

Testy diagnostyczne Autokorelacja Heteroskedastyczność

Stanisław Cichocki

Natalia Nehrebecka

Wykład 13

Plan wykładu

- ▶ 1. Autokorelacja
 - Konsekwencje
 - Testowanie autokorelacji
- ▶ 2. Metody radzenia sobie z heteroskedastycznością i autokorelacją
 - Uogólniona Metoda Najmniejszych Kwadratów (UMNK)
 - Stosowalna Uogólniona Metoda Najmniejszych Kwadratów (SUMNK)
 - Odporne macierze wariancji i kowariancji

Plan wykładu

- ▶ 1. Autokorelacja
 - Konsekwencje
 - Testowanie autokorelacji
- ▶ 2. Metody radzenia sobie z heteroskedastycznością i autokorelacją
 - Uogólniona Metoda Najmniejszych Kwadratów (UMNK)
 - Stosowalna Uogólniona Metoda Najmniejszych Kwadratów (SUMNK)
 - Odporne macierze wariancji i kowariancji

Autokorelacja


Przypomnienie: Co to znaczy, że w modelu występuje autokorelacja?

-Brak autokorelacji

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

Autokorelacja

- ▶ Przypadek zerowych kowariancji dla różnych zaburzeń losowych ε_i oraz ε_j nazywamy **brakiem autokorelacji zaburzeń**. Oznacza to, że **zaburzenia losowe dla różnych obserwacji są niezależne**, a przez to nieskorelowane, a więc nie mają tendencji do gromadzenia się np. wokół dodatnich lub ujemnych (lub naprzemiennie dodatnich i ujemnych) wartości



Rys. 2. Autokorelacja

Autokorelacja

$Cov(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \varepsilon_j) > 0$ dla $i \neq j$ - dodatnia autokorelacja

$Cov(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \varepsilon_j) < 0$ dla $i \neq j$ - ujemna autokorelacja

Sferyczność błędów losowych

- ▶ Jeżeli założenie o homoskedastyczności i autokorelacji jest spełnione to błędy losowe są **sferyczne**
- ▶ Jeżeli, któreś z tych założeń nie jest spełnione to błędy losowe są **niesferyczne** a macierz wariancji i kowariancji ma postać dowolnej macierzy symetrycznej i dodatnio półokreślonej:

$$\text{Var}(\varepsilon) = \Omega = \sigma^2 V$$

Konsekwencje autokorelacji

- Estymator b jest nadal **nieobciążony**:

$$\begin{aligned} E(b) &= E\left[(X'X)^{-1}X'y\right] = \\ &E\left[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon\right] = \\ &\beta + (X'X)^{-1}X'E(\varepsilon) = \beta \end{aligned}$$

- Nie będzie on jednak **efektywny** \longrightarrow można znaleźć estymator o mniejszej wariancji

Konsekwencje autokorelacji

- Macierz wariancji i kowariancji b :

$$\begin{aligned} \text{Var}(b) &= E\left((X'X)^{-1}X'\varepsilon\varepsilon'X(X'X)^{-1}\right) = \\ &(X'X)^{-1}X'\Omega X(X'X)^{-1} = \\ &\sigma^2(X'X)^{-1}X'VX(X'X)^{-1} \end{aligned}$$

- Wzór ten różni się znacznie od prawidłowego wzoru na wariancję MNK:

$$\text{Var}(b) = \sigma^2(X'X)^{-1}$$

Konsekwencje autokorelacji

- W rezultacie estymator macierzy wariancji i kowariancji b , którym posługiwaliśmy się do tej pory, nie będzie dobrym oszacowaniem macierzy wariancji i kowariancji b

Testowanie autokorelacji

- Test Durbina-Watsona (Test DW):

$$H_0 : Cov(\varepsilon_t, \varepsilon_{t-1}) = 0 \quad \text{- brak autokorelacji}$$

$$H_1 : Cov(\varepsilon_t, \varepsilon_{t-1}) \neq 0 \quad \text{- autokorelacja}$$

gdzie $t = 1, \dots, T$

Testowanie autokorelacji

- **Test Durbina-Watsona (Test DW):**

- specjalne tablice z wartościami krytycznymi: d_l, d_u

1. Statystyka $DW < 2$

a) $DW < d_l$ odrzucamy hipotezę zerową o braku autokorelacji i przyjmujemy hipotezę o dodatniej autokorelacji

b) $d_l < DW < d_u$ - brak konkluzji

c) $DW > d_u$ - nie ma podstaw do odrzucenia hipotezy zerowej o braku autokorelacji


Testowanie autokorelacji

- Test Durbina-Watsona (Test DW):

2. Statystyka DW > 2

- a) $DW > 4 - d_l$ - odrzucamy hipotezę zerową o braku autokorelacji i przyjmujemy hipotezę o ujemnej autokorelacji
- b) $4 - d_u < DW < 4 - d_l$ - brak konkluzji
- c) $DW < 4 - d_u$ - nie ma podstaw do odrzucenia hipotezy zerowej o braku autokorelacji

Testowanie autokorelacji



Testowanie autokorelacji

- ▶ Test Durbina-Watsona (Test BW):
 - Do badania autokorelacji I rzędu (między $\varepsilon_t, \varepsilon_{t-1}$)
 - Rozkład statystyki testowej wyprowadzony dla małych prób
 - Nie można go stosować w modelach gdzie jedną ze zmiennych objaśniających jest opóźniona zmienna zależna
 - Wada: niestandardowy rozkład i możliwość wystąpienia braku konkluzji

Testowanie autokorelacji

- ▶ Test Breuscha-Godfrey (Test BG):
 - Do badania autokorelacji wyższego rzędu
 - Można go stosować w modelach gdzie występują opóźnione zmienne zależne

Testowanie autokorelacji

- Test Breuscha-Godfrey (Test BG):

$$H_0 : Cov(\varepsilon_t, \varepsilon_{t-i}) = 0 \quad \text{gdzie} \quad i = 1, \dots, s$$

$$H_1 : \varepsilon_t = \gamma_1 \varepsilon_{t-1} + \dots + \gamma_s \varepsilon_{t-s} + u_t \quad \text{gdzie} \quad Var(u) = \sigma_u^2 I$$

- Hipoteza zerowa: brak autokorelacji
- Hipoteza alternatywna: autokorelacja

Testowanie autokorelacji

- ▶ Test Breuscha-Godfrey (Test BG) – sposób przeprowadzenia testu:

1. przeprowadzamy regresję y_i na x_i i uzyskujemy reszty

2. przeprowadzamy regresję pomocniczą:

$$e_t = x_t \mu + \gamma_1 e_{t-1} + \dots + \gamma_s e_{t-s} + u_t$$

i testujemy $H_0: \gamma_1 = \dots = \gamma_s = 0$

Testowanie autokorelacji

- ▶ Statystyka testowa:

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

lub statystyka F

Jakie założenie KMRL nie jest spełnione przy odrzuceniu H_0 ?

- ▶ Brak autokorelacji błędu losowego – kowariancja dwóch różnych błędów losowych jest zerowa:

$$\text{cov}(\varepsilon_i, \varepsilon_j) = 0 \quad \text{dla } i \neq j$$

Plan wykładu

- ▶ 1. Autokorelacja
 - Konsekwencje
 - Testowanie autokorelacji
- ▶ 2. Metody radzenia sobie z heteroskedastycznością i autokorelacją
 - Uogólniona Metoda Najmniejszych Kwadratów (UMNK)
 - Stosowalna Uogólniona Metoda Najmniejszych Kwadratów (SUMNK)
 - Odporne macierze wariancji i kowariancji

UMNK

- ▶ Jednym z możliwych sposobów rozwiązania problemu niesferyczności błędu losowego \longrightarrow oszacowanie macierzy wariancji błędu losowego
- ▶ Zastosowana metoda estymacji jest uogólnieniem MNK dla przypadku, gdy błędy losowe są niesferyczne
- ▶ Taki uogólniony estymator można uzyskać bezpośrednio z zadania na minimalizację sumy kwadratów reszt
- ▶ Wyprowadzimy go sprowadzając model uogólniony do KMRL

UMNK

- ▶ Założenia analogiczne do KMRL, ale różniące się brakiem założenia o homoskedastyczności i autokorelacji:

1. Model jest liniowy: $y = X\beta + \varepsilon$

2. X jest nielosowe

3. $E(\varepsilon) = 0$

4. $Var(\varepsilon) = \Omega = \sigma^2 V$, gdzie V jest znana

UMNK

- ▶ Dla dodatnio określonej i symetrycznej macierzy V można zawsze znaleźć taką nieosobliwą macierz z elementami rzeczywistymi, L że

$$LVL' = I$$

$$V = L^{-1}L^{-1'}$$

$$L'L = V^{-1}$$

UMNK

- ▶ Mnożąc, $y = X\beta + \varepsilon$ przez L :

$$Ly = LX\beta + L\varepsilon$$

- ▶ Definiujemy nowe zmienne, będące przekształceniem zmiennych pierwotnych:

$$y^* = X^*\beta + \varepsilon^*$$

UMNK

- ▶ Wariancja ε^* :

$$\text{Var}(\varepsilon^*) = \text{Var}(L\varepsilon) = L\text{Var}(\varepsilon)L' = \sigma^2 LVL' = \sigma^2 I$$

- ▶ Błędy losowe są homosekdstyczne i nieskorelowane.
- ▶ Model przekształcony będzie spełniał wszystkie założenia KMRL
 —————▶ prawdziwe są wszystkie wnioski na temat własności MNK

UMNK

- ▶ Estymator Ugólnionej Metody Najmniejszych Kwadratów (Generalized Least Squares – GLS):

$$\begin{aligned} b_{UMNK} &= (X^* ' X^*)^{-1} X^* ' y^* = [(LX)'(LX)]^{-1} (LX)' Ly \\ &= (X ' L' LX)^{-1} X ' L' Ly = (X ' V^{-1} X)^{-1} X ' V^{-1} y \\ &= (X ' \Omega^{-1} X)^{-1} X ' \Omega^{-1} y \end{aligned}$$

UMNK

- ▶ Macierz wariancji kowariancji estymatora b_{UMNK}

$$\begin{aligned} \text{Var}(b_{UMNK}) &= \sigma^2 (X^* ' X^*)^{-1} = \sigma^2 [(LX)'(LX)]^{-1} \\ &= \sigma^2 (X ' L' LX)^{-1} = \sigma^2 (X ' V^{-1} X)^{-1} = (X ' \Omega^{-1} X)^{-1} \end{aligned}$$

UMNK

- ▶ Reszty w przypadku estymatora UMNK:


$$y - \hat{y} = y - Xb_{UMNK} = e_{UMNK}$$

UMNK

- ▶ Estymator s^2 :

$$\begin{aligned} s_{UMNK}^2 &= \frac{e^*{}' e^*}{N - K} = \frac{(y^* - X^* b_{UMNK})' (y^* - X^* b_{UMNK})}{N - K} \\ &= \frac{(y - X b_{UMNK})' V^{-1} (y - X b_{UMNK})}{N - K} = \frac{e'_{UMNK} V^{-1} e_{UMNK}}{N - K} \end{aligned}$$

UMNK

- ▶ Model przekształcony będzie spełniał wszystkie założenia KMRL 
estymator UMNK ma wszystkie własności estymatora MNK
- ▶ Przy założeniu normalności rozkładu reszt sposób testowania hipotez w UMNK jest identyczny jak w MNK

UMNK

- ▶ Prawdziwe będzie też uogólnienie twierdzenia Gaussa Markowa:

Twierdzenie Aitkena: Estymator Uogólnionej Metody Najmniejszych Kwadratów jest najlepszym, liniowym i nieobciążonym estymatorem parametru β o ile macierz Ω lub macierz V jest znana.

Problem: prawie nigdy nie znamy V

UMNK

- ▶ Jednym z przypadków kiedy forma macierzy wariancji jest znana
 ➔ Ważona Metoda Najmniejszych Kwadratów
- ▶ W modelu występuje jedynie heteroskedastyczność:

$$\Omega = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_n^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} v_1 & 0 \\ 0 & v_n \end{bmatrix} = \sigma^2 V$$

UMNK

- ▶ Zakładając, że v_i są znane:

$$L = \begin{bmatrix} \frac{1}{\sqrt{v_1}} & 0 \\ 0 & \frac{1}{\sqrt{v_n}} \end{bmatrix}$$

UMNK

- ▶ Można pokazać, iż stosując macierz \mathbf{L} :

$$y_i^* = \frac{y_i}{\sqrt{v_i}}$$

$$x_{k,i}^* = \frac{x_{k,i}}{\sqrt{v_i}}$$

- ▶ v_i - można traktować jako wagi przypisywane obserwacjom

UMNK

- ▶ Im wyższa wariancja błędu losowego, tym niższą wagę przypisujemy obserwacjom

SUMNK

- ▶ Gdy elementy macierzy V są nieznane \longrightarrow używamy estymatora UMNK zastępując V oszacowaniem \hat{V}
 \longrightarrow metoda ta to Stosowalna Uogólniona Metoda Najmniejszych Kwadratów (Feasible Generalized Least Squares)

SUMNK

- ▶ Istota: budujemy dodatkowy model dla wariacji i kowariancji tak aby znaleźć funkcję $\Omega(\Theta)$, taką że:

$$\Omega = \Omega(\Theta)$$

i

$$\text{wymiar } \Theta \ll N$$

W takim wypadku szacowanie Ω sprowadza się do szacowania Θ

a estymatorem Ω będzie $\hat{\Omega} = \Omega(\hat{\Theta})$

SUMNK

▶ Etapy estymacji za pomocą SUMNK:

1. Szacujemy model za pomocą MNK uzyskując b_{MNK}
2. Na podstawie wektora reszt szacujemy model pomocniczy, z którego otrzymujemy oszacowania $\hat{\Theta}$ (oszacowania te oznaczamy jako $\hat{\Theta}$)
3. Powtórnie szacujemy parametry modelu stosując estymator UMNK, nieznaną macierz Ω zastępujemy jej oszacowaniem

$$\hat{\Omega} = \Omega(\hat{\Theta})$$

SUMNK

4. Uzyskany estymator SUMNK:

$$b_{SUMNK} = [X' \hat{\Omega}^{-1} X]^{-1} X' \hat{\Omega}^{-1} y$$

Odporne estymatory macierzy wariancji i kowariancji

- ▶ Bazują na formie macierzy wariancji estymatora b_{MNK} dla niesferycznych błędów losowych

$$\text{Var}(b_{MNK}) = \frac{1}{N} \left(\frac{1}{N} X'X \right)^{-1} \left(\frac{1}{N} X' \Omega X \right) \left(\frac{1}{N} X'X \right)^{-1}$$

- ▶ Konkretna postać estymatorów odpornych macierzy wariancji zależy od tego, czy w modelu występuje jedynie heteroskedastyczność, czy też autokorelacja

Odporne estymatory macierzy wariancji i kowariancji

- ▶ Najpopularniejszym odpornym na heteroskedastyczność estymatorem macierzy wariancji i kowariancji **b** jest estymator White'a
- ▶ Umożliwia przeprowadzenie wnioskowania statystycznego bez konieczności szacowania modelu dla wariancji i kowariancji
- ▶ Znacznie łatwiejszy w stosowaniu niż SUMNK

Odporne estymatory macierzy wariancji i kowariancji

```
reg wydg dochg los
```

Source	SS	df	MS			
Model	2.3877e+10	2	1.1938e+10	Number of obs =	31705	
Residual	3.4095e+10	31702	1075469.35	F(2, 31702) =	11100.72	
Total	5.7971e+10	31704	1828523.21	Prob > F =	0.0000	
				R-squared =	0.4119	
				Adj R-squared =	0.4118	
				Root MSE =	1037	

wydg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
dochg	.5683134	.0041262	137.73	0.000	.5602259	.576401
los	65.12119	3.858651	16.88	0.000	57.55809	72.6843
_cons	550.8444	13.90437	39.62	0.000	523.5913	578.0976

Odporne estymatory macierzy wariancji i kowariancji

Breusch-Pagan / Cook-Weisberg test for heteroskedasticity

Ho: Constant variance

Variables: fitted values of wydg

chi2(1) = 121623.16

Prob > chi2 = 0.0000

White's test for Ho: homoskedasticity

against Ha: unrestricted heteroskedasticity

chi2(5) = 5700.95

Prob > chi2 = 0.0000

Odporne estymatory macierzy wariancji i kowariancji

```
reg wydg dochg los, robust
```

Linear regression

```
Number of obs = 31705  
F( 2, 31702) = 1785.95  
Prob > F      = 0.0000  
R-squared     = 0.4119  
Root MSE     = 1037
```

		Robust				
wydg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
dochg	.5683134	.0319817	17.77	0.000	.505628	.6309989
los	65.12119	8.640123	7.54	0.000	48.18621	82.05617
_cons	550.8444	40.10087	13.74	0.000	472.2452	629.4437

Odporne estymatory macierzy wariancji i kowariancji

- ▶ Estymator Newey'a-Westa macierzy wariancji i kowariancji
 ➔ gdy w modelu występuje heteroskedastyczność i autokorelacja

Pytania teoretyczne

1. Za pomocą jakich testów testuje się autokorelację? Jakiemu założeniu KMRL odpowiada H_0 w tych testach? Jakie są hipotezy alternatywne w tych testach?
2. (*) Podać postać analityczną testu Durbina-Watsona i postać regresji pomocniczej w przypadku testu Breusch-Godfrey.
3. Pokazać, w jaki sposób można, w przypadku znanej macierzy Ω , sprowadzić model z niesferycznymi błędami losowymi do modelu spełniającego założenia KMRL.
4. (*) Wyjaśnić do czego powinny być proporcjonalne wagi w Ważonej Metodzie Najmniejszych Kwadratów. Odpowiedź uzasadnić.

Pytania teoretyczne

5. Wyjaśnić różnicę między UMNK i SUMNK.

Dziękuję za uwagę