

# UNIVERSITETET I OSLO

## Det matematisk-naturvitenskapelige fakultet

Eksamens i: STK1120 — Statistiske metoder og dataanalyse 2.

Eksamensdag: Tirsdag 2. juni 2009.

Tid for eksamen: 14.30 – 17.30.

Oppgavesettet er på 6 sider.

Vedlegg: Tabeller over normal-, F- og  $\chi^2$ -fordelingene.

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

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

### Oppgave 1.

I et datasett samlet inn i Sachsen i Tyskland i 1876-1885 angis kjønnsfordelingen i 6125 familier med 12 barn. Dataene sammenfattes i følgende tabell:

Antall jenter	0	1	2	3	4	5	6	7	8	9	10	11	12
Antall familier	7	45	181	478	829	1122	1343	1033	670	286	104	24	3

La  $O_y$  være antall familier med eksakt  $y$  jenter,  $y = 0, 1, \dots, 12$ . Vi skal anta at  $(O_0, \dots, O_{12})$  er multinomisk fordelt med 6125 forsøk og sannsynligheter  $(\pi_0, \dots, \pi_{12})$  der  $\pi_y$  er sannsynligheten for  $y$  jenter blant de 12 barna i en familie. Generelt gjelder bare betingelsene  $0 \leq \pi_y \leq 1$  og  $\sum_{y=0}^{12} \pi_y = 1$ , men vi skal undersøke om det er mulig å finne en parametrisering av  $\pi_y$ -ene som passer til dataene.

- (a) En rimelig modell kunne være at antall jenter i hver tolvbarnsfamilie er binomisk fordelt med 12 forsøk og sannsynlighet  $\theta$  for jente i hver fødsel, der  $\theta$  er den *samme* for alle familier. Vi antar også at familiene er uavhengige. Dermed blir de multinomiske sannsynlighetene  $\pi_y = \binom{12}{y} \theta^y (1 - \theta)^{12-y}$ . Dette kalles i det følgende den binomiske modell.

(Fortsettes side 2.)

Forklar hvorfor forventet antall familier med  $y$  barn blir lik

$$E[O_y] = 6125 \binom{12}{y} \theta^y (1-\theta)^{12-y}.$$

Forklar også hvorfor  $\hat{\theta} = (\sum_{y=0}^{12} y O_y) / (12 * 6125) (= 0.4807)$  er maximum likelihood estimatet for  $\theta$  under denne antagelsen.

- (b) Nullhypotesen om at  $\pi_y$  følger den binomiske modellen kan testes formelt ved hjelp av en Pearsons kjikvadrat-observator

$$X^2 = \sum_{y=0}^{12} \frac{(O_y - E_y)^2}{E_y}$$

der  $E_y = 6125 \binom{12}{y} \hat{\theta}^y (1-\hat{\theta})^{12-y}$ . Angi tilnærmet fordeling for  $X^2$  under nullhypotesen.

For det aktuelle datasettet ble  $X^2 = 107.9$ . Konkluder om denne modellen passer til dataene.

En alternativ modell er den såkalte beta-binomiske modellen der

$$\pi_y = \binom{12}{y} \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \frac{\Gamma(\alpha + y)\Gamma(\beta + 12 - y)}{\Gamma(\alpha + \beta + 12)} = \pi_y(\alpha, \beta) \quad (1)$$

for  $y = 0, 1, \dots, 12$ . Her er  $\Gamma(\alpha)$  gammafunksjonen og  $\alpha > 0$  og  $\beta > 0$  er to ukjente parametere. (Modellen er en utvidelse av den binomiske modellen som oppstår ved å anta at antall jenter i ulike familier alle er binomisk fordelt med 12 forsøk, men med *ulike* sannsynligheter  $\theta$  for hver familie trukket fra en beta-fordeling med tetthet  $f(\theta; \alpha, \beta) = \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}$  for  $0 < \theta < 1$ . Du skal **ikke** utlede at dette gir modellen (1).)

- (c) Hva blir forventet antall tolvbarsfamilier med  $y$  jenter under den beta-binomiske modellen uttrykt ved parametrene  $(\alpha, \beta)$ .

De estimerte forventede tallene, der maximum likelihood estimatene (MLE)  $(\hat{\alpha}, \hat{\beta})$  er satt inn for  $(\alpha, \beta)$ , er oppgitt i Tabell 1 på neste side. Sammenlign med observerte  $O_y$  samt anslagene under den binomiske modellen i punkt (a) og (b).

Basert på den beta-binomiske modellen blir Pearsons kjikvadrat-observator nå  $X^2 = 13.32$ . Angi tilnærmet fordeling for  $X^2$  under en nullhypotese om beta-binomisk modell (1) og konkluder om dataene samsvarer godt med denne modellen.

(Fortsettes side 3.)

Tabell 1: Observerte og estimerte verdier for forventede antall tolvbarnsfamilier sammen med bidrag til Pearsons  $X^2$  for  $y$  jenter under binomisk og beta-binomisk modell.

y	O	Binomisk modell		Beta-binomisk modell	
		E	$(O-E)^2/E$	E	$(O-E)^2/E$
0	7	2.4	9.15	5.2	0.63
1	45	26.2	13.53	43.7	0.04
2	181	133.3	17.10	177.9	0.05
3	478	411.2	10.87	462.6	0.51
4	829	856.3	0.87	855.6	0.83
5	1122	1268.1	16.83	1185.3	3.38
6	1343	1369.4	0.51	1261.0	5.33
7	1033	1086.4	2.63	1038.0	0.02
8	670	628.5	2.74	656.0	0.30
9	286	258.5	2.91	310.5	1.93
10	104	71.8	14.45	104.5	0.00
11	24	12.1	11.76	22.4	0.11
12	3	0.9	4.59	2.3	0.20
Total	6125	6125.1	107.9	6125.0	13.32

## Oppgave 2.

For å estimere forventet antall tolvbarnsfamilier med  $y$  jenter under den beta-binomiske modellen i Oppgave 1c trengte vi maximum likelihood estimatene (MLE) for  $(\alpha, \beta)$ . I denne oppgaven skal vi se på hvordan man kan gå fram for å finne disse. Antagelsene er som i Oppgave 1c:  $(O_0, \dots, O_{12})$  er multinomisk fordelt med 6125 forsøk og sannsynligheter  $\pi_y(\alpha, \beta)$  gitt ved (1).

- (a) Vis at likelihooden for dataene under den beta-binomiske modellen er proporsjonal med

$$L(\alpha, \beta) = \prod_{y=0}^{12} \pi_y(\alpha, \beta)^{O_y}.$$

Vis videre at scorefunksjonen blir lik

$$s(\alpha, \beta) = \begin{bmatrix} 6125\left(\frac{\Gamma'(\alpha+\beta)}{\Gamma(\alpha+\beta)} - \frac{\Gamma'(\alpha)}{\Gamma(\alpha)} - \frac{\Gamma'(\alpha+\beta+12)}{\Gamma(\alpha+\beta+12)}\right) + \sum_{y=0}^{12} O_y \frac{\Gamma'(\alpha+y)}{\Gamma(\alpha+y)} \\ 6125\left(\frac{\Gamma'(\alpha+\beta)}{\Gamma(\alpha+\beta)} - \frac{\Gamma'(\beta)}{\Gamma(\beta)} - \frac{\Gamma'(\alpha+\beta+12)}{\Gamma(\alpha+\beta+12)}\right) + \sum_{y=0}^{12} O_y \frac{\Gamma'(\beta+12-y)}{\Gamma(\beta+12-y)} \end{bmatrix}$$

og finn dessuten et uttrykk for den observerte informasjonsmatrisen (notasjonsmessig er det hensiktmessig å benytte ”trigammafunksjonen”  $\Psi(\alpha) = \frac{\partial^2 \log(\Gamma(\alpha))}{\partial \alpha^2} = \frac{\partial(\Gamma'(\alpha)/\Gamma(\alpha))}{\partial \alpha}$  i utrykket for den observerte informasjonsmatrisen.)

(Fortsettes side 4.)

- (b) Diskuter kort hvordan man på bakgrunn av resultatene i punkt (a) kan beregne MLE for  $(\alpha, \beta)$ .

MLE ble  $(\hat{\alpha}, \hat{\beta}) = (31.88, 34.44)$  og invers av observert informasjonsmatrise evaluert i  $(\hat{\alpha}, \hat{\beta})$  er lik

$$\bar{J}(\hat{\alpha}, \hat{\beta})^{-1} = \begin{bmatrix} 15.43 & 16.64 \\ 16.64 & 18.01 \end{bmatrix}$$

Benytt dette til å beregne et tilnærmet 95% konfidensintervall for  $\alpha$ . Gi en begrunnelse for intervallet.

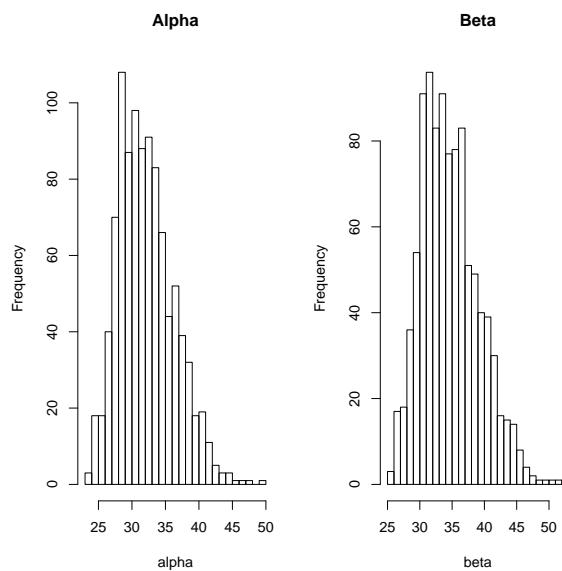
- (c) Under er det gjengitt resultater fra en ikke-parametrisk bootstrap med 1000 replikasjoner der  $(\alpha_b^*, \beta_b^*)$  er MLE for  $(\alpha, \beta)$  under den beta-binomiske modellen for bootstrap-replikasjon  $b$ .

Bruk tabellen og figuren nedenfor til å diskutere om tilnærmet inferens basert på MLE  $(\hat{\alpha}, \hat{\beta})$  ser ut til å fungere tilfredstillende i dette tilfellet. Momenter til diskusjonen er skjevhets ("bias") og standardfeil for estimatorene, normaltilnærming samt konfidensintervallet fra punkt (b).

Tabell 2: Deskriptiv statistikk for 1000 bootstrap-estimater.

	Gjennomsnitt	Standardavvik	2.5 persentil	97.5 persentil
$\alpha_b^*$	32.12	4.14	25.20	41.18
$\beta_b^*$	34.71	4.46	27.29	44.52

Figure 1: Histogram over fordelingen til bootstrap-estimatene  $\alpha_b^*$  og  $\beta_b^*$ .



(Fortsettes side 5.)

## Oppgave 3.

Modellen for enveis variansanalyse er gitt ved  $Y_{ij} = \mu_i + \varepsilon_{ij}$  der  $\mu_i$  = forventningen i gruppe  $i$  og  $\varepsilon_{ij} \sim N(0, \sigma^2)$  er uavhengige,  $i = 1, \dots, I, j = 1, \dots, J$ . Antall replikasjoner i alle grupper er da lik  $J$ .

Formålet med oppgaven er å se på sammenhengen mellom den vanlige F-testen for  $H_0 : \mu_1 = \dots = \mu_I$  og den generaliserte likelihood ratio testen (GLRT) for samme hypotese under den forutsetning at antall grupper  $I$  er fiksert, mens antall replikasjoner  $J$  vokser. Dermed vil også totalt antall observasjoner  $n = IJ$  vokse.

- (a) Parameterrommet for modellen gis generelt (i den fulle modellen) ved  $\Omega = \{(\mu_1, \dots, \mu_I, \sigma^2) : \mu_i \in \mathbb{R}, \sigma^2 \in \mathbb{R}^+\}$ . Beskriv tilsvarende parameterrommet  $\omega_0$  under  $H_0$  med en felles forventning  $\mu$  i alle grupper. Angi dimensjonene til  $\Omega$  og  $\omega_0$ .

Hva er den tilnærmede fordelingen for  $-2 \log(\Lambda)$  under  $H_0$  (når  $n$  er stor) der  $\Lambda$  = generalisert likelihood ratio, dvs. maksimal likelihood under nullhypotesen delt på maksimal likelihood i den fulle modellen.

- (b) Angi (uten bevis) eksakt fordeling for F-observatoren  $F = MS_B/MS_W$  under nullhypotesen.

Argументer dessuten for at  $(I-1)F$  er tilnærmet kjikvadratfordelt med  $I-1$  frihetsgrader under samme nullhypotesen når antall replikasjoner  $J$  er stort. Sammenlign med fordelingen for  $-2 \log(\Lambda)$  i punkt (a).

Her er  $MS_W = SS_W/[I(J-1)]$ ,  $SS_W = \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{i\bullet})^2$ ,  $MS_B = SS_B/(I-1)$ ,  $SS_B = J \sum_{i=1}^I (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2$ ,  $\bar{Y}_{i\bullet} = (1/J) \sum_{j=1}^J Y_{ij}$ ,  $\bar{Y}_{\bullet\bullet} = (1/n) \sum_{i=1}^I \sum_{j=1}^J Y_{ij}$ . Du kan dessuten bruke at Fisher-fordelingen med  $\nu_1$  og  $\nu_2$  frihetsgrader defineres som  $F_{\nu_1, \nu_2} = (\chi_{\nu_1}^2 / \nu_1) / (\chi_{\nu_2}^2 / \nu_2)$  der  $\chi_{\nu_j}^2$  er to uavhengige kjikvadratfordelte stokastiske variable med hhv.  $\nu_1$  og  $\nu_2$  frihetsgrader.

- (c) Log-likelihood for data i en enveis variansanalyse som ovenfor kan skrives

$$l(\mu_1, \dots, \mu_I, \sigma^2) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \mu_i)^2$$

og maksimeres i den fulle modellen for  $\hat{\mu}_i = \bar{Y}_{i\bullet}$  (for  $\mu_i$ -ene) og  $\hat{\sigma}^2 = SS_W/n$  (for  $\sigma^2$ ) og under nullhypotesen for  $\tilde{\mu} = \bar{Y}_{\bullet\bullet}$  (for felles forventning  $\mu$ ) og  $\tilde{\sigma}^2 = SS_{TOT}/n$  (for  $\sigma^2$ ) der  $SS_{TOT} = \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{\bullet\bullet})^2$ . Disse resultatene skal du **ikke** vise. Vis derimot at maksimal log-likelihood  $l(\mu_1, \dots, \mu_I, \sigma^2)$  over  $\Omega$  kan skrives

$$l(\bar{Y}_{1\bullet}, \dots, \bar{Y}_{I\bullet}, SS_W/n) = -\frac{n}{2} \log(2\pi \frac{SS_W}{n}) - \frac{n}{2}$$

(Fortsettes side 6.)

samt at maksimal log-likelihood over  $\omega_0$  gis ved

$$l(\bar{Y}_{\bullet\bullet}, \dots, \bar{Y}_{\bullet\bullet}, SS_{TOT}/n) = -\frac{n}{2} \log(2\pi \frac{SS_{TOT}}{n}) - \frac{n}{2}.$$

Vis at vi dermed har

$$-2 \log(\Lambda) = n \log\left(1 + \frac{(I-1)}{I(J-1)} F\right).$$

Dette betyr at den generaliserde likelihood ratio testen er ekvivalent med den vanlige F-testen. Forklar hvorfor.

- (d) Argumenter for at  $-2 \log(\Lambda) \approx (I-1)F$  når  $n = IJ$  er stor og nullhypotesen holder. Sammenhold med fordelingsresultatene i punkt (a) og (b).

SLUTT