

Testy diagnostyczne (cz. II)

Natalia Nehrebecka
Stanisław Cichocki

Wykład 11

Plan zajęć

1. Testy diagnostyczne
2. Testowanie prawidłowości formy funkcyjnej modelu
3. Testowanie normalności składników losowych
4. Testowanie stabilności parametrów
5. Testowanie heteroskedastyczności
6. Testowanie autokorelacji

Testowanie autokorelacji


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

- Brak autokorelacji



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

Sferyczne błędy losowe



Biały szum



Dodatnia autokorelacja



Ujemna autokorelacija



Testowanie autokorelacji

- Test Durbina-Watsona (Test DW):

- Test Durbina-Watsona jest powszechnie stosowanym testem wykrywania autokorelacji pierwszego rzędu, a więc *autokorelacji między sąsiednimi zaburzeniami losowymi*.
- Autokorelacje pierwszego rzędu opisuje równanie:

$$\varepsilon_t = \rho\varepsilon_{t-1} + u_t$$

- gdzie: ρ jest współczynnikiem autokorelacji zaburzeń

$$\text{Var}(u) = \sigma_u^2 I$$

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

Sposób przeprowadzenia testu:

- ▶ **Krok 1:** Estymujemy model

$$y_t = x_t\beta + \varepsilon_t$$

- ▶ **Krok 2:** Na podstawie reszt z modelu liczymy następującą statystykę:

$$\begin{aligned} DW &= \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2} = \frac{\sum_{t=2}^T e_t^2 + \sum_{t=2}^T e_{t-1}^2 - 2\sum_{t=2}^T e_t e_{t-1}}{\sum_{t=1}^T e_t^2} \\ &= \frac{2\sum_{t=1}^T e_t^2 - 2\sum_{t=1}^T e_t e_{t-1} - e_1^2 - e_T^2 + 2e_1 e_0}{\sum_{t=1}^T e_t^2} = 2(1 - \hat{\rho}) - \frac{e_1^2 + e_T^2 - 2e_1 e_0}{\sum_{t=1}^T e_t^2} \xrightarrow{p} 2(1 - \rho) \end{aligned}$$

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


- Test Durbina-Watsona (Test DW):



Testowanie autokorelacji

- Test Durbina-Watsona (Test DW):

Przyczyną występowania obszaru **braku konkluzji** jest zależność rozkładu statystyki DW od postaci nielosowej macierzy X



Testowanie autokorelacji

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

Przykład

- ▶ Dane roczne za okres 1960 – 1995 dotyczące rynku paliwowego w Stanach Zjednoczonych.
- ▶ Zmienne, które wykorzystamy w regresji:
 - G – konsumpcja benzyny wyrażona jako całkowite wydatki podzielone przez indeks cen;
 - P_g – indeks cen benzyny;
 - Y – PKB.

Przykład

```
. tsset year /*zdefiniowanie zmiennej mierzącej przebieg czasu*/
```

```
time variable: year, 1960 to 1995
```

```
delta: 1 unit
```

```
. regress g pg y
```

Source	SS	df	MS	Number of obs =	36
Model	88110.8184	2	44055.4092	F(2, 33) =	987.12
Residual	1472.79845	33	44.6302562	Prob > F =	0.0000
-----+-----				R-squared =	0.9836
Total	89583.6168	35	2559.53191	Adj R-squared =	0.9826
-----+-----				Root MSE =	6.6806

g	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
pg	-15.12235	1.880337	-8.04	0.000	-18.94792	-11.29677
y	.0369204	.0013176	28.02	0.000	.0342397	.039601
_cons	-79.7535	8.672551	-9.20	0.000	-97.39794	-62.10906

```
. dwstat /*statystyka Durbina - Watsona*/
```

```
Durbin-Watson d-statistic( 3, 36) = .4742979
```


Przykład

Wartości krytyczne testu Durбина-Watsona, $\alpha = 0.05$, K zawiera stałą

T	$K = 2$		$K = 3$		$K = 4$		$K = 5$		$K = 6$		$K = 7$		$K = 8$	
	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U
6	0.61	1.40												
7	0.70	1.36	0.47	1.90										
8	0.76	1.33	0.56	1.78	0.37	2.29								
9	0.82	1.32	0.63	1.70	0.45	2.13	0.30	2.59						
10	0.88	1.32	0.70	1.64	0.53	2.02	0.38	2.41	0.24	2.82				
11	0.93	1.32	0.76	1.60	0.59	1.93	0.44	2.28	0.32	2.64	0.20	3.00		
12	0.97	1.33	0.81	1.58	0.66	1.86	0.51	2.18	0.38	2.51	0.27	2.83	0.17	3.15
13	1.01	1.34	0.86	1.56	0.71	1.82	0.57	2.09	0.44	2.39	0.33	2.69	0.23	2.99
14	1.04	1.35	0.91	1.55	0.77	1.78	0.63	2.03	0.51	2.30	0.39	2.57	0.29	2.85
15	1.08	1.36	0.95	1.54	0.81	1.75	0.69	1.98	0.56	2.22	0.45	2.47	0.34	2.73
16	1.11	1.37	0.98	1.54	0.86	1.73	0.73	1.94	0.61	2.16	0.50	2.39	0.40	2.62
17	1.13	1.38	1.02	1.54	0.90	1.71	0.78	1.90	0.66	2.10	0.55	2.32	0.45	2.54
18	1.16	1.39	1.05	1.54	0.93	1.70	0.82	1.87	0.71	2.06	0.60	2.26	0.50	2.46
19	1.18	1.40	1.07	1.54	0.97	1.69	0.86	1.85	0.75	2.02	0.65	2.21	0.55	2.40
20	1.20	1.41	1.10	1.54	1.00	1.68	0.89	1.83	0.79	1.99	0.69	2.16	0.59	2.34
21	1.22	1.42	1.12	1.54	1.03	1.67	0.93	1.81	0.83	1.96	0.73	2.12	0.64	2.29
22	1.24	1.43	1.15	1.54	1.05	1.66	0.96	1.80	0.86	1.94	0.77	2.09	0.68	2.25
23	1.26	1.44	1.17	1.54	1.08	1.66	0.99	1.79	0.89	1.92	0.80	2.06	0.71	2.21
24	1.27	1.45	1.19	1.55	1.10	1.66	1.01	1.78	0.92	1.90	0.84	2.04	0.75	2.17
25	1.29	1.45	1.21	1.55	1.12	1.65	1.04	1.77	0.95	1.89	0.87	2.01	0.78	2.14
26	1.30	1.46	1.22	1.55	1.14	1.65	1.06	1.76	0.98	1.87	0.90	1.99	0.82	2.12
27	1.32	1.47	1.24	1.56	1.16	1.65	1.08	1.75	1.00	1.86	0.92	1.97	0.85	2.09
28	1.33	1.48	1.26	1.56	1.18	1.65	1.10	1.75	1.03	1.85	0.95	1.96	0.87	2.07
29	1.34	1.48	1.27	1.56	1.20	1.65	1.12	1.74	1.05	1.84	0.97	1.94	0.90	2.05
30	1.35	1.49	1.28	1.57	1.21	1.65	1.14	1.74	1.07	1.83	1.00	1.93	0.93	2.03
31	1.36	1.50	1.30	1.57	1.23	1.65	1.16	1.74	1.09	1.83	1.02	1.92	0.95	2.02
32	1.37	1.50	1.31	1.57	1.24	1.65	1.18	1.73	1.11	1.82	1.04	1.91	0.97	2.00
33	1.38	1.51	1.32	1.58	1.26	1.65	1.19	1.73	1.13	1.81	1.06	1.90	0.99	1.99
34	1.39	1.51	1.33	1.58	1.27	1.65	1.21	1.73	1.14	1.81	1.08	1.89	1.01	1.98
35	1.40	1.52	1.34	1.58	1.28	1.65	1.22	1.73	1.16	1.80	1.10	1.88	1.03	1.97
36	1.41	1.52	1.35	1.59	1.30	1.65	1.24	1.72	1.18	1.80	1.11	1.88	1.05	1.96

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):

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

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

- Hipoteza zerowa: brak autokorelacji
- Hipoteza alternatywna: autokorelacja

Testowanie autokorelacji – Test Breuscha-Godfrey (Test BG)

Sposób przeprowadzania:

Krok 1: Estymujemy model $y_t = x_t\beta + \varepsilon_t$ i uzyskujemy reszty e_t

Krok 2: Przeprowadzamy regresję pomocniczą reszt z tej regresji na resztach opóźnionych:

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

Krok 3: Przetestować hipotezę o braku autokorelacji możemy testując:

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

Można to zrobić za pomocą statystyki F lub statystyki

$$TR^2 \xrightarrow{D} \chi_s^2$$

Przykład

1) Szacujemy regresję i wyznaczamy z niej reszty:

```
. tsset year /*zdefiniowanie zmiennej mierzącej przebieg czasu*/
```

```
    time variable:  year, 1960 to 1995
```

```
        delta: 1 unit
```

```
. regress g pg y
```

Source	SS	df	MS	Number of obs =	36
Model	88110.8184	2	44055.4092	F(2, 33) =	987.12
Residual	1472.79845	33	44.6302562	Prob > F =	0.0000
				R-squared =	0.9836
				Adj R-squared =	0.9826
Total	89583.6168	35	2559.53191	Root MSE =	6.6806

g	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
pg	-15.12235	1.880337	-8.04	0.000	-18.94792	-11.29677
y	.0369204	.0013176	28.02	0.000	.0342397	.039601
_cons	-79.7535	8.672551	-9.20	0.000	-97.39794	-62.10906

```
. predict e, residual /*Tworzymy reszty*/
```

Przykład

2) Przeprowadzamy regresję pomocniczą:

$$e_t = \alpha_0 + \alpha_1 pg_t + \alpha_2 y_t + \gamma_1 e_{t-1} + \gamma_2 e_{t-2} + \gamma_3 e_{t-3} + \gamma_4 e_{t-4} + \xi_t, \quad t = 1, 2, \dots, T$$

. /*Regresja pomocnicza*/

. **regress e pg y l1.e l2.e l3.e l4.e** /*l1.e,l2.e,l3.e,l4.e - odpowiednio reszty opóźnione o 1, 2, 3 i 4 okresy*/

Source	SS	df	MS	Number of obs =	32
Model	919.397609	6	153.232935	F(6, 25) =	6.94
Residual	551.671362	25	22.0668545	Prob > F =	0.0002
				R-squared =	0.6250
				Adj R-squared =	0.5350
Total	1471.06897	31	47.4538378	Root MSE =	4.6975

e	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
pg	-1.07159	1.711641	-0.63	0.537	-4.596781	2.453601
y	.0005598	.0012961	0.43	0.670	-.0021097	.0032292
e						
l1.	.9448478	.2016664	4.69	0.000	.5295081	1.360187
l2.	-.3996707	.2731132	-1.46	0.156	-.9621578	.1628165
l3.	.3243404	.2747752	1.18	0.249	-.2415697	.8902505
l4.	-.0580117	.2226776	-0.26	0.797	-.5166249	.4006014
_cons	-2.02475	8.886971	-0.32	0.753	-21.12553	15.48058

Przykład

$$LM = T \cdot R^2 \xrightarrow{D} \chi_4^2$$

```
. /*Statystyka testowa*/  
. display e(r2)*(e(N)) /*e(r2) - R^2; e(N) - liczba obseracji*/
```

```
19.999554
```

```
. /*P-value*/  
. display chi2tail(4, e(r2)*(e(N)))  
.0004995
```

Przykład

```
. bfgodfrey, lags(4) nomiss0 /* test Breuscha - Godfrey'a na autokorelacje rzędu 4;
lags( ) - definiuje maksymalny rząd opóźnienia reszt w regresji pomocniczej; nomiss -
powoduje, że regresja pomocnicza jest przeprowadzana tylko na obserwacjach, które nie
zawierają braków danych. Opóźnianie zmiennej e powoduje pojawianie się braków danych.
Domyślnie w teście Breuscha - Godfreya braki danych zastępowane są przez 0 i regresja
pomocnicza przeprowadzana jest na całej próbie. */
```

Breusch-Godfrey LM test for autocorrelation

lags (p)	chi2	df	Prob > chi2
4	20.000	4	0.0005

H0: no serial correlation

Jakie założenie KMRL nie jest spełnione przy odrzuceniu H_0 ?

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

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

Pytania teoretyczne

1. Za pomocą jakich testów testuje się autokorelację? Jakiemu założeniu KMRL odpowiada H_0 w tych testach? Jakie są hipotezy alternatywne w tym testach?
2. (*) Podać postać analityczną testu *Durbina-Watsona* i postać regresji pomocniczej w przypadku testu *Breuscha-Godfrey*.

Dziękuję za uwagę