

Zastosowanie modelu potęgowego

Zmienne dyskretne

Stanisław Cichocki

Natalia Nehrebecka

Wykład 6


Plan wykładu

- ▶ 1. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa
- ▶ 2. Zmienne ciągłe za zmienne dyskretne
- ▶ 3. Interpretacja parametrów przy zmiennych dyskretnych



Plan wykładu

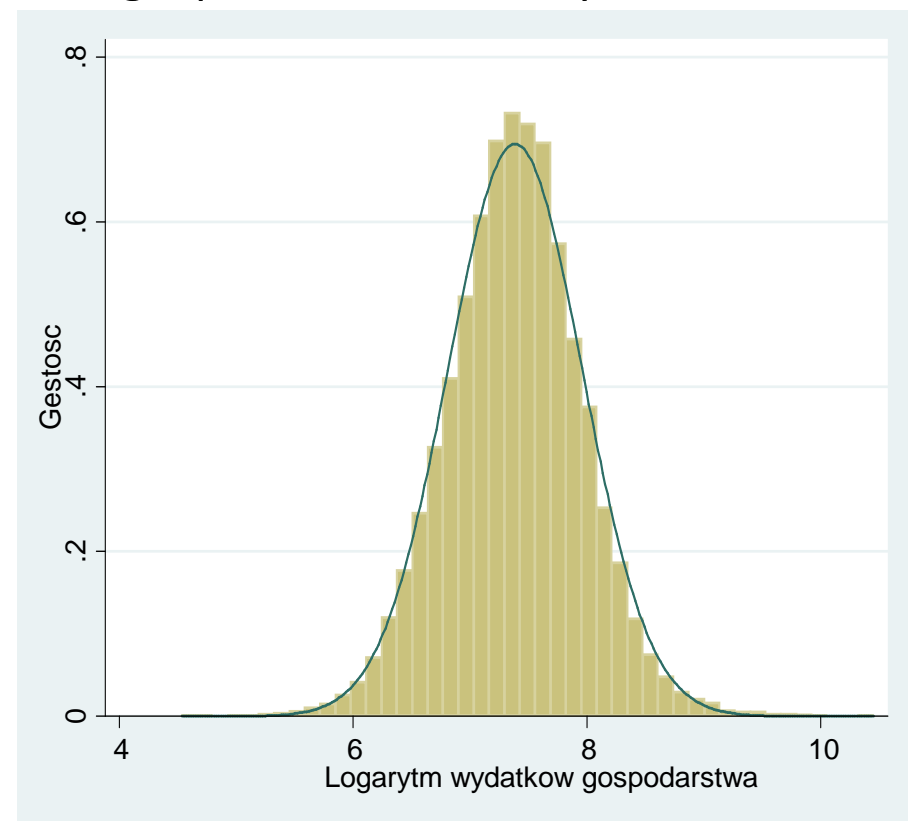

- ▶ 1. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa
- ▶ 2. Zmienne ciągłe za zmienne dyskretne
- ▶ 3. Interpretacja parametrów przy zmiennych dyskretnych



Zastosowanie modelu potęgowego - przykład

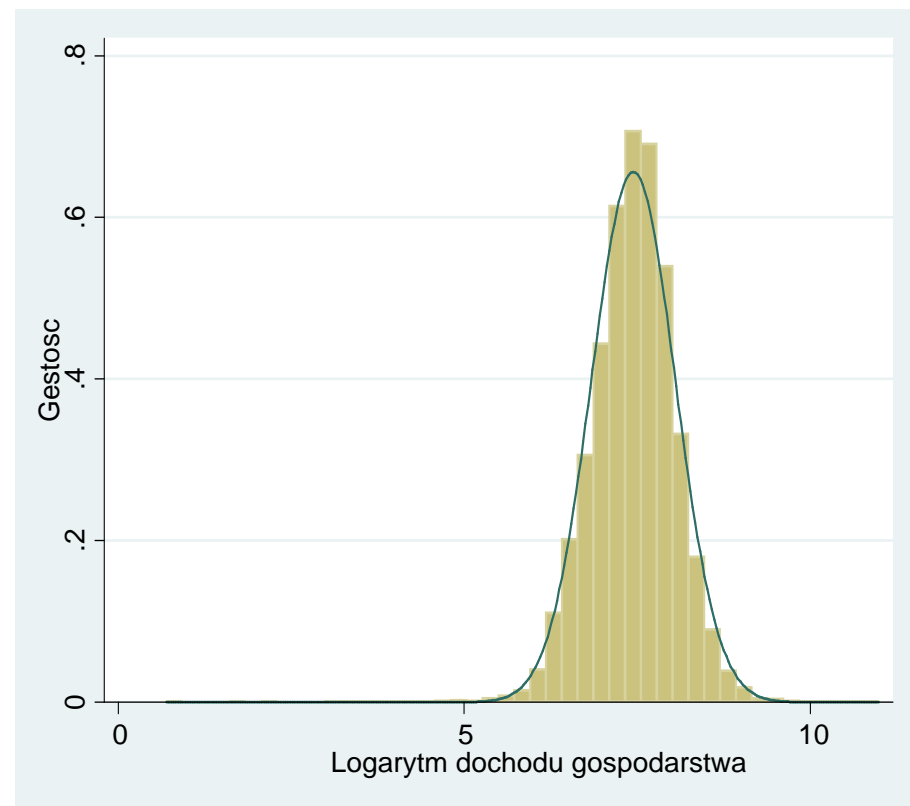
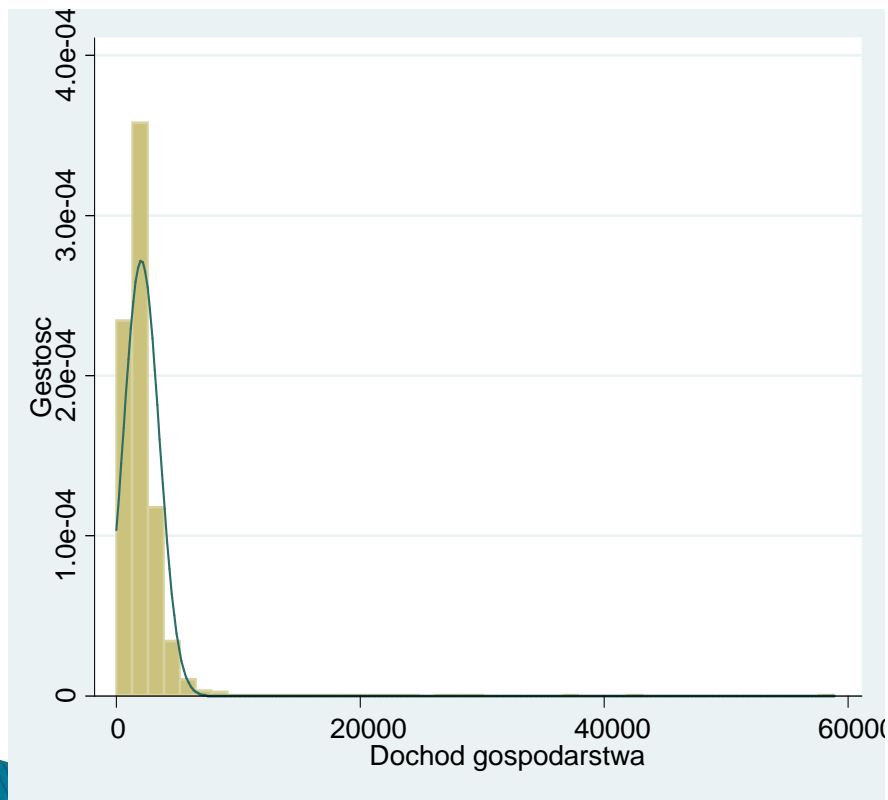
Modelujemy wydatki gospodarstw domowych za pomocą dochodu tych gospodarstw.

Histogram wydatków /logarytmu wydatków gospodarstw domowych:



Zastosowanie modelu potęgowego - przykład

Histogram dochodów/logarytmu dochodów gospodarstw:



Zastosowanie modelu potęgowego - przykład

Wyniki regresji:



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

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



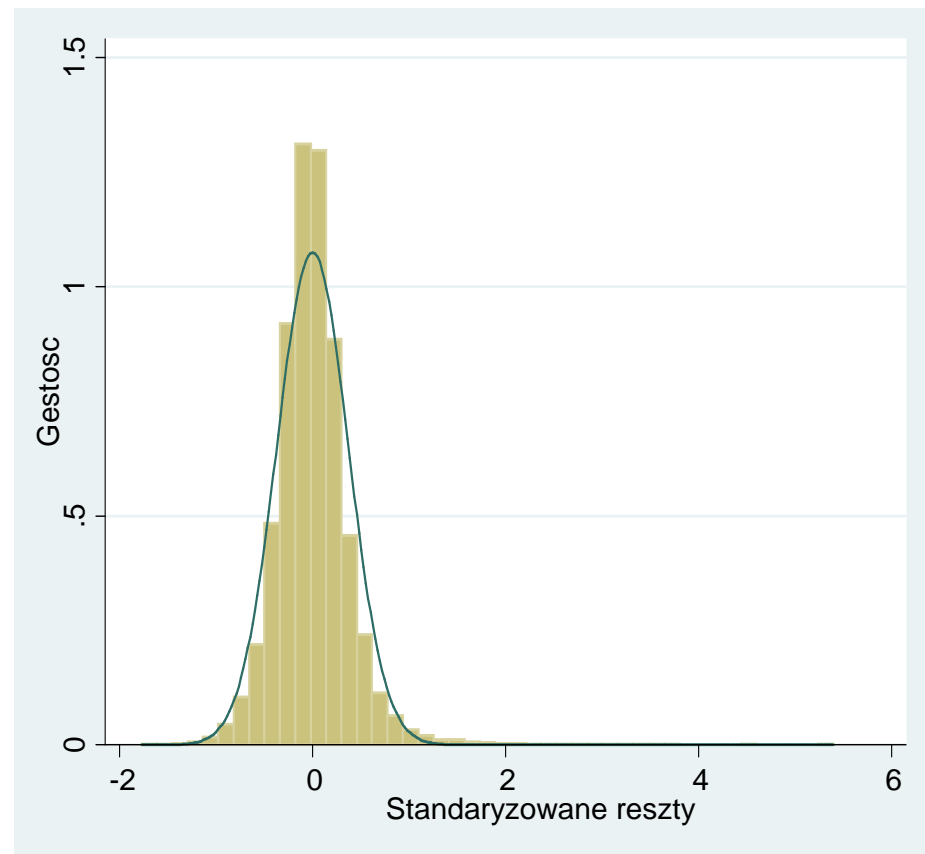
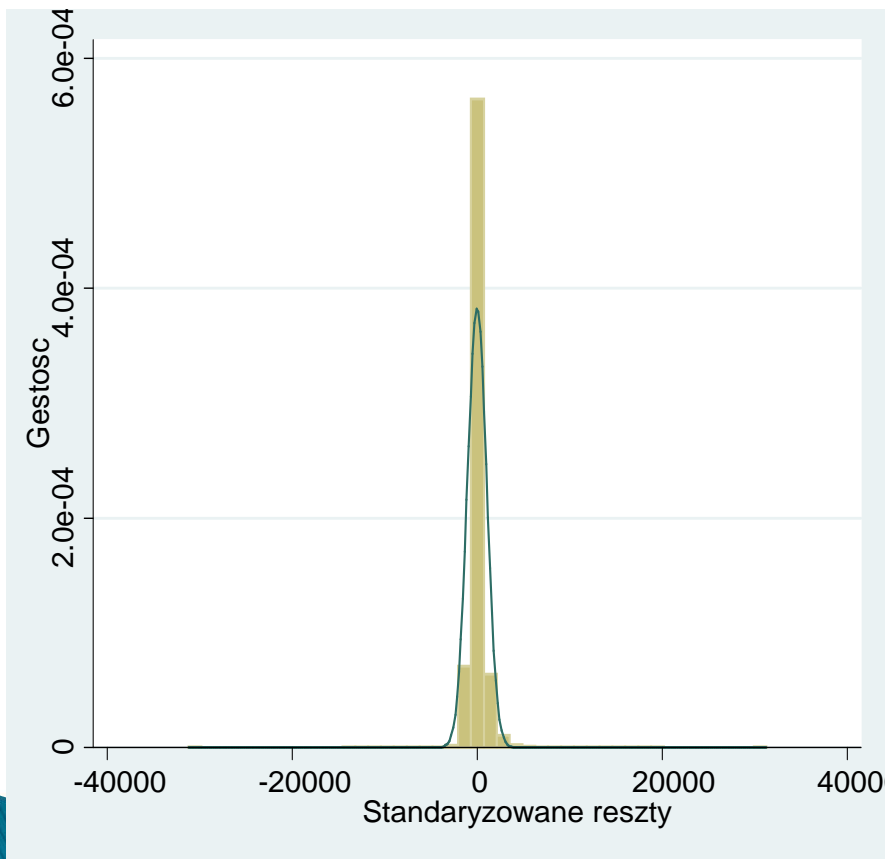
Zastosowanie modelu potęgowego - przykład

Regresja na poziomach i logarytmach:



Zastosowanie modelu potęgowego - przykład

Reszty z regresji:



Plan wykładu

- ▶ 1. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa
- ▶ 2. Zmienne ciągłe za zmienne dyskretne
- ▶ 3. Interpretacja parametrów przy zmiennych dyskretnych



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 $\lambda=0$:

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




Plan wykładu

- ▶ 1. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa
- ▶ 2. Zmienne ciągłe za zmienne dyskretne
- ▶ 3. Interpretacja parametrów przy zmiennych dyskretnych



Zmienne



Zmienne ciągłe

- ▶ Zmienną ciągłą nazywamy zmienną, która przyjmuje wartości ze zbioru liczb rzeczywistych.
- ▶ Zmienne ciągłe są zmiennymi posiadającymi charakter ilościowy
- ▶ Np. dochody, wydatki, cena nieruchomości itd.



Zmienne dyskretne

- ▶ Zmienną dyskretną nazywamy zmienną, która przyjmuje wartości ze skończonego podzbioru liczb naturalnych.
- ▶ Zazwyczaj podzbiór ten jest stosunkowo mało liczny – obejmuje kilka czy kilkanaście elementów.
- ▶ Zmienne dyskretne są zmiennymi posiadającymi charakter jakościowy.
- ▶ np. płeć, wykształcenie, miejsce zamieszkania, stan cywilny i itd.



Plan wykładu

- ▶ 1. Zastosowanie modelu potęgowego
 - Przekształcenie Boxa-Coxa
- ▶ 2. Zmienne ciągłe za zmienne dyskretne
- ▶ 3. Interpretacja parametrów przy zmiennych dyskretnych



Zmienne 0 - 1

- ▶ Zmienną zero-jedynkową nazywamy zmienną, która przyjmuje tylko dwie wartości: 0 lub 1
- ▶ płeć: 1 – kobieta, 0 – mężczyzna
- ▶ praca: 1 – pracujący, 0 – niepracujący
- ▶ obecność dzieci: 1 – nie, 0 – tak
- ▶ Uwaga!
- ▶ Ważne jest, że zmienna przyjmuje dwie wartości, nie ma znaczenia ich wielkość.



Interpretacja przy zmiennej 0 – 1 w modelu liniowym względem zmiennych objaśniających

$$D_i = \begin{cases} 1 & \text{poziombadany} \\ 0 & \text{poziombazowy} \end{cases}$$

- ▶ Niech D_i będzie zmienną zero-jedynkową:

$$y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + \gamma D_i + \varepsilon_i$$

- ▶ Dla $D_i = 1$ model ma postać:

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

- ▶ Dla $D_j = 0$ model ma postać:

$$y_j = \beta_1 + \beta_2 X_{2j} + \dots + \beta_K X_{Kj} + \varepsilon_j$$

- ▶ Zatem $\gamma = E(y_i) - E(y_j)$



Interpretacja przy zmiennej 0 – 1 w modelu liniowym względem zmiennych objaśniających

- ▶ Wniosek:
- ▶ Wielkość γ można interpretować jako zmianę oczekiwanej wartości y , jeśli D zmieni się z 0 na 1, przy założeniu pozostałych charakterystyk na niezmiennym poziomie.



Przykład

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

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

γ – współczynnik przy zmiennej 0-1

INTERPRETACJA: wartość zmiennej zależnej y dla poziomu zmiennej 0-1 $D=1$ jest:

- większa (jeżeli $\hat{\gamma} > 0$) o $|\hat{\gamma}|$ jednostek lub
- mniejsza (jeżeli $\hat{\gamma} < 0$) o $|\hat{\gamma}|$ jednostek

niż wartość zmiennej zależnej y dla poziomu zmiennej 0-1 $D=0$ (dla poziomu bazowego)

Przykład

$$placa_i = \beta_1 + \beta_2 plec_i + \varepsilon_i$$

$$\hat{placa}_i = 926,1 - 503,59 \cdot plec_i$$

▶ Zmienna $plec_i = \begin{cases} 1 & \text{jesli kobieta} \\ 0 & \text{jesli mezczyzna} \end{cases}$

▶ Interpretacja:

Oczekiwany poziom płac kobiet jest średnio o 503,59 złotego niższy niż dla mężczyzn, przy założeniu pozostałych charakterystyk na niezmiennym poziomie.



Przykład

$$placa_i = \beta_1 + \beta_2 sex_i + \varepsilon_i$$

$$\hat{placa}_i = 422,51 + 503,59 \cdot sex_i$$

- ▶ Zmienna $sex_i = \begin{cases} 1 & \text{jesli mezczyzna} \\ 0 & \text{jesli kobieta} \end{cases}$

- ▶ Interpretacja:

Oczekiwany poziom płac mężczyzn jest średnio o 503,59 złotego wyższy niż dla kobiet, przy założeniu pozostałych charakterystyk na niezmiennym poziomie.



Interpretacja przy zmiennej 0 – 1 w modelu, którym zmienna zależna jest zlogarytmowana

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

- ▶ Wniosek:

Wielkość γ (przemnożoną przez 100%)
można interpretować jako procentową zmianę oczekiwanej
wartości zmiennej zależnej y , jeśli D zmieni się z 0 na 1 .



Przykład

$$\ln(placa_i) = \beta_1 + \beta_2 plec_i + \varepsilon_i$$

$$\widehat{\ln(placa_i)} = 7,67 - 0,17 \cdot plec_i$$

▶ Zmienna $plec_i = \begin{cases} 1 & \text{jesli kobieta} \\ 0 & \text{jesli mezczyzna} \end{cases}$

▶ Interpretacja:

Oczekiwany poziom płac kobiet jest średnio o 17% niższy niż dla mężczyzn, przy założeniu pozostałych charakterystyk na niezmiennym poziomie.



Zmienne dyskretne

- ▶ Nieco bardziej skomplikowana jest sytuacja, gdy mamy do czynienia ze zmienną dyskretną która przyjmuje więcej niż 2 wartości.
- ▶ np. **wykształcenie** (1 – podstawowe, 2 – średnie, 3 - wyższe)
- ▶ W tym przypadku do każdego poziomu s zmiennej dyskretnej X_i musimy przypisać jedną zmienną zero-jedynkową $D_{s,i}$

$$D_{s,i} = 1 \text{ gdy } X_i = s$$

$$D_{s,i} = 0 \text{ gdy } X_i \neq s \text{ dla } s = 1, 2, \dots, S$$



Przykład

$$\text{wykształcenie}_i = \begin{cases} 1 & \text{podstawowe} \\ 2 & \text{średnie} \\ 3 & \text{wyzsze} \end{cases}$$

$$\text{podstawowe}_i = \begin{cases} 1 & \text{podstawowe} \\ 0 & \text{w p. p.} \end{cases}$$

$$\text{średnie}_i = \begin{cases} 1 & \text{średnie} \\ 0 & \text{w p. p.} \end{cases}$$

$$\text{wyzsze}_i = \begin{cases} 1 & \text{wyzsze} \\ 0 & \text{w p. p.} \end{cases}$$

Zmienne dyskretne

- ▶ Za **poziom bazowy** uznajemy jeden z poziomów (np. poziom 1), i zmienną zero-jedynkową związaną z tym poziomem usuwamy z modelu **ze stałą**.
- ▶ Np. dla zmiennej wykształcenie
- ▶ Poziom bazowy : wykształcenie podstawowe

$$placa_i = \beta_1 + \beta_2 \text{średnie}_i + \beta_3 \text{wyzsze}_i + \varepsilon_i$$

- ▶ Dlaczego?
Nie jest możliwe, by w modelu była jednocześnie stała i wszystkie zmienne zero-jedynkowe (dla każdego poziomu zmiennej dyskretnej), ponieważ macierz $X^T X$ byłaby osobliwa!



Interpretacja parametrów przy zmiennych dyskretnych

- ▶ Interpretacja współczynników w modelu z wieloma zmiennymi 0-1 (zmiennymi dyskretnymi) jest analogiczna jak w przypadku modelu z jedną tylko taką zmienną:


dany współczynnik opisuje różnicę między oczekiwaną wartością zmiennej y dla respondenta o charakterystyce bazowej i dla respondenta o charakterystyce s .



Przykład

Modelujemy płace za pomocą płci, wieku i wykształcenia:

Zmienna	Współczynniki
Płeć	-0,278
Wiek	0,078
Wykształc. średnie	-0,273
Wykształc. średnie zawodowe	-0,273
Wykształc. zawodowe	-0,444
Wykształc. podstawowe	-0,571
Stała	6,64



Dlaczego rozkodujemy zmienne dyskretne

$$\ln(placa_i) = \beta_1 + \beta_2 plec_i + \beta_3 wykształcenie + \varepsilon_i$$

$$\ln(placa_i) = \beta_1 + \beta_2 plec_i + \beta_3 wykształcenie + \beta_4 wojewodztwo + \varepsilon_i$$



Dziękuję za uwagę

