

# UNIVERSITETET I OSLO

## Det matematisk-naturvitenskapelige fakultet

Eksamensdag:	STK3100 — Innføring i generaliserte lineære modeller
Tid for eksamen:	Mandag 5. desember 2011.
Oppgavesettet er på 3 sider.	14.30 – 18.30.
Vedlegg:	Tabell over normal, $\chi^2$ og $t$ fordeling
Tillatte hjelpeemidler: STK1100/STK1110 og STK2120	Godkjent kalkulator og formelsamling for

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

### Oppgave 1

- (a) Modellen kalles *random intercept model*

Slike modeller er nyttige for å bygge inn korrelasjoner mellom variable som kommer fra samme individ/gruppe.

- (b) Vi har at

$$\mathbf{Y}_i = \mathbf{X}_i\boldsymbol{\beta} + b_i\mathbf{1} + \boldsymbol{\varepsilon}_i, \quad \boldsymbol{\varepsilon}_i \sim N(0, \sigma^2 \mathbf{I})$$

som gir at

$$\mathbf{Y}_i \sim N(\mathbf{X}_i\boldsymbol{\beta}, \sigma_b^2 \mathbf{1}\mathbf{1}^T + \sigma^2 \mathbf{I})$$

Ved at vi har et eksplisitt uttrykk for den marginale fordeling for  $\mathbf{Y}_i$ , har vi også et eksplisitt uttrykk for likelihooden

$$L(\boldsymbol{\beta}, \sigma_b^2, \sigma^2) = \prod_{i=1}^N f(y_i; \boldsymbol{\beta}, \sigma_b^2, \sigma^2)$$

og denne kan så puttes inn i en numerisk optimerer for å finne ML-estimatene (evt REML estimator).

- (c) Vi har

Parameter	$\beta_1$	$\beta_1$	$\beta_2$	$\sigma_b$	$\sigma$
Estimat	-4.028899	2.873710	-0.002898	0.040365	0.135060

Vi har at korrelasjonen mellom to variable fra samme fangst er

$$\frac{\sigma_b^2}{\sigma_b^2 + \sigma^2} \stackrel{\text{estimert}}{\approx} \frac{0.0016294}{0.0016294 + 0.0182412} = 0.082$$

(Fortsettes på side 2.)

(d) Vi har at  $\hat{\beta}$  er tilnærmet normalfordelt og dermed blir

$$\hat{\mu} = \hat{\beta}_0 + \hat{\beta}_1 \log(66) + \hat{\beta}_2 \log(0.46)$$

også tilnærmet normalfordelt med varians

$$\begin{aligned}\text{Var}[\hat{\mu}] &= \text{Var}[\hat{\beta}_0] + \log(66)^2 \text{Var}[\hat{\beta}_1] + \log(0.46)^2 \text{Var}[\hat{\beta}_2] + \\ &\quad 2 \log(66) \text{Cov}[\hat{\beta}_0, \hat{\beta}_1] + 2 \log(0.46) \text{Cov}[\hat{\beta}_0, \hat{\beta}_2] + \\ &\quad 2 \log(66) \log(0.46) \text{Cov}[\hat{\beta}_1, \hat{\beta}_2] \\ &= 0.2009^2 = 0.04037467\end{aligned}$$

Dermed er et 95% konfidensintervall for  $\mu$  lik

$$\hat{\mu} \pm 1.96 \text{SE}(\hat{\mu}) = [7.619373, 8.407036]$$

Siden  $L < \mu < U \Leftrightarrow \exp(L) < \exp(\mu) < \exp(U)$  blir dermed et 95% konfidensintervall for  $\theta$  lik  $[2037.283, 4478.465]$

(e) Strategi

- (a) Start med modell med alle forklaringsvariable og så mange interaksjoner som mulig
- (b) Finn optimal struktur på tilfeldige effekter.  
Her bør REML brukes!
- (c) Finn optimal struktur for faste effekter.  
Her bør ML brukes!
- (d) Presenter endelig modell med REML estimering.

## Oppgave 2

(a) Vi har at den eksponensielle klasse er gitt ved

$$f(y; \theta, \phi) = c(y; \phi) \exp\left(\frac{y\theta - a(\theta)}{\phi}\right)$$

For den binomiske fordeling har vi

$$\begin{aligned}f(y; \pi) &= \binom{n}{y} \pi^y (1 - \pi)^{n-y} \\ &= \binom{n}{y} \exp(y \log(\pi) + (n - y) \log(1 - \pi)) \\ &= \binom{n}{y} \exp(y \log(\pi/(1 - \pi)) + n \log(1 - \pi)) \\ &= c(y; \phi) \exp(y\theta - a(\theta))\end{aligned}$$

(Fortsettes på side 3.)

med  $\theta = \log(\pi/(1-\pi))$ ,  $\phi = 1$  og  $a(\theta) = -n \log(1-\pi) = -n \log(1 + \exp(-\theta))$ ,  $c(y; \pi) = \binom{n}{y}$ .

Kanonisk link:  $g(\pi) = \log(\pi/(1-\pi))$

Vi modellerer  $\pi$  gjennom  $g(\pi) = \eta = \mathbf{x}^T \boldsymbol{\beta}$ . Med kanonisk link mener vi at  $\theta = \eta$ , som forenkler matematikken involvert (score-likningene og informasjonsmatrisene blir enklere)

- (b)  $AIC = -2 \log L(\hat{\theta}) + 2q$  der  $L$  er likelihood verdi innsatt estimat på de ukjente parametre  $\theta$  og  $q$  er antall parametre i modellen. Dvs vi har et straffeledd for kompleksitet av modellen.

En velger den modell som har minst AIC verdi. Her blir det modellen med probit link-funksjon.

Her vil vi sammenlikne modeller som ikke er nøstet i hverandre. Dermed vil LR og Wald-type tester ikke være egnede. AIC kan imidlertid brukes mer generelt.

Her vil vi i praksis velge den modell som gir høyest likelihoodverdi da kompleksiteten (antall parametre) er de samme for alle valg av link-funksjoner.

- (c) Likelihoodfunksjonen er i dette tilfellet vanskelig å beregne pga den latente tilfeldige effekten, som medfører at likelihooden er gitt som et integral. Ved å skrive integranden som  $e^{g_i(\mathbf{b}_i)}$  og deretter gjøre en (2. ordens) Taylor tilnærming av  $g_i$ , får en Laplace approksimasjonen. Denne vil være betraktelig enklere å beregne og kan da optimeres for å finne estimerer.
- (d) Vi har at  $-2LR = -2(-240.8 + 240.6) = 0.4$ . Vi har her én parameter mer i modellen med tilfeldige effekter. Vi må imidlertid ta hensyn til at vi her tester en  $H_0$  som ligger på randen av parameter-rommet. Dermed må vi bruke en mikstur av  $\chi_0^2$  og  $\chi_1^2$  for beregning av P-verdi. Dette svarer til å beregne P-verdien under  $\chi_1^2$  fordelingen og så dele på 2. Nå er  $P(\chi_1^2 > 0.4) = 0.527$  som dermed gir en P-verdi på 0.2635. Dette tilsier at vi ikke har grunnlag for å forkaste  $H_0$  i dette tilfellet.
- (e) Da `log(haulsize)` har en liten z verdi (ikke signifikant) både for modellen(e) i oppgave 1 og i oppgave 2 så antyder dette at denne variabelen ikke er så viktig. Merk dog at vi kun bruker et delsett av det totale datasettet, og det kan være vi finner denne variabelen til å være signifikant hvis vi brukte det fulle datasett.

SLUTT