


## 7. Autokorelacja i heteroskedastyczność

### 7.1. Rodzaje i przyczyny autokorelacji i heteroskedastyczności

Wykres reszt spełniających założenia *KMRL* pokazano na rysunku 1. Tak zachowujące się reszty nazywamy niekiedy białym szumem (*white noise*) i charakteryzują się one chaotycznym i nieprzewidywalnym zachowaniem.



Rysunek 1: Biały szum

Przypuśćmy, że założenia 2.22 i 2.23 nie są spełnione i macierz wariancji-kowariancji błędu losowego dana jest wzorem

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

Mówimy, że w modelu występuje:

- autokorelacja, gdy

$$E(\varepsilon_i \varepsilon_{j-s}) \neq 0 \quad \text{dla pewnych } s \in 1, 2, \dots$$

- heteroskedastyczność, gdy


$$E(\varepsilon_i^2) \neq \text{const}$$

Najczęściej spotykaną formą autokorelacji jest autokorelacja dodatnia. Rysunek 2 przedstawia wykres przykładowy reszt w przypadku występowania takiej autokorelacji. Dodatnio skorelowane zaburzenia losowe nie zachowują się całkowicie chaotycznie. Jeśli w okresie  $t$  błąd losowy był dodatni, to prawdopodobieństwo, że w okresie  $t + 1$  będzie on także dodatni jest wyższe niż prawdopodobieństwo, że w okresie tym będzie on ujemny. Porównując rysunek 2 z rysunkiem 1 zauważmy, że ilość przecięć wykresu z zerem jest mniejsza w przypadku procesu dodatnio skorelowanego. Autokorelacja dodatnia występuje często w modelach szacowanych na szeregach czasowych. Spowodowana jest ona zwykle rozciągnięciem na dłużej niż jeden okres skutków zdarzeń losowych wpływających na poziom zmiennej objaśnianej.

Rzadziej spotykaną formą autokorelacji jest autokorelacja ujemna. W takim przypadku prawdopodobieństwo wystąpienia po dodatnim błędzie losowym ujemnego błędu jest wyższe niż prawdopodobieństwo wystąpienia dodatniego błędu. Proces o takich cechach przedstawiono na rysunku 3. Porównując ten wykres do wykresu nieskorelowanych błędów widzimy, że charakteryzuje się on wyższą ilością przecięć z zerem. Autokorelacja ujemna zdarza się wyjątkowo w modelach ekonomicznych szacowanych na szeregach czasowych.

Autokorelacja może być także spowodowana przyjęciem błędnej postaci funkcyjnej dla estymowanego modelu. Na rysunku 4 pokazano wynik próby dopasowania za pomocą  $MNK$  trendu liniowego do funkcji kwadratowej. Dopasowanie to jest słabe ponieważ regresja ta jest błędna z powodu przyjęcia nieprawidłowej formy funkcyjnej modelu. Reszty z takiej regresji charakteryzują się silną dodatnią autokorelacją.


W literaturze omawia się dwie postaci heteroskedastyczności. Pierwsza zachodzi, gdy wariancja



Rysunek 2: Dodatnia autokorelacja

$\sigma_i^2$  zależna jest od wielkości pewnej zmiennej  $x_i$ . Przypadek ten przedstawiony jest na rysunku 5. Na rysunku tym widać jak wraz ze wzrostem  $x_i$  wzrasta wielkość odchyłek błędów losowych od zera. Taka forma heteroskedastyczności często występuje w modelach konsumpcji szacowanych na danych danych przekrojowych dotyczących gospodarstw domowych. Pojawia się ona ponieważ bogate gospodarstwa domowe mogą sobie pozwolić na większą swobodę zachowań konsumpcyjnych. Zwykle okazuje się więc, że odchylenie standardowe błędu losowego jest dodatnio skorelowane z poziomem dochodu gospodarstwa.

Innym rodzajem heteskodastyczności jest heteroskedastyczność warunkowa. Występuje ona wtedy, gdy warunkowa wariancja  $\text{Var}(\varepsilon_t | \varepsilon_{t-1}) \neq \text{const.}$  Rysunek 6 pokazuje błędy losowe charakteryzujące się warunkową heteroskedstycznością. Na rysunku można zauważyć, że okresy o niskiej zmienności błędów losowych przeplatają się z okresami o wysokiej ich zmienności. Typowym




Rysunek 3: Ujemna autokorelacja

przykładem modeli, dla których stwierdza się warunkową heteroskedastyczność są modele szacowane na danych giełdowych. Na rynku papierów wartościowych występują okresy spokoju i niskiej zmienności cen ale także okresy niepokoju i wysokiej zmienności cen.

## 7.2. Własności estymatorów $MNK$ dla modeli z heteroskedastycznością lub autokorelacją

**Twierdzenie 7.1** *W modelu, w którym  $\text{Var}(\varepsilon) = \sigma^2 \mathbf{V} = \mathbf{\Omega}$  ale spełnione są założenia 2.19, 2.20, 2.21 estymator  $\mathbf{b}_{MNK}$  jest w dalszym ciągu estymatorem nieobciążonym.*



Rysunek 4: Reszty z regresji trendu na funkcji kwadratowej

**Dowód.**


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

■

**Twierdzenie 7.2** *Estymator  $s^2$  wariancji błędu losowego, w przypadku występowania autokorelacji lub heteroskedastyczności, jest estymatorem obciążonym.*

**Dowód.**

$$E(\mathbf{e}'\mathbf{e}) = E(\text{tr}(\mathbf{M}\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}')) = \text{tr}(\mathbf{M}E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}')) = \text{tr}(\mathbf{M}\sigma^2\mathbf{V}) = \sigma^2 \text{tr}(\mathbf{M}\mathbf{V})$$




Rysunek 5: Heteroskedastyczność zależna od  $x_i$

gdzie  $M = I - X (X'X)^{-1} X'$ . Wynika z tego, że

$$E(s^2) = E\left(\frac{e'e}{n-K}\right) = \sigma^2 \frac{\text{tr}(MV)}{n-K} \neq \sigma^2$$

ponieważ  $\text{tr}(MV) \neq n-K$ . ■

**Twierdzenie 7.3** *Macierzy wariancji kowariancji  $b$ , w przypadku występowania heteroscedastyczności lub autokorelacji, jest równa  $\sigma^2 (X'X)^{-1} X'VX (X'X)^{-1}$ .*



Rysunek 6: Warunkowa heteroskedastyczność - proces ARCH

**Dowód.**

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

■

**Wniosek 7.4** Estymator  $\mathbf{S} = s^2 (\mathbf{X}'\mathbf{X})^{-1}$  jest, w przypadku występowania heteroskedastyczności, obciążonym estymatorem wariancji  $\mathbf{b}$ .

**Wniosek 7.5** Stosowanie do testowania hipotez standardowych statystyk takich jak statystyka  $t$  czy statystyka  $F$  w modelu, w którym występuje heteroskedastyczność lub autokorelacja, może prowadzić do błędnych wyników testowania.

### 7.3. Testowanie heterskedastyczności

W tym podrozdziale omówimy testy na istnienie heteroskedastyczności. Zastosowany test powinien zależeć od typu heteroskedastyczności, którego występowanie podejrzewamy. Najprostszym testem służącym do testowania heteskedastyczności jest test Goldfelda-Quandta. Stosujemy go jeśli możliwe jest podzielenie obserwacji na dwie grupy taki sposób, że dla prawdziwej hipotezy alternatywnej, wariancje błędów losowych w tych dwóch grupach są różne. Przykładowo jeśli w modelu wyjaśniającym wydatki gospodarstw domowych podzielimy gospodarstwa na te o niskim dochodzie i te o wysokim dochodzie, to zgodnie z tym co wcześniej powiedzieliśmy wariancja błędu losowego dla gospodarstw o niskim dochodzie powinna być niższa niż dla gospodarstw o wyższym dochodzie. Zaletą testu Goldfelda-Quandta jest to, że jako jedyny z omawianych testów ma rozkład wyprowadzony dla małych prób.

Test Glejsera stosujemy, jeśli znamy postać funkcyjnej zależności między zmiennymi a odchyleniem standardowym błędu losowego. Test Breuscha-Pagana stosujemy jeśli nie jest nam znana ta postać funkcyjna. Jeśli podejrzewamy, że w naszym modelu występuje warunkowa heteroskedastyczność to możemy zastosować test na istnienie autoregresyjnej warunkowej heteroskedastyczności *ARCH*. Jest to test na istnienie najprostszej formy warunkowej heteroskedastyczności. Ostatnim omawianym testem jest test White'a. Przeprowadzając go, nie musimy mieć informacji na temat formy heteroskedastyczności, ma on jednak często niską moc i w przypadku odrzucenia hipotezy zerowej nie sugeruje sposobu w jaki można heteriskedastyczność usunąć z modelu.

#### • Test Goldfelda-Quandta

Pierwszym krokiem przy przeprowadzaniu testu Goldfelda-Quandta jest pogrupowanie obserwacji na dwie rozdzielne podgrupy. Zazwyczaj zakładamy, że ochylenie standardowe zależy wprost proporcjonalnie od pewnej zmiennej, tak że  $\sigma_i = \sigma x_{k,i}$ , gdzie  $x_k$  jest pewną zmienną, co do której podejrzewamy, że wpływa na wielkość wariancji błędu losowego. Podziału dokonujemy sortując obserwacje według wielkości  $x_{k,i}$  i dzieląc uzyskaną posortowaną próbę na dwie części przy czym

usuwamy tę część<sup>1</sup> obserwacji, dla których wartości  $x_{k,i}$  w obu grupach są sobie najbliższe.

zmienna, według której sortujemy próbę		obserwacje		
	$x_{k,1}$	$\mathbf{x}_1$	$y_1$	} grupa 1 $n_1$ obserwacji
↓	$\vdots$	$\vdots$	$\vdots$	
	$x_{k,n_1}$	$\mathbf{x}_{n_1}$	$y_{n_1}$	
	$x_{k,n_1+1}$	$\mathbf{x}_{n_1+1}$	$y_{n_1+1}$	} $c$ odrzucanych obserwacji
↓	$\vdots$	$\vdots$	$\vdots$	
	$x_{k,n_1+c}$	$\mathbf{x}_{n_1+c}$	$y_{n_1+c}$	
	$x_{k,n_1+c+1}$	$\mathbf{x}_{n_1+c+1}$	$y_{n_1+c+1}$	} grupa 2 $n_2$ obserwacji
↓	$\vdots$	$\vdots$	$\vdots$	
	$x_{k,n_1+n_2+c}$	$\mathbf{x}_{n_1+n_2+c}$	$y_{n_1+n_2+c}$	

Następnym krokiem jest znalezienie reszt dla regresji  $y_t$  na  $\mathbf{X}$  przeprowadzonej dla grupy 1 i grupy 2 z osobna. Jeśli prawdziwa jest  $H_0$ , że w modelu nie ma heteroskedastyczności i spełnione są założenia *KMRL*, reszty są niekorelowane,  $\frac{e'_1 e_1}{\sigma^2}$  i  $\frac{e'_2 e_2}{\sigma^2}$  są także niekorelowane i mają rozkłady

<sup>1</sup>Nie powinno się usuwać przy tym więcej niż  $\frac{1}{3}$  obserwacji.

$\chi_{n_1}^2$  i  $\chi_{n_2}^2$ . Z twierdzenia 17.81 otrzymujemy, że

$$\frac{e_1' e_1 / (n_1 - K)}{e_2' e_2 / (n_2 - K)} \sim F(n_1 - K, n_2 - K)$$

### • Test Glejsera

Test Goldfelda-Quandt nie może być stosowany jeśli wariancja błędu losowego zależy od więcej niż jednej zmiennej, ponieważ w takim przypadku nie ma prostego sposobu pogrupowania obserwacji. Test Glejsera możemy stosować, kiedy wiemy jaką formę funkcyjną może przyjmować heteskedastyczność. Załóżmy, że wektor  $z_i$  zawiera zmienne, od których zależy wariancja błędu losowego. W literaturze najczęściej rozważane są trzy przypadki

1.  $\sigma_i^2 = \sigma^2 (1 + z_i \alpha)$
2.  $\sigma_i^2 = \sigma^2 (1 + z_i \alpha)^2$
3.  $\sigma_i^2 = \sigma^2 \exp(z_i \alpha)$

Ponieważ  $b$  jest zgodnym estymatorem  $\beta$  nawet wtedy, gdy w modelu występuje heteskedastyczność, więc  $e_i$ , i  $e_i^2$  powinny być dobrymi estymatorami odpowiednio  $\varepsilon_i$  i  $\sigma_i^2$ . Logiczne wydaje się więc, że przeprowadzenie regresji  $e_i^2$  na  $z_i$  powinno ujawnić zależność między wariancją błędu losowego i  $z_i$ . Aby otrzymać estymator  $\hat{\alpha}$  parametru  $\alpha$  powinniśmy odpowiednio dla przypadku 1, 2, 3 przeprowadzić regresje  $e_i^2$ ,  $|e_i|$  i  $\ln(e_i^2)$  na stałej i  $z_i$ . Hipoteza o braku heteroskedastyczności odpowiada hipotezie  $H_0 : \alpha = 0$ . Test na heteroskedastyczność przeprowadzamy przy użyciu statystyki Walda o wzorze

$$W = \hat{\alpha}' \hat{\Sigma}_\alpha^{-1} \hat{\alpha} \xrightarrow{D} \chi_p^2$$

gdzie  $\hat{\Sigma}_\alpha$  jest pewnym estymatorem macierzy wariancji kowariancji estymatora  $\hat{\alpha}$  a  $p$  ilości regresorów zawartych w  $z_i$ .

## • Test Breuscha-Pagana

Test Breuscha-Pagana stosujemy jeśli nie wiemy jaką formę funkcyjną przyjmuje heteroskedastyczność ale podejrzewamy, że jest ona dana zależnością

$$\sigma_i^2 = \sigma^2 f(z_i \alpha)$$

gdzie  $f(\cdot)$  jest funkcją ciągłą taką, że  $f(0) = 1$  a  $z_i$  wektorem zmiennych, o których podejrzewamy, że zależy od nich wariancja. Hipoteza zerowa o homoskedastyczności sprowadza się w tym modelu do hipotez  $H_0 : \alpha = 0$ .

Statystyka testowa ma postać statystyki mnożników Lagrange'a i  $LM = \frac{1}{2}ESS$ , gdzie  $ESS$  jest wytłumaczoną sumą kwadratów w regresji  $\frac{e_i^2}{\hat{\sigma}^2}$  na  $z$ , gdzie  $e_i^2$  są resztami a  $\hat{\sigma}^2$  estymatorem wariancji czynnika losowego w regresji

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

Asymptotycznie

$$LM = \frac{1}{2}ESS \xrightarrow{D} \chi_p^2$$

gdzie  $p$  jest ilością zmiennych zawartych w  $z$ . Statystyka ta ma także inną formę

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

gdzie  $R^2$  jest współczynnikiem determinacji z tej samej regresji regresji reszt  $\frac{e_i^2}{\hat{\sigma}^2}$  lub też  $e_i^2$  na  $z$ . Ta forma statystyki testowej jest bardziej odporna na odchylenia rozkładu  $\varepsilon_i$  od rozkładu normalnego.

## • Testy na istnienie warunkowej heteroskedastyczności

Warunkowa heteroskedastyczność zachodzi, gdy  $\sigma_t^2 = E(\varepsilon_t^2 | \varepsilon_{t-1}, \dots, \varepsilon_{t-s}) \neq 0$ . Najczęściej rozważanym przypadkiem tego typu heteroskedastyczności jest autoregresyjna warunkowa heteroskedast

czność ARCH. Zachodzi ona wtedy,

$$\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \dots + \alpha_s \sigma_{t-s}^2$$

Bazwarunkowa wariancja  $E(\varepsilon_t^2) = \frac{\alpha_0}{1 - \alpha_1 - \dots - \alpha_s} = \sigma^2 = \text{const}$ , co oznacza, że warunki twierdzenia Gaussa-Markowa są spełnione i w takim modelu  $\mathbf{b}_{MNK}$  jest najlepszym liniowym i nieobciążonym estymatorem  $\beta$ . Jednak istnieją w takim przypadku bardziej efektywne od  $MNK$  nieliniowe estymatory  $\beta$ . Estymator macierzy wariancji-kowariancji estymatora  $\mathbf{b}$  uzyskana za pomocą  $MNK$  będzie asymptotycznie zgodny. Problem pojawi się jednak przy prognozowaniu. Jak pokazaliśmy w podrozdziale 2.8, prognoza na okres  $T + 1$  ma postać  $\mathbf{x}_{T+1}\mathbf{b}$ . W standardowym modelu wariancja tej prognozy wynosi  $\text{Var}(\mathbf{x}_{T+1}\mathbf{b}) = \sigma^2 \mathbf{x}'_{T+1} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_{T+1} + \sigma^2$ . Jednak dla modelu o warunkowej heteroskedastyczności wariancja błędu losowego zależy od wariancji tego błędu w poprzednich okresach. Wynika z tego, że

$$\text{Var}(\mathbf{x}_{T+1}\mathbf{b} | \varepsilon_{t-1}, \dots, \varepsilon_{t-s}) = \mathbf{x}'_{T+1} \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_{T+1} + \sigma_{t+1}^2$$

Do oszacowania prawidłowej wariancji prognozy musimy konieczne jest więc sformułowanie także prognozy  $\hat{\sigma}_{t+1}^2$ . Szczególnie często warunkowa heteroskedastyczność występuje w szeregach czasowych związanych z danymi finansowymi takimi jak inflacja, przychody na giełdzie itp. Testowanie hipotezy zerowej o braku warunkowej heteroskedastyczności przeprowadzamy testując łączną istotność  $\alpha_1, \dots, \alpha_s$  w regresji

$$e_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_s e_{t-s}^2$$

Zazwyczaj używa się do tego statystyki  $LM$ , którą w tym przypadku można policzyć, licząc statystykę  $TR^2$  opisaną we wniosku 3.12. Dla omawianego testu będzie ona miała asymptotyczny rozkład  $\chi_s^2$ .

### • Test White'a

Ostatnim testem na heteskodeastyczność, który omówimy jest test White'a. W przeciwieństwie do wcześniej omówionych testów, test White'a nie wymaga założenia konkretnej formy heteroskedastyczności. Jest to zarówno jego zaletą jak i wadą. Umożliwia on testowanie heteroskedastyczności

nawet wtedy, gdy nie mamy żadnego pomysłu na to jaką może ona mieć postać. Z drugiej strony negatywny wynik tego testu nie jest konstruktywny - wskazuje tylko, że w modelu występuje heteroskedastyczność, ale nie daje wskazówki jak tę heteroskedastyczność można usunąć z modelu.

Idea testu White'a opiera się na porównaniu macierzy wariancji kowariancji wektora  $\mathbf{b}$  uzyskanej z  $MNK$  i estymatora White'a<sup>2</sup> macierzy wariancji kowariancji tego wektora. Estymator White'a macierzy wariancji kowariancji wektora  $\mathbf{b}$  jest estymatorem zgodnym nawet wtedy, gdy w modelu występuje heteroskedastyczność. Z drugiej strony estymator  $MNK$  tej macierzy jest estymatorem asymptotycznie obciążonym. Test White'a opiera się na porównywaniu tych dwóch estymatorów przy czym odrzucamy hipotezę zerową o homoskedastyczności jeśli występuje między nimi zbyt duża różnica.

Test White'a przeprowadzamy licząc  $nR^2$  dla regresji  $e_i^2$  na stałą i wszystkich niepowtarzających się iloczynach  $x_{s,i}x_{r,i}$ , gdzie  $s, r$  są indeksami zmiennych. Asymptotyczny rozkład tego testu jest rozkładem chi-kwadrat o  $p$  stopniach swobody, gdzie  $p$  jest ilością regresorów dla tej regresji poza stałą. Warto zauważyć, że test White'a jest szczególnym przypadkiem testu Breusch-Pagana jakkolwiek jego uzasadnienie jest istotnie odmienne.

Test White'a jako ogólny test sprawdzający prawidłowość założeń  $KMRL$  jest niekiedy stosowany jako test sprawdzający prawidłowość formy funkcyjnej modelu.

## 7.4. Testowanie autokorelacji

### • Test Durbina-Watsona

Jednym z najpopularniejszych testów weryfikujących nieskorelowanie czynników losowych jest test Durbina-Watsona. Statystyka  $DW$  jest standardowo umieszczana na wydrukach z wynikami pochodzącymi ze pakietów ekonometrycznych. Podstawową zaletą statystyki  $DW$  jej jest prostota i fakt, że istnieją tablice wartości krytycznych dla tej statystyki w próbach skończonych. Jej wadą

---

<sup>2</sup>Estymator ten zostanie omówiony później w kontekście  $UMNK$ .

jest to, że ma ona niestandardowy rozkład. Wzór na statystykę  $DW$  jest następujący:

$$DW = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2} = \frac{2 \sum_{t=1}^T e_t^2 - 2 \sum_{t=2}^T e_t e_{t-1} - e_1^2 - e_T^2}{\sum_{t=1}^T e_t^2} \quad (7.1)$$

$$= 2 \left(1 - \widehat{\rho}_{\varepsilon_t, \varepsilon_{t-1}}\right) - \frac{e_1^2 + e_T^2}{\sum_{t=1}^T e_t^2}$$

gdzie  $e_t$  są to resztami z regresji a  $\widehat{\rho}_{\varepsilon_t, \varepsilon_{t-1}} = \frac{\sum_{t=2}^T e_t e_{t-1}}{\sum_{t=1}^T e_t^2}$ . Zauważmy, że

$$DW \xrightarrow{P} 2 \left(1 - \rho_{\varepsilon_t, \varepsilon_{t-1}}\right) \quad (7.2)$$

gdzie  $\rho_{\varepsilon_t, \varepsilon_{t-1}} = \frac{\text{Cov}(\varepsilon_t, \varepsilon_{t-1})}{\text{Var}(\varepsilon_t)}$ , ponieważ na mocy centralnego twierdzenia granicznego  $\widehat{\rho}_{\varepsilon_t, \varepsilon_{t-1}} \xrightarrow{P} \rho_{\varepsilon_t, \varepsilon_{t-1}}$  a  $\frac{e_1^2 + e_T^2}{\sum_{t=1}^T e_t^2} \xrightarrow{P} 0$ .


Sposób testowania za pomocą testu  $DW$  zależy od tego, czy dane sugerują dodatnią, czy ujemną autokorelację. Na podstawie wzoru (7.2) widać, że asymptotycznie dla dodatniej korelacji błędów losowych  $0 < DW < 2$ , a dla ujemnej  $2 < DW < 4$ . Typowe tablice dla testu  $DW$  zawierają wartości krytyczne dla określonych ilości regresorów  $K$  i obserwacji  $T$  i policzone są przy założeniu, że macierz regresorów  $\mathbf{X}$  jest nielosowa. Szczególną cechą testu  $DW$  jest to, że tablice zawierają dwie wartości krytyczne  $d_L$  i  $d_U$ . Wnioskowanie statystyczne w przypadku testu  $DW$  wygląda następująco:

1. jeśli  $DW < 2$

- (a)  $DW < d_L$  odrzucamy hipotezę  $H_0$  o homoskedastyczności i przyjmujemy hipotezę o dodatniej autokorelacji
- (b)  $d_L < DW < d_U$  brak konkluzji
- (c)  $DW > d_U$  nie ma podstaw do odrzucenia hipotezy  $H_0$  o homoskedastyczności

2. jeśli  $DW > 2$

- (a)  $DW > 4 - d_L$  odrzucamy hipotezę  $H_0$  o homoskedastyczności 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  $H_0$  o homoskedastyczności



Rysunek 7: Rozkład testu Durбина-Watsona

Istnienie obszaru, dla którego test nie ma konkluzji wynika z tego, że rozkład statystyki  $DW$  zależy od postaci nielosowej macierzy  $X$ . Wartości krytyczne  $d_L$  i  $d_U$  są policzone dla takich postaci macierzy  $X$ , dla których rozkład statystyki  $DW$  dla prawdziwej  $H_0$  jest odpowiednio najbardziej przesunięty na lewo i na prawo. Na rysunku 7 naszkicowano takie skrajne rozkłady statystyki  $DW$ . Obszary zakreskowane odpowiadają 5% obszarom krytycznym. Załóżmy, że  $DW < 2$ . Wtedy obszar między 0 i  $d_L$  należy do obszaru odrzuceń dla wszystkich postaci macierzy  $X$ . Podobnie obszar między  $d_U$  i 2 należy zawsze do obszaru przyjęć. Niestety, między wartościami krytycznymi  $d_L$  i

$d_U$  istnieje obszar, który należy do obszaru odrzuceń dla jednych postaci macierzy  $\mathbf{X}$  a dla innych postaci  $\mathbf{X}$  należy do obszaru odrzuceń. Z tego powodu dla pewnych wartości statystyki  $DW$ , test nie daje konkluzji.

Test Durбина-Watsona stosowany jest także w próbach przekrojowych jako test na poprawność formy funkcyjnej modelu. Taka interpretacja testu  $DW$  związana jest z tym, że w próbach przekrojowych trudno jest sobie wyobrazić mechanizm, który mógłby spowodować zaistnienie autokorelacji błędów losowych, dotyczących przeciw obiektów obserwowanych w tym samym momencie czasu. Jeśli autokorelacja występuje, najprawdopodobniej związana jest z nieprawidłową formą funkcyjną, która generuje systematyczne zmieniające się odchylenia reszt od zera. Sytuacja taka miała miejsce w przypadku zilustrowanym rysunkiem 4. Dla regresji pokazanej na tym rysunku statystyka  $DW = 0,017$  czyli znacznie poniżej wartości krytycznej  $d_L = 1,324$  uzyskanej z tablic dla  $T = 50$  i  $K = 1$ .

### • Test Breuscha-Godfrey'a

Test Durбина-Watsona ma tę wadę, że pozwala jedynie na badanie autokorelacji pierwszego rzędu  $E[\varepsilon_t \varepsilon_{t-1}]$ . Jakkolwiek może on służyć do wykrywania autokorelacji nawet wtedy, gdy poza autokorelacją pierwszego rzędu występuje autokorelacja wyższych rzędów, to w takim przypadku nie pozwala na bliższą analizę formy autokorelacji. W przypadku, kiedy występuje autokorelacja wyższych rzędów lepiej posłużyć się więc testem Breuscha-Godfrey'a. Test ten przeprowadzamy badając łączną istotność  $\gamma_1, \dots, \gamma_s$  w regresji

$$e_t = \mathbf{x}_t \boldsymbol{\mu} + \gamma_1 e_{t-1}, \dots, \gamma_s e_{t-s}$$

gdzie  $e_t$  są resztami z regresji  $\mathbf{y}$  na  $\mathbf{X}$ . Regresja ta sprawdza, czy niewyjaśniona przez  $\mathbf{x}_t$  zmienność reszt nie zależy od reszt opóźnionych. Test  $LM$  hipotezy zerowej o braku autokorelacji możemy przeprowadzić licząc statystykę

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

gdzie  $s$  jest założonym rzędem autokorelacji.

## 7.5. Uogólniona Metoda Najmniejszych Kwadratów

Uogólnioną metodę najmniejszych kwadratów (*UMNK*) stosujemy, gdy nie jest spełnione założenie, że błędy losowe w modelu są homoskedastyczne i nieskorelowane. Powiedzmy, że

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}, \quad (7.3)$$

$\mathbf{X}$  jest nielosowe i  $\text{Var}(\mathbf{u}) = \boldsymbol{\Omega} = \sigma^2\mathbf{V}$ . Ponieważ  $\mathbf{V}$  jest dodatnio określone więc można znaleźć taką macierz  $\mathbf{L}$ , że  $\mathbf{LVL}' = \mathbf{I}_n$  i  $\mathbf{L}'\mathbf{L} = \mathbf{V}^{-1}$ . Jak wcześniej pokazaliśmy, kiedy  $\text{Var}(\mathbf{u}) \neq \sigma^2\mathbf{I}$  estymator  $\mathbf{b}$  jest nieobciążony, ale estymatory  $\sigma^2$  i  $\mathbf{S}$  są obciążone.

Estymator  $\mathbf{b}_{UMNK}$  znajdujemy mnożąc obie strony równania (7.3) przez  $\mathbf{L}$ . Otrzymujemy w ten sposób równanie

$$\mathbf{Ly} = \mathbf{LX}\boldsymbol{\beta} + \mathbf{Lu} \quad (7.4)$$

Dla tak przekształconego równania błędy losowe są homoskedastycznie i nieskorelowane, ponieważ

$$\text{Var}(\mathbf{Lu}) = \sigma^2\mathbf{LVL}' = \sigma^2\mathbf{I}.$$

Estymator  $\mathbf{b}_{UMNK}$  otrzymujemy traktując  $\mathbf{Ly}$  jako zmienną zalezną a  $\mathbf{LX}$  jako zmienną niezależną i licząc dla tak przekształconych zmiennych estymator *MNK*

$$\begin{aligned} \mathbf{b}_{UMNK} &= ((\mathbf{LX})'(\mathbf{LX}))^{-1}(\mathbf{LX})'\mathbf{Ly} = (\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{y} \\ &= (\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{y} \end{aligned}$$

$$\text{Var}(\mathbf{b}_{UMNK}) = \sigma^2 [(\mathbf{LX})'(\mathbf{LX})]^{-1} = \sigma^2 (\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1} = (\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{X})^{-1}$$

Estymator *UMNK* wariancji błędu losowego liczymy jako

$$s_{UMNK}^2 = \frac{(\mathbf{Ly} - \mathbf{LX}\mathbf{b}_G)'(\mathbf{Ly} - \mathbf{LX}\mathbf{b}_G)}{n - K}$$

i jest łatwo pokazać, że jest on jest nieobciążony. Zauważmy też, że

$$s_{UMNK}^2 = \frac{(\mathbf{y} - \mathbf{X}\mathbf{b}_G)' \mathbf{V}^{-1} (\mathbf{y} - \mathbf{X}\mathbf{b}_G)}{n - K} = \frac{\mathbf{e}'_G \mathbf{V}^{-1} \mathbf{e}_G}{n - K},$$

gdzie  $\mathbf{e}_{UMNK} = \mathbf{y} - \mathbf{X}\mathbf{b}_{UMNK}$ .

**Uwaga 7.6** W ogólnym przypadku estymatory  $UMNK$  są niemożliwe do bezpośredniego zastosowania, ponieważ do ich policzenia konieczna jest znajomość nieznanych macierzy  $\mathbf{\Omega}$ ,  $\mathbf{V}$  lub  $\mathbf{L}$ . Wykonywalna  $UMNK$  polega na zastąpieniu macierzy  $\mathbf{\Omega}$  jej zgodnym estymatorem  $\hat{\mathbf{\Omega}}$ . Znalazienie takiego estymatora jest możliwe tylko wtedy gdy na formę  $\mathbf{\Omega}$  narzucimy pewne ograniczenia. W przypadku, kiedy  $\mathbf{\Omega}$  nie jest ograniczona, mamy zbyt mało stopni swobody by wyestymować  $\mathbf{\Omega}$ , ponieważ ilość parametrów do oszacowania zawartych w  $\mathbf{\Omega}$  wynosi  $\frac{n(n+1)}{2}$ , podczas gdy ilość dostępnych stopni swobody jedynie  $n - K$

**Przykład 7.7** Ważona Metoda Najmniejszych Kwadratów

Jeśli w modelu występuje jedynie heteroskedastyczność to macierz  $\mathbf{\Omega}$  ma postać

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

Załóżmy, że elementy  $v_i$  są znane. Dla tego przypadku macierz  $\mathbf{L}$  ma postać

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

$UMNK$  można traktować jako  $MNK$  przeprowadzoną z użyciem przekształconych zmiennych  $\mathbf{X}^* = \mathbf{L}\mathbf{X}$  i  $\mathbf{y}^* = \mathbf{L}\mathbf{y}$ . W naszym przypadku zmienne te będą miały postać  $y_i^* = \frac{y_i}{\sqrt{v_i}}$  i  $x_{s,i}^* = \frac{x_{s,i}}{\sqrt{v_i}}$ .

Wielkości  $v_i$  można interpretować jako wagi przypisywane obserwacjom. Obserwacje o niskiej wariancji błędu losowego mają przypisaną większą wagę a te o wyższej wariancji uzyskują niższą wagę.

Przypuśćmy, że heteroskedastyczność w modelu ma postać  $\sigma_i^2 = \sigma^2 z_i^2$ , gdzie  $z_i$  jest pewną z góry ustaloną zmienną. Heteroskedastyczność o tej formie można wykryć np. za pomocą testu Goldfelda-Quandt z podrozdziału •. W takim przypadku postać macierz wariancji kowariancji  $\epsilon$  ma następującą postać

$$\mathbf{\Omega} = \text{Var}(\epsilon) = \sigma^2 \begin{bmatrix} z_1^2 & & 0 \\ & \ddots & \\ 0 & & z_n^2 \end{bmatrix} = \sigma^2 \mathbf{V}$$

a macierzy  $\mathbf{L}$  będzie miała postać

$$\mathbf{L} = \begin{bmatrix} \frac{1}{z_1} & & 0 \\ & \ddots & \\ 0 & & \frac{1}{z_n} \end{bmatrix}$$

W tym przypadku  $y_i^* = \frac{y_i}{z_i}$  i  $x_{s,i}^* = \frac{x_{s,i}}{z_i}$ .

Tego rodzaju przekształcenie stosuje się w ekonometrii bardzo często. Zastanówmy się nad standardową funkcją konsumpcji

$$C_i = a + bY_i + \epsilon_i,$$

gdzie  $C_i$  jest to całkowita konsumpcja w kraju  $i$  a  $Y_i$  jest poziomem GDP w tym kraju. Jeśli tak sformułowany model oszacujemy na próbie przekrojowej, to prawie napewno wystąpi heteroskedastyczność. Jej powodem będzie nadanie tych samych wag krajom bardzo małym i bardzo dużym. Trudno jest założyć, że dla małych krajów wariancja błędu losowego jest taka sama jak dla dużych krajów. Precyzję oszacowania można mierzyć stosunkiem odchylenia standardowego błędu losowego

do wielkości zmiennej niezależnej  $\frac{\sigma}{y_i}$ . Wartość dóbr skonsumowanych na Litwie jest około 1000 razy mniejsza niż wartość konsumpcji w USA. Jeśli w oszacowanym modelu relacja  $\frac{\sigma}{C_i}$  dla Litwy wynosiłaby 1, to przy założeniu że  $\sigma$  jest stała dla wszystkich krajów, dla Stanów stosunek ten musiałaby wynosić 0,001. Konsekwencją przyjęcia założenia o homoskedastyczności jest więc przyjęcie założenia, że precyzja oszacowania jest wyższa dla krajów dużych niż dla krajów małych.

Wydaje się, że bardziej realistyczny w tym przypadku jest model na zmiennych wyrażonych w kategoriach per capita

$$C_i^* = a \frac{1}{z_i} + bY_i^* + \varepsilon_i^*$$

gdzie  $C_i^* = \frac{C_i}{z_i}$ ,  $Y_i^* = \frac{Y_i}{z_i}$  a  $z_i$  jest ludnością danego kraju. Przekształcenie to jest równoważne zastosowaniu Ważonej Metody Najmniejszych Kwadratów przy założeniu, że odchylenie standardowe błędu losowego jest proporcjonalne do liczby ludności. Zwróćmy uwagę, że stała przy takim przekształceniu zamienia się w zmienną  $\frac{1}{z_i}$ . Aby uzyskać stałą w modelu przekształconym, w modelu pierwotnym powinniśmy mieć, zamiast stałej, zmienną  $z_i$ .

### **Przykład 7.8** Dwustopniowa UMNK

Zdarza się, że heteroskedastyczność ma postać zależności funkcyjnej  $\sigma_i^2 = f(\alpha_0 + z_i\alpha)$ . Przypadek ten można wykryć za pomocą testów Glejsera i Breuscha-Pagana opisanych w podrozdziałach ● i ●. Dla modelu, w którym występuje heteroskedastyczność o tej postaci można policzyć estymator UMNK pod warunkiem, że znamy  $\alpha_0$  i  $\alpha$ . W większości przypadków parametry te są jednak nieznanne. W tym przypadku możemy posłużyć się metodą dwustopniową. Jak już wiemy estymator MNK jest nieobciążony i zgodny nawet wtedy gdy w modelu występuje heteroskedastyczność. Intuicyjnie wydaje się uzasadnione, że regresja  $f^{-1}(e_i^2)$  na stałej i  $z_i$  da zgodny estymator  $\alpha_0$  i  $\alpha$ . Dla tak policzonych estymatorów  $\hat{\alpha}_0$  i  $\hat{\alpha}$  policzyć można wartości teoretyczne  $\hat{\sigma}_i^2 = f(\hat{\alpha}_0 + z_i\hat{\alpha})$ . Wykonywalna UMNK polega teraz na wystymowaniu MNK równania

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

gdzie  $y_i^* = \frac{y_i}{\sigma_i}$  a  $x_{s,i}^* = \frac{x_{s,i}}{\sigma_i}$ . Uzyskany w ten sposób estymator będzie asymptotycznie zgodnym i będzie miał asymptotycznie niższą wariancję niż estymator MNK uzyskany z nieprzekształconej regresji.

**Literatura:** Steward (1991) str. 147-151, Green (1997) str. 507-509, Chow (1995) str. 103-108, Goldberger (1972) str. 298-312. Theil (1979) str. 244-257.

## 7.6. Estymacja macierzy wariancji kowariancji metodą White'a

Jak wcześniej wspominaliśmy, estymacja macierzy  $\Omega$  bez ograniczeń jest sprawą beznadziejną ze względu na zbyt małą liczbę stopni swobody, którymi dysponujemy. Zauważmy jednak, że do wyestymowania macierzy prawidłowej formy macierzy wariancji-kowariancji estymatora  $\mathbf{b}_{MNK}$  wystarczy znaleźć estymator macierzy  $\mathbf{X}'\Omega\mathbf{X}$ , która ma wymiar  $K \times K$ . W przypadku, kiedy w modelu występuje jedynie heteroskedastyczność macierz  $\Omega$  jest diagonalna i

$$\mathbf{S} = \frac{1}{n} \mathbf{X}' \Omega \mathbf{X} = \frac{1}{n} \sum \sigma_i^2 \mathbf{x}_i \mathbf{x}_i'$$

Pokazano, że dla bardzo ogólnych założeń, zgodnym estymatorem  $\mathbf{S}$  jest

$$\widehat{\mathbf{S}} = \frac{1}{n} \sum e_i^2 \mathbf{x}_i \mathbf{x}_i'$$

tak, zgodnym estymatorem wariancji

$$\Sigma_{\mathbf{b}} = \text{Var}(\mathbf{b}_{MNK}) = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\Omega\mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} = \Sigma$$

jest

$$\widehat{\Sigma}_{\mathbf{b}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{S}_x (\mathbf{X}'\mathbf{X})^{-1}$$

Estymator White'a umożliwia zastosowanie estymatora  $\mathbf{b}_{MKN}$  i policzenie jego macierzy wariancji nawet wtedy, kiedy nie jest możliwe zastosowanie estymatora  $\mathbf{b}_G$  ze względu na brak wystarczającej ilości ograniczeń narzuconych na  $\Omega$ .

**Literatura:** Steward (1991) str. 162, Green (1997) str. 504-505