 5.)

- b) Angi simultanfordelingen til  $(Y_1, Y_2, \dots, Y_n)$ .  
 Forklar hvorfor minste kvadraters estimatorene  $\hat{b}_1, \hat{b}_2, \dots, \hat{b}_p$  også er SME?  
 Det er tilstrekkelig å vise dette under antagelse av at  $\sigma^2$  er kjent.
- c) Angi hva  $w_{ij}$  må være ( $i = 1, \dots, n, j = 1, \dots, p$ ) for at vi kan skrive

$$\hat{b}_j = \sum_{i=1}^n w_{ij} Y_i$$

Vis at  $\hat{b}_1, \hat{b}_2, \dots, \hat{b}_p$  er normalfordelte med

$$\begin{aligned} E\hat{b}_j &= b_j \\ \text{Var}(\hat{b}_1) &= \frac{\sigma^2}{n} \\ \text{Var}(\hat{b}_j) &= \frac{\sigma^2}{S_j^2} \quad \text{når } j = 2, 3, \dots, p \end{aligned}$$

og

$$\text{Cov}(\hat{b}_j, \hat{b}_k) = 0 \quad \text{når } j \neq k.$$

- d) De predikerte verdiene er definert ved

$$\hat{Y}_i = \hat{b}_1 + \hat{b}_2 x_{i2} + \dots + \hat{b}_p x_{ip}$$

Forklar hvorfor  $\hat{Y}_1, \hat{Y}_2, \dots, \hat{Y}_n$  er normalfordelte med  $E\hat{Y}_i = EY_i$  og  $\text{Var} \hat{Y}_i = \sigma^2 \left[ \frac{1}{n} + \frac{x_{i2}^2}{S_2^2} + \frac{x_{i3}^2}{S_3^2} + \dots + \frac{x_{ip}^2}{S_p^2} \right]$ .

(Du skal ikke se på avhengighetene mellom  $\hat{Y}_1, \dots, \hat{Y}_n$ ).

- e) Vis at  $s^2 = \frac{1}{n-p} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$  er en forventningsrett estimator for  $\sigma^2$ .  
 Hint: Benytt uten bevis oppspaltningen

$$\sum_{i=1}^n (Y_i - EY_i)^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - EY_i)^2$$

SLUTT