

Metody Ekonometryczne

Metoda Najmniejszych Kwadratów

Jakub Mućk
Szkola Główna Handlowa w Warszawie

Sprawy organizacyjne

Literatura podstawowa

- Greene W.H., (2011), *Econometric Analysis*, Prentice Hall.

Literatura uzupełniająca

- Hill R.C., Griffiths W. E. i Lim G.C, (2011), *Principle of Econometrics*, Willey.
- Wooldridge J. M., (2012), *Introductory Econometrics: A Modern Approach*, Cengage Learning.

Oprogramowanie

- R.

- **Raport** opisujący badanie ekonometryczne: 50%.
- **Egzamin**: 50%.
- **Brak raportu oznacza ocenę niedostateczną.**

- 1 Metoda najmniejszych kwadratów.
- 2 Uogólniona metoda najmniejszych kwadratów.
- 3 Metoda zmiennych instrumentalnych.
- 4 Modele wielorównaniowe.

Wprowadzenie

Ekonometria to zbiór metod statystycznych i matematycznych pozwalających na empiryczną weryfikację teorii ekonomicznej.

Inaczej

Ekonometria pozwala na pomiar siły (istotności) i kierunku zjawisk i procesów ekonomicznych.

Załóżmy, że zmienna y jest funkcją x_1, x_2, \dots, x_k , t. że

$$y = \mathcal{F}(x_1, x_2, \dots, x_k) \quad (1)$$

Zauważmy, że równanie (1) określa funkcję **deterministyczną**. Wprowadźmy, element losowy, tj. ε :

$$y = f(x_1, x_2, \dots, x_k, \varepsilon) \quad (2)$$

Szczególnym przypadkiem (1) jest liniowa postać. Wtedy mowa o **modelu regresji liniowej**:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (3)$$

gdzie:

- y – zmienna objaśniana.
- x_1, \dots, x_k – zmienne objaśnianające, (egzogeniczne).
- β_1, \dots, β_k – parametry strukturalne modelu.
- β_0 – wyraz wolny.
- ε – składnik losowy.

- **Dane eksperymentalne i nieeksperymentalne** (*experimental and nonexperimental data*).
- Dane przekrojowe (*cross-section data*), szeregi czasowe (*time series*) oraz dane panelowe (*panel data*).
- Dane mikroekonomiczne oraz makroekonomiczne.
- Przepływy (*flow*) i stany (*stock*).
- Dane ilościowe (*quantitative*) i jakościowe (*qualitative*)

Konsekwencje

Rodzaj danych ma znaczenie w wyborze zarówno i) postaci funkcyjnej oraz ii) metody estymacji.

- 1 Sformułowanie celu badawczego i/lub hipotez badawczych.
- 2 Wybór modelu ekonomicznego.
- 3 Kolekcjonowanie danych i wybór odpowiednich metod ekonometrycznych lub statystycznych.
- 4 Szacowanie nieznanymi parametrów w celu odpowiedzi na kluczowe pytania badawcze lub realizacji celów badawczych.
- 5 Weryfikacja zasadności założeń wykorzystanych w procesie estymacji.

Rachunek prawdopodobieństwa i statystyka matematyczna

Zmienna losowa (*random variable*)

jest zmienną, której wartości są nieznane dopóki nie jest obserwowana.

Zmienna losowa (*random variable*)

jest zmienną, której wartości są nieznane dopóki nie jest obserwowana.

- **Dyskretna zmienna losowa** – przyjmuje wartości z ograniczonego i przeliczalnego zbioru potencjalnych wyników.
- **Binarna zmienna losowa** – przyjmuje wyłącznie wartości 0 lub 1.
- **Ciągła zmienna losowa** – przyjmuje dowolne wartości (lub z pewnego zakresu).

- **Rozkład prawdopodobieństwa (*probability density function, pdf*)** dla zmiennej losowej opsiuje potencjalne wyniki oraz towarzyszące im prawdopodobieństwa.
- Rozkład prawdopodobieństwa *pdf* dla dyskretnej zmiennej losowej X :

$$f(x) = P(X = x), \tag{4}$$

i $\sum_i^k f(x_i) = 1$.

- Ponieważ dla ciągłej zmiennej losowe $P(X = x) = 0$ *pdf* wykorzystuje się funkcję gęstości, która jest określona dla pewnego zbioru.

$$P(a \leq X \leq b) = \int_a^b f(x)dx, \tag{5}$$

i $\int_{-\infty}^{\infty} f(x)dx = 1$.

- **Dystrybuanta rozkładu prawdopodobieństwa** (*cumulative distribution function, cdf*) jest alternatywną miarą opisu potencjalnych wyników wraz z towarzyszącym im prawdopodobieństwami. Dla dowolnej stałej x dystrybuanta jest zdefiniowana następująco:

$$F(x) = P(X \leq x). \quad (6)$$

- ▶ W przypadku dyskretnych zmiennych losowych, dystrybuanta *cdf* to po prostu suma *pdf* dla wszystkich x_i (spełniających odpowiedni warunek).
- ▶ Dla ciągłej zmiennej losowej, $F(x)$ jest powierzchnią *pdf* na lewo od punktu x .
- Dystrybuanta rozkładu prawdopodobieństwa jest przydatna w obliczaniu prawdopodobieństw. W szczególności,

$$P(X > x) = 1 - P(X \leq x) = 1 - F(x), \quad (7)$$

$$P(a < X \leq b) = F(b) - F(a). \quad (8)$$

- **Rozkład łączny** (*joint probability density function*) zawiera informacje związaną z potencjalnymi wynikami (przynajmniej dwóch) zmiennych losowych oraz towarzyszącym im prawdopodobieństwom. Dla zmiennych dyskretnych:

$$f(x, y) = P(X = x, Y = y), \quad (9)$$

i dla zmiennych ciągłych:

$$P(a \leq X \leq b, c \leq Y \leq d) = \int_a^b \int_c^d f(x, y) dy dx. \quad (10)$$

- **Rozkład brzegowy** (*marginal distribution*) pozwala uzyskać informację o indywidualnym rozkładzie prawdopodobieństwa zmiennej losowej (ponizej dla X):

$$f_X(x) = P(X = x) = \sum_y f(x, y). \quad (11)$$

- **Warunkowy rozkład prawdopodobieństwa** (*conditional distribution*) jest rozkładem prawdopodobieństwa zmiennej Y w przypadku, gdy znana X jest znane:

$$f(x|y) = P(Y = y|X = x) = \frac{f(x, y)}{f_X(x)}. \quad (12)$$

- Zmienne losowe są niezależne wtedy i tylko wtedy gdy rozkład łączny prawdopodobieństwa jest równy iloczynowi indywidualnych rozkładów prawdopodobieństwa *pdfs*. Przykładowo, dla dwóch zmiennych losowych:

$$f(x, y) = f_X(x)f_Y(y). \quad (13)$$

- **Wartość oczekiwana** (*expected value, expectation*) zmiennej losowej X jest średnią ważoną (rozkładem prawdopodobieństwa) wszystkich potencjalnych wyników X .
- Wartość oczekiwana dla zmiennej dyskretnej X :

$$\mathbb{E}(X) = \sum_{i=1}^N X_i f(x_i), \quad (14)$$

gdzie $f(x)$ jest rozkładem prawdopodobieństwa X .

- Wartość oczekiwana jest również nazywana **średnią z populacji** (*population mean*) (\neq **średnia z próby** (*sample average*)).
- Wartość oczekiwana dla zmiennej ciągłej X :

$$\mathbb{E}(X) = \int_{-\infty}^{\infty} x f(x) dx. \quad (15)$$

- Własności wartości oczekiwanej
 - 1 Dla dowolnej stałej c :

$$\mathbb{E}(c) = c. \quad (16)$$

- 2 Dla dowolnych stałych a i b :

$$\mathbb{E}(aX + b) = a\mathbb{E}(X) + b. \quad (17)$$

- 3 Dla dowolnych stałych a_1, \dots, a_k i zmiennych losowych X_1, \dots, X_k :

$$\mathbb{E}\left(\sum_i^k a_i X_i\right) = \sum_i^k a_i \mathbb{E}(X_i), \quad (18)$$

i jeżeli $a_i = 1$ dla wszystkich i wtedy wartość oczekiwana sumy jest sumą wartości oczekiwanych.

- 4 Dla funkcji tworzącej nową zmienną losową $g(\cdot)$:

$$\mathbb{E}(g(X)) = \sum_i^k g(x_i) f_x(x_i), \quad (19)$$

i w przypadku ciągłej zmiennej losowej:

$$\mathbb{E}(g(X)) = \int_{-\infty}^{\infty} g(x_i) f_x(x_i), \quad (20)$$

- **Warunkowa wartość oczekiwana** (*conditional expected value*) jest wartością oczekiwaną X w przypadku gdy Y jest znane. Dla dyskretnych zmiennych losowych:

$$\mathbb{E}(X|Y = y) = \sum_{i=1}^k x_i f(x_i, y). \quad (21)$$

- **Wariancja** (*variance*) mierzy stopień zmienności (*variability*) zmiennej losowej:

$$\text{Var}(X) = \mathbb{E} [(X - \mu)^2], \quad (22)$$

where $\mathbb{E}(X) = \mu$.

- Wariancja jest zazwyczaj oznaczana jako σ^2 (lub σ_X^2 for X).
- Alternatywnie, wariancję zmiennej losowej można zapisać jako:

$$\begin{aligned} \text{Var}(X) &= \mathbb{E} (X^2 - 2X\mu + \mu^2) = \mathbb{E}(X^2) - 2\mu\mathbb{E}(X) + \mu^2 \\ &= \mathbb{E} (X^2) - \mu^2. \end{aligned}$$

- Dla dowolnych stałych wartości a i b :

$$\text{Var}(aX + b) = a^2\text{Var}(X). \quad (23)$$

- **Odchylenie standardowe** (*standard deviation, sd*) jest pierwiastkiem wariancji

$$\text{sd}(X) = \sqrt{\text{Var}(X)} \quad (24)$$

- Dla dowolnych stałych a i b :

$$\text{Var}(aX + bY) = a^2\text{Var}(X) + b^2\text{Var}(Y) + 2\text{cov}(X, Y). \quad (25)$$

- **Kowariancja (covariance)** mierzy zależność pomiędzy zmiennymi losowymi:

$$\text{cov}(X, Y) = \mathbb{E}[(X - \mu_X)(Y - \mu_Y)], \quad (26)$$

where $\mathbb{E}(Y) = \mu_Y$ i $\mathbb{E}(X) = \mu_X$.

- Kowariancja pomiędzy X i Y jest również oznaczana jako σ_{XY} .
- Kowariancja może zostać alternatywnie zapisana jako:

$$\begin{aligned} \text{cov}(X, Y) &= \mathbb{E}[(X - \mu_X)(Y - \mu_Y)] \mathbb{E}[X(Y - \mu_Y)] \\ &= \mathbb{E}[(X - \mu_X)Y] = \mathbb{E}(XY) - \mu_X\mu_Y \end{aligned}$$

- Gdy X i Y są niezależne to $\text{cov}(X, Y) = 0$ i $\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y)$.
 - Na podstawie kowariancji trudno ocenić siłę zależności pomiędzy zmiennymi losowymi.
- Korelacja correlation (ρ)** uwzględnia potencjalne różnice w wariancji zmiennych losowych:

$$\rho = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}(X)}\sqrt{\text{var}(Y)}} = \frac{\sigma_{XY}}{\sigma_X\sigma_Y}, \quad (27)$$

and $\rho \in (-1, 1)$.

- Dłazsze własności wariancji:

$$\text{Var}(aX + bY) = a^2\text{Var}(X) + b^2\text{Var}(Y) + 2ab\text{Cov}(X, Y), \quad (28)$$

$$\text{Var}(aX - bY) = a^2\text{Var}(X) + b^2\text{Var}(Y) - 2ab\text{Cov}(X, Y). \quad (29)$$

- Estymator $\hat{\theta}$ jest funkcją zmiennej losowej (zmiennych losowych) oraz próby (danych empirycznych) mającą na celu pomiar (empiryczny) parametru θ .
- Nieobciążoność (*unbiasedness*) estymatora:

$$\mathbb{E}(\hat{\theta}) = \theta \quad \text{lub} \quad \text{Bias}(\hat{\theta}) = \mathbb{E}(\hat{\theta}) - \theta = 0, \quad (30)$$

gdzie $\text{Bias}(\hat{\theta})$ to obciążenie estymatora.

- Wariancja estymatora $\hat{\theta}$:

$$\text{Var}(\hat{\theta}) = \mathbb{E}\left[(\hat{\theta} - \mathbb{E}(\hat{\theta}))^2\right], \quad (31)$$


wariancja może służyć jako miara efektywności estymatora.


- Zgodność (*consistency*) estymatora:


$$\text{plim}_{n \rightarrow \infty} \hat{\theta}_n = \theta, \quad (32)$$


gdzie $\text{plim}_{n \rightarrow \infty}$ to granica stochastyczna.

- Nieobciążoność **nie implikuje** zgodności
i zgodność **nie implikuje** nieobciążoności.












Regresja prosta – intuicja







Regresja prosta:

$$\mathbb{E}(y|x) = \beta_0 + \beta_1 x$$

Estymator MNK

Zapis ogólny:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon. \quad (33)$$

Zapis macierzowy

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon \quad (34)$$

gdzie

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}_{n \times 1}, \quad \mathbf{X} = \begin{bmatrix} 1 & x_{1,1} & x_{1,2} & \dots & x_{1,k} \\ 1 & x_{2,1} & x_{2,2} & \dots & x_{2,k} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n,1} & x_{n,2} & \dots & x_{n,k} \end{bmatrix}_{n \times (k+1)},$$

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix}_{(k+1) \times 1}, \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}_{n \times 1},$$

k – liczba zmiennych objaśniających; n – liczba obserwacji.

- β oznacza **prawdziwą (nieznaną)** wartość wektora parametru a $\hat{\beta}$ jego oszacowanie (szacunek), tj. wynik estymacji.
- \mathbf{y} jest obserwowaną (empiryczną) wartością zmiennej objaśnanej, a $\hat{\mathbf{y}}$ wartością teoretyczną, a więc wynikającą z oszacowań, tj.:

$$\hat{\mathbf{y}} = \mathbf{X}\hat{\beta}. \quad (35)$$

- ε to składnik losowy. Jego realizacje stanowi \mathbf{e} , czyli tzw. reszty (składnik losowy):

$$\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \mathbf{X}\hat{\beta}. \quad (36)$$

Dla następującego modelu liniowego:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (37)$$

załóżmy, że

- 1 **Brak współliniowości:** $rz(\mathbf{X}) = k + 1 \leq n$;
macierz obserwacji \mathbf{X} jest pełnego rzędu kolumnowego.
- 2 Zmienne x_i są **ściśle egzogeniczne**, a więc są niezależne od składnika losowego, tj. $\mathbb{E}(\mathbf{X}\varepsilon) = 0$.
- 3 $\mathbb{E}(\varepsilon) = 0$.
- 4 **Sferyczna macierz wariancji-kowariancji składnika losowego:**
 $Var(\varepsilon) = \mathbb{E}(\varepsilon\varepsilon^T) = I\sigma^2$.
- 5 $\varepsilon_i \sim N(0, \sigma^2)$.

Kluczowe są założenia (1)-(4). Założenie o normalności składnika losowego jest pomocnicze.

- Załóżmy, że badane zjawisko można opisać modelem postaci [lub *prawdziwy proces generujący zmienną y jest następujący*]:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (38)$$

- Nieznane parametry można uzyskać przy pomocy **Metody Najmniejszych Kwadratów (OLS – ordinary least squares)**. Idea tej metody polega na znalezieniu takich wartości nieznanego wektora parametrów β , który minimalizują sumę kwadratów reszt, czyli różnic pomiędzy wartościami obserwowanymi a teoretycznymi:

$$\hat{\beta}^{OLS} = \arg \min_{\beta} \mathbf{e}^T \mathbf{e}, \quad (39)$$

gdzie $\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \mathbf{X}\hat{\beta}$.

- Przyjmijmy sumę kwadratów reszt (*SSE - error sum of squares*) jako funkcję szukanego wektora parametrów β , którą chcemy minimalizować:

$$SSE(\beta) = \mathbf{e}^T \mathbf{e} = (\mathbf{y} - \hat{\mathbf{y}})^T (\mathbf{y} - \hat{\mathbf{y}}) = (\mathbf{y} - \mathbf{X}\beta)^T (\mathbf{y} - \mathbf{X}\beta), \quad (40)$$

- Po przemnożeniu macierzy w (40), otrzymujemy:

$$SSE(\beta) = \mathbf{y}\mathbf{y}^T - 2\mathbf{y}^T \mathbf{X}\beta + \beta^T \mathbf{X}^T \mathbf{X}\beta, \quad (41)$$

- Zróżniczkujemy wyrażenie (41) po β , wtedy otrzymamy:

$$\frac{\partial SSE(\beta)}{\partial \beta} = -2\mathbf{X}^T \mathbf{y} + 2\mathbf{X}^T \mathbf{X} \beta, \quad (42)$$

- Przyrównując pierwszą pochodną, tj. (42), otrzymujemy układ równań

$$\mathbf{X}^T \mathbf{y} = \mathbf{X}^T \mathbf{X} \beta, \quad (43)$$

Ostatecznie, wykorzystując założenie o pełnym rzędzie kolumnowym macierzy \mathbf{X} :

$$\hat{\beta}^{OLS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}. \quad (44)$$

- Model regresji prostej (alternatywnej notacji):

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, 2, \dots, N, \quad (45)$$

gdzie i oznacza indeks obserwacji.

- Estymator MNK dla parametrów równania (45) można wyrazić następująco:

$$\hat{\beta}_0^{OLS} = \bar{y} - \hat{\beta}_1^{OLS} \bar{x}, \quad (46)$$

$$\hat{\beta}_1^{OLS} = \frac{\sum_i^N (x_i - \bar{x})(y_i - \bar{y})}{\sum_i^N (x_i - \bar{x})^2}. \quad (47)$$

- Interpretacja?

- Ogólny wzór dla estymatora macierzy wariancji-kowariancji oszacowań ($\hat{\beta}^{OLS}$):

$$\text{Var}(\hat{\beta}^{OLS}) = \mathbb{E} \left[(\hat{\beta}^{OLS} - \beta) (\hat{\beta}^{OLS} - \beta)^T \right]. \quad (48)$$

- Zauważmy, że

$$\hat{\beta}^{OLS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\mathbf{X}\beta + \varepsilon) = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon, \quad (49)$$

- wtedy

$$\begin{aligned} \text{Var}(\hat{\beta}^{OLS}) &= \mathbb{E} \left[(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon \left((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon \right)^T \right] \\ &= \mathbb{E} \left[(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon \varepsilon^T \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \right] \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E} [\varepsilon \varepsilon^T] \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \end{aligned}$$

- Następnie korzystając z założenie o **sferyczności macierzy wariancji-kowariancji składnika losowego**, tj. $\mathbb{E}(\varepsilon \varepsilon^T) = \sigma^2 I$, można uprościć wzór na estymator wariancji kowariancji oszacowań do:

$$\text{Var}(\hat{\beta}^{OLS}) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}. \quad (50)$$

- W przypadku MNK, możemy wyznaczyć estymator macierzy wariancji-kowariancji dla parametrów $\hat{\beta}^{OLS}$ korzystając z szacunku wariancji składnika losowego (S_ϵ^2):

$$\text{Var}(\hat{\beta}^{OLS}) = S_\epsilon^2 (\mathbf{X}^T \mathbf{X})^{-1}, \quad (51)$$

gdzie

$$S_\epsilon^2 = \frac{\mathbf{e}^T \mathbf{e}}{n - (k + 1)} = \frac{SSE(\hat{\beta}^{OLS})}{df} \quad (52)$$

gdzie $SSE(\hat{\beta}^{OLS})$ to suma kwadratów reszt, a df to **liczba stopni swobody**.

- Elementy diagonalne macierzy wariancji-kowariancji (oznaczymy jako \hat{d}_{ii}), stanowią wariancję estymowanych parametrów. Zatem **błąd szacunku dla i -tego parametru** jest równy:

$$S(\hat{\beta}_i) = \sqrt{\hat{d}_{ii}}. \quad (53)$$

- Względny błąd szacunku**

$$\left| \frac{S(\hat{\beta}_i)}{\hat{\beta}_i} \right|. \quad (54)$$

Założenia:

- ❶ $rz(\mathbf{X}) = k + 1 \leq n$
- ❷ $\mathbb{E}(\mathbf{X}\varepsilon) = 0$
- ❸ $\mathbb{E}(\varepsilon) = 0$
- ❹ $Var(\varepsilon) = \mathbb{E}(\varepsilon\varepsilon^T) = I\sigma^2$
- ❺ $\varepsilon_i \sim N(0, \sigma^2)$

Twierdzenie Gaussa - Markowa

Estymator $\hat{\beta}$ uzyskany Klasyczną Metodą Najmniejszych Kwadratów jest estymatorem **BLUE** [*best linear unbiased estimator*], tj. zgodnym, nieobciążonym i najefektywniejszy w klasie liniowych estymatorów wektora β .

- nieobciążoność, czyli: $\mathbb{E}(\hat{\beta}^{OLS}) = \beta$
- najefektywniejszy, czyli posiadający najmniejszą wariancję w swojej klasie
- zgodny, czyli: $\text{plim}_{n \rightarrow \infty}(\hat{\beta}^{OLS}) = \beta$.

- Nieobciążoność estymatora:

$$\mathbb{E}(\hat{\beta}^{OLS}) = \beta. \quad (55)$$

- Korzystając z tożsamości $y = \mathbf{X}\beta + \varepsilon$ postać estymatora KMNK może zostać zapisana jako:

$$\hat{\beta}^{OLS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\mathbf{X}\beta + \varepsilon). \quad (56)$$

- Korzystając z faktu, że $(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} = \mathbf{I}$

$$\hat{\beta}^{OLS} = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon. \quad (57)$$

- Wprowadźmy wartość oczekiwaną:

$$\mathbb{E}(\hat{\beta}^{OLS}) = \mathbb{E}(\beta) + \mathbb{E}[(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon], \quad (58)$$

- Wiedząc, że $\mathbb{E}(\beta) = \beta$ oraz wykorzystując nielosowość zmiennych objaśniających, tj. $\mathbb{E}(\mathbf{X}) = \mathbf{X}$

$$\mathbb{E}(\hat{\beta}^{OLS}) = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E}(\varepsilon), \quad (59)$$

a przy założeniu, że $\mathbb{E}(\varepsilon \mathbf{X}) = 0$ otrzymujemy:

$$\mathbb{E}(\hat{\beta}^{OLS}) = \beta. \quad (60)$$

- Na podstawie wcześniejszych obliczeń:

$$\hat{\beta}^{OLS} = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon. \quad (61)$$

- Załóżmy, że $\mathbf{A} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$. Wtedy

$$\hat{\beta}^{OLS} = \beta + \mathbf{A} \varepsilon, \quad (62)$$

- a więc $\hat{\beta}^{OLS}$ jest liniową funkcją składnika losowego. Zgodnie z założeniami, które przyjąłmy $\hat{\beta}^{OLS}$ jest zatem estymatorem liniowym.

- Wprowadźmy, inny nieobciążony estymator liniowy parametru β , np. $\hat{\mathbf{B}} = C\mathbf{y}$.
Zatem

$$\mathbb{E}(\hat{\mathbf{B}}) = \mathbb{E}(C\mathbf{X}\beta + C\boldsymbol{\varepsilon}) = \beta \quad (63)$$

- Warto zauważyć, że $C\mathbf{X} = \mathbf{I}$.
- Wariancja estymatora $\hat{\mathbf{B}}$:

$$\text{Var}(\hat{\mathbf{B}}) = \sigma^2 C C^T. \quad (64)$$

- Porównując wariancję, wprowadźmy wyrażenie $D = C - (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$.
- Wariancja estymatora $\hat{\mathbf{B}}$:

$$\text{Var}(\hat{\mathbf{B}}) = \sigma^2 \left[\left(D + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \right) \left(D + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \right)^T \right], \quad (65)$$

- $D\mathbf{X} = 0$ ze względu na tożsamość $C\mathbf{X} = \mathbf{I} = D\mathbf{X} + (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{X})$. Zatem wariancję można zapisać:

$$\text{Var}(\hat{\mathbf{B}}) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} + \sigma^2 D D^T = \text{Var}(\hat{\beta}^{OLS}) + \sigma^2 D D^T. \quad (66)$$

- Zgodność estymatora MNK:

$$\text{plim}_{n \rightarrow \infty} \hat{\beta}^{OLS} = \beta \quad (67)$$

- Korzystając z wcześniejszej tożsamości ($\mathbb{E}(\hat{\beta}^{OLS}) = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E}(\varepsilon)$):

$$\text{plim}_{n \rightarrow \infty} \hat{\beta}^{OLS} = \beta + \text{plim}_{n \rightarrow \infty} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E}(\varepsilon). \quad (68)$$

- Mnożymy wyrażenie przez jeden, tj. $1 = 1/n \times n$:

$$\text{plim}_{n \rightarrow \infty} \hat{\beta}^{OLS} = \beta + \text{plim}_{n \rightarrow \infty} \left(\frac{1}{n} \mathbf{X}^T \mathbf{X} \right)^{-1} \frac{1}{n} \mathbf{X}^T \mathbb{E}(\varepsilon). \quad (69)$$

- Korzystając z egzogeniczności:

$$\text{plim}_{n \rightarrow \infty} \frac{1}{n} \mathbf{X}^T \mathbb{E}(\varepsilon) = 0, \quad (70)$$

- Ponadto, zauważmy, że o ile wyrażenie $\text{plim}_{n \rightarrow \infty} (\mathbf{X}^T \mathbf{X})$ trudno ograniczyć to $\text{plim}_{n \rightarrow \infty} (1/n \mathbf{X}^T \mathbf{X})$ można ograniczyć przez pewną wartość \mathcal{C} . Wtedy:

$$\text{plim}_{n \rightarrow \infty} \hat{\beta}^{OLS} = \beta + \mathcal{C} \times 0 = \beta. \quad (71)$$