

# Metoda najmniejszych kwadratów

*Przykład wstępny.* W ekonomicznej teorii produkcji rozważa się funkcję produkcji Cobba–Douglasa:

$$z = AL^\alpha K^\beta$$

gdzie  $z$  oznacza wielkość produkcji,  $L$  jest nakładem pracy,  $K$  nakładem kapitału. Liczby  $A, \alpha, \beta$  są pewnymi stałymi. Ekonomisci interesują się wielkościami  $A, \alpha$  i  $\beta$ . W celu oceny nieznanymi wielkościami prowadzone są obserwacje wielkości produkcji  $Z_i$  przy różnych nakładach  $L_i$  oraz  $K_i$ , przy czym zakłada się, że obserwacje te obarczone są błędami losowymi  $\varepsilon_i$ , tzn.:

$$Z_i = AL_i^\alpha K_i^\beta + \varepsilon_i, \quad i = 1, \dots, n$$

Jako oszacowania nieznanymi parametrów przyjmuje się takie wartości, przy których błędy losowe są małe

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Z_i - AL_i^\alpha K_i^\beta)^2 = \min!$$

.....

Obserwujemy zmienne losowe  $Y_1, \dots, Y_n$  takie, że

$$EY_i = g_i(\theta), \quad i = 1, \dots, n$$

$$\theta \in \mathbb{R}^k; \quad g_i : \Theta \rightarrow \mathbb{R}^1$$

$$S(\theta) = \sum_{i=1}^n (Y_i - g_i(\theta))^2$$

**Definicja 8.1** Estymatorem najmniejszych kwadratów parametru  $\theta$  ( $EMNK[\theta]$ ) nazywamy wielkość minimalizującą  $S(\theta)$ .  $\square$

Resztowa suma kwadratów ( $EMNK[\theta] \stackrel{\text{ozn}}{=} \hat{\theta}$ )

$$S(\hat{\theta}) = \sum_{i=1}^n (Y_i - g_i(\hat{\theta}))^2$$

**Definicja 8.2** Modelem liniowym nazywamy model statystyczny, w którym obserwacje  $Y_1, \dots, Y_n$  mają postać

$$Y_i = \beta_1 x_{1i} + \dots + \beta_p x_{pi} + \varepsilon_i, \quad i = 1, \dots, n$$

gdzie  $x_{ji}$  są ustalonymi liczbami,  $\beta_j$  są nieznanymi parametrami modelu,  $\varepsilon_i$  są niezależnymi „błędami losowymi” takimi, że  $E\varepsilon_i = 0$  oraz  $D^2\varepsilon_i = \sigma^2$ .  $\square$

Zapis macierzowy

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}.$$

$$\mathbf{Y}' = (Y_1, \dots, Y_n)$$

$$\boldsymbol{\beta}' = (\beta_0, \beta_1, \dots, \beta_p)$$

$$\boldsymbol{\varepsilon}' = (\varepsilon_1, \dots, \varepsilon_n)$$

$$\mathbf{X} = \begin{bmatrix} x_{11} & \cdots & x_{p1} \\ x_{12} & \cdots & x_{p2} \\ \vdots & \cdots & \vdots \\ x_{1n} & \cdots & x_{pn} \end{bmatrix}$$

Założenie: macierz  $\mathbf{X}$  jest pełnego rzędu

Resztowa suma kwadratów

$$\begin{aligned} S(\boldsymbol{\beta}) &= \sum_{i=1}^n \left( Y_i - \sum_{j=1}^p \beta_j x_{ji} \right)^2 \\ &= (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \\ &= \|\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}\|^2 \end{aligned}$$

$\mathbf{X}\boldsymbol{\beta}$  jest rzutem  $\mathbf{Y}$  na  $\{\mathbf{X}\boldsymbol{\beta} : \boldsymbol{\beta} \in \mathbb{R}^p\}$

$$(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})' \mathbf{X} = \mathbf{0}$$

$$EMNK[\boldsymbol{\beta}] = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} \stackrel{\text{ozn}}{=} \hat{\boldsymbol{\beta}}$$

Jeżeli  $\mathbf{c} \in \mathbb{R}^p$ , to

$$EMNK[\mathbf{c}'\boldsymbol{\beta}] = \mathbf{c}'\hat{\boldsymbol{\beta}}$$

**Przykład** . Na podstawie obserwacji  $Y_1, \dots, Y_n$  szacujemy wartość oczekiwaną  $\mu$ . Model

$$Y_i = \mu + \varepsilon_i, \quad i = 1, \dots, n$$

W zapisie macierzowym

$$\beta = \mu, \quad \mathbf{X} = \mathbf{1}_n$$

$$EMNK[\mu] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \bar{Y}$$

.....

**Przykład** . Rozważmy model

$$Y_i = x_{i1}\mu_1 + x_{i2}\mu_2 + \varepsilon_i, \quad i = 1, \dots, n$$

przy czym

$$x_{i1} = 1, \quad x_{i2} = 0 \quad \text{dla } i = 1, \dots, n_1$$

$$x_{i1} = 0, \quad x_{i2} = 1 \quad \text{dla } i = n_1 + 1, \dots, n$$

Szacujemy różnicę  $\mu_1 - \mu_2$ .

Zapis macierzowy

$$\boldsymbol{\beta}' = (\mu_1, \mu_2), \quad \mathbf{X} = \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} \\ \mathbf{0}_{n-n_1} & \mathbf{1}_{n-n_1} \end{bmatrix}$$

$$\begin{aligned} EMNK[\boldsymbol{\beta}] &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} \\ &= \begin{bmatrix} n_1 & 0 \\ 0 & n_2 \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=1}^{n_1} Y_i \\ \sum_{i=n_1+1}^n Y_i \end{bmatrix} \\ &= \begin{bmatrix} \frac{1}{n_1} \sum_{i=1}^{n_1} Y_i \\ \frac{1}{n-n_1} \sum_{i=n_1+1}^n Y_i \end{bmatrix} \end{aligned}$$

Jeżeli  $\mathbf{c}' = (1, -1)$ , to  $\mathbf{c}'\boldsymbol{\beta} = \mu_1 - \mu_2$

$$EMNK[\mu_1 - \mu_2] = \frac{1}{n_1} \sum_{i=1}^{n_1} Y_i - \frac{1}{n-n_1} \sum_{i=n_1+1}^n Y_i$$

Jeżeli  $\mathbf{c}' = (1, 0)$ , to  $\mathbf{c}'\boldsymbol{\beta} = \mu_1$

$$EMNK[\mu_1] = \frac{1}{n_1} \sum_{i=1}^{n_1} Y_i$$

.....

**Twierdzenie 8.1**  $EMNK[\beta]$  jest estymatorem nieobciążonym o wariancji  $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$  ■

**Definicja 8.3** Funkcję parametryczną  $\mathbf{c}'\beta$  nazywamy estymowalną, jeżeli istnieje jej estymator nieobciążony postaci  $\mathbf{b}'\mathbf{Y}$ . □

**Twierdzenie 8.2** Funkcja parametryczna  $\mathbf{c}'\beta$  jest estymowalna wtedy i tylko wtedy, gdy  $\mathbf{c} \in \text{Im}\mathbf{X}'$  ■

**Twierdzenie 8.3 (Gaussa–Markowa)** Jeżeli błędy losowe  $\varepsilon_1, \dots, \varepsilon_n$  są nieskorelowanymi zmiennymi losowymi o zerowej wartości oczekiwanej i takiej samej wariancji, to dla każdej estymowalnej funkcji parametrycznej  $\mathbf{c}'\beta$  i dla każdego nieobciążonego estymatora liniowego  $\mathbf{b}'\mathbf{Y}$  tej funkcji zachodzi

$$D_{\beta}^2(\mathbf{c}'\hat{\beta}) \leq D_{\beta}^2(\mathbf{b}'\mathbf{Y}), \quad \forall \beta \in \mathbb{R}^p$$

■

## Estymacja wariancji $\sigma^2$

Resztowa suma kwadratów

$$\begin{aligned}\|Y - X\hat{\beta}\|^2 &= (Y - X\hat{\beta})'(Y - X\hat{\beta}) \\ &= (Y - X(X'X)^{-1}X'Y)'(Y - X(X'X)^{-1}X'Y) \\ &= Y'(I - X'(X'X)^{-1}X)(I - X(X'X)^{-1}X')Y \\ &= Y'(I - X(X'X)^{-1}X')Y\end{aligned}$$

$$\begin{aligned}E_{\beta}\|Y - X\hat{\beta}\|^2 &= E_{\beta}Y'(I - X(X'X)^{-1}X')Y \\ &= \text{tr}E_{\beta}(I - X(X'X)^{-1}X')YY' \\ &= \text{tr}\{(I - X(X'X)^{-1}X')E_{\beta}(YY')\} \\ &= \sigma^2\text{tr}(I - X(X'X)^{-1}X') \\ &= (n - \text{rz}X)\sigma^2\end{aligned}$$

$$\hat{\sigma}^2 = \frac{1}{(n - \text{rz}X)}Y'(I - X(X'X)^{-1}X')Y$$



**Przykład** . Rozważamy model

$$Y_i = \mu + \varepsilon_i, \quad i = 1, \dots, n$$

W zapisie macierzowym

$$\beta = \mu, \quad \mathbf{X} = \mathbf{1}_n$$

W modelu rz $\mathbf{X} = 1$

$$\begin{aligned} \hat{\sigma}^2 &= \frac{1}{n-1} \mathbf{Y}' (\mathbf{I} - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n') \mathbf{Y} \\ &= \frac{1}{n-1} \left\{ \mathbf{Y}' \mathbf{Y} - \frac{1}{n} (\mathbf{Y}' \mathbf{1}_n) (\mathbf{1}_n' \mathbf{Y}) \right\} \\ &= \frac{1}{n-1} \left\{ \sum_{i=1}^n Y_i^2 - \frac{1}{n} \left( \sum_{i=1}^n Y_i \right)^2 \right\} \\ &= \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2 \end{aligned}$$

.....

**Przykład** . Rozważmy model

$$Y_i = x_{i1}\mu_1 + x_{i2}\mu_2 + \varepsilon_i, \quad i = 1, \dots, n$$

przy czym

$$x_{i1} = 1, x_{i2} = 0 \text{ dla } i = 1, \dots, n_1$$

$$x_{i1} = 0, x_{i2} = 1 \text{ dla } i = n_1 + 1, \dots, n$$

Zapis macierzowy ( $n_2 = n - n_1$ )

$$\beta' = (\mu_1, \mu_2), \quad \mathbf{X} = \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} \\ \mathbf{0}_{n_2} & \mathbf{1}_{n_2} \end{bmatrix}$$

W modelu rz $\mathbf{X} = 2$

$$(n - 2)\hat{\sigma}^2$$

$$= \mathbf{Y}' \left( \mathbf{I} - \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} \\ \mathbf{0}_{n_2} & \mathbf{1}_{n_2} \end{bmatrix} \begin{bmatrix} n_1 & 0 \\ 0 & n_2 \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{1}'_{n_1} & \mathbf{0}'_{n_2} \\ \mathbf{0}'_{n_1} & \mathbf{1}'_{n_2} \end{bmatrix} \right) \mathbf{Y}$$

$$= \sum_{i=1}^{n_1} \left( Y_i - \frac{1}{n_1} \left( \sum_{i=1}^{n_1} Y_i \right) \right)^2 +$$

$$+ \sum_{i=n_1+1}^n \left( Y_i - \frac{1}{n_2} \left( \sum_{i=n_1+1}^n Y_i \right) \right)^2$$

.....

**Przykład (praktyczny).** Niech  $Y_1, Y_2, Y_3, Y_4$  będą lotniczymi pomiarami kątów  $\theta_1, \theta_2, \theta_3, \theta_4$  pewnego czworokąta na powierzchni ziemi. Zakładając, że obserwacje obciążone są niezależnymi błędami o zerowej wartości oczekiwanej i takiej samej wariancji  $\sigma^2$ , wyznaczyć *EMNK* wielkości  $\theta$ . Wyznaczyć nieobciążony estymator wariancji  $\sigma^2$ .

Model

$$Y_1 = \theta_1 + \varepsilon_1$$

$$Y_2 = \theta_2 + \varepsilon_2$$

$$Y_3 = \theta_3 + \varepsilon_3$$

$$Y_4 = \theta_4 + \varepsilon_4$$

$$2\pi = \theta_1 + \theta_2 + \theta_3 + \theta_4$$

Zapis macierzowy

$$\mathbf{Y}' = (Y_1, Y_2, Y_3, Y_4, 2\pi); \quad \boldsymbol{\beta}' = (\theta_1, \theta_2, \theta_3, \theta_4)$$

$$\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \varepsilon_3, \varepsilon_4, 0)$$

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 1 & 1 & 1 \end{bmatrix}$$

$$(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 0.8 & -0.2 & -0.2 & -0.2 \\ -0.2 & 0.8 & -0.2 & -0.2 \\ -0.2 & -0.2 & 0.8 & -0.2 \\ -0.2 & -0.2 & -0.2 & 0.8 \end{bmatrix}$$

$$(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' = \begin{bmatrix} 0.8 & -0.2 & -0.2 & -0.2 & 0.2 \\ -0.2 & 0.8 & -0.2 & -0.2 & 0.2 \\ -0.2 & -0.2 & 0.8 & -0.2 & 0.2 \\ -0.2 & -0.2 & -0.2 & 0.8 & 0.2 \end{bmatrix}$$

Estymatory kątów:

$$\hat{\theta}_i = \text{?} Y_i + \frac{1}{5} \left( 2\pi - \sum_{i=1}^4 Y_i \right), \quad i = 1, 2, 3, 4$$

Estymator wariancji:

$$\hat{\sigma}^2 = \text{?} \frac{1}{5} \left( 2\pi - \sum_{i=1}^4 Y_i \right)^2$$

Wiadomo, iż dany czworokąt jest równoległobokiem takim, że  $\theta_1 = \theta_3$  oraz  $\theta_2 = \theta_4$ . Wyznaczyć EMNK kątów i estymator wariancji  $\sigma^2$ .

Model

$$Y_1 = \theta_1 + \varepsilon_1$$

$$Y_2 = \theta_2 + \varepsilon_2$$

$$Y_3 = \theta_3 + \varepsilon_3$$

$$Y_4 = \theta_4 + \varepsilon_4$$

$$2\pi = \theta_1 + \theta_2 + \theta_3 + \theta_4$$

$$0 = \theta_1 - \theta_3$$

$$0 = \theta_2 - \theta_4$$

Zapis macierzowy

$$\mathbf{Y}' = (Y_1, Y_2, Y_3, Y_4, 2\pi, 0, 0); \quad \boldsymbol{\beta}' = (\theta_1, \theta_2, \theta_3, \theta_4)$$

$$\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \varepsilon_3, \varepsilon_4, 0, 0, 0)$$

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 0 & -1 & 0 \\ 0 & 1 & 0 & -1 \end{bmatrix}$$

.....

**Przykład (Regresja liniowa). Model**

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n,$$

$\varepsilon_i$  są niezależnymi zmiennymi losowymi

$$E\varepsilon_i = 0, \quad D^2\varepsilon_i = \sigma^2, \quad i = 1, \dots, n$$

Znaleźć takie  $\beta_0$  i  $\beta_1$  by

$$\sum_{i=1}^n (Y_i - (\beta_0 + \beta_1 x_i))^2 = \min$$

Zapis macierzowy

$$\mathbf{Y}' = (Y_1, \dots, Y_n); \quad \boldsymbol{\beta}' = (\beta_0, \beta_1); \quad \boldsymbol{\varepsilon}' = (\varepsilon_1, \dots, \varepsilon_n)$$

$$\mathbf{X}' = \begin{bmatrix} 1 & \cdots & 1 \\ x_1 & \cdots & x_n \end{bmatrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix}$$

$$(\mathbf{X}'\mathbf{X})^{-1} = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix}$$

$$\mathbf{X}'\mathbf{Y} = \begin{bmatrix} \sum Y_i \\ \sum x_i Y_i \end{bmatrix}$$

$$\begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} = EMNK \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} =$$

$$\begin{bmatrix} \frac{1}{n} \sum Y_i - \frac{1}{n} (\sum x_i) \frac{\sum x_i Y_i - \frac{1}{n} (\sum x_i)(\sum Y_i)}{\sum x_i^2 - \frac{1}{n} (\sum x_i)^2} \\ \frac{\sum x_i Y_i - \frac{1}{n} (\sum x_i)(\sum Y_i)}{\sum x_i^2 - \frac{1}{n} (\sum x_i)^2} \end{bmatrix}$$

$$\begin{cases} \hat{\beta}_1 = \frac{\sum x_i y_i - n\bar{x}\bar{Y}}{\sum x_i^2 - n\bar{x}^2} \\ \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x} \end{cases}$$

.....

## Rozkłady prawdopodobieństwa estymatorów

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}.$$

$$\boldsymbol{\beta}' = (\beta_0, \beta_1, \dots, \beta_p)$$

$$\boldsymbol{\varepsilon}' = (\varepsilon_1, \dots, \varepsilon_n) \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$$

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$$

$$s^2 = \hat{\sigma}^2 = \frac{1}{(n - \text{rz}\mathbf{X})} \mathbf{Y}'(\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}')\mathbf{Y}$$

**Twierdzenie 8.4** Jeżeli  $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$  oraz  $\text{rz}\mathbf{X} = p$ , to

1.  $\hat{\boldsymbol{\beta}} \sim N_p(\boldsymbol{\beta}, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$
2.  $(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})' \mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) \sim \sigma^2 \chi_p^2$
3.  $\hat{\boldsymbol{\beta}}$  jest niezależne od  $s^2$
4.  $(n - p)s^2 \sim \sigma^2 \chi_{n-p}^2$

