

## DYNAMICZNE MODELE EKONOMETRYCZNE

X Ogólnopolskie Seminarium Naukowe, 4–6 września 2007 w Toruniu  
Katedra Ekonometrii i Statystyki, Uniwersytet Mikołaja Kopernika w Toruniu

---

*Witold Orzeszko*

*Uniwersytet Mikołaja Kopernika w Toruniu*

### Wykorzystanie koncepcji nieliniowej przyczynowości do identyfikacji autozależności w szeregach czasowych

#### 1. Wprowadzenie

Pojęcie przyczynowości w sensie Grangera pełni kluczową rolę w ekonometrycznej analizie zależności pomiędzy procesami ekonomicznymi. Metodą testowania nieliniowej przyczynowości jest procedura Hiemstry i Jonesa (1994), odwołująca się do koncepcji Baeka i Brocka (1992). Celem niniejszej pracy jest zastosowanie testu Hiemstry i Jonesa w odmienny sposób – do identyfikacji autozależności w szeregach czasowych. Pomysł ten zrealizowano w zastosowaniu do danych symulowanych, a także do szeregów czasowych z Giełdy Papierów Wartościowych w Warszawie.

#### 2. Testowanie przyczynowości w zakresie zależności nieliniowych

Występowanie zależności przyczynowych między stacjonarnymi procesami  $X_t$  i  $Y_t$  zostało zdefiniowane przez Grangera (1969) w kategorii warunkowych rozkładów prawdopodobieństwa. Według tej definicji  $X_t$  nie jest przyczyną  $Y_t$ , jeśli dla dowolnych opóźnień czasowych  $lx, ly \geq 1$  zachodzi równość:

$$F\left(Y_t \mid (X_{t-lx}, \dots, X_{t-1}; Y_{t-ly}, \dots, Y_{t-1})\right) = F\left(Y_t \mid (Y_{t-ly}, \dots, Y_{t-1})\right). \quad (1)$$

W przypadku, gdy warunek (1) nie jest spełniony mówimy, że  $X_t$  jest przyczyną  $Y_t$ , co w szczególności implikuje możliwość wykorzystania przeszłości  $X_t$  do prognozowania  $Y_t$ .

Testowanie występowania zależności przyczynowych polega na weryfikacji hipotezy zerowej, iż  $X_t$  nie jest przyczyną  $Y_t$ . W praktyce, nie weryfikuje się

zawartego w definicji warunku (1), lecz zastępuje się go bardziej operacyjnymi formułami. Jedną z metod jest ograniczenie zakresu badania do identyfikacji zależności przyczynowych jedynie o charakterze liniowym. W takiej sytuacji badanie polega na zbudowaniu i analizie modelu VAR.

Z kolei operacyjną metodą analizy przyczynowych zależności o charakterze nieliniowym jest metoda Baeka i Brocka (1992). Odwołuje się ona do pojęcia całki korelacyjnej  $C_W(\varepsilon)$ , będącej prawdopodobieństwem zdarzenia, iż dwie losowo wybrane realizacje wektora losowego  $W$  oddalone są od siebie o nie więcej niż  $\varepsilon$ , tzn.

$$C_W(\varepsilon) = P\{\|W_1 - W_2\| \leq \varepsilon\} = \iint I(s_1, s_2, \varepsilon) f_W(s_1) f_W(s_2) ds_2 ds_1, \quad (2)$$

gdzie  $W_1, W_2$  są niezależnymi realizacjami wektora  $W$ ,  $\|\cdot\|$  jest normą „supremum”, natomiast funkcja  $I(s_1, s_2, \varepsilon) = \begin{cases} 1; & \|s_1 - s_2\| \leq \varepsilon \\ 0; & \|s_1 - s_2\| > \varepsilon \end{cases}$ .

Dla ustalonych opóźnień czasowych  $lx, ly \geq 1$  niech  $X_{t-lx}^t$  oraz  $Y_{t-ly}^t$  oznaczają wektory opóźnień postaci  $X_{t-lx}^t = (X_{t-lx}, \dots, X_t)$  i  $Y_{t-ly}^t = (Y_{t-ly}, \dots, Y_t)$ . Odwołując się do pojęcia wektorów opóźnień, Baek i Brock przeformułowali definicję przyczynowości w sensie Grangera. Według ich koncepcji  $X_t$  nie jest przyczyną  $Y_t$ , jeśli:

$$\begin{aligned} & P\left\{\|Y_t - Y_s\| < \varepsilon \mid \|Y_{t-ly}^{t-1} - Y_{s-ly}^{s-1}\| < \varepsilon, \|X_{t-lx}^{t-1} - X_{s-lx}^{s-1}\| < \varepsilon\right\} = \\ & = P\left\{\|Y_t - Y_s\| < \varepsilon \mid \|Y_{t-ly}^{t-1} - Y_{s-ly}^{s-1}\| < \varepsilon\right\}, \end{aligned} \quad (3)$$

gdzie  $\|\cdot\|$  jest normą „supremum”.

Niespełnienie warunku (3) oznacza, że  $X_{t-lx}^{t-1} = (X_{t-lx}, \dots, X_{t-1})$  może być pomocne w prognozowaniu  $Y_t$ . Ta interpretacja przyczynowości jest kluczowa dla rozważań zawartych w rozdziale trzecim niniejszego artykułu.

Niech C1, C2, C3 oraz C4 oznaczają następujące całki korelacyjne:

$$C1 = P\left\{\|Y_{t-ly}^t - Y_{s-ly}^s\| < \varepsilon, \|X_{t-lx}^{t-1} - X_{s-lx}^{s-1}\| < \varepsilon\right\}, \quad (4a)$$

$$C2 = P\left\{\|Y_{t-ly}^{t-1} - Y_{s-ly}^{s-1}\| < \varepsilon, \|X_{t-lx}^{t-1} - X_{s-lx}^{s-1}\| < \varepsilon\right\}, \quad (4b)$$

$$C3 = P\left\{\|Y_{t-ly}^t - Y_{s-ly}^s\| < \varepsilon\right\}, \quad (4c)$$

$$C4 = P\left\{\|Y_{t-ly}^{t-1} - Y_{s-ly}^{s-1}\| < \varepsilon\right\}. \quad (4d)$$

Można udowodnić (np. Orzeszko, Osińska), że:

$$P\left\{\|Y_t - Y_s\| < \varepsilon \left\| Y_{t-ly}^{t-1} - Y_{s-ly}^{s-1} \right\| < \varepsilon, \|X_{t-lx}^{t-1} - X_{s-lx}^{s-1}\| < \varepsilon\right\} = \frac{C1}{C2}, \quad (5)$$

$$\text{oraz } P\left\{\|Y_t - Y_s\| < \varepsilon \left\| Y_{t-ly}^{t-1} - Y_{s-ly}^{s-1} \right\| < \varepsilon\right\} = \frac{C3}{C4}. \quad (6)$$

$$\text{A wówczas wzór (3) równoważny jest formule } \frac{C1}{C2} = \frac{C3}{C4}. \quad (7)$$

Równanie (7) jest podstawą procedury testowania występowania zależności przyczynowych w szeregach czasowych  $(x_t)$  i  $(y_t)$ .

Estymatorami całek korelacyjnych C1, C2, C3 oraz C4 są odpowiednio:

$$C1(n) = \frac{2}{n(n-1)} \sum \sum_{t < s} I(y_{t-ly}^t, y_{s-ly}^s, \varepsilon) I(x_{t-lx}^{t-1}, x_{s-lx}^{s-1}, \varepsilon), \quad (8a)$$

$$C2(n) = \frac{2}{n(n-1)} \sum \sum_{t < s} I(y_{t-ly}^{t-1}, y_{s-ly}^{s-1}, \varepsilon) I(x_{t-lx}^{t-1}, x_{s-lx}^{s-1}, \varepsilon), \quad (8b)$$

$$C3(n) = \frac{2}{n(n-1)} \sum \sum_{t < s} I(y_{t-ly}^t, y_{s-ly}^s, \varepsilon), \quad (8c)$$

$$C4(n) = \frac{2}{n(n-1)} \sum \sum_{t < s} I(y_{t-ly}^{t-1}, y_{s-ly}^{s-1}, \varepsilon), \quad (8d)$$

gdzie  $t, s = \max(lx, ly) + 1, \dots, T$ ,  $n = T - \max(lx, ly)$ ,  $T$  – długość szeregów.

Hiemstra i Jones (1994) udowodnili, że dla dowolnych stacjonarnych, słabo zależnych i spełniających warunki Denkera i Kellera (1983), procesów  $X_t$ ,  $Y_t$  oraz dla dowolnych  $lx, ly \geq 1$  i  $\varepsilon > 0$ , jeśli  $X_t$  nie jest przyczyną  $Y_t$ , to:

$$TVAL \stackrel{df}{=} \frac{\sqrt{n}}{\sigma(lx, ly, \varepsilon)} \left( \frac{C1(n)}{C2(n)} - \frac{C3(n)}{C4(n)} \right) \sim N(0,1), \quad (9)$$

gdzie  $\sigma(lx, ly, \varepsilon)$  i jej estymator są zdefiniowane w dodatku artykułu Hiemstry i Jonesa (1994).

Należy podkreślić, że metoda Hiemstry i Jonesa (H–J) identyfikuje zależności przyczynowe różnej natury. Z tego powodu w celu identyfikacji zależności nieliniowych, należy badaniu poddawać dane pozbawione zależności liniowych. Autorzy testu zalecają również, aby dokonać normalizacji danych i w teście rozważyć wartości  $\varepsilon$  pomiędzy 0.5 a 1.5.

### 3. Zastosowanie testu Hiemstry–Jonesa do identyfikacji autozależności w szeregach czasowych

W niniejszej pracy wykorzystano test H–J w odmienny sposób – do identyfikacji autozależności w szeregach czasowych. W tym celu przyjęto w

teście za  $(x_t)$  (tzn. proces – „przyczynę”) szereg złożony z przeszłych realizacji procesu  $(y_t)$  (tzn. procesu – „skutku”). Prowadzi to do weryfikacji istnienia w  $(y_t)$  autozależności o charakterze nieliniowym, które dają potencjalną możliwość prognozowania szeregu  $(y_t)$  w oparciu o jego przeszłość.

Badaniu poddano indeksy pochodzące z GPW w Warszawie, z okresu 2.01.2001-16.05.2007 (1600 obserwacji). Dla każdego z indeksów testowaniu poddano trzy szeregi: logarytmicznych stóp zmian, otrzymanych dla nich reszt z modeli ARMA oraz ARMA-GARCH. Zbadanie reszt z modeli ARMA daje możliwość stwierdzenia, czy ewentualnie wykryte zależności w szeregu stóp zmian mają charakter liniowy. W przypadku odpowiedzi negatywnej, przebadanie standaryzowanych reszt z modelu ARMA-GARCH umożliwia stwierdzenie, czy ta klasa modeli dobrze opisuje zidentyfikowaną nieliniowość.

W teście H–J przyjęto  $\varepsilon = 1.5$  oraz  $lx = ly$  równe kolejno 1, 2, ..., 5. Dla każdego z badanych szeregów (ozn.  $(a_t)$ ) w procedurze testowania przyjęto dwa zestawy szeregów:

- A)**  $(y_t)$  – badany szereg (tzn.  $y_t = a_t$ ),  $(x_t)$  – szereg jego pierwszych opóźnień (tzn.  $x_t = a_{t-1}$ ),
- B)**  $(y_t)$  – szereg złożony z obserwacji o numerach parzystych (tzn.  $y_t = a_{2t}$ ),  $(x_t)$  – szereg złożony z obserwacji nieparzystych (tzn.  $x_t = a_{2t+1}$ ).

W pierwszym zestawie odrzucenie  $H_0$  dla pewnej wartości  $lx = ly$  oznacza, że efektywność prognozowania obserwacji  $a_t$  wzrośnie, gdy wiedza badacza o obserwacjach  $a_{t-1}, a_{t-2}, \dots, a_{t-lx}$  zostanie poszerzona o znajomość wartości  $a_{t-lx-1}$ . Ponieważ  $lx \geq 1$ , więc w ten sposób możliwe jest sprawdzenie istnienia w szeregu zależności między opóźnieniami co najmniej drugiego rzędu. Weryfikację istnienia zależności pomiędzy sąsiednimi obserwacjami umożliwia drugi zestaw, w przypadku którego odrzucenie  $H_0$  oznacza, że wykorzystanie do prognozowania obserwacji  $a_{2t}, a_{2t-2}, \dots, a_{2t-2lx}$  prowadzi do gorszych rezultatów, niż wykorzystanie  $a_{2t}, a_{2t-1}, a_{2t-2}, \dots, a_{2t-2lx+1}, a_{2t-2lx}$ . Przyjmując  $lx = 1$  można zweryfikować, czy  $a_{2t-1}$  wpływa na  $a_{2t}$  pod warunkiem znajomości również  $a_{2t-2}$ . Wadą drugiego zestawu jest fakt, iż badane szeregi stają się dwa razy krótsze, co wpływa negatywnie na wiarygodność testu.

W pierwszej kolejności, przedstawioną powyżej procedurę testowania zastosowano do danych symulowanych. W tym celu, z odwzorowania logistycznego postaci  $a_{t+1} = 4a_t(1 - a_t)$ , dla  $a_0 = 0.7$ , wygenerowano szereg chaotyczny złożony z 1599 obserwacji. W tabeli 1 zaprezentowano wyniki testowania zależności nieliniowych w tym szeregu, dla porównania zestawione z rezultatami otrzymanymi dla białego szumu. W każdej z komórek widoczna jest wartość wyrażenia  $TVAL$  (por. wzór 9). W główce tabeli, symbolami *A* i *B* oznaczono kolumny zawierające wyniki testu dla szeregów skonstruowanych

odpowiednio wg procedur *A* oraz *B*. Symbole \*, \*\*, \*\*\* oznaczają odrzucenie  $H_0$  o braku przyczynowości na poziomie, odpowiednio, 10%, 5% i 1%.

Tabela 1. Wyniki testu Hiemstry-Jonesa dla białego szumu i odwzorowania logistycznego

$lx=ly$	Biały szum ( <i>A</i> )	Biały szum ( <i>B</i> )	Odwzor. logist ( <i>A</i> )		Odwzor. logist ( <i>B</i> )	
			szereg	GARCH(1,1)	szereg	GARCH(1,1)
1	-0.389	1.038	<b>-13.689***</b>	<b>-3.606***</b>	<b>4.262***</b>	<b>4.141***</b>
2	0.312	0.407	<b>4.681***</b>	-0.533	<b>4.303***</b>	<b>3.860***</b>
3	0.286	0.051	<b>-3.803***</b>	0.827	<b>4.379***</b>	<b>3.088***</b>
4	0.453	0.966	1.411	0.012	<b>3.654***</b>	<b>2.189**</b>
5	0.102	-0.438	-1.023	-0.940	<b>3.105***</b>	<b>2.136**</b>

Źródło: obliczenia własne.

Jak widać, w przypadku białego szumu test nie wykazał obecności zależności pomiędzy obserwacjami. Odmienny, a jednocześnie zgodny z oczekiwaniami, rezultat otrzymano dla odwzorowania logistycznego. Zarówno dla zestawu *A*, jak i *B*, test wykazał istnienie zależności w szeregu. Ponieważ dokonana analiza autokorelacji wskazała na brak zależności liniowych, więc otrzymane wyniki trafnie oznaczają nieliniowość. Model GARCH tylko w ograniczonym stopniu był w stanie opisać zidentyfikowane zależności. Z kolei w tabelach 2-11 zaprezentowano wyniki testu H–J dla indeksów giełdowych.

Tabela 2. Wyniki testu Hiemstry-Jonesa dla indeksu WIG-BANKI

$lx=ly$	WIG-BANKI ( <i>A</i> )			WIG-BANKI ( <i>B</i> )		
	Stopy zmian	MA(1)	MA(1)- GARCH(1,1)	Stopy zmian	MA(1)	MA(1)- GARCH(1,1)
1	-0.438	-0.542	<b>-3.949***</b>	<b>1.666*</b>	1.292	0.102
2	<b>3.011***</b>	<b>3.027***</b>	1.601	<b>2.248**</b>	<b>2.076**</b>	0.391
3	-0.137	0.182	<b>-1.861*</b>	<b>2.501**</b>	<b>2.220**</b>	0.643
4	<b>1.813*</b>	<b>1.658*</b>	0.528	<b>2.671***</b>	<b>2.276**</b>	0.225
5	1.136	1.190	-0.192	<b>3.352***</b>	<b>2.826***</b>	0.672

Źródło: obliczenia własne.

Tabela 3. Wyniki testu Hiemstry-Jonesa dla indeksu WIG-BUDOW

$lx=ly$	WIG-BUDOW ( <i>A</i> )			WIG-BUDOW ( <i>B</i> )		
	Stopy zmian	AR(1)	AR(1)- GARCH(2,1)	Stopy zmian	AR(1)	AR(1)- GARCH(2,1)
1	<b>2.631***</b>	<b>2.694***</b>	0.412	<b>3.477***</b>	<b>2.852***</b>	-0.944
2	<b>3.882***</b>	<b>3.846***</b>	<b>1.855*</b>	<b>4.188***</b>	<b>4.095***</b>	0.982
3	0.821	1.201	-0.239	<b>4.553***</b>	<b>5.462***</b>	<b>2.150**</b>
4	<b>3.004***</b>	<b>3.149***</b>	1.227	<b>4.282***</b>	<b>5.163***</b>	<b>2.377**</b>
5	<b>1.941*</b>	<b>1.980**</b>	0.493	<b>3.633***</b>	<b>4.600***</b>	1.563

Źródło: obliczenia własne.

Tabela 4. Wyniki testu Hiemstry-Jonesa dla indeksu WIG-INFO

$lx=ly$	WIG-INFO (A)			WIG-INFO (B)		
	Stopy zmian	AR(1)	AR(1)-GARCH(2,1)	Stopy zmian	AR(1)	AR(1)-GARCH(2,1)
1	<b>4.187***</b>	<b>4.230***</b>	-0.262	<b>3.183***</b>	<b>3.383***</b>	0.272
2	<b>4.069***</b>	<b>4.128***</b>	0.840	<b>4.172***</b>	<b>4.185***</b>	-0.024
3	<b>4.782***</b>	<b>4.694***</b>	1.245	<b>3.943***</b>	<b>4.219***</b>	0.485
4	<b>3.506***</b>	<b>3.626***</b>	-0.487	<b>4.290***</b>	<b>3.628***</b>	-0.432
5	<b>2.696***</b>	<b>2.549**</b>	-0.430	<b>4.374***</b>	<b>4.025***</b>	0.081

Źródło: obliczenia własne.

Tabela 5. Wyniki testu Hiemstry-Jonesa dla indeksu MWIG40

$lx=ly$	MWIG40 (A)			MWIG40 (B)		
	Stopy zmian	ARMA(2,1)	ARMA(2,1)-GARCH(1,1)	Stopy zmian	ARMA(2,1)	ARMA(2,1)-GARCH(1,1)
1	<b>4.232***</b>	<b>4.362***</b>	0.469	<b>3.434***</b>	<b>2.395**</b>	-0.295
2	<b>3.665***</b>	<b>3.649***</b>	-0.287	<b>3.586***</b>	<b>2.728***</b>	-1.109
3	<b>3.528***</b>	<b>3.696***</b>	1.625	<b>4.254***</b>	<b>3.738***</b>	-1.169
4	<b>4.566***</b>	<b>4.514***</b>	0.573	<b>4.778***</b>	<b>4.344***</b>	-0.668
5	<b>3.989***</b>	<b>3.465***</b>	0.373	<b>4.235***</b>	<b>3.712***</b>	-1.004

Źródło: obliczenia własne.

Tabela 6. Wyniki testu Hiemstry-Jonesa dla indeksu WIG-SPOZY

$lx=ly$	WIG-SPOZY (A)			WIG-SPOZY (B)		
	Stopy zmian	AR(2)	AR(2)-GARCH(1,1)	Stopy zmian	AR(2)	AR(2)-GARCH(1,1)
1	<b>4.126***</b>	<b>3.949***</b>	-0.796	<b>3.242***</b>	<b>3.091***</b>	0.503
2	<b>3.341***</b>	<b>3.698***</b>	<b>-1.687*</b>	<b>3.896***</b>	<b>3.851***</b>	-0.342
3	<b>3.808***</b>	<b>3.870***</b>	0.054	<b>4.501***</b>	<b>4.498***</b>	0.226
4	<b>3.588***</b>	<b>3.486***</b>	0.750	<b>4.783***</b>	<b>4.823***</b>	-0.019
5	<b>2.879***</b>	<b>3.103***</b>	-0.565	<b>4.519***</b>	<b>4.625***</b>	-0.855

Źródło: obliczenia własne.

Tabela 7. Wyniki testu Hiemstry-Jonesa dla indeksu SWIG80

$lx=ly$	SWIG80 (A)			SWIG80 (B)		
	Stopy zmian	ARMA(2,1)	ARMA(2,1)-GARCH(1,1)	Stopy zmian	ARMA(2,1)	ARMA(2,1)-GARCH(1,1)
1	<b>3.519***</b>	<b>3.906***</b>	1.180	<b>4.302***</b>	<b>2.965***</b>	1.162
2	<b>3.706***</b>	<b>2.667***</b>	0.272	<b>4.983***</b>	<b>3.308***</b>	0.995
3	<b>2.707***</b>	<b>2.148**</b>	0.169	<b>5.262***</b>	<b>3.433***</b>	0.516
4	<b>2.748***</b>	<b>2.006**</b>	0.003	<b>3.764***</b>	<b>2.314**</b>	-0.961
5	<b>3.115***</b>	<b>2.380**</b>	0.619	<b>2.980***</b>	<b>1.779*</b>	-1.631

Źródło: obliczenia własne.

Tabela 8. Wyniki testu Hiemstry-Jonesa dla indeksu TECHWIG

$lx=ly$	TECHWIG (A)			TECHWIG (B)		
	Stopy zmian	AR(1)	AR(1)-GARCH(1,1)	Stopy zmian	AR(1)	AR(1)-GARCH(1,1)
1	<b>4.299***</b>	<b>4.196***</b>	-0.294	<b>3.160***</b>	<b>4.068***</b>	0.108
2	<b>4.393***</b>	<b>4.804***</b>	0.825	<b>4.104***</b>	<b>4.788***</b>	-0.037
3	<b>5.322***</b>	<b>5.390***</b>	<b>1.894*</b>	<b>4.236***</b>	<b>5.325***</b>	0.294
4	<b>4.018***</b>	<b>4.158***</b>	-0.223	<b>4.482***</b>	<b>5.098***</b>	0.359
5	<b>3.091***</b>	<b>3.093***</b>	-0.520	<b>4.873***</b>	<b>5.303***</b>	1.522

Źródło: obliczenia własne.

Tabela 9. Wyniki testu Hiemstry-Jonesa dla indeksu WIG-TELKO

$lx=ly$	WIG-TELKO (A)		WIG-TELKO (B)	
	Stopy zmian	GARCH(1,1)	Stopy zmian	GARCH(1,1)
1	<b>3.797***</b>	0.264	<b>2.573**</b>	0.174
2	<b>3.273***</b>	-1.121	<b>3.184***</b>	-0.577
3	<b>3.728***</b>	1.294	<b>3.489***</b>	-0.162
4	<b>2.664***</b>	0.155	<b>3.575***</b>	-0.447
5	<b>3.372***</b>	0.844	<b>3.360***</b>	-0.393

Źródło: obliczenia własne.

Tabela 10. Wyniki testu Hiemstry-Jonesa dla indeksu WIG

$lx=ly$	WIG (A)			WIG (B)		
	Stopy zmian	AR(1)	AR(1)-GARCH(1,1)	Stopy zmian	AR(1)	AR(1)-GARCH(1,1)
1	0.997	1.026	<b>-2.321**</b>	0.825	0.711	-1.459
2	<b>3.401***</b>	<b>3.368***</b>	0.322	<b>2.179**</b>	<b>1.817*</b>	-1.107
3	<b>2.834***</b>	<b>3.154***</b>	0.301	<b>3.611***</b>	<b>3.415***</b>	0.409
4	<b>4.018***</b>	<b>4.025***</b>	<b>2.266**</b>	<b>4.053***</b>	<b>2.892***</b>	-0.486
5	<b>3.211***</b>	<b>3.453***</b>	0.338	<b>4.538***</b>	<b>3.204***</b>	-0.404

Źródło: obliczenia własne.

Tabela 11. Wyniki testu Hiemstry-Jonesa dla indeksu WIG20

$lx=ly$	WIG20 (A)			WIG20 (B)		
	Stopy zmian	MA(1)	MA(1)-GARCH(1,1)	Stopy zmian	MA(1)	MA(1)-GARCH(1,1)
1	0.625	0.725	<b>-2.949***</b>	0.755	0.671	<b>-2.084**</b>
2	<b>3.558***</b>	<b>3.494***</b>	0.658	<b>2.089**</b>	<b>2.147**</b>	-1.445
3	<b>2.816***</b>	<b>3.034***</b>	0.168	<b>3.297***</b>	<b>3.261***</b>	-0.417
4	<b>3.644***</b>	<b>3.593***</b>	1.621	<b>3.339***</b>	<b>3.285***</b>	-0.465
5	<b>3.140***</b>	<b>3.146***</b>	0.102	<b>4.301***</b>	<b>4.153***</b>	0.033

Źródło: obliczenia własne.

W przypadku wszystkich przebadanych indeksów, test wykazał istnienie autokorelacji w szeregach stóp zmian<sup>1</sup>. Taki sam rezultat otrzymano dla reszt z modelu ARMA, co wskazuje na nieliniowy charakter zidentyfikowanych zależności. W większości wypadków przefiltrowanie modelem ARMA-GARCH zmniejszało (co do modułu) wartości statystyki *TVAL*, jednak w wielu wypadkach (WIG-BUDOW (A) i (B), WIG-SPOZY (A), TECHWIG (A), WIG (A)) model ten nie był w stanie całkowicie opisać charakteru zidentyfikowanych nieliniowości. Co więcej, w niektórych wypadkach (WIG-BANKI (A), WIG (A), WIG20 (A) i (B)) filtrowanie prowadziło do wzrostu wartości statystyki, co również może wskazywać, że wykryte zależności są innej natury niż proces GARCH.

Zidentyfikowanie nieliniowych zależności w szeregach oznacza potencjalną możliwość ich prognozowania. Oczywiście zastosowana w pracy metoda testowania nie daje żadnych wskazówek co do postaci modelu opisującego te zależności. Jednak należy sobie zdawać sprawę z faktu, że ze względu na bogactwo klasy funkcji nieliniowych próba znalezienia właściwego modelu może okazać się daremna. Z tego względu zasadne może być rozważenie innych metod prognozowania (por. np. Orzeszko, 2004). Jednak kwestia wyboru właściwej metody oraz jej zastosowanie do analizowanych w pracy danych, wykracza poza zakres niniejszego artykułu.

## Literatura

- Baek, E.G., Brock, W.A. (1992), A General Test for Nonlinear Granger Causality: Bivariate Model. *Technical Report*. Iowa State University and University of Wisconsin, Madison.
- Denker, M., Keller, G. (1983), On U-statistics and von Mises' Statistics for Weakly Dependent Processes. *Zeitschrift für Wahrscheinlichkeitstheorie und Verwandte Gebiete*, 64, 505-522.
- Diks, C., Panchenko, V (2006), A New Statistics and Practical Guidelines for nonparametric Granger Causality Testing, *Journal of Economic Dynamics and Control*, 30, 1647-1669.
- Granger, C.W.J. (1969), Investigating Causal Relations by Econometric Models and Cross-Spectral Methods. *Econometrica*, 37, 424-438.
- Hiemstra, C., Jones, J.D. (1994), Testing for Linear and Nonlinear Granger Causality in the Stock Price Volume Relation. *Journal of Finance*, 49, 1639-1664.
- Orzeszko, W. (2004) Krótkoterminowe prognozowanie chaotycznych szeregów czasowych, *Przegląd Statystyczny*, vol. 51, 115-127.
- Orzeszko, W., Osińska, M., Analiza przyczynowości w zakresie zależności nieliniowych. Implikacje finansowe, w druku.

---

<sup>1</sup> Autokorelacji w szeregu istnieją, jeśli, dla choć jednej wartości  $lx$ , statystyka *TVAL* wpada do obszaru krytycznego (por. definicję przyczynowości – wzór 1).