



Norges teknisk-naturvitenskapelige universitet
Institutt for matematiske fag

TMA4240 Statistikk
Høst 2020

Anbefalte oppgaver 10
Løsningskisse

Oppgave 1

a) Antagelser for at X er binomisk fordelt:

- Gjør n forsøk: Spør n personer.
- Registrerer suksess eller fiasko i hvert forsøk: Får svaret JA eller ikke JA (nei eller vet ikke) i hvert forsøk.
- $P(\text{suksess})$ lik i alle forsøk: Sannsynlighet for JA er p for alle som blir spurt.
- Forsøkene er uavhengige: Rimelig å anta at de som blir spurt svarer uavhengig av hverandre.

$$P(X \geq 18) = 1 - P(X < 18) = 1 - P(X \leq 17) \stackrel{\text{tabell}}{=} 1 - 0.965 = 0.035.$$

$$P(10 < X < 15) = P(X \leq 14) - P(X \leq 10) \stackrel{\text{tabell}}{=} 0.584 - 0.048 = 0.536$$

- b)
- $E(\hat{P}) = p$ og $\text{Var}(\hat{P}) = \frac{1}{4}(\frac{1}{n_1} + \frac{1}{n_2})p(1-p)$.
 - $E(P^*) = p$ og $\text{Var}(P^*) = \frac{1}{n_1+n_2}p(1-p)$.

Egenskaper for god estimator: forventningsrett og liten varians. Begge estimatorene er forventningsrette, men P^* har minst varians, vi velger derfor P^* .

La $\alpha = 0.05$. Siden $\frac{\hat{P}-p}{\sqrt{\frac{1}{2n}\hat{P}(1-\hat{P})}}$ er tilnærmet standardnormalfordelt får vi:

$$P\left(-z_{\frac{\alpha}{2}} < \frac{\hat{P}-p}{\sqrt{\frac{1}{2n}\hat{P}(1-\hat{P})}} < z_{\frac{\alpha}{2}}\right) \approx 1-\alpha$$
$$P\left(\hat{P} - z_{\frac{\alpha}{2}}\sqrt{\frac{1}{2n}\hat{P}(1-\hat{P})} < p < \hat{P} + z_{\frac{\alpha}{2}}\sqrt{\frac{1}{2n}\hat{P}(1-\hat{P})}\right) \approx 1-\alpha$$

Et tilnærmet 95% konfidensintervall for p blir da:

$$\left[\hat{p} - z_{0.025}\sqrt{\frac{1}{2n}\hat{p}(1-\hat{p})}, \hat{p} + z_{0.025}\sqrt{\frac{1}{2n}\hat{p}(1-\hat{p})} \right].$$

c) Vi har at

$$Y = X_3 - n\hat{P} = X_3 - n\frac{X_1 + X_2}{2n} = X_3 - \frac{1}{2}X_1 - \frac{1}{2}X_2.$$

Siden n er stor og p ikke nær 0 og 1, vil vi ha at $np > 5$ og $n(1-p) > 5$, slik at vi kan bruke normaltilnærming til binomisk fordeling. Vi kan dermed anta at X_1 , X_2 og X_3 alle er tilnærmet normalfordelt, de er uavhengige, og lineærkombinasjonen Y er dermed også tilnærmet normalfordelt.

$$\text{Var}(Y) = \text{Var}(X_3 - n\hat{P}) \stackrel{\text{uavh.}}{=} \text{Var}(X_3) + n^2\text{Var}(\hat{P}) \stackrel{b)}{=} np(1-p) + n^2\frac{1}{2n}p(1-p) = \frac{3}{2}np(1-p).$$

Har da at

- $X_3 - n\hat{P}$ er tilnærmet normalfordelt
- $\text{Var}(X_3 - n\hat{P}) = \frac{3}{2}np(1-p)$
- $E(X_3 - n\hat{P}) = E(X_3) - nE(\hat{P}) = np - np = 0$

Vi får da et prediksjonsintervall ved:

$$P\left(-z_{\frac{\alpha}{2}} < \frac{X_3 - n\hat{P}}{\sqrt{\frac{3}{2}np(1-p)}} < z_{\frac{\alpha}{2}}\right) \approx 1 - \alpha$$

$$P\left(n\hat{P} - z_{\frac{\alpha}{2}}\sqrt{\frac{3}{2}np(1-p)} < X_3 < n\hat{P} + z_{\frac{\alpha}{2}}\sqrt{\frac{3}{2}np(1-p)}\right) \approx 1 - \alpha$$

Siden n er stor, vil variansen til \hat{P} være liten, og \hat{P} være en god estimator for p . Vi kan derfor erstatte p med estimatet \hat{p} i uttrykket for intervallgrensene.

Intervallet blir: $[n\hat{p} - z_{0.025}\sqrt{\frac{3}{2}n\hat{p}(1-\hat{p})}, n\hat{p} + z_{0.025}\sqrt{\frac{3}{2}n\hat{p}(1-\hat{p})}]$

Innsatt verdier blir intervallet [633, 704].

Oppgave 2

a)

$$P(T > 1000) = 1 - P(T \leq 1000) = 1 - F(1000) = 1 - \left(1 - \exp\left\{-\frac{2 \cdot 1000^2}{2 \cdot 10^6}\right\}\right) = e^{-1} = \underline{\underline{0.368}}$$


$$P(T > 2000 | T > 1000) = \frac{P(T > 2000 \cap T > 1000)}{P(T > 1000)} = \frac{P(T > 2000)}{P(T > 1000)} = \frac{1 - F(2000)}{e^{-1}}$$

$$= \frac{1 - \left(1 - \exp\left\{-\frac{2 \cdot 2000^2}{2 \cdot 10^6}\right\}\right)}{e^{-1}} = \frac{e^{-4}}{e^{-1}} = e^{-4+1} = e^{-3} = \underline{\underline{0.050}}.$$

La Z være antall av de tre levetidene som er større enn 1000 døgn. Siden de tre levetidene er antatt uavhengige blir da Z binomisk fordelt med $n = 3$ forsøk og sannsynlighet for suksess lik $p = P(T > 1000) = e^{-1}$. Dermed får man at

$$P(Z \geq 2) = P(Z = 2) + P(Z = 3) = \binom{3}{2}p^2(1-p)^1 + \binom{3}{3}p^3(1-p)^0$$

$$= 3p^2(1-p) + p^3 = \underline{\underline{0.306}}.$$



Figur 1: Plott av $f(t)$ når $z = 2.0$ og $\theta = 2 \cdot 10^6$. Arealet av det skraverte området er lik sannsynligheten $P(T > 1000)$.

b) For $t > 0$ får vi at

$$f(t) = F'(t) = -\exp\left\{-\frac{zt^2}{\theta}\right\} \cdot \left(-\frac{2zt}{\theta}\right) = \frac{2zt}{\theta} \exp\left\{-\frac{zt^2}{\theta}\right\}.$$

En skisse av sannsynlighetstettheten $f(t)$ for $t \in [0, 3000]$ er gitt i figur 1. I denne figuren er arealet som er lik sannsynligheten $P(T > 1000)$ skravert.

c) Den en-entydige transformasjonen mellom t og v er gitt som

$$v = \frac{2zt^2}{\theta} \Leftrightarrow t = \sqrt{\frac{v\theta}{2z}}.$$

Merk at transformasjonen er en-entydig fordi det er gitt at $t > 0$. For $v > 0$ gir transformasjonsformelen da at sannsynlighetstettheten for V blir

$$f_V(v) = f_T\left(\sqrt{\frac{v\theta}{2z}}\right) \cdot \left|\frac{dt}{dv}\right| = \frac{2z\sqrt{\frac{v\theta}{2z}}}{\theta} \exp\left\{-\frac{z\left(\sqrt{\frac{v\theta}{2z}}\right)^2}{\theta}\right\} \cdot \frac{1}{2\sqrt{\frac{v\theta}{2z}}} \frac{\theta}{2z} = \frac{1}{2} \exp\left\{-\frac{v}{2}\right\}.$$

Siden V ikke kan være negativ blir selvfølgelig $f_V(v) = 0$ for $v < 0$. Sannsynlighetstettheten til en χ^2 -fordeling med ν frihetsgrader er gitt som

$$f(x) = \frac{1}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})} x^{\nu/2-1} e^{-x/2} \quad \text{for } x > 0.$$

Setter vi her inn $\nu = 2$ får vi at tettheten blir

$$f(x) = \frac{1}{2\Gamma(1)} x^{1-1} e^{-x/2} = \frac{1}{2} \exp\left\{-\frac{x}{2}\right\}.$$

Vi ser at dette er samme sannsynlighetstetthet som $f_V(v)$ som vi utledet over. Dermed har vi vist at $V \sim \chi_2^2$.

For en χ_ν^2 -fordeling vet vi generelt at forventingsverdien er lik ν og variansen er lik 2ν . Dermed har vi spesielt at $E[V] = 2$ og $\text{Var}[V] = 4$. Dette gir

$$E[V] = E\left[\frac{2zT^2}{\theta}\right] = \frac{2z}{\theta}E[T^2] = 2 \quad \Rightarrow \quad E[T^2] = \frac{\theta}{z}$$

og

$$\text{Var}[V] = \text{Var}\left[\frac{2zT^2}{\theta}\right] = \left(\frac{2z}{\theta}\right)^2 E[T^2] = 4 \quad \Rightarrow \quad \text{Var}[T^2] = \left(\frac{\theta}{z}\right)^2.$$

d) Rimelighetsfunksjonen blir gitt som

$$L(\theta) = \prod_{i=1}^n f(t_i) = \prod_{i=1}^n \left[\frac{2z_i t_i}{\theta} \exp\left\{-\frac{z_i t_i^2}{\theta}\right\} \right].$$

Log-rimelighetsfunksjonen blir dermed

$$\begin{aligned} l(\theta) &= \ln(L(\theta)) = \sum_{i=1}^n \ln\left(\frac{2z_i t_i}{\theta} \exp\left\{-\frac{z_i t_i^2}{\theta}\right\}\right) \\ &= \sum_{i=1}^n \left[\ln(2) + \ln(z_i) + \ln(t_i) - \ln(\theta) - \frac{z_i t_i^2}{\theta} \right] \\ &= n \ln(2) + \sum_{i=1}^n \ln(z_i) + \sum_{i=1}^n \ln(t_i) - n \ln(\theta) - \frac{1}{\theta} \sum_{i=1}^n z_i t_i^2. \end{aligned}$$

Finner maksimum ved å derivere med hensyn på θ og sette lik null,

$$l'(\theta) = -n \cdot \frac{1}{\theta} - \left(-\frac{1}{\theta^2}\right) \sum_{i=1}^n z_i t_i^2 = -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n z_i t_i^2 = 0 \quad \Rightarrow \quad \theta = \frac{1}{n} \sum_{i=1}^n z_i t_i^2.$$

Sannsynlighetsmaksimeringsestimatoren for θ blir dermed

$$\hat{\theta} = \frac{1}{n} \sum_{i=1}^n z_i T_i^2.$$

Benytter resultatene fra c) til å finne forventingsverdi og varians for $\hat{\theta}$,

$$\begin{aligned} E[\hat{\theta}] &= E\left[\frac{1}{n} \sum_{i=1}^n z_i T_i^2\right] = \frac{1}{n} E\left[\sum_{i=1}^n z_i T_i^2\right] = \frac{1}{n} \sum_{i=1}^n E[z_i T_i^2] = \frac{1}{n} \sum_{i=1}^n z_i E[T_i^2] \\ &= \frac{1}{n} \sum_{i=1}^n z_i \frac{\theta}{z_i} = \frac{1}{n} \sum_{i=1}^n \theta = \frac{1}{n} \cdot n\theta = \theta \quad \Rightarrow \quad \hat{\theta} \text{ er forventingsrett,} \end{aligned}$$

$$\text{Var}[\hat{\theta}] = \text{Var}\left[\frac{1}{n} \sum_{i=1}^n z_i T_i^2\right] = \left(\frac{1}{n}\right)^2 \text{Var}\left[\sum_{i=1}^n z_i T_i^2\right] = \frac{1}{n^2} \sum_{i=1}^n \text{Var}[z_i T_i^2] = \frac{1}{n^2} \sum_{i=1}^n z_i^2 \text{Var}[T_i^2]$$

$$= \frac{1}{n^2} \sum_{i=1}^n z_i^2 \text{Var} [T_i^2] = \frac{1}{n^2} \sum_{i=1}^n z_i^2 \left(\frac{\theta}{z_i} \right)^2 = \frac{\theta^2}{n^2} \sum_{i=1}^n 1 = \frac{\theta^2}{n^2} \cdot n = \frac{\theta^2}{n}.$$

Merk at man i utregningen av variansen har benyttet at T_i 'ene er uavhengige.

e) Vi har at

$$U = \sum_{i=1}^n V_i \quad \text{der } V_i = \frac{2z_i T_i^2}{\theta}.$$

Fra punkt c) vet vi at $V_i \sim \chi_2^2$. Dessuten, siden T_i 'ene er antatt uavhengige vil også V_i 'ene være uavhengige. Siden en sum av uavhengige χ^2 -fordelte variabler også blir χ^2 -fordelt der antall frihetsgrader til summen er lik summen av antall frihetsgrader får vi dermed at U er χ^2 -fordelt med $\sum_{i=1}^n 2 = 2n$ frihetsgrader.

Siden $U \sim \chi_{2n}^2$ får vi at

$$P\left(\chi_{1-\frac{\alpha}{2}, 2n}^2 \leq U \leq \chi_{\frac{\alpha}{2}, 2n}^2\right) = 1 - \alpha.$$

Setter vi inn uttrykket for U får vi

$$P\left(\chi_{1-\frac{\alpha}{2}, 2n}^2 \leq \frac{2}{\theta} \sum_{i=1}^n z_i T_i^2 \leq \chi_{\frac{\alpha}{2}, 2n}^2\right) = 1 - \alpha.$$

Løser de to ulikheten med hensyn på θ hver for seg,

$$\chi_{1-\frac{\alpha}{2}, 2n}^2 \leq \frac{2}{\theta} \sum_{i=1}^n z_i T_i^2 \Rightarrow \theta \leq \frac{2}{\chi_{1-\frac{\alpha}{2}, 2n}^2} \sum_{i=1}^n z_i T_i^2,$$

$$\frac{2}{\theta} \sum_{i=1}^n z_i T_i^2 \leq \chi_{\frac{\alpha}{2}, 2n}^2 \Rightarrow \frac{2}{\chi_{\frac{\alpha}{2}, 2n}^2} \sum_{i=1}^n z_i T_i^2 \leq \theta$$

Dermed har vi at

$$P\left(\frac{2}{\chi_{\frac{\alpha}{2}, 2n}^2} \sum_{i=1}^n z_i T_i^2 \leq \theta \leq \frac{2}{\chi_{1-\frac{\alpha}{2}, 2n}^2} \sum_{i=1}^n z_i T_i^2\right) = 1 - \alpha$$

slik at et $(1 - \alpha) \cdot 100\%$ -konfidensintervall for θ er gitt ved

$$\left[\frac{2}{\chi_{\frac{\alpha}{2}, 2n}^2} \sum_{i=1}^n z_i T_i^2, \frac{2}{\chi_{1-\frac{\alpha}{2}, 2n}^2} \sum_{i=1}^n z_i T_i^2 \right].$$

For $\alpha = 0.05$ og $n = 10$ finner vi i tabell at $\chi_{1-\frac{\alpha}{2}, 2n}^2 = \chi_{0.975, 20}^2 = 9.591$ og $\chi_{\frac{\alpha}{2}, 2n}^2 = \chi_{0.025, 20}^2 = 34.170$. Innsatt oppgitte observasjoner blir dermed konfidensintervallet

$$\left[\frac{2}{34.170} \cdot 23\,287\,125, \frac{2}{9.591} \cdot 23\,287\,125 \right] = \underline{\underline{[1\,363\,016, 4\,856\,037]}}.$$

f) Ved å ta utgangspunkt i Y har vi at

$$P\left(y_{1-\frac{\alpha}{2}} \leq Y \leq y_{\frac{\alpha}{2}}\right) = 1 - \alpha.$$

Setter vi inn uttrykket for Y , etter å ha forenklet dette ved å forkorte, får vi dermed

$$P\left(y_{1-\frac{\alpha}{2}} \leq \frac{nz_0 T_0^2}{\sum_{i=1}^n z_i T_i^2} \leq y_{\frac{\alpha}{2}}\right) = 1 - \alpha.$$

Løser de to ulikhetene med hensyn på T_0 hver for seg (og husker på at vi vet at $T_0 > 0$),

$$y_{1-\frac{\alpha}{2}} \leq \frac{nz_0 T_0^2}{\sum_{i=1}^n z_i T_i^2} \Rightarrow \sqrt{\frac{y_{1-\frac{\alpha}{2}} \sum_{i=1}^n z_i T_i^2}{nz_0}} \leq T_0,$$

$$\frac{nz_0 T_0^2}{\sum_{i=1}^n z_i T_i^2} \leq y_{\frac{\alpha}{2}} \Rightarrow T_0 \leq \sqrt{\frac{y_{\frac{\alpha}{2}} \sum_{i=1}^n z_i T_i^2}{nz_0}}.$$

Dermed har vi at

$$P\left(\sqrt{\frac{y_{1-\frac{\alpha}{2}} \sum_{i=1}^n z_i T_i^2}{nz_0}} \leq T_0 \leq \sqrt{\frac{y_{\frac{\alpha}{2}} \sum_{i=1}^n z_i T_i^2}{nz_0}}\right) = 1 - \alpha,$$

slik at et $(1 - \alpha) \cdot 100\%$ -prediksjonsintervall for T_0 er

$$\left[\sqrt{\frac{y_{1-\frac{\alpha}{2}} \sum_{i=1}^n z_i T_i^2}{nz_0}}, \sqrt{\frac{y_{\frac{\alpha}{2}} \sum_{i=1}^n z_i T_i^2}{nz_0}} \right].$$

For å få et 90%-prediksjonsintervall må vi velge $\alpha = 0.1$ og da blir $y_{1-\frac{\alpha}{2}} = y_{0.95} = 0.051$ og $y_{\frac{\alpha}{2}} = y_{0.05} = 3.49$. Innsatt oppgitte observasjoner blir dermed prediksjonsintervallet

$$\left[\sqrt{\frac{0.051 \cdot 23\,287\,125}{10 \cdot 3}}, \sqrt{\frac{3.49 \cdot 23\,287\,125}{10 \cdot 3}} \right] = \underline{\underline{[198.97, 1\,645.92]}}.$$