

Interpretacja parametrów

Stanisław Cichocki

Natalia Nehrebecka

Wykład 5-6

Plan wykładu

- ▶ 1. Interpretacja parametrów przy zmiennych objaśniających ciągłych
 - Interpretacja współczynników regresji w modelu liniowym
 - Elastyczność
 - Semielastyczność
- ▶ 2. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa

Plan wykładu

- ▶ 1. Interpretacja parametrów przy zmiennych objaśniających ciągłych
 - Interpretacja współczynników regresji w modelu liniowym
 - Elastyczność
 - Semielastyczność
- ▶ 2. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa

Interpretacja współczynników regresji w modelu liniowym

- ▶ Model regresji liniowej dla i-tej obserwacji:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + \varepsilon_i$$

- ▶ Wartość oczekiwana zmiennej objaśnianej przy danych wartościach zmiennych objaśniających wynosi:

$$E(Y_i) = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \dots + \beta_K X_{Ki}$$

- ▶ Pochodną cząstkową warunkowej wartości oczekiwanej po x_{Ki}

$$\frac{\partial E(Y_i)}{\partial X_{ki}} = \beta_k$$

β_k mierzy oczekiwaną zmianę Y_i jako efekt zmiany X_{Ki} o jedną jednostkę, **gdy wartości innych zmiennych objaśniających modelu pozostają niezmiennione** (ceteris paribus).

Przykład

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + \varepsilon_i$$

$$\hat{Y}_i = b_1 + b_2 X_{2i} + \dots + b_K X_{Ki}$$

β_2 – współczynnik

INTERPRETACJA: jeżeli wartość zmiennej niezależnej X_{2i} wzrośnie o jednostkę, to wartość zmiennej zależnej y :

- wzrośnie (jeżeli $b_2 > 0$) o $|b_2|$ jednostek lub
- spadnie (jeżeli $b_2 < 0$) o $|b_2|$ jednostek

ceteris paribus.

β_1 – wyraz wolny

Uwaga ! Wyrazu wolnego nie interpretujemy.

Przykład

$$placa_i = \beta_1 + \beta_2 nauka_i + \beta_3 wiek_i + \varepsilon_i$$

$$\hat{placa}_i = -993,26 + 73,59 \cdot nauka_i + 35,09 \cdot wiek_i$$

- ▶ Zmienna *nauka_i* - lata nauki i-tej osoby
- ▶ Interpretacja:
Miesięczne wynagrodzenie wzrasta przeciętnie o 73,59 zł przy wzroście liczby lat nauki o jeden rok, przy założeniu pozostałych charakterystyk na niezmiennym poziomie.

Elastyczność

- ▶ Elastyczności mogą być wyznaczone z modelu - **LOGLINIOWYM**, w którym zarówno zmienna objaśniana jak i zmienne objaśniające są logarytmami zmiennych pierwotnych.

$$\ln Y_i = \beta_1 + \beta_2 \ln X_{2i} + \dots + \beta_K \ln X_{Ki} + \varepsilon_i$$

$$\ln E(Y_i) = \beta_1 + \beta_2 \ln X_{2i} + \dots + \beta_K \ln X_{Ki}$$

$$\frac{\partial \ln E(Y_i)}{\partial \ln X_{ki}} = \beta_k$$

β_k mierzy o ile procent zmieni się zmienna objaśniana, gdy zmienna objaśniająca zmieni się o jeden procent, **gdy wartości innych zmiennych objaśniających modelu pozostają niezmiennione** (ceteris paribus).

Przykład

$$\ln Y_i = \beta_1 + \beta_2 \ln X_{2i} + \dots + \beta_K \ln X_{Ki} + \varepsilon_i$$

$$\ln \hat{Y}_i = b_1 + b_2 \ln X_{2i} + \dots + b_K \ln X_{Ki}$$

β_2 – współczynnik

INTERPRETACJA: jeżeli wartość zmiennej niezależnej X_{2i} wzrośnie o 1% ,
to wartość zmiennej zależnej y :

- wzrośnie (jeżeli $b_2 > 0$) o $|b_2|$ % lub
- spadnie (jeżeli $b_2 < 0$) o $|b_2|$ %.

ceteris paribus.

β_1 – wyraz wolny

Uwaga ! Wyrazu wolnego nie interpretujemy.

Przykład

$$\ln(\text{wydatki}_i) = \beta_1 + \beta_2 \ln(\text{dochód}_i) + \varepsilon_i$$

$$\widehat{\ln(\text{wydatki}_i)} = 2 + 0,25 \cdot \ln(\text{dochód}_i)$$

► Interpretacja:

Miesięczne wydatki wzrastają przeciętnie o 0,25% przy wzroście miesięcznego wynagrodzenia o 1%, przy założeniu pozostałych charakterystyk na niezmiennym poziomie.

Semielastyczność

- ▶ Semielastyczności mogą być wyznaczone z modelu, w którym zmienna objaśniana jest zlogarytmowana a zmienne objaśniające nie są logarytmami zmiennych pierwotnych.

$$\ln Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + \varepsilon_i$$

$$\ln E(Y_i) = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki}$$

$$\frac{\partial \ln E(Y_i)}{\partial X_{ki}} = \beta_k$$

$\beta_k * 100\%$ mierzy o ile procent zmieni się zmienna objaśniana, gdy zmienna objaśniająca zmieni się o jedną jednostkę, **gdy wartości innych zmiennych objaśniających modelu pozostają niezmiennione** (ceteris paribus).

Przykład

$$\ln Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + \varepsilon_i$$

$$\ln \hat{Y}_i = b_1 + b_2 X_{2i} + \dots + b_K X_{Ki}$$

β_2 – współczynnik

INTERPRETACJA: jeżeli wartość zmiennej niezależnej X_{2i} wzrośnie o 1 jednostkę, to wartość zmiennej zależnej y :

- wzrośnie (jeżeli $b_2 > 0$) o $|b_2| * 100\%$ lub
- spadnie (jeżeli $b_2 < 0$) o $|b_2| * 100\%$.

ceteris paribus.

β_1 – wyraz wolny

Uwaga ! Wyrazu wolnego nie interpretujemy.

Przykład

$$\ln(placa_i) = \beta_1 + \beta_2 \cdot wiek_i + \varepsilon_i$$

$$\widehat{\ln(placa_i)} = 2,34 + 0,04 \cdot wiek_i$$

► Interpretacja:

Płaca wzrasta przeciętnie o 4% przy wzroście wieku o 1 rok, przy założeniu pozostałych charakterystyk na niezmiennym poziomie.

Zadanie

$$\hat{\ln(\text{wydatki}_i)} = 3,6 + 0,35 \cdot \ln(\text{dochód})_i + 0,11 \cdot \text{dzieci}_i$$

► Interpretacja:

Elastyczność: wzrost dochodu o 1% powoduje wzrost wydatków o 0,35% przy założeniu pozostałych charakterystyk na niezmiennym poziomie.

Semielastyczność: wzrost liczby dzieci o 1 powoduje wzrost wydatków o 11%=0,11*100% przy założeniu pozostałych charakterystyk na niezmiennym poziomie.



Plan wykładu

- ▶ 1. Interpretacja parametrów przy zmiennych objaśniających ciągłych
 - Interpretacja współczynników regresji w modelu liniowym
 - Elastyczność
 - Semielastyczność
- ▶ 2. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa

Zastosowanie modelu potęgowego - przykład



Modelujemy wydatki gospodarstw domowych za pomocą dochodu tych gospodarstw.

Histogram wydatków /logarytmu wydatków gospodarstw domowych:



Zastosowanie modelu potęgowego - przykład

Histogram dochodów/logarytmu dochodów gospodarstw:



Zastosowanie modelu potęgowego - przykład

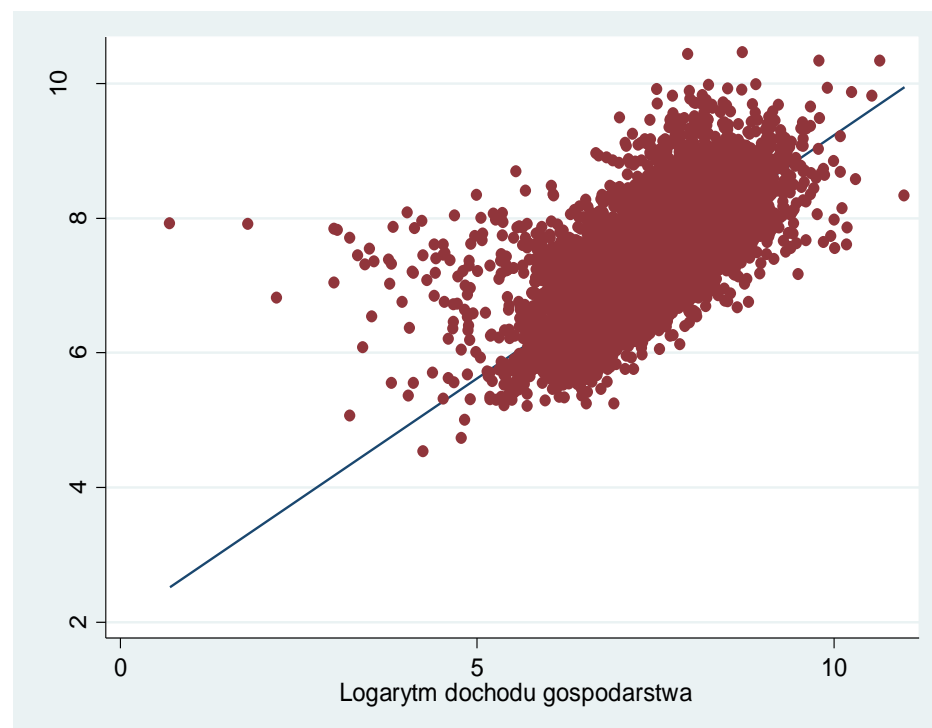

Wyniki regresji:

$$\ln(\text{Wydatki}) = 2,02 + 0,72 * \ln(\text{Dochod}) \quad R^2 = 0,58$$

$$\text{Wydatki} = 712,81 + 0,58 * \text{Dochod} \quad R^2 = 0,41$$



Zastosowanie modelu potęgowego - przykład

Regresja na poziomach i logarytmach:



Zastosowanie modelu potęgowego - przykład

Reszty z regresji:



Przekształcenie Boxa-Coxa

- ▶ Pozwala na przeprowadzenie sformalizowanej procedury wyboru między modelem liniowym i potęgowym
- ▶ Postać przekształcenia:

$$x^{(\lambda)} = g(x, \lambda) = \frac{x^\lambda - 1}{\lambda}$$

Pytanie: Co otrzymujemy dla $\lambda = 1$, $\lambda = -1$, $\lambda = 0$?

Przekształcenie Boxa-Coxa

- ▶ Stosując to przekształcenie do zmiennej zależnej i zmiennych niezależnych:

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

- ▶ Dla $\lambda = 1$:

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

Gdzie: $\beta_1^* = 1 + \beta_1 - \beta_2 - \dots - \beta_K$

Przekształcenie Boxa-Coxa

► Dla $\lambda = -1$:

$$\frac{1}{y_i} = \beta_1^* + \frac{\beta_2}{x_{2i}} + \dots + \frac{\beta_K}{x_{Ki}} + \varepsilon_i$$

Gdzie: $\beta_1^* = 1 - \beta_1 - \beta_2 - \dots - \beta_K$

Dla $\lambda = 0$:

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

Dziękuję za uwagę