

# UNIVERSITETET I OSLO

Det matematisk-naturvitenskapelige fakultet

Eksamen i: STK1120 — Innføring i anvendt statistikk – FASIT

Eksamensdag: Fredag 2. juni 2006.

Tid for eksamen: 09.00 – 12.00.

Oppgavesettet er på 4 sider.

Vedlegg: Tabeller for  $\chi^2$ ,  $t$  og  $F$  fordelingen.

Tillatte hjelpemidler: Godkjent kalkulator og formelsamling for STK1100/ STK1110 og for STK1120.

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

## Oppgave 1.

(a) Vi har

$$f(x_1, x_2, \dots, x_n) = f(x_1) \prod_{i=2}^n f(x_i | x_{1:i-1})$$

og  $x_i | x_{1:i-1} \sim N(a_1 x_{i-1} + a_2 x_{i-2}, \sigma^2)$  som gir

$$\begin{aligned} L(a_1, a_2, \sigma^2) &= f(x_1, x_2, \dots, x_n; a_1, a_2, \sigma^2) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x_i - a_1 x_{i-1} - a_2 x_{i-2})^2} \end{aligned}$$

Dette gir

$$\begin{aligned} l(a_1, a_2, \sigma^2) &= \sum_{i=1}^n \left[ -\frac{1}{2} \log(2\pi) - \frac{1}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} (x_i - a_1 x_{i-1} - a_2 x_{i-2})^2 \right] \\ &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - a_1 x_{i-1} - a_2 x_{i-2})^2 \end{aligned}$$

(Fortsettes side 2.)

som viser at maksimering av  $l(a_1, a_2, \sigma^2)$  (som er ekvivalent med maksimering av  $L(a_1, a_2, \sigma^2)$ ) er ekvivalent med minimering av  $\sum_{i=1}^n (x_i - a_1 x_{i-1} - a_2 x_{i-2})^2$

(b) Vi har

$$\frac{\partial}{\partial a_1} S(a_1, a_2) = -2 \sum_{i=1}^n (x_i - a_1 x_{i-1} - a_2 x_{i-2}) x_{i-1}$$

$$\frac{\partial}{\partial a_2} S(a_1, a_2) = -2 \sum_{i=1}^n (x_i - a_1 x_{i-1} - a_2 x_{i-2}) x_{i-2}$$

som viser at  $(\hat{a}_1, \hat{a}_2)$  må tilfredsstille likningene

$$\sum_{i=1}^n (x_i - \hat{a}_1 x_{i-1} - \hat{a}_2 x_{i-2}) x_{i-1} = 0$$

$$\sum_{i=1}^n (x_i - \hat{a}_1 x_{i-1} - \hat{a}_2 x_{i-2}) x_{i-2} = 0$$

som er ekvivalent med at

$$\hat{a}_1 \sum_{i=1}^n x_{i-1}^2 + \hat{a}_2 \sum_{i=1}^n x_{i-1} x_{i-2} = \sum_{i=1}^n x_{i-1} x_i$$

$$\hat{a}_1 \sum_{i=1}^n x_{i-1} x_{i-2} + \hat{a}_2 \sum_{i=1}^n x_{i-2}^2 = \sum_{i=1}^n x_{i-2} x_i$$

Dette er et lineært likningssystem som enkelt kan løses med standard vektor/matrise beregninger.

$$\frac{\partial}{\partial \sigma^2} l(a_1, a_2, \sigma^2) = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - a_1 x_{i-1} - a_2 x_{i-2})^2$$

som gir at  $\hat{\sigma}^2$  er gitt ved

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{a}_1 x_{i-1} - \hat{a}_2 x_{i-2})^2$$

(c) Vi har basert på normaltilnærmingen at  $\hat{\theta} \pm z_{1-\alpha/2} s_{\hat{\theta}}$  er et tilnærmet 100(1 -  $\alpha$ )% konfidensintervall. For  $\alpha = 0.05$ , blir  $z_{0.975} = 1.96$ .

Her er  $s_{\hat{a}_1} = \sqrt{0.0199} = 0.1411$  som gir at  $[0.7110 \pm 1.96 \times 0.1411] = [0.43450, 0.9875]$  er et tilnærmet 95% konfidensintervall for  $a_1$ .

Videre er  $s_{\hat{a}_2} = \sqrt{0.0204} = 0.1428$  som gir at  $[-0.2220 \pm 1.96 \times 0.1428] = [-0.5019, 0.0579]$  er et tilnærmet 95% konfidensintervall for  $a_2$

(Fortsettes side 3.)

## Oppgave 2.

(a) Vi har

$$L(\theta) = \frac{n!}{x_1!x_2!x_3!x_4!} \left(\frac{1}{2} + \frac{1}{4}\theta\right)^{y_1} \left(\frac{1}{4}(1-\theta)\right)^{y_2+y_3} \left(\frac{1}{4}\theta\right)^{y_4}$$

som gir

$$l(\theta) = K + y_1 \log(2 + \theta) + (y_2 + y_3) \log(1 - \theta) + y_4 \log(\theta)$$

og

$$\frac{\partial}{\partial \theta} l(\theta) = \frac{y_1}{2 + \theta} - \frac{y_2 + y_3}{1 - \theta} + \frac{y_4}{\theta}$$

Dermed må ML estimatet tilfredsstillere likningen

$$\frac{y_1}{2 + \hat{\theta}} - \frac{y_2 + y_3}{1 - \hat{\theta}} + \frac{y_4}{\hat{\theta}} = 0$$

som er ekvivalent med at

$$y_1(1 - \theta)\theta - (y_2 + y_3)(2 + \theta)\theta + y_4(2 + \theta)(1 - \theta) = 0$$

som igjen er ekvivalent med at

$$n\theta^2 - (y_1 - 2 * (y_2 + y_3) - y_4)\theta - 2y_4 = 0$$

Da sannsynligheter må ligge mellom 0 og 1, er en negativ  $\theta$  ikke mulig. Samtidig har vi at

$$\frac{\partial^2}{\partial \theta^2} l(\theta) = -\frac{y_1}{(2 + \theta)^2} - \frac{y_2 + y_3}{(1 - \theta)^2} - \frac{y_4}{\theta^2}$$

som alltid er negativ for  $\theta$  mellom 0 og 1, noe som viser at den positive verdien må være et maksimumspunkt.

(b) Vi estimerer forventningsskjevheten til å bli  $0.62822 - 0.62682 = 0.0014$  som er forsvinnende liten i forhold til usikkerheten i  $\hat{\theta}$ , noe som tilsier at  $\hat{\theta}$  er (tilnærmet) forventningsrett.

95% KI basert på normaltilnærming:

$$[\hat{\theta} - z_{0.975} s_{\theta^*}, \hat{\theta} + z_{0.975} s_{\theta^*}] = [0.5310, 0.7226]$$

95% KI basert på standard Bootstrap konfidensintervall:

$$[2\hat{\theta} - \theta_{(975)}^*, 2\hat{\theta} - \theta_{(25)}^*] = [0.52720, 0.7296]$$

Svært like konfidensintervaller, som tilsier at normaltilnærmingen fungerer bra i dette tilfellet.

(c) En kan her enten bruke den generaliserte likelihood ratio testen eller Pearson's  $\chi^2$  test. Har  $X^2 = \sum((y_i - E_i)^2 / E_i) = 0.616$  og  $-2\log(\Lambda) = 0.302$ . Frihetsgrader er  $4 - 1 - 1 = 2$ . Med  $\chi_2^2(0.90) = 4.61$  ser vi at testobservatorene er langt fra signifikante og det er ingen grunn til å forkaste  $H_0$ .

(Fortsettes side 4.)

### Oppgave 3.

Modell:

$$Y_{ijk} = \mu + \alpha_i + \beta_j + \delta_{ij} + \varepsilon_{ijk}$$

der  $\alpha_i$  angir variasjoner som følge av gift,  $\beta_j$  variasjoner som følge av motgift og  $\delta_{ij}$  interaksjon mellom de to faktorene.  $\mu$  er det overordnede forventningsnivå mens  $\varepsilon_{ijk}$  er støledd som angir avvik fra modell (antas å være uavhengige med forventning null, konstant varians og normalfordelt).

Aktuelle hypoteser:

$H_{AB} : \delta_{ij} = 0, \forall i, j$  For testing om additive effekter av de to faktorer

$H_A : \alpha_i = 0, \forall i$  For testing om de ulike giftstoffer har noen effekt

$H_B : \beta_j = 0, \forall j$  For testing om de ulike motgiftstoffer har noen effekt

Naturlig å teste  $H_{AB}$  først. Vi har at den observerte  $F$  verdi er mindre enn  $\chi_6^2(0.10)$  som tilsvarer en P-verdi større enn 0.9.

$H_A$ : Vi har at den observerte  $F$  verdi er større enn  $\chi_2^2(0.995)$  som tilsvarer en P-verdi mindre enn 0.005.

$H_B$ : Vi har at den observerte  $F$  verdi er større enn  $\chi_3^2(0.995)$  som tilsvarer en P-verdi mindre enn 0.005.

Konklusjon: Det er ikke grunn til å forkaste  $H_{AB}$ , men god grunn til å forkaste både  $H_A$  og  $H_B$ , dvs additive effekter av faktorene.

SLUTT