

# UNIVERSITETET I OSLO

## Det matematisk-naturvitenskapelige fakultet

Eksamen i STK2120 — Statistiske metoder og dataanalyse 2

Eksamensdag: Mandag 6. juni 2011.

Tid for eksamen: 14.30–18.30.

Oppgavesettet er på 4 sider.

Vedlegg: Tabell over normal,  $t$ ,  $\chi^2$  og  $F$  fordeling

Tillatte hjelpemidler: Godkjent kalkulator og formelsamling for STK1100/STK1110 og STK2120

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

## FASIT

### Oppgave 1

(a) Modell:

$$X_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \varepsilon_{ijk}$$

der  $\varepsilon_{ijk}$  er uavhengige, normalfordelte med forventning 0 og varians  $\sigma^2$ .

Estimat på variansen er 5.99 i dette tilfellet, (MS for residuals).

(b) Første linje svarer til  $H_0 : \alpha_i = 0$  for alle  $i$ . Forkastes med P-verdi lik 0.0018

Andre linje svarer til  $H_0 : \beta_j = 0$ , for alle  $j$ . Forkastes med P-verdi tilnærmet lik 0.

Tredje linje svarer til  $H_0 : \gamma_{ij} = 0$ , for alle  $i, j$ . Her vil vi ikke forkaste hypotesen (med P-verdi lik 0.251).

En kan da forenkle modellen til

$$X_{ijk} = \mu + \alpha_i + \beta_j + \varepsilon_{ijk}$$

dvs ingen interaksjonsledd.

### Oppgave 2

(a) For å bruke  $\chi^2$  testen bør en ha en forventet verdi på minst 5 for hver kategori. De to siste kategoriene har mye mindre forventninger, men hvis vi slår de sammen med den 3. kategorien, vil alle kategorier tilfredsstillte dette.

(Fortsettes på side 2.)

Med 3 kategorier og en fri parameter har vi  $3-1-1=1$  frihetsgrad. Dette betyr at vi vil forkaste  $H_0$ : Data følger Poisson fordelingen hvis  $\chi^2 > \chi_{\alpha,1}^2 = 3.841$  hvis  $\alpha = 0.05$ . I dette tilfellet er testobservatoren langt større og vi får dermed forkastning. Siden også  $\chi^2 > \chi_{0.001,1}^2 = 10.82$ , så er P-verdien mindre enn 0.001.

Vi kan dermed konkludere med at vi kan forkaste hypotesen om at dataene følger en Poisson fordeling på signifikansnivå 0.05 (P-verdi  $< 0.001$ ).

(b) Da  $\theta = \Pr(Y = 0t)$ , må vi ha  $0 \leq \theta \leq 1$ . For  $\theta = e^{-\lambda}$ , blir  $\Pr(Y = y) = \lambda^y e^{-\lambda} / y!$  for alle  $y$  som svarer til Poisson fordelingen.

(c) Vi har at

$$\begin{aligned} L(\boldsymbol{\theta}) &= \prod_{i=1}^n p(y_i) = \prod_{i=1}^n \prod_{y=0}^{\infty} p(y)^{I(y_i=y)} \\ &= \prod_{y=0}^{\infty} p(y)^{\sum_{i=1}^n I(y_i=y)} = \prod_{y=0}^{\infty} p(y)^{N_y}. \end{aligned}$$

Dermed blir

$$\begin{aligned} l(\boldsymbol{\theta}) &= \sum_{y=0}^{\infty} N_y \log(p(y)) \\ &= N_0 \log(p(0)) + \sum_{y=1}^{\infty} N_y \log(p(y)) \\ &= N_0 \log(\theta) + \\ &\quad \sum_{y=1}^{\infty} N_y [\log(1 - \theta) + \lambda - \log(e^\lambda - 1) + y \log(\lambda) - \lambda - \log(y!)] \\ &= \text{Konst} + N_0 \log(\theta) + (n - N_0) \log(1 - \theta) \\ &\quad - (n - N_0) \log(e^\lambda - 1) + \log(\lambda) \sum_{y=1}^{\infty} y N_y. \end{aligned}$$

(d) Score-funksjonen er de deriverte av log-likelihood funksjonen mhp parametrene. Vi har at

$$\begin{aligned} s_1(\boldsymbol{\theta}) &= \frac{\partial}{\partial \theta} l(\boldsymbol{\theta}) \\ &= \frac{N_0}{\theta} - \frac{n - N_0}{1 - \theta} \end{aligned}$$

og

$$\begin{aligned} s_2(\boldsymbol{\theta}) &= \frac{\partial}{\partial \lambda} l(\boldsymbol{\theta}) \\ &= - (n - N_0) \frac{e^\lambda}{e^\lambda - 1} + \frac{1}{\lambda} \sum_{y=1}^{\infty} y N_y \end{aligned}$$

(Fortsettes på side 3.)

Videre er

$$E[s_1(\boldsymbol{\theta})] = \frac{n\theta}{\theta} - \frac{n - n\theta}{1 - \theta} = 0.$$

Tilsvarende er

$$\begin{aligned} E[s_2(\boldsymbol{\theta})] &= -(n - n\theta) \frac{e^\lambda}{e^\lambda - 1} + n(1 - \theta) \frac{1}{\lambda} \frac{e^\lambda}{e^\lambda - 1} \lambda \\ &= -n(1 - \theta) \left[ \frac{e^\lambda}{e^\lambda - 1} - \frac{e^\lambda}{e^\lambda - 1} \right] = 0 \end{aligned}$$

Den generelle teorien sier også at forventningen skal være null.

*Mellomregning, ikke krevd i oppgaven*

Merk at siden  $s_1$  ikke avhenger av  $\lambda$ , så er kryss-leddene i informasjonsmatrisene lik 0.

$$-\frac{\partial^2}{\partial \theta^2} l(\boldsymbol{\theta}) = \frac{N_0}{\theta^2} + \frac{n - N_0}{(1 - \theta)^2}$$

med forventning

$$E\left[-\frac{\partial^2}{\partial \theta^2} l(\boldsymbol{\theta})\right] = \frac{n\theta}{\theta^2} + \frac{n - n\theta}{(1 - \theta)^2} = \frac{n}{\theta} + \frac{n}{1 - \theta}$$

mens

$$-\frac{\partial^2}{\partial \lambda^2} l(\boldsymbol{\theta}) = -(n - N_0) \frac{e^\lambda}{(e^\lambda - 1)^2} + \frac{1}{\lambda^2} \sum_{y=1}^{\infty} y N_y$$

med forventning

$$\begin{aligned} E\left[-\frac{\partial^2}{\partial \lambda^2} l(\boldsymbol{\theta})\right] &= -(n - n\theta) \frac{e^\lambda}{(e^\lambda - 1)^2} + \frac{1}{\lambda^2} n(1 - \theta) \frac{e^\lambda}{e^\lambda - 1} \lambda \\ &= n(1 - \theta) \frac{e^\lambda}{e^\lambda - 1} \left[ \frac{1}{\lambda} - \frac{1}{e^\lambda - 1} \right] \end{aligned}$$

- (e) Et problem med Newton-Raphson algoritmen er at  $\mathbf{J}$  ikke behøver å være positiv definit. Hvis den ikke er det, vil den kvadratiske tilnærmingen ikke ha et maksimumspunkt, og oppdateringen kan gi en dårligere gjett på maksimumspunktet enn forrige verdi.

Scoring-algoritmen er en modifikasjon av N-R, ved at  $\mathbf{J}$  erstattes med dens forventning,  $\mathbf{I}$ . Siden  $\mathbf{I}$  er kovariansmatrisen til scoring funksjonen, vil den alltid være positivt definit, og dermed løse denne svakheten ved N-R.

At informasjonsmatrisene er diagonale, betyr at de to parametrene oppdateres uavhengige av hverandre noe som både forenkler og kan gi raskere konvergens (dette har vi ikke diskutert i kurset).

(Fortsettes på side 4.)

(f) Vi har at

$$\begin{aligned}\theta^{(s+1)} &= \theta^{(s)} + \frac{\frac{N_0}{\theta^{(s)}} - \frac{n-N_0}{1-\theta^{(s)}}}{\frac{n}{\theta^{(s)}} - \frac{n}{1-\theta^{(s)}}} \\ &= \theta^{(s)} + \frac{N_0(1-\theta^{(s)}) - (n-N_0)\theta^{(s)}}{n(1-\theta^{(s)}) - n\theta^{(s)}} \\ &= \theta^{(s)} + \frac{N_0}{n} - \theta^{(s)} \\ &= \frac{N_0}{n}\end{aligned}$$

Denne verdien avhenger ikke av  $\theta^{(s)}$  slit at vi vil få den samme verdien på hver eneste iterasjon.

(g) Kan løse  $s_1(\theta) = 0$  direkte. Gir

$$\begin{aligned}\frac{N_0}{\theta} - \frac{n-N_0}{1-\theta} &= 0 \\ \Downarrow \\ N_0(1-\theta) - (n-N_0)\theta &= 0 \\ \Downarrow \\ \theta &= \frac{N_0}{n}\end{aligned}$$

Kan dermed sette denne løsningen inn direkte og behøver kun å optimere likelihood funksjone mhp én parameter. Dette gir som regel mye raskere konvergens til max-punkt.

(h) Siden informasjonsmatrisene er diagonale, er også de inverse diagonale. Dermed vil de asymptotiske kovariansmatrisene være diagonale og estimatene  $\hat{\theta}$  og  $\hat{\lambda}$  er tilnærmet uavhengige.

Et 95% konfidensintervall for  $\theta$  er  $[\hat{\theta} \pm z_{0.025}s_{\hat{\theta}}]$ . Med  $z_{0.025} = 1.960$  og  $s_{\hat{\theta}} = \sqrt{1/I_{11}} = 0.0289$ , får vi et intervall  $[0.696, 0.810]$ .

Et 95% konfidensintervall for  $\lambda$  er  $[\hat{\lambda} \pm z_{0.025}s_{\hat{\lambda}}]$ . Med  $z_{0.025} = 1.960$  og  $s_{\hat{\lambda}} = \sqrt{1/I_{22}} = 0.164$ , får vi et intervall  $[0.651, 1.294]$ .

(i) Bootstrap intervall for  $\theta$ :  $\delta_L = 0.695 - 0.753 = -0.058$ ,  $\delta_U = 0.812 - 0.753 = 0.059$  som gir intervallet  $[0.695, 0.812]$ .

Bootstrap intervall for  $\lambda$ :  $\delta_L = 0.656 - 0.972 = -0.316$ ,  $\delta_U = 1.298 - 0.972 = 0.326$  som gir intervallet  $[0.646, 1.288]$ .

Svært like intervaller. Indikerer at normaltilnærming er rimelig.

(j) Ønsker å teste  $H_0 : \theta = \exp(-\lambda)$ .

Kan lage et bootstrap konfidensintervall for  $\theta - \exp(-\lambda)$ . Hvis dette ikke dekker 0, betyr det at  $\theta$  er signifikant forskjellig fra  $\exp(-\lambda)$  og vi kan forkaste  $H_0$ .