

Heteroskedastyczność i autokorelacja (cz. II)

Natalia Nehrebecka
Stanisław Cichocki

Wykład 12

Plan zajęć

1. Konsekwencje heteroskedastyczności i autokorelacji
2. Uogólniona MNK
3. Stosowalna Uogólniona MNK
4. Odporne macierze wariancji i kowariancji b

Plan zajęć

1. Konsekwencje heteroskedastyczności i autokorelacji
2. Uogólniona MNK
- 3. Stosowalna Uogólniona MNK**
4. Odporne macierze wariancji i kowariancji b

Heteroskedastyczność i autokorelacja

- ▶ Jeżeli założenie o homoskedastyczności lub założenie o braku autokorelacji nie jest spełnione, to mówimy o **niesferyczności błędów losowych**
- ▶ W przypadku występowania heteroskedastyczności lub autokorelacji:

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

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*)

Stosowalna Uogólniona MNK

- ▶ **Istota:** budujemy dodatkowy model dla wariancji i kowariancji tak aby znaleźć funkcję $\Omega(\theta)$
- ▶ Zakładamy, że

$$\text{Var}(\varepsilon) = \Omega(\theta)$$

- gdzie wymiar θ nie zależy od liczby obserwacji.
- Dla znanego θ moglibyśmy zastosować UMNK, jednak zwykle θ jest nieznanne.
- Wiemy, że estymator MNK jest zgodny nawet wtedy, gdy występuje autokorelacja lub heteroskedastyczność.

Przykład

- ▶ Typowy przykład zastosowania SUMNK – usuwanie heteroskedastyczności z modelu
- ▶ Heteroskedastyczność ma postać zależności funkcyjnej:

$$\sigma_i^2 = \alpha_0 + z_i\alpha$$

- ▶ a więc

$$\text{Var}(\varepsilon) = \Omega(\alpha_0, \alpha)$$

- ▶ Można ją wykryć za pomocą testu Breuscha-Pagana.

SUMNK

▶ Etapy estymacji za pomocą SUMNK:

1. Szacujemy model za pomocą MNK, uzyskując zgodny estymator b_{MKN}
2. Na podstawie wektora reszt e szacujemy model pomocniczy, z którego otrzymujemy zgodny estymator θ
3. Powtórnie szacujemy parametry modelu stosując estymator UMNK, nieznaną macierz Ω zastępujemy jej oszacowaniem $\Omega(\hat{\theta})$

SUMNK

4. Uzyskany estymator SUMNK:

$$b_{SUMNK} = \left[X' \Omega^{-1} \left(\hat{\theta} \right) X \right]^{-1} X' \Omega^{-1} \left(\hat{\theta} \right) y$$

Przykład 1

- ▶ Typowy przykład zastosowania SUMNK – usuwanie heteroskedastyczności z modelu
- ▶ Heteroskedastyczność ma postać zależności funkcyjnej:

$$\sigma_i^2 = \alpha_0 + z_i\alpha$$

- ▶ a więc

$$\text{Var}(\varepsilon) = \Omega(\alpha_0, \alpha)$$

- ▶ Można ją wykryć za pomocą testu Breuscha-Pagana.

Przykład 1

- ▶ Najczęściej jednak α_0, α są nieznane



- ▶ W tym przypadku możemy posłużyć się metodą dwustopniową

→ Estymator MNK jest nieobciążony i zgodny

→ e^2 - kwadraty reszt z MNK stanowią pewne oszacowanie σ^2

- ▶ Regresja e^2 na stałej i \mathbf{z}_i da zgodny estymator α_0, α

- ▶ Dla tak policzonych estymatorów $\hat{\alpha}_0, \hat{\alpha}$ można policzyć wartości teoretyczne $\hat{\sigma}_i^2 = \hat{\alpha}_0 + \mathbf{z}_i \hat{\alpha}$ dla poszczególnych obserwacji i uzyskać macierz $\Omega(\hat{\alpha}_0, \hat{\alpha})$

Przykład 1

➔ Stosowana UMNK polega na wyestymowaniu MNK równania:

$$y_i^* = x_i^* \beta + \varepsilon_i^*$$

▶ gdzie:

▶ $y_i^* = \frac{y_i}{\hat{\sigma}_i}$

▶ $x_i^* = \frac{x_i}{\hat{\sigma}_i}$

▶ Uzyskany w ten sposób estymator będzie asymptotycznie zgodnym i efektywnym

Przykład 2

▶ Wydatki na żywność

Source	SS	df	MS			
Model	89.6721174	6	14.9453529	Number of obs =	3346	
Residual	275.09173	3339	.08238746	F(6, 3339) =	181.40	
Total	364.763848	3345	.109047488	Prob > F =	0.0000	
				R-squared =	0.2458	
				Adj R-squared =	0.2445	
				Root MSE =	.28703	

lq	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
linc	.3540467	.0113581	31.17	0.000	.3317772	.3763162
_Ik1m_2	-.0334229	.0197196	-1.69	0.090	-.0720866	.0052408
_Ik1m_3	-.0584767	.0213409	-2.74	0.006	-.1003194	-.0166341
_Ik1m_4	-.0325534	.0176063	-1.85	0.065	-.0670736	.0019668
_Ik1m_5	-.0423542	.019028	-2.23	0.026	-.0796619	-.0050465
_Ik1m_6	-.0203535	.0189354	-1.07	0.283	-.0574796	.0167726
_cons	3.749705	.090792	41.30	0.000	3.571692	3.927719

Przykład 2

- ▶ Regresja e^2 na stałej i klm

resid2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
_Ik1m_2	.0068093	.0091102	0.75	0.455	-.0110528	.0246715
_Ik1m_3	-.016938	.0098739	-1.72	0.086	-.0362975	.0024215
_Ik1m_4	-.0129282	.0080402	-1.61	0.108	-.0286926	.0028361
_Ik1m_5	-.0088624	.0086485	-1.02	0.306	-.0258194	.0080945
_Ik1m_6	-.0133894	.0084823	-1.58	0.115	-.0300205	.0032416
_cons	.0906276	.0066867	13.55	0.000	.0775171	.1037381

- ▶ Test na łączną nieistotność zmiennej klm :

$$F(5, 3340) = 2.19$$
$$\text{Prob} > F = 0.0526$$

Przykład 2

- ▶ Regresja e^2 na stałej i *linc*

resid2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
linc	.017435	.005053	3.45	0.001	.0075278	.0273423
_cons	-.0504988	.0385321	-1.31	0.190	-.1260476	.02505

Przykład 2

- ▶ Przyjęto, że zależność między wariancją błędu losowego i ma postać:

$$\hat{\sigma}_i^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \textit{linc}$$

resid2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
linc	.017435	.005053	3.45	0.001	.0075278	.0273423
_cons	-.0504988	.0385321	-1.31	0.190	-.1260476	.02505

Przykład 2

- ▶ Z regresji tej najpierw wartości dopasowane

$$\hat{\sigma}_i^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \text{linc}$$

- ▶ Podzielono **zmienną zależną** i **wszystkie zmienne niezależne** (łącznie ze stałą i zmiennymi zerojedynkowymi) w pierwotnej regresji przez $\hat{\sigma}_i$

$$\hat{\sigma}_i = \sqrt{\hat{\alpha}_0 + \hat{\alpha}_1 \text{linc}}$$

Przykład 2

Source	SS	df	MS		
Model	1682677.41	7	240382.487	Number of obs	= 3346
Residual	3345.60972	3339	1.00197955	F(7, 3339)	= .
				Prob > F	= 0.0000
				R-squared	= 0.9990
				Adj R-squared	= 0.9990
Total	1686023.02	3346	503.892116	Root MSE	= 1.001

t_lq	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
t_linc	.3603508	.0114135	31.57	0.000	.3379727	.382729
t_iklm_2	-.0330761	.0199833	-1.66	0.098	-.0722569	.006104
t_iklm_3	-.0565737	.0216039	-2.62	0.009	-.0989319	-.014219
t_iklm_4	-.0290265	.0178167	-1.63	0.103	-.0619593	.00590
t_iklm_5	-.0374901	.0191635	-1.96	0.051	-.0750634	.00009
t_iklm_6	-.017306	.0190144	-0.91	0.363	-.054587	.0199
t_cons	3.699076	.0906672	40.80	0.000	3.521307	3.876

Oszacowanie błędu standardowego s powinno być równe 1

Przykład 2

- Standardowo uzyskiwana **wielkość statystyki F** jest **niepoprawna** (przekształcona stała jest traktowana jako jedna ze zmiennych). Poprawny test **F** powinien testować łączną istotność wszystkich zmiennych poza przekształconą stałą.

$$\begin{aligned} F(6, 3339) &= 183.74 \\ \text{Prob} > F &= 0.0000 \end{aligned}$$

- R^2 uzyskane w takiej regresji **nie jest interpretowalne** zmienna zależna została stworzona sztucznie
- Można policzyć R^2 dla oryginalnej regresji i uzyskanych z UMNK wartości dopasowanych

$$R_{UMNK}^2 = \frac{\sum (\hat{y}_{UMNK,i} - \bar{\hat{y}}_{UMNK})^2}{\sum (y_i - \bar{y})^2} = \rho_{\hat{y},y}^2$$

Policzona wartość $R_{UMNK}^2 = .28674733$

Przykład 2

- ▶ Wynik standardowego testu Breuscha-Pagana jest teraz następujący:

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity  
chi2          =      0.00905  
Prob > chi2   =      0.9242
```

- ▶ Heteroskedastyczność udało się usunąć!

Przykład 2

lq	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
linc	.3540467	.0113581	31.17	0.000	.3317772	.3763162
_Iklm_2	.0334229	.0197196	-1.69	0.090	-.0720866	.0052408
_Iklm_3	.0584767	.0213409	-2.74	0.006	-.1003194	-.0166341
_Iklm_4	.0325534	.0176063	-1.85	0.065	-.0670736	.0019668
_Iklm_5	.0423542	.019028	-2.23	0.026	-.0796619	-.0050465
_Iklm_6	.0203535	.0189354	-1.07	0.283	-.0574796	.0167726
_cons	3.749705	.090792	41.30	0.000	3.571692	3.927719

t_lq	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
t_linc	.3603508	.0114135	31.57	0.000	.3379727	.3827289
t_Iklm_2	-.0330761	.0199833	-1.66	0.098	-.0722569	.0061048
t_Iklm_3	-.0565737	.0216039	-2.62	0.009	-.0989319	-.0142156
t_Iklm_4	-.0290265	.0178167	-1.63	0.103	-.0639593	.0059063
t_Iklm_5	-.0374901	.0191635	-1.96	0.051	-.0750634	.0000832
t_Iklm_6	-.017306	.0190144	-0.91	0.363	-.054587	.0199751
t_cons	3.699076	.0906672	40.80	0.000	3.521307	3.876845

Przykład 3

- ▶ SUMNK w modelach z autokorelacją
 - Najpopularniejszym zastosowaniem tej metody estymacji jest estymator Prais-Winstena
 - SAMODZIELNIE!

Plan zajęć

1. Konsekwencje heteroskedastyczności i autokorelacji
2. Uogólniona MNK
3. Stosowalna Uogólniona MNK
4. Odporne macierze wariancji i kowariancji b

Odporne macierze wariancji i kowariancji b

- Istnieją **estymatory macierzy wariancji i kowariancji**, które są **zgodne** w przypadku występowania heteroskedastyczności lub autokorelacji
 —————> odporne (robust) estymatory wariancji
- Stosujemy różne estymatory w zależności od tego czy w modelu występuje heteroskedastyczność czy autokorelacja
 - Najpopularniejszym odpornym na **heteroskedastyczność** estymatorem macierzy wariancji i kowariancji b jest estymator White'a
 - Estymator Newey'a-Westa macierzy wariancji i kowariancji b stosujemy gdy w modelu występuje **heteroskedastyczność i autokorelacja**
 - Estymator warstwowy (autokorelacja błędu losowego może być skutkiem częściowo nielosowego doboru próby)

Konsekwencje heteroskedastyczności i autokorelacji

- Macierz wariancji i kowariancji b :

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

Estymator odporny White

- ▶ Jeśli znalazłbyśmy macierz wariancji-kowariancji Ω , wtedy estymatorem macierzy wariancji-kowariancji wektora parametrów β byłoby

$$\text{Var}(b) = \frac{1}{N} \left(\frac{1}{N} X'X \right)^{-1} \underbrace{\left(\frac{1}{N} X'\Omega X \right)}_{\text{bracket}} \left(\frac{1}{N} X'X \right)^{-1}$$

- ▶ Jednak macierz Ω nie jest znana.
- ▶ Zachodzi więc konieczność oszacowania $\mathbf{N(N+1)/2}$ nieznanymi parametrami macierzy na podstawie \mathbf{N} obserwacji.
- ▶ White (1980) pokazał, że rozwiązaniem jest odmienne spojrzenie na problem.
 - To co jest istotne to uzyskanie **zgodnego estymatora dla macierzy $X'\Omega X$** , która ma wymiar $K \times K$
 - Ponadto liczba zmiennych w modelu jest zazwyczaj stała i nie zależy od rozmiaru próby.

- ▶ Oznaczmy przez x_i i-tą wiersz macierzy obserwacji X .

$$X'\Omega X = X'\sigma^2 V X = \sum_{i=1}^N \sigma_i^2 x_i' x_i$$

Estymator odporny White

- ▶ White zaproponował by nieznane wariancje zastąpić kwadratami reszt.
- ▶ W ten sposób uzyskany estymator jest zgodny.

$$\hat{S}_0 = \frac{1}{N} \sum_{i=1}^N e_i^2 x_i' x_i$$

- ▶ W rezultacie otrzymujemy estymator White'a, który jest zgodny w przypadku heteroscedastyczności.

$$\hat{\Sigma}_b = \frac{1}{N} \left(\frac{1}{N} X' X \right)^{-1} \hat{S}_0 \left(\frac{1}{N} X' X \right)^{-1}$$

Przykład

- ▶ Przeanalizujemy model popytu na prace zgłaszanego przez belgijskie firmy. Próba zawiera dane z 570 firm z roku 1996. Dostępne są następujące zmienne:
- ▶ labor - zatrudnienie
- ▶ wage - suma pensji podzielona przez liczbę pracowników (w milionach jednostek)
- ▶ output - wartość dodana produkcji (w milionach jednostek)
- ▶ capital - wartość majątku trwałego (w milionach jednostek)

Przykład

```
. reg lnlabor lnwage lnoutput lncapital
```

Source	SS	df	MS	Number of obs = 569		
Model	656.747032	3	218.915677	F(3, 565)	=	1011.02
Residual	122.338815	565	.216528876	Prob > F	=	0.0000
-----+-----				R-squared	=	0.8430
Total	779.085847	568	1.37163001	Adj R-squared	=	0.8421
-----+-----				Root MSE	=	.46533
-----+-----						
lnlabor	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
lnwage	-.9277642	.0714046	-12.99	0.000	-1.068015	-.7875132
lnoutput	.9900474	.0264103	37.49	0.000	.938173	1.041922
lncapital	-.0036975	.0187697	-0.20	0.844	-.0405644	.0331695
_cons	-.4480909	.0932397	-4.81	0.000	-.6312296	-.2649522

Przykład

```
. hettest
```

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
```

```
Ho: Constant variance
```

```
Variables: fitted values of lnlabor
```

```
chi2(1)      =      19.49
```

```
Prob > chi2  =      0.0000
```

Przykład

```
. reg lnlabor lnwage lnoutput lncapital, robust
```

Regression with robust standard errors

Number of obs = 569
F(3, 565) = 544.73
Prob > F = 0.0000
R-squared = 0.8430
Root MSE = .46533

	Coef.	Robust Std. Err.	t	P> t	[95% Conf. Interval]	
lnlabor						
lnwage	-.9277642	.0866604	-10.71	0.000	-1.09798	-.7575483
lnoutput	.9900474	.0467902	21.16	0.000	.8981434	1.081951
lncapital	-.0036975	.037877	-0.10	0.922	-.0780944	.0706995
_cons	-.4480909	.1332882	-3.36	0.001	-.7098918	-.18629

Estymacja macierzy wariancji kowariancji metodą Newey'a-West

- ▶ Analogicznie do odpornego na heteroskedastyczność estymatora White'a ekonometrycy Newey i West zaproponowali odporny na heteroskedastyczność i na autokorelacje (o niesprecyzowanej strukturze) estymator macierzy wariancji-kowariancji dla b , oszacowanego za pomocą MNK.

$$\hat{\Sigma}_b = T(X'X)^{-1} \hat{S}_x (X'X)^{-1}$$

- ▶ Gdzie:

$$\hat{S}_x = \hat{S}_0 + \frac{1}{T} \sum_{l=1}^L \sum_{t=l+1}^T \omega_l e_t e_{t-l} (x_t x_{t-l}' - x_{t-l} x_t')$$

$$\omega_l = 1 - \frac{l}{L+1}$$

Pytania teoretyczne

1. Wyjaśnić różnicę między UMNK i SUMNK.
2. (*) Opisać proces szacowania modelu SUMNK na przykładzie usuwania heteroskedastyczności z modelu bądź estymacji za pomocą estymatora Prais-Winsterna.
3. Jakie są zalety stosowania estymatora MNK w połączeniu z estymatorem odpornym macierzy wariancji i kowariancji w porównaniu do stosowania estymatora UMNK.

Dziękuję za uwagę