

# Wybór formy funkcyjnej modelu

## Wykład 5

Natalia Nehrebecka Stanisław Cichocki

6 listopada 2019

# Plan zajęć

- 1 Wybór formy funkcyjnej modelu
  - Sprowadzenie modelu nieliniowego do liniowego
- 2 Interpretacja parametrów
  - Interpretacja parametrów w modelu liniowym
  - Elastyczność
  - Interpretacja parametrów w modelu logliniowym
- 3 Pytania teoretyczne

# Etapy doboru formy funkcyjnej w praktyce

- 1 Dobór formy, tak aby możliwa była odpowiedź na pytanie badawcze
- 2 Szacunek modelu i ocena jakości na podstawie testów diagnostycznych

W praktyce wybiera się tę formę funkcyjną, która jest najstąbiej odrzucana przez testy diagnostyczne.

- Niech

$$y_i = f(\mathbf{x}_i, \theta, \epsilon_i) \quad (1)$$

będzie funkcją **nieliniową**.

- Pod pewnymi warunkami istnieją takie funkcje,  $g$ ,  $h$  i  $\beta$ , że model (1) można sprowadzić do modelu **liniowego**:

$$g(y_i) = h(\mathbf{x}_i)' \beta(\theta) + \epsilon_i \quad (2)$$

- Oznaczając  $g(y_i) = y_i^*$ ,  $h(\mathbf{x}_i) = \mathbf{x}_i^*$  oraz  $\beta(\theta) = \beta^*$  mamy

$$y_i^* = \mathbf{x}_i^* \beta^* + \epsilon_i \quad (3)$$

- Niech

$$y_i = f(\mathbf{x}_i, \theta, \epsilon_i) \quad (1)$$

będzie funkcją **nieliniową**.

- Pod pewnymi warunkami istnieją takie funkcje,  $g$ ,  $h$  i  $\beta$ , że model (1) można sprowadzić do modelu **liniowego**:

$$g(y_i) = h(\mathbf{x}_i)' \beta(\theta) + \epsilon_i \quad (2)$$

- Oznaczając  $g(y_i) = y_i^*$ ,  $h(\mathbf{x}_i) = \mathbf{x}_i^*$  oraz  $\beta(\theta) = \beta^*$  mamy

$$y_i^* = \mathbf{x}_i^* \beta^* + \epsilon_i \quad (3)$$

- Niech

$$y_i = f(\mathbf{x}_i, \theta, \epsilon_i) \quad (1)$$

będzie funkcją **nieliniową**.

- Pod pewnymi warunkami istnieją takie funkcje,  $g$ ,  $h$  i  $\beta$ , że model (1) można sprowadzić do modelu **liniowego**:

$$g(y_i) = h(\mathbf{x}_i)' \beta(\theta) + \epsilon_i \quad (2)$$

- Oznaczając  $g(y_i) = y_i^*$ ,  $h(\mathbf{x}_i) = \mathbf{x}_i^*$  oraz  $\beta(\theta) = \beta^*$  mamy

$$y_i^* = \mathbf{x}_i^* \beta^* + \epsilon_i \quad (3)$$

## Przykład

### Model potęgowy (logliniowy)

$$Y_i = X_{1i}^{\beta_1} X_{2i}^{\beta_2} \dots X_{Ki}^{\beta_K} e^{\epsilon_i} \quad (4)$$

#### Zadanie

Jakie zastosować funkcje, żeby model (4) przekształcić do modelu liniowego?

$$Y_i = X_{1i}^{\beta_1} X_{2i}^{\beta_2} \dots X_{Ki}^{\beta_K} e^{\epsilon_i} \quad | \quad \ln()$$

$$\ln(Y_i) = \ln(X_{1i}^{\beta_1} X_{2i}^{\beta_2} \dots X_{Ki}^{\beta_K} e^{\epsilon_i})$$

$$\ln(Y_i) = \beta_1 \ln(X_{1i}) + \beta_2 \ln(X_{2i}) + \dots + \beta_K \ln(X_{Ki}) + \epsilon_i$$

Niech  $y_i = \ln(Y_i)$  oraz  $x_{ji} = \ln(X_{ji})$ , wtedy mamy:

$$y_i = \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_K x_{Ki} + \epsilon_i$$



# Wniosek

- zależności między zmiennymi ekonomicznymi nie zawsze są liniowe  
*ale*
- model liniowy jest w praktyce wystarczająco dobrym przybliżeniem,  
*zwłaszcza, że*
- za pomocą odpowiednich przekształceń zależność nieliniową można sprowadzić do zależności liniowej względem przekształconych zmiennych

# Wniosek

- zależności między zmiennymi ekonomicznymi nie zawsze są liniowe  
*ale*
- model liniowy jest w praktyce wystarczająco dobrym przybliżeniem,  
*zwłaszcza, że*
- za pomocą odpowiednich przekształceń zależność nieliniową można sprowadzić do zależności liniowej względem przekształconych zmiennych

# Wniosek

- zależności między zmiennymi ekonomicznymi nie zawsze są liniowe  
*ale*
- model liniowy jest w praktyce wystarczająco dobrym przybliżeniem,  
*zwłaszcza, że*
- za pomocą odpowiednich przekształceń zależność nieliniową można sprowadzić do zależności liniowej względem przekształconych zmiennych

- Dobry model dobrze opisuje zjawisko i posiada parametry o intuicyjnie oczywistej interpretacji.
- Interpretacja wyników jest ważna, bo umożliwia porównanie wyników z teorią, zdrowym rozsądkiem, wynikami z innych źródeł itp.

# Efekt cząstkowy

ang. *partial effect*

**Efekt cząstkowy** zmiana oczekiwanego  $y_i$  w reakcji na zmianę  $x_{ki}$ ; wynosi  $\frac{\Delta E(y)}{\Delta x_k}$  przy założeniu, że pozostałe zmienne w modelu nie zmieniają się.

W modelu liniowym

$$E(y_i) = \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_K x_{Ki}$$

o ile zmienne  $x_{1i}, x_{2i}, \dots, x_{Ki}$  oraz parametry  $\beta_1, \beta_2, \dots, \beta_K$  są nielosowe.

Zatem **efekt cząstkowy** dla  $\Delta x_k = 1$  równy jest  $\beta_k$ .

## Wniosek

Parametr  $\beta_k$  w modelu **liniowym** opisuje zmianę oczekiwanej wartości  $y_i$  na skutek jednostkowej zmiany  $x_{ki}$ , przy założeniu, że wszystkie pozostałe zmienne w modelu nie ulegają zmianie (ceteris paribus).

# Przykład

```
. reg w04 dochg if typ==1
```

Source	SS	df	MS
Model	334324900	1	334324900
Residual	5.1186e+09	18326	279307.612
Total	5.4529e+09	18327	297534.578

Number of obs = 18328  
 F( 1, 18326) = 1196.98  
 Prob > F = 0.0000  
 R-squared = 0.0613  
 Adj R-squared = 0.0613  
 Root MSE = 528.5

w04	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
dochg	.069476	.0020081	34.60	0.000	.0655398 .0734121
_cons	285.6029	8.012152	35.65	0.000	269.8983 301.3074

Elastycznością cząstkową nazywamy procentową zmianę oczekiwanego  $y$  w reakcji na 1% zmianę  $x_k$ :

$$e_{y,x_k} = \frac{\Delta E(y)}{E(y)} \bigg/ \frac{\Delta x_k}{x_k} = \frac{\Delta E(y)}{\Delta x_k} \frac{x_k}{E(y)} \approx \frac{\partial E(y)}{\partial x_k} \frac{x_k}{E(y)}$$

ale  $\frac{\partial \ln(\varphi(x))}{\partial \varphi(x)} = \frac{1}{\varphi(x)}$ , stąd  $\frac{\partial \ln E(y)}{\partial E(y)} = \frac{1}{E(y)}$  oraz  $\frac{x_k}{\partial x_k} = \frac{1}{\partial \ln(x_k)}$ , więc:

$$e_{y,x_k} = \frac{\partial \ln(E(y))}{\partial \ln x_k}.$$



W modelu logliniowym

$$\ln E(Y_i) = \beta_1 \ln X_{1i} + \beta_2 \ln X_{2i} + \dots + \beta_K \ln X_{Ki}$$

wtedy

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

o ile zmienne  $x_{1i}, x_{2i}, \dots, x_{Ki}$  oraz parametry  $\beta_1, \beta_2, \dots, \beta_K$  są nielosowe.

## Wniosek

Parametr  $\beta_k$  w modelu **logliniowym** jest elastycznością  $y$  względem  $x_k$ .

# Przykład

```
. reg ln_wydatki_na_mieszkanie ln_dochod if typ=1
```

Source	SS	df	MS
Model	1161.9238	1	1161.9238
Residual	10886.6431	18326	.59405452
Total	12048.5669	18327	.657421669

Number of obs = 18328  
 F( 1, 18326) = 1955.92  
 Prob > F = 0.0000  
 R-squared = 0.0964  
 Adj R-squared = 0.0964  
 Root MSE = .77075

ln_wydatki~e	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ln_dochod	.4716229	.010664	44.23	0.000	.4507205	.4925253
_cons	2.178381	.085701	25.42	0.000	2.010399	2.346363

- 1 Wyjaśnić, co to jest efekt cząstkowy?
- 2 Podaj definicję elastyczności cząstkowej.