

# Testy diagnostyczne

**Stanisław Cichocki**

**Natalia Nehrebecka**

Wykład 12

# Plan wykładu

- ▶ 1. Testy diagnostyczne
  - Testowanie stabilności parametrów modelu: test Chowa
  - Testowanie heteroskedastyczności

# Testowanie stabilności parametrów

## - Test Chowa:

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


$$H_0 : \beta_1 = \beta_2 = \dots = \beta_m$$

- parametry są takie same w próbkach

$$H_1 : \beta_r \neq \beta_s$$


- parametry różnią się w próbkach

# Testowanie stabilności parametrów - dla próby przekrojowej



Rysunek 4: Podgrupy o podobnej wielkości

# Testowanie stabilności parametrów – dla szeregu czasowego



Rysunek 3: Załamanie w parametrach trendu liniowego

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

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

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

# 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?

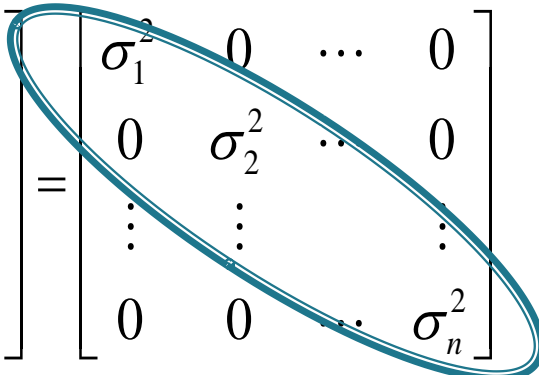
- ▶ Problem niestabilności parametrów można rozwiązać poprzez:
  - wprowadzenie do modelu interakcji pomiędzy zmiennymi 0-1 związanymi z podziałem na grupy a odpowiednimi zmiennymi objaśniającymi (w przypadku gdy jedynie część parametrów jest różna dla analizowanych podprób)
  - estymacje osobnych regresji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



# Testowanie heteroskedastyczności


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

- heteroskedastyczność

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


# Heteroscedastyczność

- ▶ 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.

# Założenia klasycznego modelu regresji liniowej

- ▶ Regresja wydatków na dochodzie



# Testowanie heteroskedastyczności

- Test Goldfelda-Quandta (Test GQ):

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

$$H_1 : Var(\varepsilon_i) > Var(\varepsilon_j) \quad \text{dla } z_i > z_j \quad \text{gdzie } z \text{ jest pewną zmienną, od której zależy wariancja błędu losowego}$$

- Hipoteza zerowa: homoskedastyczność

Hipoteza alternatywna: heteroskedastyczność

# Testowanie heteroskedastyczności

- ▶ Test Goldfelda-Quandta (Test GQ):
  - z jego konstrukcji wynika, iż 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 BP i White'a są bardziej uniwersalne niż test GQ jednak rozkłady statystyk testowych dla tych testów 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



**Dziękuję za uwagę**