

Julita Bilakiewicz, Agnieszka Mruklik

Uniwersytet Przyrodniczy we Wrocławiu

REAKCJA CEN RZEPAKU W POLSCE NA ZMIANY INDEKSU GIEŁDOWEGO – UJĘCIE EKONOMETRYCZNE

THE REACTION OF PRICES OF RAPE IN POLAND TO CHANGES IN STOCK INDEX – ECONOMETRIC CONCEPTUALIZATION

Słowa kluczowe: cena rzepaku, indeks giełdowy, model ekonometryczny, prognoza punktowa

Key words: price of rape, stock index, econometric model, point forecast

JEL codes: Q11, Q13, C51, C53

Abstrakt. Zbadano korelację liniową między indeksami giełdowymi WIG, WIG20 i WIG-Spożywczy a cenami rzepaku w Polsce. Na podstawie zgromadzonych danych skonstruowano model ekonometryczny. W rozpatrywanym modelu ekonometrycznym zmienną objaśnianą była kwartalna cena rzepaku w Polsce. Zmiennymi objaśniającymi były czas i notowanie indeksu WIG-Spożywczy. Wykorzystano dane z lat 2004-2016. Model ten został oszacowany, zweryfikowany statystycznie, a następnie zastosowany do wyznaczenia prognoz punktowych cen rzepaku w Polsce w dwóch pierwszych kwartałach roku 2017.

Wstęp

Rolnictwo jest ważnym działem gospodarki, ponieważ jego głównym celem jest produkcja żywności. Mimo rozwoju cywilizacyjnego i postępu technicznego rolnictwo nadal jest uzależnione od czynników przyrodniczych, takich jak rzeźba terenu, klasa bonitacyjna gleby, klimat. Produkcja roślinna zależy także od nieprzewidywalnych warunków pogodowych, takich jak susza czy grad. Wszystkie te czynniki wpływają na wielkość wytworzonych produktów rolnych, zarówno pod względem ilościowym, jak i jakościowym. Cena surowców rolnych zależy m.in. od podaży oraz popytu w kraju i na rynkach światowych. Wraz z wstąpieniem Polski do Unii Europejskiej (UE) na rynki rolne wpływają także postanowienia wspólnej polityki rolnej (WPR). Wpływ na ceny produktów rolnych mają także inne podejmowane działania, w tym np. embargo. Specyficzny charakter produkcji rolnej wymaga również działań interwencyjnych ze strony państwa. Działania te mają zapewnić wysokość cen surowców na poziomie akceptowanym przez konsumentów, a producentom mają przynieść odpowiednie dochody. Interwencjonizm na rynku rolnym jest konieczny ze względu na niską elastyczność popytu na produkty rolne, ma zapobiegać powstaniu niedoboru lub nadwyżki artykułów żywnościowych.

Najwięksi producenci rolni, przedsiębiorstwa z rynku artykułów żywnościowych oraz przedsiębiorstwa z rynku napojów działający jako spółki akcyjne z siedzibą w Polsce i na Ukrainie, weszli na Giełdę Papierów Wartościowych w Warszawie (GPW). Stworzony został indeks WIG-Spożywczy, do którego należy 27 spółek. Jest to indeks sektorowy. Ma on na celu informowanie inwestorów o sytuacji na rynku żywnościowym.

Biorąc pod uwagę powiązania między poszczególnymi sektorami gospodarki, można przypuszczać, że ceny produktów rolnych zależą także od notowań indeksów giełdowych. Analizie zostały poddane notowania indeksów WIG, WIG20 oraz WIG-Spożywczy. Zbadano korelację liniową między notowaniami giełdowymi a cenami rzepaku w Polsce. Na podstawie zgromadzonych danych stworzono model ekonometryczny, który wyjaśnia kształtowanie się zmiennej objaśnianej (skutku) w zależności od zmiennych objaśniających (przyczyn). Model ten został oszacowany, zweryfikowany statystycznie, a następnie zastosowany do wyznaczenia prognoz punktowych cen rzepaku w Polsce w dwóch pierwszych kwartałach 2017 roku.

Rośliny oleiste, a wśród nich i rzepak uprawia się, aby uzyskać materiał siewny, paszę dla zwierząt, z przeznaczeniem do bezpośredniej konsumpcji przez ludzi, ale przede wszystkim, żeby przerobić te rośliny na oleje i śruty [Boczar 2007]. W skali globalnej rośnie popyt na żywność i energię odnawialną. Skutkiem tego jest m.in. obserwowane od początku lat 90. ubiegłego wieku występowanie silnego wzrostu światowej produkcji nasion oleistych, w tym rzepaku. Polska pozostaje jednym z największych producentów rzepaku w Europie. Wejście Polski do UE i jej polityka w zakresie biopaliw i energii odnawialnej przyczyniła się zarówno do rozwoju produkcji, jak i przetwórstwa, a także handlu rzepakiem i produktami jego przerobu. Przewiduje się, że rosnąca na świecie konkurencja o surowce rolne, w tym surowce oleiste, pomiędzy sektorem spożywczym i biopaliwowym będzie przyczyniała się do utrzymywania ich cen na wysokich poziomach [Rosiak 2012]. Niemniej badania wskazują, że obserwowany w świecie wzrost poziomu i zmienności cen surowców rolnych w znacznej mierze jest uwarunkowany polityką biopaliwową państw [Hamulczuk 2014]. Biopaliwa w Polsce opierają się w 90% na surowcach krajowych, a ważną rolę pełni rzepak. Na produkcję biopaliw trafia ponad 60% jego krajowej produkcji, czyli blisko 2 mln t (odnawialneźródłaenergii.pl). W latach 2005-2014 w Polsce miał miejsce znaczny wzrost produkcji rzepaku. Było to spowodowane przede wszystkim rozwojem sektora biopaliw transportowych. Czynnikiem stymulującym rozwój produkcji biopaliw w Polsce jest Narodowy Cel Wskaźnikowy (NCW), który w 2020 roku ma wynieść 10% [Chibowski i in. 2016].

Metody prognozowania można podzielić na dwie główne grupy:

- metody matematyczno-statystyczne (ilościowe),
- metody niematematyczne (jakościowe, heurystyczne) [Tłuczak 2011].

Badacze zajmujący się modelowaniem oraz prognozowaniem cen wybranych produktów rolnych w Polsce stosowali na ogół metody matematyczno-statystyczne, przy czym przeważały sposoby z użyciem danych w postaci szeregów czasowych. Janusz Majewski [2006] badał zmiany cen skupu mleka w Polsce w latach 1993-2006 i wskazał kilka bazujących na szeregach czasowych sposobów predykcji tych cen. Jarosław Lira [2013] ocenił przydatność modelu Wintersa do prognozowania cen skupu mleka w Polsce. Hanna Dudek opisała ceny skupu mięsa drobiowego w Polsce sezonowym modelem ARIMA [2005].

Natomiast Mariusz Hamulczuk [2006] wykorzystał modele ARIMA w prognozowaniu cen wieprzowiny w Polsce. Z kolei J. Lira [2011] ocenił dokładność krótkoterminowych prognoz targowiskowych cen żywca wieprzowego uzyskanych z uwzględnieniem wahań cyklicznych i sezonowych na podstawie modelu multiplikatywnego według zmodyfikowanej metody klasycznej. Michał A. Jerzak i Magdalena Śmiglak [2006] wyznaczyli, stosując model wyrównania wykładniczego Wintersa, krótkoterminowe prognozy cen skupu wybranych zbóż. Wykorzystując modele ARIMA i metodę wskaźników na podstawie krajowych danych rynkowych, M. Hamulczuk i Stanisław Stańko [2009] wyznaczyli m.in. miesięczne prognozy cen skupu pszenicy w Polsce. Agnieszka Tłuczak i Mirosława Szewczyk [2010] zastosowały modele autoregresyjne do wyznaczenia punktowych prognoz cen podstawowych produktów rolnych w skupie, w tym pszenicy.

Celem M. Hamulczuka i współautorów [2011] było przedstawienie istoty i uwarunkowań prognozowania cen surowców rolnych z wykorzystaniem modeli szeregów czasowych. Rezultatem pracy było m.in. wyznaczenie na podstawie krajowych cen prognoz punktowych miesięcznych cen pszenicy, żyta, mleka, a także żywca wieprzowego, wołowego i drobiowego w Polsce na lata 2008-2012. Do modelowania cen wykorzystano procesy ARIMA. Kamil Jodź i Agnieszka Mruklik [2014] przeprowadzili badania wskazujące, że światowe ceny pszenicy można modelować procesem ARIMA(0,1,1). Ponadto, analizy potwierdziły, że występuje zależność korelacyjna między cenami światową i krajową pszenicy. Artur Wilczyński [2010], stosując metodę heurystyczną bazującą na opinii ekspertów, wyznaczył prognozy cen skupu mleka dla wybranych państw UE, z uwzględnieniem rozmaitych scenariuszy, różniących się wielkością zmian we wspólnej polityce rolnej.


Materiał i metodyka badań

Materiał badawczy stanowiły przeciętne ceny rzepaku odnotowane na stronie internetowej www.ewgt.com.pl (lata 2004-2009), dane w Zintegrowanym Systemie Rolniczej Informacji Rynkowej Ministerstwa Rolnictwa i Rozwoju Wsi (rok 2010) oraz informacje zawarte w dokumentach *Skup i ceny produktów rolnych* (lata 2011-2016) zamieszczonych na stronie internetowej GUS. Wartości notowań indeksów giełdowych WIG20 i WIG-Spożywczy zaczerpnięto ze stron internetowych: www.investing.com i www.stooq.pl.

W pracy posłużono się graficzną metodą analizy danych oraz metodami ekonometrycznymi, w tym: metodą doboru zmiennych objaśniających opierającą się na analizie empirycznych współczynników korelacji liniowej Pearsona, a także klasyczną metodą najmniejszych kwadratów użytą do oszacowania nieznanymi parametrów strukturalnych modelu. Statystyczna weryfikacja modelu sprowadzała się m.in. do wykorzystania odpowiednich testów statystycznych. W badaniach posłużono się programami Gretl i Excel.

Wyniki badań

Średnie miesięczne ceny rzepaku od stycznia 2004 roku ($t=1$) do grudnia 2016 roku ($t=156$) przedstawiono na rysunku 1. Na podstawie analizy kształtowania się cen rzepaku w poszczególnych miesiącach zauważono wahania kwartalne, dlatego w obliczeniach uwzględniono średnie kwartalne ceny rzepaku – od I kwartału 2004 roku ($t = 1$) do IV kwartału 2016 roku ($t = 52$). Zmienne objaśnia-



jące do modelu zostały wybrane na podstawie analizy wektora korelacji między zmienną objaśnianą a potencjalnymi zmiennymi objaśniającymi (tab. 1), a także na podstawie macierzy korelacji między zmiennymi objaśniającymi (tab. 2).

Analiza danych w tabeli 1 prowadzi do wniosku, że ceny rzepaku Y_t są najbardziej skorelowane z czasem t , współczynnik korelacji wynosi 0,7771 oraz z notowaniami indeksu WIG-Spożywczy X_t (wartość współczynnika korelacji wynosi 0,3758). Równocześnie czas i notowania indeksu WIG-Spożywczy są słabo skorelowane między sobą, co przedstawiono w tabeli 2. Współczynnik korelacji w tym przypadku wyniósł 0,3238.

Aneta Makowiec i Artur Górski [2014] na podstawie przeprowadzonych badań doszli do wniosku, że rola GPW w Warszawie w gospodarce Polski jest znaczna. Ponadto badacze stwierdzili, że wpływ na GPW zarówno czynników mikroekonomicznych, jak i makroekonomicznych w Polsce jest nadal bardzo duży. Ogólnie, w gospodarce rynkowej giełdę uznaje się

Tabela 1. Wektor korelacji zmiennej objaśnianej Y (cena rzepaku) z potencjalnymi zmiennymi objaśniającymi

Table 1. The vector correlation explained variable Y (the price of rape) with potential explanatory variables

Y_t	Zmienne/Variables
0,7771	t
0,3118	WIG
-0,1980	WIG20
0,3758	WIG-Spożywczy/ Comestible

Źródło: opracowanie własne w programie Gretl
 Source: own study in Gretl

Tabela 2. Macierz korelacji zmiennych objaśniających
 Table 2. The correlation matrix of explanatory variables

t	WIG	WIG20	WIG-Spożywczy/ Comestible	Zmienne/ Variables
1,0000	0,5436	-0,2138	0,3238	t
	1,0000	0,6641	0,6396	WIG
		1,0000	0,4916	WIG20
			1,0000	WIG-Spożywczy/ Comestible

Źródło: opracowanie własne w programie Gretl
 Source: own study in Gretl

Postać analityczna modelu przedstawiała się następująco:

$$\hat{Y}_t = 656,2392 + 0,070336 * X_t + 18,6463 * t$$

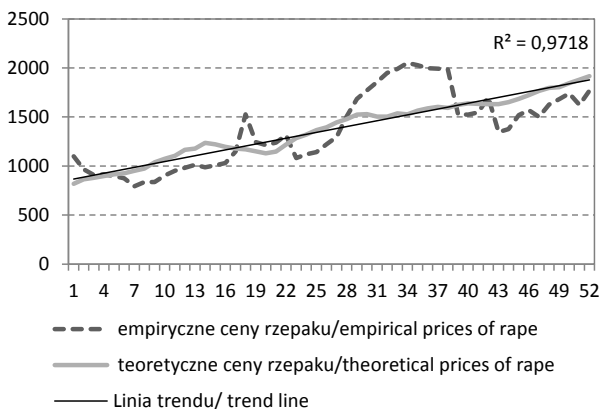
(151,5638) (0,0494) (2,4608)

Z danych na rysunku 2 wynika, że oszacowane wartości odchylają się od wartości empirycznych, co jest spowodowane m.in. wahaniami sezonowymi cen rzepaku. W latach 2010-2012 notowane ceny rzepaku były zdecydowanie wyższe od przeciętnych cen wyznaczonych za pomocą modelu ekonometrycznego. Tak drastyczny wzrost cen był następstwem rosnącej konkurencji o surowce rolne, w tym surowce oleiste, pomiędzy sektorem spożywczym i biopaliwowym ze strony ich kluczowych importerów, takich jak: Chiny, UE czy Indie, choć w poszczególnych latach podlegały one wahanom pod wpływem zmienności zbiorów. Wynikał on też z osłabienia dolara względem innych walut, miał związek z bardzo dużym wzrostem cen ropy naftowej, a także był następstwem działań spekulacyjnych na rynkach finansowych [Rosiak 2012].

W celu lepszego dopasowania modelu do danych empirycznych zostały wyodrębnione wahania kwartalne. Wyznaczono czyste wskaźniki sezonowości dla wahań addytywnych używając następujące wyniki:

$$c_1 = 29,11917, \quad c_2 = 67,57546, \quad c_3 = -64,3081, \quad c_4 = -31,3865$$

Za pomocą wyznaczonych czystych wskaźników sezonowości dla wahań addytywnych skorygowano trend o wahania kwartalne (rys. 3). Po oszacowaniu parametrów strukturalnych należy zbadać, czy zbudowany model ekonometryczny dostatecznie dobrze opisuje badane zjawisko. Weryfikacja merytoryczna to ocena, czy uzyskane wyniki (oceny parametrów) są zgodne z dotychczasową wiedzą ekonomiczną, doświadczeniem oraz zdrowym rozsądkiem – chodzi



za gospodarczy barometr [Sławiński 2006, s. 113, Sideris i in. 2008, s. 8-10, Nawrot 2008, s. 58-59].

Zakładając, że spełnione są założenia modelu regresji liniowej wielorakiej [Maddala 2006, s. 165], a także wykorzystując program Gretl, oszacowano rozpatrywany model ekonometryczny. W obliczeniach przyjęto średnie wartości kwartalne, zarówno dla cen rzepaku, jak i notowań indeksu giełdowego.

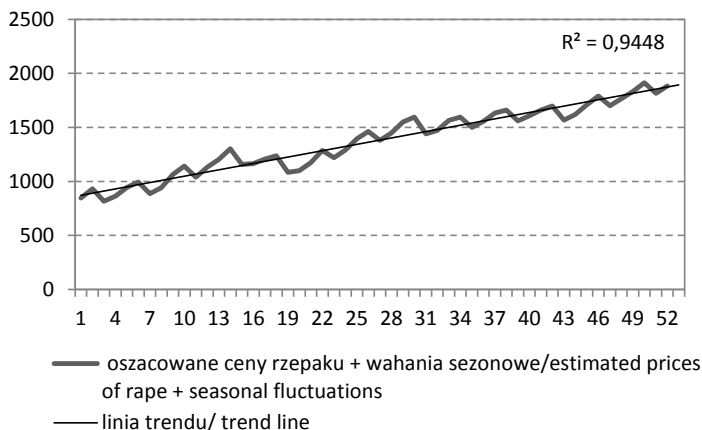
Rysunek 2. Empiryczne i teoretyczne (oszacowane na podstawie modelu ekonometrycznego) ceny rzepaku dla $t = 1, 2, \dots, 52$

Figure 2. Empirical and theoretical prices of rape for $t = 1, 2, \dots, 52$

Źródło: opracowanie własne

Source: own study

Rysunek 3. Trend oraz oszacowane ceny rzepaku, skorygowane o wahania sezonowe dla $t = 1, 2, \dots, 52$
 Figure 3. Trend and estimated prices, adjusted for seasonal fluctuations for $t = 1, 2, \dots, 52$
 Źródło: opracowanie własne
 Source: own study



tu w szczególności o rząd wielkości oraz znaki (\pm) ocen parametrów strukturalnych (zwykle sprawdza się to już po oszacowaniu parametrów). Natomiast weryfikacja statystyczna obejmuje:

- ocenę stopnia zgodności modelu z danymi empirycznymi,
- badanie poprawności postaci analitycznej modelu,
- sprawdzenie, czy spełnione są założenia o składniku losowym.

Kolejnym etapem pracy była weryfikacja modelu ekonometrycznego. Pierwszym etapem było sprawdzenie, czy przyjęto właściwą postać modelu ekonometrycznego. W tym celu wykorzystano test liniowości. Aby sprawdzić, czy model liniowy poprawnie opisuje zależności pomiędzy zmienną objaśnianą a objaśniającą zweryfikowano hipotezy:

$$H_0: Y = \alpha_0 + \alpha_1 X_1 + \dots + \alpha_k X_k + \varepsilon$$

$$H_1: Y \neq \alpha_0 + \alpha_1 X_1 + \dots + \alpha_k X_k + \varepsilon$$

W celu weryfikacji hipotez wyznaczono reszty modelu. Następnie w programie Gretl wyznaczono serię reszt (S_e) oraz liczbę reszt dodatnich (n_1) i ujemnych (n_2). Otrzymano następujące wyniki:

$$S_e = 20, n_1 = 21, n_2 = 31$$

Rozkład liczby serii jest stabilizowany dla $n_1 \leq 20$ i $n_2 \leq 20$. Wraz ze wzrostem n_1 i n_2 rozkład liczby serii dąży do rozkładu normalnego. Otrzymano:

$$Z = \frac{S - ES}{\sqrt{D^2 S}} = \frac{20 - 26,04}{\sqrt{11,80}} = -1,71, ES = \frac{2n_1 n_2}{n_1 + n_2} + 1 = 26,04,$$

$$D^2 S = \frac{2n_1 n_2 (2n_1 n_2 - n_1 - n_2)}{(n_1 + n_2)^2 (n_1 + n_2 - 1)} = 11,80$$

Statystyka testowa Z ma rozkład asymptotycznie normalny $N(0,1)$.

Obszar krytyczny dla poziomu istotności $\alpha = 0,05$ miał postać $Q = (-\infty, -1,96) \cup (1,96, \infty)$, przy czym:

$$\Phi(z_\alpha) = \Phi\left(1 - \frac{0,05}{2}\right) = \Phi(0,975), z_\alpha = 1,96$$

Wartość statystyki testowej Z nie należy do obszaru krytycznego, zatem nie było podstaw do odrzucenia hipotezy zerowej, mówiącej o liniowości modelu.

Kolejnym testem weryfikującym był test symetryczności składnika losowego. Testowane hipotezy to:

$$H_0: \frac{m}{n} = \frac{1}{2}, \quad H_1: \frac{m}{n} \neq \frac{1}{2}$$

gdzie: m – liczba reszt dodatnich, n – liczba reszt ujemnych.

W celu weryfikacji hipotezy H_0 obliczono wartość statystyki testowej na podstawie poniższego wzoru:

$$t = \frac{\frac{m}{n} - \frac{1}{2}}{\sqrt{\frac{\frac{m}{n}(1 - \frac{m}{n})}{n - 1}}}$$

Zatem podstawiając do wzoru $n_1 = 21; n_2 = 31$ otrzymano:

$$t = \frac{\frac{21}{52} - \frac{1}{2}}{\sqrt{\frac{\frac{21}{52}(1 - \frac{21}{52})}{52 - 1}}} = -1,39$$

Wartość t odczytana z tablic t-Studenta dla poziomu istotności $\alpha = 0,05$ i $52 - 1$ stopni swobody wynosiła $1,675$. Zatem $|t| < t_\alpha$, a więc nie było podstaw do odrzucenia hipotezy H_0 na rzecz hipotezy alternatywnej. Można przyjąć na tej podstawie, że składnik losowy był symetryczny.

Kolejnym etapem było sprawdzenie czy istnieje korelacja pomiędzy składnikami losowymi. Na początku wyznaczono nieobciążony estymator parametru p , który określa siłę liniowej zależności. Skorzystano z poniższego wzoru:

$$\hat{p} = \frac{\sum_{i=2}^n e_i e_{i-1}}{\sqrt{\sum_{i=1}^n e_i^2 \sum_{i=2}^n e_{i-1}^2}}$$

Podstawiając wartości do wzoru otrzymano:

$$\hat{p} = \frac{2275846,98}{\sqrt{2657182,55 * 2643825,4}} = 0,86$$

Najpopularniejszym testem weryfikującym istnienie autokorelacji I rzędu jest test Durbin-Watsona. Wartość nieobciążonego estymatora parametru p była większa od 0, dlatego wnioskowano o autokorelacji dodatniej. Zweryfikowano hipotezy:

$$H_0: p = 0, \quad H_1: p > 0$$

Statystyka d została obliczona na podstawie wzoru:

$$d = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n e_i^2}, \quad \text{stad } d = 1,66$$

Wartości krytyczne dolne d_L i górne d_U dla testu Durbin-Watsona są stabilizowane dla różnych n – liczby obserwacji, dla k – zmiennych objaśniających oraz dla poziomu istotności α . Wartości krytyczne dla 52 obserwacji, dwóch zmiennych objaśniających oraz poziomu istotności 0,05 wynosiły $d_L = 1,47410$ i $d_U = 1,63339$. Zatem $d_U < d$, a więc nie było podstaw do odrzucenia hipotezy zerowej mówiącej o braku autokorelacji składnika losowego.

Tabela 3. Prognozy cen rzepaku w 2017 roku oraz błąd *ex post* prognozy
 Table 3. Prices forecasts of rape in 2017 and *ex post* error of forecast

2017	t	Prognoza cen rzepaku na podstawie modelu/Rape price forecast based on model [PLN]	Ceny rzepaku odnotowane w 2017 roku/Prices of rape recorded in 2017 [PLN]	Błąd prognozy <i>ex post</i> /Forecast error <i>ex post</i> [PLN]
I kwartał/ quarter	53	2009,93	1920	-89,93
II kwartał/ quarter	54	2051,33	1893	-158,33

Źródło: opracowanie własne, ceny rzepaku z 2017 roku pochodzą ze strony internetowej [www.gospodarz.pl]
 Source: own stud, prices of rape from 2017 come from the website [www.gospodarz.pl]

Ostatnim etapem weryfikacji modelu było zbadanie homoskedastyczności składnika losowego. Z uwagi na dużą liczbę obserwacji ($n \geq 30$) wykorzystano test Harveya-Godfrey. Weryfikowano hipotezy:

$$H_0: \sigma_i^2 = \sigma^2, i = 1, 2, \dots, n \quad H_1: \sigma_i^2 \neq \text{constans}$$

W celu przeprowadzenia testu wykorzystano oszacowany model ekonometryczny:

$$\hat{Y}_t = 656,2392 + 0,070336 * X_t + 18,6463 * t$$

dla którego wyznaczono reszty ze wzoru $e_i = y_i - \hat{y}_i$. Następnie metodą najmniejszych kwadratów oszacowano parametry modelu pomocniczego. Postać analityczna modelu pomocniczego przedstawiała się następująco:

$$\ln \hat{e}_i^2 = 7,597174 + 0,000661 * X_t + 0,008546 * t$$

Dla modelu pomocniczego również wyznaczono reszty według wzoru: $r_i = u_i - \hat{u}_i$. Dzięki uzyskanym wynikom możliwe było obliczenie współczynnika dopasowania modelu pomocniczego według poniższego wzoru:

$$R^2 = 1 - \frac{\sum_{i=1}^n r_i^2}{\sum_{i=1}^n (u_i - \bar{u})^2}$$

gdzie:

$$\bar{u} = \frac{1}{n} \sum_{i=1}^n u_i$$

zatem:

$$\bar{u} = \frac{1}{n} \sum_{i=1}^n u_i = \frac{1}{52} * 515,7774 = 9,918796$$

$$R^2 = 1 - \frac{\sum_{i=1}^n r_i^2}{\sum_{i=1}^n (u_i - \bar{u})^2} = 1 - \frac{132,7194}{149,1726} = 1 - 0,8897 = 0,1103$$

Kolejnym etapem było wyznaczenie: $nR^2 = 52 \times 0,1103 = 5,7356$. Wartość krytyczna dla testu chi-kwadrat, poziomu istotności $\alpha = 0,05$ i dla dwóch stopni swobody ($p = 2$) wynosiła $\chi_*^2 = 5,99$. Otrzymano następującą nierówność:

$$nR^2 < \chi_*^2, \quad 5,7356 < 5,99$$

Na podstawie otrzymanej nierówności nie było podstaw do odrzucenia hipotezy o homoskedastyczności składnika losowego. Na podstawie przeprowadzonych testów można przyjąć, że rozważany model może być wykorzystany do prognozowania cen rzepaku, ponieważ składnik losowy jest symetryczny. Pomiedzy składnikami losowymi nie ma korelacji (wynik testu Durbina-Watsona), a przeprowadzony test Harvaya-Godfraya wykazał, że nie można odrzucić hipotezy o homoskedastyczności składnika losowego.

Zakładając, że spełnione są założenia predykcji ekonometrycznej [Tłuczak 2011, s. 39], wyznaczono prognozy cen rzepaku dla I i II kwartału 2017 roku, tj. dla $t = 53$ i $t = 54$. Średnie notowania indeksu WIG-Spożywczy dla I kwartału 2017 roku wynosiły 4795,85, a dla II kwartału 2017 roku 4612,59. Prognozowane ceny rzepaku przedstawiono w tabeli 3.

Wysoki błąd prognozy *ex post* wynika z faktu, że wartość notowań giełdowych indeksu WIG-Spożywczy w I kwartale 2017 roku była wyższa aż o 685,40 punktów, co stanowiło wzrost o 16,67% w porównaniu do IV kwartału 2016 roku. Równocześnie notowanie tego indeksu w I kwartale 2017 roku osiągnęło najwyższą wartość w historii. Błąd średniokwadratowy RMSE wynosił 128,76, co oznacza że prognozy cen rzepaku w I i II kwartale 2017 roku różniły się od wartości cen rzepaku zanotowanych w tych okresach, przeciętnie o 128,76 zł. Współczynnik Theila, którego pierwiastek informuje o całkowitym względnym błędzie prognozy w okresie prognozowania, wynosił $P = 0,00402$. Zatem całkowity względny błąd prognozy w okresie prognozowania wynosił $I = 0,063$.

Podsumowanie

W rozpatrywanym modelu ekonometrycznym zmienną objaśnianą była kwartalna cena rzepaku w Polsce. Zmiennymi objaśniającymi były czas i notowanie indeksu WIG-Spożywczy. Wykorzystano dane z lat 2004-2016. Współczynnik korelacji opisujący zależność między zmienną objaśnianą a notowaniami indeksu WIG-Spożywczy wynosił 0,3758 i był wyższy niż dla korelacji cen rzepaku z indeksem WIG czy indeksem WIG20. Na podstawie zweryfikowanego modelu ekonometrycznego wyznaczono prognozy na I i II kwartał 2017 roku. Wysoki błąd prognozy *ex post* był wynikiem m.in. nagłego wzrostu wartości indeksu WIG-Spożywczy w prognozowanych okresach. Zatem według oszacowanego modelu ekonometrycznego prognozowana cena rzepaku będzie zależała od trzech czynników. Pierwszym czynnikiem był czas. Drugim czynnikiem wpływającym na kształtowanie się cen rzepaku były notowania indeksu WIG-Spożywczy. Warto dodać, że im większa dynamika zmian indeksu WIG-Spożywczy, tym wyższy błąd prognozy. Trzecim czynnikiem były wahania sezonowe. Analiza cen rzepaku w ciągu analizowanych trzynastu lat wykazała kwartalne wahania cen rzepaku.

Dobłą praktyką jest wyznaczenie prognoz tego samego zjawiska wieloma metodami. Dzięki temu można porównać otrzymane rezultaty przede wszystkim pod kątem ich dokładności [Hamulczuk, Stańko 2009].

Literatura/Bibliography

- Boczar Paweł. 2007. Niektóre aspekty światowego rynku olejów roślinnych w latach 1961-2005 (Some aspects of world vegetable oil market in 1961-2005). *Roczniki Naukowe SERiA IX* (4): 20-23.
- Chibowski Piotr, Waldemar Izdebski, Oksana Makarchuk, Vladimir Sinielnikov, Jacek Skudlarski, Svetlana Aleksandrovna Zaika, Stanisław Zajac. 2016. Produkcja rzepaku w Polsce, na Białorusi i Ukrainie w aspekcie rozwoju sektora biopaliw transportowych (Rapeseed production in Poland, Belarus and Ukraine in terms of development of transportation biofuels). *Roczniki Naukowe SERiA XVIII* (2): 52-57.
- Dudek Hanna. 2005. Prognozowanie cen skupu mięsa drobiowego za pomocą sezonowego modelu ARIMA (Forecasting of poultry meat prices by using seasonal ARIMA Model). *Roczniki Naukowe SERiA VII* (5): 19-25.
- Hamulczuk Mariusz. 2006. Wykorzystanie modeli ARiMA w prognozowaniu cen wieprzowiny (Application of the ARIMA models to the pork prices forecasting). *Roczniki Naukowe SERiA VIII* (5): 43-47.

- Hamulczuk Mariusz, Stanisław Stańko (red.). 2009. *Zarządzanie ryzykiem cenowym a możliwości stabilizowania dochodów producentów rolnych* (Price risk management and the possibilities of stabilizing the income of agricultural producers). Warszawa: IERiGŻ-PIB.
- Hamulczuk Mariusz (red.). 2011. *Prognozowanie cen surowców rolnych z wykorzystaniem modeli szeregów czasowych* (Forecasting prices of agricultural commodities using time series models). Warszawa: IERiGŻ-PIB.
- Hamulczuk Mariusz. 2014. Polityka biopaliwowa a ceny surowców rolnych – wybrane problemy (Biofuel policy and agricultural commodity prices – selected issues) *Roczniki Naukowe SERiA XVI* (2): 82-87.
- Jerzak Michał A., Magdalena Śmiglak. 2006. Krótkoterminowe prognozy cen skupu zbóż, jako czynnik wspomagający zarządzanie ryzykiem cenowym w rolnictwie (Short price forecasting of selected grains as a handmaid factor of price risk management in agriculture). *Roczniki Naukowe SERiA VIII* (5): 53-57.
- Lira Jarosław. 2011. Prognozowanie targowiskowych cen żywca wieprzowego w Polsce (Forecasting of purchase prices of hog livestock in Poland). *Roczniki Naukowe SERiA XIII* (3): 168-172.
- Lira Jarosław. 2013. Ocena przydatności modelu Wintersa do prognozowania cen skupu mleka (An assessment of the usefulness of Winters' model in forecasting of procurement prices of milk). *Roczniki Naukowe SERiA XV* (4): 231-236.
- Maddala Gangadharrao S. 2006. *Ekonometria* (Econometrics). Warszawa: PWN.
- Majewski Janusz. 2006. Ceny skupu mleka w Polsce – analiza i prognozowanie (Prices of milk purchase – analysis and forecasting). *Roczniki Naukowe SERiA VIII* (2): 116-118.
- Makowiec Aneta, Górski Artur. 2014. Giełda Papierów Wartościowych w Warszawie – jej rola w gospodarce Polski (Warsaw Stock Exchange – its role in the Polish economy). *Societas et Ius* 3 (1): 25-45.
- Mruklik Agnieszka, Kamil Jodź. 2014. Koncepcja sposobu prognozowania cen pszenicy w Polsce (Idea of forecasting the price of wheat in Poland). *Roczniki Naukowe SERiA XVI* (5): 79-87.
- Nawrot Wioletta. 2008. *Rynek kapitałowy i jego rozwój* (Capital market and its development). Warszawa: Wydawnictwo CeDeWu.
- Rosiak Ewa. 2012. Stan i perspektywy rynku rzepaku w Polsce na tle rynku światowego (Situation and outlook rapeseed market of according to world market). *Roczniki Naukowe SERiA XIV* (1): 417-422.
- Sideris Stefan, Joseph Farinella, William Sackley, Ravija Badarinathi. 2008. The Dow Theory: A Historical Test as Interpreted by Richard Russell. *Annals of the International Masters of Business Administration at UNC Wilmington* 1/2 (8): 8-10.
- Sławiński Andrzej. 2006. *Rynki finansowe* (Financial markets). Warszawa: PWE.
- Thłuczak Agnieszka. 2011. *Prognozowanie w rolnictwie na podstawie wybranych modeli szeregów czasowych* (Forecasting in agriculture based on selected models of time series). Opole: Wydawnictwo Uniwersytetu Opolskiego.
- Thłuczak Agnieszka, Mirosława Szewczyk. 2010. Efektywność modeli autoregresyjnych w prognozowaniu cen produktów rolnych w Polsce (The effectiveness of the autoregressive models in forecasting the agricultural prices in Poland). *Oeconomia Copernicana* 1: 99-119.
- Wilczyński Artur. 2010. Zmiany cen skupu mleka w krajach europejskich wraz z ich prognozą do 2020 roku (Fluctuation of milk producer prices with forecasting to the year 2020). *Roczniki Naukowe SERiA XII* (4): 371-382.

Summary

The authors of the article examined the linear correlation between indexes WIG20 and WIG-food and prices of rape in Poland. Based on the collected data to be constructed econometric model, in which the quarterly price of rape in Poland since 2004 to 2016, depend on the explanatory variables: time and exchange quotations of index WIG-food. This model has been estimated, validated statistically, and then used to enumerate the point forecasts the price of rape in Poland in the first two quarters of the year 2017.

Adres do korespondencji
 dr inż. Agnieszka Mruklik (orcid.org/0000-0001-9930-3092)
 mgr Julita Bilakiewicz (orcid.org/0000-0001-5681-8416)
 Uniwersytet Przyrodniczy we Wrocławiu, Instytut Nauk Ekonomicznych i Społecznych
 Wydział Przyrodniczo-Technologiczny, Centrum Dydaktyczno-Naukowe
 pl. Grunwaldzki 24A, 50-363 Wrocław
 tel. (71) 320 15 82, e-mail: agnieszka.mruklik@upwr.edu.pl