

Metoda Najmniejszych Kwadratów

Stanisław Cichocki

Natalia Nehrebecka

Wykład 2

Plan wykładu

- ▶ 1. Model liniowy
 - Postać modelu liniowego
- ▶ 2. Estymacja modelu
 - Wstęp
 - Wartość teoretyczna (dopasowana)
 - Reszty
 - Metoda Najmniejszych Kwadratów
- ▶ 3. MNK dla modelu z jedną zmienną

Plan wykładu

- ▶ 1. Model liniowy
 - Postać modelu liniowego
- ▶ 2. Estymacja modelu
 - Wstęp
 - Wartość teoretyczna (dopasowana)
 - Reszty
 - Metoda Najmniejszych Kwadratów
- ▶ 3. MNK dla modelu z jedną zmienną

Postać modelu liniowego

teoria ekonomiczna



dane empiryczne



zależności ilościowe między zmiennymi



badanie ekonometryczne

Postać modelu liniowego

$$y_i = \beta_1 + x_{2i}\beta_2 + \dots + x_{Ki}\beta_K + \varepsilon_i$$

- y_i – zmienna objaśniana (zależna, endogeniczna),
- x_2, \dots, x_K – zmienne objaśniające (niezależne, egzogeniczne),
- ε_i – błąd losowy,
- β_1, \dots, β_K – nieznanne parametry,
- $i=1, \dots, N$
- i – indeks obserwacji,
- N – liczba obserwacji

Postać modelu liniowego

y	x
Zmienna objaśniana	Zmienna objaśniająca
Zmienna zależna	Zmienna niezależna
Zmienna endogeniczna	Zmienna egzogeniczna
Regresant	Regresor
	Zmienna kontrolna
	Predyktor

Postać modelu liniowego

▶ Zatem:

- zależność między analizowanymi zmiennymi jest liniowa (równanie regresji liniowej wyznacza hiperpłaszczyznę regresji)
- istnieje zależność przyczynowo-skutkowa między zmiennymi (≠korelacja)
 - zmienne objaśniające są przyczyną zmienności zmiennej objaśnianej
 - zależność zwykle wynika z teorii (powinna)
- pewna część zmienności zmiennej objaśnianej pozostaje niewyjaśniona, bo:
 - nieuwzględnienie pewnych zmiennych objaśniających
 - losowy charakter czynników wpływających na zmienną objaśnianą

Postać modelu liniowego

- ▶ Który z modeli jest poprawny i dlaczego?
- ▶ Co jest zmienną objaśnianą a co objaśniającą?

$$wydatki_i = \beta_1 + \beta_2 dochód_i + \varepsilon_i$$

$$dochód_i = \beta_1 + \beta_2 wydatki_i + \varepsilon_i$$

Postać modelu liniowego

- ▶ Związek przyczynowo-skutkowy \neq korelacja

Przykład

Stwierdzono dodatnią korelację między wielkością spożycia lodów w danym dniu i liczbą utonięć w tym dniu. Czy po zjedzeniu lodów nie powinno się wchodzić do wody?

Odpowiedź

Więcej utonięć zdarza się w ciepłe dni (kąpie się wtedy więcej osób). W takie dni jest też większe spożycie lodów. Jednak spożycie lodów nie powoduje utonięcia

Czyli: występuje korelacja między zdarzeniami ale nie ma między nimi związku przyczynowo-skutkowego

Plan wykładu

- ▶ 1. Model liniowy
 - Postać modelu liniowego
- ▶ 2. Estymacja modelu
 - Wstęp
 - Wartość teoretyczna (dopasowana)
 - Reszty
 - Metoda Najmniejszych Kwadratów
- ▶ 3. MNK dla modelu z jedną zmienną

Estymacja - wstęp

- ▶ Teoria zwykle nie dostarcza informacji nt. wielkości parametrów modelu $(\beta_1, \dots, \beta_K)$.
- ▶ Wielkość nieznanych parametrów należy oszacować (estymować) na podstawie danych empirycznych (próby).
- ▶ Oszacowane wielkości parametrów (estymatory) (b_1, \dots, b_K) są niedokładne (losowe), zależą od próby.

Wartość teoretyczna (dopasowana)

- ▶ **Wartości dopasowane:** wartości zmiennej objaśnianej (y_i) przewidywane na podstawie oszacowanego modelu - regresji liniowej y_i na x_{2i}, \dots, x_{Ki} :

$$\hat{y}_i = b_1 + x_{2i}b_2 + \dots + x_{Ki}b_K$$

- ▶ Różnią się od wartości rzeczywistych, bo:
 - ▶ zamiast nieznanymi prawdziwymi wielkościami parametrów (β_1, \dots, β_K) używamy ich estymatorów (b_1, \dots, b_K)
 - ▶ pomijamy błąd losowy (ε_i)

Reszty

- ▶ **Reszty:** różnica między wartością rzeczywistą a dopasowaną zmiennej objaśnianej, są to oszacowania (ε_i) :

$$e_i = y_i - \hat{y}_i = y_i - b_1 - x_{2i}b_2 - \dots - x_{Ki}b_K$$


- ▶ Zależność między resztami, obserwacjami i oszacowaniami parametrów:

$$y_i = \hat{y}_i + e_i = b_1 + x_{2i}b_2 + \dots + x_{Ki}b_K + e_i$$

Estymatory i reszty

- ▶ Estymatory (b_1, \dots, b_K) są to oszacowania (β_1, \dots, β_K) ale nie są im równe
- ▶ Reszty (e_i) są to oszacowania (ε_i) ale nie są im równe


Metoda Najmniejszych Kwadratów

- ▶ Im mniejsza jest odległość wartości rzeczywistych od teoretycznych tym lepszy model 
estymatory parametrów modelu minimalizują sumę odległości y_i od \hat{y}_i :

$$\sum_{i=1}^N (y_i - \hat{y}_i)^2 = \sum_{i=1}^N e_i^2$$

Metoda Najmniejszych Kwadratów

Rysunek: Reszty i prosta regresji



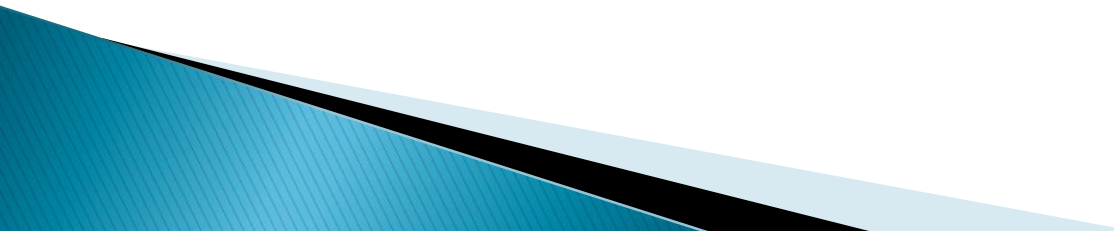
Źródło: J. Mycielski, *skrypt do ekonometrii...*

Plan wykładu

- ▶ 1. Model liniowy
 - Postać modelu liniowego
- ▶ 2. Estymacja modelu
 - Wstęp
 - Wartość teoretyczna (dopasowana)
 - Reszty
 - Metoda Najmniejszych Kwadratów
- ▶ 3. MNK dla modelu z jedną zmienną

MNK dla modelu z jedną zmienną

▶ Kroki:

1. Zapisujemy wzór na sumę kwadratów reszt i podstawiamy za reszty
 2. Liczymy warunki pierwszego rzędu (pochodne)
 3. Przekształcamy tak aby uzyskać oszacowania parametrów
- 

MNK dla modelu z jedną zmienną

- ▶ Oszacowania \mathbf{b}_1 i \mathbf{b}_2 powinny być dobrane tak, by suma kwadratów reszt była jak najmniejsza.

$$\begin{aligned} S(b_1, b_2) &= \sum_{i=1}^N e_i = \sum_{i=1}^N (y_i - b_1 - x_i b_2)^2 = \\ &= \sum_{i=1}^N (y_i^2 - 2y_i b_1 - 2y_i b_2 x_i + 2b_1 b_2 x_i + b_1^2 + b_2^2 x_i^2) \end{aligned}$$

MNK dla modelu z jedną zmienną

- ▶ Policz pochodne cząstkowe względem parametrów b_1 i b_2 powyższego równania i przyrównaj je do zera.

$$\begin{cases} \frac{\partial S(b_1, b_2)}{\partial b_1} = 0 \\ \frac{\partial S(b_1, b_2)}{\partial b_2} = 0 \end{cases}$$

Warunki pierwszego rzędu

MNK dla modelu z jedną zmienną

- ▶ Licząc pochodne dla poszczególnych równań uzyskujemy układ równań zwany **układem równań normalnych**.

$$\begin{cases} \sum_{i=1}^N [-2y_i + 2b_1 + 2b_2x_i] = 0 \\ \sum_{i=1}^N [-2y_ix_i + 2b_1x_i + 2b_2x_i^2] = 0 \end{cases}$$

MNK dla modelu z jedną zmienną

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

$$b_2 = \frac{\frac{\sum_{i=1}^N y_i x_i}{N} - \bar{y} \bar{x}}{\frac{\sum_{i=1}^N x_i^2}{N} - \bar{x}^2}$$

MNK dla modelu z jedną zmienną

- ▶ Przypomnij wzór na wariancję (s_x^2) i kowariancję (s_{xy}) empiryczną.

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

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

Dziękuję za uwagę