

UNIVERSITETET I OSLO

Det matematisk-naturvitenskapelige fakultet

- Eksamen i: ST 202 — Statistiske slutninger for den eksponentielle fordelingsklasse.
- Eksamensdag: Fredag 17. desember 1993.
- Tid for eksamen: 09.00 – 15.00.
- Oppgavesettet er på 4 sider.
- Vedlegg: Ingen.
- Tillatte hjelpemidler: Formelsamlinger for ST 101, ST 102, ST 103, lommeregner.

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

Oppgave 1.

Vi har responsen Y_1, \dots, Y_n fra en generalisert lineær modell (GLM), dvs. Y_1, \dots, Y_n er uavhengige og Y_i har tetthet $f_{Y_i}(y; \theta_i, \phi) = \exp\left(\frac{\theta_i y - b(\theta_i)}{a(\phi)} + c(y, \phi)\right)$ og lineær prediktor $\eta_i = \boldsymbol{\beta}' \mathbf{x}_i = \sum_{j=1}^p \beta_j x_{ji} = g(\mu_i)$ for linkfunksjon $g(\cdot)$ og $\mu_i = EY_i$. La dessuten $\mathbf{Y}' = (Y_1, \dots, Y_n)$ og $\boldsymbol{\mu}' = (\mu_1, \dots, \mu_n)$.

- a) Definer devians $D(\mathbf{Y}, \boldsymbol{\mu})$ og skalert devians $D^*(\mathbf{Y}, \boldsymbol{\mu})$. Angi hvordan og begrunn hvorfor $D^*(\mathbf{Y}, \boldsymbol{\mu})$ kan benyttes til å teste hypotesen (der $1 \leq q < p$)

$$H_0 : \beta_{q+1} = \dots = \beta_p = 0 \text{ mot } H_1 : \text{Alle } \beta_j \text{ vilkårlige.}$$

- b) Finn eksplisitte uttrykk for $D(\mathbf{Y}, \boldsymbol{\mu})$ og $D^*(\mathbf{Y}, \boldsymbol{\mu})$ når

(i) $f_{Y_i}(y) = \frac{\mu_i^y}{y!} e^{-\mu_i}$, dvs. Y_i poissonfordelt

(ii) $f_{Y_i}(y) = \left(\frac{\nu}{\mu_i}\right)^\nu \frac{y^{\nu-1}}{\Gamma(\nu)} e^{-\frac{\nu}{\mu_i} y}$, dvs. Y_i gammafordelt.

(Fortsettes side 2.)

- c) Vis at estimeringslikningene for sannsynlighetsmaksimeringsestimatoren $\hat{\beta}$ for β kan skrives

$$\sum_{i=1}^n \frac{Y_i - \hat{\mu}_i}{V(\hat{\mu}_i)} \frac{x_{ji}}{g'(\hat{\mu}_i)} = 0 \quad j = 1, \dots, p$$

der $V(\mu_i) = \text{Var } Y_i/a(\phi)$ og $\hat{\mu}_i = g^{-1}(\hat{\beta}' x_i)$.

- d) Vis at hvis

A. $g(\mu) = \ln(\mu)$ samt at $\eta_i = \beta_1 + \sum_{j=2}^p \beta_j x_{ji}$, dvs. η_i inneholder et konstantledd β_1 , så holder

$$\sum_{i=1}^n \frac{(Y_i - \hat{\mu}_i)\hat{\mu}_i}{V(\hat{\mu}_i)} = 0 \quad (1)$$

Vis at formelen (1) også holder hvis

B. $g(\mu) = \mu^\alpha$ for gitt $\alpha \neq 0$ også når det ikke er konstantledd i η_i .

(Hint: Benytt at $\hat{\eta}_i = \sum_{j=1}^p \hat{\beta}_j x_{ji} = g(\hat{\mu}_i)$.)

- e) Anta at formelen (1) holder. La $\hat{\mu}' = (\hat{\mu}_1, \dots, \hat{\mu}_n)$. Finn forenklete uttrykk for $D^*(\mathbf{Y}, \hat{\mu})$ og $D(\mathbf{Y}, \hat{\mu})$ i forhold til dem du fant i punkt b) for

- (i) Y_i poissonfordelt
- (ii) Y_i gammafordelt.

Oppgave 2.

Anta Y_1 og Y_2 er uavhengige og binomisk fordelte med $EY_i = n_i p_i$ og $\text{Var } Y_i = n_i p_i (1 - p_i)$. La $\theta_i = \ln\left(\frac{p_i}{1-p_i}\right)$ og $\psi = \exp(\theta_1 - \theta_2)$.

- a) Gi en fortolkning av ψ . Vis at sannsynlighetsmaksimeringsestimatoren for ψ er

$$\psi^* = \frac{Y_1(n_2 - Y_2)}{(n_1 - Y_1)Y_2}.$$

Angi en estimator for variansen til $\ln(\psi^*)$.

(Fortsettes side 3.)

- b) Vis at Y_1 betinget mhp. $Z = Y_1 + Y_2 = z$ er ikke-sentralt hypergeometrisk fordelt, dvs. har tetthet

$$f_{Y_1|Z}(y) = \frac{\binom{n_1}{y} \binom{n_2}{z-y} \psi^y}{\sum_{\nu} \binom{n_1}{\nu} \binom{n_2}{z-\nu} \psi^{\nu}}$$

der summen tas over $\nu \in \{\max(0, z - n_2), \min(n_1, z)\}$.

- c) Angi den sterkeste styrkerette α -nivå testen for

$$H_0 : \psi \geq \psi_0 \quad \text{mot} \quad H_1 : \psi < \psi_0$$

der ψ_0 er en gitt størrelse.

- d) Utfør testen for $\psi_0 = 2$, $n_1 = n_2 = 10$, $Y_1 = 2$, $Z = 8$ og $\alpha = 0.05$. Du kan benytte at $\sum_{\nu=0}^8 \binom{10}{\nu} \binom{10}{8-\nu} 2^{\nu} \approx 2.73 \cdot 10^6$.

Oppgave 3.

Anta at Y er binær med $\pi_j = P(Y = j)$, $\pi_1 + \pi_0 = 1$, $0 < \pi_j < 1$. Anta videre at for gitt $Y = j$ vil X være normalfordelt med $E[X|Y = j] = \mu_j$ og $\text{Var}[X|Y = j] = \sigma^2$.

- a) Vis at gitt $X = x$ er

$$p(x) = P(Y = 1 | X = x) = \frac{\exp(\alpha + \beta x)}{1 + \exp(\alpha + \beta x)}$$

der

$$\alpha = \ln \frac{\pi_1}{\pi_0} + \frac{\mu_0^2 - \mu_1^2}{2\sigma^2}$$

og

$$\beta = \frac{\mu_1 - \mu_0}{\sigma^2}.$$

- b) Anta at (X_i, Y_i) $i = 1, \dots, n$ er uavhengige par fordelt som (X, Y) . La $n_j = \#\{Y_i = j\}$, $\bar{X}_j = \frac{1}{n_j} \sum X_i$ og $S_j^2 = \frac{1}{n_j} \sum (X_i - \bar{X}_j)^2$ der summene tas over de i med $Y_i = j$.

Hvorfor er

$$\hat{\beta} = \frac{\bar{X}_1 - \bar{X}_0}{S_1^2 + S_0^2} (n - 2)$$

en rimelig estimator for β ? Angi en tilsvarende estimator $\hat{\alpha}$ for α . Vis at $\hat{\alpha}$ og $\hat{\beta}$ er konsistente estimatorene. Utled et tilnærmet uttrykk for $\text{Var}(\hat{\beta})$.

(Fortsettes side 4.)

- c) Den vanlige antagelsen i logistisk regresjon vil være å ignorere fordelingen til kovariatene $X_i = x_i$ og maksimere (den betingede) likelihooden

$$L = \prod_{i=1}^n p(x_i)^{Y_i} (1 - p(x_i))^{1-Y_i}$$

der $p(x)$ er gitt i punkt a).

Sett opp estimeringslikningene basert på L og utled et uttrykk for informasjonsmatrisen. Hvordan vil du gå fram for å finne et tilnærmet uttrykk for $\text{Var}(\beta^*)$ der β^* er estimatoren for β basert på L ?

Du kan i dette punktet gjøre bruk av resultatet i oppgave 1c).

- d) Sett nå at antagelsen om at X_i -ene gitt $Y_i = j$ er normalfordelt er feilaktig. Vi skal se på effekten av fortsatt å benytte estimatoren $\hat{\beta}$ fra punkt b). Anta, som et ekstremt tilfelle, at X_i -ene faktisk er binære. La antallene der $Y_i = j$ og $X_i = k$ være gitt i henhold til følgende tabell

		X_i	
		1	0
Y_i	1	A	B
	0	C	D

I henhold til oppgave 2 følger det at sannsynlighetsmaksimeringsestimatoren for β basert på L er gitt ved $\beta^* = \ln(A \cdot D / B \cdot C)$. Uttrykk $\hat{\beta}$ ved A, B, C og D .

Vis at $\hat{\beta} = 0$ hvis og bare hvis $\beta^* = 0$ samt at $\hat{\beta}$ og β^* har samme fortegn. Påvis, ved eksempel, at $\hat{\beta}$ og β^* generelt er ulike.

Hva konvergerer β^* mot når $n = A + B + C + D$ vokser?

Hva er den tilsvarende grensen for $\hat{\beta}$?

SLUTT