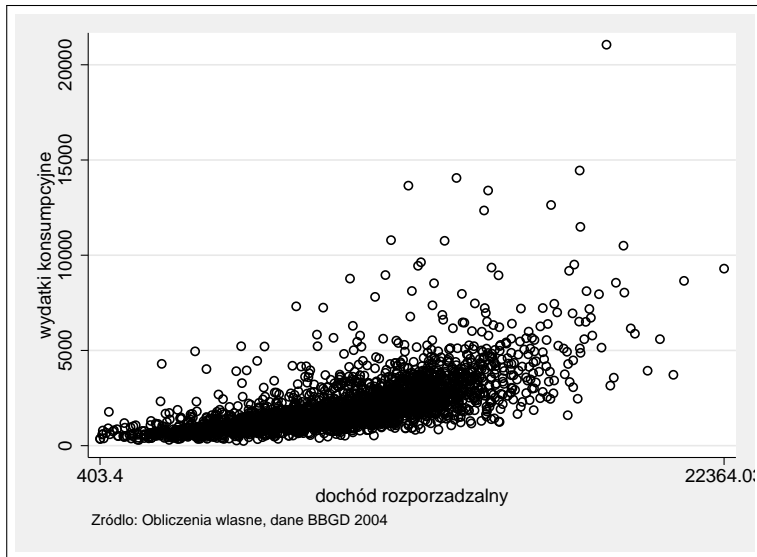


Heteroscedastyczność



- Model zjawiska

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

- Wariancja składnika losowego

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

- W przypadku heteroscedastycznego składnika losowego i braku autokorelacji \mathbb{V} jest macierzą diagonalną

- 1 Wariancja może być funkcją liniową zmiennych macierzy Z

$$\text{var}(\varepsilon_i) = \sigma_i^2 = \delta z_i \quad \delta > 0$$

- 2 Forma kwadratowa zabezpiecza przed ujemnością wariancji

$$\text{var}(\varepsilon_i) = \sigma_i^2 = \delta z_i^2 \quad \delta > 0$$

- 3 Wariancja może być również funkcją afiniczną zmiennych macierzy Z

$$\text{var}(\varepsilon_i) = \sigma_i^2 = \delta_1 + \delta_2 z_i^2 \quad \delta_1 > 0, \delta_2 > 0$$

W takim przypadku mówimy o heteroscedastyczności addytywnej.

- 4 Wariancja może przyjmować postać wykładniczą

$$\text{var}(\varepsilon_i) = \sigma_i^2 = \exp(\delta_1 + \delta_2 z_i^2)$$

Wtedy mówimy o wariancji z heteroscedastycznością multiplikatywną.

- 5 W modelu może również występować wariancja przełącznikowa (*switching*)

$$\text{var}(\varepsilon_i) = \sigma_i^2 = \begin{cases} \sigma_1^2 & \text{dla } i=1\dots s \\ \sigma_2^2 & \text{dla } i=s+1\dots T \end{cases}$$

Ten typ wariancji może być połączony z każdą z uprzednio przedstawionych postaci.

Nieobciążoność

- Nieobciążoność estymatora wektora parametrów

$$\begin{aligned}
 E(b) &= E(X'X)^{-1}X'y = E(X'X)^{-1}X'(X\beta + \varepsilon) = \\
 &= \underbrace{(X'X)^{-1}X'X}_{\text{I}} E(\beta) + (X'X)^{-1}X' \underbrace{E(\varepsilon)}_0 = \beta
 \end{aligned}$$

- Estymator MNK jest nieobciążony, gdyż jego postać nie zależy od składnika losowego

Brak zgodności

- Brak zgodności estymatora wariancji wektora parametrów

$$\text{var}(b) = E(b - E(b))(b - E(b))' = E[(X'X)^{-1}X'\varepsilon\varepsilon'X(X'X)^{-1}]$$

$$= (X'X)^{-1}X'E(\varepsilon\varepsilon')X(X'X)^{-1} = (X'X)^{-1}X'E[\Omega]X(X'X)^{-1}$$

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

- Standardowe testy oparte na statystykach t , χ^2 oraz F będą wskazywać nieprawidłowe wyniki

Twierdzenie o faktoryzacji macierzy

Każdą dodatnio określoną macierz A można przedstawić w postaci

$$A = C\Lambda C^{-1}$$

gdzie kolumny macierzy C zawierają wektory własne macierzy A , a Λ jest macierzą diagonalną z wartościami własnymi macierzy A na diagonalu.

- Zatem można przedstawić macierz wariancji jako

$$\Omega = C\Lambda C^{-1}$$

- Niech $\Lambda = \Lambda^{\frac{1}{2}}\Lambda^{\frac{1}{2}}$
- Niech $P' = C\Lambda^{-\frac{1}{2}}$. Wobec tego $\Omega^{-1} = P'P$, ponieważ P (jeśli nie ma autokorelacji) i Λ są diagonalne to $P = P'$ oraz $\Lambda = \Lambda'$.
- Mnożąc model regresji przez macierz P z lewej strony uzyskujemy

$$Py = PX\beta + P\varepsilon$$

lub alternatywnie

$$y_{\star} = X_{\star}\beta + \varepsilon_{\star} \quad (1)$$

- Wariancja składnika losowego dla przekształconego modelu wynosi

$$E[\varepsilon_{\star}\varepsilon'_{\star}] = P\varepsilon\varepsilon'P' = \sigma^2 PVP' = \sigma^2\mathbb{I}$$

Estymator UMNK wektora parametrów

- Zapiszmy wzór na estymator MNK

$$\hat{\beta} = (X_*' X_*)^{-1} X_* *' y_*$$

- Podstawiając otrzymujemy

$$\hat{\beta} = (X' P' P X)^{-1} X' P' P y$$

- W rezultacie

$$\hat{\beta} = (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} y$$

Estymator UMNK wariancji wektora parametrów

- W MNK $\text{var}(b) = \sigma^2(X'X)^{-1}$
- W UMNK $\text{var}(\hat{\beta}) = \sigma^2(X'\mathbb{V}^{-1}X)^{-1}$
- Zatem wariancja estymatora UMNK nie jest równa wariancji estymatora MNK

$$\text{var}(b) = \sigma^2(X'X)^{-1}X'\mathbb{V}X(X'X)^{-1} \neq \sigma^2(X'\mathbb{V}^{-1}X)^{-1}$$

- Więc wykorzystując MNK nie można w prawidłowy sposób oszacować wariancji jeśli składnik losowy nie jest sferyczny

Twierdzenie Aitkena

Estymator Uogólnionej Metody Najmniejszych Kwadratów jest najlepszym, liniowym i nieobciążonym estymatorem wektora parametrów β o ile postać macierzy wariancji jest znana

- Twierdzenie Aitkena wynika wprost z zastosowania Twierdzenia Gaussa-Markowa do przekształconego modelu

- Praktyka. Nie znamy postaci macierzy V
- Nie możemy jej oszacować ze względu na duży wymiar
- Szczególny przypadek - Ważona Metoda Najmniejszych Kwadratów

- Estymator UMNK dany jest wzorem:

$$\hat{\beta} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}y$$

- Jeżeli nie ma autokorelacji, elementy ω_i (wagi) są znane to Ω^{-1} jest macierzą diagonalną o elementach na diagonalu równych $1/\omega_i$.
- Przekształcając model mnożąc przez macierz P daną wzorem:

$$P = \begin{bmatrix} 1/\sqrt{\omega_1} & & 0 \\ & \ddots & \\ 0 & & 1/\sqrt{\omega_N} \end{bmatrix}$$

i stosując MNK do przekształconego modelu

- uzyskiwany jest estymator ważonej MNK

$$b = \left(\sum_{i=1}^n w_i x_i' x_i \right)^{-1} \left(\sum_{i=1}^n w_i x_i' y_i \right)$$

w którym $w_i = 1/\omega_i$.

- Zakłada się, że wariancja jest funkcją zmiennych Z

$$E(\varepsilon_i | Z_i) = \sigma_i^2 = \sigma^2 f(z_i)$$

- Wówczas odwrotność macierzy wariancji-kowariancji ma postać

$$\Omega^{-1} = \frac{1}{\sigma^2} \mathbb{V}^{-1} = \frac{1}{\sigma^2} \begin{bmatrix} \frac{1}{f(\alpha_0 + \alpha z_i)} & & 0 \\ & \ddots & \\ 0 & & \frac{1}{f(\alpha_0 + \alpha z_i)} \end{bmatrix} = \sigma^2 L' L$$

SUMNK - algorytm

- 1 Szacowane są parametry modelu $y_i = x_i b + e_i$ i zapamiętywany wektor reszt.
 - 2 Przeprowadzana jest regresja e_i^2 na stałą i wektor z_i
 - 3 Szacowana jest macierz L .
 - 4 Przekształćany jest za pomocą oszacowania \hat{L} oryginalny model
 - 5 Obliczana jest wartość estymatora
- W praktyce oszacowania uzyskane za pomocą SUMNK są zbliżone do oszacowań MNK.

SUMNK - przykład

Source	SS	df	MS	Number of obs	=	31,720
Model	3.8684e+10	1	3.8684e+10	F(1, 31718)	=	20697.02
Residual	5.9283e+10	31,718	1869075.24	Prob > F	=	0.0000
Total	9.7968e+10	31,719	3088609.94	R-squared	=	0.3949
				Adj R-squared	=	0.3948
				Root MSE	=	1367.1

dochg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
kons	0,7315	0,0051	143,86	0,00	0,7215	0,7414
_cons	789,7997	12,7227	62,08	0,00	764,8628	814,7366

SUMNK - przykład

```
. predict e, resid
. gen e2=e^2
. reg e2 los, cformat(%9,4f) pformat(%5,2f) sformat(%8,2f)
```

Source	SS	df	MS	Number of obs	=	31,720
Model	4.0371e+16	1	4.0371e+16	F(1, 31718)	=	16.62
Residual	7.7024e+19	31,718	2.4284e+15	Prob > F	=	0.0000
				R-squared	=	0.0005
				Adj R-squared	=	0.0005
Total	7.7064e+19	31,719	2.4296e+15	Root MSE	=	4.9e+07

e2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
los	7,23e+05	1,77e+05	4,08	0,00	3,76e+05	1,07e+06
_cons	-3,58e+05	6,12e+05	-0,58	0,56	-1,56e+06	8,42e+05

SUMNK - przykład

```
. gen w_os = kons/sqrt(fit)
. gen d_os = dochg/sqrt(fit)
. reg w_os d_os, cformat(%9,4f) pformat(%5,2f) sformat(%8,2f)
```

Source	SS	df	MS	Number of obs	=	31,720
Model	17556.3773	1	17556.3773	F(1, 31718)	=	19114.72
Residual	29132.1657	31,718	.918474232	Prob > F	=	0.0000
				R-squared	=	0.3760
				Adj R-squared	=	0.3760
Total	46688.543	31,719	1.47194246	Root MSE	=	.95837

w_os	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
d_os	0,5821	0,0042	138,26	0,00	0,5738 0,5903
_cons	0,5605	0,0093	60,39	0,00	0,5423 0,5787

Estymator odporny na heteroscedastyczność

- Jeżeli macierz wariacji-kowariancji Ω byłaby znana, wówczas estymatorem asymptotycznej macierzy kowariancji b byłoby

$$\Omega = \frac{1}{N} \left(\frac{1}{N} X'X \right)^{-1} \left(\frac{1}{N} X'V^{-1}X \right) \left(\frac{1}{N} X'X \right)^{-1}$$

- Aby oszacować elementy środkowej macierzy trzeba znaleźć elementy macierzy

$$plim \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N \sigma_{ij}^2 x_i x_j'$$

- Ponieważ estymator MNK dla wektora parametrów β jest zgodny, estymatory dla reszt e_i są punktowo zgodne
- White (1980) pokazał, że

$$plim \frac{1}{N} \sum_{i=1}^N e_i^2 = x_i x_i' = plim \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N \sigma_{ij}^2 x_i x_j'$$

Estymator odporny na heteroscedastyczność

- Zatem następujące macierze są asymptotycznie równoważne

$$\frac{1}{N}X'\Omega X = \frac{1}{N}X'\sigma_i^2\mathbb{I}X$$

- Zgodnym estymatorem macierzy wariancji-kowariancji wektora parametrów jest

$$\hat{\Sigma}_b = n(X'X)^{-1} \left[\frac{1}{N} \sum e_i^2 x_i x_i' \right] (X'X)^{-1}$$

Regresja odporna - przykład

```
. reg l_kons ldochg [aw=w04g], cformat(%9,4f) pformat(%5,2f) sformat(%8,2f)
(sum of wgt is 32,049.6321299076)
```

Source	SS	df	MS	Number of obs	=	32,054
Model	7183.9271	1	7183.9271	F(1, 32052)	=	46832.70
Residual	4916.63323	32,052	.153395521	Prob > F	=	0.0000
				R-squared	=	0.5937
				Adj R-squared	=	0.5937
Total	12100.5603	32,053	.377517247	Root MSE	=	.39166

l_kons	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ldochg	0,7296	0,0034	216,41	0,00	0,7230	0,7362
_cons	1,9129	0,0252	75,92	0,00	1,8635	1,9623

Regresja odporna - przykład

```
. reg l_kons ldochg [aw=w04g],robust cformat(%9,4f) pformat(%5,2f)
sformat(%8,2f)
(sum of wgt is 32,049.6321299076)
```

```
Linear regression                               Number of obs   =       32,054
                                                F(1, 32052)    =       6355.04
                                                Prob > F       =       0.0000
                                                R-squared     =       0.5937
                                                Root MSE     =       .39166
```

	Coef.	Robust Std. Err.	t	P> t	[95% Conf. Interval]	
l_kons						
ldochg	0,7296	0,0092	79,72	0,00	0,7117	0,7476
_cons	1,9129	0,0689	27,75	0,00	1,7778	2,0480