

Konf. int. / fort.

X_1, X_2, \dots, X_n uavh. $\sim N(\mu, \sigma^2)$?

$$T = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim T_{n-1}$$

$\rightarrow \bar{X} \pm t_{\alpha/2} \frac{S}{\sqrt{n}}$ = et hvilket $(1-\alpha)100\%$ CI for μ .

$$\frac{S^2}{\sigma^2} (n-1) \sim \chi^2_{n-1}$$

$\rightarrow \left(\frac{S^2}{\sigma^2} (n-1), \frac{S^2}{\sigma^2} (n-1) \right)$ er et et hvilket $(1-\alpha)100\%$ CI for σ^2

$$P(X_{n-1}^2 > \chi_\alpha^2) = \alpha$$

T-intervallset er robust for normalitetsantagelsen når n er stor.

Kj. int. krever normalfordeling også ved stor n .

Men når n er liten og/eller normalfordeling ikke holder er det ikke sikkert at

$$\text{Dekningsgrad} = \text{Coverage} = P(\hat{\theta} \in (\theta_{l_1}, \theta_{u_1})) = 1-\alpha$$

sep 12-12:13

Hvis antagelsene avviklet kan vi istedet beregne CI ved bootstraping.

Bootstrap Data $X_1, \dots, X_n \sim f(x; \theta)$

(a) Estimat $\hat{\theta}$ fra X_1, \dots, X_n

(b) Generer pseudodata X_1^*, \dots, X_B^*

(c) Beregn θ^* fra pseudodataene

(d) Gjentar (a)-(c) B ganger, $\theta_1^*, \dots, \theta_B^*$

Hvis fordelingen til θ_B^* er tiln. normal

først tiln. CI ved

$$\hat{\theta} \pm t_{\alpha/2} S_{\theta^*}$$

$$\text{der } S_{\theta^*}^2 = \frac{1}{B} \sum_{b=1}^B (\theta_b^* - \bar{\theta}^*)^2$$

boot-t

intervall

sep 12-12:44

Alternativt kan vi beregne percentilintervallet

Sorterer θ^* -ene: $\theta_{(1)}^* < \theta_{(2)}^* < \dots < \theta_{(B)}^*$

La f.eks. $b_L = [0, 0.025 B]$ (og $b_R = \text{heltall}, \text{verdi}$ av x)

$$\Rightarrow b_U = [0.975 B, B]$$

Da er $(\theta_{(b_L)}, \theta_{(b_U)})$ et 95% percentilintervall

for θ .

Parametrisk bootstrap:

Pseud. data x_1^*, \dots, x_n^* trukket fra $f(x; \hat{\theta})$

Ikke parametrisk bootstrap:

Generer x_1^*, \dots, x_n^* ved å trukke med tilbakelegging fra x_1, \dots, x_n

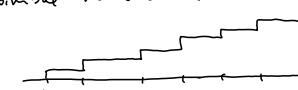
sep 12-12:51

Ikke-parametrisk bootstrap: $P(X^* = x_i) = \frac{1}{n}$

en i trukke fra fordeling $\{x_1, \dots, x_n\}$ (hvis alle u like)

Generelt: Trukk fra empiriske kumulative

$$\hat{F}_n(x) = \frac{k}{n} \# \{x_i \leq x\}$$



funn av $\hat{F}_n(x) \rightarrow F(x) = P(X \leq x)$ $n \rightarrow \infty$

$$\mathbb{E} \hat{F}_n(x) = F(x)$$

$$\text{Var } \hat{F}_n(x) = \frac{1}{n} F(x)(1-F(x))$$

Med boot-t intervall måste vi bare sette $\hat{\theta}$, ikke θ , kan holde med $B = 100$

Men for percentilintervallet ber $B = 1000$ (est. store)

sep 12-12:58

Teoretisk median M er def. ved

$$P(X \leq M) = \frac{1}{2} = P(X \geq M)$$

(når X er kont. fordelt)

$$\text{Median: utvalgt } m = \begin{cases} x_{m+1} & n \text{ er } 2m+1 \\ \frac{x_m + x_{m+1}}{2} & n \text{ er } 2m \end{cases}$$

Han da $\sqrt{n}(m - M) \rightarrow N(0, \frac{1}{4f'(M)^2})$

der X har fordeling $f(x)$

Men $f(x)$ en vanskelig å estimere

og $f'(x)$ enda vanskeligere.

Hvorfor ikke alltid bootstrap?

• Numerisk tungt

• Lite behagelig at vi ikke får samme resultater hver gang - ved gjentatt bootstrap

• For mange problemstillinger fungerer "klarsikke" metoder godt nok.

• Ikke alltid opplyst hvordan man skal bootstrappe, f.eks. med avhengige data. R har imidlertid en automatisk funksjon for bootstrapping: `boot`

Man må altså lage (boot) først.

sep 12-13:26

sep 12-13:49