


Uke 1:

n observasjonspaar $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$



$$y = a + bx$$

finnes ved å minimere
kvadratavvik

↳ veldig generelt
verktøy

Uke 9: y -ene er stokastiske!

n gitte/fikserte verdier av x :

$x_1, x_2, \dots, x_n$


$\downarrow$
 y_1

$\downarrow$
 y_2

$\downarrow$
 y_n

n stokastiske variabler

} Dvs. dersom vi gjentok
forsøket igjen med
samme verdier av x ,
ville vi fått ulike verdier
av y -ene.



$$\beta_0 + \beta_1 x$$

spredning rundt
forventningsverdi
som følge av

en normalfordeling
med standardavvik 1

Modell:

$$\textcircled{1} Y|x \sim N(\underbrace{\beta_0 + \beta_1 x}_{\mu}, \underbrace{\sigma}_{\sigma})$$

$$\textcircled{2} Y = \underbrace{\beta_0 + \beta_1 x}_{\text{konstantled (E(Y))}} + \varepsilon \quad \varepsilon \sim N(0, \sigma)$$

↑ støjled
(Var(Y))

NB : 3 parametre !

β_0, β_1, σ

} som i de to forrige
hene snakker vi da
om estimator og
estimatorer,
konfidensintervaller
og hypotesetester.

EKS I

Modell

$$Y = \beta_0 + \beta_1 x + \varepsilon$$

$$\varepsilon \sim N(0, \sigma)$$

↑
vekt
av
twist

↑
antall bokstaver

↑
støy ledd

↑ fordi vi vet
at f.eks. to twist
av samme type
kan ha ulik vekt.

↑
er $\beta_1 \neq 0$?

Minste kvadratsum:

$$y = 5.42 + 0.17x$$

FIGUR

Eks: $x = 5$ (banan)

$$y = 6.27 \text{ gram}$$

$x = 15$ (chocolate toffee)

$$y = 7.97 \text{ gram}$$

Så har
jeg 'bevis'
for påstanden
min?

(Enkle) linear regression

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad \varepsilon_i \sim N(0, \sigma)$$

$\uparrow$ Stokastisk $*$ $\uparrow$ gitt/bestemt

$i = 1, \dots, n$
uavhengige
støvel

* 3 uljente parametre

[FORMELARK]

Estimatorer for β_1, β_0 og σ^2 :

$$\hat{\beta}_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

$$s^2 = \frac{1}{n-2} \sum (y_i - \hat{y}_i)^2$$

* Forventningsbreite
for
 β_1, β_0 og σ^2

Estimator basert på vårt utvalg


$$\hat{\beta}_1 = 0.17 \text{ g} \quad \hat{\beta}_0 = 5.42 \text{ g}$$

lite
stigning

$$s^2 = 1.35 \text{ g}^2$$

$$s = 1.16 \text{ g}$$

stor
spredning



[FORMELARK]

$$H_0: \beta_1 = 0 \quad H_1: \beta_1 \neq 0$$

$$\alpha = 0.05$$


$$T = \frac{\hat{\beta}_1 - 0}{SE(\hat{\beta}_1)} \sim t_{n-2}$$

nb! $n-2$ enkel lin. reg.

H_0 sann

$$SE(\hat{\beta}_1) = \frac{S}{\sqrt{\sum (x_i - \bar{x})^2}}$$

$$S = \sqrt{\frac{1}{n-2} \sum (y_i - \hat{y}_i)^2}$$



Forkast dersom $t_{obs} > 2.101$ eller $t_{obs} < -2.101$

↑ Denne testen utføres
'automatisk' når vi tilpasser
regresjonslinje med Python
(og R, excel osv.)

Python, modell-sammendrag

Finn

1) Est. β_0 og β_1

$$\hat{\beta}_0 = 5.42 \quad \hat{\beta}_1 = 0.17$$

2) Standardfeil til estimatorene

$$SE(\hat{\beta}_0) = 0.622$$

$$SE(\hat{\beta}_1) = 0.071$$

3) t-test for β_1

$$t_{obs} = 2.36$$

← fra $\frac{0.17}{0.071}$

husk  Forhast til siden
 $t_{obs} > 2.101$. (ent p-verdi < 0.05)

4) 95% KI for β_1 $[0.018, 0.317]$

inneholder ikke 0,
kan dermed ikke fastslå at
 $\beta_1 \neq 0$.


NB: Linja for 'intercept' gjelder β_0 ,
og selv om vi ikke har formel for
denne på formelarket må
dere likevel kunne bruke disse
resultatene.

Plott, plott, plott.

Residualer: $\hat{\epsilon}_i = y_i - \hat{y}_i$

Ser ok ut for
bokstaver < 10,
litt rart
etter dette...

↑
bør oppføre seg normalfordelte
rundt 0, og f.eks samme
variasjon uansett x-verdi.



← dersom utvalget mitt på 20 ikke inneholder disse vilke ligna seg helt annerledes ut.

Konklusjon:

En slags trend, men dataene ser ut til å bryte med ~~for~~ antagelsene i linear regresjon, og skal derfor være forsiktige med å tro på hypotesetest på β -

Samvariasjon eller kausalitet?

Ek8 2: π (linear?)

$$V = \frac{4}{3} \pi r^3$$

↑ hva er π ?! ..

- har målinger av radius
- har usikre målinger av volum

Regresjonsmodell


$$V = \beta_0 + \beta_1 r^3 + \varepsilon \quad \varepsilon \sim N(0, \sigma)$$

↑
bor være 0

↖ $\frac{4}{3}\pi$

↖ ser ikke så veldig linear ut?

NB: modellen er ikke-lineær
mtp radius,
men linear i β -ene!



Modell-sammendrag

- Finn estimert regresjonslinje

$$\hat{V} = -0.42 + 4.19 r^3$$

- Er skjæringspunktet β_0 signifikant forskjellig fra 0? ($\alpha = 0.05$)

Nei $p\text{-verdi} = 0.790 > 0.05$

45% KI $[-4.287, 3.443]$

- Hva blir estimatet vårt for π ?

$$V = \frac{4}{3}\pi r^3$$

$$\hat{\beta}_1 = 4.19 = \frac{4}{3} \hat{\pi}$$

$$\hat{\pi} \stackrel{\downarrow}{=} 4.19 / 4/3 = 3.1425$$

↗ m
ok.

Merk : også vanlig
å bruke felles

log-transformasjon
for å skape lineære
sammenhenger.