



Norges teknisk-naturvitenskapelige universitet  
Institutt for matematiske fag

TMA4240 Statistikk  
Høst 2017

**Anbefalt øving 10**

Oppgavene i denne anbefalte øvingen har det til felles at de omhandler ulike typer konfidensintervall. Andre aktuelle tema er punktestimering og sannsynlighetsmaksimering.

### Oppgave 1

Miljøkonsulenten i en kommune ønsker å undersøke den ukjente pH-verdien i et vann. Betegn den sanne pH-verdien for  $\mu$ . Konsulenten har tilgjengelig to målemetoder. Metode I er rask, men måleresultatene er beheftet med betydelig måleusikkerhet. Metode II er mye mer tidkrevende, men gir mer nøyaktige målinger. Begge målemetodene er velbrukte og variansen i målingene er derfor kjent. Miljøkonsulenten velger å gjøre en observasjon med hver metode. La  $X$  betegne observasjonen ved bruk av metode I og  $Y$  observasjonen ved metode II. Vi antar at  $X$  og  $Y$  uavhengige og normalfordelt med

$$E(X) = \mu, \quad \text{Var}(X) = \sigma_0^2, \quad E(Y) = \mu, \quad \text{Var}(Y) = \tau_0^2$$

der  $\sigma_0^2$  og  $\tau_0^2$  er kjente størrelser.

Det oppgis at en forventningsrett estimator (som forøvrig også er sannsynlighetsmaksimerings-estimator) for  $\mu$  i denne situasjonen er

$$\hat{\mu} = \frac{\tau_0^2 X + \sigma_0^2 Y}{\tau_0^2 + \sigma_0^2}.$$

Ta utgangspunkt i estimatoren  $\hat{\mu}$  og utled et  $(1 - \alpha)100\%$  konfidensintervall for  $\mu$ .

### Oppgave 2

Levetiden,  $T$ , for en bestemt type elektroniske komponenter har vist seg å være eksponensialfordelt med parameter  $\lambda$ , dvs.

$$f_T(t) = \begin{cases} \lambda e^{-\lambda t} & , t > 0 \\ 0 & , \text{ellers} \end{cases}$$

a) Vis at  $Z = 2\lambda T$  er  $\chi^2$ -fordelt med 2 frihetsgrader, dvs. at

$$f_Z(z) = \begin{cases} \frac{1}{2} e^{-\frac{z}{2}} & , z > 0 \\ 0 & , \text{ellers} \end{cases}$$

b) Benytt resultatet i oppgave a) til å utlede et 90% konfidensintervall for  $\lambda$ .

I filen `levetider.txt` på hjemmesiden er 500 observerte levetider  $T_1, \dots, T_{500}$  som kan antas å ha tetthet  $f_T(t)$  med ukjent parameter  $\lambda$ .

- c) Det kan antas som kjent at sannsynlighetsmaksimeringsestimatoren (SME) til  $\lambda$  er  $\hat{\lambda} = 500 / \sum_{i=1}^{500} T_i$ . Benytt Matlab til å beregne estimatet.

Bruk Matlab til å finne et 90% konfidensintervall for  $\lambda$  basert på uttrykket du utledet i oppgave b).

### Oppgave 3

For å kunne dimensjonere en oljeplattform er det viktig å vite hvor store bølgene kan bli i området der plattformen skal plasseres. Det settes derfor ut en bølgehøydemåler. La  $X$  være største bølgehøyde en tilfeldig valgt dag. Vi antar at sannsynlighetstettheten til  $X$  er gitt ved

$$f(x; \theta) = \frac{2x}{\theta} e^{-\frac{x^2}{\theta}}, \quad x \geq 0, \quad \theta > 0.$$

Det oppgis at  $E[X^2] = \theta$  og  $E[X^4] = 2\theta^2$ .

- a) Vis at den kumulative fordelingsfunksjonen,  $F(x) = P(X \leq x)$ , er  $F(x) = 1 - e^{-\frac{x^2}{\theta}}$ . (Hint: Bruk substitusjon med  $u = x^2$ ).

Gitt at største bølgehøyde er større enn 10 meter, finn sannsynligheten for at den er større enn 15 meter hvis  $\theta = 25$ , dvs.  $P(X > 15 | X > 10)$ ?

I resten av oppgaven regnes  $\theta$  som ukjent.

Vi har observert største bølgehøyde i  $n$  dager. La  $X_i$  være største bølgehøyde på dag  $i$ . Vi antar at  $X_1, \dots, X_n$  er uavhengige og identisk fordelte med sannsynlighetstetthet  $f(x; \theta)$ .

- b) Finn sannsynlighetsmaksimeringsestimatoren (SME)  $\hat{\theta}$  for  $\theta$ .

Er estimatoren  $\hat{\theta}$  forventningsrett?

Finn også variansen til  $\hat{\theta}$ .

- c) Bruk sentralgrenseteoremet til å argumentere for at

$$Z = \frac{\frac{1}{n} \sum_{i=1}^n X_i^2 - \theta}{\sqrt{\frac{\theta^2}{n}}}$$

er tilnærmet standard normalfordelt.

Bruk  $Z$  til å finne et tilnærmet 95% konfidensintervall for  $\theta$ .

Sannsynligheten for at største bølgehøyde en tilfeldig valgt dag overskrider 10 meter er  $P(X > 10) = e^{-\frac{100}{\theta}}$ . Bruk det tilnærmede konfidensintervallet for  $\theta$  til å finne et tilnærmet 95% konfidensintervall for  $e^{-\frac{100}{\theta}}$ .

### Oppgave 4

La tiden  $X$  (målt i uker) mellom to påfølgende feil i et mobilnett være en kontinuerlig stokastisk variabel med sannsynlighetstetthet

$$f(x) = \beta x^{-\beta-1}, \quad x > 1, \quad \beta > 1.$$

a) Vis at den kumulative fordelingsfunksjonen,  $F(x)$ , for  $X$  er  $F(x) = 1 - x^{-\beta}$ , for  $x > 1$ .

Anta i resten av dette punktet at  $\beta = 3$ .

Hva er sannsynligheten for at det tar mer enn 2 uker mellom to påfølgende feil?

Dersom det er gått 2 uker siden sist det var en feil på nettet, hva er sannsynligheten for at det svikter innen det er gått 3.5 uker fra siste feil?

Vi vil estimere parameteren  $\beta$  basert på data for tidligere tilfeller av feil på nettet. La  $X_i$ ,  $i = 1, \dots, n$  være lengden på  $n$  tidsintervaller (målt i uker) mellom to påfølgende feil. Vi antar at  $X_1, X_2, \dots, X_n$  er uavhengige og identisk fordelte stokastiske variabler, med sannsynlighetstetthet  $f(x)$  som gitt i starten av oppgaven.

Tre alternative estimatorer for  $\beta$  er

$$\hat{\beta}_1 = \frac{n}{\sum_{i=1}^n \ln(X_i)}, \quad \hat{\beta}_2 = \frac{n-1}{\sum_{i=1}^n \ln(X_i)} \quad \text{og} \quad \hat{\beta}_3 = \frac{\sum_{i=1}^n \ln(X_i)}{n},$$

der  $\ln$  er den naturlige logaritmen.

b) Hvilken av estimatorene over er sannsynlighetsmaksimeringsestimatorene (SME)? Begrunn svaret ved å utlede SME. Beregn estimatet når  $n = 10$  og de observerte verdiene er som følger:

$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$
1.23	2.04	1.27	1.79	1.10	1.29	2.74	1.15	1.10	1.06

Det oppgis at  $\sum_{i=1}^{10} \ln(x_i) = 3.39$ .

c) Vis at  $2\beta \ln(X_i)$  er kjikvadratfordelt med 2 frihetsgrader, og videre at  $2\beta \sum_{i=1}^n \ln(X_i)$  er kjikvadratfordelt med  $2n$  frihetsgrader.

Utlede et 95% konfidensintervall for  $\beta$ . Hva blir intervallet når dataene er som i punkt b)?

### Oppgave 5 Dekningssannsynlighet for konfidensintervall

La  $X_1, X_2, \dots, X_n$  være uavhengig og identisk normalfordelte tilfeldige variabler med ukjent forventningsverdi  $\mu$  og ukjent varians  $\sigma^2$ .

a) Vis at et 90% konfidensintervall for  $\mu$  er  $[L, U]$  hvor

$$L(X_1, X_2, \dots, X_n) = \bar{X} - t_{n-1, 0.05} \cdot \sqrt{\frac{S^2}{n}}$$

og

$$U(X_1, X_2, \dots, X_n) = \bar{X} + t_{n-1, 0.05} \cdot \sqrt{\frac{S^2}{n}}$$

med

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \text{og} \quad S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

og hvor  $t_{n-1, 0.05}$  er 0.95-kvantilen i  $t$ -fordelingen med  $n - 1$  frihetsgrader.

- b) Sett  $n = 10$ ,  $\mu = 3$  og  $\sigma^2 = 2^2$ . Trekk realisasjoner av  $X_1, X_2, \dots, X_{10}$  fra en  $N(\mu, \sigma^2)$ -fordeling. Regn ut  $L$  og  $U$ . Dekker intervallet den sanne forventningsverdien, det vil si holder dobbeltulikheten  $L \leq \mu \leq U$ ?
- c) Gjenta prosedyren i b) 10 000 ganger. Finn den empiriske sannsynligheten for at konfidensintervallet dekker den sanne forventningsverdien  $\mu$ . Kommenter svaret.

## Fasit

2. c) 0.0097, [0.0090, 0.0104]

3. a) 0.0067

4. a) 0.125, 0.813 b) 2.95 c) [1.41, 5.04]