

## TEMA 2: Enkel regresjon

- ① Overblikk
- ② De klassiske forutsetningene
- ③ Regresjonslinja
- ④ Ordinær minste kvadraters metode
- ⑤ Usikkerhet og modellpresisjon
- ⑥ Hvorfor OLS?

## ① Øarblikk

Den multiple lineare regresjonsmodellen

$$\rightarrow Y = \beta_1 + \beta_2 X_1 + \dots + \beta_k X_k + u$$

Den enkle lineare regresjonsmodellen

$$\rightarrow Y = \beta_1 + \beta_2 X + u$$

↑  
variabelen  
vi ønsker å  
forklare

"forklaring"

uforklart  
variasjon  
i Y

→ Ikke-linearitet i variabel:

$$Y = \beta_1 + \beta_2 (X^2) + u$$

$$Y = \beta_1 + \beta_2 \left(\frac{1}{X}\right) + u$$

$$Y = \beta_1 + \beta_2 (\ln X) + u$$

→ Ikke-linearitet i parameter  $B_2$ :

$$Y = B_1 + B_2^2 X + u$$

$$Y = B_1 + e^{B_2} X + u$$

$$= B_1 + 2,714^{B_2} X + u$$

② De klassiske regresjonsforutsetningene:

KF1: Linearitet i både parametre og variabler:

$$Y_i = B_1 + B_2 X_i + u_i$$

KF2:  $Cov(X_i, u_i) = 0$ . Forklæringsvariabel  $X_i$  og feilleddet skal være ukorrelerte. Tolkning:  $X_i$  skal forklare feilene i stedet for å redusere den.

$$KF3: E(u_i | X_i) = 0 \quad (\Rightarrow E(u_i) = 0)$$

Tolkning: I gjennomsnitt skal forklaringsfeilene være like null.

kap. 9

KF4:  $\text{Var}(u_i) = \sigma^2$  for alle  $i$ . *Tolkning:*  
 Presisjonen til forklaringen vår  
 er konstant (avhenger ikke av  
 enhetene;  $i$ 'ene)

kap. 10

KF5:  $\text{Cov}(u_i, u_j) = 0$  (feilbeddene er  
 ukorrelerte).

### (3) Regresjonslinja

$$\rightarrow Y_i = \underbrace{B_1 + B_2 X_i}_{\text{forklaringen}} + u_i \quad (\text{populasjon})$$

$$\rightarrow Y_i = \underbrace{b_1 + b_2 X_i}_{\text{utvalg}} + e_i \quad (\text{utvalg})$$

$E(Y_i | X_i) = B_1 + B_2 X_i$  : Populasjons-  
 regresjonsfunksjonen (Population  
 Regression Function, PRF)


$\hat{Y}_i = b_1 + b_2 X_i$  : Utvalgsregresjonsfunksjonen, (Sample Regression Function, SRF)

→  $b_1, b_2$  er estimater av  $B_1, B_2$

→  $e_i$  er estimert forklaringsfeil / prediksjonsfeil; et estimat av  $u_i$

→ Tolkning av  $B_1$  og  $B_2$  ( $b_1$  og  $b_2$  fortolkes på tilsvarende måte)

$$Y_i = B_1 + B_2 X_i + u_i$$



$B_1$ : Gjennomsnittlig verdi til  $Y_i$  når  $X_i = 0$

MERK: Verdien til  $B_1$  kan være negativ (eller økonomisk meningsløs).

Alternativ fortolkning:  $B_1$  "plasserer" regresjonslinja slik at den går gjennom hovedtyngden til observasjonene

$B_2$ : Den gjennomsnittlige endringen i  $Y_i$  gitt en enhets endring i  $X_i$

Eksempel:  $B_1 + B_2 \cdot 11 - (B_1 + B_2 \cdot 10)$   
 $= B_2$

Eksempel (tabell 2.5, s. 38):

$Y_i$  = timelønn i USD for person  $i$

$X_i$  = ant. år med skolegang for person  $i$

$b_1 = -0,0144$        $b_2 = 0,7241$

$b_1$ : plasserer regresjonslinja slik at den går gjennom hovedtyngden til observasjonene

$b_2$ : et år mer med skolegang gir i gjennomsnitt 0,72 USD mer i timelønn

#### ④ Minste kvadrater metode

→ lineær / ordinær minste kvadrater metode

→ Ordinary Least Squares (OLS)

Hvilke verdier skal vi tillegge  $b_1$  og  $b_2$ ?

↳ vanligste framgangsmåte: OLS

$$\text{Gitt } Y_i = b_1 + b_2 X_i + e_i$$

⇕

$$e_i = Y_i - b_1 - b_2 X_i$$

⇓

$$e_i^2 = (Y_i - b_1 - b_2 X_i)^2$$

$$\sum e_i^2 = \sum (Y_i - b_1 - b_2 X_i)^2$$

\* OLS estimering består i å velge  $b_1$  og  $b_2$  slik at  $\sum e_i^2$  minimeres

Førsteordensbetingelsene

$$\frac{\partial (\sum e_i^2)}{\partial b_1} = 0$$

$$\frac{\partial (\sum e_i^2)}{\partial b_2} = 0$$

Appendix 2A:

$$\frac{\partial (\sum e_i^2)}{\partial b_1} = (-2) \cdot \sum (Y_i - b_1 - b_2 X_i)$$

$$\frac{\partial (\sum e_i^2)}{\partial b_2} = (-2) \cdot \sum (Y_i - b_1 - b_2 X_i) X_i$$

$$b_2 = \frac{S_{XY}}{S_x^2}$$

$\swarrow$  utvalgs kovariansen mellom  $X$  og  $Y$   
 $\nwarrow$  utvalgs variansen til  $X$



$$b_1 = \bar{y} - b_2 \bar{x}$$



gjennomsnitt

→ Nyttig: OLS estimatet  $b_2$  kan skrives på mange måter

$$\begin{aligned}
 b_2 &= \frac{S_{xy}}{S_x^2} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n-1} \\
 &= \frac{\sum (x_i - \bar{x})^2}{n-1} \\
 &= \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \\
 &= \frac{\sum (x_i y_i - x_i \bar{y} - \bar{x} y_i + \bar{x} \bar{y})}{\sum (x_i^2 - x_i \bar{x} - \bar{x} x_i + \bar{x}^2)} \\
 &= \frac{\sum (x_i y_i) - n \bar{x} \bar{y}}{\sum (x_i^2) - n \bar{x}^2}
 \end{aligned}$$

→ Andre egenskaper ved OLS

estimering:

$$* \bar{e} = \frac{1}{n} \sum e_i = 0$$

$$* \sum (e_i x_i) = 0$$

$$* \sum (e_i \hat{y}_i) = 0 \quad \hat{y}_i = b_1 + b_2 x_i,$$

$$\Rightarrow \sum [e_i (b_1 + b_2 x_i)] = 0$$

Eksempel (tabell 2.4, s. 37):

$$Y_i = \text{S. A. T.}$$

$$X_i = \text{familieinntekt}$$

$$Y_i = \{410, 420, 440, 490, 530, 530, 550, 540, 570, 590\}$$

$$X_i = \{5000, 15000, 25000, 35000, 45000, 55000, 65000, 75000, 90000, 150000\}$$

$$n = 10 \quad \bar{X} = \frac{1}{10} \cdot 560000 \quad (\sum X_i = 560000)$$

$$= 56000$$

$$\bar{Y} = \frac{1}{10} \cdot 5070 \quad (\sum Y_i = 5070)$$

$$\sum(x_i y_i) = 305\ 550\ 000$$

$$\sum(x_i^2) = 47\ 600\ 000\ 000$$

$$\bar{x}^2 = (56\ 000)^2$$

$$b_2 = \frac{\sum(y_i x_i) - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2} = \frac{21\ 630\ 000}{16\ 240\ 000\ 000} \approx 0,0013$$

$$b_1 = \bar{y} - b_2 \cdot \bar{x} = 507 - 0,0013 \cdot 56\ 000 = 434,2$$

\* Oppgavesett 2:

$$1. \quad s_y = \frac{1}{n-1} \cdot \underbrace{\sum (y_i - \bar{y})^2}_{TSS}$$

↓

$$39,22 = \frac{1}{37-1} \cdot TSS$$

↓

$$36 \cdot 39,22 \approx 1412$$

2. B

3.  $b_2 = \frac{S_{xy}}{S_x^2} \cdot C$

4.  $Y_i = \alpha + \beta X_i + u_i$   
 $\uparrow \quad \uparrow$   
 $\beta_1 \quad \beta_2$

$\hat{\alpha} = b_1, \quad \hat{\beta} = b_2$

5.  $b_2 = \hat{\beta} = \frac{S_{xy}}{S_x^2} \cdot C$

C.

6.  $\hat{\beta} = \frac{\sum (x_i y_i)}{\sum x_i^2} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$   
 $= b_2$

C.

7. Parametrene:  $\alpha$  og  $\beta$

$$Y_t = \alpha + \frac{\beta}{X} + u_t$$

$$= \alpha + \beta \cdot X_t^* + u_t$$



$$X^* = \frac{1}{X_t}$$

5) Usikkerhet og modellpresisjon

$$Y_i = \underbrace{\beta_1 + \beta_2 X_i}_{\text{forklaring}} + u$$

forklaring

forklaringsteil

$$Y_i = \underbrace{b_1 + b_2 X_i}_{\text{forklaring}} + e_i$$

->  $E(u^2) = \sigma^2$ : Et mål på presisjonen til forklaringen vår.

->  $\frac{1}{n-2} \sum e_i^2$ : Vårt empiriske estimat på  $\sigma^2$

→ Notasjon:

$$\hat{\sigma}^2 = \frac{1}{n-k} \sum e_i^2$$

ant. estimerte parametre

$$\hat{\sigma} = \sqrt{\frac{1}{n-k} \sum e_i^2}$$

regresjonens  
standardfeil  
(Standard Error  
of Regression; SER)

EViews: S.E. of regression

→  $\sum e_i^2$ : Kvadratsummen til residualene  
(Sum of Squared Errors; SSE)

EViews: Sum squared resid

→  $b_1$  og  $b_2$  er estimater  $\hat{\beta}_1$  og  $\hat{\beta}_2$ .

Mål på presisjonen til  $b_1$  og  $b_2$ :

$\left. \begin{matrix} se(b_1) \\ se(b_2) \end{matrix} \right\}$  standardfeilene til  
 $b_1$  og  $b_2$

$$se(b_1) = \sqrt{\text{var}(b_1)}$$

$$= \sqrt{\left[ \frac{\sum x_i^2}{n \sum (x_i - \bar{x})^2} \right] \cdot \hat{\sigma}^2}$$

↑  
SER

$$se(b_2) = \sqrt{\frac{\hat{\sigma}^2}{\sum (x_i - \bar{x})^2}}$$

EViews: Standard feilene til estimatene står i kolonnen kalt "Std. Error"

⑥ Hvorfor OLS?

Gitt KFL - KFS så er OLS

"BLUE":

- Best } "Best" (minst varians) i
- Linear } klassen av lineare estimatorer
- Unbiased }  $b_1$  og  $b_2$  forventnings-
- Estimator } rette estimatører av  $\beta_1$  og  $\beta_2$