

Institutt for matematiske fag

## Eksamensoppgave i **TMA4245 Statistikk**

**Faglig kontakt under eksamen:**

Tlf:

**Eksamensdato:**

**Eksamenstid (fra–til):**

**Hjelpemiddelkode/Tillatte hjelpemidler:** A: Alle hjelpemidler tillatt.

**Annen informasjon:**

**Målform/språk:** bokmål

**Antall sider:** 4

**Antall sider vedlegg:** 0

**Kontrollert av:**

<b>Informasjon om trykking av eksamensoppgave</b>	
<b>Originalen er:</b>	
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"/>	

\_\_\_\_\_

Dato

\_\_\_\_\_

Sign



**Oppgave 1**

- a) Medianen til datasett A er litt høyere enn medianen til datasett B. Siden A er symmetrisk så vil gjennomsnittet være ganske likt medianen. B er ikke symmetrisk. Det er ikke lett å si noe om varians men det vi ser er at A har en større variasjonsbredde ('range') enn B.
- b) I plott A er de to stokastiske variablene X og Y positivt korrelert, som betyr at det er en lineær sammenheng mellom X og Y. I plott B er X og Y ukorrelerte og ser også ut til å være uavhengige. I plott C er X og Y ukorrelerte, men det er tydelig at X og Y ikke er uavhengige.

**Oppgave 2**

- a) Vi kan definere hendelsene:

- $M_0$  Ingen skårer mål (0-0)
- $M_1$  United skårer første mål
- $M_2$  motstander skårer første mål

Fra teksten vi vet at  $P(M_1) = 0.3$ ,  $P(M_0) = 0.05$ , og fra dette kan vi regne ut

$$\begin{aligned} P(M_2) &= 1 - P(M_1) - P(M_0) \\ &= 1 - 0.3 - 0.05 = 0.65. \end{aligned}$$

Vi vet også at  $P(\text{vinn}|M_1) = 0.6$  og  $P(\text{vinn}|M_2) = 0.1$ . I tillegg er det åpenbart at  $P(\text{vinn}|M_0) = 0$ . Ved å bruke setningen om total sannsynlighet kan vi regne ut

$$\begin{aligned} P(\text{vinn}) &= P(\text{vinn}|M_1)P(M_1) + P(\text{vinn}|M_2)P(M_2) + P(\text{vinn}|M_0)P(M_0) \\ &= 0.6 \cdot 0.3 + 0.1 \cdot 0.65 + 0 \cdot 0.05 = 0.245 \end{aligned}$$

- b) Riktig svar er  $(A \cap C) \cup (C \cap (A \cup B)')$
- c) Riktig svar er 'Sann kun dersom A og B er like sannsynlige'

**Oppgave 3**

a) Vi kan regne  $P(X = 0)$  ved  $P(X = 0) = \sum_{y=0}^3 P(X = 0, Y = y) = 0.1 + 0.05 + 0.2 + 0.1 = 0.45$

b) Vi har at

$$P(Y \leq 1 | X = 0) = \frac{P(Y \leq 1, X = 0)}{P(X = 0)} = \frac{0.1 + 0.05}{0.45} = 0.333$$

c) Nei  $X$  og  $Y$  er ikke uavhengige. Vi kan for eksempel se at  $P(X = 0 | Y = 0) = \frac{0.1}{0.15} = 0.667 \neq P(X = 0)$ .

d) Vi bruker formelen  $E(g(X, Y)) = \sum_x \sum_y g(x, y)P(X = x, Y = y)$ . Siden  $g(x, y) = 0$  når  $x = 0$  kan vi regne ut

$$\begin{aligned} E(g(X, Y)) &= \sum_{y=0}^3 (1 + 2y)P(X = 1, Y = y) \\ &= 1 \cdot 0.05 + (1 + 2) \cdot 0.15 + (1 + 4) \cdot 0.3 + (1 + 6) \cdot 0.05 = 2.35 \end{aligned}$$

**Oppgave 4**

a) Forventningsverdien til en eksponensialfordeling med parameter  $\lambda = 0.8$  er  $1/\lambda = 1.25$

b) Vi har at

$$P(X > 1) = 1 - F(x) = 1 - \int_0^x f(x)dx = 1 - (1 - e^{-\lambda x}) = e^{-\lambda x} = e^{-0.8} = 0.449$$

c) Siden komponentene er koblet i serie så er levetiden til maskinen lik levetiden til den komponenten som først slutter å fungere, dvs  $\min\{X_1, \dots, X_5\}$ . Videre er minimum av 5 eksponensialfordelte variabler med samme parameter  $\lambda$  eksponensialfordelt med parameter  $5 \cdot \lambda$ . Dermed er  $P(\min(X_1, \dots, X_5) > 1) = e^{-5 \cdot 0.8 \cdot 1} = 0.018$ .

d) Eksponensialfordelingen har en kjent momentgenererende funksjon, og det har også gammafordelingen. Videre vet vi at MGF-en til en sum av uavhengige identisk fordelte variabler er gitt ved produktet av MGF-ene. I dette tilfellet blir MGF til summen av de 5 eksponensialfordelte variablene  $1/(1 - t/0.8)^5$ . Nå kan vi kjenne igjen MGF-en til en gammafordeling hvis vi setter parameteren  $\alpha = 5$  og parameteren  $\beta = 1/0.8 = 1.25$ .

**Oppgave 5**

- a) Det er ikke rimelig å anta at  $X$  og  $Y$  er uavhengige stokastiske variabler. Blodtrykksmålingene  $X$  og  $Y$  er gjort på samme person (før og etter treningsopplegg) og må antas avhengige. Det vil for eksempel være rimelig å tro at blodtrykknivået før treningsopplegget ( $X$ ) gir en viss indikasjon på hva blodtrykket etter treningsopplegget ( $Y$ ) vil være.
- b)  $E(D) = E(Y - X) = E(Y) - E(X) = \mu_y - \mu_x$  uansett om  $X$  og  $Y$  er uavhengige eller ikke. Basert på observasjonene i tabellen er  $\bar{d} = -6.88$  estimatet vårt for  $E(D)$  og  $s_d = 10.757$  er estimatet for standardavviket.
- c) Vi velger testobservatoren  $T = (\bar{D} - 0)/(S/\sqrt{10})$ , der  $\bar{D}$  er gjennomsnittet av utvalget og  $S$  er estimatoren for standardavviket til  $D$ . Når nullhypotesen er sann er testobservatoren  $t$ -fordelt med 9 frihetsgrader. Ved signifikansnivå 0.01 skal vi forkaste nullhypotesen dersom vi observerer  $t < -1.383$ . Observerte verdi av testobservatoren finner vi ved å sette inn estimat på forventningsverdi og standardavvik fra forrige del-oppgave, slik at  $t = -2.022$ . Dermed forkaster vi nullhypotesen. Dr. Hansen har grunnlag for å påstå at treningsopplegget virker.
- d) En type-1 feil går ut på å forkaste nullhypotesen, og dermed påstå at treningsopplegget 'virker', til tross for at treningsopplegget egentlig ikke hadde noen blodtrykkdempende effekt. En type-2 feil går ut på å ikke forkaste nullhypotesen selv om treningsopplegget faktisk har en blodtrykkdempende effekt.
- e) Riktig svar er 'Sannsynligheten for det vi har observert, eller noe mer ekstremt i retning av den alternative hypotesen, når vi antar at nullhypotesen er sann.'

**Oppgave 6**

- a) Ved å plote residualene kan man sjekke antagelsene om at feil-leddet i regresjonsmodellen (altså  $\epsilon$ ) har forventning 0 og samme varians ( $\sigma^2$ ) for alle verdier av  $x$ . Residualene fra modell A ser ut til å tilfredstille disse antagelsene. Residualene i modell B er også sentrert rundt 0 men vi ser at variansen øker for høyere verdier av  $x$ .

b) Vi vet at i en enkel regresjonsmodell er

$$\frac{\hat{\beta} - \beta}{\sqrt{\frac{s^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim t_{n-2}.$$

Dermed er et 95% konfidensintervall for  $\beta$  gitt ved

$$\hat{\beta} \pm t_{13,0.025} \sqrt{\frac{s^2}{\sum_{i=1}^{15} (x_i - \bar{x})^2}}$$

hvor  $t_{13,0.025} = -2.16$ .

Når vi setter inn tall finner vi at konfidensintervallet er:

$$1.109 \pm 2.16 \cdot \sqrt{\frac{0.762}{18.028}} = [0.665, 1.553]$$