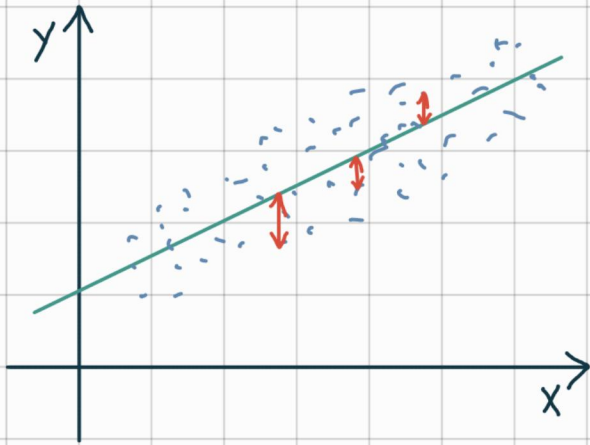


# UVOD

(Francis Galton, 1822-1911)



X - pojasnjevalna / explanatory  
Y - odvisna / dependent

To je enostavna linearna regresija, ki se ravnja po predlogi  $y = a + bx$ , kjer sta  $a, b$  koeficienta / parametra.

Splošna linearna regresija:

$$y = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

$x_1, x_2, \dots, x_p$  ... pojasnjevalne spremenljivke

$y$  ... odvisna spremenljivka

$\beta_1, \beta_2, \dots, \beta_p$  ... koeficienti / parametri

Podatki:

$$\begin{array}{l} x_{11}, x_{12}, \dots, x_{1p} \quad | \quad y_1 \\ x_{21}, x_{22}, \dots, x_{2p} \quad | \quad y_2 \\ \vdots \\ x_{n1}, x_{n2}, \dots, x_{np} \quad | \quad y_n \end{array}$$

$$\Rightarrow y_1 = \beta_1 x_{11} + \dots + \beta_p x_{1p}$$

$$\vdots$$

$$y_n = \beta_n x_{n1} + \dots + \beta_p x_{np}$$

$n > p \Rightarrow$  Predložen sistem

$$\underline{X} = \begin{bmatrix} x_{11} & \dots & x_{1p} \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{np} \end{bmatrix}, \quad \underline{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}, \quad \underline{\beta} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_p \end{bmatrix}$$

$$\Rightarrow \underline{y} = \underline{X} \underline{\beta}$$

## TOČKOVNO OCENJEVANJE KOEFICIENTOV

Uporabimo metodo najmanjših kvadratov (ordinary least squares, OLS):

$$\underline{y} = \underline{X} \underline{\beta} + \underline{\varepsilon}$$

$$\underline{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix} \text{ je vektor šumov.}$$

$$V := \text{Im } \underline{X} \subseteq \mathbb{R}^n$$

Poiščemo  $\underline{u} \in V$ , za katerega je  $\|\underline{y} - \underline{u}\|^2$  minimalna.



Nato pa rešimo  $\underline{v} = \underline{X}\underline{\beta}$ .

Privzememo, da ima  $\underline{X}$  ničelno jedro, tako da je rešitev enolična.

Računsko pride:

$$\underline{\beta} = (\underline{X}^T \underline{X})^{-1} \underline{X}^T \underline{y}$$

Statistični pogled:

$$\underline{y} = \underline{X}\underline{\beta} + \underline{\varepsilon}$$

↓ slučajen opazljiv      ↓ konstantna matrika (design matrix)      ↓ parameter (determinističen, poznan)      → šum (slučajen, neznan)

Minimalne predpostavke:

$\underline{\varepsilon}$  je beli šum:

$$E(\underline{\varepsilon}) = 0$$

$$\text{Var}(\underline{\varepsilon}) = \sigma^2 \underline{I} \quad (\text{homoskedastičnost, nekoreliranost})$$

V luči statistike iščemo cenilko  $\hat{\underline{\beta}}$  parametra  $\underline{\beta}$ .

Smiselna možnost:

$$\hat{\underline{\beta}} = (\underline{X}^T \underline{X})^{-1} \underline{X}^T \underline{y} \quad \text{iz metode najmanjših kvadratov}$$

Kako dobra je ta cenilka?

Če je  $\underline{c} \in \mathbb{R}^p$  konstanten vektor, kako dobra je cenilka  $\underline{c}^T \hat{\beta}$  karakteristike  $\underline{c}^T \beta$ ?

**Definicija:** Linearna ali afina cenilka za količino  $g$  z vrednostmi v  $\mathbb{R}$  na podlagi opažanja  $\underline{Y}$  z vrednostmi v  $\mathbb{R}^n$  je cenilka oblike  $\hat{g} = \underline{\Psi}^T \underline{Y} + \rho$ , kjer je  $\underline{\Psi} \in \mathbb{R}^n$  konstanten vektor in  $\rho \in \mathbb{R}$  konstanta.

**Definicija:** Najboljša nepristranska linearna cenilka (NNLC, best linear unbiased estimator) za  $g$  je taka nepristranska linearna cenilka  $\hat{g}$ , da za poljubno alternativno nepristransko linearno cenilko  $\hat{Q}$  velja  $\text{Var}_\theta(\hat{Q}) > \text{Var}_\theta(\hat{g})$  za vse  $\theta$ .

**Izrek 9.1 (Gauss, Markov):**

Če je  $\underline{c} \in \mathbb{R}^p$  konstanten vektor, je  $\hat{g} := \underline{c}^T \hat{\beta}$  edina NNLC za  $g := \underline{c}^T \beta$ .

Dokaz opustimo.

Minimiziramo  $\|\underline{Y} - \underline{X}\beta\|^2$  in pride  $\|(\underline{I}_n - \underline{H})\|^2 = \sum_{i=1}^n (y_i - \sum_{j=1}^p x_{ij} \hat{\beta}_j)^2$ .

$\underline{H} = \underline{X}(\underline{X}^T \underline{X})^{-1} \underline{X}^T$  je ortogonalni projektor na  $\text{Im } \underline{X}$ .

$$\underline{Y} = \underline{X}\beta + \underline{\varepsilon}$$

$$\underline{Y} = \underline{X}\hat{\beta} + \hat{\underline{\varepsilon}}$$

$\hat{\underline{\varepsilon}}$  je vektor rezidualov ali ostankov.

$$\|(\underbrace{\underline{I}_n - \underline{H}}_{\underline{Y} - \underline{X}\hat{\beta}})\underline{Y}\|^2 = \|\hat{\underline{\varepsilon}}\|^2 = \sum_{i=1}^n \hat{\varepsilon}_i^2 =: \text{RSS}$$

Trditev 9.2:  $\hat{\sigma}_+^2 = \frac{RSS}{n-p}$  je nepristranska cenilka za  $\sigma^2$ .

Dokaz opustimo.

Močnejše predpostavke:

Dodamo  $\underline{\varepsilon} \sim N(0, \sigma^2 \underline{I}_n)$ .

Trditev 9.3: Tedaj je  $\hat{\beta}$  tudi cenilka po metodi največjega verjetja.

$$\text{var}(\underline{c}^T \hat{\beta}) = \sigma^2 \underline{c}^T (\underline{X}^T \underline{X})^{-1} \underline{c}$$

$$SE = \sqrt{\text{var}(\underline{c}^T \hat{\beta})}$$

Trditev 9.4:  $\frac{\underline{c}^T \hat{\beta} - \underline{c}^T \beta}{SE} \sim N(0, 1)$

Trditev 9.5:  $\hat{\beta}$  in  $\hat{\sigma}_+$  sta neodvisni.

Posledica 9.6:  $\frac{\underline{c}^T \hat{\beta} - \underline{c}^T \beta}{SE} \sim \text{Student}(n-p)$

$$\hat{SE} = \hat{\sigma}_+ \sqrt{\underline{c}^T (\underline{X}^T \underline{X})^{-1} \underline{c}}$$