

Institutt for matematiske fag

Eksamensoppgåve i **TMA4245 Statistikk**

Fagleg kontakt under eksamen: Ingelin Steinsland^a, Jo Eidsvik^b

Tlf: ^a92 66 30 96, ^b90 12 74 72

Eksamensdato: 30. mai 2016

Eksamenstid (frå–til): 09.00-13.00

Hjelpemiddelkode/Tillatne hjelpemiddel: *Tabeller og formler i statistikk*, Tapir Forlag, K. Rottmann: *Matematisk formelsamling*, Kalkulator Casio fx-82ES PLUS, CITIZEN SR-270X, CITIZEN SR-270X College eller HP30S, Gult stempla A5-ark med egne handskrivne notat.

Annan informasjon:

Alle svar skal grunngjevast og besvarelsen skal innehalde naturlege mellomrekningar.

Målform/språk: nynorsk

Sidetal: 4

Sidetal vedlegg: 0

Kontrollert av:

Dato

Sign

Oppg ve 1 Huskj p

Gustav og Margrethe er nyutdanna sivilingeni r r fr  NTNU og er no p  bustad-jakt i Trondheim. Begge ser etter ei leilegheit i ein bestemt bydel.

Vi antar at prisen per kvadratmeter (kvadratprisen) for denne bydelen er normalfordelt. I punkt **a)** og **b)** antar vi at forventningsverdien er $\mu = 30$ kkr (30.000 kr) og standardavviket er $\sigma = 2.5$ kkr.

a) Kva er sannsynet for at kvadratprisen for ei tilfeldig leilegheit er:


- l gare enn 30 kkr?
- h gare enn 25 kkr?
- h gare enn 25 kkr gjeve at kvadratprisen er l gare enn 30 kkr.

b) Gustav vurderer ei leilegheit p  40 kvadratmeter, og Margrethe vurderer ei leilegheit p  50 kvadratmeter. La X_G vere kvadratprisen for leilegheit Gustav vurderer og la X_M vere kvadratprisen for leilegheita Margrethe vurderer. Bruk desse til   finne uttrykk for prisen (kj pssummen, ikkje kvadratprisen) til kvar av leiligheitene. Finn og eit uttrykk for prisforskjellen mellom dei to leiligheitene n r vi antar at prisane p  leiligheitene er uavhengige. Kva er sannsynet for at leiligheita Margrethe vurderer er billigare enn leiligheita Gustav vurderer?


c) Gustav og Margrethe har samla inn data (x_1, x_2, \dots, x_n) for kvadratpris (i kkr) fr  dei siste $n = 15$ bustadsala i bydelen, og  nsker basert p  desse   finne eit 95% konfidensintervall for forventa kvadratpris. Utlei eit uttrykk for konfidensintervallet (du kan ta utgangspunkt i ein kjent observator). Rekn ut konfidensintervallet numerisk n r gjennomsnittet av kvadratprisane er $\bar{x} = 32$ kkr og $\sum_{i=1}^n (x_i - \bar{x})^2 = 74.1$.

Oppg ve 2 Den nye sensoren

Firmaet SkaffData pr ver ut ein ny sensor som skal gje billige data p  vassgjennomstrauming i r yr. Dei pr ver ut sensoren i ein realistisk situasjon. I tillegg til m lingane sensoren gjev, (y_1, y_2, \dots, y_n) , m ler dei og tilh yrande sann vassgjennomstrauming, (x_1, x_2, \dots, x_n) , for $n = 1000$ uavhengige tidsperiodar. I figur 1 er histogrammet over sann gjennomstrauming, og i figur 2 er sann gjennomstrauming (x) plotta mot sensorm lt gjennomstrauming (y) .



Figur 1: Histogram for observasjonar av sann gjennomstrauming (x)



Figur 2: Observasjonar av sann gjennomstrauming (x) plotta mot sensorm lt gjennomstrauming (y) . Den heiltrukne linja er $y = x$.

a) Basert på figur 1 og 2 svar på følgjande spørsmål, og grunngje alle svara kort:

- Kva er forventningsverdien og standardavviket til sann gjennomstrauming (X)? (Både forventningsverdien og standardavviket er heiltal)
- Kva er forventningsverdien og standardavviket til sensormålt gjennomstrauming (Y) gjeve at sann gjennomstrauming er $X = 6$. (Både forventningsverdien og standardavviket er igjen heiltal)
- Er korrelasjonen (og kovariansen) mellom sann gjennomstrauming (X) og sensormålt gjennomstrauming (Y) positiv, negativ eller omlag null?

Ein enkel lineær regresjonsmodell er som kjent ofte definert som $Y_i = a + bx_i + \epsilon_i$, for $i = 1, 2, \dots, n$ der Y_i er responsen vi er interessert i, a og b er regresjonsparameterar, x_i er ein forklaringsvariabel som vi antar er kjent, og støyledda ϵ_i antar vi er uavhengige identisk normalfordelte med forventningsverdi 0 og varians σ_ϵ^2 .

b) Svar på følgjande spørsmål, og grunngje alle svara kort:

- Dersom ein tilpassar ein enkel lineær regresjonsmodell til dataene i figur 2, kva blir omlag estimata for a og b ?
- Basert på anslaga dine for a og b , kva blir predikert sensormålt gjennomstrauming (y_0) for ei sann gjennomstrauming på $x_0 = 4$.
- Diskuter om antakingane i ein enkel lineær regresjonsmodell passar for dataene i figur 2.

Oppgåve 3 Besøk på webside

For firmaet SjøMeg er talet på besøk på websida deira viktig. La X_i vere talet på besøk i løpet av t_i timar, og la X_1, X_2, \dots, X_n vere talet på besøk i n ikkje-overlappande tidsintervall. Vi antar at besøk på websida er ein poissonprosess med besøksintensitet λ . Dermed er X_1, X_2, \dots, X_n uavhengige poissonfordelte stokastiske variabler med sannsynsfordeling

$$f(x_i) = \frac{(\lambda t_i)^{x_i}}{x_i!} e^{-\lambda t_i} \quad \text{for } x_i = 0, 1, 2, \dots$$

a) Anta (berre i dette punktet) at $\lambda = 10$ og $t_1 = 1$. Finn sannsyna

$$P(X_1 = 8) \quad , \quad P(X_1 \geq 8) \quad \text{og} \quad P(8 \leq X_1 \leq 12).$$

Vi antar no at besøksintensiteten λ er ukjent. SjøMeg ønsker å estimere intensiteten λ frå data på talet på besøk frå n ikkje-overlappende tidsintervall. Det er foreslått tre estimatorar,

$$\tilde{\lambda} = \frac{1}{n} \sum_{i=1}^n X_i \quad , \quad \hat{\lambda} = \frac{\sum_{i=1}^n X_i}{\sum_{i=1}^n t_i} \quad \text{og} \quad \hat{\lambda} = \frac{1}{n} \sum_{i=1}^n \frac{X_i}{t_i},$$

og vi oppgjev at $E[\hat{\lambda}] = \lambda$ og $\text{Var}[\hat{\lambda}] = \lambda / \sum_{i=1}^n t_i$.

- b)** Kven av dei tre estimatorane vil du foretrekke når $n = 5$ og $t_1 = 1$, $t_2 = 2$, $t_3 = 5$, $t_4 = 1$, $t_5 = 5$? Grunnlegg svaret.
- c)** Utlei sannsynlighetsmaksimeringsestimatoren (SME) for λ basert på X_1, X_2, \dots, X_n .

For punkt **d)** og **e)** i denne oppgåven skal du, uavhengig av resultatane dine i punkt **b)** og **c)**, ta utgangspunkt i estimatoren $\hat{\lambda}$ definert over. Vidare kan du forutsette at $\lambda \sum_{i=1}^n t_i$ er stor og bruke at då er $\hat{\lambda}$ tilnærma normalfordelt med forventningsverdi og varians som gjevne over.

SjøMeg får vite at besøksintensiteten til deira største konkurrent er på $\lambda_0 = 10$ besøk per time, og ønsker å bruke observerte verdiar av X_1, X_2, \dots, X_n til å avgjere om det er grunnlag for å påstå at deira webside har ein høgare besøksintensitet.

- d)** Formuler hypotesene H_0 og H_1 for situasjonen skildra over.

Oppgje kva av testobservatorane du vil bruke og kva (tilnærma) sannsynsfordeling testobservatoren har når H_0 er rett.

Rekn ut p -verdien til hypotesetesten når n og t_1, t_2, \dots, t_n er som i **b)**, og observert tal på besøk er $x_1 = 8$, $x_2 = 20$, $x_3 = 48$, $x_4 = 10$ og $x_5 = 62$. Med utgangspunkt i den utreknede p -verdien, diskuter kort om det er grunnlag for å påstå at SjøMeg har høgare besøksintensitet enn konkurrenten.

- e)** Dersom ein bruker signifikansnivå $\alpha = 0.05$ i hypotesetesten i **d)**, kor stor må besøksintensiteten til SjøMeg vere for at sannsynet for å konkludere med at intensiteten er høgare enn konkurrenten sin intensitet skal vere minst 0.9? Bruk her dei same verdiane for n og t_1, t_2, \dots, t_n som i punkt **b)**.