



TMA4245 Statistikk

Eksamensmai 2016

Norges teknisk-naturvitenskapelige universitet
Institutt for matematiske fag

Oppgave 1


Gustav og Margrethe er nyutdanna sivilingeniørar frå NTNU og er no på bustadjakt 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.


- Kva er sannsynet for at kvadratprisen for ei tilfeldig leilegheit er:
 - lågare enn 30 kkr?
 - høgare enn 25 kkr?
 - høgare enn 25 kkr gjeve at kvadratprisen er lågare enn 30 kkr.
- Gustav vurderer ei leilegheit på 40 kvadratmeter, og Margrethe vurderer ei leilegheit på 50 kvadratmeter. La X_G vere kvadratprisen for leilegheit Gustav vurderer og la X_M vere kvadratprisen for leilegheita Margrethe vurderer. Bruk desse til å finne uttrykk for prisen (kjøppsummen, ikkje kvadratprisen) til kvar av leilighetene. Finn og eit uttrykk for prisforskjellen mellom dei to leilighetene når vi antar at prisane på leilighetene er uavhengige. Kva er sannsynet for at leilegheita Margrethe vurderer er billigare enn leilegheita Gustav vurderer?
- Gustav og Margrethe har samla inn data (x_1, x_2, \dots, x_n) for kvadratpris (i kkr) frå dei siste $n = 15$ bustadsala i bydelen, og ønsker basert på desse å finne eit 95% konfidensintervall for forventa kvadratpris. Utlei eit uttrykk for konfidensintervallet (du kan ta utgangspunkt i ein kjent observator). Rekn ut konfidensintervallet numerisk når gjennomsnittet av kvadratprisane er $\bar{x} = 32$ kkr og $\sum_{i=1}^n (x_i - \bar{x})^2 = 74.1$.

Oppgave 2

Firmaet SkaffData prøver ut ein ny sensor som skal gje billige data på vassgjennomstrauming i røyr. Dei prøver ut sensoren i ein realistisk situasjon. I tillegg til målingane sensoren gjev, (y_1, y_2, \dots, y_n) , måler dei og tilhøyrande 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 sensormålt gjennomstrauming (y).



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



Figur 2: Observasjonar av sann gjennomstrauming (x) plotta mot sensormålt gjennomstrauming (y). Den heiltruckne 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 støyflekkene 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.

Oppgave 3

For firmaet SjåMeg er talet på besøk på websida deira viktig. La X_i vere talet på besøk i løpet av t_i timer, 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 . Derved 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

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

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

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

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 $t_1 = 1, t_2 = 2, t_3 = 5, t_4 = 1, t_5 = 5$? Grunngje 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 resultata 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 gjeve over.

SjåMeg 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 utrekna p -verdien, diskuter kort om det er grunnlag for å påstå at SjåMeg har høgare besøksintensitet enn konkurrenten.

- e)** Dersom ein bruker signifikansnivå $\alpha = 0.05$ i hypotesestesten i **d)**, kor stor må besøksintensiteten til SjåMeg vere for at sannsynet for å konkludere med at intensiteten er høgere 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)**.

Fasit

1. **a)** 0.5, 0.9772, 0.9544 **b)** $40X_G, 50X_M, 40X_G - 50X_M, 0.0307 **c)** (30.7, 33.3)$

2. **a)** 5, 2 **b)** $a = 0, b = 1, \hat{y} = 4$

3. **a)** 0.1126, 0.7798, 0.5714 **b)** Føretrekker $\hat{\lambda}$ **d)** $H_0 : \lambda = \lambda_0, H_1 : \lambda > \lambda_0, 0.2483$ **e)** $\lambda \geq 12.6068$