

③ Statistikk

Del A: Sannsynlighetsteori

Her var modellen og dens parametre kjent, og vi regnet basert på dette.

Ek: Binomisk $\rightarrow$ parameter p
Normalf. $\quad \quad \quad \quad \quad \mu, \sigma$

I Del B: Statistikk er parametrene for modellen typisk ikke kjent. Vi skal:

- i) anslå (estimere) parameterne
- ii) ta stilling til påstander om parameterne

Vi skal også se på enkel lineær regresjon, for å studere sammenhengen mellom to variabler.

Populasjon og utvalg

Populasjon:

Alle individer/objekter vi er interessert i

Utvalg:

En delmengde av populasjonen, som vi innhenter data fra.

Viktige egenskaper:

- tilfeldig utvalg
- stort utvalg



Når utvalget er tilfeldig og stort, kan vi trekke mer presise konklusjoner om hele populasjonen

Tilfeldig:

Alle individ/objekt i populasjonen har samme sannsynlighet for å bli trukket ut

Data-analyse: én variabel

Utvalgstørrelse: n

Variabel: X

⇓

Datasett:

i	x_i
1	x_1
2	x_2
3	x_3
$\vdots$	$\vdots$
n	x_n

gjennomsnitt:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + x_2 + \dots + x_n}{n}$$

(utvalgsgjennomsnitt)

median:

når observasjonene ordnes
i stigende rekkefølge, er
observasjon $(n+1)/2$ om

n er oddetall, og
gjennomsnittet av
observasjon $n/2, n/2+1$
om n er partall

Standard avvik:

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

(utvalgs std. avvik)

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

kalles utvalgs -
kovarians

kvantiler: finnes ved å ordne observasjonene i stigende rekkefølge

øvre kvantil:

observasjon $3/4 \cdot (n+1)$

nedre kvantil:

observasjon $1/4 \cdot (n+1)$

kvantilbredde

øvre kvantil - nedre kvantil

Tolking:

gjennomsnitt / median: sentralverdi

std. avvik / kvantilbredde: spredningsmål

Beregning:

$\bar{x}$, s_x kan finnes ved hjelp av kalkulator

Føles:

7
13
9
12
14

datasett

lesses inn på kalkulator:

① C STAT

tømmer
statistikkminne

②

7 Σ+

13 Σ+

9 Σ+

12 Σ+

14 Σ+

③ Brukes
statistikkfn.

$\bar{x}$ $\rightarrow \bar{x} = 11$

s_x $\rightarrow s_x = 2.915$

median / kvartiler: finnes ved å ordne
observasjonene i stigende rekkefølge
(ikke mulig på kalkulator)


Gratisk fra stilling:

- histogram
 - bokseplott
- } bør vite hvordan man lager disse


Histogram:

Frekvenstabell

	antall	frekvens
10-20	1	$\frac{1}{8}$
20-30	3	$\frac{3}{8}$
30-40	2	$\frac{2}{8}$
40-50	2	$\frac{2}{8}$
	<u>8</u>	



Bokseplott:



Trækning fra en fordeling

Når vi skal bruge teori for å si noe populasjonen ("alle") basert på et datasett fra et utvalg (noen "få" som er trukket ut), tenker vi ofte slik:

- i) Vi velger en modell for variabelen vi ser på, for eksempel at X er binomisk fordelt eller normalfordelt med ukjente parametre.
- ii) Dessan ~~utvalgsstørrelsen~~ ~~er~~ n , tenker vi at $X_1, X_2, \dots, X_n$ er stokastiske variabler som følger samme fordeling som X . Om $X \sim N(\mu, \sigma)$ er normalfordelt, sier vi at $X_1, \dots, X_n$ er trukket fra en normalfordeling med forventning μ og std. avvik σ .

iii) Vi skriver $x_1, x_2, \dots, x_n$ for tallverdiene i datasettet (merk: små bokstaver) og kaller det de observerte verdier. Vi tenker at x_i er en av de mulige verdier X_i kan ha (med sannsynligheter som følger fra fordelingen).

iv) Dersom utvalget er tilfeldig, sier vi at $X_1, \dots, X_n$ er uavhengige trekninger fra fordelingen til X . De er de stokastiske variablene $X_1, \dots, X_n$ uavhengige.

Estimatorer: stokastisk variabel
som bruges til at
estimere en
parameter

Navn: estimator for en parameter
 θ kaldes $\hat{\theta}$, men noen
estimatorer har egne navn

μ : Parameteren μ har
$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

som estimator. Det er uanset
at skrive $\bar{X}$, eller $\hat{\mu}$.

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

som estimator. Det er uanset
at skrive S^2 , eller $\hat{\sigma}^2$.

P: Parametren p har

$$\hat{p} = \frac{X}{n}$$

Som estimator når X er
binomisk med parametre (n, p) .

Krav til estimatører:

i) Forventingsrett: $E(\hat{\theta}) = \theta$

ii) $\text{Var}(\hat{\theta})$ minst mulig

iii) $\text{Var}(\hat{\theta}) \rightarrow 0$ når $n \rightarrow \infty$

Dette er oppfylt for $\bar{X}$, S^2 , $\hat{p}$.

Noen viktige formler:

Når $x_1, \dots, x_n$ er uavhengige trekkninger
fra $N(\mu, \sigma)$, så har vi:

$$E(\bar{X}) = \mu, \quad \text{Var}(\bar{X}) = \sigma^2/n$$

Hvis X er binomisk fordelt med parametre (n, p) , så er

$$E(\hat{p}) = p, \quad \text{Var}(\hat{p}) = \frac{pq}{n}$$

med $\hat{p} = x/n$ ($q = 1 - p$).

Standard feil:

Standardfeilen til en estimator er standardavviket til estimatoren

$$SE(\hat{\theta}) = \sqrt{\text{Var}(\hat{\theta})}$$

Punktestimat for en parameter

Når vi setter inn observerte verdier fra et utvalg i en estimator for θ , får vi et punkt-estimat for θ

$$\mu: \bar{x}$$

$$\sigma^2: s^2$$

$$p: x/n$$

Konfidensintervall:

Et konfidensintervall for parameteren θ på signifikansnivå α er et intervall $[A, B]$, med stokastiske grenser A og B , slik at

$$p(A \leq \theta \leq B) = 1 - \alpha$$

Det kalles gjerne et $(1 - \alpha) \cdot 100\%$ konfidensintervall for parameteren θ .

Eksp: $\alpha = 0.05 \iff 95\%$ konfidensintervall

$$p(A \leq \theta \leq B) = 95\%$$

i) Konfidensintervall for μ , σ kjent:

Anta: $\left\{ \begin{array}{l} x_1, \dots, x_n \text{ uavhengige, identisk} \\ \text{fordelte med } E(x_i) = \mu \text{ og} \\ \text{Var}(x_i) = \sigma^2 \text{ med } \underline{\sigma \text{ kjent}} \end{array} \right.$
og

$\bar{X}$ tilnærmet normalfordelt

(x_i normalfordelt eller $n \geq 30$)
for hver i

Konfidensintervall:

$$\bar{X} \pm Z_{\alpha/2} \cdot \underbrace{\sigma/\sqrt{n}}_{\substack{\uparrow \\ SE(\bar{X}) \\ \text{std feil} \\ \text{til estimator} \\ \bar{X}}}, \text{ der } \left\{ \begin{array}{l} A = \bar{X} - Z_{\alpha/2} \cdot \sigma/\sqrt{n} \\ B = \bar{X} + Z_{\alpha/2} \cdot \sigma/\sqrt{n} \end{array} \right.$$

$\uparrow$
punkt-
estimat
for μ

"Z-intervall for μ "

ii) Konfidensintervall for μ , σ ukjent

Anta: $X_1, \dots, X_n$ uavhengige normalfordelte
med $E(X_i) = \mu$ og $\text{Var}(X_i) = \sigma^2$

Konfidensintervall:

$$\bar{x} \pm t_{\alpha/2}^{n-1} \cdot s/\sqrt{n}, \text{ dvs}$$

$$\begin{cases} A = \bar{x} - t_{\alpha/2}^{n-1} \cdot s/\sqrt{n} \\ B = \bar{x} + t_{\alpha/2}^{n-1} \cdot s/\sqrt{n} \end{cases}$$

↑
punkt-
estimat
for μ

↑
estimat
for std. feil
t.o.l $\bar{x}$

" T-intervall for μ "

iii) Konfidensintervall for σ^2

Anta: $X_1, \dots, X_n$ uavhengige normalfordelte med $E(X_i) = \mu$ og $\text{Var}(X_i) = \sigma^2$

Kritiske verdier:

La Y være χ^2_{n-1} -fordelt ($n-1$ df.).

Vi skriver χ^2_α for den kritiske verdien definert ved

$$P(Y > \chi^2_\alpha) = \alpha$$

for enhver α .

Merk: Vi kan ikke finne χ^2_α med kalkulator, må bruke tabell. (Tabell E6 i boken)

Konfidensintervall:

$$\left[S^2 \cdot (n-1) / \chi^2_{\alpha/2}, S^2 \cdot (n-1) / \chi^2_{1-\alpha/2} \right]$$

Merk: χ^2_{n-1} -fordelingen er ikke symmetrisk.

iv) Konfidensintervall for p

Anta: $\{ X \text{ binomisk fordelt med parameter } (n, p) \}$

og

$\{ n \text{ ster slikt at } X \text{ er tilnærmet normalfordelt} \}$

Konfidensintervall:

$$\hat{p} \pm z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}, \text{ dvs } \begin{cases} A = \hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \\ B = \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \end{cases}$$

↑
punkt-
estimat

$$\hat{p} = x/n$$

for p

↑
estimat
for std. feilen
til $\hat{p}$

Hvor stor må n være?

$$n \hat{p} \hat{q} = n \hat{p} (1 - \hat{p}) \geq 5$$

Hypotese test : Vi tar stilling til en påstand om en parameter θ .

Sted oppsett:

i) Velg modell og hypoteser

H_0 : nullhypotese

H_1 : alternativ hypotese

Vi velger $H_1 = \text{det vi ønsker å vise}$, og $H_0 = \text{komplementet til } H_1$

ii) Velg testobservator og fører på forkastningsområde (nøyresidig, venstresidig, tosidig)

iii) Velg signifikansnivå α = akseptert sannsynlighet for type I-feil.

iv) Finn kritisk verdi og bestem forkastningsområde = verdier for testobservator som gjør at vi forkaster H_0

v) Samle inn data, regne ut testobservator og ta stilling til påstandene.

To mulige
utfall:

Vi forkaster H_0
("H₁ sann")

Vi beholder H_0
("H₀ sann")

	H_0 sann	H_1 sann ← objektiv sannhet
Behold H_0	✓	Type II feil
Forkast H_0	Type I feil	✓

↑
Beslutning

Type I feil: "uskyldig dømt"
Type II feil: "skyldig går fri"


i) Hypotesetest for μ

Anta: $x_1, \dots, x_n$ uafhængige normalfordelte med $E(x_i) = \mu$, $\text{Var}(x_i) = \sigma^2$

Tre typer:

a)
$$\begin{aligned} H_0: \mu &\leq \mu_0 \\ H_1: \mu &> \mu_0 \end{aligned}$$

højresidig




b)
$$\begin{aligned} H_0: \mu &\geq \mu_0 \\ H_1: \mu &< \mu_0 \end{aligned}$$

venstresidig



c)
$$\begin{aligned} H_0: \mu &= \mu_0 \\ H_1: \mu &\neq \mu_0 \end{aligned}$$

toesidig



Testobservator:

$$T = \frac{\bar{x} - \mu_0}{S/\sqrt{n}}$$

(σ ukjent)

T-fordelt
n/2-1 df.
når $\mu = \mu_0$
"T-test"

$$\text{eller } Z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$$

(σ kjent)

std.
normal-
fordelt

"Z-test"

Forkastningsområde:

a) <u>Høyresidig</u>	b) <u>Venstresidig</u>	c) <u>Tv-sidig</u>
$T > t_{\alpha}$	$T < -t_{\alpha}$	$ T > t_{\alpha/2}$
eller	eller	eller
$Z > Z_{\alpha}$	$Z < -Z_{\alpha}$	$ Z > Z_{\alpha/2}$
(kritiske t-verdier her $n-1$ df.)		

Alternativer:

- Bruk $\bar{X}$ istedet for T/Z som testobservator (skriv om forkastningsområdet)
- Bruk p-verdi:

Regn ut p-verdi og sammenlikn med signifikansnivå α istedet for å finne forkastningsområde

p-verdi: sannsynlighet for en minst like ekstrem verdi for testobservator som den vi finner

Vi forkaster H_0 om $p < \alpha$
Vi beholder H_0 om $p \geq \alpha$

Styrkefunksjon og type II-feil:

Styrkefunksjon:

$$\gamma(\mu) = p(\text{forkaster } H_0 \mid \mu)$$

Sannsynlighet for type II-feil for
hver gitt verdi (sann verdi) av μ .

ii) Hypotestet for p = populasjonsandel

Anta: $\left\{ \begin{array}{l} X \text{ binomisk fordelt med} \\ \text{parametre } (n, p) \end{array} \right.$

og
 $\left\{ \begin{array}{l} n \text{ stor slik at } X \text{ er} \\ \text{tilnærmet normalfordelt } (n\hat{p}(1-\hat{p}) \geq 5) \end{array} \right.$

Merk: vi må ikke forveksle p her
(parameter for binomisk ford.)
med p -verdi

Testobservator:
$$Z = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \quad \left(\hat{p} = \frac{X}{n} \right)$$

Hypotese:

a) $H_1: p > p_0$ b) $p < p_0$ c) $p \neq p_0$

Forkastingsområde:

a) $Z > Z_{\alpha}$ b) $Z < -Z_{\alpha}$ c) $|Z| > Z_{\alpha/2}$