

MONIKA PAPIEŻ, SŁAWOMIR ŚMIECH

WYKORZYSTANIE MODELU SVECM DO BADANIA ZALEŻNOŚCI POMIĘDZY CENAMI SUROWCÓW A CENAMI STALI NA RYNKU EUROPEJSKIM W LATACH 2003-2011

1. WPROWADZENIE

Jednym z czynników wpływających na rozwój gospodarczy jest rozwój światowego przemysłu stalowego. Równocześnie wielkość produkcji i zużycie stali może być traktowane, jako wskaźnik kondycji gospodarki. Wzrost popytu na wyroby stalowe jest ściśle związany z rozwojem budownictwa, transportu, przemysłu maszynowego, samochodowego, produkcją sprzętu AGD. Bezpośrednio z kondycją przemysłu stalowego związane są takie branże jak: koksownictwo, górnictwo węgla koksowego i rud żelaza.

Konsekwencją wzrostu lub spadku popytu na wyroby stalowe jest również wzrost lub spadek produkcji stali surowej. Produkcja stali jest w ostatnim czasie głównie realizowana w ramach kontraktów, stąd można przyjąć założenie, że jest ona realizacją zgłaszanego popytu. Bezpośrednio ze zmianami popytu na wyroby stalowe związane są zmiany cen wyrobów stalowych, a także surowców potrzebnych do produkcji stali: koksu, węgla koksowego i rud żelaza oraz złomu. Z drugiej strony poziom cen surowców jest uzależniony od ich aktualnej podaży. O ile w długim okresie podaż jest stabilna (inwestycje mają ekonomiczny sens jedynie dla dużych złóż, które są eksploatowane latami), w krótkim okresie mogą występować duże wahania. Przykładowo powódź, która nawiedziła Australię (największego eksportera węgla, w tym węgla kokosowego na świecie) w grudniu 2010 roku zatrzymała wydobycie i eksport węgla na miesiąc. W konsekwencji światowe ceny węgla koksowego wzrosły z 230 \$/t FOB Australia (cena spotowa węgla koksowego w grudniu 2010 r.) do 325 \$/t FOB Australia (cena w styczniu 2011 r.). Wzrosty cen były obecne również na rynku europejskim i to pomimo tego, że wielkość importu „węgla australijskiego” do Europy jest minimalna.

Produkcja stali odbywa się głównie przy wykorzystaniu jednego z dwóch procesów: konwertorowo – tlenowego (układ technologiczny: koksownia – wielki piec – konwertor tlenowy) lub łuku elektrycznego. W Europie ok. 60% produkcji stali wytwarzane jest w procesie wielkopiecowym, a pozostała część wytwarzana jest w procesie łuku elektrycznego. W procesie wielkopiecowym jako surowiec wykorzystywany jest koks. Oba procesy wykorzystują węgiel energetyczny.

W artykule zostanie dokonana analiza rynku stali przy założeniu, że do produkcji stali wykorzystuje się proces wielkopiecowy. Stąd analizowany zbiór zmiennych obej-

muje: cenę koksu, cenę stali oraz wielkość produkcji stali. Analiza zależności zostanie przeprowadzona dla rynku europejskiego na danych miesięcznych w latach 2003-2011.

Tak dobrany zbiór zmiennych pozwala ocenić wzajemne relacje cen surowców wykorzystywanych do produkcji stali, wielkości produkcji stali i cen produktu finalnego. Badanie zależności zostanie przeprowadzone w ramach modeli VAR (ECM) w postaci strukturalnej, które wymaga przyjęcia odpowiednich restrykcji dla macierzy odpowiadających za równoczesne przyczynowości w systemie (por. Lütkepohl, 2007 s. 358 i dalsze). W badaniu przyjęto rekursywną postać systemu zależności, przy czym kolejność zmiennych odpowiada procesowi produkcji stali. Założono zatem, że ceny koksu oddziałują na wielkość produkcji stali, która dalej wpływa na jej ceny. Innymi słowy, kierunek przepływu impulsów w analizowanym systemie przyjęto zgodnie z poniższym schematem:

Cena koksu \Rightarrow Wielkość produkcji stali surowej \Rightarrow Cena stali.

Przeprowadzona w artykule analiza zależności na rynku stali będzie miała na celu udzielenie odpowiedzi na następujące pytania:

– Czy rynek stali (rozumiany, jako system trzech analizowanych zmiennych) znajduje się w długookresowej równowadze?

– Jakiego typu przyczynowości występują dla zmiennych wchodzących w skład łańcucha produkcji?

– Jaka jest reakcja zmiennych systemu na ich zmiany?

– Czy występuje i jakie jest opóźnienie takiej reakcji?


– Jaki jest wpływ poszczególnych zmiennych na wariancję błędów prognoz?

Artykuł składa się z pięciu części. Druga część przedstawia charakterystykę europejskiego rynku stali. Kolejna część prezentuje wykorzystaną w artykule metodologię wnioskowania w oparciu o strukturalne modele VAR i VECM. Część czwarta pracy zawiera wyniki, otrzymane na podstawie zbudowanego dla zmiennych charakteryzujących rynek stali, strukturalnego modelu VECM. W podsumowaniu przedstawiono odpowiedzi na postawione pytania oraz najważniejsze wnioski.

Pomimo dużego znaczenia rynku stali dla światowej gospodarki jego funkcjonowanie nie jest tematem zbyt wielu opracowań. Analiza rynku stali pojawia się w zasadzie jedynie w kontekście powiązania ze wzrostem PKB np. Ghosh (2006), Kwang-Sook (2011), Rębiasz (2006). Głównym problemem przy tego typu analizach jest dostępność odpowiedniej jakości danych. Autorzy dysponowali danymi pochodzącymi z komercyjnych baz Coke Market Report – Resource-Net oraz SBB Steel (www.steelbb.com). Bazując na tych danych autorzy prowadzili w pracach Papież, Śmiech (2011a, 2012), Wydymus et al., (2010) badania dotyczące modelowania i prognozowania cen koksu, a w pracach Papież, Śmiech (2011b), Śmiech, Papież, Fijorek (2012) analizowali przyczynowość cen na rynku surowców energetycznych, w szczególności cen na rynku węgla energetycznego, wykorzystując modele VECM.

2. RELACJE POMIĘDZY POPYTEM NA WYROBY STALOWE A CENAMI STALI I SUROWCÓW NA RYNKU EUROPEJSKIM W LATACH 2003-2011

W latach 2003-2011 możemy wyróżnić okresy koniunktury i dekonunktury przemysłu hutniczego (por. rys. 1). Pierwsze załamanie na rynku stali było w III kwartale 2005 r. i wówczas wiele koncernów europejskich okresowo ograniczyło produkcję, co w konsekwencji spowodowało zmniejszenie zapotrzebowania na surowce (koks, węgiel koksowy). Osłabienie to miało charakter przejściowy, gdyż już w IV kwartale 2005 r. obserwuje się ponowny wzrost produkcji stali, aż do III kwartału 2008 r. Jednak w drugiej połowie 2008 r. pojawiły się pierwsze oznaki osłabienia popytu na wyroby stalowe, a w efekcie od października koncerny stalowe zaczęły odczuwać skutki dekonunktury, co pociągnęło za sobą szybko spadające ceny stali, a w konsekwencji ceny surowców. Kryzys spowodował, że koncerny hutnicze wprowadziły ograniczenie produkcji, co spowodowało, że zmalał popyt na surowce (Ozga-Blaschke, 2009). Produkcja stali w Europie spadała aż do I kwartału 2009 r. Dopiero od II kwartału obserwujemy ponowny wzrost, a następnie chwilowy spadek w III kwartale 2010 r.



Rysunek 1. Wielkość miesięcznej produkcji stali surowej w Unii Europejskiej w tys. ton w okresie styczeń 2003-czerwiec 2012

Źródło: opracowanie własne na podstawie danych www.worldsteel.org.

Z drugiej strony zachwianie równowagi pomiędzy popytem a podażą węgla koksowego prowadzi do zmian cen tegoż surowca i w konsekwencji do zmian cen koksu. W światowym handlu węglem koksowym cena i wielkość tonażu dla około 90% wydobytego węgla ustalana jest w kontraktach. Do kwietnia 2010 roku ceny w ramach kontraktów ustalane były na okres roczny od 1 kwietnia danego roku do 31 marca roku następnego (tzw. rok fiskalny). Obecnie ceny ustalane są w kontraktach na okres kwartału. Pozostała ilość węgla w zależności od zapotrzebowania jest uzupełniania zakupami na rynku spotowym. Ceny spotowe są kształtowane przez bieżącą sytuację podażowo-

popytowa. Mimo, że ceny spotowe węgla dotyczą tylko 10% wymiany handlowej to ich poziom w istotny sposób wpływa na poziom negocjowanych cen (Ozga-Blaschke, 2008).


Poziom cen węgla jest uzależniony od sytuacji popytowo-podażowej. Pierwsze zachwianie tej równowagi miało miejsce w 2004 roku, bowiem wzrost produkcji stali spowodował deficyt koksu, a w konsekwencji wzrost cen koksu w I półroczu 2004 roku i wzrost cen węgla koksowego na rynku spotowym. Ten wzrost spowodował, że ceny kontraktowe węgla koksowego na 2005/2006 były o 119% wyższe w stosunku do cen z poprzedniego roku. Przez następne dwa lata cen spadły, by ponownie rosnąć od połowy 2007. Głównymi przyczynami tego wzrostu były czynniki pogodowe (np. powodzie w Australii w styczniu i lutym 2008 r.) oraz ograniczenie eksportu i zwiększenie importu węgla koksowego przez Chiny. W konsekwencji ceny kontraktowe na 2008/2009 ustalono na poziomie o 200% wyższym. Należy pamiętać, że tak wysokie ceny teoretycznie obowiązywały do końca I kwartału 2009 r., czyli przez dwa kwartały znacznego spadku produkcji stali (część dużych odbiorców dążyła do unieważnienia części kontraktów). Spadek produkcji stali spowodował, że na kolejny rok 2009/2010 ustalono niższą cenę kontraktową. Należy zauważyć, że w połowie 2009 r. nastąpiło ożywienie w światowym przemyśle stalowym oraz koksownictwie, które przyczyniło się do zwiększenia zapotrzebowania na węgiel koksowy. Znalazło to swoje odbicie we wzroście cen węgla w ramach transakcji *spot* dla dostaw w III kwartale 2009 r. W związku z dużą dynamiką zmian od II kwartału 2010 roku ceny kontraktowe ustalane są na okres kwartału. Ponieważ ceny węgla koksowego ustalane są głównie w kontraktach długoterminowych do analizy wzajemnych relacji pomiędzy cenami surowców a cenami stali wybrano cenę koksu, jako cenę surowca. Rysunek 2 przedstawia średnią miesięczną cenę kontraktową węgla koksowego australijskiego w €/t na bazie FOB Australia oraz cenę koksu hutniczego 10,50%/11,50% Ash notowaną dla Europy Północnej – CIF w €/t i średnią miesięczną cenę stali – zwoje walcowane na gorąco (HRC) notowaną dla Europy Północnej – rynek krajowy w €/t (baza EXW) w okresie styczeń 2003-czerwiec 2012. Należy dodać, że specyfika koksu polega na tym, że jest to surowiec, którego ceny nie są notowane na giełdach światowych.

3. METODYKA BADAŃ

Podstawowym modelem wielowymiarowych szeregów czasowych jest model wektorowej autoregresji (w skrócie VAR) postaci (Lütkepohl, 2007; Osińska, 2006):

$$y_t = \Phi D_t + A_1 y_{t-1} + \dots + A_p y_{t-p} + u_t, \quad (1)$$

gdzie: $y_t = (y_{1t}, \dots, y_{Kt})'$ to wektor K szeregów czasowych, D_t – oznacza zmienne deterministyczne (np. trend, sezonowość), Φ – macierz współczynników dla zmiennych deterministycznych, A_i – $(K \times K)$ wymiarowe macierze współczynników modelu, $u_t = (u_{1t}, \dots, u_{Kt})'$ – nieobserwowany wektor błędów, o którym zakładamy, że jest zbio-



Rysunek 2. Średnia miesięczna cena kontraktowa węgla koksowego australijskiego w €/t na bazie FOB Australia oraz średnia miesięczna cena koksu hutniczego 10,50%/11,50% Ash notowana dla Europy Północnej – CIF w €/t i średnia miesięczna cena stali – zwoje walcowane na gorąco (HRC) notowana dla Europy Północnej – rynek krajowy w €/t (baza EXW) w okresie styczeń 2003-czerwiec 2012
Uwaga: Miesięczna zmienność cen węgla koksowego wynika z kursu €/\$, gdyż ceny kontraktowe węgla ustalane są w \$/t

Źródło: opracowanie własne na podstawie danych: www.resource-net.com, www.steelbb.com.

rem niezależnym procesów białoszumowych o zerowej średniej i dodatnio określonej niezmienniczej w czasie macierzy kowariancji $E(u_t, u_t') = \Sigma_u$.

Mówimy, że proces y_t jest stabilny, jeśli spełniony jest warunek:

$$\det(I - A_1z - \dots - A_pz^p) \neq 0, \quad \text{dla } |z| \leq 1. \quad (2)$$

W przypadku, gdy równanie (2) posiada pierwiastek jednostkowy, $|z| = 1$, wówczas, co najmniej jedna ze zmiennych wchodzących w skład procesu jest zintegrowana w stopniu pierwszym I(1).

Model wektorowej autoregresji powstał, jako alternatywna do stosowanych wcześniej modeli o równaniach współzależnych. Argumenty, które zostały postawione przeciwko modelom o równaniach współzależnych dotyczyły między innymi arbitralności podziału na zmienne endogeniczne i egzogeniczne oraz restrykcji narzucanych na model w celu jego identyfikacji. Modele wektorowej autoregresji zostały zbudowane na następujących założeniach (Osińska, 2006):

- Nie rozróżnia się a priori zmiennych endogenicznych oraz egzogenicznych;
- Nie ma wstępnych ograniczeń dla żadnych parametrów modelu;
- Nie istnieje żadna pierwotna teoria ekonomiczna, na podstawie której budowany jest model.

Szczególnie ciekawy przypadek modelu VAR występuje w sytuacji, gdy poszczególne szeregi czasowe są zintegrowane w stopniu pierwszym I(1), ale istnieje ich liniowa kombinacja, która jest stacjonarna. Zmienne systemu znajdują się wówczas w długookresowej równowadze, a o szeregach powiemy, że są skointegrowane. W takim

wypadku, jak pokazał Granger, Weiss (1983) w twierdzeniu o reprezentacji, skointegrowane zmienne posiadają reprezentację wektorowego modelu korekty błędem (VECM). W modelu VAR pojawia się wtedy stacjonarna składowa określająca odchylenia od długookresowej równowagi. Model VECM przyjmuje wówczas postać (Johansen, 1995) (dla prostoty zrezygnowano w zapisie z części deterministycznej):

$$\Delta y_t = \Pi y_{t-1} + \Gamma_1 \Delta y_{t-1} + \dots + \Gamma_{p-1} \Delta y_{t-p+1} + u_t, \quad (3)$$

gdzie: $\Pi = -(I_K - A_1 - \dots - A_p)$, $\Gamma_i = -(A_{i+1} + \dots + A_p)$ dla $i = 1, \dots, p-1$.

Ze względu na to, że Δy_t nie zawiera trendu stochastycznego (z założenia jest zmienną I(1), dla której pierwsze przyrosty są stacjonarne) jedynym składnikiem w równaniu, który zawiera zmienne typu I(1) jest Πy_{t-1} . Kombinacja ta musi być jednak stacjonarna, inaczej nie możliwe byłoby uzgodnienie struktury stochastycznej obu stron równania. Πy_{t-1} zawiera relację kointegrującą, która opisuje zależność długookresową zmiennych. Macierze Γ_i odpowiadają za krótkookresową dynamikę układu.

W przypadku kointegracji procesów macierz Π jest nieodwracalna. Jeśli założymy, że rząd tej macierzy wynosi r tj. $rk(\Pi) = r < K$, wówczas znajdziemy takie macierze α, β rzędu r , że $\Pi = \alpha\beta'$. Z uwagi na stacjonarność iloczynu Πy_{t-1} , stacjonarna musi być również kombinacja $\beta' y_{t-1}$ (inaczej iloczyn macierzy α oraz $\beta' y_{t-1}$ byłby I(1)). Zawiera ona r relacji kointegrujących (stacjonarnych kombinacji liniowych współrzędnych wektora y_t). Macierz β jest nazywana macierzą kointegracji. Macierz α jest macierzą dostosowań (współczynników modelu), która odpowiada za szybkość powrotu do równowagi długookresowej.

Model zapisany równaniem (3) może występować w poniższych trzech szczególnych przypadkach:

- $rk(\Pi) = K$ to proces y_t jest stacjonarny w zakresie wariancji,
- $rk(\Pi) = 0$ to składnik długookresowy w równaniu (3) znika. System stabilnych równań VAR należy budować dla pierwszych przyrostów szeregów,
- $0 < rk(\Pi) = r < K$ to istnieje r relacji kointegrujących dla wektora y_t .

W empirycznych zastosowaniach, w sytuacji gdy niektóre ze zmiennych wchodzących w skład wektora y_t są rzędu I(1), kluczowe pytanie dotyczy występowania pomiędzy nimi kointegracji. Jest to tożsame z ustaleniem rzędu macierzy Π . Stosowne testy są prowadzone sekwencyjnie. W i -tym kroku testuje się hipotezę zerową mówiącą, że $rk(\Pi) = i - 1$ przeciwko hipotezie mówiącej, że $rk(\Pi) > i - 1$. Procedura testowa kończy się w dwóch przypadkach. Pierwszy występuje wtedy, gdy nie ma podstaw do odrzucenia hipotezy zerowej. Drugi, gdy odrzucana jest hipoteza zerowa w kroku K . Najpopularniejsze statystyki odnoszą się do maksymalnej wartości własnej macierzy Π albo do śladu tej macierzy i zostały opublikowane przez Johansen, Juselius (1990).

Rząd opóźnienia w modelach wektorowej autoregresji jest dobierany albo za pomocą kryteriów informacyjnych (zwykle *AIC*, *BIC*, *HQIC*) albo tak, by zminimalizować wariancję błędów prognoz. Wybranie zbyt niskiego rzędu autoregresji może powodować występowanie korelacji wzajemnych. Z kolei dobranie zbyt dużego rzędu opóź-

nienia może powodować, że parametry przy dalszych opóźnieniach będą statystycznie nieistotne.

Statystyczna ocena modelu obejmuje testowanie własności reszt modelu oraz stabilność modelu. Wykorzystuje się w związku z tym testy normalności dla reszt, które pozwalają ocenić normalność poszczególnych składowych wektora y_t oraz sprawdza się wielowymiarową normalność testem Doornika-Hansena (1994). Również weryfikuje się autokorelację reszt. W tym celu stosuje się testy: test Portmanteau, test Ljung-Boxa (1978), czy też test Breuscha-Godfrey'a. Hipotezy zerowe tych testów głoszą brak autokorelacji (korelacji wzajemnych) reszt dla pierwszych p opóźnień. Odpowiednie wzory można znaleźć w pracy Lütkepohl (2007). Stabilność modelu jest weryfikowana testem Chowa.

Modele wektorowej autoregresji umożliwiają analizę przyczynowości rozumianą w sensie zaproponowanym przez Grangera (1969). Powiemy, że wektor y_{2t} jest przyczyną w sensie Grangera dla wektora y_{1t} , jeśli bieżące wartości y_{1t} można prognozować dokładniej wykorzystując przeszłe wartości wektora y_{2t} . Przeprowadzenie testu wymaga podziału wektora $y_t = (y_{1t}, \dots, y_{Kt})'$ na dwa podwektory tj.:

$$\begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \sum_{i=1}^p \begin{bmatrix} a_{11,i} & a_{12,i} \\ a_{21,i} & a_{22,i} \end{bmatrix} \begin{bmatrix} y_{1,t-i} \\ y_{2,t-i} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}. \quad (4)$$

Powiemy, że wektor y_{2t} nie jest przyczyną w sensie Grangera dla wektora y_{1t} wtedy i tylko wtedy, gdy $a_{12,i} = 0$, dla każdego $i = 1, 2, \dots, p$. Powyższy warunek stanowi hipotezę zerową w teście przyczynowości. Uogólnienie testu przyczynowości na przypadek zmiennych skointegrowanych podał Toda, Yamamoto (1995) oraz Granger, Weiss (1983). Zastosowane w pracy podejście odnosi się do przyczynowości bezpośredniej – w sensie Grangera (Osińska, 2009) i oznacza, że zmienna zdefiniowana, jako przyczyna wywołuje skutek w kolejnym okresie. Natomiast Hsiao (1982) rozważa tzw. przyczynowość pośrednią przy obecności trzeciej zmiennej. Wówczas pierwsza zmienna działa na drugą, która z kolei z pewnym opóźnieniem oddziałuje na trzecią. Dufour, Pelletier, Renault (2006) zdefiniowali model VAR, który umożliwia analizę siły zależności predyktywnej w krótkim i długim horyzoncie.

Postać modelu zapisana równaniem (4) umożliwia również analizę przyczynowości równoczesnej (*instantaneous causality*), która oznacza zależności (niezerową korelację) dla wektorów $u_{1,t}$ oraz $u_{2,t}$. Hipoteza zerowa w teście określa brak przyczynowości i jest sformułowana następująco: $H_0 : E(u_{1t}u_{2t}') = 0$. Równoczesna przyczynowość jest relacją symetryczną, co stanowi dysonans z powszechnie używanymi pojęciami przyczyny oraz skutku (Charemza, Deadman, 1997; Osińska, 2006; Osińska, 2008).

Interpretacja parametrów w modelach wektorowej autoregresji jest utrudniona z uwagi na ich liczbę i wzajemne interakcje zmiennych systemu. Wpływ jednej zmiennej na inną badany jest przy pomocy tzw. funkcji odpowiedzi na impuls. Powstaje ona, po sprowadzeniu (stabilnego) modelu do postaci nieskończonej średniej ruchomej. Jest to tzw. dekompozycja Walda:

$$y_t = \sum_{i=0}^{\infty} \Phi_i u_{t-i}, \quad (5)$$

gdzie: $\Phi_0 = I_K$, zaś pozostałe macierze Φ_s mogą być wyznaczone rekurencyjnie:

$$\Phi_s = \sum_{j=1}^s \Phi_{s-j} A_j, \text{ dla } s = 1, 2, \dots, \quad A_j = 0, \text{ dla } j > p.$$

Element (i, j) macierzy Φ_s pokazuje odpowiedź $y_{i,t+s}$ na jednostkową zmianę wartości $y_{j,t}$ zakładając stałe wartości całego wektora y_t . Powyższa interpretacja jest możliwa o ile nie występuje przyczynowość jednoczesna. Inaczej mówiąc, wymaga się, aby macierz Σ_u była diagonalna.

Inną metodą analizy dynamicznych własności modelu VAR jest dekompozycja wariancji błędu prognozy. Pokazuje ona, jaka część zmienności błędu losowego prognozy dla horyzontu k danej zmiennej wynika z występowania kolejnych szoków strukturalnych.

Przeprowadzenie takiej dekompozycji wymaga, aby składniki losowe w poszczególnych równaniach nie były ze sobą skorelowane. Często warunek ten nie jest spełniony. Wówczas analiza zależności prowadzona w ramach modeli VAR nie daje jednoznacznych wyników, które są różne w zależności od uporządkowania zmiennych w wektorze y_t . Potrzebna jest dodatkowa informacja (z poza próby), która umożliwi właściwą interpretację rezultatów. Innymi słowy VAR są zredukowaną formą modeli, zaś strukturalne restrykcje są niezbędne do jednoznacznej identyfikacji zależności pomiędzy zmiennymi (Lütkepohl, 2007).

Konstruktywną krytykę modeli VAR podał w 1981 roku Sims proponując strukturalny model VAR. W latach 90. ubiegłego wieku King, Plosser, Stock i Watson (1991) zaproponowali strukturalny model VECM.

W najogólniejszej postaci strukturalny model VAR dla stacjonarnych zmiennych może zostać przedstawiony w postaci:

$$A y_t = A_1^* y_{t-1} + \dots + A_p^* y_{t-p} + B \varepsilon_t, \quad (6)$$

gdzie macierz A oraz B odpowiadają za nieopóźnione związki pomiędzy zmiennymi systemu (macierz A) oraz składnikami losowymi (macierz B), ε_t jest wektorem składników losowych z diagonalną macierz kowariancji, zaś macierze A_1^*, \dots, A_p^* odpowiadają za dynamiczne własności systemu.

Przejście z modelu (6) do modelu (1) nastąpi, jeśli równanie postaci (6) pomnoży się (obustronnie) przez odwrotność macierzy A . Obie postaci modeli różnią się liczbą parametrów wchodzących w skład poszczególnych macierzy. Okazuje się, że aby zidentyfikować model SVAR na podstawie modelu VAR należy dokonać K restrykcji. W literaturze przedmiotu (Lütkepohl, 2007) wskazuje się na szczególne przypadki modeli SVAR. Są to modele typu A, typu B oraz typu AB. Nazwy modeli wskazują na symbole macierzy w równaniu (6), które w danym podejściu niosą informację na

temat jednoczesnych przyczynowości i które są przedmiotem opisu. W przypadku, gdy macierze te są trójkątne dolne mamy do czynienia z rekursywną strukturalizacją systemu. Wówczas dla $i < j$ zmienne $y_{t,j}$ nie występują w równaniu dla zmiennych $y_{t,i}$. Jest to równoznaczne z określeniem łańcucha dystrybucji w danym systemie (Wold, 1960), który oznacza zależność przyczynowo – skutkową obserwowaną w tej samej jednostce czasu i przepływ impulsów od jednej zmiennej do drugiej.

Jeśli nie ma dostatecznie silnych teoretycznych przesłanek do określenia typu strukturalizacji macierzy A oraz B, wówczas można próbować określić restrykcje na podstawie skumulowanych efektów szoków. Podejście to zostało wprowadzone przez Blancharda, Quaha (1989). Jego idea polega na identyfikacji struktury systemu poprzez nałożenie restrykcji na macierz długookresowych efektów zaburzeń Φ . W przypadku, gdy rozważany system zmiennych ma r relacji długookresowych, wówczas r – impulsów ma charakter przejściowy (pozostałe $K - r$ impulsów ma natomiast charakter permanentny). Bazując na powyższych założeniach i teorii ekonomicznej nakłada się stosowne restrykcje w ten sposób doprowadzając do identyfikacji modelu.

Zwykle strukturalny model korekty błędem (SVECM) przyjmuje postać (Lütkepohl, 2007):

$$A\Delta y_t = \Pi^* y_{t-1} + \Gamma_1^* \Delta y_{t-1} + \dots + \Gamma_{p-1}^* \Delta y_{t-p+1} + B\varepsilon_t, \quad (7)$$

gdzie: $\varepsilon_t \sim (0, I_K)$.

Taki model można sprowadzić do postaci strukturalnego modelu wektorowej autoregresji SVAR i dalej rozważać restrykcje w ramach modelu typu AB. Jednak jak podaje (Lütkepohl, 2007) z faktu występowania określonej liczby relacji długookresowej równowagi wynika występowanie maksymalnej liczby przejściowych szoków, czyli szoków, których efekty wygasają wraz z upływem czasu. Jest to przeciwieństwo trwałych szoków, których efekty nigdy nie wygasają. Natomiast przejściowe szoki mogą być wykorzystane, jako restrykcje w macierzy długookresowych efektów zaburzeń. W takiej sytuacji budowa modelu koncentruje się na analizie szoków w ramach modelu B oraz wspomnianej macierzy długookresowych efektów zaburzeń.

4. PREZENTACJA DANYCH I ANALIZA WYNIKÓW

Analiza zależności na rynku stali została oparta na miesięcznych szeregach czasowych z okresu od stycznia 2003 roku do grudnia 2011 roku. Długość każdego z szeregów wynosiła 106 obserwacji. Tak niewielka podaż danych uniemożliwia budowanie modeli o dużej liczbie opóźnień. Należy dodać, że na rynku stali, gdzie podpisywane są kontrakty na kwartały dłużej stanowi to spore utrudnienie i może uniemożliwić ujęcie w modelu wszystkich istotnych informacji. Dane wykorzystane do analizy to:

- *C_koksu* – średnia miesięczna cena koksu hutniczego 10,50%/11,50% Ash notowana dla Europy Północnej – C&F w €/t (źródło danych www.resource-net.com);
- *Prod_stali* – wielkość miesięcznej produkcji stali surowej w Unii Europejskiej w tys t. (źródło danych www.worldsteel.org);

– *C_stali* – średnia miesięczna cena stali – zwoje walcowane na gorąco (HRC) notowana dla Europy Północnej – rynek krajowy w €/t (baza EXW) (źródło danych www.steelbb.com).

Analizowany zbiór zmiennych, z uwagi na sezonowość wielkości produkcji stali surowej oraz nagłe zmiany spowodowane np. kryzysem gospodarczym, powodzią, rozszerzono o następujące deterministyczne zmienne:

- Zmienne sezonowe dla miesięcy – zmienne zero-jedynkowe,
- *Impuls 04_m1* – wartość 1 w styczniu 2004 r. oraz wartość 0 dla pozostałego okresu,
- *Impuls 04_m5* – wartość 1 w maju 2004 r. oraz wartość 0 dla pozostałego okresu,
- *Impuls 08_m10* – wartość 1 w październiku 2008 r. oraz wartość 0 dla pozostałego okresu,
- *Impuls 09_m3* – wartość 1 w marcu 2009 r. oraz wartość 0 dla pozostałego okresu,
- *Impuls 10_m4* – wartość 1 w kwietniu 2010 r. oraz wartość 0 dla pozostałego okresu.

Wszystkie obliczenia zostały wykonane w programach JMulTi oraz Gretl.

Analizę zależności pomiędzy zmiennymi rozpoczęto od przeprowadzenia testu kointegracji Johansena, który miał wskazać istnienie relacji kointegrujących. W związku z tym najpierw sprawdzono stopień zintegrowania szeregów. Do badania stacjonarności szeregów czasowych wykorzystano test pierwiastka jednostkowego ADF (Dickey, Fuller, 1981). Wartości statystyki w teście ADF dla zmiennej i jej przyrostów przedstawia tabela 1. Wyboru liczby opóźnień w teście dokonano wykorzystując wartość kryterium informacyjnego Akaike.

Tabela 1.

Wartości p-value dla statystyki w teście ADF dla zmiennej i jej przyrostów

Zmienna	Wartość p-value w teście ADF		
	Bez stałej	Stała	Stała + trend
<i>C_koksu</i>	0,5878 (3)	0,2252 (3)	0,1736 (12)
<i>Prod_stali</i>	0,4819 (12)	0,1787 (1)	0,3187 (1)
<i>C_stali</i>	0,5883 (1)	0,1850 (2)	0,1890 (2)
ΔC_koksu	0,0000 (2)	0,0000 (2)	0,0000 (2)
$\Delta Prod_stali$	0,0025 (12)	0,0015 (9)	0,0092 (9)
ΔC_stali	0,0000 (0)	0,0000 (0)	0,0000 (0)

Uwaga: w nawiasie liczba opóźnień ustalona na podstawie kryterium AIC

Źródło: Obliczenia własne

Na podstawie wartości statystyki w teście ADF można stwierdzić, że analizowane szeregi są zintegrowane w stopniu 1. Testowanie kointegracji przebiegało zgodnie z pro-

cedurą Johansena w oparciu o test śladu i maksymalnej wartości własnej (Lütkepohl, 2007 s. 328). Wyniki testów dla różnych specyfikacji modelu (liczby opóźnień) nie były jednoznaczne zarówno, jeśli chodzi o występowanie kointegracji jak i liczbę równań kointegrujących. Ostatecznie przyjęto na podstawie oceny wartości kryteriów informacyjnych, że rząd opóźnienia wynosi 4 miesiące, zaś w równaniu kointegrującym nie występuje ani stała ani trend liniowy. Testowane układy zmiennych uzupełniono o zbiór zmiennych deterministycznych. Wyniki testu przedstawia tabela 2. Na podstawie testu Johansena przyjęto, że w modelu występuje jedna relacja kointegrująca.

Przeprowadzona analiza jest punktem wyjścia do estymacji modelu VECM.

Tabela 2.

Test kointegracji Johansena: liczba równań: 3, rząd opóźnienia: 4, zmienne egzogeniczne: *Impuls 04_m1*, *Impuls 04_m5*, *Impuls 08_m10*, *Impuls 09_m3*, *Impuls 10_m4*, zmienne sezonowe dla miesiący

Liczba wektorów kointegrujących	Statystyka śladu macierzy λ_{trace}	Wartość p-value λ_{trace}	Statystyka maksymalnej wartości własnej λ_{max}	Wartość p-value λ_{max}
H0: $r = 0$; H1: $r > 0$	52,906	0,0000	46,920	0,0000
H0: $r = 1$; H1: $r > 1$	5,9864	0,4380	4,3786	0,5738
H0: $r = 2$; H1: $r > 2$	1,6078	0,2402	1,6078	0,2397

Źródło: opracowanie własne na podstawie obliczeń w Gretlu

Na podstawie przeprowadzonej analizy szeregów czasowych ustalono, że model VECM będzie zawierał 3 opóźnienia oraz jedno równanie kointegrujące. Estymacji parametrów dokonano metodą Johansena (*reduced rank estimation*) (Lütkepohl, Krätzig, 2004). Wyniki estymacji modelu VECM zostały przedstawione w tabeli 3.

Natomiast parametry macierzy kointegracji, po znormalizowaniu ze względu na zmienną *C.koksu*, oraz macierzy dostosowań zostały przedstawione w tabeli 4.

W równaniu długookresowym zarówno wielkość produkcji stali jak i jej cena mają istotny wpływ na cenę koksu, a więc można je traktować jako zmienne długookresowego oddziaływania. Natomiast w relacji krótkookresowej wszystkie rozważane zmienne dostosowują się do relacji długookresowej, gdyż parametry przy mechanizmie korekty błędem (ecm_{t-1}) są istotne statystycznie. Ponadto ujemne wartości tych parametrów zapewniają dochodzenie do stanu równowagi. Najszybciej do stanu równowagi dochodzi wielkość produkcji stali. Natomiast bardzo wolno do poziomu równowagi dostosowują się ceny koksu i stali.

Następnie dokonano weryfikacji modelu ze względu na założenia dotyczące składników losowych. Wyniki testów Boxa-Pierce'a i Breuscha-Godfrey'a wskazują na brak autokorelacji reszt. Wartości statystyki wielowymiarowego testu Doornika-Hansena nie zaprzeczają, że łączny rozkład wielowymiarowego składnika losowego jest normalny. Podobnie test na wielowymiarowy efekt ARCH, wskazuje na homoskedasyzność wariancji wielowymiarowego rozkładu reszt modelu. Dodatkowo testy Jarque-Bera i test mnożników Lagrange'a dla poszczególnych równań wskazują, że nie ma podstaw do

Tabela 3.

Wartości oszacowanych parametrów w modelu VECM

	d(C_Koksu)	d(Prod_stali)	d(C_stali)
d(C_koksu)(t-1)	0,528***	3,179*	0,213**
d(Prod_stali)(t-1)	-0,003*	0,360***	0,016***
d(C_stali)(t-1)	0,027	3,823**	0,319***
d(C_koksu)(t-2)	0,058	1,895	-0,137
d(Prod_stali)(t-2)	0,007*	-0,020	0,000*
d(C_stali)(t-2)	0,027	-1,217	0,056
d(C_koksu)(t-3)	-0,335***	-4,864**	-0,262***
d(Prod_stali)(t-3)	0,004	0,049	0,006*
d(C_stali)(t-3)	0,037	-2,438	-0,038
Zmienne deterministyczne:			
Impulse_04_m1(t)	66,928***	-152,785	5,082
Impulse_04_m5(t)	3,712	142,323	134,598***
Impulse_08_m10(t)	-7,739	-610,939	43,883**
Impulse_09_m3(t)	-10,882	-2639,708***	-58,378***
Impulse_10_m4(t)	-6,341	-47,065	77,371***
S1(t)	17,613	3174,251***	31,428***
S2(t)	47,980***	326,607	-1,083
S3(t)	18,576	3413,314***	28,386*
S4(t)	25,483*	308,158	-26,919*
S5(t)	9,611	2277,527***	23,948*
S6(t)	28,281**	559,038**	-18,566
S7(t)	5,213	1068,852***	13,606
S8(t)	22,212**	136,485	23,562**
S9(t)	13,267	3972,060***	17,019
S10(t)	33,896*	1412,598***	-31,535*
S11(t)	23,316	502,901	-7,816
ecm(t-1)	-0,008**	-0,608***	-0,002*

Źródło: Obliczenia własne w programie JMulTi. Istotność parametrów na poziomie poniżej 1%, 5% i 10% oznaczono następująco: ***, **, *.

Tabela 4.

Wartości oszacowanych parametrów wektora kointegrującego oraz wektora współczynników dostosowań

	<i>C_koksu(t-1)</i>	<i>Prod_stali(t-1)</i>	<i>C_stali(t-1)</i>
β'	1,000***	0,114***	0,685*
α'	-0,008**	-0,608***	-0,002*

Źródło: Obliczenia własne w programie JMulTi. Istotność parametrów na poziomie poniżej 1%, 5% i 10% oznaczono następująco: ***, **, *.

odrzućcenia hipotez, że wszystkie reszty mają rozkład normalny i ich wariancja jest homoskedastyczna.

Wyniki przeprowadzonych testów pozwalają przyjąć, że model został zbudowany poprawnie i może zostać narzędziem oceny zależności zmiennych na rynku stali.

W ramach oceny zależności cen na rynku stali analizowano przyczynowość w sensie Grangera oraz równoczesną przyczynowość. Przyjmowano wszystkie możliwe kombinacje zmiennych, jako przyczyny dla pozostałych elementów systemu. Wyniki przeprowadzonych testów w postaci wartości p-value zostały zestawione w tabeli 5.

Tabela 5.

Wartości p-value dla testu przyczynowości w sensie Grangera oraz równoczesnej przyczynowości w wariancie testu LM

Przyczyna	Skutek	p-value dla testu przyczynowości w sensie Grangera	p-value dla testu równoczesnej przyczynowości
<i>C_Koksu</i>	<i>Prod_stali, C_Stali</i>	0,0004	0,0036
<i>Prod_stali</i>	<i>C_Koksu, C_Stali</i>	0,0005	0,0354
<i>C_Stali</i>	<i>C_Koksu, Prod_stali</i>	0,4171	0,0004
<i>C_Koksu, Prod_stali</i>	<i>C_Stali</i>	0,0000	0,0004
<i>C_Koksu, C_Stali</i>	<i>Prod_stali</i>	0,0006	0,0354
<i>Prod_stali, C_Stali</i>	<i>C_Koksu</i>	0,4774	0,0036

Źródło: opracowanie własne na podstawie obliczeń w JMulTi

Wyniki analizy przyczynowości w sensie Grangera wskazują, że wektor pary zmiennych: wielkość produkcji stali i cena stali nie może zostać uznany, przy 5% poziomie istotności, za przyczynę w sensie Grangera dla ceny koksu. Oznacza to, że para zmiennych wielkość produkcji stali i cena stali nie poprawia prognoz cen koksu. Podobnie przy takim samym poziomie istotności cena stali nie jest przyczyną w sensie Grangera dla pary pozostałych zmiennych. Pozostałe zmienne (oraz pary zmiennych) należy uznać za przyczyny dla pozostałych elementów systemu.

Natomiast dla wszystkich par przyczyn oraz skutków wartość testowa wskazuje, że przy 5% poziomie istotności można odrzucić hipotezę o braku równoczesnej przyczynowości (por. tabela 5). Można twierdzić, że impulsy (składniki losowe) zmiennych

dochodzące w chwili t są ze sobą skorelowane. Oznacza to, że zmienne (pary zmiennych) oddziałują na siebie równocześnie, a zatem występują między tymi zmiennymi natychmiastowe reakcje. Wzrost lub spadek ceny koksu i wielkości produkcji stali następuje jednocześnie ze wzrostem lub spadkiem cen stali. Podobne zależności zachodzą dla pozostałych par na rynku stali.

W celu dokonania interpretacji modelu VECM należy dokonać jego strukturalizacji, którą przyjęto za (Lütkepohl, 2007). W tym celu nałożono restrykcje na macierz długookresowych efektów zaburzeń wynikające z analizy przyczynowości w sensie Grangera. Ostateczne postacie macierzy B i Φ , po nałożeniu dodatkowych restrykcji wynikających z tego, że parametry w macierzach byłnieistotne statystycznie, mają następujące postacie:

$$B = \begin{bmatrix} 18,6 & 1,6 & 4,9 \\ 0 & 108,7 & 349,9 \\ 8,2 & 16,5 & 1,1 \end{bmatrix}, \quad \Phi = \begin{bmatrix} 20,8 & 0 & 0 \\ -182,2 & -120,2 & 0 \\ 0 & 20,1 & 0 \end{bmatrix}.$$

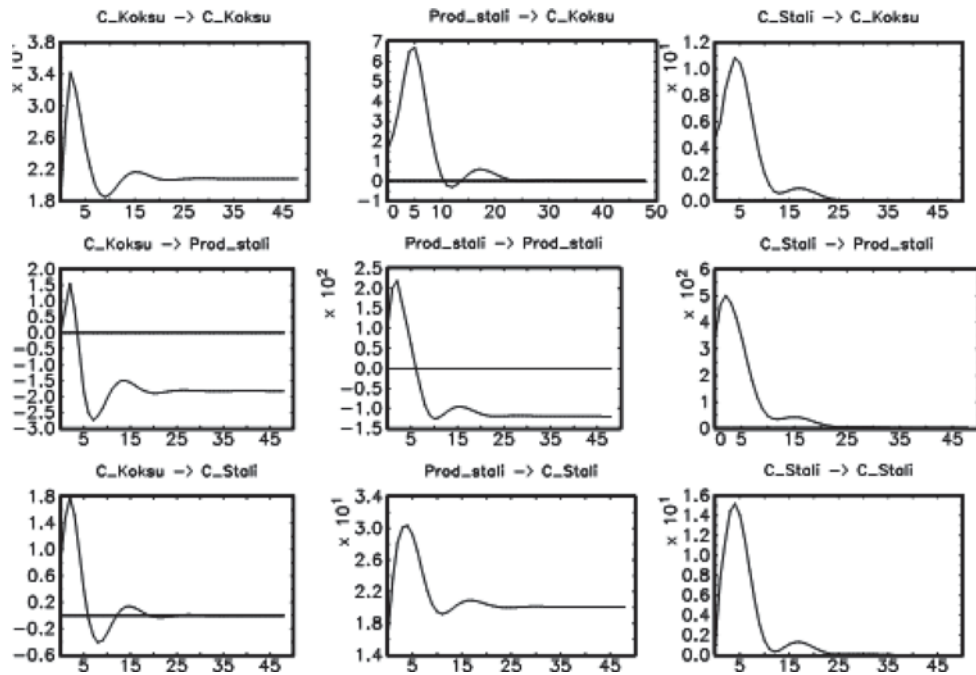
Interpretacji parametrów macierzy B oraz macierzy długookresowych efektów zaburzeń dokonano poprzez analizę funkcji reakcji na impuls. Rysunek 3 przedstawia funkcje reakcji odpowiednio cen koksu, produkcji stali, cen stali, na impuls wywołany jednostkową zmianą cen koksu (pierwsza kolumna na wykresie), wielkości produkcji stali (druga kolumna), cen stali (trzecia kolumna).

Analiza funkcji odpowiedzi na impuls pozwala wskazać kilka charakterystycznych cech europejskiego rynku stali. Przede wszystkim należy zauważyć, że reakcje na szoki stabilizują się po około dwóch latach, co wydaje się stosunkowo długim okresem. Zgodnie z oczekiwaniami impuls pochodzący od ceny koksu prowadzi w długim okresie do spadku produkcji. Można to tłumaczyć, niższą rentownością produkcji *ceteris paribus*. Reakcja cen stali na impuls ze strony cen koksu jest natomiast przejściowa.

Zaskakujące natomiast są wyniki otrzymane dla impulsu pochodzącego z równania dla produkcji stali. Impuls ten ma charakter krótkookresowy dla cen koksu, ale już permanentny dla produkcji i dla cen stali. Ostateczny wzrost cen w reakcji na ten impuls może być jedynie tłumaczony długookresowym spadkiem produkcji.

Krótkookresowy charakter impulsów pochodzących od cen stali jest oczywiście efektem założeń wynikających z własności statystycznych całego systemu (tj. istnienia jednej relacji kointegrującej) oraz otrzymanych wyników przyczynowości w sensie Grangera.

Rezultaty dekompozycji wariancji błędów prognoz dla analizowanego zestawu zmiennych zostały przedstawione na rys. 4a-c. Przyjęto tutaj 36 miesięczny horyzont analizy. W wypadku równania ceny koksu niepewność prognoz cen koksu w początkowym okresie zależy w 93% od zmienności cen koksu i w 7% od zmienności cen stali (por. rys. 4a). Podobnie w długim okresie wariancja prognozy ceny koksu (surowca) w 95% wynika z występowania szoków (zmian) w równaniu ceny koksu, zaś 1% wariancji jest związane ze zmianami wielkości produkcji stali a pozostałe 4% zmienności zależy od cen stali.



Rysunek 3. Funkcje reakcji na impuls dla modelu SVECM


Źródło: opracowanie własne na podstawie obliczeń w JMulTi

Zmiany wielkości produkcji tłumaczą w pierwszym miesiącu tylko w 9% wariację błędu prognozy tej zmiennej (por. rys. 4b). Natomiast wariacja ta w pierwszym miesiącu zależy aż w 91% od cen stali. W długim okresie wariacja błędu prognozy wielkości produkcji zależy w 40% od cen koksu, 43% cen stali i w 17% od wielkości produkcji.


Warto zauważyć, że w pierwszym miesiącu nie istnieje wpływ zmienności cen stali na wariację jej błędu prognozy. Natomiast aż ok. 80% zmienności produkcji stali i 20% zmienności cen koksu wpływa na wariację prognoz cen stali (por. rys. 4c). W kolejnych miesiącach udział zmienności cen stali wzrasta do 14%. W długim okresie wariacja prognozy cen stali tylko w 6% wynika z występowania szoków w równaniu cen stali, zaś 94% wariacji związane jest ze zmianami cen koksu (5%) i produkcji stali (aż 89%).

Wyniki analizy dekompozycji wariacji błędu prognoz pozwalają stwierdzić, że zmienną najbardziej niezależną (najsilniej egzogeniczną) w całym badanym układzie są ceny koksu, zaś zmienną najbardziej zależną od pozostałych jest cena stali. Co więcej, niepewność cen stali najsilniej zależy od wielkości produkcji, zatem podaży. Z kolei niepewność wielkości prognoz produkcji stali zależy bardziej od ceny stali niż od ceny koksu.


a) cen koksu



b) wielkości produkcji stali surowej

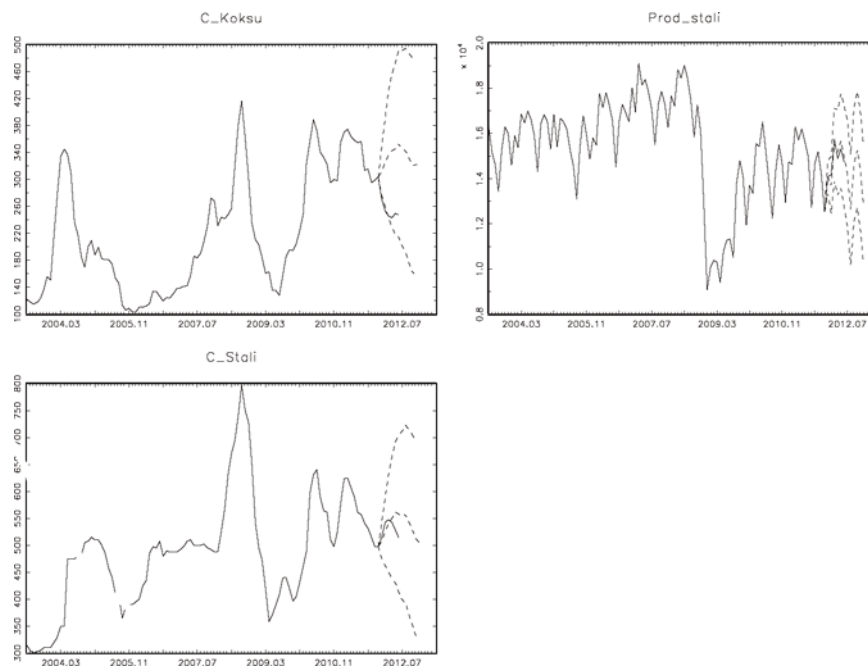


c) cen stali



Rysunek 4. Dekompozycja wariancji błęd prognoz
Źródło: opracowanie własne na podstawie obliczeń w JMulti

Ostatecznie zbudowany model został wykorzystany do wyznaczenia prognoz punktowych oraz przedziałowych na 2012 rok. Analiza trafności otrzymanych prognoz może być traktowana, jako „empiryczne” narzędzie weryfikacji modelu. Rezultaty obliczeń zostały przedstawione na rysunku 5.



Rysunek 5. Prognozy punktowe i przedziałowe analizowanych zmiennych – cena koksu, produkcja stali, cena stali na rok 2012

Źródło: opracowanie własne na podstawie obliczeń w JMulti

Jako ocena błędu prognoz posłużył miernik MAPE, który był wyznaczany dla poszczególnych zmiennych. Jego wartość obliczono dla danych z próby tj. z okresu styczeń 2003 r. – grudzień 2011 r. Największy błąd na poziomie 7,34% uzyskano dla zmiennej opisującej wielkość produkcji stali surowej, najmniejszy 3,62% dla zmiennej cena stali. MAPE dla szeregu cen koksu wyniósł natomiast 6,54%. Biorąc pod uwagę dużą zmienność wszystkich analizowanych zmiennych prognozy można uznać za trafne.

Dodatkowo wyznaczono prognozy poza próbę, na 3 kolejne miesiące 2012. Również te prognozy zostały ocenione miernikiem MAPE. Tym razem wartość MAPE wynosiła odpowiednio: dla ceny koksu 30,5%; dla wielkości produkcji stali surowej 1,61%; a dla ceny stali 1,81%. Negatywnie należy ocenić trafność prognoz dla cen koksu. Z drugiej strony, to właśnie ta zmienna okazała się najbardziej niezależna w całym systemie, stąd jej wartości są potencjalnie najtrudniejsze do przewidzenia.

5. PODSUMOWANIE

Celem prowadzonej analizy było zbudowanie modelu dla oddziaływania głównych zmiennych na europejskim rynku stali. Autorzy zastosowali w tym celu strukturalny model wektorowej autoregresji. Badanie kointegracji zmiennych pokazało, że analizowane zmienne tj. cena koksu, wielkość produkcji stali i cena stali znajdują się w długookresowej równowadze. Testy kointegracji wskazywały przy tym na występowanie jednego wektora kointegrującego. Ponadto analiza wskazała, że najszybciej do stanu równowagi powraca wielkość produkcji stali a bardzo wolno wracają do stanu równowagi ceny stali i ceny koksu. Biorąc pod uwagę dużą zmienność cen, można uznać ten wynik za zaskakujący. Należy jednak pamiętać, że okres analizy obejmował boom na rynkach finansowych (lata 2006-2008), kiedy to ceny większości instrumentów finansowych, w tym ceny surowców i ceny stali, pozostawały na nieuzasadnionym wysokim poziomie.

Wyniki analizy przyczynowości w sensie Grangera pokazały dominującą rolę cen koksu w analizowanym systemie zmiennych. To właśnie ceny tego produktu wpływają na przyszłe wartości pozostałych zmiennych. Odmienna jest rola cen stali, które nie poprawiają prognoz cen koksu i wielkości produkcji. Otrzymane wyniki analizy przyczynowości okazały się zbieżne z, założonym na początku badania, schematem zależności w analizowanym systemie. W pracy przeprowadzono też analizę równoczesnej przyczynowości, która wykazała, że istnieją zależności dla wszystkich par przyczyn oraz skutków. Tak więc np. wzrost lub spadek ceny koksu i wielkości produkcji stali następuje jednocześnie ze wzrostem lub spadkiem cen stali. Podobne zależności zachodzą dla pozostałych par na rynku stali. Takie natychmiastowe reakcje można tłumaczyć tym, że rynek stali nie jest izolowany rynkiem, ale na wielkości zmiennych na tym rynku wpływają inne, globalne czynniki. Warto zauważyć, że popyt na stal, a w efekcie jej produkcja jest związana ze zmianą PKB oraz zmianą produkcji przemysłowej w skali globalnej (jako, że stal jest produktem podlegającym obrotowi międzynarodowemu) a także w skali regionalnej i krajowej. Jak podaje (Crude Steel Quarterly Industry & Market Outlook, 2011) jednym z kluczowych mierników rozwoju rynku stali jest krzywa S dla stali, która przedstawia relację pomiędzy PKB na 1 mieszkańca oraz zużyciem gotowych wyrobów stalowych na 1 mieszkańca dla poszczególnych krajów. Historyczne obserwacje w Ameryce Północnej i w Europie Zachodniej pokazują, że zużycie stali gwałtownie rośnie, gdy PKB na 1 mieszkańca zaczyna wzrastać, osiągając szczyt przy poziomie PKB na 1 mieszkańca ok. 20.000 USD a następnie zaczyna spadać, gdy kraj wchodzi w etap mniej intensywnego rozwoju pod względem zapotrzebowania na stal. Wynika to z faktu, że stal jest metalem niezbędnym do budowy infrastruktury i zużycie stali rośnie w miarę, jak kraj buduje drogi, mieszkania i wytwarza produkty konsumpcyjne.

Interpretacja wyników modelu została przeprowadzona w oparciu o funkcję odpowiedzi na impuls oraz dekompozycję wariancji błędu prognoz. Otrzymane rezultaty potwierdziły założony na wstępie łańcuch przepływu impulsów i pokazały, że domi-

nującą zmienną w badanych systemie jest cena koksu. Pokazano, że reakcje na impulsy stabilizują się po około dwóch latach.

Reasumując, można stwierdzić, że rynek stali (rozumiany jako system trzech analizowanych zmiennych) znajduje się w długookresowej równowadze. Cena koksu jest zmienną dominującą w systemie. Ceny stali surowej są pochodną cen surowców oraz popytu zgłaszanego na wyroby stalowe a ponadto cena stali nie jest przyczyną w sensie Grangera dla pozostałych zmiennych. System zgodnie z oczekiwaniem reaguje na wzrost popytu na produkty stalowe oraz na wzrost cen surowców. Prognozy wyznaczone modelem mają dostateczną trafność i mogą być punktem odniesienia dla podmiotów będących stronami kontraktów dla kluczowych produktów na rynku stali.

Chociaż otrzymane wyniki wydają się autorom zgodne z intuicją zdają sobie oni sprawę, z ograniczeń zastosowanego podejścia. Szczególnie dużym uproszczeniem, wydaje się zastosowanie niewielkiej liczby opóźnień zmiennych w modelu.

Uniwersytet Ekonomiczny w Krakowie

LITERATURA

- [1] Blanchard O., Quah D., (1989), *The Dynamic Effects of Aggregate Demand and Supply Disturbances*, American Economic Review, 79, 655-673.
- [2] Charemza W.W., Deadman D.F., (1997), *Nowa ekonometria*, PWE, Warszawa.
- [3] Coke Market Report – Resource-Net, www.resource-net.com.
- [4] Crude Steel Quarterly Industry & Market Outlook, (2011), www.crugroup.com.
- [5] Dickey D.A., Fuller W.A., (1981), *Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root*, Econometrica, 49, 1057-1072.
- [6] Doornik J.A., Hansen H., (1994), *A practical test for univariate and multivariate normality*, Discussion paper, Nuffield College, University of Oxford.
- [7] Dufour J.M., Pelletier D., Renault E., (2006), *Short Run and Long Run Causality in Time Series: Inference*, Journal of Econometrics, 132 (2), 337-362.
- [8] Ghosh S., (2006), *Steel Consumption and Economic Growth: Evidence from India*, Resources Policy, 31, 7-11.
- [9] Granger C.W.J., Weiss, (1983), *Time Series Analysis of Error-Correcting Models*, Studies in Econometrics, Time Series, and Multivariate Statistics, New York, Academic Press, 255-278.
- [10] Granger C.W.J., (1969), *Investigating Causal Relations by Econometric Models and Cross-Spectral Methods*, Econometrica, 37 (3), 424-438.
- [11] Hsiao C., (1982), *Autoregressive Modelling and Causal Ordering of Economic Variables*, Journal of Economic Dynamic and Control, 4, 243-259.
- [12] Johansen S., Juselius K., (1990), *Maximum Likelihood Estimation and Inference on Cointegration – with Application to the Demand for Money*, Oxford Bulletin of Economic and Statistics, 52, 169-210.
- [13] Johansen S., (1995), *Likelihood-Based Inference in Cointegrated Vector Autoregressive Models*, Oxford University Press, Oxford.
- [14] King R.G., Plosser C.I., Stock J.H., Watson M.W., (1991), *Stochastic Trends and Economic Fluctuations*, American Economic Review, 81, 819-840.
- [15] Kwang-Sook H., (2011), *Steel Consumption and Economic Growth in Korea: Long-Term and Short-Term Evidence*, Resources Policy, 36, 107-113.

- [16] Ljung G.M., Box G.E.P., (1978), *On a Measure of Lack of Fit in Time Series Models*, *Biometrika*, 65, 297–303.
- [17] Lütkepohl H., (2007), *New Introduction to Multiple Time Series Analysis*, corr. 2nd print, Springer, Berlin.
- [18] Lütkepohl H, Krätzig M. (red.), (2004), *Applied Time Series Econometrics*, Cambridge University Press.
- [19] Osińska M., (2006), *Ekonometria finansowa*, Polskie Wydawnictwo Ekonomiczne.
- [20] Osińska M., (2008), *Ekonometryczna analiza zależności przyczynowych*, Wydawnictwo Naukowe UMK, Toruń.
- [21] Osińska M., (2009), *Analiza przyczynowości w długim i krótkim okresie w modelu popytu na pieniądź*, *Acta Universitatis Nicolai Copernici, Oeconomia XXXIX*, 40-50.
- [22] Ozga-Blaschke U., (2008), *Analiza sytuacji na światowych rynkach stali oraz prognozy w zakresie zmian popytu i podaży*, *Czasopismo Techniczne*, nr 134-137, 1-10.
- [23] Ozga-Blaschke U., (2009), *Wpływ kryzysu gospodarczego na rynki stali, węgla koksowego i koks*, *Przegląd Górniczy*, 3-4, 1036-37.
- [24] Papież M., Śmiech S., (2012), *Analiza przyczynowości na rynku koks, węgla koksowego i stali w latach 2003-2010*, A. Sagan (red.), *Metody analizy danych*, Zeszyt Naukowy Uniwersytet Ekonomiczny w Krakowie, 878, 57-71.
- [25] Papież M., Śmiech S., (2011a), *The Analysis and Forecasting of Coke Prices*. *Econometrics 32* /red. Dittmann P., *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu* 196, 213-220.
- [26] Papież M., Śmiech S., (2011b), *The Analysis of Relations Between Primary Fuel Prices on the European Market in the Period 2001-2011*, *Rynek Energii* 5(96), 139-144.
- [27] Rebiasz B., (2006), *Polish Steel Consumption 1974-2008*, *Resources Policy*, 31, 37-49.
- [28] Śmiech S., Papież M., Fijorek K., *Causality on the Steam Coal Market*. *Energy Sources*, Part B: Economics, Planning, and Policy, DOI:10.1080/15567249.2011.627909.
- [29] Toda H.Y., Yamamoto T., (1995), *Statistical Inference in Vector Autoregressions with Possibly Integrated Processes*, *Journal of Econometrics*, 66, 225-250.
- [30] Wold, H., (1960), *A Generalization of Causal Chain Models*, *Econometrica*, 28, 443–463.
- [31] www.worldsteel.org.
- [32] www.steelbb.com.
- [33] Wydymus S., Papież M., Śmiech S., Zysk W., Jaśko P., (2010), *Modelowanie i prognozowanie cen koks na rynkach światowych – studium przypadku*, [w:] *Bezpośrednie inwestycje zagraniczne jako czynnik konkurencyjności handlu zagranicznego* (red. Maciejewski M. Wydymus S.), 241-262.

WYKORZYSTANIE MODELU SVECM DO BADANIA ZALEŻNOŚCI POMIĘDZY CENAMI SUROWCÓW A CENAMI STALI NA RYNKU EUROPEJSKIM W LATACH 2003-2011

Streszczenie

W artykule przedstawiono analizę zależności pomiędzy popytem na wyroby stalowe a cenami stali i surowców (koks) na europejskim rynku na podstawie danych miesięcznych w latach 2003-2011. Analiza zależności została przeprowadzona z wykorzystaniem wektorowego modelu korekty błędem w postaci strukturalnej (SVECM), który ma służyć do oceny wpływu podaży surowców oraz popytu na wyroby stalowe na ceny produktów stalowych. Wyniki badania wskazały, że rynek stali znajduje się w długookresowej równowadze. Cena koks jest zmienną dominującą w systemie a ceny stali surowej są pochodną cen surowców oraz popytu zgłaszanego na wyroby stalowe. Ponadto cena stali nie jest przyczyną w sensie Grangera dla pozostałych zmiennych. System zgodnie z oczekiwaniem reaguje na wzrost popytu na produkty stalowe oraz na wzrost cen surowców. Prognozy wyznaczone modelem mają dostateczną

trafność i mogą być punktem odniesienia dla podmiotów będących stronami kontraktów dla kluczowych produktów na rynku stali.

Słowa kluczowe: przyczynowość, model VECM, rynek stali, ceny koksu i stali

USING SVECM MODEL FOR THE ANALYSIS OF THE RELATIONS BETWEEN RAW MATERIAL PRICES AND STEEL PRICES ON THE EUROPEAN MARKET IN THE PERIOD 2003-2011

A b s t r a c t

The article presents the analysis of the relations between the demand for steel products and the prices of steel and raw materials (coking coal) on the European market based on the monthly data in the period 2003-2011. The analysis of those relations was conducted with the use of Structural Vector Error Correction Model (SVECM), which allowed to determine the impact of the supply of raw materials and the demand for steel products on the prices of steel products. The results obtained indicate that steel market is in long run equilibrium. The price of coking coal is the dominant variable in the system, and the prices of crude steel depend on the prices of raw materials and the demand for steel products. The price of steel is not the Granger cause for the remaining variables. As expected, the system reacts both to the increase in the demand for steel products and the increase in the prices of raw materials. The forecasts obtained using the model are valid enough and can be treated as reference points by the participants of the steel market.

Key words: causality, SVECM model, steel market, coke and steel prices