

WPLYW CZYNNIKÓW POGODOWYCH NA WIELKOŚĆ I CENY SKUPU PSZENICY I ŻYTA W POLSCE

Agnieszka TŁUCZAK

Uniwersytet Opolski, Wydział Ekonomiczny, Zakład Ekonometrii i Metod Ilościowych

Słowa kluczowe: ceny zbóż, modele VAR, skup zbóż, test Grangera, związki przyczynowe

Streszczenie

W artykule przedstawiono wyniki analizy zależności między wybranymi czynnikami pogodowymi a wielkością skupu oraz cenami pszenicy i żyta w Polsce. W badaniach wykorzystano test przyczynowości Grangera, który opiera się na modelach wektorowej autoregresji. Na podstawie oszacowanych, dla pierwszych przyrostów analizowanych zmiennych, modeli wykazano istnienie zależności pomiędzy czynnikami pogodowymi i wielkością skupu oraz brak tych związków między czynnikami pogodowymi a cenami zbóż w Polsce.

WSTĘP

Rolnictwo jest jedną z tych gałęzi aktywności ludzkiej, na którą warunki pogodowe mają szczególny wpływ. Niekorzystne warunki pogodowe powodują wiele zmian w środowisku naturalnym, które mogą przełożyć się na wymierne straty ekonomiczne. Na całym świecie obserwuje się zjawiska klimatyczne, które mają wpływ na warunki produkcji rolnej. Do głównych czynników wpływających na wielkość tej produkcji, w szczególności roślinnej, można zaliczyć temperaturę powietrza, opady atmosferyczne i usłonecznienie. Niewątpliwie czynniki te, w szczególności temperatura, wpływają na wydłużenie lub skrócenie okresu wegetacyjnego. Mała suma opadów w okresie letnim może doprowadzić do niekorzystnego bilansu wodnego niektórych obszarów. Należy też zwrócić uwagę na wzrost tempera-

tury w okresie lata, powodującej zwiększone parowanie wody i zmniejszanie się jej zapasów w glebie [BAŃSKI, BŁAŻEJCZYK 2011; JACZEWSKA-KALICKA 2008].

Od warunków meteorologicznych, ale również od intensywności produkcji zależy wielkość plonów zbóż, co wpływa na wielkość skupu podstawowych zbóż. Rynek zbóż jest najważniejszym rynkiem branżowym – ziarno zbóż jest wykorzystywane na siew, do spożycia oraz jako surowiec dla różnych przemysłów, w tym dla przemysłu spożywczego, farmaceutycznego oraz spirytusowego. Skup na rynku zbóż jest prowadzony przez cały rok. Charakterystyczna sezonowość skupu zbóż wiąże się z cyklem produkcyjnym. Szczyt skupu występuje tuż po żniwach, czyli w trzecim kwartale każdego roku kalendarzowego. Zwiększona podaż ziarna dostępnego na rynku wpływa bezpośrednio na ceny zbóż w skupie.

Celem badań było ustalenie związków przyczynowych pomiędzy warunkami pogodowymi a wielkością i cenami skupu pszenicy i żyta w Polsce. W tym celu zastosowano test przyczynowości Grangera¹⁾, którego procedura opiera się na modelach wektorowej autoregresji – VAR.

METODY I MATERIAŁ BADAWCZY

Modele VAR są licznie prezentowane w literaturze ekonometrycznej, dlatego w niniejszym opracowaniu zostaną przedstawione ich ogólne założenia.

Modele wektorowej autoregresji, które sformułował Sims w 1980 r., są to modele wielorównaniowe, w których każda zmienna jest objaśniana przez swoje opóźnienia oraz przez opóźnienia pozostałych zmiennych. Podstawowa postać modelu VAR przedstawia się następująco [KUSIDEŁ 2000]:

$$y_t = A_0 D_t + \sum_{i=1}^k A_i y_{t-i} + e_t \quad t = 1, 2, \dots, T \quad (1)$$

gdzie:

y_t – wektor obserwacji na bieżących wartościach wszystkich n zmiennych modelu: $y_t = \{y_{1t}, y_{2t}, \dots, y_{nt}\}$;

D_t – wektor deterministycznych składników równań;

A_0 – macierz parametrów przy zmiennych wektora D_t ;

A_i – macierze parametrów przy opóźnionych zmiennych wektora y_t , macierze A_0 i A_i nie zawierają zerowych elementów;

e_t – wektor stacjonarnych zakłóceń losowych²⁾;

t – numer obserwacji.

¹⁾ Definicja przyczynowości w sensie Grangera głosi, że zmienna x jest przyczyną zmiennej y , jeżeli bieżące wartości zmiennej y można prognozować z większą dokładnością za pomocą przeszłych wartości zmiennej x niż bez ich wykorzystania, z założeniem, że pozostała informacja jest niezmienną.

²⁾ Składniki losowe powinny charakteryzować się brakiem autokorelacji oraz rozkładem normalnym.

Model (1) jest szacowany klasyczną metodą najmniejszych kwadratów, a uzyskane estymatory są zgodne i asymptotycznie efektywne. Głównym celem stosowania modeli VAR jest znalezienie istotnych powiązań między zmiennymi. Istotną kwestią w modelowaniu wektorowej autoregresji jest stacjonarność zmiennych³⁾.

Do badania stacjonarności został wykorzystany najpopularniejszy test, a mianowicie rozszerzony test Dickeya-Fullera (test ADF), bazujący na oszacowaniu parametrów równania:

$$\Delta y_t = \mu + \delta y_{t-1} + \sum_{i=1}^k \delta_i \Delta y_{t-i} + \varepsilon_t \quad (2)$$

lub

$$\Delta y_t = \delta y_{t-1} + \sum_{i=1}^k \delta_i \Delta y_{t-i} + \varepsilon_t \quad (3)$$

Statystyka testowa przyjmuje postać:

$$DF = \frac{\hat{\delta}}{S(\hat{\delta})} \quad (4)$$

gdzie:

$\hat{\delta}$ – ocena parametru z równania (2) lub (3) oszacowanego klasyczną metodą najmniejszych kwadratów;

$s(\hat{\delta})$ – średni błąd szacunku parametru δ .

Statystyka DF pozwala na weryfikację hipotez: $H_0: \delta = 0$ (brak stacjonarności) wobec hipotezy $H_1: \delta \neq 0$ (proces jest stacjonarny) [KUSIDEŁ 2000].

W celu ustalenia rzędu opóźnień, podobnie jak w przypadku modeli ARMA, stosuje się kryteria informacyjne, a na użytek tej pracy, zwrócimy szczególną uwagę na kryterium SBC (Schwarz Bayesian Criterion), dla którego statystyka ma postać [KUSIDEŁ 2000]:

$$SBC_l = l(\tilde{\theta}) - \frac{1}{2} k \cdot \log T \quad (5)$$

gdzie:

$l_T(\tilde{\theta})$ – maksymalna wartość logarytmu wiarygodności modelu, w którym $\tilde{\theta}$ jest estymatorem największej wiarygodności;

³⁾ Brak stacjonarności zmiennych może prowadzić do obiecujących wyników, nawet jeśli regresja nie będzie miała sensu. Stacjonarność w węższym sensie, bo taką będziemy się interesować na potrzeby badań, oznacza stałość średniej oraz wariancji w czasie oraz niezależność kowariancji od czasu.

k – liczba szacowanych parametrów;
 T – liczba obserwacji.

Procedura stosowania testu Grangera rozpoczyna się od oszacowania parametrów modeli [BORKOWSKI 2005; CHAREMZA, DEADMAN 1997]:

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t \quad (6)$$

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \beta_p x_{t-p} + \eta_t \quad (7)$$

gdzie:

x_t – realizacja zmiennej X ;
 y_t – realizacja zmiennej Y ;
 p – rząd opóźnień zmiennych.

W teście Grangera weryfikacji poddaje się hipotezy postaci:
 $H_0 : \sigma^2(\varepsilon_t) = \sigma^2(\eta_t)$; $H_1 : \sigma^2(\varepsilon_t) \neq \sigma^2(\eta_t)$.

Statystyka testowa ma postać:

$$F = \frac{n \cdot (s^2(\varepsilon_t) - s^2(\eta_t))}{s^2(\varepsilon_t)} \quad (8)$$

gdzie:

n – liczebność próby;
 $s^2(\varepsilon_t)$, $s^2(\eta_t)$ – wariancje składników losowych odpowiednio modelu (6) i (7),
i zakładając prawdziwość hipotezy zerowej ma ona rozkład chi-kwadrat $\chi^2_\alpha(p)$.

Dane miesięczne o warunkach pogodowych, wielkości skupu zbóż oraz o cenach skupu zbóż zaczerpnięto z Biuletynów Statystycznych Głównego Urzędu Statystycznego [GUS 2011]. W badaniach uwzględniono następujące czynniki pogodowe: temperatura w °C, opady atmosferyczne w mm, zachmurzenie w oktanach, usłonecznienie w h oraz wielkość skupu w tysiącach ton pszenicy oraz żyta, jak również ceny tych zbóż w skupie w zł·(100 kg)⁻¹.

Ze względu na wielość zmiennych przyjęto następujące oznaczenia:

v_1 – średnia temperatura, °C;
 v_2 – suma opadów atmosferycznych w miesiącu, mm;
 v_3 – średnie zachmurzenie, w oktanach;
 v_4 – suma usłonecznienia w miesiącu, h;
 v_5 – wielkość skupu pszenicy, tys. t.;
 v_6 – wielkość skupu żyta, tys. t.;

v_7 – średniomiesięczna cena pszenicy, zł·(100 kg)⁻¹;

v_8 – średniomiesięczna cena żyta, zł·(100 kg)⁻¹.

WYNIKI BADAŃ

W opracowaniu zbadano występowanie związków przyczynowych pomiędzy warunkami pogodowymi a wielkością skupu oraz cenami podstawowych zbóż w Polsce, w okresie od października 2002 r. do grudnia 2010 r.

Wszystkie analizowane zmienne charakteryzują się dużym bądź umiarkowanym zróżnicowaniem – współczynnik zmienności dla zmiennych, opisujących warunki pogodowe, kształtuje się na średnim poziomie 58% (tab. 1). Najmniejszym zróżnicowaniem charakteryzuje się zmienna v_3 – średnie zachmurzenie w oktanach (wsp. zmienności 19%) oraz zmienna v_7 – średniomiesięczna cena pszenicy w zł·(100 kg)⁻¹ (wsp. zmienności 27%) (rys. 1). Pozostałe podstawowe statystyki opisowe dla analizowanych zmiennych przedstawiono w tabeli 1.

Tabela 1. Podstawowe statystyki opisowe analizowanych zmiennych

Table 1. The basic characteristic of the individual time series

Parametry Parameters	Wyszczególnienie Specification							
	v_1	v_2	v_3	v_4	v_5	v_6	v_7	v_8
Średnia Mean	8,4	54,2	5,2	157,1	314,9	47,2	53,9	42,6
Odchylenie standardowe Standard deviation	7,71	31,11	0,99	99,55	247,54	43,37	14,68	13,45
Współczynnik zmienności, % Variation coefficient, %	92	57	19	63	79	92	27	32
Minimum Minimum	-7,2	9,0	2,5	14,6	59,2	9,5	34,5	25,3
Maximum Maximum	22,1	157,4	7,1	405,1	1412,9	265,1	92,2	73,7
Mediana Median	8,5	44,9	5,2	146,6	237,9	34,4	49,4	36,3





Objaśnienia: v_1 – średnia temperatura w °C, v_2 – suma opadów atmosferycznych w miesiącu w mm, v_3 – średnie zachmurzenie w oktanach, v_4 – suma usłonecznienia w miesiącu w h, v_5 – wielkość skupu pszenicy w tys. t, v_6 – wielkość skupu żyta w tys. t, v_7 – średniomiesięczna cena pszenicy w zł·(100 kg)⁻¹, v_8 – średniomiesięczna cena żyta w zł·(100 kg)⁻¹.

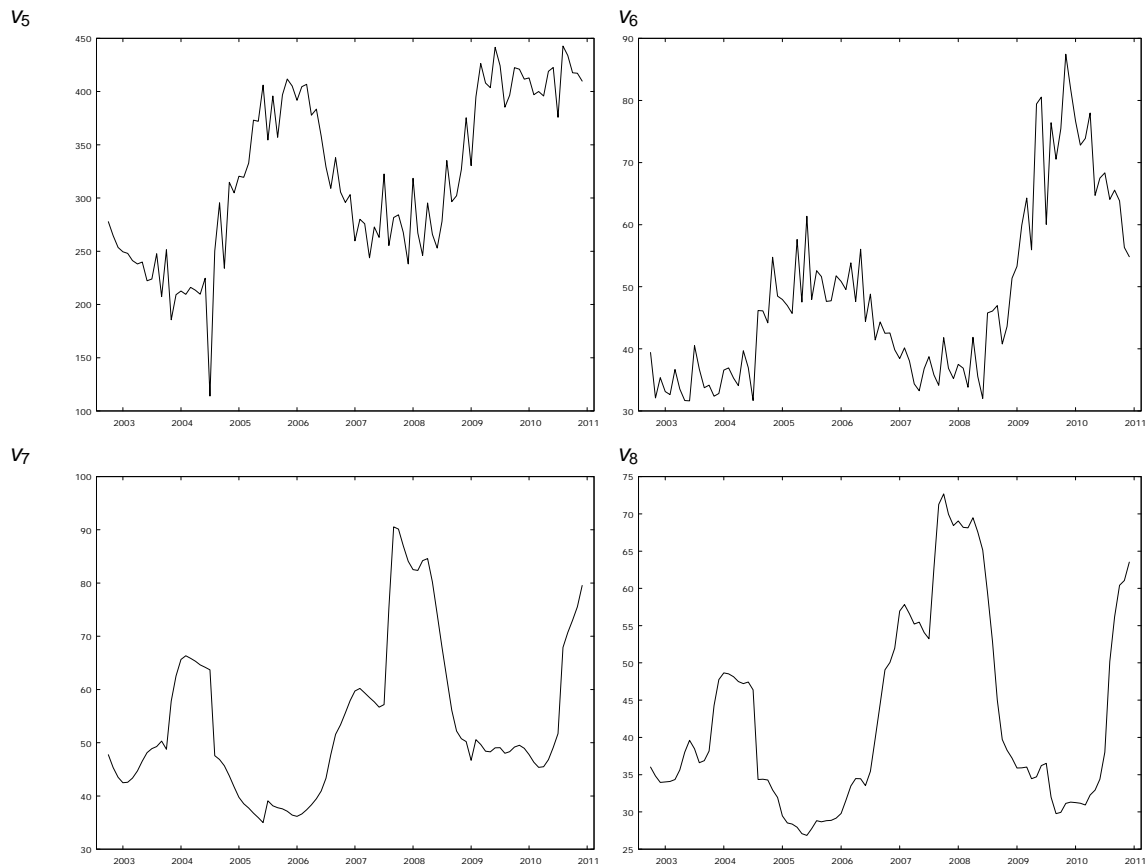
Źródło: obliczenia własne na podstawie danych GUS.

Explanations: v_1 – mean temperature in °C, v_2 – monthly sum of precipitation in mm, v_3 – mean cloudiness in octanes, v_4 – monthly sum of insolation in h, v_5 – purchase of wheat in thousand tons, v_6 – purchase of rye in thousand tons, v_7 – monthly mean price of wheat in zł·(100 kg)⁻¹, v_8 – monthly mean price of rye in zł·(100 kg)⁻¹.

Source: own studies acc. to GUS data.

W celu sprowadzenia zmiennych do porównania, dokonano ich oczyszczenia z wahań sezonowych i przypadkowych, wykorzystując dostępną w programie GRETL procedurę TRAMO/SEATS. Procedurę tę szczegółowo opisały m.in. GRUDKOWSKA i PAŚNICKA [2007].

V1**V2****V3****V4**



Rys. 1. Kształtowanie się miesięcznych wartości analizowanych zmiennych w okresie 10.2002–12.2010;
 źródło: opracowanie własne na podstawie danych GUS

Fig. 1. The monthly values of the analyzed variables for the period 10.2002–12.2010; source: own studies acc. GUS data

Modelowanie za pomocą modeli VAR wymaga, aby zmienne były stacjonarne, zatem w pierwszej kolejności zbadano stacjonarność zmiennych v_i , $i = 1, \dots, 8$. Na podstawie testu ADF, gdy poziom istotności wynosi 0,05, odrzucono hipotezę o stacjonarności zmiennych. Za stacjonarne uznano pierwsze przyrosty zmiennych Δv ⁴⁾.

Tabela 2. Wyniki testu ADF dla zmiennych v_i oraz Δv_i , $i = 1, \dots, 8$

Table 2. The results of ADF test for variables v_i and Δv_i , $i = 1, \dots, 8$

Zmienna Variable	Wartość statystyki ADF ADF statistic	<i>p</i> -value	Zmienna Variable	Wartość statystyki ADF ADF statistic	<i>p</i> -value
v_1	-2,3167	0,1666	Δv_1	-3,7980	0,0029
v_2	-1,7665	0,3977	Δv_2	-3,8380	0,0025
v_3	-2,5811	0,0968	Δv_3	-3,8679	0,0022
v_4	-2,4063	0,1399	Δv_4	-3,4393	0,0097
v_5	-1,8796	0,3423	Δv_5	-2,8827	0,0473
v_6	-2,9256	0,2424	Δv_6	-2,3385	0,0187
v_7	-2,1292	0,2332	Δv_7	-2,5533	0,0103
v_8	-2,3225	0,1648	Δv_8	-2,0629	0,0375

Źródło: wyniki własne. Source: own studies.

W kolejności ustalono rzędy opóźnień dla modeli VAR, podczas wyboru optymalnego rzędu opóźnień kierowano się kryterium informacyjnym Schwarz – SBC (tab. 3). W tym celu oszacowano następujące modele (tab. 4):

Dla przyjętych opóźnień, w wyniku estymacji modeli w programie GRETL [Program komputerowy: GRETL 2011], otrzymano następujące modele teoretyczne:

$$\text{model 1: } \Delta v_5 = -0,589469\Delta v_{5t-1} - 0,300120\Delta v_{5t-2} - 0,0427684\Delta v_{1t-1} + 0,449127\Delta v_{1t-2}$$

$$\text{model 2: } \Delta v_5 = -0,609915\Delta v_{5t-1} - 0,285960\Delta v_{5t-2} + 0,178634\Delta v_{2t-1} + 0,0482382\Delta v_{2t-2}$$

$$\text{model 3: } \Delta v_5 = -0,566498\Delta v_{5t-1} - 0,269276\Delta v_{5t-2} + 3,42942\Delta v_{3t-1} + 0,0482382\Delta v_{3t-2}$$

$$\text{model 4: } \Delta v_5 = -0,588936\Delta v_{5t-1} - 0,277790\Delta v_{5t-2} - 0,0856477\Delta v_{4t-1} + 0,0304205\Delta v_{4t-2}$$

$$\text{model 5: } \Delta v_6 = -0,563008\Delta v_{6t-1} - 0,271136\Delta v_{6t-2} + 0,172637\Delta v_{1t-1} + 0,250984\Delta v_{1t-2}$$

$$\text{model 6: } \Delta v_6 = -0,562326\Delta v_{6t-1} - 0,273043\Delta v_{6t-2} + 0,00463315\Delta v_{2t-1} - 0,0148284\Delta v_{2t-2}$$

$$\text{model 7: } \Delta v_6 = -0,561230\Delta v_{6t-1} - 0,243921\Delta v_{6t-2} - 0,642775\Delta v_{3t-1} - 1,35563\Delta v_{3t-2}$$

$$\text{model 8: } \Delta v_6 = -0,556259\Delta v_{6t-1} - 0,251740\Delta v_{6t-2} + 0,00458232\Delta v_{4t-1} + 0,0204715\Delta v_{4t-2}$$

$$\text{model 9: } \Delta v_7 = 0,446435\Delta v_{7t-1} + 0,0338472\Delta v_{1t-1}$$

$$\text{model 10: } \Delta v_7 = 0,447939\Delta v_{7t-1} - 0,00147211\Delta v_{2t-1}$$

$$\text{model 11: } \Delta v_7 = 0,445294\Delta v_{7t-1} + 0,0529676\Delta v_{3t-1}$$

⁴⁾ Pierwsze przyrosty zmiennych Δv oznaczają różnicę pomiędzy poziomem zmiennej w okresach t oraz $t-1$, $\Delta v = v_t - v_{t-1}$.

Tabela 3. Wartości statystyki SBC oraz rzędy opóźnień dla szacowanych modeli**Table 3.** The values of BIC statistics for chosen rank of delay models

Model Model	Rząd opóźnień Rank of delay	SBC	Model Model	Rząd opóźnień Rank of delay	SBC
1	2	9,948683	9	1	5,6430
2	2	9,946221	10	1	5,6744
3	2	9,897682	11	1	5,6350
4	2	9,948225	12	1	5,6429
5	2	6,566880	13	1	4,9356
6	2	6,574893	14	1	4,9199
7	2	6,557804	15	1	4,9213
8	2	6,559559	16	1	4,9356

Źródło: wyniki własne. Source: own studies.

Tabela 4. Modele VAR**Table 4.** VAR models

Model Model	Zmienna endogeniczna Endogenous variable	Zmienna egzogeniczna Exogenous variable	Model Model	Zmienna endogeniczna Endogenous variable	Zmienna egzogeniczna Exogenous variable
1		Δv_1	9		Δv_1
2		Δv_2	10		Δv_2
3	Δv_5	Δv_3	11	Δv_7	Δv_3
4		Δv_4	12		Δv_4
5		Δv_1	13		Δv_1
6		Δv_2	14		Δv_2
7	Δv_6	Δv_3	15	Δv_8	Δv_3
8		Δv_4	16		Δv_4

Źródło: wyniki własne. Source: own studies.

model 12: $\Delta v_7 = 0,448152\Delta v_{8t-1} + 0,00403591\Delta v_{4t-1}$

model 13: $\Delta v_8 = 0,570294\Delta v_{8t-1} + 0,0297358\Delta v_{1t-1}$

model 14: $\Delta v_8 = 0,567968\Delta v_{8t-1} + 0,00190859\Delta v_{2t-1}$

model 15: $\Delta v_8 = 0,570628\Delta v_{8t-1} - 0,0219818\Delta v_{3t-1}$

model 16: $\Delta v_8 = 0,571664\Delta v_{8t-1} + 0,00282880\Delta v_{4t-1}$

Za pomocą testu Jarque-Bera zweryfikowano hipotezy o normalności rozkładów składników losowych [THADEWALD, BUNNING 2007], natomiast test mnożnika Lagrange'a LM posłużył do weryfikacji hipotez o braku autokorelacji składników losowych modeli [OSIŃSKA 2007]. Na poziomie istotności 0,05 składniki losowe wszystkich modeli charakteryzowały się pożądanymi własnościami, czyli rozkładem normalnym i brakiem autokorelacji.

Uzyskane w teście Grangera wyniki pozwoliły zidentyfikować jednokierunkowe zależności przyczynowe pomiędzy analizowanymi zmiennymi (tab. 5). Na podstawie statystyki testu G można stwierdzić, że zmienne Δv_1 , Δv_2 , Δv_3 , Δv_4 (które są pierwszymi różnicami następujących zmiennych: temperatura w °C, opady atmosferyczne w mm, zachmurzenie w oktanach, usłonecznienie w h) są przyczynami dla zmiennej Δv_5 (pierwsze różnice zmiennej wielkość skupu pszenicy, w tys. t). Natomiast na zmienną Δv_6 (pierwsze różnice zmiennej wielkość skupu żyta, w tys. t) mają wpływ zmienne Δv_1 , Δv_2 (pierwsze różnice zmiennych: temperatura, w °C, opady atmosferyczne, w mm). W pozostałych przypadkach różnice pomiędzy modelami 3 i 4 są nieistotne, zatem nie występują zależności przyczynowe między zmiennymi w sensie Grangera.

Tabela 5. Wartości statystyki Grangera G oraz wartości krytyczne $\chi^2_{0,05}$

Table 5. The values of Granger test statistic and critical value of $\chi^2_{0,05}$

Model	Wartość statystyki G The value of G statistic	$\chi^2_{0,05}$	Model	Wartość statystyki G The value of G statistic	$\chi^2_{0,05}$
1	10,9003	5,9914	9	1,3743	3,8414
2	9,3536	5,9914	10	1,3864	3,8414
3	7,6044	5,9914	11	1,3869	3,8414
4	9,2287	5,9914	12	1,2225	3,8414
5	6,4492	5,9914	13	2,2530	3,8414
6	6,3000	5,9914	14	2,2545	3,8414
7	4,8834	5,9914	15	2,2834	3,8414
8	5,2850	5,9914	16	2,1146	3,8414

Źródło: wyniki własne. Source: own study.

PODSUMOWANIE

Przeprowadzone badania wykazały, że modele VAR są użytecznym narzędziem identyfikacji związków przyczynowych między zmiennymi. W niniejszym opracowaniu przedstawiono wyniki badań zależności między warunkami meteorologicznymi a wielkością skupu pszenicy i żyta w Polsce oraz warunkami meteorologicznymi a cenami skupu tychże zbóż. Wyniki potwierdziły hipotezę o występowaniu jednokierunkowych zależności między czynnikami meteorologicznymi a wielkością skupu, a co za tym idzie ilością zboża, jaką rolnicy uzyskują ze swoich upraw. Nie wykryto istotnych związków między czynnikami meteorologicznymi a cenami tych zbóż w Polsce. Brak tych związków wynika przypuszczalnie z obowiązującej Wspólnej Polityki Rolnej oraz daleko posuniętego interwencjonizmu cenowego na wspólnotowych rynkach rolnych.

LITERATURA

- BORKOWSKI B. 2005. Wnioskowanie o przyczynowości na podstawie modeli VAR [online]. [Dostęp 20.04.2011] Dostępny w Internecie: <http://www.warsztaty.wnr.edu.pl/10/sesjanauko/referatuucz/borkowski.pdf>
- BAŃSKI J., BŁAŻEJCZYK K. 2011. Globalne zmiany klimatu, wpływ na rozwój rolnictwa na świecie [online]. [Dostęp 20.04.2011] Dostępny w Internecie: http://www.igipz.pan.pl/zpz/banski/PDF/6_Globalne_zmiany.pdf
- CHAREMZA W., DEADMAN D. 1997. Nowa ekonometria. Warszawa. Polskie Wydawnictwo Ekonomiczne ss. 123–146.
- GUS 2011. Biuletyn statystyczny [online]. Warszawa. [Dostęp 20.04.2011]. Dostępny w Internecie: http://www.stat.gov.pl/gus/5840_738_PLK_HTML.htm
- GRUDKOWSKA S., PAŚNICKA E. 2007. X-12-ARIMA i TRAMO/SEATS – empiryczne porównanie metod wyrównania sezonowego w kontekście długości próby [online]. Warszawa. [Dostęp 20.04.2011]. Dostępny w Internecie: www.nbp.pl/publikacje/materialy_i_studia/ms220.pdf
- JACZEWSKA-KALICKA A. 2008. Wpływ zmian klimatycznych na plonowanie i ochronę zbóż w Polsce [online]. Warszawa. [Dostęp 20.04.2011]. Dostępny w Internecie: <http://www.progress.plantprotection.pl/pliki/2008/48-2-26>
- KUSIDEL E. 2000. Modele wektorowo-autoregresyjne VAR. Metodologia i zastosowania. Łódź. Wydaw. Absolwent s. 14–40.
- OSIŃSKA M. 2007. Ekonometria współczesna. Toruń. Wydaw. Dom Organizatora ss. 367–406.
- Program komputerowy GRET 2011. Dostępny w Internecie: <http://www.kufel.torun.pl>
- THADEWALD T., BUNING H. 2007. Jarque–Bera test and its competitors for testing normality – a power comparison. *Journal of Applied Statistics*. Vol. 34 no. 1 s. 87–105.

Agnieszka TŁUCZAK

THE EFFECT OF WEATHER CONDITIONS ON THE PURCHASE AND PRICE OF WHEAT AND RYE IN POLAND

Key words: causal relationships, cereal prices, cereal procurement, Granger test, VAR models

S u m m a r y

The article presents the results of analysis of the relationship between selected climatic factors and the purchase of cereals and cereal prices in Poland. The study used the causality Granger test, which is based on the vector autoregression models. Based on the estimated models the author shows the relationships between weather and the quantity of purchase and a lack of such relationships between weather and the prices of cereals in Poland.

Praca wpłynęła do Redakcji 17.05.2011 r.