

# Metody Ekonometryczne

## Niesferyczność macierzy wariancji kowariancji składnika losowego

Jakub Mućk  
Szkola Główna Handlowa w Warszawie

## Estymator MNK

- Dla jednorównaniowego modelu liniowego:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (1)$$

estymator MNK (OLS) przyjmuję postać:

$$\hat{\beta}^{OLS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}. \quad (2)$$

- Estymator wariancji-kowariancji można zapisać jako:

$$\text{Var}(\hat{\beta}^{OLS}) = \mathbb{S}_{\varepsilon}^2 (\mathbf{X}^T \mathbf{X})^{-1}, \quad (3)$$

gdzie wariancja składnika losowego można oszacować jako  $\mathbb{S}_{\varepsilon}^2$ :

$$\mathbb{S}_{\varepsilon}^2 = \frac{e^T e}{n - (k + 1)} = \frac{SSE(\hat{\beta}^{OLS})}{df} \quad (4)$$

gdzie  $SSE(\hat{\beta}^{OLS})$  to suma kwadratów reszt, a  $df$  to **liczba stopni swobody**.

Założenia:

- ❶  $rz(\mathbf{X}) = k + 1 \leq n$
- ❷  $\mathbb{E}(\mathbf{X}\varepsilon) = 0$
- ❸  $\mathbb{E}(\varepsilon) = 0$
- ❹  $Var(\varepsilon) = \mathbb{E}(\varepsilon\varepsilon^T) = I\sigma^2$
- ❺  $\varepsilon_i \sim N(0, \sigma^2)$

## Twierdzenie Gaussa - Markowa

Estymator  $\hat{\beta}$  uzyskany Klasyczną Metodą Najmniejszych Kwadratów jest estymatorem **BLUE** [*best linear unbiased estimator*], tj. zgodnym, nieobciążonym i najefektywniejszy w klasie liniowych estymatorów wektora  $\beta$ .

- nieobciążoność, czyli:  $\mathbb{E}(\hat{\beta}^{OLS}) = \beta$
- najefektywniejszy, czyli posiadający najmniejszą wariancję w swojej klasie
- zgodny, czyli:  $\text{plim}_{n \rightarrow \infty} \hat{\beta}_n^{OLS} = \beta$ .

# Nieferyczność macierzy wariancji-kowariancji składnika losowego

- Przypomnijmy estymator macierzy wariancji-kowariancji oszacowań ( $\hat{\beta}^{OLS}$ ):

$$\text{Var}(\hat{\beta}^{OLS}) = \mathbb{E} \left[ (\hat{\beta}^{OLS} - \beta) (\hat{\beta}^{OLS} - \beta)^T \right] \quad (5)$$

- Korzystając z zapisu macierzowego:

$$\begin{aligned} \text{Var}(\hat{\beta}^{OLS}) &= \mathbb{E} \left[ (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon \left( (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon \right)^T \right] \\ &= \mathbb{E} \left[ (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \varepsilon \varepsilon^T \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \right] \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E} [\varepsilon \varepsilon^T] \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \end{aligned}$$

- Następnie korzystając z założenie o **sferyczności macierzy wariancji-kowariancji składnika losowego**, tj.  $\mathbb{D}^2(\varepsilon) = \mathbb{E}(\varepsilon \varepsilon^T) = \sigma^2 I$ , można uprościć wzór na estymator wariancji kowariancji oszacowań do:

$$\text{Var}(\hat{\beta}^{OLS}) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}. \quad (6)$$

- **Brak sferyczności macierzy wariancji-kowariancji składnika losowego** prowadzi do **obciążenia macierzy wariancji-kowariancji parametrów strukturalnych**  $Var(\hat{\beta}^{OLS})$ .
- Naturalną konsekwencją jest **brak wiarygodności błędów standardowych**.
- **Obciążone są również wyniki testów statystycznych** bazujących na macierzy wariancji-kowariancji wektora parametrów strukturalnych. W szczególności test t-studenta czy test liniowych restrykcji (test Walda).
- **Brak sferyczności macierzy wariancji-kowariancji składnika losowego** może świadczyć o poważniejszych problemach jak np.
  - ▶ **problemie pominiętych zmiennych** (*omitted variable bias*) .

- Autokorelacja składnika losowego
- Heteroskedastyczność



- Autokorelacja składnika losowego
- Heteroskedastyczność
- Efekt ARCH (*Autoregressive Conditional Heteroscedasticity*).
- Zależność przestrzenna
- Zależność pomiędzy jednostkami panelu (*cross-sectional dependence*)

- Próba wyjaśnienia źródeł niesferyczności.
- Zmiana specyfikacji modelu.
- Odporne estymatory wariancji-kowariancji (*robust covariance estimators*).
  - ▶ Konsekwencją niesferyczności składnika losowego jest obciążoność macierzy wariancji-kowariancji. Dlatego rozwiązaniem estymatora wariancji-kowariancji uwzględniającego (*odpornego*) tę własność skłanika losowego.
- Inne metody estymacji parametrów strukturalnych:
  - ▶ Uogólniona MNK (*GLS - Generalized Least Squares*)
  - ▶ Ważona MNK w przypadku heteroskedastyczności.

## Autokorelacja składnika losowego

- **Autokorelacja składnika losowego** jest problemem najczęściej występującym w przypadku **szeregów czasowych** i polega na zależności (skorelowaniu) bieżących wartości składnika losowego od wartości przeszłych.
- **Autokorelację składnika losowego** można wiązać z **inercją/persystencją** zmiennych/procesów ekonomicznych. Jest to własność polegająca na rozłożonej w czasie absorpcji czynników zewnętrznych.
- Indeks  $t$  będzie oznaczać czas obserwacji.
- Zgodnie z założeniami MNK:

$$\text{Var}(\varepsilon_t) = \begin{bmatrix} \sigma^2 & 0 & \dots & \dots & 0 \\ 0 & \ddots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \sigma^2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & 0 \\ 0 & \dots & \dots & 0 & \sigma^2 \end{bmatrix}$$

co jest równoznaczne:

$$\forall_{t \neq s} \text{cov}(\varepsilon_t, \varepsilon_s) = 0$$

- Autokorelacja składnika losowego pierwszego rzędu AR(1):

$$\varepsilon_t = \rho\varepsilon_{t-1} + \eta_t \quad (7)$$

gdzie  $\eta_t \sim \mathcal{N}(0, \sigma_\eta^2)$ ,  $\mathbb{E}(\eta) = 0$  oraz  $Var(\eta)^2 = I\sigma_\eta^2$ . Zakładamy również, że  $|\rho| < 1$

- Wariancja składnika losowego:

$$Var(\varepsilon_t) = Var(\rho\varepsilon_{t-1} + \eta_t). \quad (8)$$

Korzystając z definicji (60) można podmienić  $\varepsilon_{t-1}$ :

$$Var(\varepsilon_t) = Var(\rho^2\varepsilon_{t-2} + \rho\eta_{t-1} + \eta_t). \quad (9)$$

- Iterując powyższą czynność uzyskujemy:

$$Var(\varepsilon_t) = Var(\eta_t + \rho\eta_{t-1} + \rho^2\eta_{t-2} + \dots). \quad (10)$$

- $\eta_t$  są niezależne w czasie a więc

$$Var(\varepsilon_t) = \sigma_\eta^2 + \rho\sigma_\eta^2 + \rho^2\sigma_\eta^2 + \dots, \quad (11)$$

- a więc wariancja składnika losowego jest równa

$$Var(\varepsilon_t) = \frac{\sigma_\eta^2}{1 - \rho}. \quad (12)$$

- W przypadku kowariancji warto *iść krok po kroku*:

$$cov(\varepsilon_t, \varepsilon_{t-1}) = cov(\varepsilon_{t-1} + \eta_t, \varepsilon_{t-1}) = \rho cov(\varepsilon_{t-1}, \varepsilon_{t-1}) = \rho Var(\varepsilon_{t-1}) = \rho \frac{\sigma_\eta^2}{1 - \rho}. \quad (13)$$



- Łatwo pokazać ogólną zależność:

$$\text{cov}(\varepsilon_t, \varepsilon_{t-k}) = \rho^k \frac{\sigma_\eta^2}{1 - \rho}. \quad (14)$$

- Zatem, w przypadku autokorelacji składnika losowego macierz wariancji-kowariancji składnika losowego nie jest diagonalna:

$$\text{Var}(\varepsilon_t) = \frac{\sigma_\eta^2}{1 - \rho} \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \dots & \rho^{n-2} \\ \rho^2 & \rho & 1 & \dots & \rho^{n-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \rho^{n-3} & \dots & 1 \end{bmatrix}.$$

Przykład idiosynkratycznego zaburzenia losowego (L) oraz AR(1) (P)



## Przyczyny autokorelacji składnika losowego:

- Wysoka **inercja (persystencja)** zjawisk gospodarczych.
- Psychologia podejmowanych zjawisk.
- Problem pominięcia ważnej zmiennej.
- Niepoprawna postać funkcyjna; wadliwa struktura dynamiczna, brak uwzględnienie czynników cyklicznych/sezonowych.
- Przekształcenia statystyczne.



**Analiza reszt ( $e_t$ ):**

- wykresy reszt w czasie,
- scatterploty, tj. wykres reszt  $e_t$  względem opóźnionych reszt, np.  $e_{t-1}$ .

**Testowanie autokorelacji składnika losowego**

- test Durбина-Watsona,
- testy *portmanteau*,
- test Breuscha-Godfrey.

- Test Durбина-Watsona umożliwia sprawdzenie jedynie autokorelacji pierwszego rzędu.
- Statystyka testu DW opiera się na oszacowaniu współczynnika korelacji pomiędzy  $e_t$  a  $e_{t-1}$ :

$$d = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_{t-1}^2} \quad (15)$$

Łatwo zauważyć, że  $d \approx 2(1 - \hat{\rho})$ . Hipotezą zerową jest brak autokorelacji, tj.:

$$\mathcal{H}_0 : \quad \rho = 0 \quad (16)$$

Natomiast **hipoteza alternatywna testu DW zależy od wartości statystyki testowej**, tj.

$$\mathcal{H}_1 : \quad \rho > 0 \quad \text{gdy } d \in (0, 2) \quad (17)$$

$$\mathcal{H}_1 : \quad \rho < 0 \quad \text{gdy } d \in (2, 4) \quad (18)$$

- Wartości krytyczne  $d_U$  i  $d_L$  są stabilizowane.

$\mathcal{H}_1 : \quad \rho > 0$		$\mathcal{H}_1 : \quad \rho < 0$	
Statystyka d	Decyzja	Statystyka d	Decyzja
$(0, d_L)$	są podstawy do odrzucenia $\mathcal{H}_0$ na rzecz $\mathcal{H}_1$ o <b> dodatniej autokorelacji</b>	$(4 - d_L, 4)$	są podstawy do odrzucenia $\mathcal{H}_0$ na rzecz $\mathcal{H}_1$ o <b> ujemnej autokorelacji</b>
$(d_L, d_U)$	brak decyzji	$(4 - d_L, 4 - d_U)$	brak decyzji
$(d_U, 2)$	nie ma podstaw do odrzucenia $\mathcal{H}_0$	$(4 - d_U, 2)$	nie ma podstaw do odrzucenia $\mathcal{H}_0$

- Test DW posiada **obszary niekonkluzywności**.
- Test Durbina-Watsona umożliwia weryfikację autokorelacji jedynie pierwszego rzędu.
- W specyfikacji modelu ekonometrycznego nie może zostać uwzględniona część autoregresyjna zmiennej objaśniane (późnione wartości zmiennej objaśnianej), ponieważ wtedy statystyka DW jest obciążona.
- Test Durbina-Watsona można stosować w przypadku modeli z wyrazem wolnym.

- Statystyka **uogólnionego testu Durbina-Watsona** nie wykazuje obciążenia w przypadku modeli autoregresyjnych.
- Hipoteza zerowa odnosi się do braku autokorelacji.
- Statystyka testowa:

$$d^{\mathcal{G}} = \left(1 - \frac{d}{2}\right) \sqrt{\frac{T}{1 - TVar(\hat{\beta}_y)}} \quad (19)$$

gdzie  $Var(\hat{\beta}_y)$  to wariancja szacunku parametru autoregresji, a  $d$  to statystyka podstawowego testu Durbina-Watsona.

- Statystyka  $d^{\mathcal{G}}$  posiada standardowy rozkład normalny, tj.  $d^{\mathcal{G}} \sim \mathcal{N}(0, 1)$ .

- Generalna konstrukcja testów *portmanteau* polega na weryfikacji statystycznej zależności w czasie (tj. autokorelacji) do rzędu  $P$  włącznie.
- Hipotezy zerowa postuluje **brak autokorelacji do rzędu  $P$  włącznie**.
- Niech  $\hat{\rho}_k$  będzie korelacją pomiędzy resztami  $e_t$  a resztami opóźnionymi o  $k$  okresów, tj.  $e_{t-k}$ .

### ■ Statystyka Boxa-Pierca:

$$Q_{BP} = T \sum_{i=1}^P \hat{\rho}_T^2 \quad (20)$$

ma rozkład  $\chi^2$  z  $P$  stopniami swobody a  $T$  oznacza wielkość próby.

### ■ Statystyka Ljung-Boxa:

$$Q_{LB} = T(T+2) \sum_{i=1}^P \frac{\hat{\rho}_k^2}{T-i} \quad (21)$$

ma rozkład  $\chi^2$  z  $P$  stopniami swobody.

- Statystyka  $Q_{LB}$  ma *lepsze* własności od  $Q_{PB}$  bez względu na wielkość próby.

- Test mnożnika Lagrange'a (LM) zaproponowany przez Breusch'a i Godfrey'a pozwala na testowanie autokorelacji zarówno pierwszego jak i wyższych rzędów.
- W pierwszym kroku szacowane są parametry modelu:

$$y_t = \beta_0 + \beta_1 x_{1,t} + \dots + \beta_k x_{k,t} + \varepsilon_t \quad (22)$$

- W drugim kroku szacowane są parametry modelu, w którym wyjaśniany jest składnik resztowy z modelu (22). Dodatkowo, uwzględniane są opóźnienia do rzędu  $P$  włącznie:

$$e_t = \beta_0 + \underbrace{\beta_1 x_{1,t} + \beta_2 x_{2,t} + \dots + \beta_k x_{k,t}}_{\text{zmiennne objaśniające z modelu (22)}} + \underbrace{\beta_{k+1} e_{t-1} + \dots + \beta_{k+P} e_{t-P}}_{\text{opóźnione reszty z modelu (22)}} + \eta_t \quad (23)$$

- Hipoteza zerowa testu LM jest równoznaczna braku autokorelacji do rzędu  $P$  włącznie:

$$\mathcal{H}_0 : \beta_{k+1} = \dots = \beta_{k+P} = 0 \quad (24)$$

$$\mathcal{H}_1 : \exists l \in (1, \dots, P) \beta_{k+l} \neq 0 \quad (25)$$

- Statystyka testowa:

$$LM = nR^2 \quad (26)$$

posiada rozkład  $\chi^2$  z  $P$  stopniami swobody (rząd weryfikowanej autokorelacji składnika losowego). Są podstawy do odrzucenia  $\mathcal{H}_0$ , jeżeli  $LM$  jest większa od wartości krytycznej  $\chi^2$ .

- Estymator wariancji-kowariancji wektora  $\beta$ :

$$\text{Var}(\hat{\beta}^{OLS}) = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E} [\varepsilon \varepsilon^T] \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1}. \quad (27)$$

- Niech  $\Omega$  będzie niesferyczną macierzą wariancji kowariancji składnika losowego, tj.

$$\text{Var}(\hat{\beta}^{OLS}) = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \Omega \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1}. \quad (28)$$

- Newey i West (1987) proponują następujący estymator wariancji-kowariancji:

$$\mathbf{X}^T \hat{\Omega} \mathbf{X} = \mathbf{X}^T \hat{\Omega}_0 \mathbf{X} + \sum_{j=1}^L \sum_{t=j+1}^T w_j e_t e_{t-j} [x_t x_{t-j}^T + x_{t-j} x_t^T], \quad (29)$$

gdzie  $L$  to maksymalna liczba opóźnień,  $x_t$  to wektor obserwacji zmiennych objaśniających w momencie  $t$ ,  $w_j$  to wagi dla  $j$ -tego opóźnienia, a  $\hat{\Omega}_0$  jest wyznaczana następująco:

$$\mathbf{X}^T \hat{\Omega}_0 \mathbf{X} = \frac{T}{T-k} \sum_{t=1}^T e_t^2 x_t^T x_t. \quad (30)$$

- Newey i West (1987) proponują następujące wagi

$$w_j = 1 - j/L. \quad (31)$$

- **Wybór maksymalnej liczby opóźniej  $L$**  jest kluczowy. Im mniejsze  $L$  tym mniejsza wariancja ale większe obciążenie.
  - ▶ metoda Andrews (1991) czy Neweya i Westa (1994),
  - ▶ metoda prób i błędów,
- **Wybór wag  $w_j$ .**
  - ▶ Możliwe wykorzystanie estymatora jądra gęstości spektralnej ( *kernel spectral density*), np. Barletta czy Parzena.
- Często praktyką mającą na celu ograniczenie obciążenia (wynikającego z persystencji obserwacji empirycznych) jest tzw. *prewhitening* przy pomocy modelu VAR (wektorowej autoregresji).



- **[Hill, Griffiths i Lim]:** krzywa Phillipsa dla Australii.
- **Dane:** szeregi czasowe od 1987Q1 do 2009Q3.
  - ▶  $inf_t$  - inflacja w okresie  $t$ .
  - ▶  $\Delta u_t$  - zmiana stopy bezrobocia w okresie  $t$ .

- Model:

$$inf_t = inf_t^E - \gamma \Delta u_t + \varepsilon_t \quad (32)$$

- Zakładając, że oczekiwania inflacyjne są stałe w czasie:

$$inf_t = \beta_0 + \beta_1 \Delta u_t + \varepsilon_t \quad (33)$$


gdzie  $\beta_1 = -\gamma$ .


- Rozważany model:


$$inf_t = \beta_0 + \beta_1 \Delta u_t + \varepsilon_t \quad (34)$$

	Oszacowanie	Błąd stand.	t-Studenta	wartość p
$\beta_0$	0.777621	0.0658249	11.8135	0.0000
$\beta_1$	-0.527864	0.229405	-2.3010	0.0238

- Czy oszacowanie parametru  $\beta_1$  jest statystycznie istotne?







**■ Test Durbina-Watsona:**

- ▶ Statystyka testowa: 0.887
- ▶ Wartości krytyczne ( $N = 90$  i  $k = 1$ ) przy 5% poziomie istotności:  
 $d_L : 1.6345$   
 $d_U : 1.6794$

**■ Test Durbina-Watsona:**

- ▶ Statystyka testowa: 0.887
- ▶ Wartości krytyczne ( $N = 90$  i  $k = 1$ ) przy 5% poziomie istotności:  
 $d_L : 1.6345$   
 $d_U : 1.6794$

**■ Statystyka testu LM:**

p	Wartość statystyki	p-value
1	27.592	0.000
4	36.672	0.000

Rozważany model:

$$inf_t = \beta_0 + \beta_1 \Delta u_t + \varepsilon_t \quad (35)$$

Podstawowe oszacowania oszacowania

	Oszacowanie	Błąd stand.	t-Studenta	wartość p
$\beta_0$	0.777621	0.0658249	11.8135	0.0000
$\beta_1$	-0.527864	0.229405	-2.3010	0.0238
<b>ODPORNE BŁĘDY STANDARDOWE</b>				
	Oszacowanie	Błąd stand.	t-Studenta	wartość p
$\beta_0$	0.777621	0.101848	7.6351	0.0000
$\beta_1$	-0.527864	0.309225	-1.7071	0.0913



## Heteroskedastyczność składnika losowego

- Heteroskedastyczność składnika losowego jest drugą formą niespełnienia założenia o sferyczności macierzy wariancji-kowariancji składnika losowego.
- Zjawisko heteroskedastyczności składnika losowego charakteryzuje przede wszystkim modele oparte o **dane przekrojowe**.
- Ogólny zapis heteroskedastyczności składnika losowego:

$$\text{Var}(\varepsilon) = \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & \sigma_n^2 \end{bmatrix},$$

gdzie

$$\sigma_1^2 \neq \sigma_2^2 \neq \dots \neq \sigma_k^2.$$

- Heteroskedastyczność składnika losowego można wiązać ze zmiennością roli nieobserwowalnej heterogeniczności (różnorodności):

$$\sigma_1^2 \neq \sigma_2^2 \neq \dots \sigma_k^2.$$

- Zasadniczo  $\sigma_i^2$  może w tym przypadku zależeć od zmiennych objaśniających, tj.  $X_i$ :

$$\sigma_i^2 = f(x_{1i}, x_{2i}, \dots, x_{ki}), \quad (36)$$

gdzie  $f(\cdot)$  jest pewną funkcją.

- ▶ Kluczowe jest zdiagnozowanie tej zależności oraz próba wytłumaczenia.

## Analiza reszt ( $e_t$ ):

- wykresy kwadratów reszt względem zmiennych objaśniających,

## Testowanie heteroskedatyczności składnika losowego

- test Godfleda i Quandta,
- Test Breuscha i Pagana,
- test White'a.

- Test Goldfelda Quandta polega na porównaniu wariancji w dwóch grupach.
- Kluczowa jest tutaj identyfikacja grup.
  - ▶ zmienne binarne,
  - ▶ porządkowanie (sortowanie) próby względem pewnej (ciągłej) zmiennej objaśniającej.
- W pierwszym kroku szacowane są parametry strukturalne modeli dla obu grup **osobno**, a następnie wyznaczane są reszty.
- W drugim kroku porównywana jest wariancja składnika losowego przy pomocy statystyki  $\mathcal{F}$ :

$$\mathcal{F} = \frac{SSE_1/(N_1 - K)}{SSE_2/(N_2 - K)}, \quad (37)$$

gdzie  $SSE_i$  i  $N_i$  to suma kwadratów reszt i liczebność  $i$ -tej podpróby. **Wariancja reszt pierwszej podpróby jest większa.**

- Hipoteza zerowa postuluje brak różnic w wariancji pomiędzy grupami.
- Statystyka  $\mathcal{F}$  ma rozkład F-Snedecora z  $N_1 - K$  oraz  $N_2 - K$  stopniami swobody.

- W teście Breuscha i Pagana zakłada się specyficzną zależność:

$$\sigma_i^2 = \sigma^2 f(\alpha_0 + \alpha X). \quad (38)$$

- Pierwszy krok: szacujemy parametry strukturalne i wyznaczamy reszty.
- Drugi krok: obliczamy kwadrat reszt w relacji do ich wariancji w całej próbie, tj.  $\hat{e}_i^2/\hat{\sigma}^2$ .
- Trzeci krok: regresja pomocnicza, w której zmienną objaśnianą są  $\hat{e}^2/\hat{\sigma}^2$ :

$$\hat{e}_i^2/\hat{\sigma}^2 = \alpha_0 + \alpha_1 x_{1i} + \dots + \alpha_k x_{ki} + \eta_i, \quad (39)$$

gdzie  $\eta_i \sim \mathcal{N}(0, \sigma_\eta^2)$ . Hipoteza zerowa postuluje brak heteroskedastyczności (w rozważanej formie):

$$\mathcal{H} : \alpha_1 = \dots = \alpha_k \quad \text{tj.} \quad \sigma_i^2 = \sigma^2. \quad (40)$$

- Statystyka testowa:

$$LM = nR^2 \quad (41)$$

posiada rozkład  $\chi^2$  z  $k$  stopniami swobody.

- Test White'a jest najogólniejszym testem pozwalającym zbadać heteroskedastyczność składnika losowego.
- W pierwszym kroku szacowane są parametry modelu:

$$y_i = \beta_0 + \beta_1 x_{1,i} + \dots + \beta_k x_{k,i} + \varepsilon_i \quad (42)$$

- W drugim kroku, zmienną objaśnianą są kwadraty reszt z oszacowanego modelu (42). Ponadto uwzględniane są kwadraty oraz interakcje zmiennych objaśniających z modelu (42), tj.:

$$\begin{aligned} \hat{e}_i^2 = & \alpha_0 + \alpha_1 x_{1,i} + \dots + \alpha_k x_{k,i} + \beta_{k+1} x_{1,i}^2 + \dots + \alpha_{k+k} x_{k,i}^2 + \\ & + \alpha_{k+k+1} x_{1,i} x_{2,i} + \dots + \alpha_{k+k+s} x_{k-1,i} x_{k,i} + \eta_i \end{aligned}$$

- Hipotezą zerową jest homoskedastyczność składnika losowego:

$$\mathcal{H}_0 : \sigma_i^2 = \sigma^2 \quad \mathcal{H}_1 : \sigma_i^2 \neq \sigma^2 \quad (43)$$

- Statystyka testowa:

$$LM = nR^2 \quad (44)$$

posiada rozkład  $\chi^2$  z  $M$  stopniami swobody (liczba wszystkich wszystkich zmiennych objaśniających w regresji testowej, tj.  $M = 2k+s$ ). Są podstawy do odrzucenia  $\mathcal{H}_0$ , jeżeli  $LM$  jest większa od wartości krytycznej  $\chi^2$ .

- Test White'a jest ogólny ponieważ szczegółowa postać heteroskedastyczności jest nieznana. Tym samym, wynik tego testu może świadczyć np. o braku poprawnej specyfikacji (np. brak uwzględnienia nieliniowości).



- Macierz projekcji (*projection/hat matrix*)  $\mathbf{P}$  określa zależność pomiędzy obserwacjami empirycznymi a wartościami teoretycznym:

$$\hat{\mathbf{y}} = \mathbf{P}\mathbf{y}. \quad (45)$$

- Macierz projekcji w przypadku estymatora MNK:

$$\mathbf{P} = \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T. \quad (46)$$

- Wybrane własność macierzy projekcji:

- ▶ Symetryczność, tj.  $\mathbf{P} = \mathbf{P}^T$ .
- ▶ Idempotentność, tj.  $\mathbf{P}\mathbf{P} = \mathbf{P}$ .

- Najczęstsze estymatory macierzy wariancji-kowariancji ( $\Omega$ ) uwzględniające heteroskedastyczność HC (*heteroskedasticity-consistent*):

$$\text{homoskedatyczność: } \omega_i = \hat{\sigma}_\varepsilon^2(\text{const}),$$

$$HC_0 \text{ (White)} \quad \omega_i = \hat{e}_i^2,$$

$$HC_1 \quad \omega_i = \frac{N}{N-k} \hat{e}_i^2,$$

$$HC_2 \quad \omega_i = \frac{\hat{e}_i^2}{1-p_i},$$

$$HC_3 \quad \omega_i = \frac{\hat{e}_i^2}{(1-p_i)^2},$$

$$HC_4 \quad \omega_i = \frac{\hat{e}_i^2}{(1-p_i)^{\delta_i}}.$$

gdzie  $p_i$  to diagonalny element macierzy projekcji  $P$ , a  $\delta_i = \min(4, p_i/\bar{p})$ .

## Estymator GLS (UMNK)

**■ Kluczowy problem:**

$$\text{Var}(\varepsilon) = \sigma^2 \Omega \neq \sigma^2 I. \quad (47)$$

**■ Konsekwencje:**

- ▶ Obciążenie estymatora wariancji-kowariancji  $\text{Var}(\beta^{OLS})$ .
- ▶ Niewiarygodność błędów standardowych, statystyk testu t-studenta, statystyki testu liniowych resztykacji.

**■ Rozwiązania:**

- ▶ Alternatywna postać funkcyjna
  - ★ **Szeregi czasowe:** modele autoregresyjne.
  - ★ **Dane przekrojowe:** transformacja logarytmiczna, uwzględnienie pominiętych zmiennych, uwzględnienie nieliniowości, itp.
- ▶ Odporny estymator wariancji-kowariancji.
- ▶ **Estymator GLS (UMNK).**

- Model regresji liniowej:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (48)$$

gdzie

- ▶  $\mathbf{y}$  – wektor zmiennej objaśnianej,
- ▶  $\mathbf{X}$  – macierz zmiennych objaśniających,
- ▶  $\beta$  – wektor parametrów strukturalnych,
- ▶  $\varepsilon$  – składnik losowy.

- Model regresji liniowej:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (48)$$

gdzie

- ▶  $\mathbf{y}$  – wektor zmiennej objaśnianej,
  - ▶  $\mathbf{X}$  – macierz zmiennych objaśniających,
  - ▶  $\beta$  – wektor parametrów strukturalnych,
  - ▶  $\varepsilon$  – składnik losowy.
- Estymator GLS (UMNK) – założenia:**

- 1  $rz(\mathbf{X}) = k + 1 \leq n$
- 2  $\mathbb{E}(\mathbf{X}\varepsilon) = 0$
- 3  $\mathbb{E}(\varepsilon) = 0$
- 4  $Var(\varepsilon) = \mathbb{E}(\varepsilon\varepsilon^T) = \sigma^2\Omega$
- 5  $\varepsilon_i \sim N(0, \sigma^2)$

- Model regresji liniowej:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (48)$$

gdzie

- ▶  $\mathbf{y}$  – wektor zmiennej objaśnianej,
- ▶  $\mathbf{X}$  – macierz zmiennych objaśniających,
- ▶  $\beta$  – wektor parametrów strukturalnych,
- ▶  $\varepsilon$  – składnik losowy.

- Estymator GLS (UMNK) – założenia:**

- 1  $rz(\mathbf{X}) = k + 1 \leq n$
- 2  $\mathbb{E}(\mathbf{X}\varepsilon) = 0$
- 3  $\mathbb{E}(\varepsilon) = 0$
- 4  $Var(\varepsilon) = \mathbb{E}(\varepsilon\varepsilon^T) = \sigma^2\Omega$
- 5  $\varepsilon_i \sim N(0, \sigma^2)$

- Estymator Uogólnionej Metody Najmniejszych Kwadratów UMNK (GLS – generalized least squares):**

$$\hat{\beta}^{GLS} = (\mathbf{X}^T\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}^T\Omega^{-1}\mathbf{y} \quad (49)$$

- Estymator GLS (UMNK):

$$\hat{\beta}^{GLS} = (\mathbf{X}^T \Omega^{-1} \mathbf{X})^{-1} \mathbf{X}^T \Omega^{-1} \mathbf{y} \quad (50)$$

- Geneza:

$$\hat{\beta}^{GLS} = \arg \min_{\beta} (\mathbf{y} - \mathbf{X}\beta)^T \Omega^{-1} (\mathbf{y} - \mathbf{X}\beta). \quad (51)$$

- Estymator  $\hat{\beta}^{GLS}$  jest zgodny, nieobciążony i najefektywniejszy przy spełnieniu założeń z poprzedniego slajdu.

- ▶ Jeżeli  $\Omega = I$  to wtedy  $\hat{\beta}^{GLS} = \hat{\beta}^{OLS}$ .

- Kluczowa jest znajomość  $\Omega$ , a więc macierzy wariancji-kowariancji składnika losowego.



- Kluczowe założeniem o macierzy wariancji-kowariancji skłanika losowego jest fakt, że  $\Omega$  jest **symetryczną pozytywnie zdefiniowaną macierzą**. Wtedy,

$$\Omega = C\Lambda C^T, \quad (52)$$

gdzie  $C$  to macierz wektorów własnych a  $\Lambda$  to macierz diagonalna, której elementami są wartości własne macierzy  $\Omega$ .

- Zdefiniujmy macierz  $P$ :

$$P^T = C\Lambda^{-1/2}, \quad (53)$$

a więc w szczególności:

$$\Omega^{-1} = P^T P. \quad (54)$$

- Wprowadźmy transformację elementów polegającą na lewostronnym pomnożeniu przez macierz  $P$ , tj.  $\mathbf{y}_* = P\mathbf{y}$ , wtedy zapis:

$$P\mathbf{y} = P\mathbf{X}\beta + P\varepsilon, \quad (55)$$

jest tożsamy zapisowi:

$$\mathbf{y}_* = \mathbf{X}_*\beta + \varepsilon_*. \quad (56)$$

- Natomiast wariancja składnika losowego jest sferyczna (pamiętając, że  $\Omega^{-1} = P^T P$ ):

$$\text{Var}(\varepsilon_*) = P\Omega P^T = \sigma^2 I. \quad (57)$$

- Znając powyższą transformację, zastosujemy teraz estymator MNK dla przetransformowanych obserwacji, ponieważ  $\text{Var}(\varepsilon_*)$  jest sferyczna:

$$\begin{aligned} \hat{\beta}_*^{OLS} &= (\mathbf{X}_*^T \mathbf{X}_*)^{-1} \mathbf{X}_*^T \mathbf{y}_* \\ &= (\mathbf{X}^T P^T P \mathbf{X})^{-1} \mathbf{X}^T P^T P \mathbf{y} \\ &= (\mathbf{X}^T \Omega^{-1} \mathbf{X})^{-1} \mathbf{X}^T \Omega^{-1} \mathbf{y} = \hat{\beta}^{GLS}. \end{aligned}$$

- Kluczowym praktycznym wyzwaniem jest **znajomość macierzy wariancji-kowariancji składnika losowego  $\sigma^2\Omega$** .
- W empirycznych aplikacjach wykorzystywany jest **estymator FGLS** (*feasible generalized squares*). Ogólna idea:
  - ❶ Szacujemy parametry modelu MNK. Dzięki wektorowi  $\hat{\beta}^{OLS}$  uzyskujemy reszty.
  - ❷ Na podstawie (i) **uzyskanych reszt** oraz (ii) **założenia o strukturze niesferyczności składnika losowego (np. heteroskedastyczność lub autokorelacja)** wyznaczamy szacunek macierzy  $\hat{\Omega}$ .
  - ❸ Mając macierz  $\hat{\Omega}$  możemy wyznaczyć estymator (F)GLS, tj. :

$$\hat{\beta}^{FGLS} = (\mathbf{X}^T \hat{\Omega}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \hat{\Omega}^{-1} \mathbf{y}, \quad (58)$$

... lub zastosować odpowiednią transformację danych.

- Rozszerzeniem estymatora FGLS jest **iterowany estymator FGLS**.
  - ▶ Transformacja wynikająca z estymatora GLS jest stosowana wielokrotnie do momentu spełnienia pewnego kryterium (np. brak autokorelacji).

## Metoda Cochrane'a -Orcutta

- Metoda Cochrane'a -Orcutta polega na wykorzystaniu estymatora FGLS w przypadku autokorelacji składnika losowego pierwszego rzędu.

- Model regresji liniowej dla szeregów czasowych:

$$y_t = X_t\beta + \varepsilon_t \quad (59)$$

- Autokorelacja składnika losowego pierwszego rzędu AR(1):

$$\varepsilon_t = \rho\varepsilon_{t-1} + \eta_t \quad (60)$$

gdzie  $\eta_t \sim \mathcal{N}(0, \sigma_\eta^2)$ ,  $\mathbb{E}(\eta) = 0$  oraz  $Var(\eta)^2 = I\sigma_\eta^2$ . Zakładamy również, że  $|\rho| < 1$ .

- Przy takich założeniach, macierz wariancji-kowariancji składnika losowego nie jest diagonalna:

$$Var(\varepsilon_t) = \frac{\sigma_\eta^2}{1-\rho} \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \dots & \rho^{n-2} \\ \rho^2 & \rho & 1 & \dots & \rho^{n-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \rho^{n-3} & \dots & 1 \end{bmatrix} = \sigma_\eta^2 \Omega.$$

- Macierz odwrotna do macierzy  $\Omega$ :

$$\Omega^{-1} = \begin{bmatrix} 1 & -\rho & 0 & \dots & 0 \\ -\rho & 1+\rho^2 & -\rho & \dots & 0 \\ 0 & -\rho & 1+\rho^2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1+\rho^2 \end{bmatrix}$$

- Korzystając z dekompozycji macierzy  $\Omega^{-1} = P^T P$ , otrzymujemy następującą macierz  $P$ :

$$P = \begin{bmatrix} \sqrt{1-\rho^2} & 0 & 0 & \dots & 0 \\ -\rho & 1 & 0 & \dots & 0 \\ 0 & -\rho & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix}.$$

- Powyższy zapis sugeruje następującą transformację (dla  $t > 1$ ):

$$y_t - \hat{\rho}y_{t-1} = X_t\beta - \hat{\rho}X_{t-1}\beta + \eta_t. \quad (61)$$

- Transformacja ta zmniejsza liczebność obserwacji wykorzystywanych w próbie. Proszczeniem metody Cochrane'a-Orcutta jest metoda Prais-Winstena, z godnie z którą proponowana jest następująca transformacja dla  $t = 1$  (pierwszej obserwacji):

$$\sqrt{1-\hat{\rho}^2}y_1 = \sqrt{1-\hat{\rho}^2}X_1\beta + \eta_t. \quad (62)$$

- Oszacowanie współczynnika autokorelacji pierwszego rzędu ( $\hat{\rho}$ ) można wyznaczyć na podstawie reszt z modelu, którego parametry szacowano MNK.
- Powyższa transformacja jest nazywana **quasi różnicowaniem** *quasi-differencing*. Przypominając operator opóźnień  $Ly_t = y_{t-1}$ , dla  $t > 1$  mamy:

$$y_t (1 - \hat{\rho}L) = (1 - \hat{\rho}L) X_t\beta + \eta_t, \quad (63)$$

a operator różnicowania jest definiowany jako  $\Delta y_t = (1 - L)y_t$ .

## Ważona MNK i FGLS

- **Ważona Metoda Najmniejszych Kwadratów WLS** (*weighted least squares*) jest szczególnym przypadkiem estymatora GLS, który jest wykorzystywany w przypadku **heteroskedastyczności składnika losowego**.
- W przypadku heteroskedastyczności składnika losowego, macierz wariancji-kowariancji jest następująca:

$$\text{Var}(\varepsilon) = \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & \sigma_n^2 \end{bmatrix},$$

a samą wariancję składnika losowego możemy zapisać jako:

$$\sigma_i^2 = \omega_i \sigma^2 \quad (64)$$

wtedy macierz wariancji-kowariancji można zapisać:

$$\text{Var}(\varepsilon) = \sigma^2 \Omega = \sigma^2 \begin{bmatrix} \omega_1 & 0 & \dots & 0 \\ 0 & \omega_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & \omega_n \end{bmatrix}.$$



- Stosując estymator GLS

$$\hat{\beta}^{GLS} = (\mathbf{X}^T \Omega^{-1} \mathbf{X})^{-1} \mathbf{X}^T \Omega^{-1} \mathbf{y} \quad (65)$$

możemy zauważyć, że nieznaną macierz  $\Omega^{-1}$  to macierz zawierająca elementy  $\omega_i$  na przekątnej (*weights*):

$$\Omega^{-1} = \begin{bmatrix} \frac{1}{\omega_1} & 0 & \dots & 0 \\ 0 & \frac{1}{\omega_2} & \ddots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & \frac{1}{\omega_n} \end{bmatrix}.$$

- Kluczowe jest zdefiniowanie macierzy  $P$ , a więc macierzy transformacji GLS. Pamiętając, że  $\Omega^{-1} = P^T P$  łatwo pokazać, że taką macierzą dla estymatora WLS można zapisać następująco:

$$P = \begin{bmatrix} \frac{1}{\sqrt{\omega_1}} & 0 & \dots & 0 \\ 0 & \frac{1}{\sqrt{\omega_2}} & \ddots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & \frac{1}{\sqrt{\omega_n}} \end{bmatrix}.$$

- Powyższe własności (macierz  $P$ ) implikują następującą transformację danych:

$$y_{i*} = \frac{y_i}{\sqrt{\omega_i}}, \quad (66)$$

a następnie możliwość zastosowania estymatora OLS dla następującego modelu:

$$y_* = X_*\beta + \eta_i. \quad (67)$$

- **Intuicja:** w estymacji **ważoną MNK** **niższe wagi (znaczenie)** będą *otrzymywać* jednostki charakteryzujące się **wyższą wariancją składnika losowego**.

- Kluczowym założeniem estymatora WLS jest fakt, że znamy wagi wynikające z poniższej zależności

$$\sigma_i^2 = \omega_i \sigma^2. \quad (68)$$

- Jednak w aplikacjach empirycznych zazwyczaj nie znamy wag, tj.  $\sqrt{\omega_i}$ . Dlatego, kluczem jest zrozumienie problemu heteroskedastyczności odpowiednio wyznaczyć wagi.
- Popularne strategie wyznaczania wag:

- 1 Założenie o zależności pomiędzy  $\sigma_i$  a  $x_{ij}$ , czyli pewną zmienną objaśniającą. Np.

$$\sigma_i^2 = \sigma^2 x_{ij} \quad (69)$$

wtedy wagami są naturalnie  $1/\sqrt{x_{ij}}$ .

- 2 Uwzględnienie różnic pomiędzy grupami. Procedura jest następująca:
  - ★ Identyfikujemy  $K$  grup. Każda jednostka/obserwacja powinna być przyporządkowana dokładnie do jednej grupy.
  - ★ Dla każdej grupy szacujemy parametry strukturalne (MNK) a następnie wyznaczamy wariancję wariancję składnika losowego, tj.  $\hat{\sigma}_i^2$  będzie taka sama dla wszystkich jednostek przynależących do pewnej grupy.
  - ★ Wagami w estymatorze WLS będą zatem  $1/\hat{\sigma}_i$ .

- W przypadku heteroskedastyczności można rozważyć bardziej *elastyczną* zależność między wariancją składnika losowego  $\sigma_i^2$  a zmiennymi objaśniającymi ( $x$ ). Wtedy możliwe jest zastosowanie estymatora FGLS. Ogólna procedura jest następująca:
  - ① Oszacuj parametry rozważanego modelu MNK.
  - ② Na podstawie oszacowań z poprzedniego punktu wyznacza kwadraty reszt,  $\hat{e}_i^2$ .
  - ③ Rozważ model pomocniczy, w którym zmienną objaśnianą są  $\hat{e}_i^2$  (lub logarytm naturalny  $\ln \hat{e}_i^2$ ) a zmiennymi objaśniającymi  $x$ . Oszacuj parametry takiego modelu MNK.
  - ④ Wyznacz wartości teoretyczne na podstawie oszacowań z poprzedniego punktu, tj.  $\hat{e}_i^2$ .
  - ⑤ Wykorzystaj  $\sqrt{\hat{e}_i^2}$  jako wagi w estymatorze WLS, a więc przeprowadź transformację wykorzystując (dzieląc przez)  $\hat{e}_i$ .
- Zazwyczaj zależność między  $\sigma_i^2$  a  $x_i$  ma charakter multiplikatywny. Przykładowe założenia o zależności między  $\sigma_i^2$  a  $x_i$ 
  - ▶ [Przykład #1] założenie  $\sigma_i^2 = \sigma^2 x_{1i}^{\gamma_1} x_{2i}^{\gamma_2}$  będzie implikować następującą postać regresji pomocniczej:
 
$$\ln \hat{e}_i^2 = \gamma_0 + \gamma_1 \ln x_{1i} + \gamma_2 \ln x_{2i} + \eta_i. \quad (70)$$
  - ▶ [Przykład #2] założenie  $\sigma_i^2 = \sigma^2 \exp(\gamma_1 + x_{1i}^{\gamma_2 x_{2i}})$  będzie implikować następującą postać regresji pomocniczej:
 
$$\ln \hat{e}_i^2 = \gamma_0 + \gamma_1 x_{1i} + \gamma_2 x_{2i} + \eta_i. \quad (71)$$
  - ▶ [Przykład #3] wykorzystać  $\hat{y}$  i  $\hat{y}^2$  zamiast  $x$ .

- Testowanie liniowych restrykcji ma sens jeżeli korzystamy z tych samych wag.
- Co jeżeli oszacowania WLS i OLS są statystycznie różne, tj. charakteryzują się przeciwnymi znakami?
- Czy  $R^2$  ma interpretację?