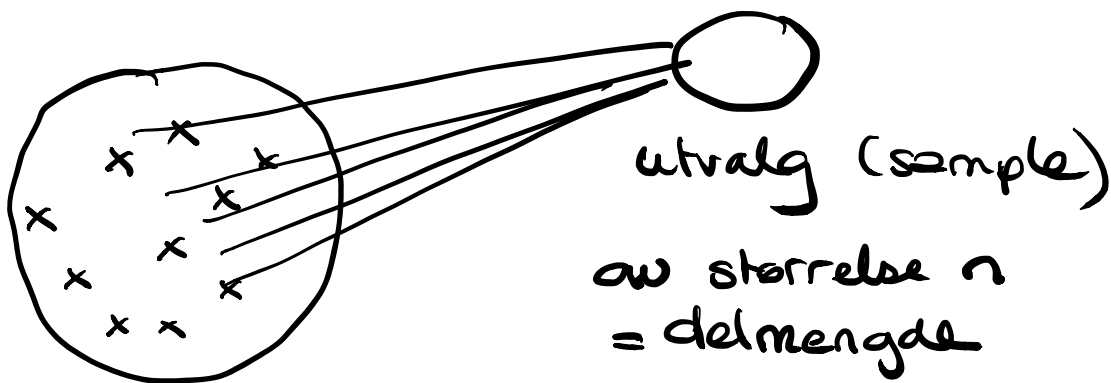


Bok 2:
STATISTISK INFERENS

TMA 4240
FIS, kap 8

Fra populasjon til utvalg [8.1]



populasjon = alle
enheter/individer vi
ønsker å studere

utvalg (sample)
av størrelse n
= delmengde
av populasjonen
↑
bør være representanter
for hele populasjonen

Tilfeldig utvalg (random sample)
= enhetene som trekkes fra populasjonen
velges tilfeldig og uavhengig av hverandre.

Formelt: X_1, X_2, \dots, X_n $\begin{matrix} \text{SV} \\ \downarrow \\ \text{stok. var} \end{matrix}$

med sannsynlighetsfordeling $f(x)$,
trukket tilfeldig.

$$f(x_1, x_2, \dots, x_n) = f(x_1) \cdot f(x_2) \cdot \dots \cdot f(x_n)$$

↑
simultanfordeling

↑
marginalford.

↑
uavhengighet

X_1, X_2, \dots, X_n kalles uavhengige (u)

identisk (i)

fordelte (f)

u. i. f

observasjoner



engelsk i. i. d ← distributed

↑
independent

↑
identically

EKS: $VO_2\text{max}$ data

$n = 1477$ obs av drøygenopptak



IQR = inter quartile range

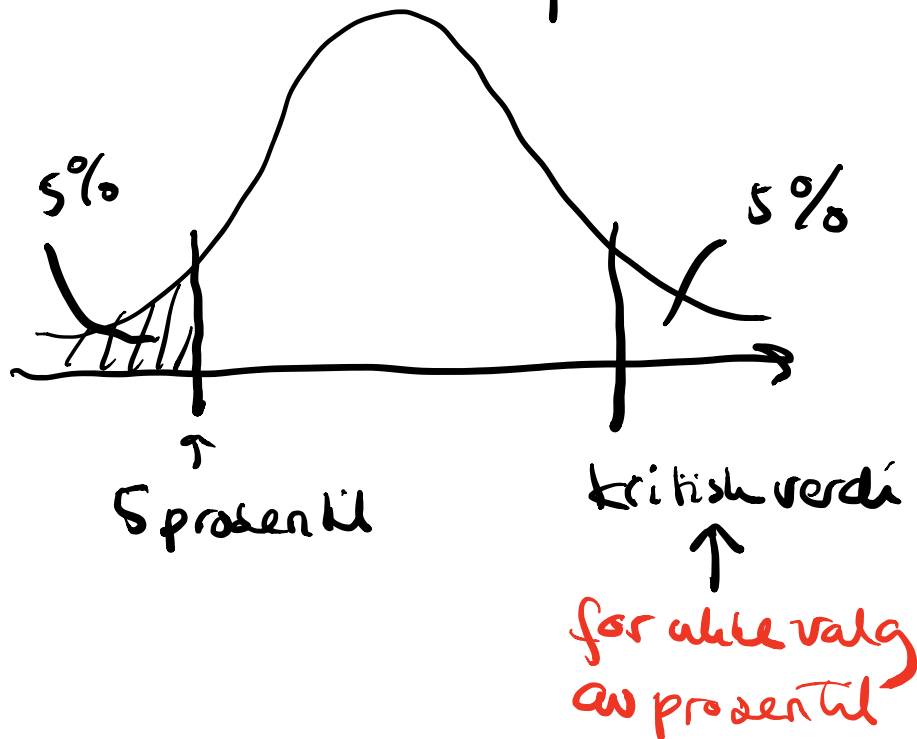
* $> 1.5 \cdot \text{IQR} \Rightarrow$ tegnes enkeltobs

Ordbruk: kvartil, kvantil, persentil
& kritisk verdi

litvalg: sorter og del inn i 4
deler (kvartil)

1. kvartil: 25% data er \leq dette tallet
2. — " — 50% : median
3. — " — 75%
4. — " — 100%

Deler inn i 100 deler \rightarrow persentiler



Kvantil: generelt tall.

Vi trekker et tilfeldig utvalg for å lære om populasjonen

- anslå (estimer) ukjente

parametere i $f(x)$

μ, σ, p, λ

- teste en hypotese

[8.2-8.3]

Observatorer og utvalgsfordelinger

Observator (stochastic ^{eng.}) er en funksjon av SV i et tilfeldig utvalg.
↳ stokastiske variable

Fordelingen til en observator heter en utvalgsfordeling (sampling distribution).

De to viktigste observatorene er

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

utvalgsgjenn

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

utvalgsvarians

↑
biasjon

si noe om

$$\mu = E(\bar{X})$$


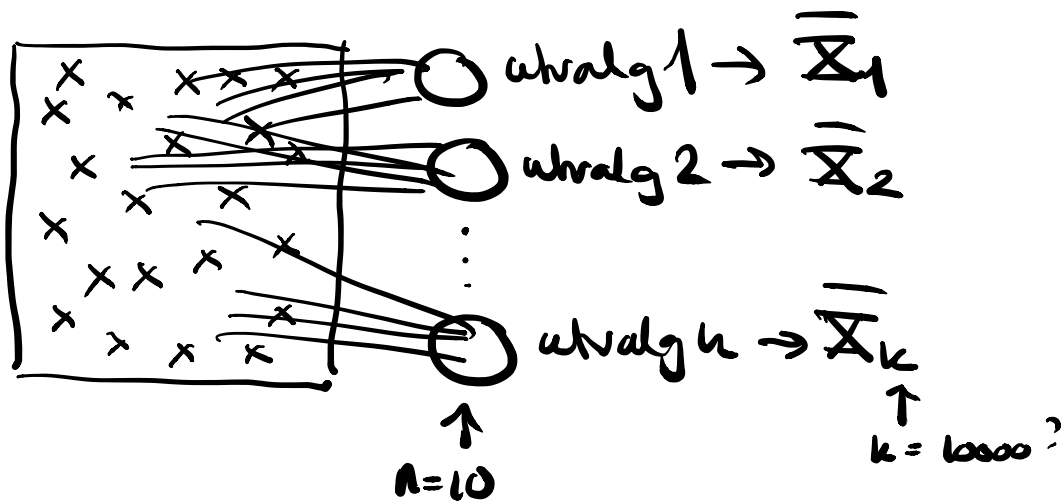
↑
spredning

si noe om

$$\sigma^2 = \text{Var}(\bar{X}) \\ = E[(\bar{X} - \mu)^2]$$

[84]

Fordelingen til utvalgsgjennomsnittet \bar{X}



Obs: \bar{X} er en stokastisk variabel og har derfor en fordeling.

1) X_1, X_2, \dots, X_n u.i.f. f(x)
med $E(X_i) = \mu$ og $\text{Var}(X_i) = \sigma^2$

$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$, finn $E(\bar{X})$ og $\text{Var}(\bar{X})$.

$$\begin{aligned} E(\bar{X}) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \underbrace{E(X_i)}_{\mu} \\ &= \frac{1}{n} \cdot n \cdot \mu = \underline{\underline{\mu}} \end{aligned}$$

$$\begin{aligned} \text{Var}(\bar{X}) &= \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \left(\frac{1}{n}\right)^2 \text{Var}\left(\sum_{i=1}^n X_i\right) \\ &\quad \uparrow \\ &\quad E\left((\bar{X} - \mu)^2\right) \end{aligned}$$


$$\begin{aligned} &= \left(\frac{1}{n}\right)^2 \sum_{i=1}^n \underbrace{\text{Var}(X_i)}_{\sigma^2} = \left(\frac{1}{n}\right)^2 n \cdot \sigma^2 \\ &\quad \uparrow \\ &\quad \text{uafhængig} \end{aligned} = \underline{\underline{\frac{\sigma^2}{n}}}$$

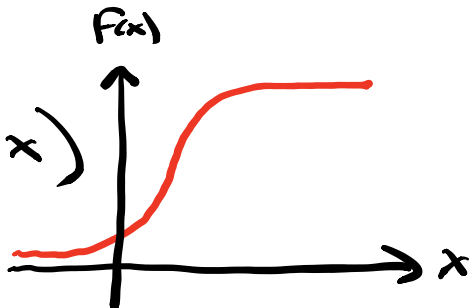
\Rightarrow gjelder uansett hva $f(x)$ er

2) Hvis X_1, X_2, \dots, X_n er u.i.f
normal (μ, σ) $N(\mu, \sigma^2)$
 \uparrow \uparrow
to notasjoner \swarrow varians

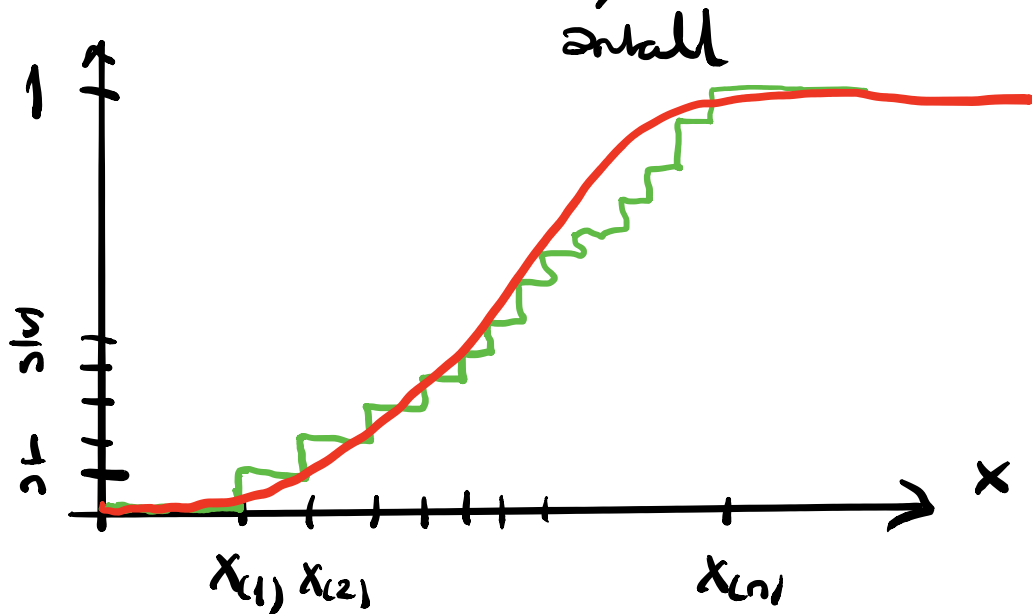
\bar{X} vil også være normal fordelt med
 $E(\bar{X}) = \mu$ og $\text{Var}(\bar{X}) = \frac{\sigma^2}{n}$, $\text{SD}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$.

Hvordan kan vi sjekke at X_1, \dots, X_n
er et tilfeldig utvalg
fra normalfordelingen. [8.8]

a)  $f(x)$

b) $F(x) = P(X \leq x)$  $F(x)$

Empirisk $\hat{F}(x) = \frac{\# X_i \leq x}{n} \xrightarrow{n \rightarrow \infty} F(x)$



Hvis X er $N(\mu, \sigma^2)$ vil

$$\hat{F}(x) \approx \Phi\left(\frac{x-\mu}{\sigma}\right)$$

$$\Phi^{-1}(\hat{F}(x)) \approx \frac{x-\mu}{\sigma}$$

Hvis vi tar invers funksjon ender vi opp med en rett linje hvis data er normal fordelt.

\Rightarrow Matlab normplot

NB: finnes også qq plot som
gjør små modifikasjoner på normalplot.

⇒ fett linje!

3) neste gang → sentralgrenseteoriet.