



Norwegian University of
Science and Technology

Department of Mathematical Sciences

Examination paper for **TMA4240 Statistikk – løsningskisse**

Academic contact during examination:

Phone:

Examination date: August 2021

Examination time (from–to): 09:00–13:00

Permitted examination support material:

Other information:

Language: English

Number of pages: 13

Number of pages enclosed: 0

Checked by:

Informasjon om trykking av eksamensoppgave	
Originalen er:	
1-sidig <input type="checkbox"/>	2-sidig <input checked="" type="checkbox"/>
sort/hvit <input checked="" type="checkbox"/>	farger <input type="checkbox"/>
skal ha flervalgskjema <input checked="" type="checkbox"/>	

Date

Signature

NB: Merk at det ble gitt ulike varianter av oppgavene. I denne løsningsskissen gis det kun detaljert utregning for variant A av hver oppgave. De øvrige oppgavevariantene løses tilsvarende. For disse gis det derfor her kun fasitsvar.

Problem 1

- Utvalgets gjennomsnitt: $\frac{1}{5}(-1 + 2 + 3 + 7 + 9) = \underline{4.00}$
- Utvalgsvarians (empirisk varians):

$$\frac{1}{5-1}((-1-4)^2 + (2-4)^2 + (3-4)^2 + (7-4)^2 + (9-4)^2) = \underline{16.00}$$

- Median: 3.00

B: 14, 16, 13

C: 7, 37.5, 10

D: 5, 11, 5

Problem 2

- $P(B \cap C) = P(B)P(C|B) = 0.2 \cdot 0.5 = \underline{0.1}$
- $P(C|A) = \frac{P(A \cap C)}{P(A)} = \frac{P(A|C)P(C)}{P(A)} \Rightarrow P(C) = \frac{P(A)P(C|A)}{P(A|C)} = \frac{0.08 \cdot 0.25}{0.1} = \underline{0.20}$
- $P(A \cap C) = P(A)P(C|A) = 0.08 \cdot 0.25 = 0.02$.

$$P(B|A \cup C) = \frac{P(B \cap (A \cup C))}{P(A \cup C)} = \frac{P(B \cap C)}{P(A) + P(C) - P(A \cap C)} = \frac{0.1}{0.08 + 0.2 - 0.02} = \underline{0.385}$$

B: 0.04, 0.50, 0.05

C: 0.09, 0.125, 0.257

D: 0.10, 0.05, 0.690

Problem 3

- $16^4 \cdot 4 = \underline{262144}$
- $\binom{6}{3} \cdot 16^3 \cdot 4^3 \cdot 4 = \underline{20971520}$

B: 1856465, 974644125

C: 24576, 622080

Problem 4

- $P(X > 1) = P(X = 2) + P(X = 3) + P(X = 4) + P(X = 5) = 0.10 + 0.25 + 0.20 + 0.25 = \underline{0.800}$
- $P(X \leq 4 | X \geq 3) = \frac{P(X \leq 4 \cap X \geq 3)}{P(X \geq 3)} = \frac{P(X=3) + P(X=4)}{P(X=3) + P(X=4) + P(X=5)} = \frac{0.25 + 0.20}{0.25 + 0.20 + 0.25} = \underline{0.643}$
- $E[X] = 0 \cdot 0.05 + 1 \cdot 0.15 + 2 \cdot 0.10 + 3 \cdot 0.25 + 4 \cdot 0.20 + 5 \cdot 0.25 = \underline{3.150}$

B: 0.75, 0.727, 2.65

C: 0.70, 0.737, 3.15

D: 0.55, 0.833, 2.65

Problem 5

I en eksponensialfordeling har vi at $\text{Var}[X] = \beta^2 = \frac{1}{\lambda^2}$ slik at vi her får $\beta = \frac{1}{3}$, eventuelt $\lambda = 3$. Dessuten vet vi at kumulativ fordelingsfunksjon i en eksponensialfordeling er gitt ved

$$F(x) = P(X \leq x) = \begin{cases} 1 - e^{-\lambda x} & \text{for } x \geq 0, \\ 0 & \text{ellers.} \end{cases}$$

- $E[X] = \beta = \frac{1}{\lambda} = \underline{0.333}$

- $P(X > 1) = 1 - P(X \leq 1) = 1 - (1 - e^{-\lambda \cdot 1}) = e^{-3} = \underline{0.050}$
- $P(X \leq 0.5 | X < 1.1) = \frac{P(X \leq 0.5 \cap X < 1.1)}{P(X < 1.1)} = \frac{P(X \leq 0.5)}{P(X < 1.1)} = \frac{1 - e^{-3 \cdot 0.5}}{1 - e^{-3 \cdot 1.1}} = \underline{0.807}$

B: 0.25, 0.0183, 0.875

C: 0.5, 0.135, 0.711

Problem 6

Vi har oppgitt at

$$E[X] = \mu, \quad \text{Var}[X] = \sigma^2, \quad E[Y] = 2\mu \quad \text{og} \quad \text{Var}[Y] = 4\sigma^2.$$

Vi starter med å sjekke hvilke estimatorene som er forventningsrette ved å regne ut forventningsverdien til hver estimator.

$$\begin{aligned} E[\hat{\mu}] &= E\left[\frac{X+Y}{2}\right] = \frac{1}{2}E[X+Y] = \frac{1}{2}(E[X] + E[Y]) = \frac{1}{2}(\mu + 2\mu) = \frac{3}{2}\mu \\ E[\mu^*] &= E\left[\frac{2X+Y}{4}\right] = \frac{1}{4}E[2X+Y] = \frac{1}{4}(2E[X] + E[Y]) = \frac{1}{4}(2\mu + 2\mu) = \mu \\ E[\tilde{\mu}] &= E\left[\frac{3X+Y}{5}\right] = \frac{1}{5}E[3X+Y] = \frac{1}{5}(3E[X] + E[Y]) = \frac{1}{5}(3\mu + 2\mu) = \mu \end{aligned}$$

Vi ser at μ^* and $\tilde{\mu}$ er forventningsrette. Finner derfor variansen til disse to for å bestemme hvilken av disse som er mest effisient.

$$\begin{aligned} \text{Var}[\mu^*] &= \text{Var}\left[\frac{2X+Y}{4}\right] = \left(\frac{1}{4}\right)^2 \text{Var}[2X+Y] = \frac{1}{16}(\text{Var}[2X] + \text{Var}[Y]) \\ &= \frac{1}{16}(2^2\text{Var}[X] + \text{Var}[Y]) = \frac{1}{16}(4\sigma^2 + 4\sigma^2) = \frac{1}{2}\sigma^2 \\ \text{Var}[\tilde{\mu}] &= \text{Var}\left[\frac{3X+Y}{5}\right] = \left(\frac{1}{5}\right)^2 \text{Var}[3X+Y] \\ &= \frac{1}{25}(\text{Var}[3X] + \text{Var}[Y]) = \frac{1}{25}(3^2\text{Var}[X] + \text{Var}[Y]) = \frac{1}{25}(9\sigma^2 + 4\sigma^2) = \frac{13}{25}\sigma^2 \end{aligned}$$

Siden $\frac{13}{25} > \frac{1}{2}$ får vi at μ^* er mest effisient. Så av de tre estimatorene vil vi foretrekke μ^* .

B: Foretrekker $\hat{\mu}$.

C: Foretrekker $\tilde{\mu}$.

Problem 7

Vi finner først marginalfordelingen for X . For $x > 0$ får vi

$$\begin{aligned}
 f(x) &= \int_{-\infty}^{\infty} f(x, y) dy = \int_{-\infty}^{\infty} \frac{1}{4} \exp \left\{ - \left[x + \frac{1}{2} |y - x| \right] \right\} dy \\
 &= \frac{1}{4} e^{-x} \int_{-\infty}^{\infty} \exp \left\{ -\frac{1}{2} |y - x| \right\} dy \\
 &= \frac{1}{4} e^{-x} \left[\int_{-\infty}^x \exp \left\{ -\frac{1}{2} |y - x| \right\} dy + \int_x^{\infty} \exp \left\{ -\frac{1}{2} |y - x| \right\} dy \right] \\
 &= \frac{1}{4} e^{-x} \left[\int_{-\infty}^x \exp \left\{ \frac{1}{2} (y - x) \right\} dy + \int_x^{\infty} \exp \left\{ -\frac{1}{2} (y - x) \right\} dy \right] \\
 &= \frac{1}{4} e^{-x} \left[\left[2 \exp \left\{ \frac{1}{2} (y - x) \right\} \right]_{y=-\infty}^{y=x} + \left[-2 \exp \left\{ -\frac{1}{2} (y - x) \right\} \right]_{y=x}^{y=\infty} \right] \\
 &= \frac{1}{4} e^{-x} \left[(2e^0 - 0) + (0 - (-2e^0)) \right] \\
 &= \frac{1}{4} e^{-x} \cdot 4 = e^{-x}.
 \end{aligned}$$

For $x \leq 0$ har vi åpenbart $f(x) = 0$, så marginalfordelingen til x blir

$$\underline{\underline{f(x) = \begin{cases} e^{-x} & \text{for } x > 0, \\ 0 & \text{ellers.} \end{cases}}}$$

Den betingede fordelingen for Y gitt $X = x$ blir da

$$\begin{aligned}
 f(y|x) &= \frac{f(x, y)}{f(x)} = \frac{\frac{1}{4} \exp \left\{ - \left[x + \frac{1}{2} |y - x| \right] \right\}}{\exp \{-x\}} \\
 &= \underline{\underline{\frac{1}{4} \exp \left\{ -\frac{1}{2} |y - x| \right\}}}
 \end{aligned}$$

for $-\infty < y < \infty$.

B:

$$\begin{aligned}
 f(x) &= \begin{cases} \frac{1}{2} e^{-\frac{1}{2}x} & \text{for } x > 0, \\ 0 & \text{ellers.} \end{cases} \\
 f(y|x) &= \frac{1}{2} \exp \{-|y - x|\}
 \end{aligned}$$

C:

$$f(x) = \begin{cases} 2e^{-2x} & \text{for } x > 0, \\ 0 & \text{ellers.} \end{cases}$$

$$f(y|x) = \exp\{-2|y - x|\}$$

Problem 8

For å finne sannsynlighetsmaksimeringsestimatorene for p starter vi med å etablere rimelighetsfunksjonen,

$$L(p) = \prod_{i=1}^n f(x_i) = \prod_{i=1}^n [(1-p)^{x_i-1} p] = p^n (1-p)^{\sum_{i=1}^n x_i - n}.$$

Log-rimelighetsfunksjon blir da

$$\ell(p) = \ln L(p) = n \ln p + \left(\sum_{i=1}^n x_i - n \right) \ln(1-p).$$

Deriverer $\ell(p)$ og setter den deriverte lik null for å bestemme for hvilken verdi av p log/rimelighetsfunksjonen har sitt maksimum,

$$\begin{aligned} \ell'(p) &= \frac{n}{p} + \left(\sum_{i=1}^n x_i - n \right) \cdot \frac{1}{1-p} \cdot (-1) = 0 \\ &\Downarrow \\ n(1-p) &= \left(\sum_{i=1}^n x_i - n \right) p \\ &\Downarrow \\ n - np &= p \sum_{i=1}^n x_i - np \\ &\Downarrow \\ p &= \frac{n}{\sum_{i=1}^n x_i} \end{aligned}$$

Sannsynlighetsmaksimeringsestimatorene for p blir dermed

$$\hat{p} = \frac{n}{\sum_{i=1}^n X_i},$$

og med de oppgitte observasjonene blir estimatet

$$\frac{6}{1 + 5 + 2 + 10 + 15 + 3} = \frac{6}{36} = \frac{1}{\underline{\underline{6}}}.$$

For å finne sannsynlighetsmaksimeringsestimatoren for $\theta = \frac{1}{p}$ kan vi argumentere med at sannsynlighetsmaksimeringsestimatoren er invariant under reparametrisering og dermed direkte få at sannsynlighetsmaksimeringsestimatoren for θ er

$$\underline{\underline{\hat{\theta}}} = \frac{1}{\underline{\underline{\hat{p}}}} = \frac{1}{\frac{\sum_{i=1}^n X_i}{n}} = \frac{1}{n} \sum_{i=1}^n X_i.$$

Dersom man ikke kjenner til at sannsynlighetsmaksimeringsestimatoren er invariant under reparametrisering kan man utlede sannsynlighetsmaksimeringsestimatoren for $\theta = \frac{1}{p} \Leftrightarrow p = \frac{1}{\theta}$ ved å starte med rimelighetsfunksjonen for θ . Denne rimelighetsfunksjonen blir

$$L(\theta) = \prod_{i=1}^n f(x_i) = \prod_{i=1}^n \left[\left(1 - \frac{1}{\theta}\right)^{x_i-1} \frac{1}{\theta} \right] = \frac{1}{\theta^n} \left(1 - \frac{1}{\theta}\right)^{\sum_{i=1}^n x_i - n}.$$

Log-rimelighetsfunksjonen blir da

$$\ell(\theta) = -n \ln \theta + \left(\sum_{i=1}^n x_i - n \right) \ln \left(1 - \frac{1}{\theta}\right).$$

Deriverer så denne med hensyn på θ og setter den deriverte lik null for å finne for hvilken verdi av θ log-rimelighetsfunksjonen har sitt maksimum.

$$\begin{aligned} \ell'(\theta) &= -\frac{n}{\theta} + \left(\sum_{i=1}^n x_i - n \right) \cdot \frac{1}{1 - \frac{1}{\theta}} \cdot \left(- \left(-\frac{1}{\theta^2} \right) \right) \\ &= -\frac{n}{\theta} + \left(\sum_{i=1}^n x_i - n \right) \cdot \frac{1}{\theta^2 - \theta} = 0 \\ &\Downarrow \\ n(\theta^2 - \theta) &= \left(\sum_{i=1}^n x_i - n \right) \theta \end{aligned}$$

Siden vi har at $p \in (0, 1)$ må vi ha at $\theta = \frac{1}{p} > 1$. Vi er dermed kun interessert i løsninger av ligningen over hvor $\theta > 1$. Løsningen vi er interessert i må dermed ha

$$n(\theta - 1) = \left(\sum_{i=1}^n x_i - n \right) \Leftrightarrow \theta = \frac{1}{n} \sum_{i=1}^n x_i.$$

Sannsynlighetsmaksimeringsestimatoren for θ blir dermed

$$\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i.$$

For en geometrisk fordeling vet vi at $E[X_i] = \frac{1}{p} = \theta$. Dermed får vi at

$$\begin{aligned} E[\hat{\theta}] &= E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] \\ &= \frac{1}{n} E\left[\sum_{i=1}^n X_i\right] \\ &= \frac{1}{n} \sum_{i=1}^n E[X_i] \\ &= \frac{1}{n} \sum_{i=1}^n \theta \\ &= \frac{1}{n} \cdot n\theta = \theta. \end{aligned}$$

Dermed ser vi at $\hat{\theta}$ er forventningsrett.

$$\text{B: } \hat{p} = \frac{5}{54} = 0.0926$$

$$\text{C: } \hat{p} = \frac{7}{30} = 0.2333$$

Problem 9

For å bestemme for hvilke verdier av X ulikheten er oppfylt løser vi først den tilhørende andregradsligningen,

$$\begin{aligned} X^2 - \frac{9X}{4} = -\frac{7}{8} &\Leftrightarrow X^2 - \frac{9}{4}X + \frac{7}{8} = 0 \\ X &= \frac{-\left(-\frac{9}{4}\right) \pm \sqrt{\left(-\frac{9}{4}\right)^2 - 4 \cdot 1 \cdot \frac{7}{8}}}{2 \cdot 1} = \frac{\frac{9}{4} \pm \sqrt{\frac{81}{16} - \frac{28}{8}}}{2} \\ &= \frac{\frac{9}{4} \pm \sqrt{\frac{81-56}{16}}}{2} = \frac{\frac{9}{4} \pm \sqrt{\frac{25}{16}}}{2} \\ &= \frac{\frac{9}{4} \pm \frac{5}{4}}{2} \Leftrightarrow X = \frac{14}{8} = \frac{7}{4} = 1.75 \quad \vee \quad X = \frac{4}{8} = \frac{1}{2} = 0.5. \end{aligned}$$

Ved å sette inn ser vi at ulikheten ikke er oppfylt for, for eksempel, $X = 1$,

$$X^2 - \frac{9X}{4} = 1^2 - \frac{9 \cdot 1}{4} = -\frac{5}{4} \not> -\frac{7}{8}.$$

Vi kan dermed konkludere med at ulikheten er oppfylt for $X < \frac{1}{2}$ og for $X > \frac{7}{4}$.
Dermed får vi at sannsynligheten det spørres om er gitt ved

$$\begin{aligned} P\left(X^2 - \frac{9X}{4} > -\frac{7}{8}\right) &= P\left(X < \frac{1}{2}\right) + P\left(X > \frac{7}{4}\right) \\ &= \int_{-\infty}^{\frac{1}{2}} f(x)dx + \int_{\frac{7}{4}}^{\infty} f(x)dx \\ &= \int_{-2}^{\frac{1}{2}} \frac{1}{12}(x+3)dx + \int_{\frac{7}{4}}^2 \frac{1}{12}(x+3)dx \\ &= \frac{1}{12} \left(\left[\frac{1}{2}x^2 + 3x \right]_{-2}^{\frac{1}{2}} + \left[\frac{1}{2}x^2 + 3x \right]_{\frac{7}{4}}^2 \right) \\ &= \frac{1}{12} \left(\frac{1}{8} + \frac{3}{2} - 2 + 6 + 2 + 6 - \frac{49}{32} - \frac{21}{4} \right) \\ &= \frac{1}{12} \cdot \frac{4 + 3 \cdot 16 + 12 \cdot 32 - 49 - 21 \cdot 8}{32} \\ &= \frac{219}{384} = 0.570. \end{aligned}$$

B: $\frac{271}{320} = 0.847$

C: $\frac{15}{32} = 0.469$

D: $\frac{37}{50} = 0.74$

Problem 10

- a)
- Det er rimelig å anta at hver av de 1000 forsøkspersonene får immunitet uavhengig av hverandre og med samme sannsynlighet p . Dermed har vi oppfylt betingelsen for binomisk fordeling, slik at antall forsøkspersoner som oppnår immunitet, X , er binomisk fordelt med $n = 1000$ forsøk og sannsynlighet for suksess lik p .
 - Siden vi ønsker å avgjøre om det er grunnlag for å påstå at den nye vaksinen er bedre enn den gamle velger dette som alternativ hypotese, dvs.

$$H_0 : p = p_0 \quad \text{mot} \quad H_1 : p > p_0,$$

der $p_0 = 0.9$.

- Siden $n = 1000$ er stor, og spesielt er $np_0 = 1000 \cdot 0.9 = 900 > 5$ og $n(1 - p_0) = 100 > 5$, vil X være tilnærmet normalfordelt under H_0 . Under H_0 har vi dermed tilnærmet at

$$X \sim N(np_0, np_0(1 - p_0))$$

og den tilsvarende standardiserte variabelen blir

$$Z = \frac{X - np_0}{\sqrt{np_0(1 - p_0)}} \sim N(0, 1).$$

Vi bruker dermed testobservatoren

$$Z = \frac{X - np_0}{\sqrt{np_0(1 - p_0)}}$$

og under H_0 er denne (tilnærmet) standard normalfordelt.

- Vi forkaster H_0 dersom $Z \geq k$ der k bestemmes fra kravet

$$P(\text{Forkast } H_0 | H_0 \text{ er riktig}) = \alpha = 0.05$$

$$P(Z \geq k | p = 0.9) = 0.05 \Rightarrow k = z_\alpha = z_{0.05} = 1.645.$$

Vi forkaster dermed H_0 dersom $Z \geq 1.645$. Innsatt $x = 912$ blir observert verdi for testobservatoren

$$z = \frac{912 - 1000 \cdot 0.9}{\sqrt{1000 \cdot 0.9 \cdot (1 - 0.9)}} = 1.265.$$

Siden $z = 1.265 \not\geq 1.645$ blir konklusjonen at man ikke skal forkaste H_0 . Det er ikke grunnlag for å påstå at den nye vaksinen er bedre enn den gamle.

B: Forkaster H_0 hvis $Z \geq z_{0.01} = 2.326$, observert verdi for testobservator

$$z = \frac{815 - 1000 \cdot 0.8}{\sqrt{1000 \cdot 0.8 \cdot (1 - 0.80)}} = 1.186$$

C: Forkaster H_0 hvis $Z \geq z_{0.05} = 1.645$, observert verdi for testobservator

$$z = \frac{961 - 1000 \cdot 0.95}{\sqrt{1000 \cdot 0.95 \cdot (1 - 0.95)}} = 1.596$$

- b)** • Vi forutsetter nå at $p = 0.92$ og ønsker sannsynligheten

$$P(Z \geq 1.645 | p = 0.92).$$

Merk at når $p = 0.92$ er H_0 ikke korrekt og dermed er ikke testobservatoren Z standard normalfordelt. Derimot har vi også i denne situasjonen (tilnærmet) at

$$\frac{X - np}{\sqrt{np(1-p)}} \sim N(0, 1).$$

Ved å benytte dette får vi at

$$\begin{aligned} P(Z \geq 1.645 | p = 0.92) &= P\left(\frac{X - np_0}{\sqrt{np_0(1-p_0)}} \geq 1.645 \mid p = 0.92\right) \\ &= P\left(X \geq np_0 + 1.645\sqrt{np_0(1-p_0)} \mid p = 0.92\right) \\ &= P\left(\frac{X - np}{\sqrt{np(1-p)}} \geq \frac{np_0 + 1.645\sqrt{np_0(1-p_0)} - np}{\sqrt{np(1-p)}} \mid p = 0.92\right) \\ &= 1 - P\left(\frac{X - np}{\sqrt{np(1-p)}} \leq \frac{np_0 + 1.645\sqrt{np_0(1-p_0)} - np}{\sqrt{np(1-p)}} \mid p = 0.92\right) \\ &= 1 - \Phi\left(\frac{np_0 + 1.645\sqrt{np_0(1-p_0)} - np}{\sqrt{np(1-p)}}\right) \\ &= 1 - \Phi\left(\frac{1000 \cdot 0.9 + 1.645\sqrt{1000 \cdot 0.9 \cdot 0.1} - 1000 \cdot 0.92}{\sqrt{1000 \cdot 0.92 \cdot 0.08}}\right) \\ &= 1 - \Phi(-0.51) = 1 - 0.3050 = \underline{\underline{0.695}}. \end{aligned}$$

- Ønsker nå å bestemme n slik at

$$P(Z \geq 1.645 | p = 0.92) \geq 0.8.$$

Benytter at vi fra utregningen over vet at

$$P(Z \geq 1.645 | p = 0.92) = 1 - \Phi\left(\frac{np_0 + 1.645\sqrt{np_0(1-p_0)} - np}{\sqrt{np(1-p)}}\right),$$

slik at vi trenger å bestemme n slik at

$$\begin{aligned}
 1 - \Phi\left(\frac{np_0 + 1.645\sqrt{np_0(1-p_0)} - np}{\sqrt{np(1-p)}}\right) &\geq 0.8 \\
 \Phi\left(\frac{np_0 + 1.645\sqrt{np_0(1-p_0)} - np}{\sqrt{np(1-p)}}\right) &\leq 0.2 \\
 \frac{np_0 + 1.645\sqrt{np_0(1-p_0)} - np}{\sqrt{np(1-p)}} &\leq -z_{0.2} = -0.842 \\
 np_0 + 1.645\sqrt{np_0(1-p_0)} - np &\leq -0.842\sqrt{np(1-p)} \\
 n(p_0 - p) + \sqrt{n}\left(1.645\sqrt{p_0(1-p_0)} + 0.842\sqrt{p(1-p)}\right) &\leq 0
 \end{aligned}$$

Setter vi inn $p_0 = 0.9$ og $p = 0.92$ får vi da ulikheten

$$\begin{aligned}
 -0.02n + 0.7219\sqrt{n} &\leq 0 \\
 \sqrt{n}\left(-0.02\sqrt{n} + 0.7219\right) &\leq 0 \\
 -0.02\sqrt{n} + 0.7219 &\leq 0 \\
 \sqrt{n} &\geq \frac{-0.7219}{-0.02} \\
 n &\geq \left(\frac{0.7219}{0.02}\right)^2 = 1302.85.
 \end{aligned}$$

Siden antall personer man skal teste nødvendigvis må være et heltall betyr dette at man må teste minst 1303 forsøkspersoner for at teststyrken skal bli minst 0.8.

$$\text{B: } P(Z \geq 2.326 | p = 0.83) = 0.5199, n \geq 1727$$

$$\text{C: } P(Z \geq 1.645 | p = 0.96) = 0.6915, n \geq 2741$$

Problem 11

Her får vi

$$\bar{X} = \frac{1}{2}(X_1 + X_2) \sim N\left(\mu, \frac{\sigma^2}{2}\right)$$

og vi har selvfølgelig

$$X_3 \sim N(\mu, \sigma^2).$$

Dermed får vi

$$\bar{X} - X_3 \sim N\left(0, \frac{3}{2}\sigma^2\right).$$

Ved å standardisere denne får vi at

$$\frac{\bar{X} - X_3}{\sqrt{\frac{3}{2}\sigma^2}} \sim N(0, 1).$$

Siden σ^2 er ukjent må vi etablere en estimator for denne,

$$\begin{aligned} S^2 &= \frac{1}{2-1} \sum_{i=1}^2 (X_i - \bar{X})^2 = (X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 \\ &= \left(X_1 - \frac{1}{2}(X_1 + X_2)\right)^2 + \left(X_2 - \frac{1}{2}(X_1 + X_2)\right)^2 \\ &= \left(\frac{1}{2}(X_1 - X_2)\right)^2 + \left(\frac{1}{2}(X_2 - X_1)\right)^2 \\ &= 2 \cdot \frac{1}{2^2}(X_1 - X_2)^2 = \frac{1}{2}(X_1 - X_2)^2. \end{aligned}$$

Dermed får vi at

$$\begin{aligned} T &= \frac{\bar{X} - X_3}{\sqrt{\frac{3}{2}S^2}} = \frac{\bar{X} - X_3}{\sqrt{\frac{3}{2} \cdot \frac{1}{2}(X_1 - X_2)^2}} \\ &= \frac{\bar{X} - X_3}{\sqrt{\frac{3}{4}(X_1 - X_2)^2}} = \frac{\bar{X} - X_3}{\frac{\sqrt{3}}{2}|X_1 - X_2|} \sim t_{2-1} \end{aligned}$$

som i sin tur gir at

$$P\left(-t_{1, \frac{\alpha}{2}} \leq T \leq t_{1, \frac{\alpha}{2}}\right) = 1 - \alpha.$$

Setter vi inn uttrykket vi har for T og at $1 - \alpha = \frac{1}{3}$ slik at $\alpha = \frac{2}{3}$ og $\frac{\alpha}{2} = \frac{1}{3}$ gir dette

$$P\left(-t_{1, \frac{1}{3}} \leq \frac{\bar{X} - X_3}{\frac{\sqrt{3}}{2}|X_1 - X_2|} \leq t_{1, \frac{1}{3}}\right) = 1 - \frac{1}{3} \quad (1)$$

Setter vi inn den oppgitte kvantilen $t_{1, \frac{1}{3}} = \frac{1}{\sqrt{3}}$ gir den venstre ulikheten i dette uttrykket at

$$\begin{aligned} -\frac{1}{\sqrt{3}} &\leq \frac{\bar{X} - X_3}{\frac{\sqrt{3}}{2}|X_1 - X_2|} \\ -\frac{1}{2}|X_1 - X_2| &\leq \bar{X} - X_3 \\ -\bar{X} - \frac{1}{2}|X_1 - X_2| &\leq -X_3 \\ X_3 &\leq \bar{X} + \frac{1}{2}|X_1 - X_2| = \frac{1}{2}(X_1 + X_2) + \frac{1}{2}|X_1 - X_2|. \end{aligned}$$

Ved å betrakte hver av de to tilfelle $X_1 \leq X_2$ og $X_1 > X_2$ hver for seg kan man verifisere at $(X_1 + X_2) + |X_1 - X_2| = 2 \max\{X_1, X_2\}$. Ved å benytte dette får vi da at den venstre ulikheten blir

$$X_3 \leq \max\{X_1, X_2\}.$$

For den høyre ulikheten får vi tilsvarende

$$\begin{aligned} \frac{\bar{X} - X_3}{\frac{\sqrt{3}}{2}|X_1 - X_2|} &\leq \frac{1}{\sqrt{3}} \\ \bar{X} - X_3 &\leq \frac{1}{2}|X_1 - X_2| \\ -X_3 &\leq -\bar{X} + \frac{1}{2}|X_1 - X_2| \\ X_3 &\geq \bar{X} - \frac{1}{2}|X_1 - X_2| = \frac{1}{2}(X_1 + X_2) - \frac{1}{2}|X_1 - X_2|. \end{aligned}$$

Ved å betrakte hver av de to tilfellene $X_1 \leq X_2$ og $X_1 > X_2$ hver for seg kan man her verifisere at $(X_1 + X_2) - |X_1 - X_2| = \min\{X_1, X_2\}$, og ved å benytte dette får vi at den høyre ulikheten blir

$$X_3 \geq \min\{X_1, X_2\}.$$

Dermed har vi at uttrykket i (1) kan skrives som

$$P(\min\{X_1, X_2\} \leq X_3 \leq \max\{X_1, X_2\}) = 1 - \frac{1}{3},$$

slik at $(1 - \frac{1}{3})$ -prediksjonsintervall for X_3 blir

$$\underline{[\min\{X_1, X_2\}, \max\{X_1, X_2\}]}$$

For observasjonene $X_1 = 2$ og $x_2 = 5$ blir intervallet $[2, 5]$.

Siden variablene X_1, X_2, X_3 kommer fra samme kontinuerlige fordeling vil det være sannsynlighet $\frac{1}{3}$ for at X_3 er den minste av disse variablene, det vil være sannsynlighet $\frac{1}{3}$ for at X_3 vil være den største av variablene, og det vil være sannsynlighet $\frac{1}{3}$ for at X_3 vil være den midterste verdien. Prediksjonsintervallet som ble utledet over er en måte å uttrykke den siste av disse sannsynlighetene.

B: $[\min\{X_1, X_2\}, \max\{X_1, X_2\}] = [12, 15]$

C: $[\min\{X_1, X_2\}, \max\{X_1, X_2\}] = [1, 6]$