

Forelesning 14

MET1190

Plan:

- ① Lineær regresjon
- ② Statistiske egenskaper

Repetisjon:

Forelesning 12-13: Hypotesetester

$$\begin{cases} H_0: \text{komplementet til } H_1 \\ H_1: \text{det som skal "vises"} \end{cases}$$

Metoder:

- finne forkastningsområde $t=1$
testobservater (basert på α)
 $\Rightarrow$ Forkaste H_0 hvis testobservatøren
faller i forkast.omr.
Behold H_0 ellers

- bruke p-verdi

p = sannsynlighet for å få en
uønsket eller ekstrem verdi
på testobs. som den realiserte

Forkaste H_0 : $p < \alpha$
 Behold H_0 : ellers

① Linear regresjon


X : forklaringsvariabel (kontrollert)
 Y : responsvariabel (stokastisk)

Ek: Boligpriser

X : ant. kvm.

y : pris (mill. kr.)

x	y	$\hat{y}$
109	9.5	
181	15.9	
112	9.39	
102	8.75	
158	11.5	



Multipl
linear regr.
 $\rightarrow$ mer enn én
 forklingsvar.

Modell: $Y = \alpha + \beta X + \varepsilon$

α, β : parameter med ulikt verdi
 (α : skj. med y -aksen, β : stign.tall)

ε : feil-ledd, tilfeldig variasjon

Antagelser:


X : gitt verdi

ε : normalfordelt $N(0, \sigma^2)$

(σ ukjent parameter)

$$Y = \underbrace{\alpha + \beta X}_{\text{regr. linje } \hat{y}} + \varepsilon$$

regr.
linje $\hat{y}$



Y : normalfordelt $N(\hat{y}, \sigma^2)$

$$y = \alpha + \beta x$$

Tilpassing:

i	x_i	y_i
1	x_1	y_1
2	x_2	y_2
$\vdots$	$\vdots$	$\vdots$
n	x_n	y_n

data sett

$$Y_1 = \alpha + \beta x_1 + \varepsilon_1$$

$$Y_2 = \alpha + \beta x_2 + \varepsilon_2$$

$$Y_n = \alpha + \beta x_n + \varepsilon_n$$

Musk: α, β ukjente

Minste kvadraters
metode:

Velg α, β slik at
 $\varepsilon_1^2 + \varepsilon_2^2 + \dots + \varepsilon_n^2$
er minst mulig.

Husk: α, β er de ubjorte (vareldene)

$$\varepsilon_1 = y_1 - (\alpha + \beta x_1)$$

$$\varepsilon_2 = y_2 - (\alpha + \beta x_2)$$

$\vdots$

$$\varepsilon_n = y_n - (\alpha + \beta x_n)$$

$$\varepsilon_1^2 + \varepsilon_2^2 + \dots + \varepsilon_n^2 = [y_1 - (\alpha + \beta x_1)]^2 + \dots + [y_n - (\alpha + \beta x_n)]^2$$

$$= y_1^2 - 2y_1 \cdot (\alpha + \beta x_1) + (\alpha + \beta x_1)^2 + \dots$$

$$\dots + y_n^2 - 2y_n (\alpha + \beta x_n) + (\alpha + \beta x_n)^2$$

$$= \underbrace{y_1^2} - \underbrace{2y_1\alpha} - \underbrace{2x_1y_1\beta} + \underbrace{\alpha^2} + \underbrace{2\alpha\beta x_1} + \underbrace{\beta^2 x_1^2} + \dots$$

$$\begin{aligned} f(\alpha, \beta) &= n\alpha^2 + 2\alpha\beta(x_1 + x_2 + \dots + x_n) + \beta^2(x_1^2 + x_2^2 + \dots + x_n^2) \\ &\quad - 2\alpha(y_1 + y_2 + \dots + y_n) - 2\beta(x_1y_1 + x_2y_2 + \dots + x_ny_n) \\ &\quad + (y_1^2 + y_2^2 + \dots + y_n^2) \end{aligned}$$

Mål: - Setter inn $(x_1, y_1), \dots, (x_n, y_n)$ fra datasettet

- løser minimumsproblem

$$\min f(\alpha, \beta)$$

$$\text{Set } f(\alpha, \beta) = \varepsilon_1^2 + \dots + \varepsilon_n^2 = \sum_{i=1}^n (y_i - (\alpha + \beta x_i))^2$$

$$= \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$$

U: least squares problem: $\min f(\alpha, \beta)$

$$f'_\alpha = \sum_{i=1}^n 2 \cdot (y_i - \alpha - \beta x_i) \cdot (-1)$$

$$= -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) = 0 \quad | : (-2)$$

$$\sum y_i = \sum (\alpha + \beta x_i) = n \cdot \alpha + (\sum x_i) \beta$$

$$n \bar{y} = n \alpha + n \bar{x} \beta \quad | : n$$

$$\bar{y} = \alpha + \bar{x} \beta \Rightarrow \alpha = \bar{y} - \beta \bar{x}$$

$$f'_\beta = \sum_{i=1}^n 2 (y_i - \alpha - \beta x_i) \cdot (-x_i)$$

$$= -2 \sum (x_i y_i - \alpha x_i - \beta x_i^2) = 0 \quad | : (-2)$$

$$\sum x_i y_i = \alpha \sum x_i + \beta \sum x_i^2$$

$$= (\bar{y} - \beta \bar{x}) \cdot \sum x_i + \beta \sum x_i^2$$

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

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

$$\beta = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2} = \frac{(n-1) s_{xy}}{(n-1) s_x^2} = \frac{s_{xy}}{s_x^2}$$

$$\beta = \frac{s_{xy}}{s_x^2} = \frac{s_{xy}}{s_x \cdot s_y} \cdot \frac{s_y}{s_x} = r \frac{s_y}{s_x}$$

$$\beta = r \cdot \frac{s_y}{s_x}$$

Oppsummering:

$$\begin{aligned} f'_{\alpha} &= 0 \\ f'_{\beta} &= 0 \end{aligned}$$

gir

$$\begin{aligned} \alpha^* &= \bar{y} - \beta \bar{x} \\ \beta^* &= r \cdot s_y / s_x \end{aligned}$$

das
Störterm
plot

Klasschering:

$$H(t) : f''_{\alpha\alpha} = \sum_{i=1}^n 2 \cdot (-1) \cdot (-1) = \underline{2n}$$

$$f''_{\alpha\beta} = \sum_{i=1}^n 2 \cdot (-1) \cdot (-x_i) = 2 \sum x_i = \underline{2n\bar{x}}$$

$$f''_{\beta\beta} = \sum_{i=1}^n \left[2 \cdot (-x_i) \cdot (y_i - \alpha - \beta x_i) \right]_{\beta}$$

$$= \sum -2x_i (-x_i) = \underline{2 \sum_{i=1}^n x_i^2}$$

$$\det H(t) = (2n) (2 \sum x_i^2) - (2n\bar{x})^2$$

$$= 4n \sum x_i^2 - 4n^2 \bar{x}^2$$

$$= 4n (\sum x_i^2 - n\bar{x}^2) = 4n \cdot (n-1) s_x^2 \geq 0$$

Siden $f(\alpha, \beta)$ er kvadratisk uttrykk
med $\det H(\alpha) = 4n(n-1) s_x^2 \geq 0$
og $\text{tr } H(\alpha) = 2n + 2 \sum x_i^2 > 0$

så er det stasjonære pkt.

$$\begin{cases} \alpha^* = \bar{y} - \beta^* \bar{x} \\ \beta^* = r \cdot \frac{s_y}{s_x} \end{cases}$$

et minimum for $f(\alpha, \beta)$.

Dette pktet gir derfor den
rette linjen $y = \alpha + \beta x$ som passer
best til datasettet.

Hovedtrekk:

i) Finn størstørre pkt.: (α^*, β^*) $\begin{cases} f'_\alpha = 0 \\ f'_\beta = 0 \end{cases}$

ii) Klassifisere størstørre pkt.

$$H(f)(\alpha^*, \beta^*)$$

Resultat: et størstørre pkt.,
lokal og globalt min.

Kan vise mellomregningene på notene
eller forelesnings Resultat:

$$\beta^* = \frac{S_{xy}}{S_x^2}$$

$$\alpha^* = \bar{y} - \beta^* \bar{x}$$

Konklusjon:

Regressionslinjen er gitt ved $y = \hat{\alpha} + \hat{\beta}x$
der

$$\hat{\beta} = \frac{S_{xy}}{S_x^2} = r \cdot \frac{S_y}{S_x}$$

$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}$$

$\hat{\alpha}, \hat{\beta}$: estimatører for α, β

Beregning av $\hat{\alpha}$, $\hat{\beta}$:

x	y
109	9.5
181	15.9
112	9.39
102	8.75
158	11.5

$$\hat{\beta} = r \cdot \frac{s_y}{s_x}$$

$$\hat{\alpha} = \bar{y} - \hat{\beta} \cdot \bar{x}$$

C STAT

109 INPUT 9.5 Σ+

⋮

158 INPUT 11.5 Σ+

x (første): forkl. var.
y (andre): respons var.

En kvadratmeter
extra øker prisen
med 79.000 kr. →

0 kvm gir
pris 555.000 kr →

$\hat{r}$ Swap 0.946 = r

s_x 38.0 = s_x

s_x, s_y SWAP 2.92 = s_y

$\bar{x}$ 132.4 = $\bar{x}$

$\bar{x}, \bar{y}$ SWAP 11 = $\bar{y}$

$\hat{\alpha}, \hat{\beta}$ direkte:

$\hat{\beta}$: $\hat{y}_{im}$ SWAP

$\hat{\beta} = 0.079$

$\hat{\alpha}$: $\bar{x}wib$ SWAP

$\hat{\alpha} = 0.555$

Estimat for regresjonslinjen:

$$y = 0.555 + 0.079x$$

Prediksjoner:

$$y = 0.555 + 0.079x$$

$x = 82$:


$$\hat{y} = 0.555 + 0.079 \cdot 82$$

(82 km)

Kalk: $82 \boxed{\hat{y}, m} \rightarrow 7.029 = \hat{y}$

$$y \sim N(\hat{y}, \sigma^2)$$

$x = 82$: $y \sim N(7.029, \sigma^2)$



Husk:

Anter at $\epsilon \sim N(0, \sigma^2)$

Anter at vi har et tilfeldig utvalg
slik at $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ er uavhengige

② Statistiske egenskaper

Resultat:
$$\left. \begin{aligned} E(\hat{\alpha}) &= \alpha \\ E(\hat{\beta}) &= \beta \end{aligned} \right\} \text{forventningsrette} \\ \text{estimatorer}$$

$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x} \quad \hat{\beta} = r \cdot \frac{s_y}{s_x}$$

Resultat:

$$\text{Var}(\hat{\alpha}) = \frac{\sigma^2 \cdot \sum_{i=1}^n x_i^2}{n \cdot (\sum_{i=1}^n x_i^2 - n \bar{x}^2)}$$
$$\text{Var}(\hat{\beta}) = \frac{\sigma^2}{\sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2}$$

$\sigma^2 = \text{Var}(\varepsilon)$

$$\left. \begin{aligned} SE(\hat{\alpha}) &= \sqrt{\text{Var}(\hat{\alpha})} \\ SE(\hat{\beta}) &= \sqrt{\text{Var}(\hat{\beta})} \end{aligned} \right\} \begin{array}{l} \text{std. feil} \\ \text{std. avvik} \end{array}$$

Praktisk bruk: Må estimere σ^2 ved å bruke S^2

$$S^2 = \frac{1}{n-2} \sum_{i=1}^n \varepsilon_i^2 = \frac{SS_E}{n-2}$$
$$SS_E = \sum_{i=1}^n \varepsilon_i^2 = \varepsilon_1^2 + \varepsilon_2^2 + \dots + \varepsilon_n^2$$

Exs. Hypo-test for β

$\left(\begin{array}{l} X: \text{ Erklärungsvariable} \\ Y: \text{ Responsvariable} \end{array} \right)$

$H_0: \beta = 0 \stackrel{\beta \neq 0}{=} \leftarrow$ ingen sammenheng
 mellom X og Y
 $H_1: \beta \neq 0 \leftarrow$ det fins en sammenheng
 mellom X og Y

eller

$H_0: \rho \leq 0 \stackrel{!}{=} \rho_0$ $\leftarrow$ neg. oder neg. Zusammenhang
 $H_1: \rho > 0$ $\leftarrow$ pos. Zusammenhang


test observer: T eller β

$$T = \frac{\hat{\beta} - \beta_0}{SE(\hat{\beta})} = \frac{\hat{\beta}}{SE(\hat{\beta})}$$

- kan regne ut $\hat{\beta} = r \cdot \frac{S_y}{S_x}$ fra datasettet
- må estimere $SE(\hat{\beta})$ for å finne T.

Tokening av R^2 :

Oppdeling av
avvik:



$$y_i - \bar{y} = (\hat{y}_i - \bar{y}) + (y_i - \hat{y}_i)$$

totalt
avvik

avvik
forklart
av
regresjonen

feilledd
 ϵ_i

Man kan vise:

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

SS_T SS_R SS_E

$$\epsilon_1^2 + \dots + \epsilon_n^2$$

$$s_y^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (y_i - \bar{y})^2$$

$$= \frac{1}{n-1} \cdot SS_T$$

$$\boxed{SS_T = (n-1) s_y^2}$$

↑
kan finne
dette på
kalkulator

$$SS_T = SS_R + SS_E$$

⇐

$$\boxed{SS_E = SS_T - SS_R}$$

↑
onsker
å regne
ut

Man kan vise:

$$r^2 = \frac{SS_R}{SS_T}$$

$$SS_R = r^2 \cdot SS_T$$

Tolkning:

R^2 er andelen
af total
varians forklaret
af regressions-
modellen

Vi kombinerer disse formlene:

$$\begin{aligned} SS_E &= SS_T - SS_R \\ &= SS_T - r^2 \cdot SS_T \\ &= SS_T (1 - r^2) \end{aligned}$$

$$SS_E = (n-1) s_y^2 \cdot (1 - r^2) = \varepsilon_1^2 + \varepsilon_2^2 + \dots + \varepsilon_n^2$$

Bruger dette slik:

$$\begin{aligned} \sigma^2 \text{ estimeres af } s^2 &= \frac{1}{n-2} \cdot SS_E \\ &= \frac{1}{n-2} \cdot (n-1) s_y^2 \cdot (1 - r^2) \end{aligned}$$

$$s^2 = \frac{n-1}{n-2} s_y^2 (1 - r^2)$$

$$\underbrace{\frac{1}{n-1} SS_T}_{S_y^2} = \underbrace{\frac{1}{n-1} SS_R}_{\text{den delen av}} + \underbrace{\frac{1}{n-1} SS_E}_{\text{den delen av}}$$

variansen
(total varians)
i y

den delen av
av total
varians
forklart
av modellen
(regr. linjen)

den delen av
variansen som
ikke er forklart
av modellen.