

TMA 4315 14. Desember 2006

Oppgave 1

a) [Se boka s. 144]

Respons er ordinell, multinomisk.

Prop. oddsmodell antar en latent kontinuerlig variabel som måler CGI.

$$\ln \frac{\pi_0}{\pi_1 + \pi_2} = \beta_{00} + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$

$$\ln \frac{\pi_0 + \pi_1}{\pi_2} = \beta_{01} + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$

Siden den ~~inversen~~ inverse av logit-funksjonen er den logistiske funksjon kan vi

$$\pi_0 = \frac{e^{\beta_{00} + \underline{x}^T \underline{\beta}}}{1 + e^{\beta_{00} + \underline{x}^T \underline{\beta}}}$$

$$\pi_0 + \pi_1 = \frac{e^{\beta_{01} + \underline{x}^T \underline{\beta}}}{1 + e^{\beta_{01} + \underline{x}^T \underline{\beta}}}$$

$$\Rightarrow \pi_1 = \frac{e^{\beta_{01} + \underline{x}^T \underline{\beta}} - e^{\beta_{00} + \underline{x}^T \underline{\beta}}}{1 + e^{\beta_{01} + \underline{x}^T \underline{\beta}}}$$

og endelig

$$\pi_2 = 1 - \pi_0 - \pi_1$$

b) 
$$\frac{P(\text{CGI} \leq 0 | \underline{x})}{P(\text{CGI} > 0 | \underline{x})} = \frac{\pi_0}{\pi_1 + \pi_2} = e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3}$$

Ser at hvis  $x_3$  økes med 1 (og  $x_1, x_2$  ikke endres) vil dette multipliseres med  $e^{\beta_3}$ . Tilsvarende for  $P(\text{CGI} \leq 1 | \underline{x}) / P(\text{CGI} > 1 | \underline{x})$

Fortolkning: Hvis  $e^{\beta_3} < 1$  (dvs  $\beta_3 < 0$ ) vil økning i  $x_3$  gi en reduksjon i odds for å være i tilstand 0 eller  $\leq 1$  etter behandlingen.

Ser av  $\textcircled{*}$  at økninger i  $x_1$  og  $x_2$  medfører på samme måte multiplikasjon med  $e^{\beta_1}$ ,  $e^{\beta_2}$ , henholdsvis.

Fortolkninger: Hvis f.eks.  $e^{\beta_1} < 1$  vil det å gå over fra hver annen uke til hver tredje uke gi en reduksjon i odds for de "gode tilstandene" 0 og  $\leq 1$ .

Hvis  $e^{\beta_2} < 1$  vil ~~kurven~~ menn ha mindre odds enn kvinner for å gå til de "gode tilstandene" 0 og  $\leq 1$ .

c) Sahwert modell:

Hver rad i tabellen har sin egen  $\pi$ -vektor,  $(\pi_{i0}, \pi_{i1}, \pi_{i2})$ . Modellen vil dermed ha  $12 \cdot 2 = 24$  frie parametre

siden  $\pi_{i0} + \pi_{i1} + \pi_{i2} = 1$

Fra pensum er

$$D = 2 \left[ l_{\text{satursat modell}} - l_{\text{aktuell modell}} \right]$$

der  $l_m$  betyr maksimum log likelihood for modell  $m$ .

Det er vist i et notat fra siste forelesning (se web-side) at

$$D = 2 \sum_{i=1}^n \sum_{j=0}^2 y_{ij} \ln \frac{y_{ij}}{\hat{y}_{ij}}$$

der  $\hat{y}_{ij} = n_i \hat{\pi}_{ij}$  og  $\tilde{y}_i = (y_{i0}, y_{i1}, y_{i2})$

er responsen for  $i$ -te linje i tabellen, mens  $\hat{\pi}_{ij}$  er estimerte  $\pi_{ij}$  fra den aktuelle modellen.

$$\begin{aligned} df &= \text{ant. frie parametre i satursat modell} \\ &\quad - \quad \text{---} \quad \text{aktuell modell} \\ &= 24 - 5 = \underline{\underline{19}} \end{aligned}$$

d)  $B * K + B * I$  har lineære prediktorer

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_1 x_2 + \beta_5 x_1 x_3$$

(sett inn på høyre side i modellen i (a)).

Den har 7 parametre, des  $df = 24 - 7 = 17$

Antall parametre og <sup>frihetsgrader</sup> ~~test~~ for modellene:

	$K+I$	$B+K+I$	$B*I+K$	$B*K+B*I$
Param.	4	5	6	7
df	20	19	18	17

Tester  $H_0: K+I$  mot hver av de andre modellene.

Mot  $B+K+I$ :  $\Delta D = 10.64 - 10.56 = 0.08, \approx \chi^2_1$  under  $H_0$   
Forkast ikke!

Mot  $B*I+K$ :  $\Delta D = 10.64 - 8.52 = 2.12, \approx \chi^2_2$  under  $H_0$   
Forkast ikke!

Mot  $B*K+B*I$ :  $\Delta D = 10.64 - 8.33 = 2.31, \approx \chi^2_3$  under  $H_0$   
Forkast ikke!

Velger derfor modellen  $K+I$  (dis. behandl. intervall har ikke betydning).

$$e) \hat{e}^{\hat{\beta}_1} = e^{\hat{\beta}_1} = e^{-0.21992} = \underline{0.8026}$$

Konf. int.:

$$\approx 95\% \text{ for } \beta_1: \hat{\beta}_1 \pm 1.96 \cdot SD(\hat{\beta}_1)$$

$$\approx 95\% \text{ for } e^{\beta_1}: e^{\hat{\beta}_1 \pm 1.96 \cdot SD(\hat{\beta}_1)}$$

$$= -0.21992 \pm 1.96 \cdot 0.75607$$

des  $e$

$$\text{des } [0.1824, 3.5324]$$

Dette inneholder 1, så vi kan ikke forkaste  $H_0: e^{\beta_1} = 1$  (des  $\beta_1 = 0$ ) som betyr at behandlingsintervall ikke har signifikant betydning.

Dette stemmer med konklusjonen i (d)

$$\hat{e}^{\hat{\beta}_2} = e^{\hat{\beta}_2} = e^{-2.15758} = \underline{0.1156}$$

$$\hat{e}^{\hat{\beta}_3} = e^{\hat{\beta}_3} = e^{-2.27249} = \underline{0.1031}$$

Ser på en kvinne, init. COI = 5, injeksj. hver annen uke:

$$\text{des } x_1 = 0, x_2 = 0, x_3 = 5.$$

$$\begin{aligned}
 \text{Fra (a)} \quad \hat{\pi}_0 &= \frac{e^{-6 - \hat{\beta}_{00} + 5\hat{\beta}_3}}{1 + e^{-6 - \hat{\beta}_{00} + 5\hat{\beta}_3}} \\
 &= \frac{e^{8.47538 + 5 \cdot (-2.27249)}}{1 + e^{8.47538 + 5 \cdot (-2.27249)}} \\
 &= \underline{\underline{0.0528}}
 \end{aligned}$$

Standardavvik beregnes ved å Taylor-utvikle

$\hat{\pi}_0$  omkring  $(\beta_{00}, \beta_3)$

$$\text{La } f(x, y) = \frac{e^{x+5y}}{1+e^{x+5y}}$$

$$\text{Da er } \frac{\partial f}{\partial x} = \frac{e^{x+5y}}{(1+e^{x+5y})^2} = f(1-f)$$

$$\frac{\partial f}{\partial y} = \frac{5e^{x+5y}}{(1+e^{x+5y})^2} = 5f(1-f)$$

Dermed

$$\begin{aligned}
 \hat{\pi}_0 &\approx \pi_0 + \pi_0(1-\pi_0) (\hat{\beta}_{00} - \beta_{00}) \\
 &\quad + 5\pi_0(1-\pi_0) (\hat{\beta}_3 - \beta_3)
 \end{aligned}$$

slut at

$$\text{var}(\hat{\pi}_0) \approx \pi_0^2 (1-\pi_0)^2 \left[ \text{Var}(\hat{\beta}_{00}) + 25 \text{Var}(\hat{\beta}_3) + 10 \text{Cov}(\hat{\beta}_{00}, \hat{\beta}_3) \right]$$

Estimerer dette ved å sette  $\hat{\pi}_0$  for  $\pi_0$ ,  
og lese av  $\text{Var}(\cdot)$ ,  $\text{Cov}(\cdot, \cdot)$  fra R-utskrift.  
Dette gir

$$\begin{aligned} \text{SD}(\hat{\pi}_0) &= 0.0528 \cdot 0.9472 \cdot \sqrt{11.1599 + 25 \cdot 0.04879 - 10 \cdot 1.8574} \\ &= \underline{\underline{0.1094}} \end{aligned}$$

## Oppgave 2.

$$a) f(y_i; \theta_i) = \theta_i \cdot e^{-\theta_i y_i} = e^{-\theta_i y_i + \ln \theta_i}$$

som kommer fra familien  $f(y; \theta) = e^{-\theta y + \ln \theta}$

Med notasjon fra boka:

$$a(y) = y, \quad b(\theta) = -\theta, \quad c(\theta) = \ln \theta, \quad d(y) = 0.$$

$$\text{Når } b'(\theta) = -1, \quad b''(\theta) = 0$$

$$c'(\theta) = \frac{1}{\theta}, \quad c''(\theta) = -\frac{1}{\theta^2}$$

Dermed (fra boka)

$$\underline{\underline{\mu_i}} = -\frac{c'(\theta_i)}{b'(\theta_i)} = \underline{\underline{\frac{1}{\theta_i}}}$$

$$\underline{\underline{\sigma_i^2}} = \frac{b''(\theta_i) c'(\theta_i) - c''(\theta_i) b'(\theta_i)}{(b'(\theta_i))^3} = \underline{\underline{\frac{1}{\theta_i^2}}}$$

$$\begin{aligned} b) \quad l &\stackrel{\text{def}}{=} \sum_{i=1}^N \ln f(y_i; \theta_i) \\ &= \sum_{i=1}^N (-\theta_i y_i + \ln \theta_i) \quad (*) \end{aligned}$$

Når

$$D = 2 [ l_{\text{saturnt}} - l_{\text{aktuell modell}} ]$$

Saturnt modell: alle  $\theta_i$  ulike

$$\frac{\partial l}{\partial \theta_i} = -y_i + \frac{1}{\theta_i}$$

Settes dette lik 0 får  $\hat{\theta}_i = \frac{1}{y_i}$

$$\text{Dermed fra } (*) : l_{\text{saturnt}} = \sum_{i=1}^N (-1 + \ln \frac{1}{y_i})$$

I GLM-modellen er  $\mu_i$  ved en  $\mu_i$  (som vi her ikke trenger noe uttrykk for), som her kalles  $\hat{y}_i$ . Dermed bli faktisk  
gilt ved  $\hat{\theta}_i = \frac{1}{\hat{y}_i}$  i (\*).

$$l_{aktuell} = \sum_{i=1}^N \left[ -\frac{y_i}{g_i} + \ln \frac{1}{g_i} \right]$$

$$= \sum_{i=1}^N \left[ -\frac{y_i}{g_i} - \ln g_i \right]$$

Dermed er

$$D = 2 \sum_{i=1}^N \left[ -1 - \ln g_i + \frac{y_i}{g_i} + \ln \frac{1}{g_i} \right]$$

$$= 2 \sum_{i=1}^N \left[ \frac{y_i - g_i}{g_i} - \ln \frac{g_i}{g_i} \right] \text{ Q.E.D.}$$

c) Pearson-res:  $r_i = \frac{y_i - E(y_i)}{\sqrt{\text{Var}(y_i)}}$

$$= \frac{y_i - g_i}{g_i}$$

siden  $\text{Var}(y_i) = E(y_i)^2$   
for eksponentiell  
fordeling.

Forsøelse at  $x^2 \approx D$  Taylor-utvikling i

$$f(x) = \frac{x-a}{a} - \ln \frac{x}{a} \text{ omkring } x=a.$$

Vi har  $f(a) = 0$ ,  $f'(x) = \frac{1}{a} - \frac{1}{x}$  så  $f'(a) = 0$ ,

$$f''(x) = \frac{1}{x^2} \text{ så } f''(a) = \frac{1}{a^2}$$

Dermed:  $f(x) \approx \frac{1}{2} \cdot \frac{1}{a^2} (x-a)^2$

og  $D \approx \sum_{i=1}^N \frac{(y_i - \hat{y}_i)^2}{\hat{y}_i^2} = \sum_{i=1}^N r_i^2 = \chi^2$  Q.E.D.

ved  $\hat{a}$   
sette inn i  
oppgitt D i  
oppgavetekst

d)  $H_0$  svarer til en GLM der alle  $\theta_i$  er like, lik en  $\theta$ .

Da er  $l = -\theta \sum_{i=1}^N y_i + N \ln \theta$

denne og som ved  $\hat{a}$  sette  $l = 0$  gir  ~~$\hat{\theta} = \frac{1}{\frac{1}{N} \sum_{i=1}^N y_i}$~~

$\hat{\theta} = \frac{1}{\frac{1}{N} \sum_{i=1}^N y_i} = \frac{1}{\bar{y}}$

der  $\hat{\theta}_i = \frac{1}{\bar{y}}$  for hver  $i$ , der  $\hat{\mu}_i = \hat{y}_i = \bar{y}$

Da leri fra (b)

$D = 2 \sum_{i=1}^N \left( \frac{y_i - \bar{y}}{\bar{y}} - \ln \frac{y_i}{\bar{y}} \right)$

som er  $\approx \chi^2_{N-1}$  under  $H_0$

ant. param. i saturert modell

ant. param. i modell under  $H_0$

(Vi forkastar  $H_0$  hvis  $D$  er stor).

Tilsvarende blir  $\chi^2 = \sum_{i=1}^N \left( \frac{y_i - \bar{y}}{\bar{y}} \right)^2$

en testobservator som er  $\chi^2_{N-1}$  under  $H_0$ .

Merk at vi kan skrive

$$\chi^2 = \frac{\sum_{i=1}^N (y_i - \bar{y})^2}{\bar{y}^2} = \frac{(N-1) s^2}{\bar{y}^2}$$

Under  $H_0$  er både  $s^2$  og  $\bar{y}^2$  estimatorene for  $\mu^2$  (siden  $\text{Var}(Y) = E(Y)^2$  i eksponensiell-fordelingen)

Forkastning vil da skje hvis  $s^2$  blir "for stor" i forhold til  $\bar{y}^2$  som er en intuitiv testmetode.