

**Alicja Grześkowiak**

**POŁĄCZENIE KLASYCZNEGO I NIEKLASYCZNEGO  
PODEJŚCIA W CELU WYKRYWANIA  
NIEJEDNORODNOŚCI WARIANCJI SKŁADNIKÓW  
LOSOWYCH MODELU EKONOMETRYCZNEGO**

**1. Wstęp**

Klasyczna metoda najmniejszych kwadratów, stosowana powszechnie do estymacji parametrów liniowych modeli ekonometrycznych, wymaga spełnienia szeregu założeń, dotyczących między innymi rozkładu składników losowych modelu. Przy określonych założeniach estymator metody najmniejszych kwadratów posiada pożądane własności – jest nieobciążony, zgodny i najefektywniejszy w klasie nieobciążonych estymatorów liniowych. Weryfikacja założeń dotyczących składników losowych wiąże się z licznymi trudnościami, wynikającymi z tego, że są one nieobserwowalne. Wnioskowanie o składnikach losowych przeprowadza się za pomocą testów statystycznych na podstawie reszt otrzymanych w wyniku zastosowania metody najmniejszych kwadratów. Z wielu względów nie stanowią one idealnego narzędzia umożliwiającego podjęcie właściwej decyzji co do postaci rozkładu składników losowych. W niniejszej pracy przedstawiono koncepcję połączenia zalet postępowania klasycznego (stosowania testów statystycznych) z korzyściami płynącymi z możliwości wyboru „najlepszego” rozkładu przy zastosowaniu dyskryminacyjnej reguły największej wiarygodności. Problemem, którego rozwiązanie zaproponowano, jest określanie rodzaju heteroskedastyczności składników losowych jednorównaniowego liniowego modelu ekonometrycznego. W pracy przedyskutowano postulowaną koncepcję i zilustrowano ją badaniem empirycznym.

## 2. Klasyczne podejście do wykrywania niejednorodności wariancji składników losowych modelu ekonometrycznego

Stosując metodę najmniejszych kwadratów do szacowania parametrów modelu ekonometrycznego postaci:

$$Y = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_m X_m + \varepsilon, \quad (1)$$

gdzie:  $Y$  – zmienna objaśniana,  
 $X_1, X_2, \dots, X_m$  – zmienne objaśniające,  
 $\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_m$  – parametry strukturalne,  
 $\varepsilon$  – składniki losowe.

czyni się założenia dotyczące struktury stochastycznej modelu. Zespół założeń dotyczących składników losowych jest następujący:

1. Wartość oczekiwana wynosi zero:  $E(\varepsilon_i)$  dla każdego  $i$ . U podstaw tego założenia leży przekonanie, iż zakłócenia reprezentowane przez składniki losowe wzajemnie się redukują.

2. Wariancja jest stała:  $V(\varepsilon_i) = \sigma^2$  dla każdego  $i$ . Stałość wariancji nosi miano homoskedastyczności.

3. Brak autokorelacji, czyli brak skorelowania składników losowych pochodzących z dwóch różnych obserwacji:  $Cov(\varepsilon_i, \varepsilon_j) = 0$  dla  $i \neq j$ .

W przypadku wystąpienia różnych wariancji lub istnienia autokorelacji składników losowych estymator metody najmniejszych kwadratów przestaje być estymatorem najefektywniejszym. Preferowaną wówczas metodą szacowania parametrów modelu powinna być uogólniona metoda najmniejszych kwadratów (UMNK), której estymator posiadający pożądane własności podał Aitken. Mimo tego znanego sposobu przewyższania trudności związanych z niespełnieniem założeń o składnikach losowych, praktyczne zastosowanie UMNK napotyka wiele trudności, wymaga bowiem wiedzy o kształtowaniu się składników losowych, której badacz raczej nie posiada *a priori*. Nie ma też możliwości, aby bezpośrednio sprawdzić przebiegu procesu, co wynika z samej natury składników losowych, które są nieobserwowalnymi zmiennymi losowymi. Wobec tak silnych ograniczeń poznawczych wnioskowanie o składnikach losowych oparte jest na pewnym ich substytucie, jakim są reszty modelu, które nie będąc realizacjami  $\varepsilon$ , stanowią tylko pewne ich przybliżenie.

W trakcie procesu modelowania ekonometrycznego badacz zmuszony jest więc do formułowania stwierdzeń dotyczących składników losowych, dysponując bardzo ograniczonym zasobem informacji. Podczas weryfikacji modelu w zakresie badania jednorodności wariancji bardzo ważne wydaje się rozwiązanie następujących problemów:

1. Czy składniki losowe spełniają założenie o homoskedastyczności?
2. Jeżeli występuje w modelu heteroskedastyczność, to jaki jest jej charakter?

Rozstrzygnięcie kwestii zawartej w pierwszym pytaniu pozwala na trafny wybór metody estymacji, natomiast znalezienie odpowiedzi na pytanie drugie otwiera możliwość zastosowania UMNK do szacowania parametrów modelu.

Idealne narzędzie badawcze niesłoby odpowiedzi na oba pytania, umożliwiając tym samym aplikację UMNK w sytuacjach, gdy zostanie stwierdzona niejednorodność składników losowych. Rozwiązanie tych kwestii nie jest jednakże tak proste. W zakresie wykrywania heteroskedastyczności prace ekonometryków (zob. [1; 2; 5; 6; 8; 11; 13]) skupiają się na konstrukcji testów statystycznych i dotychczas nie opracowano skutecznego narzędzia, które jednocześnie wykrywałoby na dużym poziomie ogólności odstępstwo od założenia o homoskedastyczności i postulowało schemat opisujący kształtowanie się wariancji. Proponowane rozwiązania pozwalają albo przebadać możliwość wystąpienia heteroskedastyczności określonego typu, albo stwierdzić istnienie niejednorodności wariancji bez wskazówek, jak się ona kształtuje. W pierwszym przypadku badanie jest bardzo fragmentaryczne, w drugim zaś bardzo ogólne. W literaturze przedmiotu dzieli się testy wykrywające heteroskedastyczność na dwie kategorie:

- testy konstruktywne, w których w hipotezie alternatywnej zdefiniowany jest konkretny model heteroskedastyczności (zob. [4; 10; 13]) – np. test Goldfelda-Quandt, test Bartletta, test Ramseya, test Glejsera,
- testy niekonstruktywne, w których w hipotezie alternatywnej nie specyfikuje się charakteru heteroskedastyczności, tylko ogólnie stwierdza jej występowanie – (zob. [12; 13; 14]) – np. testy klasy Szroetera, nieparametryczny test szczytów Goldfelda-Quandt, test White'a.

Do niewątpliwych zalet testu konstruktywnego można zaliczyć to, że przyjęcie hipotezy alternatywnej oznacza zaakceptowanie wyspecyfikowanego w niej schematu heteroskedastyczności i możliwość zastosowania UMNK. Sytuacja komplikuje się natomiast w przypadku braku podstaw do odrzucenia hipotezy zerowej, gdyż wówczas badacz otrzymuje jedynie informację, że w modelu nie wystąpił określony rodzaj heteroskedastyczności, co nie oznacza, że wariancje są jednorodne – istnieje możliwość, że kształtują się według innego wzorca niż zdefiniowany w zastosowanym teście.

Z kolei zastosowanie testu niekonstruktywnego przewycięża tę niedogodność. Zastosowanie tego rodzaju postępowania pozwala na przyjęcie jednego ze stwierdzeń: albo składniki modelu są heteroskedastyczne (jeśli odrzucona zostanie hipoteza zerowa na rzecz alternatywnej), albo charakteryzują się homoskedastycznością (jeśli nie ma podstaw do odrzucenia hipotezy zerowej). Grupa testów niekonstruktywnych odznacza się więc dużo większym stopniem ogólności, pozwalając wykryć istnienie niejednorodności wariancji. Niestety, na podstawie wyniku testu nie

można określić, jaki rodzaj schematu heteroskedastyczności wystąpił w modelu, co uniemożliwia zastosowanie UMNK do estymacji parametrów modelu.

### 3. Kombinacja podejścia klasycznego i dyskryminacyjnej reguły największej wiarygodności umożliwiające określenie rodzaju heteroskedastyczności

Niedostatki testów statystycznych w zakresie wykrywania istnienia i określania typu heteroskedastyczności mogą zostać zniwelowane poprzez zastosowanie kombinacji podejścia klasycznego z dyskryminacyjną regułą największej wiarygodności, której zastosowanie nie wymaga ani wiedzy o prawdopodobieństwach *a priori* przynależności do klas, ani informacji o kosztach błędnej alokacji. Tego rodzaju niewiedza pojawia się w praktyce modelowania bardzo często, gdyż brakuje przesłanek pozwalających określić prawdopodobieństwa *a priori* wystąpienia poszczególnych schematów heteroskedastyczności, a także niezmiernie trudno sformułować postulaty odnoszące się do kosztów błędnej alokacji. Dlatego też w przedstawianej koncepcji przyjmuje się występowanie równych strat i równych prawdopodobieństw *a priori*, zgodnie z postulatem Bayesa zakładającym, że w przypadku braku informacji przeczące wszystkie prawdopodobieństwa *a priori* są takie same.

Sugerowana procedura postępowania obejmuje dwa główne etapy:

**Etap I:** zastosowanie testu niekonstruktywnego, ogólnego, pozwalającego na wykrycie zjawiska niejednorodności wariancji składników losowych modelu ekonometrycznego.

W przypadku stwierdzenia heteroskedastyczności niezbędne staje się określenie jej rodzaju; cel ten jest osiągniany poprzez:

**Etap II:** wykorzystanie dyskryminacyjnej reguły największej wiarygodności do wyboru najlepszego schematu opisującego kształtowanie się wariancji składników losowych.

Jeśli spełnione są założenia dotyczące składników losowych, ich macierz kowariancji jest macierzą skalarną postaci  $\sigma^2 \mathbf{I}$  ( $\mathbf{I}$  – macierz jednostkowa stopnia  $n$ ). Jeżeli występuje heteroskedastyczność, elementy diagonalne nie są jednakowe, a macierz kowariancji ma wówczas postać  $\sigma^2 \mathbf{V}$ . Przy założeniu normalności rozkładu funkcja gęstości wektora składników losowych ma postać:

$$f(\boldsymbol{\varepsilon}) = \frac{1}{(2\pi)^{\frac{n}{2}} |\sigma^2 \mathbf{V}|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} \boldsymbol{\varepsilon}^T (\sigma^2 \mathbf{V})^{-1} \boldsymbol{\varepsilon} \right\}. \quad (2)$$

Po zastosowaniu testu niekonstruktywnego nie jest znany rodzaj heteroskedastyczności, nie są więc znane elementy macierzy  $\mathbf{V}$ . W literaturze można się zetknąć z sugestią, iż wówczas określenie typu heteroskedastyczności zależy od

badacza, który decyzję swoją powinien oprzeć na doświadczeniu i merytorycznej ocenie modelowanych zjawisk. Postulowane rozwiązanie przeciwstawia się tak subiektywnej metodzie wyboru i zmierza ku bardziej obiektywnemu kryterium. Jeśli hipoteza o homoskedastyczności zostanie odrzucona, można zaproponować różne modele opisujące kształtowanie się wariancji i wybrać spośród nich najbardziej adekwatny, stosując dyskryminacyjną regułę największej wiarygodności.

Każdemu z  $g$  zaproponowanych możliwych typów heteroskedastyczności odpowiada określona postać macierzy  $\mathbf{V}$ , której elementy można otrzymać na podstawie schematu obrazującego kształtowanie się wariancji, np. uznając, iż wariancja zależy od wartości bezwzględnej pewnej zmiennej objaśniającej  $X_i$ , z dokładnością do stałej  $\sigma^2$ :

$$\sigma_j^2 = \sigma^2 |X_{ij}|, \quad (3)$$

otrzymuje się macierz kowariancji postaci:

$$\sigma^2 \mathbf{V} = \sigma^2 \begin{bmatrix} |X_{i1}| & 0 & \dots & 0 \\ 0 & |X_{i2}| & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & |X_{in}| \end{bmatrix}. \quad (4)$$

W przypadku bardziej skomplikowanych schematów heteroskedastyczności zachodzi potrzeba estymacji ich parametrów i wyznaczenie wartości teoretycznych (oszacowań wariancji). W procesie szacowania stosuje się wartości bezwzględne lub kwadraty reszt uzyskanych przy szacowaniu parametrów modelu metodą najmniejszych kwadratów.

Po ustaleniu  $g$  postaci macierzy  $\mathbf{V}$  dla  $g$  branych pod uwagę typów heteroskedastyczności można określić  $g$  funkcji wiarygodności postaci (2), odpowiadających poszczególnym schematom. Selekcja najlepszego z nich może zostać dokonana przy użyciu metod analizy dyskryminacyjnej, gdyż zadanie sprowadza się do wyboru jednego spośród skończonej i z góry znanej liczby  $g$  ( $g \geq 2$ ) rodzajów heteroskedastyczności. Dla każdej z rozpatrywanych możliwości istnieje  $n$ -wymiarowy rozkład wektora składników losowych  $\epsilon$ . Każdy wariant ( $i = 1, 2, \dots, g$ ) jest scharakteryzowany poprzez funkcję gęstości  $f_i(\epsilon)$ , a właściwie wiarygodności  $L_i(\epsilon)$ , gdyż wartość jest ustalana przy różnych znanych parametrach rozkładu (elementach macierzy  $\mathbf{V}$ ).

Dyskryminacyjna reguła największej wiarygodności przydziela wektor  $\epsilon$  do tej populacji, dla której funkcja wiarygodności  $L_i(\epsilon)$  ( $i = 1, 2, \dots, g$ ) jest maksymalna, czyli wybrany zostaje schemat heteroskedastyczności, dla którego funkcja określona wzorem (2) osiąga największą wartość wśród wszystkich  $g$  zaproponowanych

możliwości (por. [7; 9]). Ze względu na monotoniczność funkcji logarytmicznej wnioski można formułować również na podstawie wartości  $\ln L_i(\varepsilon)$ .

#### 4. Zastosowanie postulowanej procedury w badaniu empirycznym

Przedstawiona metoda łącząca zalety testu niekonstruktywnego z korzyściami wynikającymi z zastosowania analizy dyskryminacyjnej została wykorzystana do określania rodzaju heteroskedastyczności w jednorównaniowym modelu ekonometrycznym służącym do opisu relacji pomiędzy oczekiwanymi ( $Y$ ) a osiąganymi przez respondentów dochodami ( $X$ ). Prezentowane badanie empiryczne oparte jest na obszernym zbiorze obserwacji pochodzącym z Polskiego Generalnego Sondażu Społecznego<sup>1</sup>. Odpowiadając na pytania ankietera, respondenci wypowiadali się m.in. w kwestiach dotyczących swojej pracy zarobkowej i sytuacji materialnej. Analizie zostały poddane odpowiedzi na następujące pytania zawarte w kwestionariuszu:

Pytanie nr 32: *Biorąc pod uwagę ... rok, proszę powiedzieć, ile wynoszą Pana(-i) przeciętne miesięczne zarobki (dochody) pochodzące z pracy po odjęciu podatków?*

Pytanie nr 34: *A jak Pan(-i) sądzi, na jakie miesięczne wynagrodzenie (dochód z pracy) Pan(i) zasługuje?*

Polski Generalny Sondaż Społeczny przeprowadzany był ośmiokrotnie, począwszy od 1992 r. do 2005 r. Modelowaniu poddano dane dotyczące badania najwcześniejszego oraz najpóźniejszego (1992 r. oraz 2005 r.). W przypadku niekompletnych odpowiedzi respondentów usunięto obserwacje z brakującymi elementami i otrzymano następujące zbiory danych: dla roku 1992 o liczebności 674, dla roku 2005 o liczebności 459. Metodą najmniejszych kwadratów oszacowano parametry modeli liniowych opisujących zależność oczekiwanych dochodów od dochodów osiągniętych. W celu sprawdzenia, czy w modelach występuje zjawisko niejednorodności wariancji, zastosowano test White'a bazujący na tzw. modelu pomocniczym, którego parametry estymuje się, korzystając z kwadratów reszt otrzymanych z modelu podstawowego. Zespół hipotez jest następujący (zob. [3, s. 88]):

$H_0: \beta_k = 0$  parametry modelu pomocniczego są równe zero, czyli wariancja składników losowych modelu podstawowego jest jednorodna,

$H_0: \beta_k \neq 0$  przynajmniej jeden parametr modelu pomocniczego jest różny od zera, czyli wariancja składników losowych modelu podstawowego jest niejednorodna.

<sup>1</sup> Bogdan Cichomski (kierownik programu), Tomasz Jerzyński i Marcin Zieliński. Polskie Generalne Sondaże Społeczne: skumulowany komputerowy zbiór danych 1992-2002. Instytut Studiów Społecznych, Uniwersytet Warszawski, Warszawa 2003.

Model pomocniczy ma postać:

$$\sigma_{e1}^2 = \beta_0 + \sum_{k=1}^K \beta_k x_{kl} + \sum_{\substack{k=K+1 \\ i,j=1}} \beta_k x_{i1} x_{j1} + h_i, \quad i, j = 1, 2, \dots, K, \quad (5)$$

gdzie:  $\beta_0, \beta_1, \dots, \beta_K$  – parametry modelu pomocniczego,  
 $h_i$  – składnik losowy modelu pomocniczego,  
 $K$  – liczba zmiennych objaśniających w modelu pomocniczym.

Statystyka służąca weryfikacji hipotez ma postać  $W = nR^2$ , gdzie  $R^2$  oznacza współczynnik determinacji obliczony dla modelu pomocniczego. Przy prawdziwości hipotezy zerowej statystyka  $W$  ma rozkład  $\chi^2$  z  $K$  stopniami swobody.

Oszacowania parametrów oraz rezultaty testu White’a dla analizowanych modeli przedstawiono w tab. 1.

Tabela 1. Rezultaty estymacji modeli oraz wyniki testu White’a (poziom istotności 0,05)

Rok	Wynik estymacji (MNK) parametrów modelu podstawowego	Wartość statystyki $W$	Wartość krytyczna testu	Wniosek
1992	$\hat{Y} = 1,26 X + 102,11$ (0,04) (12,94)	21,09	5,99	występuje heteroskedastyczność składników losowych
2005	$\hat{Y} = 1,27 X + 480,21$ (0,04) (67,48)	20,25		występuje heteroskedastyczność składników losowych

Źródło: obliczenia własne.

W obydwu rozpatrywanych modelach wystąpiło zjawisko niejednorodności wariancji składników losowych, właściwą metodą estymacji jest więc uogólniona metoda najmniejszych kwadratów. Ponieważ test White’a nie daje podstaw do sformułowania wniosków o mechanizmie kształtującym wariancję, zaproponowano następujące modele heteroskedastyczności:

Model 1:  $\sigma_i^2 = \sigma^2 |X_{ij}|$ .

Model 2:  $\sigma_i^2 = \sigma^2 X_{ij}^2$ .

Model 3:  $\sigma_i = \alpha_0 + \alpha_1 X$ .

Model 4:  $\sigma_i^2 = \alpha_0 + \alpha_1 X$ .

Model 5:  $\sigma_i = \alpha_0 + \alpha_1 X + \alpha_2 X^2$ .

Model 6:  $\sigma_i^2 = \alpha_0 + \alpha_1 X + \alpha_2 X^2$ .

Model 7:  $\sigma_i^2 = \sigma_0^2 X^\alpha$ .

Model 8:  $\sigma_i^2 = \sigma_0^2 \exp(\alpha X)$ .

Po estymacji parametrów sugerowanych modeli metodą najmniejszych kwadratów obliczono wartości teoretyczne, które zastosowano do budowy macierzy  $V$ .

Oszacowane w ten sposób macierze kowariancji dały podstawę do zastosowania dyskryminacyjnej reguły największej wiarygodności. Ponieważ rozpatrywane zbioru obserwacji były duże, wyznaczając wartości funkcji wiarygodności postaci (2) dla modeli 1-8, przybliżono wektor składników losowych modelu za pomocą wektora reszt. Najlepszym z proponowanych typów heteroskedastyczności jest ten, dla którego wartość funkcji wiarygodności (lub jej logarytmu) jest największa. Otrzymane rezultaty zaprezentowano w tab. 2.

Tabela 2. Ocena proponowanych schematów heteroskedastyczności za pomocą logarytmu funkcji wiarygodności

Rok	Wartości logarytmu funkcji wiarygodności							
	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6	Model 7	Model 8
1992	-67 169,6	<b>-3779,8</b>	-4689,5	-5411,3	-4686,1	-4530,4	-5891,8	-6042,6
2005	-180 014,9	-4337,7	-3907,2	<b>-3878,3</b>	-3957,2	<b>-3761,9</b>	-5177,6	-4949,4

Tłustym drukiem zaznaczono modele najlepsze spośród zaproponowanych.

Źródło: obliczenia własne.

W przypadku modelu skonstruowanego dla roku 1992 adekwatny jest prosty typ heteroskedastyczności (model 2), w którym wariancja uzależniona jest od kwadratu zmiennej objaśniającej  $X$  (przeskalowanej o  $\sigma^2$ ). Mechanizm kształtowania się wariancji dla relacji w roku 2005 jest bardziej skomplikowany, model opisujący ma charakter paraboli. Wartości logarytmów funkcji wiarygodności pozwalają również na uporządkowanie proponowanych specyfikacji. W obu przypadkach okazało się, że najgorsze, i znacznie odbiegające *in minus* od pozostałych, jest rozwiązanie najprostsze, uzależniające wartości wariancji bezpośrednio od wartości zmiennej objaśniającej  $X$  (model 1).

Po ustaleniu typu heteroskedastyczności możliwe było zastosowanie UMNK do szacowania parametrów modeli. Ostateczne wyniki estymacji są następujące:

- dla roku 1992:  $\hat{Y} = 1,30 X + 61,30$ ,  
(0,03) (30,98)
- dla roku 2005:  $\hat{Y} = 1,25 X + 501,66$ .  
(0,03) (77,81)

Uwzględnienie faktu występowania niejednorodności wariancji i zastosowanie UMNK prowadzi do nieco odmiennych rezultatów niż aplikacja MNK (por. tab. 1). Współczynnik przy zmiennej  $X$  w modelu dla roku 1992 jest większy niż analogiczny współczynnik dla roku 2005, co oznacza, że wraz ze wzrostem dochodów oczekiwania co do wysokości zarobków wzrastały nieco szybciej w 1992 r. Stosowanie MNK prowadzi do przeciwnego wniosku i mniej wyraźnej różnicy. Stosowanie procedury zawierającej niekonstruktywny test heteroskedastyczności oraz dyskryminacyjnej reguły największej wiarygodności stwarza możliwość otrzymania bardziej precyzyjnych wyników.



## Literatura

- [1] Adijbolosoo S. B-S. K., *Estimation of Parameters of Heteroscedastic Error Models Under Various Hypothesized Error Structures*, „The Statistician” 1993, vol. 42, s. 123-133.
- [2] Davidson R., MacKinnon J., *Estimation and Inference in Econometrics*, Oxford University Press 2003.
- [3] *Ekonometria współczesna*, red. M. Osińska, Toruń 2007.
- [4] Goldfeld S.M., Quandt R.E., *Some Tests for Homoscedasticity*, „Journal of the American Statistical Association” 1965, vol. 60, s. 539-547.
- [5] Greene W.H., *Econometric Analysis*, Prentice Hall, Upper Saddle River, New Jersey 1997.
- [6] Hayashi F., *Econometrics*, Princeton University Press, Princeton N.J 2000.
- [7] Jajuga K., *Statystyczna teoria rozpoznawania obrazów*, PWN, Warszawa 1990.
- [8] Maddala G.S., *Ekonometria*, PWN, Warszawa 2006.
- [9] Mardia K.V., Kent J.T., Bibby J.M., *Multivariate Analysis*, Academic Press, London 1979.
- [10] Ramsey J.B., *Test for Specification Error in Classical Linear Least-Squares Regression Analysis*, „Journal of the Royal Statistical Society, Ser. B” 1969, vol. 31, s. 350-371.
- [11] Ruud P.A., *An Introduction to Classical Econometric Theory*, Oxford University Press, Oxford 2000.
- [12] Szroeter J., *A Class of Parametric Tests for Heteroscedasticity in Linear Econometric Models*, „Econometrica” 1977, vol. 46, s. 1311-1327.
- [13] Tomaszewicz A., *Jednorównaniowe modele ekonometryczne przy nieklasycznych założeniach*, Wydawnictwo Uniwersytetu Łódzkiego, Łódź 1985.
- [14] White H., *A Heteroscedasticity – Consistent Covariance Matrix Estimator and a Direct Test for Heteroscedasticity*, „Econometrica” 1980, vol. 48, s. 817-838.

### A COMBINATION OF CLASSICAL AND NON-CLASSICAL APPROACH TO DISTURBANCE HETEROSCEDASTICITY DETECTION IN THE ECONOMETRIC MODEL

In this paper a concept of heteroscedasticity character determination in the linear econometric model is presented. The suggested method combines classical approach (hypothesis testing) with the maximum likelihood discriminant rule. The suggested solution is illustrated by the empirical analysis of models describing real and expected incomes of Poles.