

Konfidensintervall

TMA4240/TMA4245 Statistikk

Håkon Tjelmeland

Institutt for matematiske fag

Norges teknisk-naturvitenskapelige universitet

Konfidensintervall

Observator: En observerbar funksjon av en eller flere variabler som utgjør et utvalg

* Situasjon:

- er interessert i en populasjon, parameter θ
- observerer verdier for et utvalg, X_1, X_2, \dots, X_n
- har estimator for θ : $\hat{\theta}$
- ønsker nå et intervall som inneholder verdien til θ med en angitt sannsynlighet

Definisjon (Konfidensintervall)

Anta at vi har stokastiske variabler X_1, X_2, \dots, X_n , og at sannsynlighetsfordelingen til disse inneholder en parameter θ og at verdien til θ er ukjent. La x_1, x_2, \dots, x_n være observerte verdier for de stokastiske variabler X_1, X_2, \dots, X_n . Anta videre at for to observatører $\hat{\theta}_L(X_1, X_2, \dots, X_n)$ og $\hat{\theta}_U(X_1, X_2, \dots, X_n)$ har at

$$P\left(\hat{\theta}_L(X_1, X_2, \dots, X_n) \leq \theta \leq \hat{\theta}_U(X_1, X_2, \dots, X_n)\right) = 1 - \alpha,$$

for $\alpha \in (0, 1)$. Det numeriske intervallet

$$\left[\hat{\theta}_L(x_1, x_2, \dots, x_n), \hat{\theta}_U(x_1, x_2, \dots, x_n)\right]$$

kalles da et $(1 - \alpha) \cdot 100\%$ -konfidensintervall for θ

- * Hvordan finne slike observatører $\hat{\theta}_L(X_1, X_2, \dots, X_n)$ og $\hat{\theta}_U(X_1, X_2, \dots, X_n)$?
- * Hva er tolkningen av intervallet $\left[\hat{\theta}_L(x_1, x_2, \dots, x_n), \hat{\theta}_U(x_1, x_2, \dots, x_n)\right]$?

Eksempel: Utledning av konfidensintervall

* Situasjon:

- la X_1, X_2, \dots, X_n være et tilfeldig utvalg fra $N(\mu, \sigma^2)$ -populasjonen
- verdien til μ er ukjent, ønsker et konfidensintervall for μ , antar verdien til σ^2 kjent!

* Estimator for μ : $\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

* Vi vet at

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right) \Rightarrow \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim N(0, 1)$$

* Dermed

$$P\left(-z_{\frac{\alpha}{2}} \leq \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \leq z_{\frac{\alpha}{2}}\right) = 1 - \alpha$$


* Løser hver ulikhet hver for seg med hensyn på μ

$$-z_{\frac{\alpha}{2}} \leq \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}}$$

$$-z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}} \leq \bar{X} - \mu$$

$$-\bar{X} - z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}} \leq -\mu$$

$$\mu \leq \bar{X} + z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}}$$



$$\frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \leq z_{\frac{\alpha}{2}}$$

$$\bar{X} - \mu \leq z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}}$$

$$-\mu \leq -\bar{X} + z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}}$$

$$\bar{X} - z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}} \leq \mu$$

* Får at

$$P\left(\bar{X} - z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}} \leq \mu \leq \bar{X} + z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}}\right) = 1 - \alpha$$

* $(1 - \alpha) \cdot 100\%$ -konfidensintervall for μ :

$$\left[\bar{x} - z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}}, \bar{x} + z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}}\right]$$

Utledning av konfidensintervall

- Prosedyre for å utlede et konfidensintervall for parameter θ basert på x_1, x_2, \dots, x_n

- Bestemme pivotal, $Z = h(\theta, X_1, X_2, \dots, X_n)$
 - inneholder ingen ukjente parametere unntatt θ
 - har en kjent fordeling (som ikke avhenger av θ)

$$Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim N(0, 1)$$

- Finne kvantiler $z_{1-\frac{\alpha}{2}}$ og $z_{\frac{\alpha}{2}}$ slik at

$$P\left(z_{1-\frac{\alpha}{2}} \leq h(\theta, X_1, X_2, \dots, X_n) \leq z_{\frac{\alpha}{2}}\right) = 1 - \alpha$$


- Løse hver ulikhet med hensyn på θ

- Sette ulikhettene sammen igjen med θ i midten

$$P\left(\hat{\theta}_L(X_1, X_2, \dots, X_n) \leq \theta \leq \hat{\theta}_U(X_1, X_2, \dots, X_n)\right) = 1 - \alpha$$

- Konkludere ved å skrive opp $(1 - \alpha) \cdot 100\%$ -konfidensintervallet for θ

$$\left[\hat{\theta}_L(x_1, x_2, \dots, x_n), \hat{\theta}_U(x_1, x_2, \dots, x_n)\right]$$



Tolkning av konfidensintervall

$P(A)$: Andel av gangene hendelsen A skjer hvis man gjentar det stokastiske forsøket uendelig mange ganger

- * Kan ikke tolke selve konfidensintervallet


$$\left[\widehat{\theta}_L(x_1, x_2, \dots, x_n), \widehat{\theta}_U(x_1, x_2, \dots, x_n) \right]$$

- * Må tolke sannsynlighetsuttrykket

$$P\left(\widehat{\theta}_L(X_1, X_2, \dots, X_n) \leq \theta \leq \widehat{\theta}_U(X_1, X_2, \dots, X_n)\right) = 1 - \alpha$$

- * Simuleringseksempel:

- la X_1, X_2, \dots, X_n være tilfeldig utvalg fra $N(\mu, \sigma^2)$ -populasjonen
- verdien til μ er ukjent, ønsker konfidensintervall for μ , antar verdien til σ^2 kjent
- $(1 - \alpha) \cdot 100\%$ -konfidensintervall for μ : $\left[\bar{x} - z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}}, \bar{x} + z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma^2}{n}} \right]$
- Stokastisk simulering med $n = 30$, $\mu = 20$, $\sigma^2 = 5^2$ og $\alpha = 0.05$



Oppsummering

- ★ Har definert begrepet
 - konfidensintervall
- ★ Har diskutert
 - prosedyre for å utlede et konfidensintervall
 - tar utgangspunkt i en pivotal
 - tolkningen av konfidensintervall
 - tenker oss at vi gjentar målingene uendelig mange ganger