

# Testy diagnostyczne

**Stanisław Cichocki**

**Natalia Nehrebecka**

Wykład 11

# Plan wykładu

- ▶ 1. Testy diagnostyczne
  - Testowanie normalności składników losowych: test Jarque-Berra
  - Testowanie stabilności parametrów modelu: test Chowa
- ▶ 2. Heteroskedastyczność
  - Testowanie heteroskedastyczności

# Plan wykładu

- ▶ 1. Testy diagnostyczne
  - Testowanie normalności składników losowych: test Jarque-Berra
  - Testowanie stabilności parametrów modelu: test Chowa
- ▶ 2. Heteroskedastyczność
  - Testowanie heteroskedastyczności

# Testy diagnostyczne

▶ Dla każdego testu:

1. Nazwa testu
2. Hipotezy
3. Jakie założenie KMRL nie jest spełnione w przypadku odrzucenia  $H_0$ ?
4. Jakie są konsekwencje niespełnienia założenia KMRL?
5. W jaki sposób można rozwiązać problemy zasygnalizowane przez wynik testu?

# Testowanie normalności składników losowych

- Test Jarque – Bera (Test JB):

$$H_0 : \varepsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$$

- składnik los. ma rozkład normalny

$$H_1 : \varepsilon \not\sim N(\mathbf{0}, \sigma^2 \mathbf{I})$$

- składnik los. nie ma rozkładu normalnego

# Testowanie normalności składników losowych

► Sposób przeprowadzenia testu:

1. estymujemy model:  $y_i = x_i\beta + \varepsilon_i$  i uzyskujemy reszty

2. liczymy współczynnik skośności i kurtozę dla rozkładu reszt:

$$\hat{\Theta}_1^\Lambda = \frac{\sum_{i=1}^N e_i^3 / N}{\hat{\sigma}^\Lambda^3}$$

$$\hat{\Theta}_2^\Lambda = \frac{\sum_{i=1}^N e_i^4 / N}{\hat{\sigma}^\Lambda^4}$$

gdzie  $\hat{\sigma}^\Lambda = \sqrt{\frac{\sum_{i=1}^N e_i^2}{N}}$

# Testowanie normalności składników losowych

▶ Sposób przeprowadzenia testu:

3. Porównujemy wielkość skośności i kurtozy uzyskanych z rozkładu reszt z oczekiwanymi wielkościami tych statystyk dla rozkładu normalnego :

$$\Theta_1 = 0$$

$$\Theta_2 = 3$$

statystyka testowa:  $LM = N \left[ \frac{\hat{\Theta}_1}{6} + \frac{(\hat{\Theta}_2 - 3)^2}{24} \right] \xrightarrow{D} \chi^2$

# Testowanie normalności składników losowych

## ► Przykład

xi: reg wydg dochg i.klm


Source	SS	df	MS	
Model	2.3693e+10	6	3.9489e+09	Number of obs = 31705
Residual	3.4278e+10	31698	1081405.34	F( 6, 31698) = 3651.59
Total	5.7971e+10	31704	1828523.21	Prob > F = 0.0000

R-squared = 0.4087  
Adj R-squared = 0.4086  
Root MSE = 1039.9

wydg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
dochg	.5818533	.0040164	144.87	0.000	.573981	.5897256
_Ik1m_2	-40.65607	23.26644	-1.75	0.081	-86.2592	4.947067
_Ik1m_3	-70.57179	25.89099	-2.73	0.006	-121.3191	-19.82444
_Ik1m_4	-109.2499	20.60656	-5.30	0.000	-149.6395	-68.86021
_Ik1m_5	-153.3497	22.98153	-6.67	0.000	-198.3944	-108.305
_Ik1m_6	-173.5506	18.96167	-9.15	0.000	-210.7162	-136.385
_cons	836.1774	18.74554	44.61	0.000	799.4354	872.9194



# Testowanie normalności składników losowych



# Testowanie normalności składników losowych

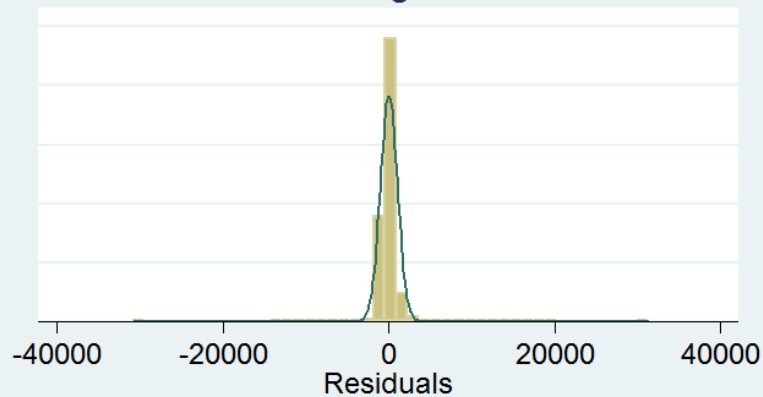
Skewness/Kurtosis tests for Normality

Variable	Obs	Pr(Skewness)	Pr(Kurtosis)	----- joint ----- chi2(2)	Prob>chi2
e	3.2e+04	0.0000	0.0000	34060.88	0.0000


# Testowanie normalności składników losowych

## Analiza Graficzna Reszt

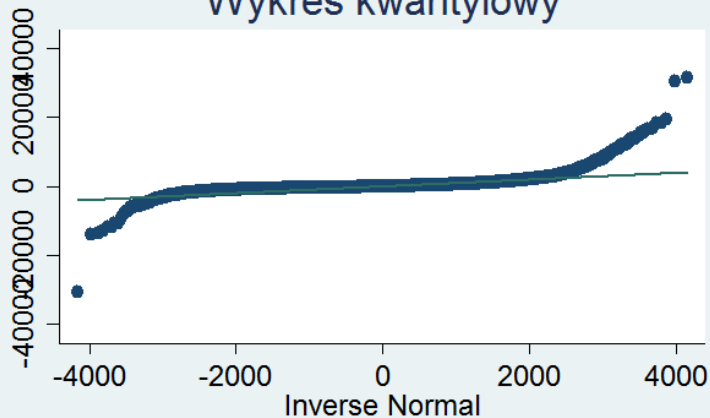
Histogram




Wykres pudełkowy



Wykres kwantylowy



Wykres prawdopodobieństwa



## Jakie założenie KMRL nie jest spełnione przy odrzuceniu $H_0$ ?

- ▶ Niespełnione dodatkowe założenie o tym, że składnik losowy ma rozkład normalny

# Jakie są skutki niespełnienia założenia KMRL

- ▶ **Próba duża:** rozkłady statystyk są bliskie standardowym rozkładom
- ▶ **Mała próba:** jest problemem, gdyż:
  - To założenie jest niezbędne do wyprowadzenia rozkładów statystyk testowych oraz prawidłowego wnioskowania statystycznego.
  - Estymator  $b$  uzyskany metodą MNK jest najlepszym estymatorem wśród *liniowych i nieobciążonych* estymatorów  $\longrightarrow$  można znaleźć estymator *nieliniowy i nieobciążony* o wariancji mniejszej niż estymator  $b$

# Testowanie stabilności parametrów

## Test Chowa:


Służy do weryfikacji czy parametry modelu będą takie same dla kilku różnych próbek

Założmy, że modele dla próbek:  $y_s = X_s \beta_s + \varepsilon_s$   
gdzie  $s=1, \dots, m$  oznacza numer próbki.

$H_0 : \beta_1 = \beta_2 = \dots = \beta_m$  - parametry są takie same w próbkach

$H_1 : \beta_r \neq \beta_s$   
dla pewnych  $r$  i  $s$  - parametry różnią się w próbkach

# Testowanie stabilności parametrów - dla próby przekrojowej



# Testowanie stabilności parametrów

Sposób przeprowadzania testu:

1. przeprowadzamy regresję na całej próbie (bez zmiennej wyodrębniającej podpróbki);
2. przeprowadzamy regresję na każdej z próbek;
3. obliczamy statystkę:

$$F = \frac{(S - \sum_{s=1}^m S_j) / [K(m-1)]}{\sum_{s=1}^m S_j / (N - mK)} \sim F(K(m-1), N - mK)$$



# Testowanie stabilności parametrów

Gdzie:

$S$  – suma kwadratów reszt z regresji na całej próbie;

$S_j$  – suma kwadratów reszt z regresji na j-tej podpróbie;

$m$  - liczba podprób;

$K$  - liczba szacowanych parametrów;

$N$  - liczba obserwacji

# Jakie założenie KMRL nie jest spełnione przy odrzuceniu $H_0$ ?

- ▶ Związek pomiędzy zmienną zależną a zmiennymi niezależnymi opisany jest równaniem:

$$y_i = \beta_1 + \beta_2 x_{2i} + \beta_3 x_{3i} + \cdots + \beta_K x_{Ki} + \varepsilon_i \quad i = 1, 2, 3, \dots, n$$

# Jakie są skutki niespełnienia założenia KMRL

Odrzucenie hipotezy zerowej o tym, że parametry są stabilne

- podważa interpretacje ekonomiczną modelu (interpretacja oszacowanych parametrów)
- niemożliwe udowodnienie własności estymatora MNK (nieobciążoność czy efektywność estymatora MNK )

# W jaki sposób można rozwiązać problemy zasygnalizowane przez wynik testu?

- ▶ Problem niestabilności parametrów można rozwiązać poprzez:
  - wprowadzenie do modelu interakcji pomiędzy zmiennymi 0-1 związanymi z podziałem na grupy a odpowiednimi zmiennymi objaśniającymi (w przypadku gdy jedynie część parametrów jest różna dla analizowanych podprób)
  - estymacje osobnych regresji na wyodrębnionych podpróbach

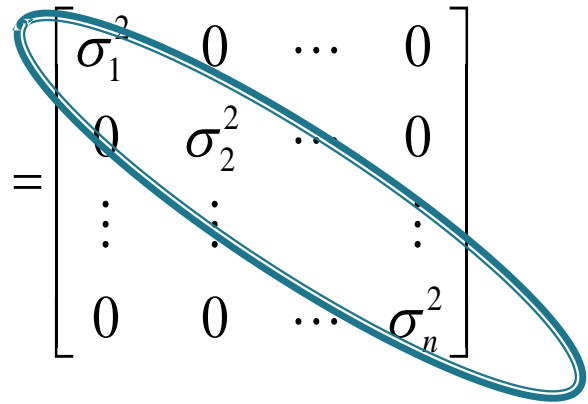
# Plan wykładu

- ▶ 1. Testy diagnostyczne
  - Testowanie normalności składników losowych: test Jarque-Berra
  - Testowanie stabilności parametrów modelu: test Chowa
- ▶ 2. Heteroskedastyczność
  - Testowanie heteroskedastyczności

# Heteroskedastyczności


Przypomnienie: Co to znaczy, że w modelu występuje homoskedastyczność/heteroskedastyczność?

## - Heteroskedastyczność

$$\text{Var}(\varepsilon) = \begin{bmatrix} \text{Var}(\varepsilon_1) & \text{Cov}(\varepsilon_1, \varepsilon_2) & \cdots & \text{Cov}(\varepsilon_1, \varepsilon_n) \\ \text{Cov}(\varepsilon_2, \varepsilon_1) & \text{Var}(\varepsilon_2) & \cdots & \text{Cov}(\varepsilon_2, \varepsilon_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(\varepsilon_n, \varepsilon_1) & \text{Cov}(\varepsilon_n, \varepsilon_1) & \cdots & \text{Var}(\varepsilon_n) \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_n^2 \end{bmatrix}$$


# Heteroskedastyczność

- ▶ Stałość wariancji zaburzeń nazywamy **homoskedastycznością zaburzeń**. Oznacza to, że zaburzenia losowe są **jednakowo rozproszone wokół zerowej wartości oczekiwanej**. Jeśli wariancje nie byłyby jednakowe, to sytuację taką nazywamy **heteroskedastycznością**.




Rys.1. Heteroskedastyczność

# Heteroskedastyczność

Oznacza to, że zaburzenia losowe są jednakowo rozproszone wokół zerowej wartości oczekiwanej.




**Homoskedastyczność:** reszty zachowują się losowo.



**Heteroskedastyczność:** Wariancja reszt zmienia się wraz ze zmianą zmiennej niezależnej X.



# Heteroskedastyczność



# Heteroskedastyczność



# Testowanie heteroskedastyczności

- ▶ Test Goldfelda-Quandta – **samodzielnie**:
  - Można go stosować do wykrywania zależności między wariancją błędu losowego a wielkością jednej zmiennej
  - Jako jedyny z testów na heteroskedastyczność ma rozkład wyprowadzony dla **małych prób**

# Testowanie heteroskedastyczności

- Test Breuscha-Pagana (Test BP):

$$H_0 : \text{Var}(\varepsilon_i) = \sigma^2 \quad \text{dla } i = 1, \dots, N$$

$$H_1 : \text{Var}(\varepsilon_i) = \sigma_i^2 = \sigma^2 f(\alpha_0 + z_i \alpha)$$

gdzie  $f(\bullet)$  - funkcja różniczkowalna

$z_i$  - wektor zmiennych, może zawierać zmienne występujące w wektorze zmiennych objaśniających

# Testowanie heteroskedastyczności

- ▶ Test Breuscha-Pagana (Test BP):
  - Hipoteza zerowa: homoskedastyczność
  - Hipoteza alternatywna: heteroskedastyczność
  - Szczególnie przydatny, jeżeli wariancja błędu losowego zależy od kilku zmiennych

# Testowanie heteroskedastyczności

- ▶ Test Breusch-Pagana (Test BP) – sposób przeprowadzenia testu:

1. przeprowadzamy regresję  $y_i$  na  $x_i$  i uzyskujemy  $e_i$

2. przeprowadzamy regresję pomocniczą:

$$\frac{e_i^2}{\hat{\sigma}^2} = \alpha_0 + z_i \alpha + u_i$$

i testujemy  $H_0: \alpha = 0$

# Testowanie heteroskedastyczności

- ▶ Statystyka testowa:

$$LM = \frac{1}{2} ESS \xrightarrow{D} \chi_p^2$$

gdzie: ESS – wyjaśniona suma kwadratów w regresji pomocniczej

p- ilość zmiennych zawartych w  $Z$

# Testowanie heteroskedastyczności

- ▶ Inna statystyka testowa:

$$LM = NR^2 \xrightarrow{D} \chi_p^2$$

gdzie:  $R^2$  - współczynnik determinacji z regresji pomocniczej



# Testowanie heteroskedastyczności

- ▶ Szczególną postacią testu BP jest test White'a  $\longrightarrow z_i$  zawiera wszystkie kwadraty i iloczyny krzyżowe zmiennych objaśniających
- ▶ Stosujemy gdy interesuje nas samo wykrycie heteroskedastyczności a mniej wykrycie zmiennych, od których zależy wariancja błędu losowego

# Testowanie heteroskedastyczności

- ▶ Test Breuscha-Pagana i test White'a są bardziej uniwersalne niż test Goldfelda-Quandta
- ▶ Jednak statystyki testowe dla testu Breuscha-Pagana i testu White'a są znane tylko dla dużych prób

# Jakie założenie KMRL nie jest spełnione przy odrzuceniu $H_0$ ?

- ▶ Homoskedastyczność składnika losowego – wariancja błędu losowego jest stała dla wszystkich obserwacji:

$$\text{Var}(\varepsilon_i) = \sigma^2 \quad \text{dla } i = 1, 2, \dots, N$$

# Testowanie heteroskedastyczności

## ▶ Przykład

xi: reg wydg dochg i.klm

Source	SS	df	MS			
Model	2.3693e+10	6	3.9489e+09	Number of obs	=	31705
Residual	3.4278e+10	31698	1081405.34	F( 6, 31698)	=	3651.59
Total	5.7971e+10	31704	1828523.21	Prob > F	=	0.0000
				R-squared	=	0.4087
				Adj R-squared	=	0.4086
				Root MSE	=	1039.9

wydg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
dochg	.5818533	.0040164	144.87	0.000	.573981	.5897256
_Ik1m_2	-40.65607	23.26644	-1.75	0.081	-86.2592	4.947067
_Ik1m_3	-70.57179	25.89099	-2.73	0.006	-121.3191	-19.82444
_Ik1m_4	-109.2499	20.60656	-5.30	0.000	-149.6395	-68.86021
_Ik1m_5	-153.3497	22.98153	-6.67	0.000	-198.3944	-108.305
_Ik1m_6	-173.5506	18.96167	-9.15	0.000	-210.7162	-136.385
_cons	836.1774	18.74554	44.61	0.000	799.4354	872.9194

# Testowanie heteroskedastyczności

## ▶ Przykład

Breusch-Pagan / Cook-Weisberg test for heteroskedasticity

Ho: Constant variance

Variables: fitted values of wydg

chi2(1) = 129088.50

Prob > chi2 = 0.0000

White's test for Ho: homoskedasticity

against Ha: unrestricted heteroskedasticity

chi2(12) = 6142.84

Prob > chi2 = 0.0000

# Pytania teoretyczne

1. Za pomocą jakiego testu weryfikowana jest normalność składnika losowego? Jakiemu założeniu KMRL odpowiada  $H_0$  w tym teście? Jaka jest hipoteza alternatywna w tym teście? Jakie są konsekwencje dla własności MNK, jeśli  $H_0$  jest fałszywe?
2. Za pomocą jakiego testu testowana jest stabilność parametrów? Jakiemu założeniu KMRL odpowiada  $H_0$  w tym teście? Jaka jest hipoteza alternatywna w tym teście?

# Pytania teoretyczne

3. Za pomocą jakich testów można testować heteroskedastyczność? Jakiemu założeniu KMRL odpowiada  $H_0$  w tych testach? Jakie są hipotezy alternatywne w tych testach?

**Dziękuję za uwagę**