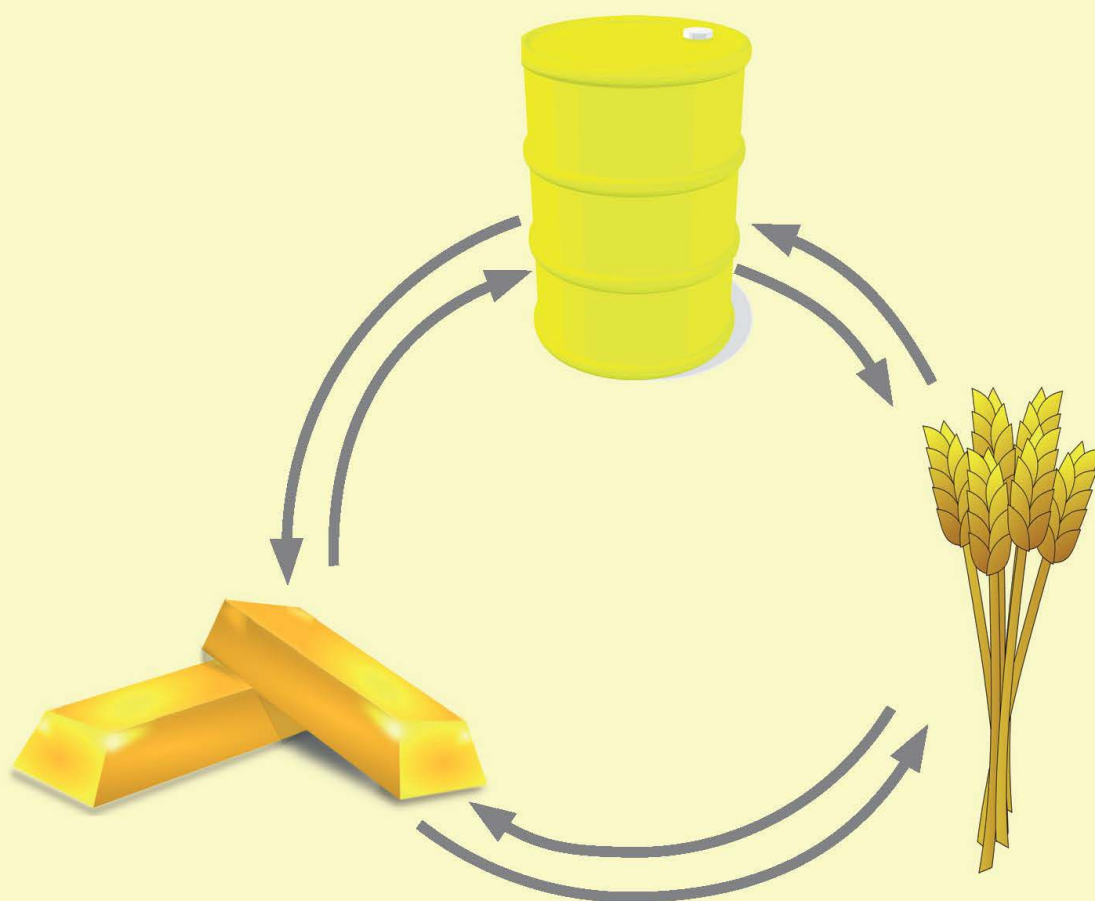


Katarzyna Czech
Anna Górska
Dorota Koziół-Kaczorek

Związki cenowe towarów w warunkach finansjeryzacji gospodarki na przykładzie cen ropy naftowej, złota i pszenicy



**Katarzyna Czech
Anna Górska
Dorota Koziół-Kaczorek**

**Związki cenowe towarów
w warunkach
finansjeryzacji gospodarki
na przykładzie cen ropy naftowej,
złota i pszenicy**

**Wydawnictwo SGGW
Warszawa 2019**

© Copyright by Wydawnictwo SGGW, Warszawa 2019
Wydanie I

Projekt okładki – Krystyna Piotrowska
Redakcja – Anna Dołomisiewicz
Redakcja techniczna – Krystyna Piotrowska

ISBN 978-83-7583-895-4

Wydawnictwo SGGW
ul. Nowoursynowska 166, 02-787 Warszawa
tel. 22 593 55 20 (-22; -25 – sprzedaż)
e-mail: wydawnictwo@sggw.pl
www.wydawnictwosggw.pl

Druk: ZAPOL sp.j., al. Piastów 42, 71-062 Szczecin

Spis treści

Wstęp	5
1. Towary – definicja i klasyfikacja	7
2. Charakterystyka rynku ropy naftowej	16
3. Charakterystyka rynku złota	28
4. Charakterystyka rynku pszenicy	40
5. Związek między cenami ropy naftowej i złota	54
6. Związek między cenami ropy naftowej i pszenicy	61
7. Modelowanie szeregów czasowych – wektorowe modele autoregresji i ich strukturalna postać	73
8. Empiryczna identyfikacja relacji cenowych między ropą naftową, złotem i pszenicą	96
Podsumowanie i wnioski	112
Literatura	115

Wstęp

Pojęcie wartości i ceny oraz związek między tymi kategoriami stanowi jedno z kluczowych zagadnień będących przedmiotem zainteresowania badaczy już od czasów antycznych. Znaczący wkład w zdefiniowanie wartości oraz jej roli w kreowaniu stosunków gospodarczych wnieśli już filozofowie antyku – Heraklit z Efezu i Arystoteles. Prace ich stanowiły podstawę teorii wartości w kolejnych okresach. Heraklit wartość dóbr i usług definiował jako subiektywną ocenę użyteczności. Arystoteles natomiast wskazywał, iż wartość dóbr wynika z działania mechanizmów podaży i popytu. Zauważał również udział pieniądza w subiektywnej ocenie wartości. W okresie średniowiecza Tomasz z Akwinu prezentował pogląd, iż wartość to pożytek uzyskiwany z określonego dobra i wynikający z jego użyteczności w zaspokajaniu potrzeb. Szczególną rolę w teorii wartości i cen odegrali główni przedstawiciele szkoły ekonomii klasycznej, czyli Adam Smith i David Ricardo. Według Smitha podstawową miarą wartości jest praca ludzka. Jednak założenie, że praca jest jedynym wyznacznikiem wartości, ignorowało fakt, iż wiele rzeczy w naturze (np. kamienie szlachetne, minerały) ma znaczną wartość ekonomiczną, zależną nie tylko od nakładu pracy. Z kolei Ricardo w swoich badaniach wskazał rzadkość dóbr jako dodatkowe źródło wartości. Jean-Baptiste Say podkreślił duże znaczenie w tworzeniu wartości, użyteczności dobra dla potencjalnego nabywcy. Jego zdaniem należy zwrócić również uwagę na czynniki popytowe kształtujące wartość i cenę. Od tego momentu teorie dotyczące wartości i ceny rozwijały się dynamicznie, a do czynników ekonomicznych kształtujących cenę włączone zostały także czynniki demograficzne czy polityczne.

Badania podjęte w niniejszej pracy dotyczą wyłącznie cen wybranych towarów. Coraz więcej badaczy podkreśla, iż towary stanowią bardzo zróżnicowaną grupę aktywów, których ceny determinowane są wieloma czynnikami. Początek XXI w. przyniósł znaczące zmiany na rynku surowców. W ostatnich latach surowce zaczęły być traktowane bowiem jako alternatywne i bezpieczne aktywa inwestycyjne. Jednym z popularnych produktów finansowych stały się na przykład fundusze inwestycyjne oparte jedynie na towarach. Ich wartość wzrosła nieomal 25-krotnie w pierwszej dekadzie XXI w. Coraz większa liczba transakcji o charakterze spekulacyjnym przyczyniła się do wzrostu zmienności cen surowców oraz występowania nowych istotnych zależności cenowych. Duży wpływ na kształtowanie się cen towarów miały także czynniki o charakterze demograficznym, makroekonomicznym i politycznym. Jednym z nich jest dynamiczny rozwój państw z grupy krajów rozwijających się, w tym Indii i Chin. W związku z tym rozwojem wzrosło zapotrzebowanie na surowce energetyczne, w tym ropę naftową, metale i towary rolne. Rosnący popyt na towary rolne wynika z jednej strony ze zwiększającej się liczby ludności (głównie w wymienionych krajach), a z drugiej ze wzrostu zamożności społeczeństw, szczegól-

nie tzw. klasy średniej. Bogacące się społeczeństwo bardzo chętnie inwestuje również w złoto. Wzrost popytu na towary energetyczne spowodowany był natomiast intensywną rozbudową infrastruktury, przemysłu i sektora transportowego krajów rozwijających się.

Celem niniejszego opracowania była identyfikacja zależności między cenami ropy naftowej, będącej głównym i strategicznym surowcem energetycznym, a cenami złota i pszenicy. Uzasadnieniem takiego właśnie wyboru towarów była między innymi ich kluczowa rola w swojej grupie towarów.

Układ publikacji jest następujący. W pierwszym rozdziale scharakteryzowano pojęcie towarów oraz zaprezentowano podstawowe ich klasyfikacje. Drugi, trzeci i czwarty rozdział są poświęcone charakterystyce odpowiednio rynku ropy naftowej, złota i pszenicy. Do ilościowej i jakościowej analizy towarów wykorzystano dane źródłowe pochodzących między innymi z bazy Reuters Datastream, raportów Eni, Organization of the Petroleum Exporting Countries, Głównego Urzędu Statystycznego, danych z World Gold Council, United States Geological Survey, Observatory of Economic Complexity oraz United States Department of Agriculture. Kolejne dwa rozdziały stanowią szczegółowy przegląd literatury odnoszącej się do relacji cen ropy naftowej i złota (piąty rozdział) oraz ropy naftowej i pszenicy (szósty rozdział). Wspomniane związki analizowano za pomocą wybranych technik ekonometrycznych. Siódmy rozdział traktuje o teorii dotyczącej modelowania szeregów czasowych. Szczególną uwagę poświęcono modelom autoregresji wektorowej (VAR) i strukturalnym modelom wektorowej autoregresji (SVAR). Wyniki przeprowadzonych analiz zostały przedstawione w ósmym rozdziale. Analizę szeregów czasowych rozpoczęto od zbadania ich stacjonarności z użyciem testów ADF i KPSS. Badanie zależności szeregów stacjonarnych przeprowadzono z wykorzystaniem testu przyczynowości w sensie Grangera oraz SVAR. W celu oceny kierunku i siły zależności między badanymi zmiennymi zastosowano funkcję reakcji na impuls oraz dekompozycję wariancji błędu prognozy. Publikację kończy podsumowanie z wnioskami.

Zaprezentowane w opracowaniu analizy zostały przeprowadzone na podstawie dziennych cen spot ropy naftowej, złota i pszenicy z okresu od 3 stycznia 2000 do 29 grudnia 2017 r., pochodzących z bazy Reuters Datastream.

Badania podjęte w niniejszej pracy wpisują się w nurt prowadzonych na świecie analiz dotyczących związków między cenami bardzo ważnych surowców. Praca stanowi ponadto kompendium podstawowej wiedzy w zakresie analizowanych towarów, a także przykładowych narzędzi, które mogą być wykorzystane w badaniu zależności cenowych. Otrzymane wyniki empiryczne mogą stanowić źródło informacji nie tylko dla naukowców zajmujących się rynkiem finansowym czy towarowym, ale także praktyków – między innymi inwestorów, analityków finansowych, doradców inwestycyjnych.

1. Towary – definicja i klasyfikacja

Wymiana towarów jest jedną z najstarszych form handlu na świecie, istniejącą na długo przed pojawieniem się waluty, obligacji i udziałów. Towary stanowią istotną część rynku i są niezwykle ważne zarówno dla światowej gospodarki łącznie, jak i dla każdego kraju z osobna. Pomimo tak dużego znaczenia towarów trudno je jednak jednoznacznie zdefiniować, a termin towary jest używany w bardzo szerokim i niejednorodnym znaczeniu.

Według Tomaszewskiego (2013) najszersza definicja towarów została najprawdopodobniej sformułowana przez Karla Marksa w 1955 roku, w której to stwierdził, że są to wszelkie zbywalne przedmioty wytwarzane w celu zaspokajania potrzeb, co oznacza, że za towary można uznać wszelkie dobra i usługi, które wytwarzane są w gospodarce. Znacznie częściej jednak terminu towary używa się w zawężonym znaczeniu – tylko do dóbr materialnych, które podlegają konsumpcji.

Według „Słownika ekonomicznego dla przedsiębiorcy” towar to produkt przeznaczony na sprzedaż, a stosunki towarowo-pieniężne w gospodarce znajdują wyraz w wymianie na rynku, która określa wartość wymienną towaru (Dowgiałło, 2004).

W podstawowym i szerokim znaczeniu towar w ekonomii jest zatem określany jako dobro materialne, które można kupić, sprzedać lub wymienić na produkty o podobnej wartości. W zależności od kontekstu definicja ta może być bardziej szczegółowa. Z punktu widzenia przedsiębiorstwa towarem (ang. *merchandise*) jest dobro materialne, które po zakupie przeznaczone jest na sprzedaż bez jego przetwarzania. W przypadku gdy przedsiębiorstwo zakupi dobro w celu jego dalszego przetworzenia, to będzie ono wtedy materiałem, a po przetworzeniu stanie się produktem. To samo dobro zatem może być przez jedno przedsiębiorstwo określane jako towar, zaś przez inne już nie.

Bardzo często definicja towaru zależy też od samego definiującego. Ekonomista mianem towaru określi zasób konsumpcyjny. Ograniczona dostępność tego zasobu w postaci na przykład złożu naturalnych lub zgromadzonych zapasów ma ogromny wpływ, zarówno na gospodarkę światową, jak i gospodarki poszczególnych krajów. Z kolei bankowiec zauważy, że towar nie jest papierem wartościowym generującym strumień przepływów pieniężnych i wycenianym według koncepcji wartości bieżącej netto, a analityk finansowy stwierdzi, że towar jest wzorcem, w odniesieniu do którego należy mierzyć wartość portfela ze względu na aktualną zmienność wszystkich walut, także tych najważniejszych. Ekolog zaś może uważać za towar naturalne dobro, które należy chronić (Geman, 2007). Z punktu widzenia obrotu giełdowego

wszystkie dobra, które są notowane na giełdzie towarowej, określa się mianem towarów (ang. *commodity*) bez względu na ich dalsze przeznaczenie.

Zatem towary można rozumieć jako wszelkie dobra, na które istnieje popyt, a ich podaż ma charakter jakościowo jednolity, o doskonałej (lub zbliżoną do doskonałej) substytucji (Tomaszewski, 2013). Towarami są w szczególności surowce mineralne, produkty rolnicze czy wydobywcze takie jak ruda żelaza, cukier lub zboża (np. ryż, pszenica). Mogą nimi być również masowo produkowane produkty niespecyficzne takie jak chemikalia czy pamięć komputerowa.

Podobnie jak z definicją towarów nie istnieje również jedna uniwersalna i powszechnie obowiązująca klasyfikacja towarów (Krawiec, 2016).

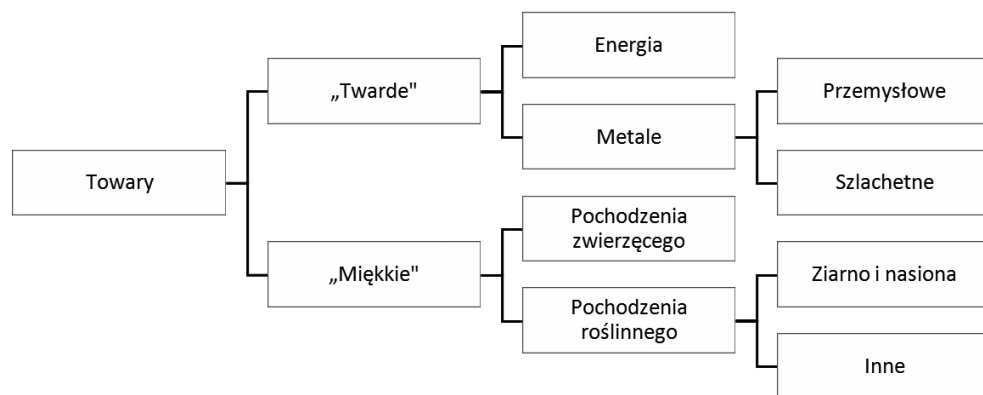
Najprostsza klasyfikacja towarów, biorąca pod uwagę cechy mające istotny wpływ na kształtowanie się poziomu i zmienność cen, dzieli je na dwie grupy: nieprzechowywalne oraz przechowywalne (Pirrong, 2008; Tomaszewski, 2013). Przykładem towaru zakwalifikowanego do grupy towarów nieprzechowywalnych jest energia elektryczna, ale także, co może budzić pewne wątpliwości, pogoda czy zdolność przewozowa w transporcie, tj. fracht (Tomaszewski, 2013). Te dwa ostatnie towary zostały zaliczone do grupy towarów nieprzechowywalnych przez samych uczestników rynków towarowych ze względu na obrót nimi realizowany w instytucjach finansowych biorących udział w handlu na rynkach towarowych. Do grupy towarów przechowywalnych zalicza się te, których zapasy mogą być gromadzone i przechowywane. W tej grupie można wyodrębnić kilka podgrup ze względu na ich popyt i podaż (Tomaszewski, 2013):

- towary produkowane i konsumowane w sposób ciągły, na które popyt nie podlega istotnym fluktuacjom sezonowym (np. rudy metali: żelaza, miedzi, cynku itp.);
- towary produkowane i konsumowane w sposób ciągły, na które popyt podlega istotnym fluktuacjom sezonowym (np. surowce energetyczne: gaz ziemny, węgiel kamienny);
- towary sezonowo produkowane o podaży elastycznej (produkty rolne: zboża, rośliny oleiste);
- towary sezonowo produkowane o podaży mało elastycznej (produkty rolne zbierane z drzew lub krzewów: owoce, kawa, herbata, kakao, winorośl).

Na elastyczność towarów sezonowych ma wpływ na przykład dostępność powierzchni ziemi uprawnej, która może być przeznaczona w krótkim czasie na potrzeby zwiększenia zdolności produkcyjnych, czy tempo wzrostu drzew i krzewów do wieku, w którym mogą wydać plon.

Kolejnymi klasyfikacjami towarów są klasyfikacje zaproponowane przez Ellera i Sagerera (2008) oraz Fabozziego i innych (2008).

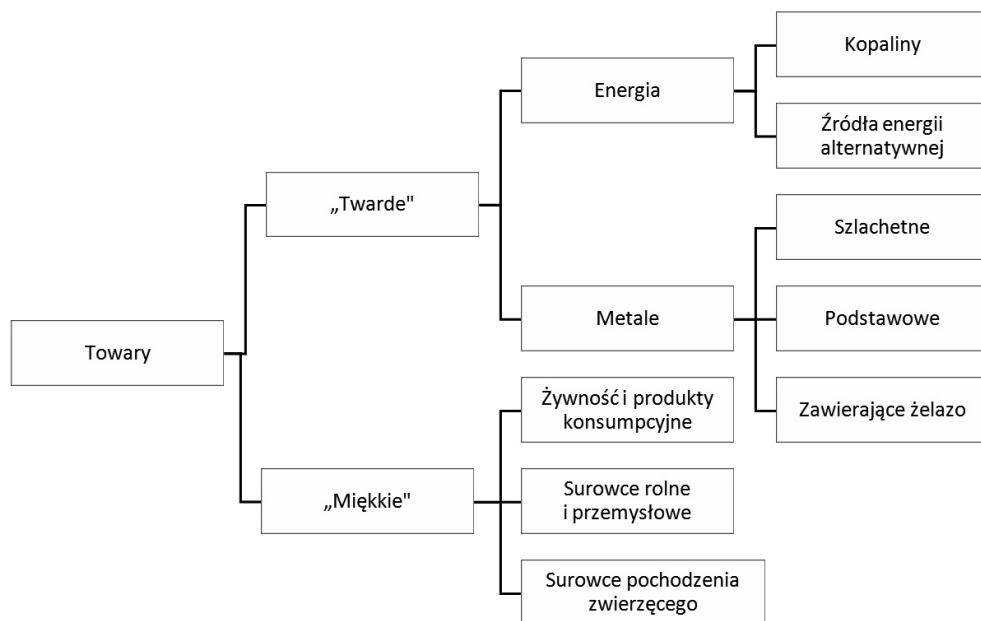
Fabozzi i inni (2008) pogrupowali towary w dwie główne kategorie towarów (rys. 1.1): „twarde” (ang. *hard*) i „miękkie” (ang. *soft*). Do kategorii towarów „twardych” zaliczają towary pozyskiwane metodą wydobywania lub przetworzenia surowców kopalnych. Towary te również można podzielić na dwie grupy. Pierwsza grupa, tzw. energia, obejmuje takie produkty jak ropa naftowa, węgiel, gaz ziemny, olej opałowy, benzyna bezołowiowa. Drugą grupę, tzw. metale, dzielą na metale przemysłowe oraz metale szlachetne. Do metali przemysłowych zaliczają: aluminium, chrom, miedź, ołów, rtęć, nikiel, selen, cynę, tytan i cynk, a do szlachetnych: złoto, iryd, pallad, platynę, osm, rod, ruten, srebro. Kategoria towarów „miękkich” obejmuje wszystkie towary inne niż surowce mineralne i energetyczne, a zatem wszelkie towary pochodzenia rolnego pozyskiwane metodą hodowli. W kategorii tej wyróżniają grupę towarów pochodzenia zwierzęcego (bydło opasowe, zwierze wołowy, zwierze wieprzowy, półtusze wieprzowe) oraz grupę towarów pochodzenia roślinnego. Tę ostatnią dzielą na dwie podgrupy: ziarno i nasiona (fasola adzuki, jęczmień, rzepak, kukurydza, proso, owies, pszenicę, ryż, sorgo, soja, mączka sojowa) oraz inne towary (kawa, kakao, bawełna, sok pomarańczowy, kauczuk, cukier, jedwab, drewno, wełna) (Krawiec, 2016).



Rysunek 1.1. Klasyfikacja towarów według Fabozziego, Füssa i Kaisera
Źródło: opracowanie własne na podstawie (Fabozzi i in. 2008), s. 8.

Eller i Sagerer (2008) także dokonali podziału towarów na dwie grupy: „twarde” i „miękkie” (rys. 1.2). W grupie towarów „twardych”, podobnie jak Fabozzi i inni (2008), wyodrębniają kategorię energia i kategorię metale. Kategoria pierwsza obejmuje tradycyjną energię z produktów kopalnych (ropa, uran, gaz ziemny i węgiel), energię alternatywną (słoneczna, wiatrowa, wodna, z biomasy, geotermiczna), a także energię nuklearną. Druga kategoria dzieli się na metale szlachetne (złoto, platyna, srebro, pallad) i metale podstawowe (aluminium, miedź, ołów, nikiel, cynk)

oraz zawierające żelazo (żelazo, stal). W grupie towarów „miękkich” wyodrębniają trzy podgrupy: żywność i produkty konsumpcyjne (zboża – pszenica, ryż, jęczmień; rośliny oleiste – soja, olej palmowy; produkty półluksusowe – kawa, kakao, herbata, tytoń, cukier, sok pomarańczowy), surowce rolne i przemysłowe (bawełna, wełna, drewno, kauczuk) oraz produkty pochodzenia zwierzęcego (bydło opasowe, żywiec wołowy, prosięta) (Krawiec, 2016).



Rysunek 1.2. Klasyfikacja towarów według Ellera i Sagerera

Źródło: opracowanie własne na podstawie (Eller i Sagerer, 2008), s. 682.

Kolejnym sposobem klasyfikacji towarów jest ich podział ze względu na sektor gospodarki, w którym są one produkowane i konsumowane (Tomaszewski, 2011, 2013). Według tego kryterium towary można podzielić na pięć grup: towary sektora energetycznego, metale przemysłowe, metale szlachetne, towary „miękkie” oraz inwentarz żywy. Grupa towarów sektora energetycznego obejmuje wszelkie surowce energetyczne, tj. ropę naftową, gaz ziemny, węgiel kamienny, a także energię elektryczną. Kolejna grupa, metale przemysłowe, obejmuje żelazo, miedź, cynk, ołów i aluminium. Metale szlachetne według tej klasyfikacji to złoto, srebro i platyna. Grupa towarów „miękkich”, podobnie jak w przedstawianych wcześniej klasyfikacjach, obejmuje towary pochodzenia roślinnego takie jak zboża, używki, owoce, rośliny oleiste. W tej grupie zboża są często oddzielnie klasyfikowane ze względu na ich szczególne znaczenie gospodarcze. Odrebną klasyfikacją, ze względu na geogra-

ficzne pochodzenie, stosowana jest także często w przypadku towarów roślinnych, szczególnie tzw. rośliny pochodzenia tropikalnego. Do ostatniej grupy towarów, tj. inwentarz żywy, zalicza się żywe zwierzęta hodowlane (np. bydło wołowe, trzoda chlewna).

Ostatnia klasyfikacja jest często wykorzystywana na potrzeby konstrukcji indeksów cenowych rynków towarowych (Tomaszewski, 2013).

Biorąc pod uwagę wszystkie powyżej wymienione i opisane klasyfikacje towarów, można zauważyć, że głównymi grupami towarów są energia, metale oraz produkty rolnicze. Najbardziej popularnymi instrumentami są złoto, ropa naftowa i zboża.

Miejscem, gdzie dochodzi do wymiany towarów (w tym produktów rolnych, metali szlachetnych czy towarów energetycznych, a także instrumentów opierających się na cenach tych produktów rozliczanych tylko finansowo bez fizycznej dostawy), jest rynek towarowy. Rynki towarowe mają zdecydowanie najdłuższą historię spośród wszystkich rynków, bowiem handel towarami odbywał się na długo przed pojawieniem się walut. Podstawowe produkty rolne i surowce mineralne były produkowane czy wydobywane i konsumowane przez człowieka od bardzo dawna, a ze względu na nierówność dostępu do niektórych dóbr pojawiła się potrzeba wymiany nadwyżek produkowanych towarów. Najstarszą formą handlu towarami była wymiana barterowa (zainicjowana przez kupców na rynkach lokalnych) polegająca na przeprowadzeniu transakcji natychmiastowych z fizyczną dostawą towaru.

W miarę ewolucji obrotu towarowego i chęci rozszerzenia rynku towarowego fizyczna wymiana handlowa coraz częściej była utrudniona czy też praktycznie niemożliwa. Konieczne zatem stało się odejście od fizycznej obecności towarów podczas zawieranych transakcji. Było to możliwe dzięki wypracowaniu standardów obrotu towarami o określonych cechach ilościowych i jakościowych. Miejscem obrotu wystandaryzowanymi towarami stała się giełda.

Czynnikami determinującym charakter rynku towarowego były od zawsze fizyczne cechy towarów, a tym samym jakość towarów. Utrudnienia podczas transportu niektórych towarów sprawiają, że pomimo istnienia ogólnoświatowej wymiany towarowej występuje segmentacja na wiele rynków lokalnych, które charakteryzują się często wyraźnymi różnicami cen tych samych dóbr. Pomimo zakładanej doskonałej substytucyjności towarów w rzeczywistości, w wyniku między innymi rozwoju przemysłu przetwórstwa towarów, określony typ towaru nie ma idealnego zamiennika. Występujące różnice jakościowe są często na tyle istotne, iż powodują, że poszczególne towary nie mogą być wykorzystywane w tych samych celach. Przykładem takiego towaru jest ruda żelaza czy pszenica. Ruda żelaza w przyrodzie występuje o bardzo zróżnicowanej zawartości czystego pierwiastka, co ma istotne

znaczenia dla nabywców zainteresowanych czystym żelazem. Na rynku pszenicy występują na przykład gatunki o twardych nasionach i dużej zawartości białka (pszenica twarda durum) oraz gatunki o miękkich nasionach i małej zawartości protein (Tomaszewski, 2013).

Rynkiem formalnym, na którym w określonym czasie i miejscu dochodzi do przeciwstawienia się podaży i popytu oraz do kupna i jednoczesnej sprzedaży towarów masowych, bardzo ujednoczonych pod względem jakości, jest giełda towarowa. Giełdy towarowe dostarczają ponadto informacji na temat tendencji dotyczących popytu oraz podaży tych towarów, a także długoterminowych tendencji cenowych.

Giełdy towarowe we współczesnym rozumieniu pojawiły się dopiero w XVI w. Do najstarszych giełd w Europie poza giełdami powstałymi w Antwerpii, Lyonie i Amsterdamie należą: giełda londyńska powstała w 1536 r., giełda paryska funkcjonująca od 1724 r., giełda berlińska założona w 1740 r. oraz giełda wiedeńska istniejąca od 1771 r. Do rozwoju rynku towarowego przyczynili się jednak w głównej mierze Amerykanie. Pierwsze dwie giełdy w USA powstały w Nowym Jorku już w 1725 r. Jedna z nich znajdowała się na wschodnim końcu Wall Street, a druga na Broad Street. Na pierwszej odbywał się handel pszenicą, tytoniem i niewolnikami, a na drugiej handlowano masłem oraz jajami.

Na terenie Polski historia giełd towarowych sięga średniowiecza. Polska z racji swojego geograficznego położenia była istotnym szlakiem handlowym nie tylko Europy. Związki handlowe z państwami z terenu dzisiejszych Niemiec, Flandrią oraz Francją miały często charakter formalny. Pierwsza polska giełda powstała w Warszawie w 1890 r., następne giełdy powstały w Krakowie, we Lwowie i Wrocławiu. Niestety w 1950 r. giełdy towarowe zastąpiono przedsiębiorstwami handlu zagranicznego. Dopiero w latach 90. XX w., po prawie czterdziestoletniej przerwie, giełdy towarowe ponownie pojawiły się na polskiej scenie gospodarczej. Do największych giełd w Polsce należą: Giełda Poznańska Towarowa, Giełda Galicyjska w Tarnowie i Warszawska Giełda Towarowa. Choć wiele instytucji używa w swoich nazwach słowa giełda, to w rzeczywistości są one rynkami hurtowymi, na których odbywa się handel artykułami spożywczymi, rolniczymi oraz kwiatami.

Spośród największych obecnie giełd towarowych na świecie można wyróżnić:

- European Exchange (EUREX);
- Euronext;
- Marché à Terme International de France (MATIF);
- Hong Kong Futures Exchange (HKFE);
- Tokyo International Financial Futures Exchange (TIFFE);
- Tokyo Commodity Exchange (TOCOM);
- Deutsche Terminbörse (DTB);

- Moscow Interbank Currency Exchange (MICEX);
- Singapore International Monetary Exchange (SIMEX);
- Chicago Board of Trade (CBOT);
- Chicago Mercantile Exchange (CME);
- Chicago Board Options Exchange (CBOE);
- New York Mercantile Exchange (NYMEX);
- New York Cotton Exchange (NYCE);
- Swiss Options & Financial Futures Exchange (SOFFEX);
- London International Financial Futures and Options Exchange (LIFFE);
- London Metal Exchange (LME);
- Stockholmbörsen AB (OMLX);
- Sydney Futures Exchange (SFE);
- Wiener Börse AG.

Od wielu lat obserwuje się, jak rynki towarowe coraz bardziej przypominają rynki finansowe. Proces ten nosi nazwę ufinansowania rynków towarowych. Ufinansowanie, inaczej zwane finansjalizacją (Tomaszewski, 2013) czy finansjeryzacją (Zawojka, 2011), jest definiowane jako proces przesuwania się punktu ciężkości gospodarki ze sfery produkcji do sfery finansów lub jako eksplozywny wzrost rynków finansowych i ich oderwanie się od realnej gospodarki (Zawojka, 2011; Kra-
wiec, 2016). W wyniku finansjeryzacji rynków towarowych nastąpiła intensyfikacja oddziaływania rynków finansowych, a tym samym instytucji i inwestorów finansowych, na rynki towarowe, czego skutkiem jest ich wpływ na ceny na tych rynkach. Przejawem finansjeryzacji rynków towarowych jest wzmocnienie korelacji cen towarów z aktywami finansowymi (Tomaszewski, 2015).

Ufinansowanie rynków towarowych ułatwia inwestorom udział w transakcjach na rynkach towarowych. W związku z powyższym rynki towarowe są coraz częściej wykorzystywane do dywersyfikacji portfeli inwestycyjnych. Włączenie inwestycji towarowych do portfeli aktywów finansowych wykazuje istotne korzyści dywersyfikacyjne (Gorton i Rouwenhorst, 2004). Wzrost aktywności inwestorów finansowych na rynkach towarowych wywołał na początku XXI w. długotrwały trend wzrostu cen na większości rynków towarowych (Tomaszewski, 2015). Należy jednak zaznaczyć, że przeważająca część inwestycji portfelowych na rynkach towarowych nie ma charakteru inwestycji w fizyczne aktywa. Popularnymi produktami okazały się produkty oparte na indeksach cenowych rynku towarowego, a nie na cenach poszczególnych towarów (Tomaszewski, 2016). Indeks cen runku towarowego opracowano według cen wybranych towarów różnych klas lub cen określonej klasy towarów. Podstawą konstrukcji najbardziej popularnych indeksów rynku towarowego są ceny termino-

we, szczególnie ceny towarowych kontraktów futures pochodzących z najbardziej płynnych rynków giełdowych.

Wybór odpowiedniego towaru i formy inwestowania nie zawsze jest jednak łatwy. Tradycyjnym sposobem inwestowania w towary jest ich fizyczny zakup na rynku gotówkowym. Niestety w wypadku większości towarów pojawia się konieczność zapewnienia odpowiednich warunków przechowywania, co może być kłopotliwe szczególnie dla inwestorów indywidualnych.

Niezwykle ważnymi i strategicznymi towarami w inwestycjach są ropa naftowa, złoto i pszenica. Należą one bowiem do kluczowych surowców w swojej grupie, tj. surowców energetycznych, metali szlachetnych i surowców rolnych.

Ropa naftowa to obecnie najważniejszy surowiec energetyczny, bowiem jest czystsza i wydajniejsza niż węgiel oraz łatwiejsza do transportowania w porównaniu do gazu ziemnego. Stanowi także jeden z najważniejszych surowców dla przemysłu chemicznego. Wykorzystywana jest do produkcji nie tylko asfaltu, olei i smarów, nafty czy benzyny, ale także między innymi kosmetyków, leków, plastiku i kauczuku (Jewulski, 2006). Jej zasoby są nierównomiernie rozmieszczone na świecie. Największe jej rezerwy zlokalizowane są na Bliskim Wschodzie. Drugim pod względem zasobności w ropę naftową regionem na świecie jest Ameryka Środkowa i Południowa. Trzecim regionem świata bogatym w ten surowiec jest Ameryka Północna. Najmniej udowodnionych zasobów ropy naftowej zlokalizowanych jest w Europie (OPEC Annual Statistical Bulletin 2018).

Złoto jest bardzo pożądanym metalem szlachetnym mającym bardzo szerokie spektrum wykorzystania. Większość obecnie produkowanego złota wykorzystywana jest do produkcji biżuterii. Ze względu na doskonałą przewodność elektryczną i odporność na korozję oraz inne pożądane kombinacje właściwości fizycznych i chemicznych jest ono niezbędnym metalem wykorzystywanym w przemyśle. Zasoby złota znajdują się praktycznie na każdym kontynencie, ale zawartość czystego metalu w urobku z biegiem lat jest coraz mniejsza (Darst, 2013). Pomimo stosowania nowych technik wydobywania odkrywane są coraz mniejsze pokłady o małej zawartości złota. Zjawisko to powoduje, że produkcja złota staje się coraz mniej zyskowna (Mikita i Pełka, 2009). Warto jednak zaznaczyć, że ze względu na trwałość i wartość złoto praktycznie jest zawsze odzyskiwane i ponownie wprowadzane do obiegu. Kruszec ten jest bardzo ważny dla przemysłu i sztuki, zachowuje również wyjątkowy status wśród wszystkich towarów jako długoterminowy zasób wartości, bowiem siła nabywcza złota od wielu pokoleń się nie zmienia.

Pszenica jest również jednym z kluczowych surowców na światowych rynkach towarowych. Obok jęczmienia zalicza się do grupy najstarszych i odgrywających największą rolę w gospodarce zbóż. Jest pożywieniem milionów ludzi i jednym

z trzech podstawowych zbóż produkowanych na świecie. Wysoka pozycja pszenicy na globalnym rynku zbóż wynika z tego, że jest uprawiana na zdecydowanie większą skalę od innych zbóż i stanowi podstawę diet nieomal na całym świecie (Curtis i in., 2002). Ziarno pszenicy jest cenione z wielu powodów. Jednym z nich jest łatwość gromadzenia i przechowania. Drugi powód to łatwość przemiału, czyli uzyskania bardzo wartościowej mąki. Z tym wiąże się kolejny powód wysokiej pozycji pszenicy, czyli duża zawartość glutenu, która plasuje mąkę uzyskaną z pszenicy na pierwszym miejscu w przemyśle piekarniczym i cukierniczym. Pszenica jest składnikiem wielu produktów żywnościowych, ale nie tylko. Na jej bazie produkowane są różnego rodzaju pasze. Pszenica odgrywa również istotną rolę w intensywnie rozwijającej się produkcji biopaliw.

2. Charakterystyka rynku ropy naftowej

Ropa naftowa, zwana również czarnym złotem, stanowi jeden z najważniejszych surowców mineralnych na Ziemi. To olej skalny, który wykorzystywany jest do otrzymania wielu cennych produktów przemysłowych takich jak benzyna, nafta, olej napędowy czy też asfalt. Początek rozwoju przemysłu naftowego sięga przełomu wieków XIX i XX i jest nierozdzielnie związany z rozwojem przemysłu motoryzacyjnego. W skład ropy naftowej wchodzi przede wszystkim węglowodory parafinowe, naftenowe i aromatyczne oraz związki heteroorganiczne obejmujące siarkę, azot i tlen. Do najważniejszych właściwości fizycznych ropy naftowej należy gęstość, która uzależniona jest głównie od zawartości węglowodorów ciekłych i stałych: asfaltu, smoły, parafiny itp. (Jewulski, 2006). Najbardziej korzystna z punktu widzenia zastosowania jest ropa lekka, której gęstość nie przekracza $0,87 \text{ t/m}^3$. Jest ona źródłem większej ilości lekkich frakcji (gazów, benzyn oraz oleju napędowego) (Osikowicz, 2012). Ropy ciężkie klasyfikowane są jako ropy asfaltowe, asfaltowo-żywiczne oraz asfaltowo-siarkowe. Substancje żywiczno-asfaltowe mogą stanowić nawet 50% ich ogólnego składu (Jewulski, 2006).

Zasoby ropy naftowej są nierównomiernie rozłożone po świecie. Dodatkowo nie wszystkie zasoby są łatwe do identyfikacji i wydobycia. Zależy to między innymi od możliwości technicznych, jakimi dysponuje państwo, od opłacalności wydobycia surowca, ale także od sytuacji geopolitycznej i ekonomicznej państwa (Sorrell i in., 2012). Postęp technologiczny z pewnością sprzyja identyfikacji nowych złóż, a także pozwala na odkrywanie nowych, tańszych metod ich wydobycia. Dzięki postępowi technologicznemu światowe rezerwy ropy naftowej wzrastają. Szacuje się, że ich obecny poziom wystarczy na 54 lata, dla porównania w połowie lat 80. XX w. wskaźnik ten kształtował się na poziomie około 40 lat (Osikowicz, 2012).

W literaturze przedmiotu wyróżnia się kilka klasyfikacji zasobów naturalnych. Do najważniejszych z nich zalicza się tzw. udowodnione zasoby (ang. *proven reserve*) ropy naftowej. Udowodnione zasoby definiuje się jako wielkość zasobów, które zostały odkryte i dla których występuje co najmniej 90% prawdopodobieństwo, że mogą być one wydobyte i sprzedane z zyskiem. Przyjmuje się tu pewne założenia dotyczące kosztów wydobycia, sytuacji geopolitycznej, dostępnych technologii, możliwości zbytu oraz prognozowanych przyszłych cen (Ulatowski, 2014). W tabeli 2.1 przedstawiono rozkład udowodnionych zasobów ropy naftowej w podziale na regiony w latach 2000–2017. Zaprezentowane w tabeli 2.1 dane wyrażone są w milionach baryłek rocznie. Baryłka jest najpopularniejszą na świecie miarą ilości ropy naftowej. Jedna baryłka mierzy 42 galony, czyli około 159 litrów. Miara

Tabela 2.1. Udowodnione zasoby ropy naftowej w podziale na regiony w wybranych latach (mln baryłek/rok)

Region	2000	2010	2015	2016	2017
Europa	19 429	12 865	11 682	12 942	12 976
Rosja i Azja Centralna	56 384	98 283	118 284	118 284	118 284
Bliski Wschód	692 991	794 599	802 851	814 166	804 575
Afryka	92 882	123 900	123 491	123 313	123 313
Azja Pacyfik	47 110	46 243	50 507	52 520	50 083
Ameryka Północna	205 021	200 029	207 425	202 175	233 337
Ameryka Środkowa i Południowa	125 953	335 542	339 398	334 258	337 436
Świat	1 239 769	1 611 461	1 653 637	1 657 658	1 680 004
w tym:					
państwa OPEC	853 496	1 198 717	1 213 432	1 225 027	1 214 209
państwa spoza OPEC	386 273	412 744	440 205	432 631	465 795

Źródło: opracowanie własne na podstawie (Eni, 2017, 2018).


ta została ustanowiona przez amerykańską firmę Rockefellera, która to wprowadziła do handlu tzw. *standard oil blue barrel* (Sierakowska, 2016).

Największe rezerwy ropy naftowej zlokalizowane są na Bliskim Wschodzie, w tym głównie w Arabii Saudyjskiej, Iranie, Iraku, Kuwejcie i Zjednoczonych Emiratach Arabskich (tab. 2.1). Rezerwy na Bliskim Wschodzie stanowią prawie 50% rezerw światowych. Drugim pod względem zasobności w ropę naftową regionem na świecie jest Ameryka Środkowa i Południowa. Na czele tego regionu stoi Wenezuela, w której dysponowaniu znajdowało się w 2017 r. około 18% rezerw ogółem. Trzecim regionem świata bogatym w ropę naftową jest Ameryka Północna. Najmniej zasobów ropy naftowej posiada Europa. Z państw europejskich największe rezerwy znajdują się w Norwegii i stanowią około 0,4% rezerw ogółem (OPEC Annual Statistical Bulletin 2018).

Udowodnione zasoby ropy naftowej w złożach konwencjonalnych na świecie w 2017 r. wynosiły 1 680 004 mln baryłek, czyli o 36% więcej niż w 2000 r. (tab. 2.1). Zdecydowana większość światowych rezerw jest w posiadaniu państw należących do Organizacji Krajów Eksportujących Ropę Naftową (OPEC) zrzeszającej 12 krajów z Zatoki Perskiej, z Afryki i Ameryki Południowej. W latach 2000–2017 udowodnione zasoby ropy naftowej krajów OPEC stanowiły ponad 70% wszystkich zasobów. Warto podkreślić, że występują różnice w sposobie szacowania światowych rezerw ropy naftowej. Ich wielkość wahała się w 2017 r., w zależności od źródła, od około 1480 do 1680 mld baryłek. Przykładowo zasoby ropy naftowej w 2017 r. zostały wycenione przez Organizację Krajów Eksportujących Ropę Naf-

ową na 1 482 773 mln baryłek, co sugeruje, że państwa członkowskie OPEC dysponowały wówczas aż 82% światowych rezerw ropy naftowej (OPEC Annual Statistical Bulletin 2018).

Na rysunku 2.1 przedstawiono udowodnione rezerwy ropy naftowej w 2017 r. w podziale na państwa członkowskie OPEC. Prawie połowa rezerw ropy naftowej członków OPEC należy do Wenezueli i Arabii Saudyjskiej, które dysponują odpowiednio 24,9% oraz 21,9% zasobów OPEC. Duże rezerwy ropy naftowej posiadają także Iran (12,8%), Irak (12,0%), Kuwejt (8,4%) oraz Zjednoczone Emiraty Arabskie (8,1%). Pozostałe państwa członkowskie OPEC, tj. Libia, Nigeria, Katar, Algieria, Angola, Ekwador, Gabon i Gwinea Równikowa, posiadają łącznie około 12% rezerw należących do OPEC.



Rysunek 2.1. Udowodnione rezerwy ropy naftowej członków OPEC w 2017 r.

Źródło: opracowanie własne na podstawie (OPEC Annual Statistical Bulletin 2018).

Największymi udowodnionymi rezerwami ropy naftowej, nie tylko wśród państw OPEC, ale także na całym świecie, dysponuje Wenezuela. Badacze rynku ropy naftowej uważają dodatkowo, że wenezuelskie złoża tego surowca są jeszcze większe, tylko nie zostały jeszcze odkryte. Blisko 75% wenezuelskich rezerw to jednak niekonwencjonalne złoża ciężkich frakcji ropy naftowej. Ich eksploatacja jest bardzo kosztowna i wymaga zastosowania nowoczesnych technologii (Goćłowska-Bolek, 2018). W latach 60. XX w. Wenezuela była kluczowym członkiem OPEC

i wywierała duży wpływ na podejmowane przez organizację decyzje. Na początku XXI w. jej znaczenie w organizacji znacznie się zmniejszyło. Pomimo posiadania tak dużych złóż tego cennego surowca energetycznego kraj ten od wielu lat walczy z problemami ekonomicznymi, co widoczne było przede wszystkim w latach 2015–2017, kiedy to znacznie spadły ceny ropy naftowej. W latach 50. XX w. Wenezuela była czwartym najbogatszym krajem na świecie pod względem poziomu PKB per capita, w 2017 r. ponad 80% społeczeństwa żyło poniżej progu ubóstwa (Gocłowska-Bolek, 2018).

Wzrost udowodnionych rezerw ropy naftowej przebiega wolniej niż wzrost światowego wydobycia. W latach 2000–2009 na jedną odkrytą baryłkę ropy naftowej przypadały dwie wydobyte. Szacuje się, że państwa dysponujące największymi udokumentowanymi zasobami ropy naftowej mogą utrzymywać aktualny poziom produkcji tego surowca przez najbliższe kilkadziesiąt lat. Na rysunku 2.2 zaprezentowano największych producentów ropy naftowej. Państwa produkujące powyżej 400 mln ton rocznie zostały zaznaczone najciemniejszym kolorem szarym. Wśród największych producentów ropy naftowej znajdują się Rosja, Arabia Saudyjska i Stany Zjednoczone. Do czołowych producentów tego cennego surowca energetycznego zalicza się także Irak, Chiny, Indie, Kanadę, Zjednoczone Emiraty Arabskie, Kuwejt, Brazylię, Wenezuelę i Meksyk.



Rysunek 2.2. Produkcja ropy naftowej na świecie w 2017 r. (mln ton)

Źródło: Global Energy Statistical Yearbook 2018.

W tabeli 2.2 przedstawiono 15 największych producentów ropy naftowej na świecie w latach 2000–2017. Światowa produkcja ropy naftowej w 2016 r. wynosiła 3 949 674 tys. ton i była o 16% większa niż w 2000 r. Roczna produkcja 15 największych producentów ropy naftowej stanowi około 80% całkowitej produkcji światowej. Wśród trzech czołowych producentów ropy naftowej znajdowały się Rosja, Arabia Saudyjska i Stany Zjednoczone. Ich produkcja w 2016 r. stanowiła prawie 38% całkowitej produkcji światowej.

Tabela 2.2. Najwięksi producenci ropy naftowej w wybranych latach (tys. ton/rok)

Kraj	2000	2010	2015	2016	2017
Rosja	321 692	505 327	501 857	515 945	514 604
Arabia Saudyjska	410 595	406 997	508 026	522 800	495 970
Stany Zjednoczone	287 933	376 576	474 499	447 713	467 407
Irak	126 452	116 971	172 141	228 953	219 524
Chiny	163 000	203 832	211 451	199 578	191 908
Iran	187 689	175 976	156 510	181 819	bd
Kanada	87 937	133 879	178 648	177 576	190 968
Zjednoczone Emiraty Arabskie	107 834	111 650	154 900	159 929	153 026
Kuwejt	100 818	116 401	bd	bd	136 145
Brazylia	62 720	104 801	124 178	128 214	133 678
Wenezuela	164 146	144 752	138 888	124 565	108 059
Meksyk	156 403	133 916	117 851	111 948	101 297
Nigeria	108 541	120 083	103 886	88 901	90 529
Angola	36 705	84 588	86 807	84 373	80 371
Norwegia	157 522	91 316	77 611	80 078	78 570

Źródło: opracowanie własne na podstawie danych Głównego Urzędu Statystycznego.

Nie zawsze państwa, które dysponują największymi złożami ropy naftowej, są zarazem jej największymi producentami. Przykładowo Rosja, która była największym producentem ropy naftowej w 2017 r., posiadała wówczas zaledwie 5% całkowitych rezerw tego surowca (tab. 2.2). Z kolei Wenezuela, która dysponuje 18% zasobów ropy naftowej, odpowiadała w 2017 r. jedynie za 3% światowej produkcji. Państwa członkowskie OPEC charakteryzują się tym, iż pomimo tego, że posiadają olbrzymie zasoby ropy naftowej (82% wszystkich rezerw łącznie), to produkują dużo poniżej swoich możliwości. W 2017 r. odpowiadały one za około 43,5% całkowitej światowej produkcji (OPEC Annual Statistical Bulletin 2018). Takie działanie z pewnością zmniejsza u nich ryzyko szybkiej eksploatacji złóż. Ciekawym zobra-

zowaniem tego zjawiska jest to, że rezerwy ropy naftowej Rosji szacowane są na 25 lat, a Arabii Saudyjskiej na 65 lat (Osikowicz, 2012).

Produkcja ropy naftowej w Arabii Saudyjskiej i Rosji kształtuje się na podobnym poziomie, jednak to Arabia Saudyjska jest liderem w eksporcie tego surowca. W tabeli 2.3 przedstawiono 15 największych eksporterów ropy naftowej w latach 2000–2017. Głównymi dostawcami ropy naftowej na świecie w 2017 r. były Arabia Saudyjska, Rosja i Irak. Do grona wielkich eksporterów należą też Kanada, Zjednoczone Emiraty Arabskie, Iran i Kuwejt, których dzienny eksport ropy naftowej przekraczał wówczas 2 tys. baryłek. Eksport 15 największych dostawców ropy naftowej kształtował się w 2017 r. na poziomie 82% światowego eksportu (tab. 2.3).

Tabela 2.3. Najwięksi eksporterzy ropy naftowej w wybranych latach (tys. baryłek/dzień)

Kraj	2000	2010	2015	2016	2017
Arabia Saudyjska	6253	6644	7163	7463	6968
Rosja	3150	4978	4897	5081	5062
Irak	2040	1890	3005	3804	3802
Kanada	1180	1478	2301	2742	2912
Zjednoczone Emiraty Arabskie	1815	2104	2441	2408	2379
Iran	2492	2248	1081	1922	2125
Kuwejt	1231	1430	1964	2128	2010
Nigeria	1986	2464	2114	1738	1811
Wenezuela	2004	1562	1974	1835	1596
Angola	749	1711	1711	1670	1577
Kazachstan	521	1240	1229	1232	1371
Norwegia	2903	1602	1235	1373	1362
Meksyk	1850	1460	1247	1274	1265
Brazylia	20	581	736	891	1127
Stany Zjednoczone	52	42	465	591	1118

Źródło: opracowanie własne na podstawie (OPEC Annual Statistical Bulletin 2018).

W tabeli 2.4 zaprezentowano 15 największych importerów ropy naftowej. Największymi odbiorcami tego surowca w 2017 r. były Chiny, USA, Indie, Japonia i Korea Południowa. Ich średni dzienny import ropy naftowej kształtował się wówczas na poziomie powyżej 3 tys. baryłek. Import 15 największych odbiorców ropy naftowej stanowi prawie 82% importu światowego. W grupie 15 największych importerów ropy naftowej znalazło się siedem państw europejskich: Niemcy, Włochy, Hiszpania, Francja, Holandia, Wielka Brytania i Belgia. Ich łączny dzienny import

Tabela 2.4. Najwięksi importerzy ropy naftowej w wybranych latach (tys. baryłek/dzień)

Kraj	2000	2010	2015	2016	2017
Chiny	1409,2	4766,7	6730,9	7625,4	8425,7
Stany Zjednoczone	9814,9	9862,1	7363,0	7850,0	7912,0
Indie	1510,4	2758,6	3935,5	4308,3	4341,5
Japonia	4328,2	3472,7	3233,5	3157,8	3235,2
Korea Południowa	2474,4	2400,7	2781,1	2928,0	3040,6
Niemcy	2095,0	1883,2	1843,1	1837,4	1832,3
Włochy	1697,5	1591,7	1261,6	1225,5	1340,4
Hiszpania	1160,5	1060,6	1308,0	1292,1	1329,9
Francja	1725,7	1297,9	1145,8	1092,4	1140,7
Holandia	1103,8	1036,7	1056,5	1091,5	1092,9
Singapur	842,4	715,6	806,3	896,9	977,0
Tajlandia	676,2	848,8	874,0	852,6	906,0
Wielka Brytania	986,7	965,4	856,2	797,0	893,8
Kanada	918,1	764,7	565,5	888,5	807,1
Belgia	686,6	672,1	647,9	642,0	688,4

Źródło: opracowanie własne na podstawie (OPEC Annual Statistical Bulletin 2018).

ropy naftowej kształtował się w 2017 r. na poziomie około 8318 baryłek, czyli mniej więcej tyle, ile wynosił średni dzienny import ropy naftowej Chin. Z tego też powodu zmiany w kondycji gospodarczej Chin wywierają duży wpływ na rynek ropy naftowej.


Na świecie wydobywa się wiele gatunków ropy naftowej. Poniżej wyróżniono najbardziej popularne odmiany:

- ropa naftowa Brent (Brent blend, London Brent) – lekka ropa wydobywana od 1975 r. z Morza Północnego, której gęstość kształtuje się na poziomie około $0,835 \text{ t/m}^3$, wykorzystywana jest do produkcji paliw i benzyny;
- ropa naftowa WTI (West Texas Intermediate) – lekka ropa naftowa, której gęstość kształtuje się na poziomie około $0,825 \text{ t/m}^3$, wykorzystywana jest do produkcji paliw i benzyny, w procesie destylacji uzyskuje się z niej więcej oleju napędowego i benzyny niż z ropy Brent;
- ropa naftowa Dubai Crude (Arabian Light) – kwaśna, średniej gęstości ropa naftowa wydobywana głównie w Zatoce Perskiej;
- ropa naftowa Ural (Russian Export Blend Crude Oil – REBCO) – średniej gęstości ropa naftowa pochodząca ze złóż z rejonu Uralu i zachodniej Syberii.

Wymienione gatunki ropy naftowej należą do najbardziej popularnych i to od ich cen uzależnia się ceny pozostałych gatunków tego surowca energetycznego. Do-

datkowo często wykorzystywanym wskaźnikiem cen ropy naftowej jest referencyjny koszyk OPEC. Obliczany jest on na podstawie średniej ważonej cen surowca sprzedawanego przez państwa członkowskie OPEC. Znajdują się w nim zarówno ropy lekkie, jak i ciężkie. Średnia gęstość ropy w koszyku OPEC jest wyższa niż gęstość ropy Brent.

Na rysunku 2.3 przedstawiono kształtowanie się cen koszyka referencyjnego OPEC w latach 2000–2017.



Rysunek 2.3. Notowanie dzienne koszyka referencyjnego OPEC w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

W latach 2000–2003 ceny ropy naftowej zmieniały się w tendencji horyzontalnej, a ich poziom oscylował wokół 30 USD za baryłkę. Po amerykańskiej inwazji na Irak w 2003 r. ceny ropy naftowej zaczęły systematycznie wzrastać, osiągając w połowie 2008 r. rekordowy poziom 138 USD za baryłkę. W drugiej połowie 2008 r. nastąpił gwałtowny spadek cen ropy naftowej, wynikający między innymi z ustabilizowania sytuacji geopolitycznej w Iraku. Kolejne konflikty i walki w krajach arabskich przyczyniły się jednak do szybkiej zmiany tendencji i ceny ropy naftowej ponownie zaczęły wzrastać, osiągając w 2011 r. poziom około 120 USD za baryłkę. Lata 2011–2014 to czas wysokich cen ropy naftowej, kiedy to eksporterzy tego surowca energetycznego odnotowywali rekordowo duże zyski z jego sprzedaży. Ich sytuacja zmieniła się jednak w 2014 r. Spadek cen ropy naftowej do poziomu około 20 USD za baryłkę wywołał duże problemy ekonomiczne, przede wszystkim w państwach, w których podstawowym źródłem dochodu jest wydobycie i sprzedaż ropy naftowej. W literaturze przedmiotu wskazuje się wiele krótkoterminowych i długoterminowych czynników, które miały wpływ na gwałtowny spadek cen ropy naftowej od czerwca 2014 do stycznia 2016 r. Baffes i inni (2015) wyróżnili między innymi czynniki podażowe. W wyniku wzrostu podaży ropy naftowej ze źródeł niekonwencjonalnych oraz zmiany polityki kartelu OPEC, który w listopadzie 2014 r.

ogłosił, że nie będzie już ograniczał swojej produkcji, aby utrzymać globalną podaż ropy naftowej na stabilnym poziomie, doszło do znacznego wzrostu jej podaży, co natychmiastowo odbiło się na cenach tego energetycznego surowca. Dodatkowo Baffes i inni (2015) są zdania, że duży wpływ na spadek cen ropy naftowej w badanym okresie miało obniżenie światowego popytu na ten surowiec, w tym przede wszystkim spadek zapotrzebowania na niego ze strony Chin. W tym okresie doszło także do silnej aprecjacji dolara amerykańskiego, co również wpłynęło negatywnie na rynek ropy naftowej. Ponadto duże znaczenie w kształtowaniu się cen tego surowca energetycznego miały także czynniki geopolityczne. Należy podkreślić, że spadkowi cen ropy naftowej w czerwcu 2014 r. towarzyszyły konflikty na Bliskim Wschodzie czy też sankcje gospodarcze nakładane na Rosję, co znacznie zwiększyło ryzyko geopolityczne.

Do najważniejszych determinantów zmian cen na rynku ropy naftowej można zaliczyć czynniki: makroekonomiczne, podażowe, popytowe oraz geopolityczne.

Piórkarz (2013) wyróżnia tzw. tradycyjne czynniki kształtujące ceny ropy naftowej, do których należą: poziom podaży ropy naftowej grupy państw OPEC oraz państw niestowarzyszonych w kartelu, produkcja i konsumpcja energii, zapasy ropy naftowej, wolne moce przerobowe oraz ryzyko geopolityczne. Dodatkowo wśród ważniejszych czynników mających wpływ na zmienność cen ropy naftowej wymienia on: zmienność kursów walutowych, inwestycje spekulacyjne na rynku surowców, giełdowy handel instrumentami pochodnymi opartymi na cenach towarów oraz zmienność cen na rynku akcji.

Ważnym czynnikiem makroekonomicznym mającym wpływ na ceny ropy naftowej jest rozwój gospodarczy państw. Szybki wzrost gospodarczy krajów przyczynia się do zwiększenia popytu na ropę naftową i produkty ropopochodne, a tym samym powoduje wzrost ich cen. Procesy polityczno-gospodarcze zaczęły przebiegać w coraz szybszym tempie po pierwszej wojnie światowej. Można było wówczas zaobserwować wzrost zużycia energii, której głównymi źródłami stały się ropa naftowa i gaz ziemny. Po drugiej wojnie światowej nastąpił gwałtowny rozwój przemysłu, który wywołał wzrost zapotrzebowania na ropę naftową, większy niż nastąpiło to na początku XX w. Proces ten nadal trwa nieprzerwalnie. Przeplatany jest on jedynie krótkimi okresami spadku popytu na ropę naftową, wynikającymi z przejściowych problemów gospodarczych (Kłaczyński, 2010). Fournier i inni (2013) wykazali, że wraz ze wzrostem gospodarczym kraju rośnie popyt na ropę naftową. Oszacowali oni, że wzrost średniego realnego PKB krajów należących do Organizacji Współpracy Gospodarczej i Rozwoju (OECD) wywołuje 0,5-procentowy wzrost zapotrzebowania na ropę naftową. Z kolei wzrost średniego realnego poziomu PKB wśród krajów nienależących do OECD przyczynia się szacunkowo do wzrostu o 1% popytu

na ropę naftową. W latach 2000–2017 można było zaobserwować gwałtowny wzrost popytu na ropę naftową, zwłaszcza w takich krajach jak Chiny i Indie. Gospodarka tych krajów rozwijała się w tym okresie bardzo dynamicznie, a wzrost ten był surowcochłonny. Duży wzrost konsumpcji ropy naftowej w Chinach i Indiach spowodował dodatkowo, że kraje zrzeszone w OPEC zwiększyły swoje zaangażowanie w eksport ropy naftowej do państw tego regionu. W 2006 r. 67,3% eksportowanej ropy naftowej trafiło do krajów Dalekiego Wschodu, podczas gdy w 2016 r. były one odbiorcami 74,5% eksportu (Socha i Wdowiński, 2018). Warto dodać, że popyt na ropę naftową charakteryzuje się małą cenową elastycznością (Hamilton, 2008). W warunkach wysokich cen na rynku ropy naftowej ciężko jest bowiem znacząco zmniejszyć zapotrzebowanie w gospodarce na ten cenny surowiec. Dodatkowo, pomimo wprowadzania pewnych nowych rozwiązań technologicznych w transporcie, ropa naftowa jest nadal podstawowym surowcem do produkcji paliw i nie wynaleziono równie dobrego jej substytutu.

Ważnym czynnikiem wpływającym na ceny ropy naftowej od strony podażowej jest bieżący poziom udowodnionych rezerw, ich dostępność oraz poziom wydobycia. Źródła ropy naftowej należą do źródeł nieodnawialnych, co oznacza, że zasoby raz wydobyte i zużyte nie mogą zostać odtworzone (w relatywnie krótkim terminie) (Papież i Śmiech, 2015). Zmniejszający się poziom udowodnionych zasobów ropy naftowej prowadzi do wzrostu cen. Duży wpływ na wielkość wydobycia i ceny ropy naftowej ma także organizacja OPEC (Łęt, 2012). Światowy rynek ropy naftowej charakteryzuje się bowiem dużą wrażliwością na zmiany jej wydobycia (Kaliski i Jedynak, 2009). Jeżeli kwoty wydobycia surowca zostają zmniejszone, to wówczas spada podaż ropy naftowej, a tym samym dochodzi do wzrostu jej ceny.

Istotny wpływ na cenę ropy naftowej ma także działalność inwestycyjna spółek wydobywczych i ich nakłady na rozwój nowych technologii. Podaż tego surowca energetycznego zależy bowiem od dostępnych technologii jego wydobycia. Analizując rynek ropy naftowej od strony podażowej, silny wpływ na kształtowanie się cen mają również wolne moce produkcyjne i zdolności przerobowe koncernów naftowych, a także wielkość marż rafineryjnych. Ważnym czynnikiem mającym swoje odbicie w cenie ropy naftowej są także zdolności do magazynowania tego surowca. Dodatkowo duże znaczenie mają ceny pozostałych czynników produkcji takich jak koszty transportu czy też siły roboczej.

Należy podkreślić, że ropa naftowa jest nie tylko podstawowym towarem handlowym na rynkach światowych, ale także stanowi najbardziej płynny instrument finansowy rynku towarowego. Domanski i Heath (2007) są zdania, że XXI w. przyniósł duże zmiany w kształtowaniu się cen na rynku towarów. Na rynku tym pojawili się nowi uczestnicy, w tym instytucje finansowe takie jak fundusze inwestycyjne (Ir-

win i Sanders, 2012). Surowce oraz bazujące na nich instrumenty pochodne często postrzegane są bowiem jako alternatywne rynku kapitałowego instrumenty inwestycyjne (Zawojska, 2011). Gordon i Rouwenhorst (2006) uważają, że towary pozwalają na efektywną dywersyfikację portfela inwestycyjnego, gdyż w czasach wysokiej inflacji ich ceny utrzymują się na ogół w tendencji wzrostowej, podczas gdy rynek obligacji i akcji „porusza się” wówczas w trendzie spadkowym. Ważnym źródłem zmienności cen na rynku ropy naftowej jest zatem aktywność uczestników rynku finansowego (Fattouh i in., 2007). Wzrost aktywności inwestorów na rynku surowców oraz wszystkie następstwa z tego wynikające określane są w literaturze jako finansjeryzacja rynku surowców (Falkowski, 2011). Fattouh i inni (2013) wykazali jednak, że współzależność ceny spot ropy naftowej i ceny kontraktów terminowych na ten surowiec jest zgodna z podstawowymi teoriami ekonomicznymi dotyczącymi wyceny kontraktów terminowych i nie nosi znamion finansjeryzacji rynku terminowego ropy naftowej.

Dodatkowo cena ropy naftowej związana jest silnie z kształtowaniem się ceny dolara amerykańskiego. Po kryzysie naftowym z początku lat 70. ubiegłego wieku na mocy porozumienia z 1975 r. państwa zrzeszone w kartelu OPEC zgodziły się na rozliczanie transakcji wyłącznie w dolarach amerykańskich. Silna deprecjacja dolara amerykańskiego w latach 60. i 70. XX w. przyczyniła się bowiem do pogorszenia sytuacji finansowej głównych producentów ropy naftowej i zachęciła ich do podniesienia ceny tego surowca. Czterokrotny wzrost cen ropy naftowej w latach 1973–1974 wynikał głównie z działań organizacji OPEC, która broniła się przed spadkiem realnej wartości wpływów ze sprzedaży (Laidi, 2012). Deprecjacja dolara amerykańskiego wpływa zatem na decyzje producentów ropy naftowej, którzy w trosce o swoje dochody często decydują się na ograniczenie podaży tego surowca, a tym samym na wzrost jego ceny (Yousefi i Wirjanto, 2003). Jednocześnie tańszy dolar amerykański jest źródłem wzrostu popytu na ropę naftową w innych krajach. Deprecjacja waluty amerykańskiej oznacza bowiem niższą cenę ropy naftowej wyrażoną w walucie krajowej. Niższa cena ropy denominowanej w walucie krajowej powoduje wzrost popytu na ten surowiec i w rezultacie prowadzi do wzrostu jego ceny (De Schryder i Peersman, 2012). Zdaniem Fratzschera i innych (2014) związek między cenami ropy naftowej i wartością dolara amerykańskiego w latach 2004–2014 był ujemny i silniejszy niż w poprzednich latach. Fratzscher i inni (2014) wykazali, że spadek wartości dolara amerykańskiego o 1% powoduje wzrost średnich cen ropy naftowej o 0,73%. Na podstawie wyników dekompozycji wariancji prognozy uznali oni, że udział zmienności cen dolara amerykańskiego w zmienności cen ropy naftowej ma jednak ograniczone znaczenie ekonomiczne.

Wśród geopolitycznych czynników wpływających na wzrost cen ropy naftowej znajdują się konflikty zbrojne w regionach bogatych w złoża tego surowca energetycznego, napięcia polityczne między krajami importerami ropy naftowej a jej eksporterami oraz nacjonalizacja koncernów wydobywczych w niektórych państwach. Dodatkowo to państwa są najważniejszymi uczestnikami rynku energetycznego i to one w sposób bezpośredni czy też pośredni mają kluczowy wpływ na kształtowanie się cen ropy naftowej. Państwa są bowiem właścicielami surowców naturalnych znajdujących się na ich terytorium. Udzielają one zezwoleń na eksploatację zasobów naturalnych, nakładają na przedsiębiorstwa podatki i inne opłaty oraz ustalają normy ochrony środowiska naturalnego. Państwa są także właścicielami lub współwłaścicielami licznych koncernów naftowych. Dodatkowo państwa kształtują zachowania konsumentów. Drugim kluczowym podmiotem występującym na rynku ropy naftowej są koncerny naftowe. Dysponują one dużymi zasobami technologii i kapitału, a skala ich działalności pozwala im wywierać wpływ na sytuację ekonomiczną gospodarek na całym świecie (Ulatowski, 2014).

W ostatnich latach coraz większy wpływ na cenę ropy naftowej mają koszty ochrony środowiska. Wynikają one głównie z nałożonych opłat na producentów ropy naftowej i produktów ropopochodnych. Dodatkowo w przypadku skażenia środowiska naturalnego, spowodowanego na przykład wyciekami ropy z tankowców, jej właściciele są zobowiązani ponieść wysokie koszty odszkodowań. Do wzrostu cen ropy naftowej przyczyniają się także różnego rodzaju katastrofy naturalne (np. huragany), które niszczą platformy wiertnicze, generują straty u producentów tego surowca (Hymel, 2007).

3. Charakterystyka rynku złota

Długo przed okresem spisanej historii świata i ludzkości złoto było drogocennym i poszukiwanym metalem szlachetnym. Było ono cenione już od czasów starożytnych ze względu na jego piękno i trwałość. Do tej pory wykorzystywane jest między innymi do bicia monet, wytwarzania biżuterii czy wykonywania innych przedmiotów rzemiosła artystycznego. Surowiec ten stanowił i stanowi nadal symbol bogactwa. Ten cenny kruszec zajmuje także ważne miejsce w różnych symbolikach i ideologiach. Warto wspomnieć, że parytet złota był najpowszechniejszą podstawą polityki monetarnej w historii człowieka, powszechnie zastąpioną w XX w. przez pieniądz fiducyjny. Standardy złota stanowiły bowiem podstawę polityki monetarnej. Od 1945 r. złoto jest najważniejszym zasobem wartości i najważniejszym składnikiem globalnej gospodarki. Najbardziej atrakcyjne cechy złota to faktyczna wartość na całym świecie, zdolność do uzyskiwania zwrotów z inwestycji, ochrona inwestorów przed ryzykiem i jego płynność.

Złoto jest pierwiastkiem chemicznym o symbolu Au (od łacińskiego słowa *aurum* znaczącego świecący poranek) i liczbie atomowej 79. Jest on gęstym, błyszczącym, najbardziej kowalnym i ciągliwym metalem czystym. Czyste złoto ma jasno-żółtą barwę i połysk, który jest tradycyjnie uznawany za atrakcyjny. Pod względem chemicznym nie zmienia się wskutek oddziaływania powietrza, wilgoci i większości korozyjnych reagentów i dlatego nadaje się do stosowania w monetach, biżuterii, a także jako składnik powłok ochronnych na innych, bardziej reaktywnych metalach. Złoto rozpuszcza się jednak w rtęci i tworzy amalgamaty, lecz nie wchodzi z nią w reakcję. Złoto jest natomiast nierozpuszczalne w kwasie azotowym, który rozpuszcza srebro i metale nieszlachetne. Ta właściwość jest wykorzystywana w metodzie oczyszczania złota, znanej jako inkwartacja i rafinacja, czy potwierdzania obecności złota w różnych substancjach. Ponadto złoto z łatwością tworzy stopy z wieloma innymi metalami. Stopy te można wytwarzać, aby modyfikować twardość i inne właściwości metalurgiczne, kontrolować temperaturę topnienia lub tworzyć egzotyczne barwy. Powszechne, kolorowe stopy złota, takie jak złoto różowe, można utworzyć poprzez dodanie różnych ilości miedzi i srebra. Stopy zawierające pallad lub nikiel są także istotne w jubilerstwie komercyjnym, gdyż stanowią białe złoto. Dodanie manganu, glinu, żelaza, indu i innych pierwiastków umożliwia uzyskanie bardziej nietypowych barw złota do różnych zastosowań, co jednak praktykuje się mniej powszechnie. Co ciekawe, jeden gram złota można wykuć na arkusz

o powierzchni jednego metra kwadratowego, a uncję¹ złota na arkusz o powierzchni 300 stóp kwadratowych². Listek złota może być zatem tak cienki po wykuciu, że będzie półprzezroczysty, a przepuszczane przez nie światło jest zielonkawoniebieskie ze względu na mocne odbijanie żółtego i czerwonego koloru. Takie półprzezroczyste arkusze silnie odbijają także światło podczerwone, co sprawia, że są przydatne obecnie jako ekrany podczerwieni (ciepło promieniowania) w osłonach ubrań termoodpornych i osłonach przeciwsłonecznych kombinezonów kosmicznych (Darst, 2013). Złoto także dobrze przewodzi ciepło i prąd elektryczny.

Jak można zauważyć, złoto jest bardzo pożądanym metalem szlachetnym mającym bardzo szerokie spektrum wykorzystania. Złoto, będące bardzo cennym minerałem, wydobywane jest jednak w ograniczonych ilościach. Według danych do 2012 r. w historii ludzkości wydobyto w sumie 161 000 ton metrycznych (tj. 5 176 150 000 uncji trojańskich) złota (Darst, 2013). Surowca tego bowiem nie można łatwo znaleźć w naturze, a zatem ma ograniczoną podaż. Kruszec ten występuje jako samorodki lub ziarenka w skałach, naniesionych żyłach i złożach.

Większość obecnie produkowanego złota wykorzystuje się w produkcji biżuterii. Ze względu na doskonałą przewodność elektryczną i odporność na korozję oraz inne pożądane kombinacje właściwości fizycznych i chemicznych złoto pojawiło się również pod koniec XX w. jako niezbędny metal przemysłowy. Spełnia ono krytyczne funkcje w komputerach, sprzęcie komunikacyjnym, statkach kosmicznych, silnikach samolotów odrzutowych i wielu innych produktach. Złoto wykorzystywane jest także w stomatologii czy nawet w przemyśle spożywczym, stanowi również długoterminowy zasób wartości. Do niedawna uważano go za metal monetarny, a większość wyprodukowanego złota każdego roku trafiała do skarbców skarbu państwa lub banków centralnych (Darst, 2013).

Analizując charakter złota, należy jednak podkreślić, że możliwości zwiększenia jego wydobycia na świecie są ograniczone. Warto jednak zaznaczyć, że ze względu na trwałość i wartość złoto praktycznie jest zawsze odzyskiwane i ponownie wprowadzane do obiegu (Durst, 2013). Nie ma zatem prawdziwej konsumpcji złota w sensie ekonomicznym – globalne zapasy złota zwiększają się przy stosunkowo niskiej stopie rocznej, przy czym własność przechodzi „z rąk do rąk”. Ocenia się, że już w starożytności wydobyto około 10 000 ton złota. W okresie od XV do XVII w. produkcja wyniosła blisko 7 ton, a w XIX w. wzrosła do ponad 230 ton.

¹Uncja jest to jednostka masy bądź objętości, oznaczana jest symbolem „oz”. Najbardziej popularnymi odmianami uncji są: uncja międzynarodowa i uncja trojańska. Masa jednej uncji międzynarodowej wynosi 28,34952981 g, a masa jednej uncji trojańskiej to 31,1034768 g (www.mennica.com.pl).

²W terminologii metrycznej stopę kwadratową określa się jako kwadrat o długości boków wynoszącej 0,3048 m. Jedna stopa kwadratowa jest równa 0,09290304 metra kwadratowego (www.metric-conversions.org/pl).

Tak gwałtowny wzrost wydobycia był możliwy w wyniku odkrycia bogatych złóż w Kalifornii, Australii, na Alasce i w Afryce Południowej. Po drugiej wojnie światowej roczne wydobycie kształtowało się na poziomie powyżej 1000 ton. Złóża złota pozostałe obecnie pod ziemią oceniane są na 54 tys. ton. Przy aktualnym poziomie wydobycia te złoża wystarczyłyby na około 15–20 lat. Zasoby złota znajdują się praktycznie na każdym kontynencie (rys. 3.1), ale zawartość czystego metalu w urobku jest coraz mniejsza. Pomimo stosowania nowych technik wydobycia odkrywanie coraz mniejszych pokładów o małej zawartości złota powoduje, że produkcja złota staje się coraz mniej zyskowna (Mikita i Pelka, 2009).




Rysunek 3.1. Wydobycie złota na świecie w 2017 r.

Źródło: World Gold Council (gold.org/goldhub/data/historical-mine-production)

W latach 2000–2007 wydobycie złota kształtowało się na poziomie około 2,5 tys. ton rocznie (rys. 3.2). Po niewielkim spadku w 2008 r. (do ok. 2,3 tys. ton), wydobycie charakteryzuje się ponownie corocznym wzrostem. W latach 2008–2017, z roku na rok, średnie tempo wielkości wydobycia złota wynosiło około 1,3%. W 2017 r. wydobyto łącznie około 3,15 tys. ton tego kruszcu.

Od lat 80. XIX w. duża część światowych dostaw złota pochodziła z Republiki Południowej Afryki, która stanowiła wówczas około 50% całego wyprodukowanego złota. Produkcja złota w tym kraju w 1970 r. stanowiła już 79% światowych dostaw i wynosiła prawie 1000 ton. Jednak w 2007 r. produkcja spadła i wyniosła zaledwie 272 ton. Ten nagły spadek spowodowany był coraz większymi trudnościami związanymi z wydobywaniem, zmieniającymi się czynnikami ekonomicznymi wpływa-



Rysunek 3.2. Wielkość wydobycia złota na świecie w latach 2000–2017

Źródło: opracowanie własne na podstawie danych U.S. Geological Survey (2001–2018).

jącymi na przemysł i zwiększonymi środkami bezpieczeństwa. W 2007 r. Chiny, z wynikiem produkcji 276 ton, wyprzedziły RPA i stały się największym producentem złota na świecie. Innymi, głównymi producentami złota poza Chinami są obecnie Stany Zjednoczone, Australia, Rosja i Peru. Kopalnie w Południowej Dakocie i Nowadzie produkują około dwóch trzecich całego złota wydobywanego w kraju.

W 2017 r. Chiny wydobuły około 440 ton kruszcu. Taki poziom wydobycia utrzymuje się w tym kraju od kilku lat (tab. 3.1). Na drugim miejscu plasuje się Australia z wydobyciem corocznym nieprzekraczającym 300 ton kruszcu, następnie Rosja z poziomem wydobycia około 255 ton i Stany Zjednoczone z wydobyciem na poziomie około 245 ton złota.

Zazwyczaj wydobycie zwiększa się proporcjonalnie do wzrostu cen surowców. W przypadku złota jednak obserwuje się, że produkcja złota nie reaguje na rosnące ceny (Mikita i Pełka, 2009).

Notowania złota przedstawiane są w dolarach amerykańskich za uncję. Z kolei jedna tona to około 35 tys. uncji. Zatem obecnie jedna tona złota warta jest ponad 45 mln USD (przy cenie uncji ok. 1300 USD).

Wpływ na cenę złota ma bieżący popyt czy bieżąca podaż, te zaś są uzależnione od wielu czynników. Są nimi: inflacja, poziom stóp procentowych, sytuacja na rynkach finansowych (akcji), sytuacja geopolityczna, notowania dolara amerykańskiego, popyt, a także ceny ropy naftowej. Inflacja, jak również oczekiwania inflacyjne inwestorów i konsumentów mają bezpośrednie przełożenie na wartość pieniądza. Siła nabywcza złota zaś od wielu pokoleń się nie zmienia. Zatem oczekiwania

Tabela 3.1. Wielkość wydobycia złota w wybranych krajach w wybranych latach (tony)

Kraj	2000	2005	2006	2007	2010	2014	2015	2016	2017*
Chiny	180	225	245	275	345	450	450	453	440
Australia	296	262	244	246	261	274	278	290	300
Rosja	126	169	159	157	192	247	252	253	255
Stany Zjednoczone	353	256	252	238	231	210	214	222	245
Kanada	154	119	104	101	91	152	153	165	180
Peru	133	208	203	170	164	140	145	153	155
Republika Południowej Afryki	431	295	272	252	189	152	145	145	145
Meksyk	–	–	–	39	73	118	135	111	110
Uzbekistan	–	–	–	85	90	100	102	102	100
Brazylia	–	–	–	40	58	80	81	85	85
Ghana	–	–	–	84	82	91	88	79	80
Indonezja	125	140	164	118	120	69	97	80	80
Kazachstan	–	–	–	–	–	–	–	69	70
Papua Nowa Gwinea	–	–	–	65	68	53	60	62	60
Pozostałe kraje	735	793	818	513	597	858	897	840	845

*dane dla 2017 r. szacunkowe

Źródło: opracowanie własne na podstawie danych U.S. Geological Survey (2001–2018)

inflacyjne skutkują bardzo często tym, że następuje ucieczka kapitału do złotych aktywów. W przypadku zaś niskich stóp procentowych oferty banków okazują się być mało atrakcyjne i wówczas popyt na złoto rośnie, a tym samym rośnie jego cena. Jak wynika z prowadzonych analiz, notowania złota nie są skorelowane z innymi aktywami. Podczas gdy rynki finansowe ulegają wstrząsom, posiadanie kruszcu jako wysokiej jakości aktywa płynnego stanowi zabezpieczenie portfela inwestycyjnego. Złoto pozwala na łagodzenie strat inwestycyjnych. Konflikty zbrojne czy wzrost napięcia politycznego przekładają się także na wzrost cen złota. Sytuacje takiego typu wpływają na wzrost państwowych wydatków i inflację, a także w tych przypadkach przestają funkcjonować reguły ekonomii i różnego rodzaju aktywa finansowe stają się bezużyteczne. Nie spada wówczas jednak cena złota. Złoto chociaż nie jest oficjalną walutą, jednak ma wiele wspólnych z nią cech. Spadek kursu dolara amerykańskiego przekłada się na wzrost cen złota i jest to wyraźniejszy wpływ niż spadek ceny złota przy umacnianiu się kursu dolara. Cena ropy naftowej jest ściśle skorelowana z sytuacją geopolityczną ze względu na bycie surowcem strategicznym we współczesnym świecie. Wzrost ceny ropy skutkuje wzrostem cen towarów i usług konsumpcyjnych, tj. inflacji, co stymuluje wzrost ceny złota. Także ilość dostępnego na rynku złota wpływa w istotny sposób na jego cenę. Spadek podaży złota może spowodować jego deficyt na rynku, co w efekcie spowoduje wzrost jego ceny.

W okresie od 2000 r. najwyższe ceny złota notowano w latach 2010–2013, przy czym wydobycie złota było w tym okresie znacznie mniejsze niż w latach późniejszych (rys. 3.3). W 2000 r. cena złota za uncję kruszcu wynosiła około 270 USD, a na koniec 2017 r. kształtowała się na poziomie około 1330 USD.

Od 2006 r. można zauważyć gwałtowny wzrost ceny złota. Zapoczątkowany był on między innymi polityką niskich stóp procentowych w Stanach Zjednoczonych,




Rysunek 3.3. Ceny spot złota w latach 2000–2017

Źródło: opracowanie własne na podstawie danych World Gold Council.

która spowodowała boom gospodarczy oparty na rynku nieruchomości finansowanym tanimi kredytami. Skutkiem tego kryzysu była ucieczka inwestorów z rynku nieruchomości i akcji w bezpieczne inwestycje w złoto. W konsekwencji od 2007 r. pojawiały się bankructwa banków, między innymi banku inwestycyjnego Bear Stearns czy Lehman Brothers, polityka zerowych stóp procentowych wprowadzona przez duże banki centralne, a także dodruk pieniędzy w celu tzw. ratowania gospodarki. Wymienione czynniki powodują utratę wartości pieniądza (inflację). Cena złota 5 października 2011 r. osiągnęła szczyt na poziomie 1902,30 USD. Od tego momentu ceny złota spadły.


Kształtowanie się ceny złota ma swoje odzwierciedlenie w wartości eksportu i importu tego kruszcu. We wczesnych latach XXI w., gdy cena złota była dosyć niska i stabilna, wartość światowego obrotu złotem nie przekraczała 50 mld USD. Dopiero od 2005 r. wartość obrotu się zwiększała, osiągając największą wartość w 2013 r. (rys. 3.4). W 2000 r. obrót był na poziomie 31,7 mld USD, a osiągnął wartość 395 mld USD w 2013 r. W 2017 r. wartość światowego obrotu wyniosła 331 mld USD.



Rysunek 3.4. Światowy obrót złotem w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z Observatory of Economic Complexity.


Podaż i popyt na złoto od kilku lat pozostają na podobnym poziomie. Podaż złota oscyluje wokół 4,5 tys. ton (rys. 3.5). W podaży złota największy udział mają kopalnie (obecnie ponad 70% całej produkcji), następnie złoto pozyskane z recyklingu (niecałe 30%) i banki centralne.



Rysunek 3.5. Podaż złota w latach 2010–2017

Źródło: opracowanie własne na podstawie danych World Gold Council.

Na rysunku 3.6 zilustrowano zmianę światowego popytu na złoto w latach 2010–2017. Wzrost popytu na złoto jest często skutkiem zwiększonych czynników ryzyka na rynkach spowodowanych przez kryzysy zachodzące w gospodarce światowej, niestabilność na rynkach finansowych czy obawy o terroryzm i napięcia polityczne między krajami. Na zauważalnie wyższym poziomie był popyt w latach 2011–2012 i przekroczył nieznacznie 4,5 tys. ton (rys. 3.6). Korespondowało to w wysokim poziomie cen złota w tym okresie.



Rysunek 3.6. Popyt na złoto w latach 2010–2017

Źródło: opracowanie własne na podstawie danych World Gold Council.

Złoto jest bardzo często postrzegane przez inwestorów jako bezpieczna forma inwestycji. Jednak inwestycje nie są jedynym obszarem jego wykorzystania. Kruszec ten wykorzystywany jest przede wszystkim do produkcji biżuterii (ok. 55% całego popytu). W związku ze wzrostem ceny złota jednak można zauważyć spadek jego wykorzystania w tej branży, co widoczne było w latach 2010–2012. Branża jubilerska chociaż ma lwią część wykorzystania złota, to jest ono ponadto wykorzystywane w przemyśle (ok. 8%), szczególnie w sektorze elektronicznym (ok. 7%) oraz stomatologii (ok. 0,5%). Wykorzystanie złota w celach inwestycyjnych pochłaniało w ostatnich latach od około 20 do 39% całego złota, z tego najczęściej przeznaczano na sztabki i monety.

Od wielu lat największymi konsumentami złota na świecie są Chiny i Indie (tab. 3.2), następnie kraje Europy i Środkowego Wschodu. Chiny i Indie

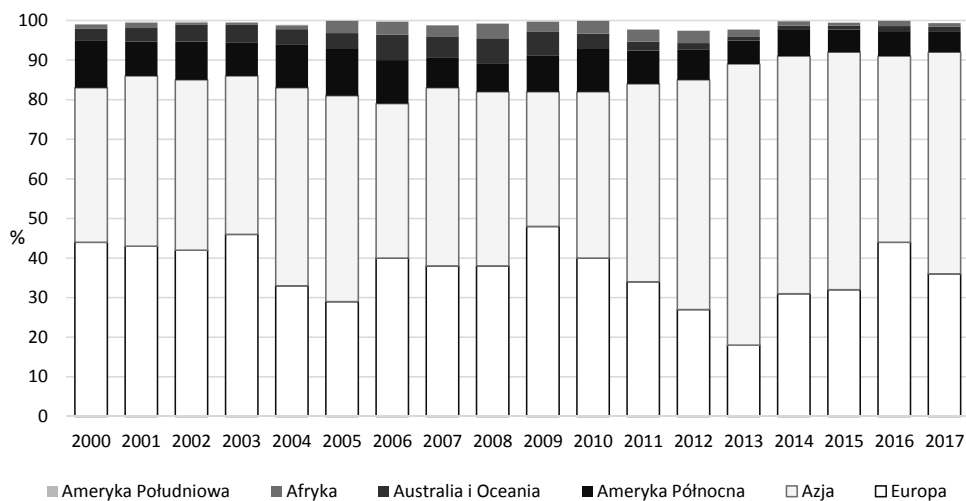
Tabela 3.2. Popyt konsumpcyjny złota w wybranych krajach w latach 2010–2017 (tony)

Kraj	2010	2011	2012	2013	2014	2015	2016	2017
	tony							
Indie	1001,7	974,0	914,2	958,6	833,5	857,2	666,1	771,2
Pakistan	33,8	39,9	39,4	44,2	35,8	37,6	42,2	44,9
Sri Lanka	0,0	0,0	0,0	0,0	9,1	10,7	10,5	11,2
Chiny	676,2	873,0	918,2	1449,4	1083,4	1047,8	970,3	1012,6
Japonia	-19,1	-36,4	5,1	20,9	13,7	32,7	34,0	13,3
Indonezja	50,6	60,8	61,7	88,1	63,4	59,0	59,5	58,8
Malezja	17,0	20,4	20,6	28,6	26,9	22,1	19,4	19,1
Singapur	9,9	13,1	14,8	20,9	20,5	18,1	17,1	16,6
Korea Południowa	19,2	26,5	27,9	40,6	39,2	45,0	38,4	40,4
Tajlandia	71,3	113,6	110,0	153,8	108,7	90,2	81,5	75,4
Wietnam	82,3	103,4	84,3	99,6	66,7	63,4	58,3	53,9
Środkowy Wschód	327,5	302,5	299,6	387,2	325,0	299,8	224,5	236,2
Arabia Saudyjska	84,5	72,5	65,9	84,7	84,0	84,4	60,2	55,6
Zjednoczone Emiraty Arabskie	76,9	68,2	60,0	78,5	66,0	60,2	49,5	48,3
Kuwejt	10,3	9,7	9,3	15,5	17,8	16,2	15,0	16,5
Egipt	55,3	36,4	44,2	52,8	51,1	43,2	28,2	24,5
Iran	85,0	98,2	102,1	127,7	75,4	67,3	45,1	64,5
Turcja	108,8	145,5	114,0	184,1	116,7	72,1	70,1	93,6
Rosja	60,3	64,4	67,7	79,7	75,5	47,9	42,0	42,9
Ameryka, w tym	303,8	266,8	224,2	251,4	224,6	248,5	266,3	215,4
Stany Zjednoczone	226,6	198,4	160,2	187,8	164,7	190,5	209,9	158,8
Kanada	20,4	20,6	17,6	19,6	18,4	17,5	17,9	17,0
Meksyk	27,5	21,9	18,4	18,4	18,0	19,0	18,2	19,3
Brazylia	29,2	25,9	28,1	25,6	23,5	21,4	20,2	20,2
Europa ze Wspólnotą Niepodległych Państw	394,5	421,8	317,2	336,3	274,3	297,6	278,0	266,5
Francja	22,0	25,7	18,4	16,8	15,1	13,1	9,2	13,2
Niemcy	136,6	154,4	118,9	143,4	111,3	126,1	121,1	117,0
Włochy	34,2	26,9	22,6	21,1	19,9	19,2	19,0	18,8
Hiszpania	11,6	8,2	8,4	7,8	8,3	8,5	8,3	8,5
Wielka Brytania	40,9	39,0	34,9	32,5	33,2	34,4	37,1	33,4
Szwajcaria	86,9	96,8	62,2	61,7	47,7	50,3	45,6	42,5
Austria	13,7	15,1	10,4	13,0	10,2	12,2	10,8	9,7

Źródło: opracowanie własne na podstawie „Gold Demand Trends”, World Gold Council.

odpowiadają za ponad połowę światowego popytu na fizyczne złoto. Popyt na ten kruszec w tych krajach stanowił w 2017 r. odpowiednio 31 i 24%. Popyt krajów europejskich stanowił 8%, a Środkowego Wschodu 7%.

Ze względu na wysoki popyt konsumpcyjny złota w światowym imporcie złota dominują kraje z Azji i Europy (rys. 3.7). W 2017 r. import krajów azjatyckich stanowił 56% (przy udziale w 2016 r. wynoszącym 47%) całego importu, a 36% krajów europejskich (44% w 2016 r.). Ameryka Północna z wartością importu na poziomie około 17 mld USD uplasowała się na trzecim miejscu (5,1%), a kraje z Oceanii i Afryki zaimportowały po odpowiednio około 1,3 i 0,93%.



Rysunek 3.7. Struktura importu złota według kontynentów

Źródło: opracowanie własne na podstawie danych z Observatory of Economic Complexity.


Spośród wszystkich krajów świata największym importerem złota jest Szwajcaria (tab. 3.3). W 2017 r. import kruszcu w tym kraju wyniósł około 71 mld USD i był o 19% mniejszy niż w 2016 r. Chiny w 2017 r. zaimportowały złoto o wartości 40 mld USD i było to o 21% mniej niż w 2016 r.

Największym eksporterem złota od wielu lat charakteryzują się kraje azjatyckie z europejskimi (rys. 3.8). W 2017 r. kraje z Europy wyeksportowały łącznie złoto o wartości około 107 mld USD, co stanowiło 32% całego eksportu złota, zaś kraje z Azji o wartości około 99 mld USD (30%). Kraje afrykańskie, Ameryka Północna, Oceania i Ameryka Południowa wyeksportowały złoto odpowiednio z udziałami: 11, 11, 10 i 6%.

Tabela 3.3. Najwięksi importerzy złota w 2017 r.

Kraj	Wartość (mld USD)	Udział (%)
Szwajcaria	70,9	21,0
Chiny	40,3	12,0
Indie	39,0	12,0
Hongkong	35,0	11,0
Wielka Brytania	34,3	10,0
Zjednoczone Emiraty Arabskie	17,2	5,2
Turecja	17,1	5,2
Singapur	12,1	3,7
Stany Zjednoczone	11,1	3,3
Tajlandia	10,6	3,2
Kanada	5,5	1,6
Niemcy	5,2	1,6
Australia	4,3	1,3
Włochy	3,6	1,1
Malezja	3,2	1,0

Źródło: opracowanie własne na podstawie danych z Observatory of Economic Complexity.

**Rysunek 3.8.** Struktura eksportu złota według kontynentów

Źródło: opracowanie własne na podstawie danych z Observatory of Economic Complexity.

Podobnie jak w imporcie, tak i w eksporcie złota od wielu lat prym wiodzie Szwajcaria. W 2017 r. wyeksportowała ona złoto o wartości 70 mld USD (tab. 3.4). Na drugim miejscu uplasowała się Australia, a następnie Hongkong przed Stanami Zjednoczonymi.

Tabela 3.4. Najwięksi eksporterzy złota w 2017 r.

Kraj	Wartość (mld USD)	Udział (%)
Szwajcaria	70,3	21,0
Australia	29,1	8,8
Hongkong	25,6	7,7
Stany Zjednoczone	22,0	6,7
Republika Południowej Afryki	20,2	6,1
Zjednoczone Emiraty Arabskie	16,9	5,1
Wielka Brytania	16,1	4,9
Japonia	12,9	3,9
Singapur	10,3	3,1
Ghana	8,4	2,5
Peru	7,1	2,2
Turcja	7,0	2,1
Kanada	6,9	2,1
Meksyk	5,1	1,5
Niemcy	5,0	1,5

Źródło: opracowanie własne na podstawie danych z Observatory of Economic Complexity.

Według opinii Michała Teklińskiego z goldenmark.com 2018 r. był najlepszym rokiem na rynku złota od 2010 r. Inwestycje w złoto zdeklasowały inwestycje w inne metale szlachetne, tj. srebro, platynę czy pallad. Swoją popularność złoto zawdzięczało sytuacji na rynku geopolitycznym, w szczególności decyzjom Kima Dzonga Una, który groził atakiem nuklearnym. Cena złota zyskiwała również na słabnącym dolarze amerykańskim, a także na niskim poziomie stóp procentowych. „Oszczędzający coraz częściej wycofują środki z obligacji lub lokat bankowych, które przy odradzającej się inflacji przynoszą tylko coraz większą stratę i kierują w stronę alternatywnych aktywów, co podniosło cenę szlachetnego kruszcu” (Tekliński, 2018).

4. Charakterystyka rynku pszenicy

Pszenica jest to zboże, które obok jęczmienia, zalicza się do grupy najstarszych i odgrywających największą rolę w gospodarce zbóż. Jest pożywieniem milionów ludzi i jednym z trzech podstawowych zbóż produkowanych na świecie. Dwa pozostałe zboża to jęczmień i kukurydza. Pszenica jest uprawiana na większej powierzchni niż jakakolwiek inna komercyjna uprawa i nadal jest najważniejszym źródłem żywności przeznaczonym do spożycia przez ludzi (Curtis i in., 2002). Pszenica jest głównym produktem spożywczym ze względu nieskomplikowany sposób przechowywania zbiorów i łatwość przekształcania ziarna na mąkę do wyrobu podstawowych artykułów spożywczych. Jest też głównym źródłem węglowodanów w diecie ludzi z wielu krajów. Jej niekwestionowana popularność wynika, między innymi, z dużej zawartości glutenu i innych składników mineralnych oraz tego, iż stanowi ona bardzo ważne źródło energii oraz wspomaga metabolizm (Norton i in., 2010).

Tak zwana udomowiona pszenica (uprawna) ma znaczną i wciąż rosnącą liczbę odmian. Obecnie w gospodarce bezdyskusyjnie czołowe znaczenie ma pszenica zwyczajna (Engliad i in., 2017).

Początki upraw różnych gatunków pszenicy sięgają co najmniej dziesięciu tysięcy lat wstecz i znajdują swe miejsce na Bliskim Wschodzie, w obszarze tzw. Żyźnego Półksiężycy, czyli terenów współczesnej południowo-wschodniej Turcji. Uprawiana dzisiaj pszenica zwyczajna pojawiła się stosunkowo późno, bo dopiero pod koniec drugiego tysiąclecia przed naszą erą na terenach północno-wschodniego Iranu. Ze względu na swoje liczne, cenione walory zdominowała ona rynek i stała się najbardziej pożądanym zbożem ówczesnego świata basenu Morza Śródziemnego. Jednym z głównych producentów i dostawców pszenicy w starożytności był między innymi Egipt, aż do jego upadku w pierwszej połowie VII w. (Jagusiak, 2015).

Przez całą starożytność pszenica zwyczajna stanowiła dla Rzymian podstawę żywienia. W tamtym okresie jednakże była bardzo droga i trudno dostępna. Jedną z przyczyn tego stanu było to, iż na terenie Grecji właściwej i w części Italii ze względu na nieodpowiednią glebę i warunki klimatyczne zupełnie nie uprawiano pszenicy. Konieczne zatem było jej importowanie. I tak, od początku V w. p.n.e. Rzymianie importowali pszenicę z obszarów Morza Czerwonego. Z upływem czasu Rzymianie w rejonach sprzyjających uprawom, czyli Etrurii, żyźnej Kampanii, okolicach Ankony i Umbrii, zaczęli uprawiać pszenicę. Mimo to w miarę wzrostu liczby ludności Rzymu oraz zdobywania przez państwo rzymskie nowych terytoriów pojawiła się konieczność uzupełniania posiadanych zasobów pszenicy. Na szeroką skalę rozwinął się import zboża do Rzymu z Egiptu, Afryki Północnej, a także Galii,

Sycylii, Sardinii i Hiszpanii. Od końca II w. p.n.e. większość Rzymian miała dostęp do pszenicy po zaniżonych cenach, a od czasów cesarza Oktawiana Augusta do V w. do pewnej darmowej ilości pszenicy (Jagusiak, 2015).

Pszenica była także najważniejszym zbożem w Cesarstwie Wschodnio-Rzymskie. Od czasów ustanawiania i umacniania pozycji Konstantynopola jako stolicy Cesarstwa Bizantyjskiego, tj. od pierwszej połowy IV w., powszechne było rozdawnictwo chleba pszennego. Pszenicę do wypieku chleba sprowadzano wówczas z Egiptu. Stan ten utrzymywał się do początków VII w., czyli do upadku Egiptu pod wpływem arabskiego podboju. Po upadku Egiptu pszenicę sprowadzano z Tracji i Azji Mniejszej (Jagusiak, 2015).

Mijały wieki, świat obserwował liczne zmiany demograficzne, etniczne i technologiczne, a pszenica zwyczajna zachowywała status ulubionego i jednego z dwóch najczęściej sianych zbóż w krainach należących do Bizancjum. Głównymi producentami i dostawcami pszenicy w tym okresie byli wielcy posiadacze ziemscy. Tylko oni, przy ówczesnych metodach gospodarowania, zmiennych warunkach pogodowych, pustoszących pola najazdów wrogich ludów, byli w stanie dostarczać ludności odpowiednią ilość ziarna. Państwo w tym okresie w żaden sposób nie ingerowało w zasady handlu i transportu pszenicy (Jagusiak, 2015).

W kolejnych stuleciach produkcja pszenicy była nierozzerwalnie związana z rozwojem cywilizacji. W połowie XX w. znaczenie ekonomiczne produkcji pszenicy dawało jej pierwsze miejsce wśród pozostałych upraw ze względu na rozmiary powierzchni zasiewów (ok. 22% ziemi uprawnej całego globu), produkowaną ilość oraz liczbę pracowników zatrudnionych przy jej uprawie. W połowie XX w. największym zarówno producentem, jak i konsumentem pszenicy był Związek Socjalistycznych Republik Radzieckich (Jankowiak i Makiela, 1968). Drugie miejsce jako producent pszenicy zajmowały Stany Zjednoczone, które jednocześnie były największym jej eksporterem. Szacowano, iż na Stany Zjednoczone przypada 40% światowego eksportu pszenicy. Eksport ten skierowany był głównie do Japonii, Indii, Pakistanu, Wielkiej Brytanii, Holandii, Belgii, Niemieckiej Republiki Federalnej, Hiszpanii, Meksyku i Zjednoczonej Republiki Arabskiej (Jankowiak i Makiela, 1968). Liczącym się eksporterem pszenicy w tamtym okresie była również Kanada. Mimo że jako producent pszenicy zajmowała dopiero trzecie miejsce, to ze względu na małe spożycie generowała duże nadwyżki pszenicy i zajmowała drugie miejsce w światowym eksporcie tego zboża. Głównymi odbiorcami kanadyjskiej pszenicy były Wielka Brytania i kraje Brytyjskiej Wspólnoty Narodów (Jankowiak i Makiela, 1968).

W wieloletniej perspektywie światowego rynku daje się zauważyć znaczący wzrost produkcji pszenicy w drugiej połowie XX w. oraz jej nadal dominującą (obok kukurydzy) pozycję w światowym handlu. Za determinanty tego stanu uważa się postęp w technologii uprawy i genetyce, intensyfikację produkcji oraz zwiększe-

nie areалу uprawy. Głównymi importerami pszenicy były kraje Azji Południowej, Afryki, Związek Radziecki i Oceania, a głównymi eksporterami Ameryka Północna i Południowa (głównie Argentyna) (Jankowiak i Makiela, 1968).


W XXI w. pszenica wciąż pozostaje jednym z kluczowych surowców na światowych rynkach. Pozycję tę zapewnia jej z jednej strony areal, z drugiej strony to, iż nadal stanowi ona podstawę diet nieomal na całym świecie. Ziarna są obecnie najważniejszym źródłem zaopatrzenia w żywność ludzi na całym świecie. Około 21% światowej żywności zależy od rocznych zbiorów pszenicy. A skoro tak, to zasoby pszenicy mają bezpośrednie przełożenie na poziom bezpieczeństwa żywnościowego (FAO, 2013–2014; Enghiad i in., 2017). Zważywszy na niski poziom zapasów pszenicy, zaspokojenie potrzeb żywnościowych zależy od bieżących zbiorów. Kraje rozwijające się, z których większość to importerzy netto, zużywają około 77% całkowitej światowej produkcji pszenicy. Pszenica stanowi około 24% towarów żywnościowych importowanych przez te kraje (Ortiz, 2008; Enghiad i in., 2017).

Obserwowane wcześniej tendencje na światowym rynku pszenicy uległy w XXI w. znaczącej zmianie. Państwa dotychczas importujące pszenicę zwiększają jej areal u siebie, natomiast kraje eksportujące odwrotnie – ograniczają. Wzrost areалу pszenicy obserwuje się w krajach Azji Południowej, Afryki, Oceanii, a także w krajach Wspólnoty Niepodległych Państw, czyli w byłych republikach Związku Radzieckiego należących do tego regionalnego ugrupowania integracyjnego. Zmniejszenie areálu dotyczy krajów Ameryki Północnej i Południowej (Szajner i in., 2015).


W pierwszym dziesięcioleciu XXI w. pszenica uprawiana była w 74 krajach, od 2010 r. uprawia się ją w 80 krajach. Kraje, w których w ostatnich latach pojawiała się uprawa pszenicy, to Uganda, Tajwan, Ruanda, Namibia, Mali i Malawi. W 2017 r. łączny areal upraw pszenicy wynosił około 219 475 000 ha. Pod względem areálu pszenicy bezwzględnie światowa palma pierwszeństwa należy do Indii, które od 2000 r. mają największy (z roku na rok większy) jej areal. Stanowi on około 14% światowego areálu pszenicy.

Na rysunku 4.1 przedstawiono areal upraw w 2017 r. w krajach z największym arealem. W poprzednich latach drugie miejsce zajmowała przeważnie Unia Europejska, ustępując w 2017 r. Rosji. Arealy upraw pszenicy w Unii Europejskiej i Rosji w 2017 r. stanowią po około 12%. W pierwszej czwórce krajów z największym arealem pszenicy znajdują się również Chiny, których areal stanowi około 11% światowego areálu pszenicy. Na rysunku 4.2 przedstawiono areal upraw pszenicy w krajach Unii Europejskiej.

Wśród krajów Unii Europejskiej, podobnie jak w ubiegłym stuleciu, największy areal upraw pszenicy znajduje się we Francji (21% areálu w Unii Europejskiej i ok. 3% światowego areálu). Drugie miejsce pod względem areálu pszenicy zaj-



Rysunek 4.1. Areał upraw pszenicy na świecie w 2017 r. (20 krajów z największym areałem)
Źródło: opracowanie własne na podstawie danych U.S. Department of Agriculture.



Rysunek 4.2. Areał upraw pszenicy w Unii Europejskiej w 2017 r. (20 krajów z największym areałem)
Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

mują Niemcy (ok. 12% areału w Unii Europejskiej i ok. 1,5% światowego areału). Na trzecim miejscu zaś znajduje się Polska, której areał pszenicy stanowi około 9% areału Unii Europejskiej i 1% światowego areału.

W latach 2000–2017 nastąpił wzrost plonów pszenicy. Na rysunku 4.3 przedstawiono zmiany średniego plonu pszenicy. Wzrost plonu pszenicy uzasadniany jest



Rysunek 4.3. Zmiany średniego plonu na świecie w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.


postępem technicznym w zakresie uprawy oraz intensyfikacji produkcji, szczególnie w krajach rozwijających się. Wiodącym krajem pod względem uzyskiwanego plonu pszenicy w XXI w. jest Nowa Zelandia (ok. 4,6% łącznego światowego plonu w 2017 r.). W tabeli 4.1 przedstawiono 10 krajów, które uzyskały najwyższe plony pszenicy w 2017 r. wraz z ich udziałami w łącznej wielkości plonu na świecie. Jedynie w przypadku Australii odnotowano spadek plonów, który jest wynikiem zmian klimatycznych oraz długotrwałych susz.

Tabela 4.1. Plon zbóż w 10 krajach o największych plonach na świecie

Kraj	Plon (Mt/ha)	Udział w światowym plonie (%)
Meksyk	5,24	2,4
Norwegia	5,33	2,4
Chiny	5,41	2,5
Namibia	5,50	2,5
Kraje Unii Europejskiej	5,77	2,6
Chile	6,00	2,7
Szwajcaria	6,00	2,7
Egipt	6,40	2,9
Zambia	7,19	3,3
Nowa Zelandia	9,98	4,6

Źródło: opracowanie własne na podstawie danych uzyskanych z U.S. Department of Agriculture.

W przypadku wielkości zbiorów zbóż w badanym okresie wyraźnie widać duże wahania, spowodowane zmiennymi warunkami klimatycznymi. Mimo to obserwuje się tendencję wzrostową zbiorów. Na rysunku 4.4 przedstawiono zmiany średniej wielkości produkcji pszenicy w latach 2000–2017.




Rysunek 4.4. Zmiany średniej wielkości produkcji pszenicy na świecie w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

W większości krajów obserwowany jest również wzrost wielkości zbiorów pszenicy. Jedynie w Ameryce Południowej ograniczono areał i produkcję pszenicy na korzyść zbóż paszowych i soi. W omawianym okresie zmieniła się też nieco struktura geograficzna produkcji pszenicy w stosunku do tego, co było obserwowane w XX w. Zmniejszył się udział dwóch dużych rejonów nadwyżkowych, czyli Unii Europejskiej i Ameryki Południowej, oraz największego rejonu importerskiego, czyli Bliskiego Wschodu. Wzrósł natomiast udział pozostałych dużych importerów, czyli Azji i Afryki. Wzrósł również udział państw Wspólnoty Niepodległych Państw¹ jako eksportera pszenicy. Największymi producentami pszenicy są zarówno kraje deficytowe w jej produkcji (importerzy), do których należą Chiny, Indie, Pakistan, jak i kraje dysponujące trwałymi, strukturalnymi nadwyżkami, do których zalicza się Unię Europejską, Stany Zjednoczone, Australię, Kanadę, Argentynę, a także Rosję i Ukrainę. Produkcja pszenicy na świecie jest silnie skoncentrowana i występuje w nielicznej grupie krajów. Dziesięciu największych producentów wytwarza około 84% światowych zbiorów pszenicy. Mimo zmniejszonego udziału nadal pierwsze miejsce pod względem wielkości produkcji pszenicy zajmuje Unia Europejska,

¹W skład tej wspólnoty wchodzi wszystkie kraje byłego Związku Socjalistycznych Republik Radzieckich oprócz Litwy, Łotwy i Estonii.

której wielkość produkcji stanowiła około 20% światowej produkcji pszenicy. Na drugim miejscu są Chiny (ok. 17% światowej produkcji), a na trzecim Indie (ok. 13% światowej produkcji). Na rysunku 4.5 przedstawiono produkcję pszenicy w grupie 20 największych producentów pszenicy na świecie.



Rysunek 4.5. Produkcja pszenicy w 2017 r. w grupie największych producentów
Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

O światowej podaży handlowej pszenicy, czyli tzw. nadwyżkach eksportowych, decyduje jednak osiem największych eksporterów: Argentyna, Australia, Kanada, Unia Europejska, Stany Zjednoczone, Rosja, Ukraina, Kazachstan. Zbiory pszenicy w tych krajach stanowią ponad połowę światowej produkcji, czyli około 52% światowej produkcji.

W krajach Unii Europejskiej wiodącym producentem pszenicy jest Francja, której wielkość produkcji stanowi około 26% europejskiej produkcji i 5% światowej produkcji. Na drugim miejscu pod względem produkcji pszenicy w Unii Europejskiej są Niemcy (16% europejskiej produkcji i ok. 3% produkcji światowej), a na trzecim miejscu Wielka Brytania (ok. 10% europejskiej produkcji i 2% produkcji światowej). Polska w ostatnich latach zajmowała czwarte miejsce pod względem produkcji pszenicy. W 2017 r. wielkość zbiorów pszenicy w Polsce stanowiła około 8% europejskiej produkcji i 1,5% produkcji światowej.

Udział 10 głównych importerów w światowej produkcji pszenicy kształtuje się na poziomie 40%. W tabeli 4.2 przedstawiono 20 największych importerów na rynku pszenicy w 2017 r.


Tabela 4.2. Import pszenicy w 10 największych krajach importerskich

Kraj	Import (1000 Mt)	Udział w światowym imporcie (%)
Egipt	12 000	0,07
Indonezja	10 500	0,06
Algieria	8 200	0,05
Brazylia	7 000	0,04
Bangladesz	6 400	0,04
Turcja	6 400	0,04
Japonia	6 000	0,03
Filipiny	5 800	0,03
Kraje Unii Europejskiej	5 600	0,03
Meksyk	5 300	0,03

Źródło: opracowanie własne na podstawie danych uzyskanych z U.S. Department of Agriculture.


W niektórych dużych krajach importerskich, takich jak Egipt, obowiązują wysokie cła na produkty pszenne, na przykład na makarony i pieczywa. Doprowadziło to do zwiększenia importu ziarna pszenicy i wzrostu pozycji tego kraju jako głównego eksportera pszenicy (Enghiad i in., 2017).

Światowe zużycie zbóż charakteryzuje się wieloletnią tendencją wzrostową. Na rysunku 4.6 przedstawiono zmianę średnich poziomów konsumpcji domowej obserwowanej w latach 2000–2017.

**Rysunek 4.6.** Zmiana średniej konsumpcji krajowej pszenicy w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

Wraz ze zmianami areалу, produkcji i plonu zauważalna jest również zmiana struktur spożycia determinowana kilkoma czynnikami. Zbiór owych czynników obejmuje wzrost dochodów ludności i związaną z tym zmianę sposobu odżywiania się, wzrost populacji oraz postęp technologiczny (Szajner i in., 2015). Zużycie pszenicy w bieżącym stuleciu rosło średnio o około 8 mln ton rocznie. Zmienność zużycia pszenicy była natomiast znacząco mniejsza niż w przypadku pozostałych zbóż. Największy wzrost zużycia pszenicy wystąpił w najbiedniejszych krajach oraz krajach rozwijających się, czyli w krajach Azji Południowej i Północno-Wschodniej, Afryki, Ameryki Południowej oraz na Bliskim Wschodzie. Wzrost ten spowodowany był wzrostem populacji oraz poprawą sytuacji ekonomicznej ludności. W krajach rozwiniętych wzrost zużycia pszenicy był o wiele mniejszy (Szajner i in., 2015). Na rysunku 4.7 przedstawiono 20 krajów, w których w 2017 r. była największa konsumpcja krajowa pszenicy.




Rysunek 4.7. Średnia konsumpcja krajowa pszenicy w 2017 r.
Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

Największym konsumentem pszenicy jest Unia Europejska (18% światowej konsumpcji), drugie miejsce zajmują Chiny (16% światowej konsumpcji). Trzecie miejsce przypada Indiom, których konsumpcja krajowa stanowiła w 2017 r. 13% światowej konsumpcji.

W strukturze geograficznej zużycia pszenicy zmniejszył się udział krajów rozwiniętych, czyli krajów Unii Europejskiej, Azji Wschodniej i Ameryki Północnej. Zwiększył się natomiast udział krajów rozwijających się z Azji Południowej, Afryki i Azji Północno-Wschodniej (Szajner i in., 2015).

Przedmiotem obrotów handlowych w badanym okresie było blisko 160 mln ton pszenicy, co stanowi 22% wielkości jej zbiorów. Wolumen handlu na rynku pszenicy również wykazuje tendencję wzrostową. Wzrost zapotrzebowania na pszenicę w różnych regionach świata, szczególnie w państwach azjatyckich, wpłynął na wzrost światowego obrotu pszenicą. Na rysunku 4.8 przedstawiono zmianę średniego poziomu eksportu w latach 2000–2017.



Rysunek 4.8. Zmiana średniego eksportu w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

Nadwyżki eksportowe pszenicy skoncentrowane są w kilku regionach świata. Do głównych eksporterów pszenicy należą: Rosja, Stany Zjednoczone, Unia Europejska, Kanada, Ukraina, Australia. Ich rola w poprzedniej i obecnej dekadzie znacznie się zwiększyła. Pochodzi z nich 90% podaży eksportowej. W tabeli 4.3 przedstawiono 10 największych eksporterów pszenicy w 2017 r.

Istotną kwestią na światowym rynku pszenicy jest efekt programów pomocy żywnościowej. Większość z tych programów to darowizny od największych światowych eksporterów pszenicy do krajów rozwijających się, które mają na celu zwalczanie głodu. Należy zauważyć, że pszenica nie ma prostego geograficznego wzorca przepływów handlowych, ponieważ wiele krajów jest zarówno eksporterami, jak i importerami pszenicy. Z czasem zmieniają się również wzorce handlu, ponieważ zmienia się wielkość produkcji, importu i eksportu pszenicy w różnych krajach, a ceny na świecie napędzają wstrząsy wtórne na rynku (Szajner i in., 2015).

W okresie 2000–2017 odnotowano również wzrost popytu na pszenicę. Największe wzrosty odnotowano w krajach rozwijających się Afryki, Azji oraz

Tabela 4.3. Eksport pszenicy w 10 największych krajach importerskich

Kraj	Eksport (1000 Mt)	Udział w światowym eksporcie (%)
Pakistan	1 200	0,01
Turcja	6 200	0,03
Kazachstan	8 500	0,05
Argentyna	12 000	0,07
Australia	15 000	0,08
Ukraina	17 500	0,10
Kanada	22 800	0,13
Kraje Unii Europejskiej	23 300	0,13
Stany Zjednoczone	24 524	0,14
Rosja	41 000	0,23

Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

w Ameryce Północnej. Zjawisko to wyjaśnia rosnącą rolę tych regionów w strukturze światowego popytu importowego. Warto podkreślić, że struktura ta jest bardziej rozproszona niż struktura popytu eksportowego. Oznacza to, że udziały największych importerów w rynku są znacznie mniejsze niż największych eksporterów (Szajner i in., 2015). W tabeli 4.4 zestawiono 10 największych eksporterów i importerów pszenicy oraz ich udziały w rynku.

Tabela 4.4. Zestawienie udziałów w rynku największych eksporterów i importerów pszenicy

Kraj	Udział w światowym importcie (%)	Kraj	Udział w światowym eksporcie (%)
Egipt	0,07	Pakistan	0,01
Indonezja	0,06	Turcja	0,03
Algieria	0,05	Kazachstan	0,05
Brazylia	0,04	Argentyna	0,07
Bangladesz	0,04	Australia	0,08
Turcja	0,04	Ukraina	0,10
Japonia	0,03	Kanada	0,13
Filipiny	0,03	Kraje Unii Europejskiej	0,13
Kraje Unii Europejskiej	0,03	Stany Zjednoczone	0,14
Meksyk	0,03	Rosja	0,23

Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.



*1 bu (buszel) = 27,22 kg

Rysunek 4.9. Cena pszenicy w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z U.S. Department of Agriculture.

Na rysunku 4.9 przedstawiono dzienne ceny pszenicy w latach 2000–2017. Ceny pszenicy determinowane są wieloma czynnikami. Oprócz stopniowego i konsekwentnego zwiększania się globalnego popytu na pszenicę do czynników wpływających na ceny pszenicy na świecie zalicza się między innymi klimat, rozmiar plonów, import, a także ceny ropy. Zauważalny wzrost popytu na pszenicę, podobnie jak w przypadku innych produktów żywnościowych, wynika ze wzrostu zarówno populacji światowej, jak i zamożności krajów rozwijających się (Enghiad i in., 2017). Wiele z nich płaci subsydia mające na celu ustabilizowanie lub nawet obniżenie ceny żywności, tak aby konsumenci mogli jak najlepiej zaspokajać swoje potrzeby żywieniowe. Jednakże wzrost konsumpcji pszenicy, wynikający ze wzrostu liczby ludności i rosnących dochodów w gospodarstwach krajów rozwijających się, powoduje presję na wzrost cen pszenicy (Enghiad i in., 2017). W szczególności wzrost liczebności klasy średniej w gęsto zaludnionych krajach rozwijających się, zwłaszcza w krajach Azji, w połączeniu ze zmianami stylu życia i wzorców konsumpcji wynikającymi ze wzrostu zamożności powoduje wzrost popytu na żywność, w tym właśnie zboża. Zmiany klimatyczne mogą wpływać na produkcję żywności na wiele sposobów, ponieważ klimat głównych obszarów produkcyjnych może zmieniać się w zależności od długości sezonu wegetacyjnego, a także zmian średnich wartości temperatury i opadów (Enghiad i in., 2017).

Wahania i schematy w cenach pszenicy zmieniały się w ostatnich latach w porównaniu do wcześniejszych dziesięcioleci głównie ze względu na wskazane wczes-

śniej czynniki, czyli wzrost populacji, wzrost zamożności, zmiany klimatu (Enghiad i in., 2017). Wraz ze wzrostem cen pszenicy na świecie droższy stał się import, a następnie wzrosły również ceny żywności wytwarzanej w dużej mierze z pszenicy jako surowca. W wielu krajach rozwijających się żywność na bazie pszenicy stanowi znaczącą część diety domowej, co oznacza, że wzrost cen pszenicy będzie miał zauważalny wpływ na koszty żywności. Kilka lat suszy (w Europie w 2006 r., Ameryce Północnej w latach 2006–2007 oraz Australii w latach 2006–2008) doprowadziło do spadku zapasów pszenicy do krytycznego minimum. To w połączeniu z gwałtownym wzrostem zapotrzebowania na biopaliwa przyczyniło się do rekordowych cen zbóż (McCalla, 2009; Enghiad i in., 2017), które sprawiają, że niedobór zapasów buforowych stanowi problem dla tych, którzy dążą do stabilizacji światowych cen żywności.

Globalne wydarzenia z ostatnich trzech dekad, choć nie były bezpośrednio związane z rynkiem pszenicy, mogły zniekształcić rynki. We wczesnych latach 80. XX w. recesja gospodarcza w Stanach Zjednoczonych, poziom bezrobocia w innych krajach, szoki cenowe energii i odpowiednia polityka monetarna w globalnej gospodarce mogły być możliwymi przyczynami zmian cen pszenicy, które nie są uwzględniane przez bezpośrednie czynniki omówione wcześniej (Moy, 1985; Enghiad i in., 2017). Innym ważnym zakłóceniem rynku na początku lat 80. XX w. było amerykańskie embargo eksportowe na handel zbożem i technologią ze Związkiem Socjalistycznych Republik Radzieckich w odpowiedzi na inwazję w Afganistanie (Hennemuth, 2012). Chociaż restrykcje zostały zniesione kilka lat później, zmieniły się schematy handlu, gdy obowiązywało embargo, a Związek Radziecki borykał się z brakami importowymi i musiał znaleźć alternatywnych dostawców pszenicy. Dodatkowe interwencje na rynku krajowym również miały miejsce w Stanach Zjednoczonych ze względu na odpowiednie spadki cen pszenicy na świecie, ale ich długoterminowe konsekwencje dla handlu nie są jasne (Enghiad i in., 2017).

Ropa naftowa to kolejny czynnik wpływający na ceny surowców rolnych (Sadorsky, 2014; Enghiad i in., 2017). Rynek ropy naftowej wpływa zarówno bezpośrednio na ceny pszenicy poprzez nakłady produkcyjne, jak i pośrednio poprzez popyt na biopaliwa i związane z tym efekty substytucyjne. Na ceny nawozów, maszyn rolniczych i transportu wpływają ceny ropy naftowej, co wpływa na koszty produkcji pszenicy. Baffes i Haniotis (2016) przypisują bezpośredni wpływ cen energii na towary żywnościowe (większy niż wpływ produkcji biopaliw) i uważają, że aspekty zmian cen energii wywarły największy wpływ na ceny towarów, w tym pszenicy, w ciągu ostatnich kilku dekad. Niemniej jednak biopaliwa mogą również wpływać na ceny pszenicy. Przy wysokich cenach ropy naftowej rośnie popyt na biopaliwa. Powoduje to, że środki produkcji rolnej, takie jak grunty, są przeznaczane na sadze-

nie roślin energetycznych (np. kukurydza) zamiast pszenicy. Takie konkurencyjne użytkowanie ziemi zmniejsza rozmiar produkcji pszenicy, co może wyjaśniać pewną zmienność i presję na wzrost cen pszenicy (Chen i in., 2010). Oprócz dynamiki rynku również polityka energetyczna znajduje się w stanie ciągłego rozwoju. Na przykład Unia Europejska, Stany Zjednoczone i inne kraje z dużymi sektorami rolnictwa zachęcają do stosowania biopaliw poprzez wprowadzanie dopłat do produkcji i kwot na odnawialne paliwo, co jeszcze bardziej zwiększa popyt na biopaliwa (Enghiad i in., 2017). Bardziej szczegółowo relacja cen pszenicy i ropy naftowej została omówiona w kolejnym rozdziale.

Jak już wspomniano, wskaźniki wykorzystania zasobów mierzą związek między dostępną podażą i popytem poprzez podzielenie końcowej wartości zapasów przez całkowite roczne zużycie (Zeng i in., 2013). Mała wartość wskaźnika zapasów do użycia prowadzi do wyższej ceny rynkowej, ponieważ małe zapasy odzwierciedlają niedobór. Chociaż ten wskaźnik jest skorelowany z cenami pszenicy, to istnieją sprzeczne dowody dotyczące jego znaczenia dla kosztów uprawy. Daugherty i Kelly (2014) stwierdzili, że wskaźnik wykorzystania zapasów jest słabym czynnikiem, zaś Baffes i Haniotis (2016) uznali uprawę pszenicy za drugą najbardziej energetycznie kosztowną pod względem wyjaśniania długoterminowych zmian kosztów upraw.

Jeszcze jeden czynnik mogący mieć znaczący wpływ na cenę związany jest z tzw. finansjeryzacją pszenicy. Finansjeryzacja rozumiana jest w ten sposób, że oprócz „klasycznej” roli, jaką odgrywa pszenica na światowym rynku towarowym, w ostatnich latach stała się ona również aktywem, podobnie jak ropa naftowa czy złoto, dla funduszy i banków inwestycyjnych. Jej cena stanowi bazę dla finansowych transakcji pochodnych (Rapsomanikis, 2009). Oznacza to, że pszenica pojawiła się również na rynkach finansowych i zjawiska kierujące tymi rynkami będą wpływały na cenę pszenicy.

5. Związek między cenami ropy naftowej i złota

„Żaden rynek nie działa w izolacji. (...) Analiza dolara (walut), indeksu CRB¹ (towarów), obligacji skarbowych oraz akcji zawsze musi być połączona” (Murphy, 1998).

Obligacje są źródłem informacji o poziomie stóp procentowych. Analiza zmian cen towarów pozwala określić kierunek inflacji, której poziom z kolei zależy od kursu walutowego. Analiza cen akcji na rynku zagranicznym dostarcza wielu informacji przydatnych w ocenie sytuacji na rynku globalnym. Takich zależności między poszczególnymi sektorami rynku globalnego można wymienić bardzo wiele. W celu lepszego zrozumienia relacji między nimi należy dokonać podziału rynku na cztery podstawowe części: rynek akcji, rynek obligacji oraz rynek towarowy i walutowy (Murphy, 1998).

Murphy (1998) zaproponował cztery podstawowe zależności, jakie można zaobserwować na rynku finansowym:

- ceny akcji i obligacji poruszają się w tym samym kierunku;
- istnieje ujemna relacja między cenami na rynku towarów a cenami akcji;
- kurs dolara amerykańskiego biegnie zazwyczaj w przeciwnym kierunku do cen towarów;
- rynki obligacji i rynki towarów są ujemnie skorelowane.

Podstawą wyodrębnionych zależności jest między innymi teoria cykli koniunkturalnych. Cykl koniunkturalny jest wahadłowym ruchem całkowitego produktu narodowego, dochodu i zatrudnienia, zwykle trwającym 2–10 lat, któremu towarzyszy szeroko zakrojony wzrost lub spadek poziomu aktywności gospodarczej w większości sektorów gospodarczych (Samuelson i Nordhaus, 2004). Wyjaśnia on chronologię wydarzeń w trzech najważniejszych sektorach rynku: akcji, obligacji i towarów. Cykliczne zmiany łącznego popytu i podaży mają istotny wpływ na kształtowanie się cen na rynkach finansowych (Schiller, 1989). Na przykład rozwój aktywności gospodarczej przyczynia się na ogół do wzrostu cen akcji, z kolei przy słabej aktywności ceny obligacji mają z reguły tendencję wzrostową.

W zależności od faz cyklu preferowane są inne rodzaje aktywów. Pring (1998) podzielił cykl koniunkturalny na sześć etapów (tab. 5.1).

Poszczególne etapy cyklu koniunkturalnego odznaczają się innym poziomem stóp procentowych. Współzależność cen w poszczególnych segmentach rynku fi-

¹Commodity Research Bureau Index obejmuje ceny surowców przemysłowych, metali, nośników energii, zbóż, mięsa, kakao, kawy i cukru.

Tabela 5.1. Etapy cyklu koniunkturalnego według Pringa

Etap	Ceny rynkowe obligacji	Ceny rynkowe akcji	Ceny rynkowe towarów
1	↑	↓	↓
2	↑	↑	↓
3	↑	↑	↑
4	↓	↑	↑
5	↓	↓	↑
6	↓	↓	↓

Objaśnienie: ↑ wzrost cen, ↓ spadek cen

Źródło: opracowanie własne na podstawie (Murphy, 1998, s. 251).

nansowego jest w pewnym stopniu związana właśnie ze zmiennością stóp procentowych. Pierwszy etap przedstawiony w tabeli 5.1 to spowolnienie wzrostu gospodarczego. Zaczynają spadać stopy procentowe, co wskazuje na to, iż podstawową lokatę powinny stanowić obligacje albo akcje spółek zależnych od stóp procentowych. W drugim etapie cyklu koniunkturalnego warto inwestować w akcje. Kolejny etap jest hossą na rynku towarów. Gospodarka odzyskuje wówczas siłę, wzrasta konsumpcyjny i inwestycyjny popyt, co prowadzi do wzrostu ogólnego poziomu cen. W tej sytuacji należy inwestować w aktywa takie jak towary, które zabezpieczają przed skutkami inflacji. Wzrost cen towarów przyczynia się z kolei do wzrostu stóp procentowych, a tym samym powoduje spadek cen obligacji (etap 4). Ów spadek cen obligacji jest najczęściej sygnałem końca ekspansji gospodarczej. W kolejnym etapie następuje spadek cen akcji, opłacalne pozostaje więc jedynie inwestowanie w towary. Ostatni etap to bessy na wszystkich rynkach.

Z powyższego opisu wynika, że ceny surowców powinny poruszać się z reguły w tym samym kierunku. Towary stanowią jednak bardzo zróżnicowaną grupę aktywów, których ceny są często ujemnie skorelowane (Sierakowska, 2016). Kierunek relacji między towarami zależy z pewnością od grupy towarów, które są przedmiotem analizy. Ropa naftowa i złoto należą do najważniejszych surowców na świecie. Związek między tymi kluczowymi towarami reprezentującymi dwie różne grupy, czyli grupę surowców energetycznych oraz grupę towarów szlachetnych, był przedmiotem wielu badań.

W literaturze przedmiotu dominuje przekonanie, że ceny ropy naftowej i złota są ze sobą dodatnio powiązane (Mo i in., 2018). Badacze tłumaczą to między innymi istnieniem tzw. kanału inflacyjnego (Narayan i in., 2010). Wzrastające ceny ropy naftowej przyczyniają się do wzrostu kosztów produkcji i w rezultacie prowadzą do wysokiej inflacji. Złoto jest surowcem, który uważany jest za dobrą lokatę kapitału w czasach wysokiego średniego poziomu cen. Wzrost popytu na złoto przyczynia

się wówczas do wzrostu cen tego surowca. W warunkach wysokiej inflacji zwyżka cen ropy naftowej prowadzi zatem do wzrostu cen złota (Bampinas i Panagiotidis, 2015a).

Reboredo (2013) również potwierdził, że ceny ropy naftowej i złota są ze sobą dodatnio powiązane. Jego zdaniem wzrost cen ropy naftowej wpływa negatywnie na rozwój gospodarczy państw, prowadzi do spadku cen wielu aktywów finansowych, motywując tym samym inwestorów do inwestycji środków na bezpiecznych rynkach takich jak rynek złota. Według Laidiego (2012) około 11% popytu na złoto zgłaszane jest przez spekulantów i inwestorów, którzy traktują ten surowiec szlachetny jako lokatę kapitału. Laidi pokazał, że na początku 2008 r., kiedy to w wyniku kryzysu finansowego znacznie wzrosły niepokoje na rynku finansowym, inwestorzy stali się za pośrednictwem otwartych funduszy inwestycyjnych notowanych na giełdzie właścicielami 870 ton złota, czyli ponad 7% wydobycia tego kruszcu. Więcej złota posiadały wówczas jedynie Stany Zjednoczone, Niemcy, Międzynarodowy Funduszu Walutowy, Francja, Włochy i Szwajcaria.

Melvin i Sultan (1990) uważają natomiast, że silna dodatnia relacja między cenami ropy naftowej i złota wywołana jest tzw. kanałem przychodów z eksportu. W sytuacji wzrostu cen ropy naftowej państwa bogate w złoża tego cennego surowca energetycznego, będące zarazem jego dużym eksporterem, dywersyfikują swoje portfele, kupując złoto. Ponownie wzrost popytu na złoto przyczynia się wówczas do wzrostu jego cen i w rezultacie jest źródłem dodatniej zależności między cenami obu surowców. Vilayil i inni (2015) byli natomiast zdania, że dodatnia zależność między cenami ropy naftowej i złota wywołana jest tzw. kanałem importowym. Duża część importerów ropy naftowej płaci bowiem za ten surowiec energetyczny w zlocie. Wyższy popyt na ropę naftową to zarazem wyższy popyt na złoto.

Duży wpływ na kształtowanie się cen surowców wywiera wartość dolara amerykańskiego. Wielu badaczy jest zdania, że to powiązanie ceny surowców z wartością waluty amerykańskiej jest źródłem silnej i dodatniej zależności między surowcami (Wang i Chueh, 2013). Dolar amerykański postrzegany jest bowiem jako waluta kluczowa z punktu widzenia rynku towarów. Notowania towarów są na ogół wyrażane właśnie w dolarach amerykańskich. Zdaniem Sierakowskiej (2016) istnieje odwrotna zależność między indeksem towarów CRB a indeksem dolara amerykańskiego (U.S. Dollar Index). Podkreśla ona jednak, że występują krótkoterminowe okresy, kiedy to ceny surowców i wartość dolara amerykańskiego poruszają się w tym samym kierunku. W literaturze przedmiotu dominuje przekonanie, że zarówno ceny ropy naftowej, jak i ceny złota są na ogół ujemnie powiązane z wartością dolara amerykańskiego. Przykładowo w czasie spowolnienia wzrostu gospodarczego w Stanach Zjednoczonych Rezerwa Federalna podejmuje zazwyczaj decyzję o obniżce stóp

procentowych. Ma to na celu ożywienie gospodarki między innymi poprzez wzrost inwestycji. Niższy koszt pieniądza przyczynia się w krótkim okresie do spadku wartości waluty krajowej, czyli dochodzi do deprecjacji dolara amerykańskiego. Zmiana wartości tej waluty determinuje kształtowanie się cen na rynku surowców (Wang i Chueh, 2013). Osłabienie waluty amerykańskiej wpływa na decyzje producentów ropy naftowej, którzy w trosce o swoje dochody decydują się często na ograniczenie podaży tego surowca, a tym samym na wzrost jego ceny (Yousefi i Wirjanto, 2003). Dodatkowo tańszy dolar amerykański jest źródłem wzrostu popytu na ropę naftową w innych krajach. Deprecjacja waluty amerykańskiej oznacza bowiem niższą cenę ropy naftowej wyrażoną w walucie krajowej. Niższa cena ropy naftowej denominowanej w walucie krajowej powoduje wzrost popytu na ten surowiec energetyczny i w rezultacie prowadzi do wzrostu jego ceny (De Schryder i Peersman, 2012).

Deprecjacja dolara amerykańskiego wywiera duży wpływ także na ceny złota. Tully i Lucey (2007) wykazali (na podstawie modeli klasy GARCH), że zmienność kursu dolara amerykańskiego jest jedyną zmienną makroekonomiczną, która w sposób istotny wpływa na ceny złota. Ich zdaniem istnieje silna, ujemna i istotna statystycznie zależność między cenami spot i futures złota oraz efektywnym kursem dolara amerykańskiego. Deprecjacji waluty amerykańskiej towarzyszy zatem wzrost cen złota. Laidi (2012) wykazał, że między styczniem 1999 a majem 2008 r. współczynnik korelacji między cenami złota i wartością dolara amerykańskiego wynosił $-0,84$. Ta odwrotna i silna relacja nie jest jednak regułą. Można wyróżnić kilka krótkoterminowych okresów, kiedy to zależność między cenami złota i wartością dolara amerykańskiego jest dodatnia. Przykładowo między kwietniem i grudniem 2005 r. aprecjacji amerykańskiej waluty towarzyszył wzrost cen złota. Zazwyczaj jednak zależność ta jest ujemna i istotna statystycznie, dlatego też Ciner i inni (2013) zauważyli, że złoto można wykorzystywać w celu efektywnego zabezpieczenia się przed zmiennością kursu dolara amerykańskiego.

Z tej współzależności między cenami ropy naftowej i złota z wartością dolara amerykańskiego wynika również silna i dodatnia zależność między cenami badanych towarów (Beckmann i Czudaj, 2013; Bampinas i Panagiotidis, 2015b). Warto podkreślić, że powyższe zależności powinny działać stopniowo, czyli deprecjacja/precjacja waluty amerykańskiej powinna dopiero po pewnym czasie wpłynąć na zmianę cen towarów (Sierakowska, 2016). Okazuje się jednak, że w wyniku dużej aktywności spekulantów na rynkach surowców zmiana wartości dolara amerykańskiego wywołuje niemal natychmiastową reakcję cen na rynku towarów. Jeśli dolar amerykański traci na wartości, to wówczas uczestnicy rynku finansowego oczekują ruchu wzrostowego cen surowców i zaczynają zawierać długie pozycje na tych rynkach. W efekcie wzrost cen surowców przebiega niemal równoległe do zmiany

wartości waluty amerykańskiej i nie jest on wynikiem przemian w gospodarce światowej, tylko wynika ze wzrostu długich transakcji zawieranych przez uczestników rynku finansowego, którzy chcą zarobić na zwwyżce cen surowców (Sierakowska, 2016).

Zhang i Wei (2010) wykazali dodatnią, istotną statystycznie zależność między cenami złota i ropy naftowej. Analizowali oni dane z okresu od stycznia 2000 do marca 2008 r. Obliczony przez nich współczynnik korelacji wynosił 0,93, co świadczy o bardzo silnej zależności między badanymi zmiennymi. Podobne wyniki uzyskali Shafiee i Topal (2010). Na podstawie próby z okresu od stycznia 1968 do grudnia 2008 r. wyliczyli oni współczynnik korelacji między cenami złotą i ropy naftowej na poziomie 0,85. Dodatkowo podkreślili oni, że ceny na obu badanych rynkach charakteryzowały się w analizowanym okresie dużym wzrostem. Nominalne ceny ropy naftowej wzrosły około 23 razy, a nominalne ceny złota około 16 razy. Dodatnią zależność między ceną ropy naftowej i złotą wykazali także Narayan i inni (2010). Ich zdaniem rynki te są skointegrowane. Wzrost cen ropy naftowej to także czas wzrostu ogólnego poziomu cen, czyli wysokiej inflacji. Inwestorzy wykorzystują natomiast złoto w celu zabezpieczenia się przed wysoką inflacją. Narayan i inni (2010) są zdania, że ceny ropy naftowej mogą być zatem wykorzystywane jako ważna zmienna objaśniająca w modelach prognozujących przyszłe ceny złota. Shahbaz i inni (2017) również wykazali, że ceny ropy naftowej mogą służyć do prognozy cen złota. Pokazali oni jednak, że w warunkach ekstremalnych odznaczających się bardzo niskimi albo bardzo wysokimi cenami złotego kruszcu wpływ cen ropy naftowej na cenę złota jest znacznie mniejszy. El Hedi Arouri i inni (2015) podkreślają dodatkowo, że o ile kierunek zależności między cenami ropy naftowej i złota jest na ogół dodatni, o tyle zmienność cen tych surowców różni się znacznie przede wszystkim w czasie niepokoju, kryzysu, spadków cen akcji i obligacji. Yaya i inni (2016) wykazali, że ceny na rynku złota charakteryzują się mniejszą zmiennością niż ceny na rynku ropy naftowej. Swoje badania przeprowadzili dla danych z okresu od 1986 do 2015 r. Dutta (2017) zauważył, że w warunkach dużej zmienności cen na rynku ropy naftowej zwiększa się liczba inwestycji na rynku złota, co w konsekwencji prowadzi do wzrostu cen tego szlachetnego metalu. Z powyższego wynika, że to nie tylko poziom, ale także zmienność cen ropy naftowej wpływa na sytuację na rynku złota. W przeciwieństwie do Dutty (2017) Liu i inni (2013) nie znaleźli żadnych dowodów potwierdzających występowanie istotnej relacji między zmiennościami cen ropy naftowej i złota.

Zhang i Wei (2010) pokazali, że zmiany cen ropy naftowej są przyczyną zmian cen złota w sensie Grangera. Ceny złota natomiast nie są przyczyną w sensie Grangera zmian cen ropy naftowej. Zhang i Wei przeprowadzili swoje badania dla danych

miesięcznych pochodzących z okresu od 2000 do 2008 r. Bampinas i Panagiotidis (2015b) badali przyczynowość zmian między cenami ropy naftowej i złota za pomocą nieliniowych testów przyczynowości. Ich próba badawcza obejmowała lata 2003–2012. Wykazali oni, podobnie jak Zhang i Wei (2010), że ceny ropy naftowej były przyczyną w sensie Grangera zmian cen ropy naftowej w całym badanym okresie. Pokazali natomiast, że ceny złota były przyczyną zmian cen ropy naftowej, ale jedynie w czasie kryzysu finansowego lat 2007–2008. Wyniki te są zgodne z tym, co pokazali także Chen i inni (2016), którzy podkreślili, że wzrost ryzyka politycznego wywołany kryzysem finansowym ma swoje odbicie także w cenach ropy naftowej i jest źródłem asymetryczności w relacji między cenami ropy naftowej i złota. Kumar (2017) pokazał, że zmiany cen ropy naftowej są przyczyną w sensie Grangera zmian cen złota zarówno w długim, jak i krótkim okresie. Przeprowadził on swoje badania na podstawie miesięcznych danych obejmujących okres od kwietnia 1990 do kwietnia 2016 r. Zdaniem Kumara ceny złota są bardziej wrażliwe na spadek cen ropy naftowej, a nie na ich wzrost. Dodatkowo podkreślił on, że relacja między cenami badanych surowców jest nieliniowa i asymetryczna. Do podobnych wniosków doszli Vilayil i inni (2015) oraz Sephton i Mann (2018). Na podstawie testu nieliniowej kointegracji Sephton i Mann pokazali, że istnieje długookresowa zależność między cenami ropy naftowej i złota. Ich zdaniem ta relacja narażona jest na oddziaływanie egzogenicznych szoków, których wpływ na zależność między badanymi surowcami jest asymetryczny i zależy od kierunku zaburzeń. Ponadto obecność kointegracji nieliniowej wskazuje na występowanie zależności przyczynowej przynajmniej w jednym kierunku, co umożliwia budowanie prognoz na podstawie modeli wektorowej korekty błędem.

Kanijlal i Ghosh (2017) zbadali zależność między cenami ropy naftowej i złota przy wykorzystaniu dwureżimowego modelu wektorowej korekty błędem. Ich zdaniem relacja między analizowanymi surowcami jest nieliniowa i asymetryczna. Można wyróżnić w niej dwa reżimy. Pierwszy z nich to reżim, w którym ceny ropy naftowej wpływają dodatnio na ceny złota. Zależność ta wynika głównie z tzw. kanału inflacyjnego. W czasie dużego wzrostu cen ropy naftowej oraz innych towarów wzrasta także popyt na złoto, które postrzegane jest za dobrą lokatą kapitału w trakcie wysokiej inflacji. W drugim reżimie zależność między ceną ropy naftowej i złota jest natomiast ujemna. Kanijlal i Ghosh (2017) jako jedni z pierwszych badaczy zwrócili uwagę na to, że relacja między badanymi surowcami nie zawsze jest dodatnia i jej kierunek zależy w dużej mierze od sytuacji na globalnych rynkach finansowych. Khalfaoui (2018) również zauważył, że zależność między cenami ropy naftowej i złota nie zawsze jest dodatnia. Podzielił on próbę badawczą na trzy podokresy: czas poprzedzający kryzys finansowy, kryzys i czas po kryzysie. Jego dane obejmowały

lata 2007–2016. Na podstawie wielowymiarowych dynamicznych modeli warunkowej korelacji – DCC-MGARCH (Engle, 2002) pokazał on, że związek między cenami ropy naftowej i złota jest na ogół dodatni, jednak w czasie kryzysu finansowego ceny badanych surowców „poruszały się” na ogół w przeciwnym kierunku.

Opublikowane wyniki badań nie dają jednoznacznej odpowiedzi na temat istotności statystycznej oraz kierunku zależności między cenami ropy naftowej i złota. W literaturze przedmiotu dominuje przekonanie, że relacja między badanymi surowcami jest dodatnia. Najnowsze publikacje, w których zastosowano zaawansowane modele ekonometryczne, wskazują jednak na nieliniowość i asymetryczność badanej zależności. Ich autorzy podkreślają, że korelacja między cenami ropy naftowej i złota nie jest zawsze dodatnia i jej kierunek zależy między innymi od sytuacji na rynkach finansowych.

6. Związek między cenami ropy naftowej i pszenicy

W XXI w. zaobserwowano znaczący wzrost cen pszenicy. Co więcej, światowa gospodarka była świadkiem nieomal jednoczesnego wzrostu cen ropy naftowej i cen towarów rolnych. Zjawisko to wzmogło zainteresowanie badaczy ewentualnym związkiem między cenami ropy naftowej i cenami żywności, w tym cenami pszenicy. Niejako naturalne bowiem jest rozumowanie wskazujące, iż to właśnie ceny ropy naftowej determinują światowe ceny pszenicy oraz pozostałych surowców rolnych (Fowowe, 2016). W literaturze przedmiotu nie ma jednak jednoznacznej odpowiedzi na pytanie, czy rzeczywiście zmiany światowych cen pszenicy warunkują ceny ropy naftowej. Hamulczuk i Klimkowski (2011) podkreślają, że jest to problem niejednoznaczny. Niektórzy autorzy wskazują na istnienie tej relacji, inni zaś ją stanowiąc wykluczają. Inni natomiast uważają, że ceny surowców rolnych, a co za tym idzie ceny pszenicy, za słabo lub negatywnie są skorelowane z cenami ropy naftowej (Hertel i Beckman, 2011). Ponadto dopatrywano się raczej związków między cenami ropy i kosztową stroną produkcji rolnej (Hamulczuk i Klimkowski, 2011).

Co więcej, w literaturze przedmiotu nie ma nawet jednolitego trendu w podejściu do badania relacji między cenami ropy naftowej i surowców rolnych. Wykorzystywane są różne techniki ekonometryczne, dane pochodzą z różnych okresów, a łączny okres badania w niektórych opracowaniach traktowany jest jako całość, w innych zaś analizy prowadzone są na podstawie danych z wyodrębnionych podokresów (dwa lub więcej). Podział na wspomniane podokresy uzasadniany jest w literaturze przedmiotu kryzysem żywnościowym lat 2006–2008. Ponadto związek między światowymi cenami pszenicy i ropy naftowej najczęściej badany jest łącznie z cenami innych surowców rolnych, zwłaszcza kukurydzy i soi.

Jednym z aspektów pojawiających się w kontekście badania relacji między cenami ropy naftowej i pszenicy jest rozwój produkcji biopaliw. Przypuszcza się, że rosnące ceny ropy naftowej, ograniczone dostawy paliw kopalnych i wzrost obaw o globalne ocieplenie spowodowały wzrost zapotrzebowanie na odnawialne źródła energii (Srinivasan, 2009) oraz na zwrócenie szczególnej uwagi właśnie na biopaliwa. Uważa się, że dominującym czynnikiem kształtującym ceny produktów rolnych (w tym pszenicy) są rynki energii, ponieważ produkty rolne stały się konkurencyjnym źródłem energii i wysokie ceny ropy naftowej są przyczyną koncentrowania się na biopaliwach (Mitchell, 2008; Abbott i in. 2009). Ponadto w XXI w. wzrosły ceny surowców energetycznych, a to doprowadziło do wzrostu cen produktów otrzymanych z surowców takich jak nawozy i chemikalia (tzw. produkty ropopochodne) oraz produktów, które są produkowane z użyciem dużych ilości energii. Doprowa-

dziło to zatem do wzrostu kosztów produkcji rolnej i do wyższych cen towarów rolnych (Mitchell, 2008; Gohin i Chantret, 2010). Ponadto wspomniany wcześniej szybki wzrost produkcji biopaliw doprowadził zarówno do wzrostu popytu na towary rolne, jak i konkurencji w zdobywaniu ziemi pod uprawy tych roślin, które są używane do produkcji biopaliw jako alternatywnych źródeł energii. Wzrost produkcji biopaliw, w odpowiedzi na wzrost cen surowców energetycznych, wywarł presję na ceny towarów rolnych, przyczyniając się w ten sposób do ich szybkiego wzrostu. Zidentyfikowano dwa możliwe mechanizmy transmisji między cenami ropy naftowej i surowców rolnych: bezpośredni i pośredni. Zgodnie z mechanizmem transmisji bezpośredniej wyższe ceny ropy naftowej prowadzą do wzrostu kosztów nakładów takich jak nakłady na nawozy i chemikalia, a także wzrostu kosztów transportu. Oprócz tego identyfikuje się również inny kanał bezpośredni, mianowicie wysokie ceny ropy naftowej prowadzą do większego popytu na biopaliwa i w konsekwencji doprowadza to do większego zapotrzebowania na pszenicę, kukurydzę i soję, czyli główne surowce do produkcji biopaliw (Nazlioglu i Soytaş, 2011, 2012). Kanał pośredni to powiązanie ceny ropy naftowej i ceny towarów rolnych poprzez kurs wymiany walut (Abbott i in., 2009). Niektórzy z autorów uważają, że produkcja biopaliw mogłaby chronić konsumentów przed negatywnymi skutkami rosnących światowych cen ropy naftowej, ale mogłaby równie dobrze spowodować wzrost cen surowców rolnych (Wei i i Chen, 2016). Wynika to z tego, iż podstawowe surowce rolne wykorzystywane obecnie do produkcji biopaliw są też bezpośrednio lub pośrednio wykorzystywane do produkcji żywności. Tymi surowcami są soja, kukurydza i właśnie pszenica. Przykładowo w Stanach Zjednoczonych produkcja bioetanolu opiera się głównie na kukurydzy, a produkcja biodiesla w 82% oparta jest na oleju sojowym. W Unii Europejskiej pszenica jest głównym surowcem do produkcji bioetanolu. W 2008 r. całkowita europejska produkcja bioetanolu była oparta na pszenicy w 70% i tylko 10% na kukurydzy. Produkcja biodiesla w Unii Europejskiej oparta jest w 18% na oleju sojowym (Wei i Chen, 2016).

W literaturze przedmiotu można wyodrębnić pewne grupy badań dotyczących związków między cenami ropy naftowej, pszenicy i innych surowców rolnych. Po pierwsze wiele badań koncentruje się wokół tzw. hipotezy neutralności zakładającej brak związków między cenami ropy naftowej i surowców rolnych, w tym cenami pszenicy. Kolejna grupa badań to te, w których, aby wyodrębnić relacje między badanymi zjawiskami, okres próby podzielono na dwa podokresy (przed kryzysem finansowym i po nim). Badania te zasadniczo stwierdzają neutralność między cenami ropy naftowej i towarów rolnych (również pszenicy) w pierwszym okresie, aby następnie znaleźć argument, że ceny ropy naftowej napędzają ceny towarów rolnych w drugim okresie, który zasadniczo odpowiada okresowi po światowym kryzysie finansowy.

Badania według hipotezy neutralności prowadzili między innymi: Fowowe (2010), Gilbert (2010), Zhang i inni (2010), Nazlioglu i Soytaş (2011), Reboredo (2012).

Fowowe (2010) wskazuje na brak cenowej transmisji między cenami ropy naftowej i surowców rolnych. Badania swoje prowadził z wykorzystaniem tygodniowych cen ropy naftowej i surowców rolnych w latach 2001–2014. W analizie posłużył się modelami korekty błędem (ECM) oraz analizą nieliniowej przyczynowości. Gilbert (2010) wskazuje między innymi kursy walut jako czynniki wzrostu cen produktów rolnych, odrzuca natomiast wpływ cen ropy naftowej. W prowadzonych badaniach wykorzystał kwartalne dane z okresu od 1971 do 2008 r. Analizę przeprowadził z zastosowaniem badania przyczynowości Grangera oraz metody najmniejszych kwadratów (MNK), dwustopniowej metody najmniejszych kwadratów i trzostopniowej metody najmniejszych kwadratów.

Nazlioglu i Soytaş (2011) badali związek między światowymi cenami ropy naftowej i surowców rolnych w Turcji. Autorzy wykorzystali dane miesięczne w okresie od stycznia 1994 do marca 2010 r. Badanymi zmiennymi była światowa cena ropy naftowej, kurs liry tureckiej do dolara amerykańskiego oraz ceny pszenicy, kukurydzy, bawełny, soi i słonecznika. W badaniach posłużyli się testem przyczynowości Tody–Yamamoto oraz funkcją odpowiedzi na impuls. Wyniki testu przyczynowości Tody–Yamamoto wskazały na brak związku między cenami ropy naftowej i pszenicy w dłuższym okresie. Związki krótkookresowe zostały zbadane funkcją odpowiedzi na impuls. Uzyskane wyniki nie wykazują statystycznej istotnej zależności między szokiem cen ropy naftowej i cenami pszenicy.

Reboredo (2012) wykorzystał tygodniowe dane z lat 1998–2011 do badania tych niemal jednoczesnych zmian cen ropy naftowej i, między innymi, pszenicy. W analizie posłużył się modelami Copula. Uzyskane wyniki empiryczne wykazały brak istotnej zależności między cenami ropy naftowej i pszenicy. Autor stwierdził, że wyniki potwierdzają hipotezę neutralności, czyli założenie, że ceny ropy naftowej nie mają znaczącego wpływu na ceny towarów rolnych.

Podobnie w badaniach przeprowadzonych przez Zhanga i innych w 2010 r. wykazano brak zależności między cenami ropy naftowej i pszenicy w długim okresie. W swoich badaniach autorzy wykorzystali dane z okresu od 1989 do 2008 r. Analizę zależności między cenami przeprowadzili, wykorzystując modele wektorowej korekty błędem (VECM).

Balcilar i inni (2016) wskazują, iż główną przyczyną wzrostu cen pszenicy i generalnie surowców rolnych są wyższe ceny ropy naftowej. Zauważają oni jednak, że dowody empiryczne tego związku pozostają niejednolite i niejasne oraz w dużej mierze zależne od zastosowanej metody badawczej. Sugerują zatem, aby związek cen ropy naftowej i pszenicy analizować w kontekście różnych metodologii. Balcilar

i inni (2016) również formułują hipotezę neutralności, która zakłada, że w Afryce Południowej ceny towarów rolnych determinowane są krajowymi, lokalnymi czynnikami i nie zależą od światowych cen ropy naftowej. W przytoczonej pracy związku między cenami surowców rolnych i ropy naftowej autorzy badają za pomocą testu przyczynowości Grangera. Wykorzystany materiał badawczy obejmuje okres od 19 kwietnia 2005 do 31 lipca 2014 r. i dotyczy światowych cen ropy naftowej (U.S. Department of Energy) i cen poszczególnych surowców rolnych (w tym pszenicy). Dane dotyczące cen towarów rolnych pochodziły z Johannesburgskiej Giełdy Towarowej. Wyniki liniowego testu przyczynowości wskazują, że ceny ropy naftowej nie wpływają na ceny towarów rolnych (w tym pszenicy). Jednak z powodu pęknięć strukturalnych i nieliniowej zależności między badanymi zmiennymi uznali te wyniki za mylące. Jako alternatywę zaproponowali nieparametryczny test przyczynowości Grangera w kwantylach, opracowany przez Jeonga i innych (2012). Według autorów wykorzystanie tego testu nie tylko umożliwiło przyjrzenie się przyczynowości poprzez średnie szacunki, ale również uwzględniła strukturalne przerwy i nieliniową zależność między zmiennymi. W wyniku przeprowadzonych analiz ustalili, że wpływ zmian cen ropy naftowej na ceny surowców rolnych różni się w zależności od kwantyla warunkowego rozkładu. Analiza pokazuje ponadto, że zależność między cenami ropy naftowej i surowców rolnych zależy od konkretnych faz rynku, a zatem przeczy hipotezie zakładającej, że ceny ropy naftowej nie determinują cen surowców rolnych w Afryce Południowej. Oznacza to, że krajowe ceny surowców rolnych muszą uwzględniać zmiany na światowych rynkach ropy naftowej.

Ma i inni (2015) w swoim artykule również badali relacje między cenami ropy naftowej i pszenicy. W analizie wykorzystali tygodniowe ceny z okresu od czerwca 2002 r. do sierpnia 2013 r. Ewentualne związki badali za pomocą testu przyczynowości Grangera oraz funkcji odpowiedzi na impuls. Uzyskane przez autorów wyniki wskazują na brak wpływu cen ropy naftowej na ceny pszenicy.

Kolejną grupę badań stanowią badania zakładające symetryczną transmisję cen między ropą naftową a pszenicą i pozostałymi surowcami rolnymi.

Chen i inni (2010) prowadzili swoje badania na tygodniowych danych dotyczących cen ropy naftowej, pszenicy, kukurydzy i soi w okresie od 1983 do 2010 r. Na potrzeby analizy wyodrębnili cztery okresy: pierwszy od 1983 do 1985 r.; drugi od 1985 do 2005 r.; trzeci od 2005 do 2008 r. i czwarty od 2008 do 2010 r. Do badania relacji między cenami zastosowali modele autoregresyjne o opóźnieniach rozłożonych (ARDL). Uzyskane przez autorów empiryczne wyniki wskazują, że ceny ropy naftowej i zbóż zasadniczo są silniej powiązane, gdy cena ropy naftowej jest na wyższym poziomie. Drugie ich odkrycie pokazuje, że zmiany cen jednego zboża mają znaczny wpływ na zmiany cen innych zbóż. Zmierzyli ponadto także wartości procentowe zmiany cen zbóż spowodowane zmianą ceny ropy naftowej o 1%,

czyli ocenili wrażliwość cen zbóż na zmianę cen tego surowca energetycznego. W przypadku pszenicy wzrost ceny ropy naftowej o 1% zwiększa cenę pszenicy o 41,30% w pierwszym okresie. Wielkość zmiany procentowej w cenie każdego zboża ze względu na zmianę ceny ropy naftowej o 1% okazała się istotna i pozytywna w pierwszym i trzecim okresie, ponieważ w tych terminach ceny tego surowca energetycznego osiągnęły wyjątkowo duże wartości. Stwierdzono, że zmiana cen ropy naftowej wpływa na ceny towarów rolnych poprzez gwałtowny wzrost cen różnych, energochłonnych czynników produkcji, w tym nawozów i paliwa, a także kosztów transportu.

De Nicola i inni (2016) wykorzystali wielowymiarowy model GARCH (MV-GARCH) do wykazania silnej korelacji między cenami ropy naftowej i pszenicy oraz cenami pozostałych surowców rolnych. Analizę przeprowadzili na podstawie danych z okresu od 1970 do 2013 r.

Nazlioglu i Soytaş (2012) wykorzystując wyniki testów panelowej kointegracji i przyczynowości Grangera, wskazują na silną zależność cen surowców rolnych od zmian światowych cen ropy naftowej. Zastosowane w badaniu dane dotyczyły miesięcznych cen ropy naftowej i 24 surowców rolnych z okresu od 1980 do 2010 r.

Kolejni badacze, niezależnie od siebie, w analizach nad związkami cen ropy naftowej i pszenicy wykorzystali modele VECM oraz testy przyczynowości. Byli to Saghalian (2010) oraz Obadi i Korček (2014). W obu przypadkach badania prowadzono na podstawie danych miesięcznych i w obu wykazano istnienie wpływu zmian cen ropy naftowej na ceny pszenicy. Jednakże badania prowadzono dla różnych okresów. Obadi i Korček (2014) badali cenę w okresie od 1975 do 2013 r., a Saghalian wykorzystał informacje z lat 1988–2002. Co ciekawe, w przypadku badań Obadiego i Korčeka (2014) test przyczynowości Grangera wskazał na dwukierunkową relację między cenami ropy naftowej i pszenicy. Dzięki przeprowadzeniu testów Johansena – test śladu i test największej wartości własnej, autorzy wskazali na kointegrację cen ropy naftowej i pszenicy, długoterminowy związek między cenami i wspólny trend. Wykorzystując modele VECM, wykazali długoterminową relację między cenami pszenicy i ropy naftowej. Na podstawie wyników uzyskanych w teście Walda potwierdzili również krótkoterminowy związek między cenami pszenicy i ropy naftowej.

Inną grupę badań stanowią badania zakładające asymetryczną transmisję cen między ropą naftową a surowcami rolnymi. Badania takie dotyczące pszenicy prowadzili Zhang i inni (2010). Dla danych dziennych z okresu od 2004 do 2014 r. wykorzystali modele ARMA-GARCH i wykazali, że szok cenowy na rynku ropy naftowej ma asymetryczny wpływ na zmiany cen pszenicy.

Jeszcze inną grupę badań stanowią odnoszące się do związków między zmiennością cen ropy naftowej i surowców rolnych, w tym zmiennością cen pszenicy.

W grupie tej znajdują się badania opublikowane przez Ahumadę i Cornejo w 2016 r. W analizie wykorzystali oni dzienne ceny ropy naftowej oraz dzienne ceny, między innymi, pszenicy. Wykorzystując modele SVAR, wykazali, że istnieje silna relacja między zmiennością cen pszenicy i ropy naftowej.

Podobnie Du i inni (2011) zbadali stopień wpływu wahań cen ropy naftowej na rynki towarów rolnych. Autorzy wykorzystali dane tygodniowe z okresu od 1998 do 2009 r., ale w podziale na dwa okresy (do i od 2006 r.). Uzyskane wyniki wskazują, że zmienność cen ropy naftowej wpływa na wahania cen pszenicy, ale w okresie po 2006 r.

Podobne wyniki, ale z wykorzystaniem dziennych danych okresu od 1986 do 2011 r. i modele GARCH uzyskali Nazlioglu i inni (2013). W celu uwzględnienia ewentualnego wpływu kryzysu cen żywności dane podzielili na dwa podokresy: okres przedkryzysowy od 1986 do 2005 r. i okres pokryzysowy od 2006 do 2011 r. W okresie przedkryzysowym nie zauważyli oni istotnych relacji między ropą naftową i surowcami rolnymi. Potwierdzili natomiast związek między zmiennością cen ropy naftowej i pszenicy w okresie po 2006 r. Ponadto wskazują, że szok cenowy na rynku ropy naftowej znajduje swoje odzwierciedlenie w cenach pszenicy i innych surowców rolnych wyłącznie w okresie pokryzysowym. Co interesujące, zauważyli transmisję zmienności w kierunku od pszenicy do ropy naftowej w obu wyodrębnionych okresach. Wskazują oni, że rynki ropy naftowej zawsze przyciągały globalnych inwestorów. Fakt, że po kryzysie obserwuje się znaczące przeniesienie ryzyka z ropy naftowej na rynki towarów rolnych, sugeruje, że inwestorzy szukający bezpiecznych przystani zwiększają finansjeryzację rynków towarów rolnych. Lokalne środki mające na celu zmniejszenie niepewności cen na rynkach rolnych mogą nie być skuteczne na krótką metę. Czynniki globalne, takie jak ryzyko na rynkach energii, wydają się napędzać krótkoterminową zmienność na rynkach rolnych. Znaczenie tego efektu jest większe w przypadku krajów najbardziej narażonych na wahania cen żywności. Nazlioglu i inni (2013) wskazują, iż więcej światła można rzucić w tej kwestii, badając reakcje lokalnych cen towarów rolnych na globalne szoki cenowe na rynkach energetycznych, w tym rynkach ropy naftowej.

Wei i Chen (2016) również sformułowali pytanie o istnienie współzależności cen ropy naftowej i światowych cen towarów rolnych. Swoje badania Wei i Chen (2016) prowadzili na podstawie dziennych cen pszenicy, soi i kukurydzy oraz dziennych cen kontraktów na ropę naftową z okresu od stycznia 2006 do lutego 2012 r. Do analizy wykorzystali model wektorowej autoregresji (VAR), funkcję odpowiedzi na impuls oraz dekompozycję wariancji. Bezpośrednio w analizach wykorzystali stopy zwrotu obliczone dla wymienionych cen surowców, określone mianem zwrotów. Głównym celem ich badania była analiza zależności między stopami zwrotu dla cen

ropy naftowej i pszenicy oraz soi i kukurydzy. Wyniki analizy funkcji odpowiedzi na impuls sugerują, że zwroty wszystkich produktów rolnych są uzależnione od zwrotów ropy naftowej. Wpływ dodatniego szoku cenowego na rynku ropy naftowej na towary rolne jest znacznie większy niż na odwrót. Jedno odchylenie standardowe szoku cenowego w odniesieniu do zwrotów ropy naftowej ma w dłuższym okresie wpływ na pszenicę oraz soję i kukurydzę w wysokości odpowiednio 9,12, 13,18 i 12,04%. Wyniki sugerują, że istnieje związek między cenami ropy naftowej i towarów rolnych. To stwierdzenie jest zgodne z obserwacją, że pszenica i pozostałe zboża konkurują z popytem na biopaliwa poprzez wykorzystanie soi do produkcji biodiesla, pszenicy i kukurydzy do produkcji bioetanolu. Szok spowodował wzrost popytu na biopaliwa jako alternatywnego paliwa ropy naftowej. Jednocześnie spowodowało to wzrost zapotrzebowania produkcji biopaliw na soję, pszenicę i kukurydzę, co z kolei zwiększyło ceny produktów rolnych w krótkim okresie. Ponadto ceny pszenicy i innych alternatywnych zbóż również wzrosły do wysokich poziomów, ponieważ istniał ograniczony areal gruntów uprawnych, a inne zboża były coraz częściej wykorzystywane jako substytuty kukurydzy. Sugeruje to, że cena ropy naftowej jest ważnym czynnikiem kosztów produkcji artykułów zbożowych i intensyfikuje relacje konkurencyjne między alternatywnymi ziarnami.

Pal i Mitra (2018) sformułowali pytanie, czy współzależność cen ropy naftowej i surowców rolnych na świecie istniała i czy różniła się istotnie w zależności od badanego okresu, przy czym mają na myśli okres przed kryzysem i okres po nim. Cały okres badania podzielili na cztery podokresy: pierwszy od stycznia 1990 do października 1999 r.; drugi od listopada 1999 do lutego 2005 r.; trzeci od marca 2005 do września 2010 r.; czwarty od października 2010 do lipca 2016 r. Trzeci okres zbiegł się z kryzysem żywnościowym i umożliwił autorom porównanie zależności paliwowo-żywnościowej w okresie poprzedzającym kryzys, w trakcie kryzysu i po jego zakończeniu. W swoich badania podjęli próbę wyjaśnienia możliwej współzależności cen ropy naftowej i światowych cen żywności. Uzyskane przez nich wyniki wskazują, że ponieważ kukurydza i soja stanowią podstawowe surowce w bioenergetyce, to właśnie uprawa tych surowców będzie pożądana, a co za tym idzie może zmusić rolników do realokacji ziemi z upraw spożywczych (np. pszenicy) do upraw energetycznych, co może doprowadzić do wzrostu cen pszenicy i tym samym cen żywności. Taka interpretacja zmian cen pojawia się często w literaturze przedmiotu i ma na celu wyjaśnienie wzajemnego ruchu ceny ropy naftowej i światowych cen żywności, szczególnie w latach 2006–2008. Od 27 USD za baryłkę w styczniu 2000 r. ceny ropy naftowej (Brent) osiągnęły poziom 132 USD za baryłkę w czerwcu 2008 r. W tym samym miesiącu światowy wskaźnik cen żywności (FAO) również osiągnął historyczną wartość, wartość indeksu wyniosła 225,8. Sytuacja ta stała się

wówczas istotą wielu dyskusji politycznych, jako że wiele krajów rozwijających się jest importerem zarówno ropy naftowej, jak i żywności, a to nasuwa pytania odnośnie bezpieczeństwa energetycznego i żywnościowego. Rosnące zainteresowanie badaniem związków cen ropy naftowej i światowych cen żywności zostało również przypisane potencjałowi finansjeryzacji towarów rolnych, zwłaszcza po kryzysie finansowym, który zbiegł się z kryzysem żywnościowym 2006–2008. Bazując na cyklach koniunkturalnych i podstawach ekonomicznych, w których tradycyjne instrumenty inwestycyjne, takie jak obligacje i instrumenty kapitałowe, znacznie różniły się od towarów rolnych, twierdzono, że po kryzysie inwestorzy zwiększyli swoje zainteresowanie instrumentami pochodnymi opartymi na surowcach głównie w celu ograniczenia ryzyka inwestycyjnego poprzez dywersyfikację portfela. Opozycyjne opinie przypisywały współzależność cen ropy naftowej i surowców rolnych nie popytowi na biopaliwa i finansjeryzacji towarów rolnych, ale popytowej i podażowej stronie mechanizmu rynkowego. Hanson i inni (1993) zasugerowali, że ponieważ uprawy surowców rolnych mają powszechny i masowy charakter, to wiążą się z wysokimi kosztami transportu. Ponadto wiele nawozów chemicznych było również ropopochodnych. W związku z tym wzrost cen ropy naftowej przeniósł się na towary rolne, podnosząc zarówno koszty produkcji, jak i transportu. Hochman i inni (2012) oraz Baumeister i Kilian (2014) argumentują, że rosnące ceny ropy naftowej, które przypisywali wzrostowi gospodarczej aktywności, oraz ekspansywna polityka pieniężna były również odpowiedzialne za zwiększone zapotrzebowanie na towary i usługi, w tym produkty spożywcze. Zwiększone zapotrzebowanie na produkty żywnościowe podniosło ceny surowców rolnych.

Teorie wyjaśniające relacje cen ropy naftowej i światowych cen żywności popytem na biopaliwa i finansjeryzacją produktów rolnych spotkały się z krytyką. Ich przeciwnicy dopatrywali się wyjaśnienia relacji cen ropy naftowej i surowców rolnych po stronie podażowej i popytowej mechanizmu rynkowego.

Kristoufek i inni (2012) prowadzili badania nad cenami ropy i surowców rolnych w okresie od 2006 do 2008 r. Podzielili oni jednak ten okres na dwa podokresy: do lipca 2007 r. i od lipca 2007 r., czyli na czas przed kryzysem żywnościowym i po nim. Autorzy wykazali, że powiązania między ropą naftową i towarami rolnymi są silniejsze po rozpoczęciu kryzysu żywnościowego. Podobnie Nazlioglu i inni (2013) potwierdzili dowody transmisji zmienności cen ropy naftowej na ceny produktów rolnych tylko w okresie po kryzysie żywnościowym. W przypadku tych badań szerszy był zakres czasowy, bowiem wykorzystali oni dane z okresu od 1 stycznia 1986 do 21 marca 2011 r., za datę podziału przyjęli 1 stycznia 2006 r.

Ahumada i Cornejo (2016) dane z okresu od kwietnia 1993 do maja 2014 r. również podzielili na dwa podokresy, w tym przypadku datą graniczną był maj 2006 r. Zastosowanie strukturalnych modeli wektorowej autoregresji (SVAR) pozwoliło

wykazać, że silniejsze powiązania między cenami ropy naftowej i surowców rolnych są w okresie pokryzysowym.

Podobnie Wang i inni (2014) znaleźli dowody silniejszego wpływu szoków cenowych ropy naftowej na wahania cen towarów rolnych w okresie po kryzysie żywnościowym. Według nich przed 2006 r. wzajemne relacje między cenami ropy naftowej i surowców rolnych były nieistotne. Badania prowadzili z wykorzystaniem miesięcznych cen ropy naftowej, pszenicy i ośmiu innych surowców rolnych odnotowanych od 1980 do 2012 r. Badany okres podzielili na dwa podokresy: od stycznia 1980 do kwietnia 2006 r. oraz od maja 2006 do grudnia 2012 r. W analizie posłużyli się strukturalnymi modelami wektorowej autoregresji (SVAR). Na podstawie wyznaczonych funkcji odpowiedzi na impuls autorzy wskazują, że skutki szoków cenowych ropy naftowej na rynkach rolnych różnią się znacznie w zależności od tego czynnika wywołującego zmiany cen ropy naftowej i to zarówno przed kryzysem, jak i po nim. Wang i inni (2014) dowodzą, że w okresie poprzedzającym kryzys reakcja cen pszenicy i innych surowców rolnych na szoki podaży ropy naftowej lub szoki popytu związane z ropą naftową nie były istotne. Rynek ropy naftowej nie powinien być więc odpowiedzialny za zmiany cen surowców rolnych w okresie poprzedzającym kryzys. W okresie pokryzysowym Wang i inni (2014) zauważyli reakcje cen pszenicy i innych surowców rolnych na gwałtowne wahania popytu na ropę naftową i wskazali, że aktywność na rynku ropy naftowej może znacząco wpływać na rynki towarów rolnych. Chcąc oszacować udział szoków na rynkach ropy naftowej w zmianach cen pszenicy, zastosowali metodę dekompozycji wariancji. Uzyskane przez nich wyniki wskazują, że w okresie przed kryzysem podaż ropy naftowej i gwałtowne wahania popytu na nią wyjaśniają nieistotne frakcje wahań cen surowców rolnych. W okresie po kryzysie frakcje te są istotnie większe, dlatego też aktywność na rynku ropy naftowej ma znacznie większy wpływ na rynek pszenicy i pozostałych surowców rolnych po kryzysie niż przed nim.

Lucotte (2016) w swoich badaniach posłużył się danymi z okresu od marca 1990 do maja 2015 r., jako graniczną datę przyjął styczeń 2007 r. On również potwierdził silniejszą korelację między cenami ropy naftowej i żywności w okresie pokryzysowym, czyli po styczniu 2007 r.

De Nicola i inni (2016) obserwowali relacje cen ropy naftowej i surowców rolnych w okresie od 1970 do 2013 r. Na podstawie uzyskanych wyników potwierdzili oni relację dodatnią między cenami ropy naftowej i produktów rolnych za pomocą dynamicznych modeli warunkowej korelacji.

Pal i Mitra (2018) uznali, że chociaż badania szacujące siłę wzajemnych relacji między wzrostem cen ropy naftowej i światowymi cenami surowców rolnych, w okresie przed kryzysem żywnościowym i po nim, opierały się na różnych metodach ekonometrycznych (np. kointegracja, przyczynowość, lub autoregresyjny mo-

del wektorowy), to nadal wiedza na temat tego, jak zmieniały się ceny ropy naftowej i żywności w przedkryzysowym i pokryzysowym okresie, jest ograniczona. Autorzy podjęli się zatem próby odpowiedzi na pytanie, czy kryzys żywnościowy zmienia siłę i charakter współzależności między cenami ropy naftowej a światowymi cenami żywności. W tym celu wykorzystali analizę zdetrendowanej korelacji krzyżowej (DCCA). Badali siłę tej współzależności w różnych przedziałach czasowych oraz różnicę siły współzależności przed kryzysem i po nim. Nie byli oni jednak pierwszymi badaczami, którzy wykorzystali DCCA do oceny korelacji krzyżowej między cenami ropy naftowej i produktów rolnych. W 2014 r. Liu opublikował wyniki swoich badań opartych na DCCA, na podstawie których stwierdził, że uprawy energetyczne, czyli uprawy soi i kukurydzy, będą konkurować z uprawami żywności takimi jak pszenica o ziemię pod te uprawy, tym samym podnosząc ceny pszenicy. Pal i Mitra (2018), którzy badali korelację krzyżową między cenami ropy naftowej a światowym indeksem cen żywności, zamiast zgodnie z podejściem pośrednim, w którym badania przypisywały głównie rosnącą cenę żywności wahaniom cen ropy naftowej poprzez wskazanie współzależności między cenami ropy naftowej i produktów rolnych, zastosowali bardziej bezpośrednie podejście, badając współzależność między cenami ropy naftowej i żywności. Wskaźnik cen zbóż jest średnią ważoną ceną kukurydzy, pszenicy i ryżu, oczekuje się więc, że będzie on wykazywał współzależność z ropą naftową wykazywaną przez kukurydzę i pszenicę (Liu, 2014). Ponadto, jak wspomniano wcześniej, w odróżnieniu od innych badań swoje prowadzili na podstawie danych podzielonych na cztery okresy. Głównym celem ich badania było wykazanie, że wraz z nadejściem kryzysu żywnościowego wzrosły współzależności między cenami ropy naftowej a światowym indeksem cen żywności wskazujące, że po kryzysie te korelacje były znacznie większe.

Xiaodong i Hayes (2009) znajdują dowody na przenikanie się zmienności spośród rynków ropy naftowej, kukurydzy i pszenicy, które mogły być w dużej mierze wyjaśnione przez ściślejszą współzależność między tymi rynkami indukowaną przez produkcję etanolu.

Alghalith (2010) szacuje wpływ niepewności cen ropy naftowej na ceny żywności. Empiryczne wyniki wskazują, że wyższa cena ropy naftowej zwiększa cenę żywności, a większa zmienność jej cen powoduje wyższą cenę żywności. Co więcej, zwiększenie podaży ropy naftowej obniża cenę żywności. Badania swoje prowadzili z wykorzystaniem danych z lat 1974–2007 uzyskanych z Centralnego Banku Trynidadu i Tobago, małego kraju Południowych Karaibów.

Rosegrant (2008) oraz Engdahl (2008) wskazali, że wykorzystanie upraw do produkcji paliwa jest czynnikiem napędzającym wzrost cen żywności. Ten wzrost w ostatnich kilku latach był głównie tłumaczony jako wynik ekspansji biopaliw, któ-

ra ograniczyła dostępność podaży żywności na rynku międzynarodowym i zwiększyła ceny żywności.

W publikacji Ghaita i Awada (2011) opisane jest badanie długookresowego związku między cenami ropy naftowej, pszenicy i kilkoma innymi surowcami rolnymi. Badania przeprowadzili na danych z okresu od stycznia 1998 do grudnia 2009 r. Wykorzystując analizę kointegracji, dowiedli długookresowej relacji między cenami ropy naftowej i surowców rolnych, w tym oczywiście pszenicy.

Podobne badania z zastosowaniem analizy kointegracji prowadzili Ciaian i Kancs (2011). Do analizy wykorzystali dane z okresu od stycznia 1994 do grudnia 2008 r. Ich badania również wykazały związek między cenami ropy naftowej i pszenicy oraz ośmiu innych surowców rolnych. Oszacowali ponadto, iż wzrost cen ropy naftowej o 1 USD za baryłkę spowoduje wzrost cen pszenicy o nie mniej niż 10 centów, ale nie więcej niż 1,80 USD.

Harri i inni (2009) również badali związek między cenami kukurydzy, soi, bawełny i pszenicy a kursem dolara amerykańskiego i cenami ropy naftowej za pomocą analizy kointegracji. W badaniach wykorzystali dane z okresu od stycznia 2000 do września 2008 r. Uzyskali oni nieco odmienne od powyższych wyniki, wskazujące na istniejącą relację między cenami kukurydzy, bawełny, soi a cenami ropy naftowej oraz na brak związku między cenami pszenicy i ropy naftowej.

W opracowaniu Arshada i Hameeda (2009) analizowano związek między cenami ropy naftowej i zbóż (tj. kukurydzą, ryżem i pszenicą) na podstawie danych z okresu od stycznia 1980 do marca 2008 r. W niniejszym opracowaniu zastosowano dwustopniowe oszacowanie Engle'a–Grangera i testy przyczynowości Grangera. Wyniki empiryczne potwierdzają obecność jednokierunkowej długoterminowej przyczynowości od cen ropy naftowej do trzech cen zbóż.

Rezitis (2015) analizował długoterminową zależność między cenami ropy naftowej, kursami dolara amerykańskiego, światowymi cenami 30 wybranych surowców rolnych (w tym oczywiście pszenicy) oraz cenami pięciu nawozów z użyciem panelowych metod ekonometrycznych. W badaniu wykorzystał miesięczne dane z okresu od czerwca 1983 do czerwca 2013 r. Wyniki empiryczne wskazują, że w długim okresie wpływ zmian cen ropy naftowej na ceny produktów rolnych jest dodatni i statystycznie istotny. Rezitis (2015) oszacował szybkość dostosowania cen surowców rolnych w kierunku długoterminowej równowagi. Uzyskane przez niego wyniki empiryczne wskazują, że ceny surowców rolnych powoli dostosowują się do długoterminowej równowagi.

Fretheim (2019) przeanalizował dzienne zmiany cen w latach 1984–2017 i stwierdził, że korelacja między zmianami cen ropy naftowej i pszenicy jest w najlepszym wypadku marginalna. Nie znalazł dowodów na dodatnią korelację między

zmianami cen ropy naftowej i zboża w okresie między styczniem 1984 a grudniem 2005 r. Jego oszczędne modele regresji wskazują, że po 2006 r. istnieje ściślejszy związek między zmianami cen ropy naftowej i zboża, z istotnymi oszacowaniami parametrów i nieznacznym wzrostem wartości współczynnika determinacji. Wzrost mocy wyjaśniającej jest jednak niewielki i najprawdopodobniej spowodowany czynnikami globalnymi, a raczej rynkiem ropy naftowej, który staje się bardziej wrażliwy na specyficzne wstrząsy na rynku żywności.

Hamulczuk i Klimkowski (2011) ocenę związków między cenami ropy naftowej i pszenicy przeprowadzili na podstawie tygodniowych danych z okresu od maja 2004 do lipca 2011 r. W analizie wykorzystali test przyczynowości Grangera, modele wektorowej autoregresji (VAR) oraz model o rozłożonych opóźnionych (ARDL). Autorzy wykazali, iż w badanym przez nich okresie istnieje dodatnia korelacja między cenami pszenicy i ropy naftowej. Dowiedli ponadto istnienia związków przyczynowych między badanymi zmiennymi. Ceny ropy naftowej wywołują zmiany cen pszenicy na krajowym rynku pszenicy. Ponadto pod koniec 2007 r. nastąpiła zmiana struktury zależności między badanymi zmiennymi. Hamulczuk i Klimkowski (2011) podzielili badany okres na dwa podokresy, za koniec pierwszego podokresu przyjęli sierpień 2007 r., za początek drugiego grudzień 2007 r. Podział ten wykazał silniejsze relacje między cenami ropy naftowej i pszenicy niż w przypadku analizy przeprowadzonej dla całego okresu. Modele ARDL wykazały, że długookresowym skutkiem jednoprocetowej zmiany cen ropy naftowej jest zmiana cen pszenicy o nie mniej niż 0,21%, ale nie więcej niż o 0,24%. Silniejsze oddziaływanie cen ropy naftowej na ceny pszenicy uzyskano dla drugiego podokresu. Efekty zauważalne w ciągu jednego tygodnia, tzw. natychmiastowe efekty, stanowiły około jedną czwartą efektu długookresowego. W pierwszym podokresie efekt ten był wyraźnie silniejszy. Uzyskane przez autorów wyniki wskazują na istnienie wpływu zmian cen ropy naftowej na ceny pszenicy, szczególnie silnego do połowy 2007 r. Wynik ten stoi niejako w opozycji do wyników innych autorów wskazujących na istnienie związku między cenami ropy naftowej i pszenicy, ale w okresie po 2006/2007 określanym mianem pokryzysowego. Można domniemywać, iż przyczyną tego stanu jest wykorzystanie krajowych cen pszenicy. Autorzy nie konfrontują wyniku z tymi uzyskanymi przez innych badaczy, uzasadnią go natomiast wysokim popytem na biopaliwa. W przypadku drugiego podokresu autorzy wskazują na niewielkie zmniejszenie siły wpływu cen ropy naftowej na ceny pszenicy. Hamulczuk i Klimkowski (2011) podkreślają, że ponieważ polskie rolnictwo jest w niewielkim stopniu uzależnione od popytu na biopaliwa, to dodatnie skorelowanie kosztotwórczych cen ropy naftowej z cenami pszenicy wpływa na obniżenie ryzyka dochodowego producentów rolnych.

7. Modelowanie szeregów czasowych – wektorowe modele autoregresji i ich strukturalna postać

Omawiane w pracy rynki pszenicy, ropy i złota wpisują się w proces wzmacniania się wzajemnych powiązań w obrębie światowej ekonomii, polityki, zjawisk społecznych i kulturalnych. Do ich analizy zatem potrzebne są takie modele ekonometryczne, które opisują zależności między różnymi, nawet pozornie niepowiązanymi ze sobą zjawiskami. Co ważne, w modelach tych konieczne jest ponadto uwzględnienie tego, że badane zjawiska obserwowane są w czasie. Modelami odpowiadającymi na tak zdefiniowane potrzeby są modele autoregresji wektorowej VAR oraz modele strukturalne autoregresji wektorowej SVAR należące do grupy modeli wielowymiarowych szeregów czasowych.

Modele szeregów czasowych

Modele szeregów czasowych to takie, w których uwzględniony jest czas. Szeregiem czasowym bowiem jest ciąg wartości obserwacji, z których każda związana jest z konkretnym momentem w czasie. Analiza pojedynczego zjawiska obserwowanego w czasie jest określana mianem jednowymiarowej analizy szeregów czasowych. W przypadku gdy w tym samym okresie obserwowanych jest więcej zjawisk, wówczas jest to wielowymiarowa analiza szeregów czasowych.

Przyjmijmy, że obserwujemy przebieg badanego zjawiska w czasie. Niech y_t oznacza wartość badanej zmiennej w okresie t . Prognoza tej zmiennej na koniec okresu $T + h$ może przyjąć następującą postać

$$\hat{y}_{T+h} = f(y_T, y_{T-1}, \dots), \quad (7.1)$$

gdzie $f(\cdot)$ oznacza odpowiednią funkcję poprzednich obserwacji y_T, y_{T-1}, \dots . Otwarta pozostaje tutaj kwestia, ile wcześniejszych obserwacji jest wykorzystanych w modelowaniu badanego zjawiska (Lütkepohl, 2005). Jeżeli przejrzymy ponadto, iż tylko skończona liczba p poprzednich wartości zmiennej y jest wykorzystywana w jej modelu, to otrzymujemy

$$\hat{y}_{T+h} = f(y_T, y_{T-1}, \dots, y_{T-p+1}). \quad (7.2)$$

Jednym z kluczowych celów analizy jednowymiarowych szeregów czasowych jest określenie postaci funkcji opisującej zależność badanej zmiennej od jej wcześniejszych realizacji (Lütkepohl, 2005). W wielu zastosowaniach $f(\cdot)$ jest funkcją liniową

$$\hat{y}_{T+h} = v + \alpha_1 y_T + \alpha_2 y_{T-1} + \dots + \alpha_p y_{T-p+1}. \quad (7.3)$$

Badana zmienna jest zmienną losową z określonym prawdopodobieństwa w każdym okresie T , dlatego też model jednowymiarowego szeregu czasowego ma postać procesu autoregresyjnego AR

$$y_t = v + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t, \quad (7.4)$$

gdzie wartości u_t są błędami losowymi. Chcąc uzyskać proces AR, zakładamy brak autokorelacji błędów losowych ε_t (Lütkepohl, 2005).

W przypadku zjawisk ekonomicznych bardzo często wartości badanej zmiennej są związane nie tylko z jej wcześniejszymi realizacjami, ale również zależą od wcześniejszych realizacji innych zmiennych ($y_{1t}, y_{2t}, \dots, y_{Kt}$). Prognoza zmiennej y_k na koniec okresu $T + h$ może zatem przyjąć następującą postać

$$\hat{y}_{k,T+h} = f(y_{1T}, y_{2T}, \dots, y_{kT}, y_{1,T-1}, y_{2,T-1}, \dots, y_{K,T-1}, \dots). \quad (7.5)$$

Zbiór szeregów czasowych y_{kt} , $k = 1, \dots, K$, $t = 1, \dots, T$ określa się mianem wielowymiarowych szeregów czasowych. Powyższa funkcja to wielowymiarowa funkcja szeregów czasowych. Głównym celem analizy wielowymiarowych szeregów czasowych jest określenie postaci tej funkcji (Lütkepohl, 2005). Podobnie jak i w tym przypadku w wielu zastosowaniach funkcja $f(\cdot)$ ma liniową postać

$$\hat{y}_{T+h} = v + \mathbf{A}_1 y_T + \dots + \mathbf{A}_p y_{T-p+1}, \quad (7.6)$$

gdzie

$$\hat{y}_t := (\hat{y}_{1t}, \dots, \hat{y}_{Kt})', y_t := (y_{1t}, \dots, y_{Kt})', v := (v_1, \dots, v_K)'$$

oraz

$$\mathbf{A}_i = \begin{bmatrix} \alpha_{11,i} & \dots & \alpha_{1K,i} \\ \vdots & \ddots & \vdots \\ \alpha_{iK,i} & \dots & \alpha_{KK,i} \end{bmatrix}.$$

Badana zmienna jest zmienną losową z określonym rozkładem prawdopodobieństwa w każdym okresie T , dlatego też model wielowymiarowego szeregu czasowego ma postać modelu wektora autoregresyjnego

$$\hat{y}_t = v + \mathbf{A}_1 y_{t-1} + \dots + \mathbf{A}_p y_{t-p} + \varepsilon_t, \quad (7.7)$$

gdzie $\varepsilon_t = (\varepsilon_{1t}, \dots, \varepsilon_{Kt})'$ to niezależne wektory losowe z jednakowym rozkładem i zerowym wektorem średniej (Lütkepohl, 2005).

Modele autoregresji wektorowej VAR

W 1980 r. Christopher Sims sformułował modele autoregresji wektorowej VAR, które są związane z analizą i estymacją modeli niestacjonarnych szeregów czasowych. Modele VAR są uogólnieniem modeli AR odnajdujących się w przypadku analizy wielu szeregów czasowych. Są to modele wielorównaniowe, w których każda zmienna objaśniająca (endogeniczna) jest wyjaśniana opóźnieniem swoim i opóźnieniami pozostałych zmiennych endogenicznych. Związki między kolejnymi równaniami widoczne są w powiązaniach między składnikami losowymi tych równań. Konstrukcja tych modeli nie wymaga wiedzy dotyczącej ekonomicznej struktury powiązań między zmiennymi. Z tego też powodu krytycy modeli autoregresji wektorowej zarzucają im „ateoretyczność” (Kusideł, 2000; Lütkepohl, 2005; Witkowska i in., 2008).

Celem analizy VAR jest znalezienie wszystkich istotnych powiązań między zmiennymi. Spektrum implementacji modeli VAR można sklasyfikować w grupy:

- modelowanie zależności;
- prognozowanie;
- badanie kointegracji, czyli długookresowego związku między dwiema niestacjonarnymi zmiennymi;
- analiza odpowiedzi na impuls, która pozwala stwierdzić, w jaki sposób zareaguje określona zmienna w modelu na zaburzenia innej zmiennej;
- dekompozycja wariancji, na podstawie której ustala się, jaki udział w objaśnianiu błędu określonej zmiennej w modelu mają inne zmienne;
- badanie przyczynowości (Witkowska i in., 2008).

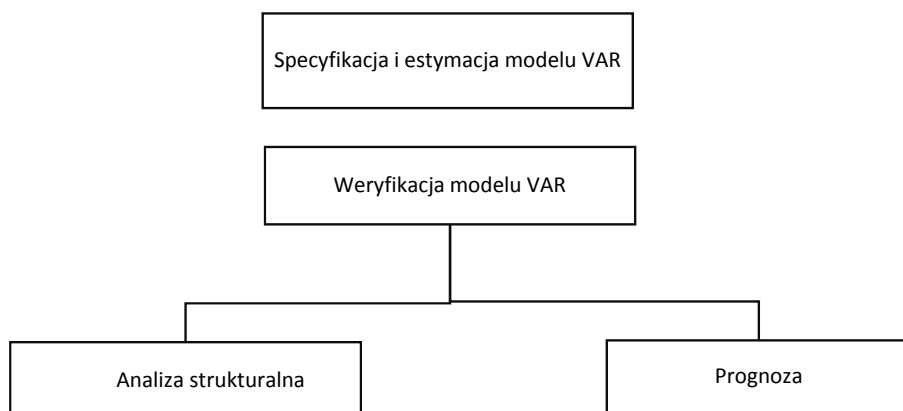
Wykorzystanie modeli VAR i SVAR w modelowaniu wielowymiarowych szeregów czasowych wymaga przyjęcia założenia, iż:

- nie ma *a priori* rozróżnienia między zmiennymi endogenicznymi i zmiennymi egzogenicznymi (objaśniającymi);
- nie ma uzasadnionych ograniczeń odnośnie wartości parametrów modelu, czyli nie zakłada się warunków zerowych;
- nie ma ściśle i przeznaczoną tylko do tego teorii ekonomicznej, na podstawie której budowany jest model (Kusideł, 2000; Wójcik, 2014).

Pierwsze założenie odnosi się do zasady, że każda zmienna występująca w badaniu wyznacza osobne równanie modelu, a więc w modelu jest tyle równań, ile jest zmiennych użytych w badaniu. Wobec tego nie jest konieczny podział zmiennych w modelu na zmienne endogeniczne i egzogeniczne. Ponadto, jako że w zbiorze zmiennych objaśniających występują jedynie opóźnienia wszystkich zmiennych występujących w badaniu, nie jest konieczne nakładanie tzw. restrykcji zerowych dla osiągnięcia identyfikacji systemu. Warto jednak dodać, iż w badaniach eko-

nomicznych dopuszczane jest dołączenie do modelu zmiennych egzogenicznych w postaci wyrazu wolnego trendu liniowego zmiennych binarnych. Konsekwencją pierwszego i drugiego założenia jest brak potrzeby identyfikacji zmiennych egzogenicznych. Trzecie założenie jest następstwem dwóch pierwszych. Brak wyróżnionych z równań modelu zmiennych endogenicznych oznacza, że żadnej z nich nie można określić zmienną egzogeniczną. Wobec tego można uznać, iż wszystko jest przyczyną wszystkiego, czyli nie ma możliwości nałożenia jakichkolwiek hipotez ekonomicznych, poza bardzo ogólnymi hipotezami przyjmowanymi jako punkt początkowy (Kusideł, 2000; Wójcik, 2014).

Analiza VAR stanowi sekwencyjny proces modelowania obejmujący badanie własności zmiennych, budowę modelu, prognozowanie, analizę związków między zmiennymi oraz ich kointegrację. Każdy etap modelowania potwierdzany jest odpowiednimi testami statystycznymi. Schemat analizy VAR przedstawiono na rysunku 7.1.



Rysunek 7.1. Analiza VAR

Źródło: opracowanie własne na podstawie (Lütkepohl, 2005).

Etapy konstruowania modeli autoregresji wektorowej obejmują:

- badanie stacjonarności zmiennych;
- wyznaczenie długości opóźnień;
- badanie własności reszt równań modelu;
- badanie istotności parametrów, czyli tzw. weryfikację restrykcji zerowych.

Podstawowy model VAR ma postać

$$y_t = \mathbf{A}_0 D_t + \mathbf{A}_1 y_{t-1} + \mathbf{A}_2 y_{t-2} + \dots + \mathbf{A}_k y_{t-k} + \varepsilon_t \quad (7.8)$$

lub

$$y_t = \mathbf{A}_0 D_t + \sum_{i=1}^k \mathbf{A}_i y_{t-i} + \varepsilon_t, t = 1, 2, \dots, T, \quad (7.9)$$

gdzie

$y_t = [y_{1t}, y_{2t}, \dots, y_{kt}]'$ – wektor obserwacji bieżących wartości wszystkich n zmiennych modelu;

D_t – wektor deterministycznych składników równań, takich jak: wyraz wolny, zmienna czasowa, zmienne zero-jedynkowe lub inne niestochastyczne regresory;

A_0 – macierz parametrów przy zmiennych wektora D_t , niezawierająca zerowych elementów;

A_i – macierz parametrów przy opóźnionych zmiennych wektora D_t , również niezawierająca zerowych elementów.

Wreszcie $\varepsilon_t = [\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{kt}]$ jest k -wymiarowym białym szumem, czyli wektorem stacjonarnych, niezależnych zakłóceń losowych o rozkładzie normalnym ze średnią zero i stałą wariancją Σ_ε .

Ponadto przyjmuje się brak autokorelacji składników losowych poszczególnych równań oraz istnienie powiązań składników losowych między poszczególnymi równaniami modelu, czyli kowariancje jednoczesne $\text{cov}(\varepsilon_{it}, \varepsilon_{jt}) \neq 0$ (Kusideł, 2000).

Estymację parametrów tego modelu przeprowadza się, wykorzystując klasyczną metodę najmniejszych kwadratów, którą stosuje się do każdego równania z osobna. Uzyskane w ten sposób estymatory są zgodne i asymptotycznie efektywne. Metodę MNK można zastosować, ponieważ model VAR jest modelem prostym i nieuwzględniającym wzajemnych powiązań między bieżącymi zmiennymi endogenicznymi. Jeżeli jednak występują powiązania między składnikami losowymi poszczególnych równań, to należy zastosować uogólnioną wersję MNK (Witkowska i in., 2008).

Chociaż prezentowany model zdaje się być prosty w konstrukcji, to przy jego tworzeniu powinny być spełnione pewne warunki. Pierwszym warunkiem jest dobór zmiennych do modelu, który powinien wynikać z dobrej znajomości modelowanego układu ekonomicznego, szczególnie jeżeli ma być on wykorzystany w analizach strukturalnych powiązań między zmiennymi czy też do badania kointegracji. Drugi warunek odnosi się do rzędu opóźnień, który powinien odzwierciedlać naturalne interakcje między zmiennymi (dla danych miesięcznych – miesięczne, tygodniowych – tygodniowe itp.). Powinien również gwarantować brak autokorelacji błędów losowych (Kusideł, 2000). Trzeci warunek dotyczy stacjonarności zmiennych. W literaturze przedmiotu (Philips, 1986; Kusideł, 2000) wskazuje się, iż wyniki uzyskane dla niestacjonarnych szeregów czasowych są wątpliwej jakości. Oznacza to, że w przypadku niestacjonarnego szeregu możliwe jest uzyskanie pozytywnych wyników, nawet wtedy gdy model nie ma logicznego uzasadnienia. Podobnie w przypadku niestacjonarnych szeregów w modelach VAR uzyskane statystyki testowe nie mają pożądanych rozkładów. Stacjonarność szeregów losowych jest tu rozumiana

jako szczególny stan ich „statycznej równowagi” (Kusideł, 2000). Ten stan jest zachowany wówczas, gdy łączny rozkład zmiennych losowych jest stały. W konsekwencji oznacza to, że jest stacjonarność ścisła, czyli stałe w czasie są wszystkie momenty zwykłe i centralne. W badaniach ekonomicznych dopuszczana jest słaba stacjonarność, czyli stacjonarność, dla której wymagane jest spełnienie następujących założeń:

- stała w czasie jest średnia szeregu czasowego $E(y_t) = E(y_{t-k}) = \mu$;
- stała w czasie jest wariancja $E[(y_t - \mu)^2] = [(y_{t-k} - \mu)]^2 = \sigma^2$;
- nie zależy od czasu, ale zależy od okresu s kowariancja $E[(y_t - \mu)(y_{t-k} - \mu)] = E[(y_{t-s} - \mu)(y_{t-k-s} - \mu)] = \gamma_s$.

W literaturze przedmiotu wykazany jest fakt, iż niespełnienie któregoś z wymienionych warunków ma wpływ na właściwości wnioskowania statystycznego. Co więcej, że zachowanie szeregów niestacjonarnych uzależnione jest od tego, który z warunków nie jest spełniony. Nie ma natomiast jednoznacznej odpowiedzi na pytania o przyczyny niestacjonarności. Jedna z dwóch alternatywnych hipotez wskazuje, że procesy niestacjonarne reprezentują stacjonarne wahania wokół trendu (Kusideł, 2000). Druga hipoteza dotyczy pierwiastków jednostkowych lub błędzenia przypadkowego i wskazuje, że niestacjonarność jest efektem niestałej wariancji tych procesów. Procesy te po wystąpieniu zakłócenia losowego nie powracają do deterministycznego trendu. Prawdziwość tej hipotezy oznacza, iż losowe zakłócenia wywierają trwały wpływ na system ekonomiczny i zakłócenia te nie są tymczasowe (Kusideł, 2000).

W praktyce szczególnie istotne jest rozróżnienie na szeregi niestacjonarne w średniej (niespełniony pierwszy z warunków) i szeregi niestacjonarne w wariancji (niespełniony drugi warunek). Ma to znaczenie w przypadku wyboru sposobu filtrowania zmiennych w celu doprowadzenia do ich stacjonarności. Istnieje wiele metod badających stacjonarność: badanie funkcji autokorelacji i funkcji gęstości spektralnej, test Perrona, test według statystyki LM (mnożnika Lagrange’a), rozszerzona wersja testu Dickeya–Fullera (test ADF) oraz test Kwiatkowskiego, Philipisa, Schmidta i Shina (test KPSS). Niniejsza publikacja nie ma celu szczegółowej charakterystyki stacjonarności zmiennych i metod jej badania, dlatego też w dalszej części ograniczono się do charakterystyki wykorzystanych w analizie testów ADF i KPSS.

Rozszerzona wersja testu Dickeya–Fullera (test ADF)

W 1981 r. David A. Dickey i Wayne A. Fuller zaproponowali autorski rozszerzony test ADF (ang. *augmented Dickey–Fuller test*). Hipoteza zerowa w tym teście zakłada występowanie niestacjonarności. Pierwszym krokiem jest oszacowanie jednego z następujących równań (Witkowska i in., 2008):

$$\Delta y_t = \alpha_1 y_{t-1} + \sum_{i=1}^p c_i \Delta y_{t-1} + \varepsilon_t, \quad (7.10)$$

$$\Delta y_t = \alpha_0 + \sum_{i=1}^p c_i \Delta y_{t-1} + \varepsilon_t, \quad (7.11)$$

$$y_t = \alpha_0 + \lambda_1 t + \alpha_1 y_{t-1} + \sum_{i=1}^p c_i \Delta y_{t-1} + \varepsilon_t. \quad (7.12)$$

Statystyka τ testu jest określona wzorem:

$$\tau = \frac{\hat{\alpha}_1}{S(\hat{\alpha}_1)}, \quad (7.13)$$

gdzie

$\hat{\alpha}_1$ – estymator parametru α_1 oszacowany metodą najmniejszych kwadratów dla każdego z równań (7.10)–(7.12);

$S(\hat{\alpha}_1)$ – błąd standardowy α_1 .

Hipoteza zerowa i alternatywna dla testu ADF jest następująca:

- H_0 : szereg y_t jest niestacjonarny z powodu występowania pierwiastka jednostkowego;
- H_1 : szereg jest stacjonarny.

Jeśli wartość statystyki τ jest mniejsza od wartości krytycznej, hipoteza zerowa jest odrzucana na rzecz stacjonarności zmiennej. Hamulczuk i inni (2012) zauważyli, że statystyka τ „podąża” za rozkładem, który różni się od innych standardowych rozkładów, dlatego konieczne jest użycie specjalnych tabel statystycznych. Jeśli wartość prawdopodobieństwa $p < 0,05$, to H_0 można odrzucić.

W przypadku gdy hipotezy o braku stacjonarności nie odrzucamy, należy sprawdzić, czy pierwsze przyrosty zmiennej są stacjonarne. W tym celu buduje się następujący model:

$$\Delta^2 y_t = \alpha_1 \Delta y_{t-1} + \sum_{i=1}^p c_i \Delta^2 y_{t-1} + \varepsilon_t. \quad (7.14)$$

Statystyka testująca stacjonarność przyrostów ma postać jak w teście, w (7.13). Hipotezy zerową i alternatywną w tym przypadku można sformułować w sposób:

- H_0 : przyrosty zmiennej są niestacjonarne;
- H_1 : przyrosty zmiennej są stacjonarne.

Na ogół okazuje się, że przyrosty zmiennej są stacjonarne, czyli zmienna jest zintegrowana pierwszego stopnia, co oznacza, że jest niestacjonarna, ale pierwsze przyrosty wystarczają do uzyskania stacjonarności.

Test Kwiatkowskiego, Philipa, Schmidta i Shina (test KPSS)

Innym testem wykorzystywanym do sprawdzenia stacjonarności szeregów czasowych jest test Kwiatkowskiego, Philipa, Schmidta i Shina (test KPSS). W tym teście hipotezy zerowa i alternatywna mają układ odwrotny niż w teście ADF. Mianowicie:

- H_0 : szereg czasowy y_t jest stacjonarny;
- H_1 : szereg czasowy jest niestacjonarny, jest zintegrowany w pierwszym stopniu.

Konstrukcja testu KPSS przebiega w poniżej opisany sposób. Zakładając brak komponentu liniowego trendu, zmienna y_t ma postać (Lütkepohl i Krätzig, 2007; Hamulczuk i Klimkowski, 2011)

$$y_t = x_t + \zeta t + z_t, \quad (7.15)$$

gdzie

- x_t – proces błędzenia przypadkowego: $x_t = x_{t-1} + v_t$, w którym v_t jest stacjonarnym procesem $v_t \sim IID(0, \sigma_v^2)$;
- z_t – stacjonarny proces postaci $z_t \sim IID(0, \sigma_z^2)$.

Jeśli wariancja składnika losowego v_t jest zerowa, to wartości $x_t = x_0$, tzn. są stałe dla każdego t . Wówczas proces y_t jest sumą stałej v_0 lub stałej i trendu deterministycznego $x_0 + \zeta t$ oraz stacjonarnego składnika czysto losowego. Jeśli natomiast wariancja składnika losowego v_t jest niezerowa, to równanie to określa proces błędzenia losowego. Wówczas proces v_t będący sumą procesu x_t (i ewentualnie trendu deterministycznego ζt) oraz stacjonarnego składnika czysto losowego jest niestacjonarny.

Hipotezy zerową i alternatywną można zapisać w sposób:

- $H_0 : \sigma_v^2 = 0$
- $H_1 : \sigma_v^2 > 0$.

Statystyka testu KPSS dana jest wzorem

$$KPSS = \frac{1}{T^2} \sum_1^T \frac{S_t^2}{\hat{\sigma}_\infty^2}, \quad (7.16)$$

gdzie

$$S_T^2 = \sum_{j=1}^T (y_j - \bar{y});$$

$\hat{\sigma}_\infty^2$ – estymator długookresowej wariancji.

Kolejnym istotnym zagadnieniem w modelach VAR jest weryfikacja długości opóźnień, która musi być wyznaczona bardzo krytycznie. Jeśli k będzie zbyt małe, to

może wystąpić autokorelacja błędów losowych równań. Jeśli k będzie zbyt duże, to może z kolei nastąpić niedopuszczalne zmniejszenie liczby stopni swobody. Wyznaczeniu optymalnej długości opóźnienia służy test ilorazu wiarygodności LR.

Weryfikację długości opóźnień rozpoczyna się z najdłuższym prawdopodobnym opóźnieniem lub możliwie największą długością opóźnień ze względu na liczbę stopni swobody k . Następnie zmniejsza się liczbę opóźnień o r i estymuje równania modelu VAR dla $k - r$. Badanie długości opóźnień polega na weryfikacji hipotezy zerowej, że długość opóźnienia w modelu wynosi $k - r$ przeciwko hipotezie alternatywnej, że wynosi ona k . W celu weryfikacji hipotez należy oszacować elementy macierzy wariancji–kowariancji reszt modelu o maksymalnej liczbie opóźnień \sum_k . Następnie należy ponownie oszacować parametry modelu dla tej samej próbki, używając opóźnienia $k - r$ i obliczyć macierz wariancji–kowariancji reszt \sum_{k-r} . Należy podkreślić, że macierz \sum_{k-r} dotyczy układu n równań z $(k - r) \cdot n$ ograniczeniami w każdym równaniu, czyli ogólnie z $(k - r) \cdot n^2$ ograniczeniami. Statystyka testu LR ma postać

$$ALR = (T - c)(\ln|\sum_{k-r}| - \ln|\sum_k|) \sim \chi^2_v \quad (7.17)$$

gdzie

T – liczba obserwacji w próbie;

c – liczba estymowanych parametrów każdego równania modelu VAR z maksymalną liczbą opóźnień;

$v = (k - r) \cdot n^2$ – liczba stopni swobody rozkładu χ^2 .

Innym sposobem ustalenia długości opóźnień jest wykorzystanie kryteriów informacyjnych. Najpopularniejszymi kryteriami informacyjnymi jest kryterium Akaikego (ang. *Akaike Information Criterion* – AIC) oraz bayesowskie kryterium informacyjne Schwartza (ang. *Bayes Information Criterion* – BIC). Wzory na te kryteria w przypadku metody najmniejszych kwadratów można sformułować w kategoriach logarytmu funkcji wiarygodności:

– kryterium informacyjne Akaikego (AIC)

$$AIC(k) = -\frac{2l(\hat{\theta})}{T} + \frac{2n^2k}{T} \quad (7.18)$$

– kryterium informacyjne Schwartza (BIC)

$$BIC(k) = -\frac{2l(\hat{\theta})}{T} + \frac{n^2k \ln(T)}{T} \quad (7.19)$$

gdzie

$l(\hat{\theta})$ – logarytm funkcji wiarygodności dla oszacowanego wektora parametrów;

k – liczba parametrów modelu;

T – liczba obserwacji.

Wykorzystując powyższe kryteria, do modelu wybieramy ten rząd opóźnień, dla którego wartość wybranego kryterium jest najmniejsza, ponieważ oznacza to najmniejszą utratę informacji.

Różnica między kryteriami AIC a BIC polega na innym wazeniu jakości dopasowania i prostoty modelu. Drugi element sumy we wzorach (7.18) i (7.19) mierzy prostotę modelu. W obu przypadkach element ten rośnie wraz ze wzrostem liczby parametrów, który jest tym większy, im mniejsza jest liczba obserwacji. Takie zdefiniowanie kryterium informacyjnego związane jest z tym, iż prostota modelu jest szczególnie ważna w przypadku modeli szacowanych na małych próbach. Jakkolwiek asymptotycznie oba kryteria będą wybierać jako prawidłowy model prawdziwy, to jednak w małych próbach ich wskazania mogą znacznie się różnić. W literaturze sugeruje się, że kryterium AIC ma tendencję do wybierania modelu o zbyt dużej liczbie parametrów.

Po ustaleniu wymiaru opóźnień, kolejnym etapem jest weryfikacja założeń odnoszących się do reszt modelu. Warunkiem koniecznym jest, aby reszty z kolejnych równań modelu były stacjonarne. Weryfikacja stacjonarności reszt przebiega według np. testu ADF. Chociaż w procesach integrowanych rzędu pierwszego za każdym razem występuje autokorelacja, to nie zawsze oznacza to proces niestacjonarny. W tym przypadku może występować jedynie stacjonarność średniej i wariancji. Zatem oprócz weryfikacji stacjonarności niezbędne jest również zbadanie występowania autokorelacji reszt. Należy jednak pamiętać, iż w przypadku modeli VAR może występować autokorelacja zarówno pierwszego, jak i k -tego rzędu. Z tego między innymi powodu wykorzystanie popularnego testu Durбина–Watsona nie jest możliwe. W tym przypadku zastosowanie znajduje test Godfrey'a seryjnej autokorelacji reszt weryfikujący autokorelację dowolnego rzędu. Kolejne etapy weryfikacji własności reszt modelu obejmują badanie normalności oraz homoskedastyczności zakłóceń. Weryfikacja normalności reszt przebiega z zastosowaniem statystyki Jarque'a–Bery, a weryfikacja jednorodności wariancji według testu LM lub F.

Kolejnym etapem weryfikacji poprawności dopasowania modelu VAR jest testowanie istotności jego parametrów. W pierwszym kroku bada się istotność parametrów wektora zmiennych deterministycznych i eliminuje zmienne nieistotne. Dzięki temu uzyskuje się model z mniejszą liczbą zmiennych, a co za tym idzie, uzyskuje się wyniki mające znaczenie z punktu widzenia interpretacji ekonomicznej. Niezerowość parametrów wektora zmiennych deterministycznych bada się z wykorzystaniem testu ilorazu wiarygodności LR.

Drugi krok to weryfikacja parametrów przy zmiennych opóźnionych, czyli weryfikacja warunków zerowych dla opóźnień zmiennych. Proces ten związany jest z pojęciem przyczynowości.

Przyczynowość

W analizach ekonomicznych czy ekonometrycznych istotne znaczenie ma pojęcie przyczynowości. Przyczyna jest zdarzeniem – zmianą, która ma siłę sprawczą zgodnie z przyrodzoną prawidłowością następstwa zdarzeń (Witkowska i in., 2008).

Zależności przyczynowe mogą mieć charakter deterministyczny lub stochastyczny. W zależności deterministycznej przyczyna zawsze wywołuje określony skutek, a w przypadku zależności stochastycznej nie jest jednoznaczne, że skutek jest zdeterminowany przez przyczynę. W analizach ekonomicznych opartych na szeregach czasowych nie jest wymagane, aby punkty pomiarowe kolejnych obserwacji pokrywały się z odstępami czasu, według których występuje zależność przyczynowa. Zdarza się więc, że jednocześnie zdarzenia pozostają ze sobą w związku przyczynowym. Nie przeczy to jednak zasadzie o asymetryczności związku przyczynowego, który realizowany jest w odpowiednim dla danej zależności odstępie czasowym.

Podczas analizy związków przyczynowych zazwyczaj analizuje się przyczyny bezpośrednie, które występują bezpośrednio na styku w czasie między przyczyną i skutkiem lub stanowią sąsiednie ogniwa w szeregu przyczyn i skutków. W rzeczywistości gospodarczej pojawiający się skutek jest wynikiem jednoczesnego oddziaływania wielu przyczyn (Witkowska i in., 2008).

Analizowanie przyczynowości i jej testowanie służą do weryfikacji teorii ekonomicznych lub do identyfikacji zależności przyczynowych nieopartych rozważaniami teoretycznymi.

Ze względu na dysponowanie w analizach przyczynowości danymi pochodzącymi z konkretnych momentów czy okresów, a nie danymi ciągłymi, w analizach praktycznych dopuszcza się stwierdzenie natychmiastowej i wzajemnej przyczynowości. W analizach ekonomicznych jest rozpatrywana głównie przyczynowość w rozumieniu przyczynowości zdefiniowanej przez Clive'a W.J. Grangera w 1969 r.

Według koncepcji przyczynowości w sensie Grangera (lub Grangera–Wienera) zmienna X jest przyczyną zmiennej Y , co można oznaczyć ($X \rightarrow Y$), jeśli bieżące wartości Y można prognozować z większą dokładnością, wykorzystując przeszłe wartości X , niż bez nich (zakładając niezmiennosc pozostałej informacji), a więc gdy współczynniki przy opóźnionych zmiennych X są statystycznie istotne. Inaczej mówiąc, błąd prognozy wyznaczony dla zmiennej Y będzie mniejszy, jeśli w modelu zostanie uwzględniona zmienna X , niż wtedy, gdy zostanie ona pominięta. Definicję przyczynowości można zapisać w sposób

jeśli $MSE(\hat{y}_t|U_{t-1}) < MSE(\hat{y}_t|U_{t-1}\setminus X_{t-1})$ to $X \rightarrow Y$,

gdzie

U_{t-1} – zbiór wszelkiej przeszłej informacji istniejącej w chwili t ;

X_t – zbiór wszelkiej bieżącej i przeszłej informacji zmiennej X istniejącej w chwili t , $X_t = X_t \{x_1, \dots, x_t\}$, z tym że $X_t \subset U_t$;

y_t – wartość zmiennej y w chwili t ($y_t \subset U_t$);

\hat{y}_t – nieobciążona prognoza zmiennej Y ;

MSE – błąd średniokwadratowy prognozy *ex post*.

Zasadniczo przyszłość nie może przewidzieć przeszłości, jeśli zmienna X jest przyczyną dla zmiennej Y , dlatego też zmiany w X powinny poprzedzać zmiany w Y . Innymi słowy: kiedy identyfikujemy jedną zmienną jako zależną (Y), a drugą jako objaśniającą niezależną (X), zakładamy domyślne założenie, że zmiany w zmiennej objaśniającej wywołują zmiany w zmiennej zależnej. Z tego powodu, jeśli w modelu regresji zmiennej Y opartym na innych zmiennych (w tym własnych wartościach przeszłych) uwzględnimy przeszłe lub opóźnione wartości X , to znacząco poprawia to przewidywanie Y . Możemy zatem powiedzieć, że X jest przyczyną w sensie Grangera zmiennej Y . Podobna definicja ma zastosowanie, jeśli Y jest przyczyną w sensie Grangera zmiennej X (Gujarati, 2003). Jeśli X powoduje Y i Y powoduje X , to dwie zmienne są wspólnie określane i istnieje dwustronna przyczynowość, inaczej nazywana relacją o sprzężeniu zwrotnym lub o wzajemnej przyczynowości, co można oznaczyć w sposób $X \leftrightarrow Y$.

Tak rozumianą przyczynowość można rozszerzyć na przypadek przyczynowości jednoczesnej (natychmiastowej). Przyczynowość natychmiastowa występuje wtedy, jeśli bieżące wartości Y mogą być z lepszym skutkiem prognozowane z użyciem bieżących i przeszłych wartości przy założeniu niezmięnionej pozostałej informacji. Ten wariant przyczynowości można oznaczyć w sposób $X \Leftrightarrow Y$. Formalną definicję można przedstawić w sposób

jeśli $MSE(\hat{y}_t|U_{t-1}, y_t) < MSE(\hat{y}_t|U_{t-1}\setminus X_{t-1}, y_t)$ to $X \rightarrow Y$,

gdzie

U_{t-1} – zbiór wszelkiej bieżącej i przeszłej informacji istniejącej w chwili t .

Występowanie przyczynowości podlega weryfikacji statystycznej. Istnieje kilka różnych procedur testowania przyczynowości w sensie Grangera. Jedną z nich jest procedura zaprezentowana przez Ramanathana (2002). Rozważamy model z pełną informacją

$$Y_t = \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{j=1}^q \beta_j X_{t-j} + u_t, \quad (7.20)$$

który porównujemy z modelem z tzw. restrykcjami

$$Y_t = \sum_{i=1}^p \alpha_i Y_{t-i} + \vartheta_t, \quad (7.21)$$

gdzie

- u_t, ϑ_t – składniki losowe (biały szum);
- p – kolejność opóźnień dla zmiennej Y ;
- q – opóźnienie dla zmiennej X .

Jeśli $\beta_j = 0$ dla $j = 1, 2, \dots, q$, to X nie jest przyczyną Y w sensie Grangera. Nałożenie restrykcji polega na usunięciu z modelu z pełną informacją składowej, która oznacza wpływ zmiennej X na zmienną Y .

W teście weryfikującym istnienie przyczynowości formułuje się następujące hipotezy

- $H_0: \beta_j = 0$ dla $j = 1, \dots, q$;
- $H_1: \beta_j \neq 0$ dla $j = 1, \dots, q$.

Do weryfikacji hipotezy występowania przyczynowości można wykorzystać statystykę Walda

$$W = \frac{(SSE^* - SSE)}{SSE} T \quad (7.22)$$

lub statystykę LR (LR_G)

$$LR_G = \ln \left(\frac{SSE^*}{SSE} \right) T,$$

czy statystykę LM (LM_G)

$$LM_G = \frac{(SSE^* - SSE)}{SSE^*} T, \quad (7.23)$$

gdzie

- T – liczba obserwacji;
- SSE^* – suma kwadratów reszt dla modelu z restrykcjami (7.21);
- SSE – suma kwadratów reszt dla modelu z pełną informacją (7.20).

Wszystkie wymienione powyżej statystyki są asymptotycznie zbieżne do rozkładu χ^2 o q stopniach swobody i mogą być stosowana dla dużych prób.

Należy pamiętać, że w analizie i teście przyczynowości, między innymi przyczynowości w sensie Grangera, wymagana jest stacjonarność zmiennych (Gu-

jarati, 2003). Metody weryfikacji stacjonarności zmiennych zostały wcześniej przedstawione.

Modele VAR nie służą wyłącznie do opisu relacji między zmiennymi i ich opóźnieniami, ale również są wdzięcznym narzędziem do prognozowania. Znajdują one szerokie zastosowanie w wyznaczaniu prognoz dynamicznych. Ze względu na to, że w modelach są wyłącznie zmienne endogeniczne i deterministyczne elementy wektora D_t (wyraz wolny, zmienna czasowa, zmienna binarna), to nie ma konieczności formułowania założeń odnośnie do wartości zmiennych egzogenicznych w okresie prognozowanym. Modele VAR służą przede wszystkim prognozom krótkoterminowym. W przypadku prognoz długoterminowych istotne jest uprzednie ustalenie stałości parametrów równań dla okresów estymacji i predykcji. Służy do tego test badający stałość parametrów, czyli powszechnie stosowany test Chowa (Kusideł, 2000). Statystyka testu Chowa ma postać

$$ChT = \frac{\left[(RSS^* - RSS) / (T^* - T) \right]}{RSS / (T - k)}, \quad (7.24)$$

gdzie

RSS^* – suma kwadratów reszt dla modelu oszacowanego na podstawie danych z obu okresów, tj. z próby i prognoz, czyli dla $t = 1, \dots, T, T + 1, \dots, T^*$;

RSS – suma kwadratów reszt dla modelu oszacowanego dla okresu $t = 1, \dots, T$;

k – liczba szacowanych parametrów w równaniu.

Statystyka testu Chowa ma asymptotyczny rozkład F z $(T^* - T)$ i $(T - k)$ stopniami swobody. Odrzucenie hipotezy zerowej ($ChT < F_{(T^*-T), (T-k)}$) oznacza, że parametry modelu oszacowanego dla okresów próby i prognozy nie są takie same (Kusideł, 2000).

Chcąc dopełnić weryfikację modelu autoregresji wektorowej, można jeszcze zbadać korelację składników losowych poszczególnych równań. Macierz wariancji–kowariancji błędów losowych modelu jest postaci

$$\Sigma_e = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2n} \\ \cdots & \cdots & \cdots & \cdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{bmatrix},$$

gdzie σ_{ij} oznacza jednoczesne kowariancje zakłóceń i -tego i j -tego równania modelu dla $i \neq j$ oraz wariancje zakłóceń dla $i = j, t = 1, \dots, T$.

W celu weryfikacji jednoczesnej współzależności składników losowych z poszczególnych równań formułuje się łączną hipotezę zerową

$$\begin{aligned} H_0: \sigma_{12} &= \sigma_{13} = \dots = \sigma_{1n} = 0, \\ \sigma_{23} &= \dots = \sigma_{2n} = 0, \\ &\dots, \\ \sigma_{nn} &= 0. \end{aligned}$$

Odrzucenie hipotezy zerowej oznacza, że jedna lub więcej kowariancji jest różna od zera. Weryfikację tak sformułowanej hipotezy przeprowadza się z wykorzystaniem statystyki testowej LR postaci

$$LR(H_0|H_1) = 2(LL_u - LL_R), \quad (7.25)$$

gdzie

LL_u – maksymalna wartość logarytmu funkcji wiarygodności obliczona dla całego modelu;

LL_R – suma maksymalnych wartości logarytmu funkcji wiarygodności liczonych dla każdego z poszczególnych równań.

Podstawą konstrukcji testu jest założenie, że przy prawdziwości hipotezy zerowej prawdziwa jest równość

$$LL_u = LL_R.$$

Statystyka testowa $LR(H_0|H_1)$ ma rozkład χ^2 z liczbą stopni swobody $\frac{n(n-1)}{2}$, gdzie n oznacza liczbę równań w modelu. Hipotezę zerową odrzuca się, jeżeli $LR(H_0|H_1) < \chi^2_{\frac{n(n-1)}{2}}$ (Kusideł, 2000).

Strukturalny model autoregresji wektorowej SVAR

Alternatywę dla klasycznych modeli VAR stanowią strukturalne modele VAR(SVAR). Są to modele zgodne z teorią ekonomiczną, które znajdują zastosowanie w analizie polityki ekonomicznej. Ich konstrukcja jest możliwa dzięki założeniu, że wielowymiarowy składnik losowy w podstawowym równaniu modelu VAR może charakteryzować się niezerowymi kowariancjami $\text{cov}(\varepsilon_{it}, \varepsilon_{jt}) \neq 0$, zatem istnieją powiązania między składnikami losowymi poszczególnych równań modelu. Strukturalny model VAR ma postać

$$B y_t = \Gamma_0 D_t + \Gamma_1 y_{t-1} + \Gamma_2 y_{t-2} + \dots + \Gamma_k y_{t-k} + \zeta_t, \quad (7.26)$$

gdzie

B – macierz parametrów przy nieopóźnionych zmiennych wektora y_t

$$\mathbf{B} = \begin{bmatrix} 1 & b_{12} & \cdots & b_{1n} \\ b_{21} & 1 & \cdots & b_{2n} \\ \cdots & \cdots & 1 & \cdots \\ b_{n1} & b_{n2} & \cdots & 1 \end{bmatrix}$$

y_t – wektor obserwacji na bieżących wartościach wszystkich zmiennych w modelu

$$y_t = [y_{1t}, y_{2t}, \dots, y_{nt}]';$$

Γ_0 – macierz parametrów przy zmiennych wektora D_t ;

D_t – wektor deterministycznych składników równania;

Γ_i – dla $i = 1, 2, \dots, k$ macierze parametrów przy opóźnionych zmiennych y_t ;

ξ_t – $(n \times 1)$ – wektor zakłóceń losowych modelu strukturalnego.

Powiązanie modelu SVAR z klasycznym modelem VAR otrzymuje się poprzez przemnożenie równania modelu SVAR przez macierz \mathbf{B}^{-1}

$$y_t = \mathbf{B}^{-1}\Gamma_0 + \mathbf{B}^{-1}\Gamma_1 y_{t-1} + \mathbf{B}^{-1}\Gamma_2 y_{t-2} + \dots + \mathbf{B}^{-1}\Gamma_k y_{t-k} + \mathbf{B}^{-1}\xi_t. \quad (7.27)$$

Przyjmując następujące oznaczenia

$$\mathbf{A}_0 = \mathbf{B}^{-1}\Gamma_0,$$

$$\mathbf{A}_i = \mathbf{B}^{-1}\Gamma_i, \quad i = 1, 2, \dots, k,$$

$$e_t = \mathbf{B}^{-1}\xi_t,$$

uzyskuje się równanie klasycznego modelu VAR

$$y_t = \mathbf{A}_0 + \mathbf{A}_1 y_{t-1} + \mathbf{A}_2 y_{t-2} + \dots + \mathbf{A}_k y_{t-k} + e_t, \quad (7.28)$$

przy czym występuje zależność między macierzami wariancji–kowariancji obu postaci modelu VAR. Zależność tę zapisuje się następująco

$$\Sigma_\xi = \mathbf{B}\Sigma_e\mathbf{B}^T, \quad (7.29)$$

gdzie

Σ_ξ – diagonalna macierz wariancji–kowariancji składnika losowego w modelu SVAR;

Σ_e – macierz wariancji–kowariancji składnika losowego modelu VAR.

Strukturalna postać modelu VAR służy do oszacowania i interpretacji funkcji odpowiedzi na impuls oraz do dekompozycji wariancji błędów prognozy. Składniki losowe modelu SVAR nie są skorelowane, a zatem równania modelu mogą być oddzielnie wykorzystywane do analizy polityki gospodarczej. Przy takim podejściu analiza ta może dotyczyć wpływu określonego zaburzenia losowego na cały model. Jest to wówczas tzw. analiza funkcji odpowiedzi na impuls. W tym przypadku bierze

się pod uwagę model wektorowej średniej ruchomej VMA, który wyraża zmienne wektora x_t za pomocą składników losowych modelu strukturalnego i jest postaci

$$y_t = \mu + \sum_{i=0}^{\infty} \Phi_i \xi_{t-i}, \quad (7.30)$$

gdzie $\phi_i = A_1^i B^{-1}$. Zakładając, że macierz $\Phi_i = [\phi_{jk}(i)]$, to kolejne wartości $\phi_{jk}(i)$ dla $i = 1, 2, \dots, T$ stanowią funkcję odpowiedzi na impuls (Witkowska i in., 2008). Wartości $\phi_{jk}(i)$ pokazują reakcję poszczególnych zmiennych modelu na jednostkowe zaburzenie k -tej zmiennej o i -okresów wcześniej (Witkowska i in., 2008). Innymi słowy wartości te pokazują reakcję poszczególnych zmiennych na różne impulsy w niezależnych zaburzeniach modelu strukturalnego.

Dekompozycja wariancji błędu prognoz zmiennych ma natomiast na celu wyjaśnienie, jaki udział w wyjaśnieniu błędu danej zmiennej mają inne zmienne systemu (Witkowska i in., 2008). Niech prognoza o dowolnym horyzoncie czasowym n wynosi

$$E_t y_{t+n} = (I + A_1 + A_1^2 + \dots + A_1^{n-1}) A_0 + A_1^n y_t, \quad (7.31)$$

z błędem równym

$$e_{t+n} + A_1 e_{t+n-1} + A_1^2 e_{t+n-2} + \dots + A_1^{n-1} e_{t+1}. \quad (7.32)$$

Wariancję błędu prognozy dla j -tej zmiennej w modelu na T^* okresów w przyszłości zapisuje się jako

$$\sigma_{y_j}^2(T^*) = \sum_{k=1}^K \left[\sigma_{y_k}^2 \cdot \sum_{i=0}^{n-1} (\phi_{jk}(i))^2 \right]. \quad (7.33)$$

Wariancja błędu prognozy rozdzielana jest na udziały według zaburzeń przyporządkowanych poszczególnym równaniom w modelu VAR. Udział zaburzenia ξ_{kt} w wariancji prognozy dla j -tej zmiennej przyjmuje postać

$$\sigma_{y_j}^2 = \frac{\sigma_{y_k}^2 \cdot \sum_{i=0}^{n-1} (\phi_{jk}(i))^2}{\sigma_{y_i}^2(T^*)}. \quad (7.34)$$

Zarówno przy konstrukcji funkcji odpowiedzi na impuls, jak i przy dekompozycji macierzy istotne jest ustalenie kolejności zmiennych. Dokonuje się tego podczas tzw. dekompozycji Choleskiego, która określana jest również jako porządko-

wanie zmiennych. W efekcie dekompozycji Choleskiego zmienne porządkuje się według ich „ważności”. Zmienna, której zaburzenia wpływają na wszystkie pozostałe zmienne, określana jest mianem priorytetowej lub najbardziej egzogenicznej w modelu. Zmienna, na która mają wpływ wszystkie zaburzenia w pozostałych zmiennych, nazywa się najbardziej endogeniczną w modelu (Kusideł, 2000). Ustalona w ten sposób kolejność ma wpływ na wyniki związane z dekompozycją wariancji oraz wartości funkcji odpowiedzi na impuls (Kusideł, 2000; Witkowska i in., 2008).

Niech model SVAR będzie modelem z trzema zmiennymi objaśniającymi

$$\begin{aligned}w_t &= a_{10} + a_{11}w_{t-1} + a_{12}y_{t-1} + a_{13}z_{t-1} + e_{wt}, \\y_t &= a_{20} + a_{21}w_{t-1} + a_{22}y_{t-1} + a_{23}z_{t-1} + e_{yt}, \\z_t &= a_{30} + a_{31}w_{t-1} + a_{32}y_{t-1} + a_{33}z_{t-1} + e_{zt}.\end{aligned}\tag{7.35}$$

Strukturalną postać tego modelu można zapisać jako

$$\begin{aligned}w_t &= \gamma_{10} + b_{12}y_t + b_{13}z_t + \gamma_{11}w_{t-1} + \gamma_{12}y_{t-1} + \gamma_{13}z_{t-1} + \xi_{wt}, \\y_t &= \gamma_{20} + b_{22}y_t + b_{23}z_t + \gamma_{21}w_{t-1} + \gamma_{22}y_{t-1} + \gamma_{23}z_{t-1} + \xi_{yt}, \\z_t &= \gamma_{30} + b_{32}y_t + b_{33}z_t + \gamma_{31}w_{t-1} + \gamma_{32}y_{t-1} + \gamma_{33}z_{t-1} + \xi_{zt},\end{aligned}\tag{7.36}$$

znając oszacowania parametrów modelu (7.35) parametrów modelu strukturalnego bez nakładania dodatkowych ograniczeń. Problem identyfikacji postaci modelu strukturalnego jest rozwiązywany poprzez nałożenie na macierz

$$\mathbf{B} = \begin{bmatrix} 1 & b_{12} & b_{13} \\ b_{21} & 1 & b_{23} \\ b_{31} & b_{32} & 1 \end{bmatrix}$$

tylu ograniczeń zerowych, ile wynosi różnica między nieznanymi i znanymi oszacowaniami parametrów. Jedną z możliwości identyfikacji postaci modelu strukturalnego jest przekształcenie go do systemu równań rekurencyjnych, czyli strukturyzacja rekursywna. Jeżeli model składa się z trzech równań, to przekształcenie to oznacza nałożenie trzech ograniczeń na macierz \mathbf{B}

$$\mathbf{B}^* = \begin{bmatrix} 1 & 0 & 0 \\ b_{21} & 1 & 0 \\ b_{31} & b_{32} & 1 \end{bmatrix}.$$

Jako że macierz \mathbf{B}^* jest nieosobliwa, to istnieje macierz

$$\mathbf{B}^{-1} = \begin{bmatrix} 1 & 0 & 0 \\ -b_{21} & 1 & 0 \\ b_{21}b_{32} - b_{31} & -b_{32} & 1 \end{bmatrix}.$$

Taką postać macierz \mathbf{B}^{*-1} wartości reszt modelu (7.35) można wyznaczyć jako

$$\begin{aligned} e_{wt} &= \zeta_{wt}, \\ e_{yt} &= -b_{21}\zeta_{wt} + \zeta_{yt}, \\ e_{zt} &= (b_{21}b_{32} - b_{31})\zeta_{wt} + b_{32}\zeta_{yt} + \zeta_{zt}. \end{aligned} \tag{7.37}$$

Dekompozycja Choleskiego jest właśnie taką „trójkątną” dekompozycją, w tym przypadku reszt e_t modelu (Kusideł, 2000).

Test Baia-Perrona

Istotnym zagadnieniem w ekonometrii jest testowanie zmian strukturalnych. Niezliczona liczba czynników, w tym politycznych czy ekonomicznych, może z czasem zmieniać relacje między zmiennymi ekonomicznymi. Quandt (1958) i Chow (1960) w swoich pracach uwzględniali testy zmian strukturalnych dla znanej pojedynczej daty zmiany. Badania te zmierzały do modelowania, w którym ta data zmiany jest traktowana jako nieznaną zmienną. Quandt (1960) rozszerzył test Chowa i zaproponował przyjęcie największej statystyki Chowa w odniesieniu do wszystkich możliwych dat zmian. W tym samym kontekście najważniejszy wkład w badania przypisuje się Andrewsowi i Plobergerowi (Andrews, 1993; Andrews i Ploberger, 1994), którzy rozważali kompleksową analizę problemu testowania zmian strukturalnych (Önel, 2005).

Dzięki Perronowi (1989) obecnie dobrze jest znane zjawisko, w którym widoczna trwałość w danych makroekonomicznych może być wynikiem niewymodelowanych załamań strukturalnych w procesie danych bazowych. Seria, która wydaje się być dobrze zamodelowana jako proces $I(1)$, może w rzeczywistości być procesem stacjonarnym z jedną lub kilkoma przerwami strukturalnymi. Perron (1989) przeprowadził standardowe testy weryfikujące hipotezę istnienia pierwiastka jednostkowego wobec trend-stacjonarnych alternatyw z przełamaniem trendu. Badania i testy Perrona wskazały na odrzucenie zerowej hipotezy występowania pierwiastka jednostkowego dla większości serii, jeśli prawdziwym procesem generowania danych jest stacjonarna fluktuacja wokół funkcji trendu, która zawierała jedną przerwę strukturalną. W tym samym kontekście Zivot i Andrews (1992) przeanalizowali odmianę testów Perrona, w których data przerwy jest szacowana, a nie ustalona (Jouni i Boutahar, 2005; Önel, 2005).

Makroekonomiczne szeregi czasowe bardzo często mogą zawierać więcej niż jedną zmianę strukturalną. Bai i Perron (1998, 2003, 2004) przedstawili kompleksową analizę kilku zagadnień w kontekście modeli wielu zmian strukturalnych. Zaproponowali oni kilka sposobów testowania zmian strukturalnych dla przypadku bez regresorów trendujących i w celu oszacowania liczby punktów zmian procedurę selekcji opartą na sekwencji testów. Badacze przeanalizowali wielkość i moc testów zmian strukturalnych, wskaźniki zasięgu przedziałów ufności dla dat zmian oraz względne zalety i wady procedur wyboru modeli.

Metodologia Baia–Perrona (1998, 2003) oparta jest na następującym modelu regresji wielorakiej z m zmianami ($m + 1$ reżimami) (Ben Aïssa i Jouni, 2003; Ben Aïssa i in., 2004; Önel, 2005)

$$y_t = x_t' \beta + z_t' \delta_1 + u_t, t = 1, \dots, T_1, \quad (7.38)$$

$$y_t = x_t' \beta + z_t' \delta_2 + u_t, t = T_1 + 1, \dots, T_2,$$

...

$$y_t = x_t' \beta + z_t' \delta_{m+1} + u_t, t = T_m + 1, \dots, T,$$

gdzie

y_t – obserwowana zmienna zależna w czasie t ;

$x_t(p \times 1)$ oraz $z_t(q \times 1)$ – wektory zmiennych;

β oraz $\delta_j (j = 1, \dots, m + 1)$ – odpowiednie wektory współczynników w modelu;

u_t – składnik losowy w czasie t .

Momenty zmian (T_1, \dots, T_m) w szeregu są traktowane jako nieznanne i są szacowane razem z nieznanymi współczynnikami modelu na podstawie T obserwacji. Ze względu na to, że parametr β nie podlega przesunięciom i jest szacowany z użyciem całej próbki, model ten jest modelem częściowej zmiany strukturalnej. W przypadku gdy $p = 0$, to otrzymujemy tzw. czysty model zmiany strukturalnej, w którym wszystkie współczynniki mogą ulec zmianie. Zakłada się, że wariancja dla składnika losowego u_t nie musi być stała, a przerwy w wariancji są dozwolone pod warunkiem, że występują w tych samych momentach co przerwy w parametrach funkcji regresji.

Powyższy liniowy model regresji wielorakiej można przedstawić w formie macierzowej

$$Y = X\beta + \bar{Z}\delta + U, \quad (7.39)$$

gdzie $Y = (y_1, \dots, y_T)'$, $X = (x_1, \dots, x_T)'$, $U = (u_1, \dots, u_T)'$, $\delta = (\delta_1, \dots, \delta_T)'$ są wektorami, a \bar{Z} jest macierzą diagonalną, która po przekątnej rozdziela macierz Z na m -partycje (T_1, \dots, T_m) , tj. $\bar{Z} = \text{diag}(Z_1, \dots, Z_{m+1})$, w której $Z_i = (z_{\tau_{i-1}+1}, \dots, z_{\tau_i})'$.

Celem metody jest oszacowanie nieznanych współczynników regresji oraz dat przerw, tj. $(\beta, \delta_1, \dots, \delta_m, T_1, \dots, T_m)$, na podstawie obserwacji (y_t, x_t, z_t) z wykorzystaniem metody najmniejszych kwadratów zaproponowanej przez Baia i Perrona (1998).

Dla każdej m -partycji (T_1, \dots, T_m) , oznaczonej $\{T_j\}$, parametr δ_j jest oszacowany przez zminimalizowanie sumy kwadratów reszt

$$\sum_{i=1}^{m+1} \sum_{t=T_{i-1}}^{T_i} (y_t - z_t' \delta_i)^2. \quad (7.40)$$

Jeśli $\hat{\beta}(\{T_j\})$ oraz $\hat{\delta}(\{T_j\})$ oznaczają wynikowy szacunek, to uwzględniając je w funkcji celu i oznaczając wynikową sumę kwadratów reszt jako $S_T(T_1, \dots, T_m)$, szacowane daty przerw $(\hat{T}_1, \dots, \hat{T}_m)$ są takie, że

$$(\hat{T}_1, \dots, \hat{T}_m) = \arg \min_{T_1, \dots, T_m} S_T(T_1, \dots, T_m), \quad (7.41)$$

gdzie minimalizacja jest przejmowana przez wszystkie partycje takie, że $T_i - T_{i-1} \geq q$. Według Baia i Perrona (2003a), jeśli nie są wymagane testy, a szacowanie jest jedynym problemem, wówczas minimalna liczba obserwacji w każdym segmencie może zostać ustawiona na dowolną wartość większą niż q . Z tego powodu estymatory punktu załamania/przerwy są tzw. globalnymi minimizerami funkcji celu. Ostatecznie estymatory parametrów regresji są powiązаныmi estymatorami parametrów dla poszczególnych m -partycji $\{T_j\}$, tzn. $\hat{\beta} = \hat{\beta}(\{T_j\})$ oraz $\hat{\delta} = \hat{\delta}(\{T_j\})$.

Bai i Perron (2003a) do identyfikacji punktów przerwy zaproponowali opracowany według zasady programowania dynamicznego algorytm, który pozwala na uzyskanie globalnych minimalizatorów z użyciem pewnej liczby sum kwadratów reszt, które są rzędu $O(T^2)$ dla dowolnego $m \geq 2$.

Bai i Perron (1998) rozważając oszacowanie wielu zmian strukturalnych w modelu liniowym, opracowali trzy testy.

W pierwszej kolejności wzięli pod uwagę test *sub F* stabilności strukturalnej. Hipotezą alternatywną w tym teście jest założenie, że istnieje znana liczba przerw n . Niech (T_1, \dots, T_k) oznacza partycje, gdzie $T_i = [T\lambda_i]$ ($i = 1, \dots, k$). Statystyka dla powyższego testu jest zdefiniowana następująco

$$F_T(\lambda_1, \dots, \lambda_n; q) = \frac{1}{T} \left(\frac{T - (n+1)q}{nq} \right) \hat{\delta}' R' (R \hat{V}(\hat{\delta}) R')^{-1} R \hat{\delta}, \quad (7.42)$$

gdzie

\mathbf{R} – macierz taka, że $(R\delta)' = (\delta'_1 - \delta'_2, \dots, \delta'_n - \delta'_{n+1})$;

$\hat{\mathbf{V}}(\hat{\delta})$ – macierz kowariancji dla $\hat{\delta}$ odporna na szeregową korelację i heteroskedastyczność, tj. oznacza spójne oszacowanie $\hat{\mathbf{V}}(\hat{\delta}) = p \lim T(\bar{Z}'\bar{Z})^{-1} \bar{Z}'\Omega\bar{Z}(\bar{Z}'\bar{Z})^{-1}$, przy $\Omega = E(UU')$.

Statystykę $\sup F$ można zatem zapisać w postaci:

$$\sup F_T(n; q) = \sup_{(\lambda_1, \dots, \lambda_n) \in A_\varepsilon} F_T(\lambda_1, \dots, \lambda_n; q) = F_T(\hat{\lambda}_1, \dots, \hat{\lambda}_n; q), \quad (7.43)$$

gdzie oszacowanie frakcji przerw $(\hat{\lambda}_1, \dots, \hat{\lambda}_n)$ minimalizuje globalną sumę kwadratów reszt. W zależności od założeń dokonanych w odniesieniu do dystrybucji regresorów i błędów między segmentami można uzyskać różne wersje tych testów (Bai i Perron, 2003a).

Kolejnym testem rozważanym przez Baia i Perrona (1998) był test braku zmian strukturalnych w stosunku do nieznannej liczby przerw, zważywszy na pewną górną granicę liczby przerw M dla m . Nowa klasa testów nosi nazwę podwójnych testów maksymalnych i jest zdefiniowana dla określonych stałych wag $\{a_1, \dots, a_M\}$ jako:

$$\begin{aligned} D \max F_T(M, q, a_1, \dots, a_M) &= \max_{1 \leq m \leq M} a_m \sup_{(\lambda_1, \dots, \lambda_n) \in A_\varepsilon} F_T(\lambda_1, \dots, \lambda_n; q) = \\ &= \max_{1 \leq m \leq M} a_m F_T(\hat{\lambda}_1, \dots, \hat{\lambda}_n; q). \end{aligned} \quad (7.44)$$

Wagi $\{a_1, \dots, a_M\}$ mogą odzwierciedlać narzucenie określonych pierwowzorów na prawdopodobieństwo różnej liczby przerw strukturalnych. Oczywistym podejściem jest przyjęcie wszystkich wag równych jedności, tj. $a_m = 1$. Tę wersję testu oznacza się jako $UD \max F_T(M, q)$. Następnie rozważany jest taki zestaw wag, że krańcowe wartości p są równe wartościom m . Wagi są definiowane w sposób: $a_1 = 1$ i $a_m = c(q, \alpha, 1) / c(q, \alpha, m)$, dla $m > 1$, gdzie α to poziom istotności testu, a $c(q, \alpha, m)$ jest asymptotyczną krytyczną wartością testu $\sup_{(\lambda_1, \dots, \lambda_n) \in A_\varepsilon} F_T(\lambda_1, \dots, \lambda_n; q)$. Ta wersja testu jest oznaczona jako $WD \max F_T(M, q)$.

Ostatnim testem opracowanym przez Baia i Perrona (1998) jest sekwencyjny test l zmian/przerw strukturalnych przeciwko $l + 1$ zmianom/przerwom. W tym teście hipoteza zerowa zakłada istnienie l przerw przeciwko alternatywnej, że istnieje $l + 1$ przerw. Dla modelu z l przerwami oszacowane zmiany/przerwy $\hat{T}_1, \dots, \hat{T}_l$ są wyznaczone na podstawie globalnej sumy najmniejszych kwadratów reszt. W celu identyfikacji dodatkowej przerwy/zmiany testuje się $l + 1$ sekwencji (uzyskanych z użyciem szacowanej partycji $(\hat{T}_1, \dots, \hat{T}_l)$). Zatem test sprowadza się do przeprowadzenia $l + 1$ testów z hipotezą zerową o braku zmian strukturalnych w porównaniu

z alternatywną hipotezą pojedynczej zmiany. Ta procedura jest stosowana do każdego segmentu zawierającego obserwacje od $\hat{T}_{i-1} + 1$ do $\hat{T}_i (i = 1, \dots, l + 1)$, przy czym $\hat{T}_0 = 0$ i $\hat{T}_{l+1} = T$. O odrzucenie hipotezy zerowej na korzyść modelu z $l + 1$ przerwami wnioskuje się, jeśli całkowita minimalna wartość sumy kwadratów reszt jest wystarczająco mniejsza od sumy kwadratów reszt dla modelu z l przerwami. W ten sposób wybrana zostaje data przerwy, która jest związana z tym ogólnym minimum. Statystyka testu jest zdefiniowana następująco

$$F_T(l+1|l) = \frac{S_T(\hat{T}_1, \dots, \hat{T}_l) - \min_{1 \leq i \leq l+1} \inf_{\tau \in A_{i,\eta}} S_T(\hat{T}_1, \dots, \hat{T}_{i-1}, \tau, \hat{T}_i, \dots, \hat{T}_l)}{\hat{\sigma}^2}, \quad (7.45)$$

gdzie

$$A_{i,\eta} = \{\tau, \hat{T}_{i-1} + (\hat{T}_i - \hat{T}_{i-1})\eta \leq \tau \leq \hat{T}_i - (\hat{T}_i - \hat{T}_{i-1})\eta\};$$

$\hat{\sigma}^2$ – zgodny estymator σ^2 w hipotezie zerowej. Dla $i = 1$, $S_T(\hat{T}_1, \dots, \hat{T}_{i-1}, \tau, \hat{T}_i, \dots, \hat{T}_l)$ jest rozumiany jako $S_T(\tau, \hat{T}_i, \dots, \hat{T}_l)$, a dla $i = l + 1$ jako $S_T(\hat{T}_1, \dots, \hat{T}_l, \tau)$.


Bai i Perron (1998, 2003b) w swoich pracach zaprezentowali ponadto asymptotyczne rozkłady tych trzech omówionych testów, a także obliczone wartości krytyczne.

8. Empiryczna identyfikacja relacji cenowych między ropą naftową, złotem i pszenicą

W latach 2000–2017 ceny na rynku towarów charakteryzowały się bardzo dużą zmiennością. Towary stały się zróżnicowaną klasą aktywów, przez co poszerzyły możliwości inwestycyjne inwestorów zarówno instytucjonalnych, jak i indywidualnych. Duży wpływ na wzrosty cen towarów w pierwszej dekadzie XXI w. miała między innymi deprecjacja dolara amerykańskiego – waluty, w której wyceniana jest większość surowców. Bessa na rynku akcji w latach 2000–2002 wywołana pęknięciem bańki spekulacyjnej na rynku nowych technologii przyczyniła się do obniżenia stóp procentowych przez Rezerwę Federalną. Spadek kosztu pieniądza w Stanach Zjednoczonych doprowadził natomiast do deprecjacji amerykańskiej waluty, a w dalszej kolejności do wzrostu ogólnego poziomu cen, w tym także większości surowców.

Początek XXI w. przyniósł także duże zmiany po stronie popytu i podaży surowców. Bardzo szybkie tempo wzrostu gospodarek rozwijających się, w tym Chin, Brazylii i Indii, wpłynęło na wzrost zapotrzebowania na surowce energetyczne, metale oraz towary rolne. Dodatkowo wzrost popytu na surowce wynikał z włączania tej klasy aktywów do portfeli inwestycyjnych dużych korporacyjnych i państwowych funduszy inwestycyjnych i emerytalnych, a także klientów indywidualnych. Laidi (2012) pokazał, że na koniec 1998 r. fundusze inwestycyjne przeznaczone dla aktywów z rynku towarowego zarządzały kwotą 10 mld USD, na koniec 2007 r. kwotą 142 mld, a do połowy 2008 r. suma ta wzrosła do 250 mld. W latach 2003–2008 odnotowano duże wzrosty cen na rynku metali, surowców energetycznych (w tym przede wszystkim ropy naftowej) i wybranych towarów rolnych. Połączone z rosnącym popytem na surowce deprecjacja dolara amerykańskiego oraz wysoka inflacja ukształtowały jeden z największych w historii trendów wzrostowych na rynku surowców.


Na rysunku 8.1 przedstawiono kształtowanie się dziennych cen złota i ropy naftowej w latach 2000–2017. W okresie od stycznia 2000 do marca 2008 r. zarówno ceny złota, jak i ropy naftowej poruszały się w tendencji wzrostowej (rys. 8.1). Kryzys finansowy początku XXI w. wywołał wiele zmian w zależnościach między cenami na rynku finansowym. Od 2008 do 2017 r. można zaobserwować bardzo dużą zmienność cen ropy naftowej i złota (rys. 8.1). Dodatkowo ta zależność między cenami badanych surowców jest złożona i trudna do przewidzenia. Po 2008 r. zmienność cen na rynku surowców coraz bardziej przypomina zmienność cen na rynku akcji czy walutowym, czyli rynkach o dużej płynności oraz wielu uczestnikach zarabiających głównie na zmienności cen (Jain i Biswal, 2016; Kumar, 2017).



Rysunek 8.1. Kształtowanie się dziennych cen złota (oś lewa) i cen ropy naftowej (oś prawa) w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Porównując ceny ropy naftowej i pszenicy na przestrzeni lat 2000–2017, daje się zauważyć, iż w początkowym okresie, tj. do stycznia 2001 r., ceny obu surowców nie wykazywały znaczącej zmienności i były mniej więcej na tym samym poziomie (rys. 8.2). W kolejnych latach zwiększyła się różnica między cenami ropy naftowej i pszenicy, przy czym ceny tej drugiej były wyższe. Gwałtowny wzrost ceny pszenicy odnotowano pod koniec 2003 r. W kolejnym okresie poziomy ceny ponownie się wyrównały, aby od początku 2005 r. zamienić się rolami, tj. ceny ropy naftowej znacząco przekroczyły ceny pszenicy i wykazywały się większą zmiennością. W obu przypadkach trend był rosnący, przy czym tempo wzrostu cen ropy naftowej było większe niż pszenicy. W 2007 r. ceny obu surowców zaczęły gwałtownie rosnąć. Najpierw gwałtowny wzrost cen odnotowała pszenica, kilka miesięcy później najwyższy poziom osiągnęły ceny ropy naftowej. W okresie gdy ceny ropy naftowej miały największy poziom, ceny pszenicy zaczęły dość gwałtownie spadać. Pod koniec 2008 r. również ceny ropy naftowej odnotowały gwałtowny spadek i na krótko osiągnęły ponownie poziom niższy niż ceny pszenicy. Od 2009 r. ponownie obserwowano rosnący trend cen, przy czym ceny ropy naftowej rosły szybciej niż ceny pszenicy i przekroczyły ich poziom. W tym okresie ponownie daje się zauważyć, że gdy rosną ceny ropy naftowej, to maleją ceny pszenicy. Po 2015 r. ceny obu surowców malały, dynamika zmian cen była większa w przypadku cen ropy. Od połowy 2016 do końca 2017 r. ceny obu surowców były na podobnym poziomie i nie wykazywały się dużą zmiennością.



Rysunek 8.2. Kształtowanie się dziennych cen ropy naftowej (oś prawa) i cen pszenicy (oś lewa) w latach 2000–2017

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Testowanie zależności między cenami ropy naftowej a złotą oraz zależności między cenami ropy naftowej a pszenicy zostało przeprowadzone z użyciem strukturalnych modeli wektorowej autoregresji (SVAR). Badania wykonano dla dziennych cen ropy naftowej, złota i pszenicy z okresu od stycznia 2000 do grudnia 2017 r. Dane pochodzą z bazy Reuters Datastream.

Zmienne wykorzystane do budowy modelu wektorowej autoregresji powinny być stacjonarne. Do zbadania stacjonarności zmiennych zastosowano test ADF oraz test KPSS. W tabeli 8.1 przedstawiono wyniki testu ADF dla poziomów i przyrostów badanych zmiennych.

Tabela 8.1. Wyniki testu ADF

Zmienne	Poziomy zmiennych	Pierwsze przyrosty
Ropa naftowa	-1,94	-72,17***
Złoto	-1,10	-69,92***
Pszenica	-2,35	-70,27***

*** odrzucenie hipotezy zerowej na poziomie istotności 0,01

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

W teście ADF hipoteza zerowa zakłada niestacjonarność szeregu ($H_0 : y_t \sim I(1)$). Liczba opóźnień w teście ADF została ustalona na podstawie minimalizacji kryterium informacyjnego Schwarza (BIC). Z danych przedstawionych w tabeli 8.1 wyni-

ka, że dla poziomów badanych zmiennych brak jest podstaw do odrzucenia hipotezy zerowej o niestacjonarności szeregu czasowego. Test ADF wskazuje na niestacjonarność szeregów czasowych cen ropy naftowej, złota i pszenicy. Dla pierwszych przyrostów analizowanych zmiennych natomiast hipoteza zerowa o niestacjonarności została odrzucona (na poziomie istotności 0,01). Zmienne te są zatem zintegrowane w stopniu pierwszym i obliczenie ich pierwszych przyrostów pozwoli na uzyskanie szeregów stacjonarnych.

Badanie stacjonarności zmiennych cen ropy naftowej, złota i pszenicy zostało dodatkowo uzupełnione o test KPSS. Hipoteza zerowa testu KPSS zakłada stacjonarność, a hipoteza alternatywna niestacjonarność badanego procesu. Do estymacji wariancji długookresowej w teście KPSS zastosowano funkcję gęstości Barletta. Wyniki testu KPSS przedstawiono w tabeli 8.2.

Tabela 8.2. Wyniki testu KPSS

Zmienne	Poziomy zmiennych	Pierwsze przyrosty
Ropa naftowa	3,36***	0,11
Złoto	7,35***	0,13
Pszenica	3,63***	0,13

*** odrzucenie hipotezy zerowej na poziomie istotności 0,01

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Z danych tabeli 8.2 wynika, że dla poziomów zmiennych wartość statystyki testowej jest większa niż wartość krytyczna testu, co świadczy o odrzuceniu hipotezy o stacjonarności wybranych zmiennych (na poziomie istotności poniżej 0,01). Dla pierwszych przyrostów badanych zmiennych nie ma natomiast podstaw do odrzucenia hipotezy zerowej zakładającej stacjonarność szeregu czasowego.

Zarówno test ADF, jak i test KPSS potwierdzają, że pierwsze przyrosty badanych zmiennych są stacjonarne. Model wektorowej autoregresji (wzór 7.8) został zatem obliczony dla zlogarytmowanych przyrostów badanych zmiennych. Zbudowano dwa modele VAR. Jeden model wektorowej autoregresji dla zależności między cenami ropy naftowej i złota (VAR_{R-Z}) oraz drugi model dla zależności między cenami ropy naftowej i pszenicy (VAR_{R-P}).

Wyboru rzędu opóźnień w modelach VAR_{R-Z} i VAR_{R-P} dokonano z wykorzystaniem wartości kryteriów informacyjnych. W tabeli 8.3 przedstawiono wartości kryterium Akaike'a (AIC) i kryterium Schwarz'a (BIC) dla poszczególnych modeli wektorowej autoregresji. Mniejsze wartości kryteriów informacyjnych świadczą o lepszym dopasowaniu modelu do danych empirycznych.


Tabela 8.3. Wartości kryteriów informacyjnych dla rozważanych modeli VAR_{R-Z} i VAR_{R-P}

Model VAR (<i>p</i> -opóźnień)	AIC	BIC	AIC	BIC
	VAR _{R-Z}		VAR _{R-P}	
VAR(1)	-10,814	-10,806	-9,662	-9,653
VAR(2)	-10,815	-10,801	-9,662	-9,648
VAR(3)	-10,814	-10,795	-9,661	-9,642
VAR(4)	-10,814	-10,789	-9,660	-9,635
VAR(5)	-10,813	-10,783	-9,660	-9,63

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Wartości kryteriów informacyjnych wskazują, że dla relacji między ropą naftową a złotem najlepszy będzie model VAR_{R-Z} z liczbą opóźnień $p = 1$ lub $p = 2$ (tab. 8.3). Wartości kryterium Akaike'a (AIC) oraz kryterium Schwarza (BIC) wskazują bowiem na inną optymalną liczbę opóźnień. Z kolei dla zależności między ropą naftową a pszenicą wartości obu kryteriów informacyjnych osiągają najmniejsze wartości dla modelu VAR_{R-P} z liczbą opóźnień $p = 1$. Na podstawie wstępnej analizy jakości modelu VAR_{R-Z} z liczbą opóźnień $p = 1$ lub $p = 2$ oraz modelu VAR_{R-P} z liczbą opóźnień $p = 1$ stwierdzono, że modele te nie spełniają podstawowych założeń dotyczących reszt. Do badania zależności między cenami ropy naftowej i złota oraz cenami ropy naftowej i pszenicy wybrano modele VAR z liczbą opóźnień $p = 3$.

Na rysunku 8.3 przedstawiono pierwiastki charakterystyczne równania oszacowanych modeli VAR_{R-Z} dla zależności między ropą naftową a złotem oraz modeli VAR_{R-P} dla relacji między ropą naftową a pszenicą.



Rysunek 8.3. Pierwiastki charakterystyczne równania modelu wektorowej autoregresji VAR_{R-Z} (strona lewa) i VAR_{R-P} (strona prawa)

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Z danych przedstawionych na rysunku 8.3 wynika, że zbudowane modele wektorowej autoregresji dla relacji między ropą naftową a złotem oraz ropą naftową a pszenicą są stabilne. Wszystkie wartości własne macierzy \mathbf{A} (wzór 7.8), czyli pierwiastki charakterystyczne równania modelu VAR, leżą wewnątrz koła jednostkowego.

Składnik losowy poszczególnych równań modeli VAR_{R-Z} i VAR_{R-P} nie wykazuje autokorelacji. W tabeli 8.4 przedstawiono wartości statystyk testowych testu mnożnika Lagrange'a (LM) na autokorelację składnika losowego. Hipoteza zerowa testu LM mówi, że nie występuje autokorelacja składnika losowego rzędu p . Statystyka testowa ma rozkład χ^2 z k^2 stopniami swobody, gdzie k oznacza liczbę zmiennych w modelu VAR. W przypadku modeli VAR_{R-Z} i VAR_{R-P} k jest równe 1. Na podstawie wyników przedstawionych w tabeli 8.4 można uznać, że składnik losowy poszczególnych równań modeli VAR_{R-Z} i VAR_{R-P} nie wykazuje autokorelacji. Na poziomie istotności poniżej 0,05 nie ma podstaw do odrzucenia hipotezy zerowej zakładającej brak autokorelacji składnika losowego.

Tabela 8.4. Wyniki testu LM na autokorelację składnika losowego modeli VAR_{R-Z} i VAR_{R-P}

Liczba opóźnień p	Statystyka LM	
	VAR _{R-Z}	VAR _{R-P}
1	6,50	2,71
2	8,10*	7,93*
3	1,90	2,27
4	6,53	2,46
5	6,77	9,42*

* odrzucenie hipotezy zerowej na poziomie istotności odpowiednio 0,1

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Badanie zależności między ropą naftową a złotem oraz ropą naftową a pszenicą rozpoczęto od przeprowadzenia testu przyczynowości w sensie Grangera (Granger, 1969) (tab. 8.5).

Tabela 8.5. Wyniki testu przyczynowości w sensie Grangera

Zmienna Y	Zmienna X		
	ropa naftowa	złoto	pszenica
Ropa naftowa	×	0,92	0,67
Złoto	20,15***	×	2,75**
Pszenica	2,84**	0,62	×

** , *** odrzucenie hipotezy zerowej na poziomach istotności odpowiednio 0,05; 0,01

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Zmienna X jest przyczyną Y w sensie Grangera, jeżeli bieżące wartości Y można prognozować z większą dokładnością z użyciem opóźnionych wartości X do rzędu p włącznie niż bez ich wykorzystania (Osińska, 2008). Hipoteza zerowa dla jednokierunkowej zależności przyczynowo-skutkowej mówi, że X nie jest przyczyną Y , czyli opóźnione wartości zmiennej X są statystycznie nieistotne. Statystyka testowa ma rozkład χ^2 z p stopniami swobody. Przyjęto rząd opóźnień $p = 3$. Badania przeprowadzono dla 4691 obserwacji. Wartości statystyki testowej $\chi^2(3)$ zostały przedstawione w tabeli 8.5.

Na podstawie wyników zaprezentowanych w tabeli 8.5 można wywnioskować, że zmiany cen złota i pszenicy nie są przyczyną zmian cen ropy naftowej w sensie Grangera. Brak jest podstaw do odrzucenia hipotezy zerowej dla jednokierunkowej zależności przyczynowo-skutkowej mówiącej, że zmiany cen złota/pszenicy nie są przyczyną zmian cen ropy naftowej. Wykazano dodatkowo, że zmiany cen złota nie są przyczyną w sensie Grangera zmian cen pszenicy. Wyniki przedstawione w tabeli 8.5 wskazują jednak na istotny wpływ w sensie Grangera cen ropy naftowej na ceny złota oraz cen ropy naftowej na ceny pszenicy. Hipoteza zerowa dla jednokierunkowej zależności przyczynowo-skutkowej mówiąca, że ceny ropy naftowej nie są przyczyną zmian cen złota, została odrzucona na poziomie istotności 0,01. Z kolei hipoteza zerowa dla jednokierunkowej zależności przyczynowo-skutkowej mówiąca, że ceny ropy naftowej nie są przyczyną zmian cen pszenicy, została odrzucona na poziomie istotności 0,05. Można zatem uznać, że zmiany cen ropy naftowej wpływają w sensie Grangera w sposób istotny na zmiany cen złota i pszenicy. Dodatkowo wykazano, że zmiany cen pszenicy są przyczyną w sensie Grangera zmian cen złota.

Przedmiotem dalszej części badań jest zależność między zmianami cen ropy naftowej i złota oraz zmianami cen ropy naftowej i pszenicy. Analizę zależności między badanymi zmiennymi przeprowadzono z wykorzystaniem strukturalnej postaci modelu VAR (wzór 7.26). W celu określenia parametrów modelu strukturalnego wektorowej autoregresji (SVAR) zastosowano zaproponowaną przez Simsa (1980) strukturyzację rekursywną. Należy podkreślić, że w przypadku strukturyzacji rekursywnej bardzo ważne jest właściwe uporządkowanie zmiennych w modelu VAR. Jako pierwszą zmienną wybiera się tę, która nie zależy od bieżących realizacji pozostałych zmiennych, a ostatnia zmienna to taka, której bieżące wartości zależą od realizacji wszystkich pozostałych zmiennych modelu. Kolejność zmiennych w rozważanych modelach SVAR określono na podstawie wyników testu przyczynowości w sensie Grangera. Przyjęto, że w modelu SVAR_{R-Z} pierwszą zmienną są ceny ropy naftowej, a drugą ceny złota. Test przyczynowości w sensie Grangera wykazał bowiem, że to zmiany cen ropy naftowej mają wpływ na zmiany cen złota, a nie na odwrót. W modelu SVAR_{R-P} przyjęto natomiast, że pierwszą zmienną są ceny ropy

naftowej, a drugą zmienną ceny pszenicy. Test przyczynowości w sensie Grangera wskazuje bowiem, że to zmiany cen ropy naftowej mają wpływ w sensie Grangera na zmiany cen pszenicy.

Oszacowane macierze **A** i **B** strukturalnych modeli wektorowej autoregresji dla relacji między ropą naftową a złotem (SVAR_{R-Z}) oraz ropą naftową a pszenicą (SVAR_{R-P}) kształtują się następująco


$$\mathbf{A}_{R-Z} = \begin{pmatrix} 1 & 0 \\ -0,064 & 1 \end{pmatrix} \quad \mathbf{B}_{R-Z} = \begin{pmatrix} 0,024 & 0 \\ 0 & 0,011 \end{pmatrix}$$

$$\mathbf{A}_{R-P} = \begin{pmatrix} 1 & 0 \\ -0,070 & 1 \end{pmatrix} \quad \mathbf{B}_{R-P} = \begin{pmatrix} 0,024 & 0 \\ 0 & 0,019 \end{pmatrix}$$

Strukturalne modele wektorowej autoregresji służą przede wszystkim do obliczenia i interpretacji funkcji odpowiedzi na impuls i dekompozycji wariancji błędów prognoz. Wykres funkcji reakcji na impuls (ang. *impulse-response function* – IRF) obrazuje zachowanie poszczególnych zmiennych na impulsy w niezależnych zaburzeniach modelu strukturalnego. Z uwagi na to, że model SVAR został zbudowany dla pierwszych przyrostów badanych zmiennych, w pracy wykorzystano skumulowane funkcje odpowiedzi na impuls (ang. *accumulated impulse-response function* – AIRF). Kumulacja funkcji reakcji na impuls umożliwia skonstruowanie funkcji opartej na poziomach wybranych zmiennych. Pozwala to zatem na interpretacje wpływu szoku strukturalnego na poziom badanych zmiennych, a nie na ich pierwsze przyrosty (Cholewiński, 2008).


Na rysunku 8.4 przedstawiono szok cen ropy naftowej. Szok ten oznacza w badanym przypadku wzrost cen tego surowca energetycznego (w pierwszym dniu). Rysunek 8.5 przedstawia skumulowaną funkcję reakcji na impuls w postaci szoku cen ropy naftowej. W odpowiedzi na szok w postaci wzrostu cen ropy naftowej początkowo ceny złota gwałtownie wzrastają. Trend wzrostowy trwa około dwóch dni. Później następują jedno-, dwudniowa niewielka korekta i ceny złota stabilizują się na nowym wyższym poziomie po okresie od czterech do pięciu dni.

Z uwagi na to, że macierz funkcji reakcji na impuls zbudowana jest według oszacowanych parametrów modelu SVAR, w analizie funkcji IRF należy również wziąć pod uwagę błędy standardowe tych oszacowań (Goczek, 2012). Przerywane linie na rysunku 8.5 przedstawiają tzw. wstęgi błędu (ang. *error bands*) dla oszacowanych skumulowanych funkcji reakcji na impuls. Odległość górnej i dolnej linii od funkcji reakcji na impuls równa jest wartości dwóch odchyłeń standardowych. Zakłada się, że jeżeli jedna z przerywanych linii przekroczy poziom zero na osi Y, to wówczas wpływ badanego szoku na poziom zmiennej nie jest istotny statystycz-



Rysunek 8.4. Szok cen ropy naftowej

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.




Rysunek 8.5. Wykres skumulowanej funkcji reakcji cen złota na szok na rynku ropy naftowej

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

nie. Z danych przedstawionych na rysunku 8.5 wynika, że reakcja cen złota na szok związany ze spadkiem cen ropy naftowej jest istotna statystycznie. Wyniki badań są zgodne z tym, co otrzymali inni badacze. W literaturze przedmiotu dominuje bowiem przekonanie, że ceny ropy naftowej i złota są ze sobą dodatnio powiązane (Melvin i Sultan, 1990; Roberedo, 2010; Beckmann i Czudaj, 2013; Wang i Chueh,

2013; Bampinas i Panagiotidis, 2015b; Vilayil i in., 2015; Mo i in., 2018). Wynika to między innymi z istnienia tzw. kanału inflacyjnego, kanału przychodów z eksportu, kanału importowego, co zostało dokładnie opisane w rozdziale 5.

Zhang i Wei (2010) pokazali, że zmiany wartości cen ropy naftowej są przyczyną zmian cen złota w sensie Grangera, ale odwrotnie nie ma takiej zależności. Na rysunku 8.6 przedstawiono szok cen złota. W badanym przypadku jest on utożsamiany ze wzrostem cen tego surowca.




Rysunek 8.6. Szok cen złota


Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Rysunek 8.7 przedstawia skumulowaną funkcję reakcji cen ropy naftowej na szok w postaci wzrostu cen złota. W odpowiedzi na wzrost cen złota ceny ropy naftowej wzrastają. Reakcja cen ropy naftowej nie jest jednak istotna statystycznie. Wstęgi błędów dla oszacowanej skumulowanej funkcji reakcji na impuls przekroczyły bowiem poziom zero na osi Y. Uzyskane wyniki potwierdzają wyniki testu Grangera, w którym wykazano, że to zmiany cen ropy naftowej wpływają w sensie Grangera na zmiany cen złota, a nie na odwrót.

Kolejną badaną zależnością jest związek między cenami ropy naftowej i pszenicy. Szok cen ropy naftowej został przedstawiony na rysunku 8.4. Jest on utożsamiany ze wzrostem cen tego surowca. Rysunek 8.8 obrazuje skumulowaną funkcję reakcji cen pszenicy na szok w postaci wzrostu cen ropy naftowej. W odpowiedzi na szok w postaci wzrostu cen ropy naftowej następuje dwudniowy wzrost cen pszenicy i po krótkiej korekcie ceny te stabilizują się na nowym wyższym poziomie. Stabilizacja cen następuje po okresie od trzech do czterech dni.



Rysunek 8.7. Wykres skumulowanej funkcji reakcji cen ropy naftowej na szok na rynku złota
 Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.




Rysunek 8.8. Wykres skumulowanej funkcji reakcji cen pszenicy na szok na rynku ropy naftowej
 Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Z danych przedstawionych na rysunku 8.8 wynika, że reakcja cen pszenicy na impuls na rynku ropy naftowej jest istotna statystycznie. Zaznaczone na rysunku liniami przerywanymi wstęgi błędów dla oszacowanej skumulowanej funkcji reakcji na impuls nie przekroczyły bowiem poziomu zero na osi Y.

Jak już wspomniano wcześniej, w literaturze przedmiotu nie ma jednoznacznych wyników i wniosków dotyczących relacji między cenami ropy naftowej i pszenicy. Niemniej jednak w kilku pracach wykazano (podobnie jak w niniejszej publikacji), że ceny ropy naftowej i pszenicy są dodatnio powiązane (Balcilar i in., 2006; Arshad i Hameed, 2009; Nazlioglu i Soytaş, 2012; Wang i in., 2014; Ahmadi i in., 2016; Wei i in., 2016). Teorie wyjaśniające takie relacje wskazują, między innymi, bądź na popyt na biopaliwa i finansjeryzację produktów rolnych, bądź na podaźową i popytową stronę mechanizmu rynkowego. Szczegółowy opis efektów przeglądu systematycznego dotyczącego związków między cenami ropy naftowej i pszenicy zawarto w rozdziale szóstym.


Zaprezentowane w tabeli 8.5 wyniki testu Grangera wskazują, że to tylko zmiany cen ropy naftowej wpływają w sensie Grangera na zmiany cen pszenicy, a nie na odwrót. Na rysunku 8.9 przedstawiono szok cen pszenicy. W badanym przypadku szok ten utożsamiany jest ze wzrostem cen tego surowca.



Rysunek 8.9. Szok cen pszenicy

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Rysunek 8.10 przedstawia skumulowaną funkcję reakcji cen ropy naftowej na szok w postaci wzrostu cen pszenicy. W odpowiedzi na wzrost cen pszenicy ceny ropy naftowej wzrastają. Reakcja cen ropy naftowej nie jest jednak istotna statystycznie. Wstęgi błędów dla oszacowanej skumulowanej funkcji reakcji na impuls przekroczyły bowiem poziom zero na osi Y. Uzyskane wyniki potwierdzają wyniki przeprowadzonego testu Grangera (tab. 8.5).



Rysunek 8.10. Wykres skumulowanej funkcji reakcji cen ropy naftowej na szok na rynku pszenicy
Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Prawidłowa interpretacja wyników strukturalnych modeli wektorowej autoregresji wymaga, poza analizą funkcji reakcji na impuls, przeprowadzenia analizy dekompozycji wariancji błędu prognozy. Dekompozycja wariancji błędu prognozy określa, jaki udział w objaśnianiu wariancji błędu prognozy mają wszystkie zmienne użyte do budowy modelu SVAR. Opis teoretyczny dekompozycji wariancji błędu prognozy znajduje się w rozdziale 7. W tabeli 8.6 przedstawiono wartości komponentów wariancji błędu prognozy dla cen złota i ropy naftowej na podstawie modelu $SVAR_{R-Z}$.

Tabela 8.6. Dekompozycja wariancji błędu prognoz cen złota i cen ropy naftowej (model $SVAR_{R-Z}$)

Okres (dni)	Złoto		Ropa naftowa	
	ceny ropy naftowej	ceny złota	ceny złota	ceny ropy naftowej
1	1,972	98,028	0,000	100,000
2	3,007	96,993	0,002	99,998
3	3,138	96,862	0,054	99,946
4	3,139	96,861	0,057	99,943
5	3,143	96,857	0,057	99,943
6	3,143	96,857	0,057	99,943
7	3,143	96,857	0,057	99,943
8	3,143	96,857	0,057	99,943
9	3,143	96,857	0,057	99,943
10	3,143	96,857	0,057	99,943

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

W prawidłowo oszacowanym modelu SVAR wartości komponentów wariancji błędu prognozy powinny po pewnym czasie się stabilizować. W przypadku modelu SVAR_{R-Z} dla cen złota stabilizacja następuje po około pięciu dniach. W modelu SVAR_{R-Z} dla cen ropy naftowej stabilizacja następuje już po czterech dniach. Z danych tabeli 8.6 wynika, że w przypadku cen złota procentowy udział cen ropy naftowej w wariancji błędu prognozy wynosi około 3%, a w około 97% wariancja błędu prognozy cen złota wyjaśniona jest przez własne wartości. Z powyższego wynika, że ceny ropy naftowej wyjaśniają jedynie w małym stopniu wariancję błędu prognozy cen złota. Zaprezentowane w tabeli 8.6 wyniki dekompozycji wariancji błędu prognozy dla modelu SVAR_{R-Z} wskazują dodatkowo na niewielki, rzędu 0,06%, udział cen złota w wariancji błędu prognozy cen ropy naftowej.

W tabeli 8.7 przedstawiono wartości komponentów wariancji błędu prognozy dla cen pszenicy i ropy naftowej na podstawie modelu SVAR_{R-P}.

Tabela 8.7. Dekompozycja wariancji błędu prognoz cen pszenicy i cen ropy naftowej (model SVAR_{R-P})

Okres (dni)	Pszenica		Ropa naftowa	
	ceny ropy naftowej	ceny pszenicy	ceny pszenicy	ceny ropy naftowej
1	0,737	99,263	0,000	100,000
2	0,837	99,163	0,001	99,999
3	0,887	99,113	0,027	99,973
4	0,891	99,109	0,040	99,960
5	0,892	99,108	0,041	99,959
6	0,892	99,108	0,041	99,959
7	0,892	99,108	0,041	99,959
8	0,892	99,108	0,041	99,959
9	0,892	99,108	0,041	99,959
10	0,892	99,108	0,041	99,959

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Wartości komponentów wariancji błędów prognozy w modelu SVAR_{R-P} dla cen zarówno pszenicy, jak i ropy naftowej stabilizują się po około pięciu dniach (tab. 8.7). Zaprezentowane w tabeli 8.7 wyniki dekompozycji błędu prognozy wskazują na niewielki, około 0,9%, udział cen ropy naftowej w wariancji błędu prognozy cen pszenicy. W przypadku cen ropy naftowej procentowy udział cen pszenicy w wariancji błędu prognozy wynosi zaledwie 0,04%.

Badania przeprowadzone z wykorzystaniem SVAR potwierdziły, że istnieje dodatni związek między cenami złota i ropy naftowej oraz cenami pszenicy i ropy naftowej. Na podstawie analizy skumulowanej funkcji reakcji na impuls pokazano, że

w odpowiedzi na szok w postaci wzrostu cen ropy naftowej ceny zarówno złota, jak i pszenicy wzrastają. Należy podkreślić, że reakcja cen złota i pszenicy na szok na rynku ropy naftowej jest istotna statystycznie. Wyniki testu Grangera oraz analizy skumulowanej funkcji reakcji na impuls sugerują natomiast, że ceny zarówno złota, jak pszenicy nie mają istotnego wpływu na ceny ropy naftowej. Badania przeprowadzone z zastosowaniem strukturalnego modelu wektorowej autoregresji wskazują na niewielki udział zmian cen ropy naftowej w wyjaśnieniu wariancji błędów prognoz cen złota i pszenicy.

W literaturze przedmiotu dominuje przekonanie, że ceny surowców powinny „poruszać się” w tym samym kierunku. Wyniki przeprowadzonych badań potwierdzają tę tezę. Zdaniem niektórych badaczy kierunek zależności między cenami analizowanych surowców może jednak ulegać zmianie w zależności od globalnej sytuacji na rynkach finansowych (Kanijlal i Ghosh, 2017; Khalfaoui, 2018). Może to sugerować, że współczynnik kierunkowy w modelu opisującym powyższą zależność nie jest stabilny i następuje zmiana znaku z dodatniego na ujemny. W celu sprawdzenia prawdziwości powyższej tezy zbudowano liniowy model regresji ze zmianami strukturalnymi. Na podstawie testu Baia–Perrona zidentyfikowano wielokrotne zmiany strukturalne w badanych zależnościach. W tabeli 8.8 przedstawiono model regresji ze zmianami strukturalnymi, w którym zmienną objaśnianą są ceny złota, a zmienną objaśniającą ceny ropy naftowej. Nie zbudowano odrębnego modelu dla zależności odwrotnej, gdyż zarówno test przyczynowości w sensie Grangera, jak i model SVAR_{R-Z} wskazywały na nieistotny wpływ cen złota na ceny ropy naftowej. W drugiej kolumnie tabeli 8.8 zapisano wartości oszacowań parametrów β_0 i β_1

Tabela 8.8. Wpływ zmian cen ropy naftowej na zmiany cen złota – model ze zmianami strukturalnymi (test Baia–Perrona)

Zmienna	Parametry modelu	Statystyka <i>t</i>
3.01.2000–15.09.2005 (1489 obserwacji)		
Stała	0,00029	1,019
Ropa naftowa	0,02798	2,492**
16.09.2005–10.09.2013 (2083 obserwacji)		
Stała	0,00049	2,060**
Ropa naftowa	0,12394	12,328***
11.09.2013–28.12.2017 (1122 obserwacji)		
Stała	–0,00004	–0,144
Ropa naftowa	–0,00368	–0,259

** ,*** odrzucenie hipotezy zerowej na poziomach istotności odpowiednio 0,05; 0,01

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

modelu liniowego ze zmianami strukturalnymi. Trzecia kolumna zawiera wartości statystyki testowej t -Studenta. Weryfikacji poddano następujące hipotezy zerowe: $H_0: \beta_0 = 0$ oraz $H_0: \beta_1 = 0$.

Wyniki testu Baia–Perrona wskazują na istnienie trzech zmian strukturalnych. W pierwszych dwóch wyodrębnionych okresach tj. od 3 stycznia 2000 do 15 września 2005 r. oraz od 16 września 2005 do 10 września 2013 r. istniała dodatnia i istotna statystycznie zależność między cenami złota a ropy naftowej. W drugim okresie ta zależność była jednak silniejsza. Oszacowany parametr kierunkowy b_1 wynosił wówczas 0,124. W trzecim wyodrębnionym okresie nastąpiła zmiana kierunku zależności między cenami złota i ropy naftowej. Zmiany cen badanego surowca energetycznego wpływały wówczas ujemnie na ceny złota. Wpływ ten nie był jednak istotny statystycznie.

W tabeli 8.9 przedstawiono model regresji liniowej ze zmianami strukturalnymi, w którym zmienną objaśnianą są ceny pszenicy, a zmienną objaśniającą ceny ropy naftowej.

Tabela 8.9. Wpływ zmian cen ropy naftowej na zmiany cen pszenicy – model ze zmianami strukturalnymi (test Baia–Perrona)

Zmienna	Parametry modelu	Statystyka t
3.01.2000–5.02.2008 (2112 obserwacji)		
Stała	0,00068	1,625
Ropa naftowa	–0,00492	–0,273
6.02.2008–10.04.2012 (1217 obserwacji)		
Stała	–0,00016	–0,290
Ropa naftowa	0,20080	10,039***
11.09.2013–28.12.2017 (1122 obserwacji)		
Stała	–0,00039	–0,740
Ropa naftowa	0,00588	0,242

*** odrzucenie hipotezy zerowej na poziomie istotności 0,01

Źródło: opracowanie własne na podstawie danych z bazy Reuters Datastream.

Wyniki testu Baia–Perrona wskazują na istnienie trzech zmian strukturalnych (tab. 8.9). W pierwszym wyodrębnionym okresie, tj. od stycznia 2000 do 5 lutego 2008 r., zależność między cenami pszenicy i ropy naftowej była ujemna oraz nieistotna statystycznie. W drugim okresie nastąpiło odwrócenie kierunku zależności. Od lutego 2008 do kwietnia 2012 r. ceny ropy naftowej wpływały dodatnio na ceny pszenicy. Zależność między badanymi surowcami była wówczas istotna statystycznie. W trzecim wyodrębnionym okresie, tj. 11 września 2013 do 28 grudnia 2017 r., zmiany cen badanego surowca energetycznego nadal wpływały dodatnio na ceny pszenicy, jednak zależność ta nie była istotna statystycznie.

Podsumowanie i wnioski

Niezwykle ważnymi i strategicznymi towarami w inwestycjach są złoto, ropa naftowa i pszenica. Te trzy surowce odgrywają dominującą rolę na światowych rynkach, dlatego też identyfikacja związków między nimi stanowi ważki i interesujący problem badawczy.

Złoto jest pożądanym metalem szlachetnym mającym bardzo szerokie spektrum wykorzystania. Jest niezbędnym metalem wykorzystywanym w produkcji biżuterii i różnych precjozów, ale również znajduje szerokie zastosowanie w przemyśle. Złoto zachowuje ponadto wyjątkowy status wśród wszystkich towarów jako długoterminowy zasób wartości.

Ropa naftowa jest obecnie najważniejszym surowcem w energetyce, a także w przemyśle chemicznym. Wykorzystywana jest ona do produkcji nie tylko asfaltu, olei i smarów, nafty czy benzyny, ale także między innymi kosmetyków, leków, plastiku i kauczuku. Ze względu na swoje szerokie zastosowanie oraz duże znaczenie dla gospodarek na całym świecie nazywana jest często czarnym złotem.

Pszenica jest na światowych rynkach towarowych jednym z kluczowych surowców. Obok jęczmienia zalicza się do grupy najstarszych i odgrywających największą rolę w gospodarce zbóż. Jest pożywieniem milionów ludzi i jest jednym z trzech podstawowych zbóż produkowanych na świecie. Na bazie pszenicy produkowane są różnego rodzaju pasze. Pszenica odgrywa również istotną rolę w intensywnie rozwijającej się produkcji biopaliw.

W latach 2000–2017 ceny na rynku towarów charakteryzowały się bardzo dużą zmiennością. Towary stały się zróżnicowaną klasą aktywów, przez co poszerzyły możliwości inwestycyjne zarówno inwestorów instytucjonalnych, jak i inwestorów indywidualnych. Celem opracowania była próba identyfikacji zależności między cenami ropy naftowej a złota i pszenicy. Badania zostały przeprowadzone na podstawie dziennych cen spot ropy naftowej, złota i pszenicy z okresu od 3 stycznia 2000 do 29 grudnia 2017 r. Dane pochodzą z bazy Reuters Datastream.

Związki między cenami ropy naftowej, złota i pszenicy analizowano za pomocą wybranych technik ekonometrycznych. Analizę szeregów czasowych rozpoczęto od zbadania ich stacjonarności. Zarówno test ADF, jak i test KPSS potwierdziły, że pierwsze przyrosty badanych zmiennych są stacjonarne, dlatego też dalsza analiza została przeprowadzona na podstawie stóp zwrotu cen ropy naftowej, złota i pszenicy. Badanie zależności szeregów stacjonarnych wykonano z zastosowaniem testu przyczynowości w sensie Grangera oraz strukturalnych modeli wektorowej autoregresji (SVAR). Hipoteza zerowa dla jednokierunkowej zależności przyczynowo-

-skutkowej mówiąca, że zmiany cen ropy naftowej nie są przyczyną zmian cen złota, została odrzucona na poziomie istotności 0,01. Brak było natomiast podstaw do odrzucenia hipotezy zerowej mówiącej, że zmiany cen złota nie są przyczyną zmian cen ropy naftowej. Podobne wyniki otrzymano dla relacji między cenami ropy naftowej i pszenicy. Hipoteza zerowa dla jednokierunkowej zależności przyczynowo-skutkowej zakładająca, że zmiany cen ropy naftowej nie są przyczyną zmian cen pszenicy, została odrzucona na poziomie istotności 0,05. Dodatkowo wykazano, że zmiany cen pszenicy nie są przyczyną, w sensie Grangera, zmian cen ropy naftowej. Otrzymane wyniki badań są zbieżne z pracami między innymi Zhanga i Weia (2010), Nazliogla i Soyta (2012) i Kumara (2017).

W celu oceny kierunku i siły zależności między badanymi zmiennymi wykorzystano oparte na modelach SVAR funkcje reakcji na impuls oraz dekompozycję wariancji błędu prognozy. Wykres funkcji reakcji na impuls obrazuje odpowiedź poszczególnych zmiennych na impulsy w niezależnych zaburzeniach modelu strukturalnego. Reakcja cen złota na szok związany ze wzrostem cen ropy naftowej była dodatnia i istotna statystycznie. Analogiczne wyniki badań uzyskali między innymi: Melvin i Sultan (1990), Roboredo (2010), Wang i Chueh (2013), Beckmann i Czudaj (2013), Vilayil i inni (2015), Mo i inni (2018). Dodatkowo pokazano, że w odpowiedzi na wzrost cen złota, ceny ropy naftowej wzrastały. Reakcja cen ropy naftowej nie była jednak istotna statystycznie. Uzyskane wyniki potwierdziły wyniki testu Grangera, w którym wykazano, że to zmiany cen ropy naftowej są przyczyną zmian cen złota, a nie na odwrót. Do podobnych wniosków doszli Zhang i Wei (2010) oraz Bampinas i Panagiotidis (2015b).

Analiza skumulowanej funkcji reakcji cen pszenicy na szok na rynku ropy naftowej wskazywała na istnienie istotnej statystycznie i dodatniej zależności między badanymi zmiennymi. W odpowiedzi na szok w postaci wzrostu cen ropy naftowej następował wzrost cen pszenicy. Odwrotna zależność nie była natomiast istotna statystycznie. Podobne wyniki badań uzyskali w swoich pracach między innymi: Balçilar i inni (2016), Arshad i Hameed (2009), Nazlioglu i Soyta (2012), Wang i inni (2014), Ahumada i Cornejo (2016), Wei i Chen (2016).

Dodatkowo badania przeprowadzone przy wykorzystaniu modeli SVAR wskazywały na niewielki udział zmian cen ropy naftowej w wyjaśnieniu wariancji błędu prognoz cen złota i pszenicy.

Badanie zależności między cenami ropy naftowej oraz złota i pszenicy uzupełniono o funkcję regresji ze zmianami strukturalnymi. Zmiany te zostały zidentyfikowane na podstawie testu Baia–Perrona. Wykazano, że od 3 stycznia do 10 września 2013 r. istniała dodatnia i istotna statystycznie zależność między cenami ropy naftowej i złota. W okresie od 11 września 2013 do 28 grudnia 2017 r. doszło jednak

do odwrócenia kierunku badanej zależności. Zmiany cen ropy naftowej wpływały wówczas ujemnie na ceny złota. Wpływ ten nie był jednak istotny statystycznie. Wyniki testu Baia–Perrona wskazują na istnienie trzech zmian strukturalnych w zależności między cenami ropy naftowej i pszenicy. W okresie od stycznia 2000 do 5 lutego 2008 r. zależność między cenami pszenicy i ropy naftowej była ujemna i nieistotna statystycznie. W drugim i trzecim okresie, czyli od lutego 2008 do 28 grudnia 2017 r., nastąpiło odwrócenie kierunku zależności. Jednak jedynie w trzecim okresie, czyli od lutego 2008 do kwietnia 2012 r., ceny ropy naftowej miały istotny statystycznie wpływ na ceny pszenicy.

Otrzymane wyniki badań wskazują na istnienie dodatniej i istotnej statystycznie zależności między cenami ropy naftowej oraz cenami złota i pszenicy. Na podstawie testu Grangera wykazano, że zmiany cen ropy naftowej mają istotny statystycznie wpływ na zmiany cen złota i pszenicy, a nie na odwrót. Na podstawie analizy skumulowanej funkcji reakcji na impuls pokazano, że w odpowiedzi na szok w postaci wzrostu cen ropy naftowej ceny zarówno złota, jak i pszenicy wzrastają. Wyniki badań są zbieżne z wynikami opisanymi w literaturze przedmiotu, w której bowiem dominuje przekonanie, że relacja między badanymi surowcami jest na ogół dodatnia, o ile w ogóle istnieje. Należy podkreślić, że najnowsze publikacje, w których zastosowano zaawansowane modele ekonometryczne, wskazują na nieliniowość i asymetryczność zależności między cenami ropy naftowej oraz złota i pszenicy. Ich autorzy podkreślają, że związek między badanymi surowcami nie jest zawsze dodatni i jego kierunek zależy między innymi od sytuacji na rynkach finansowych. Wyniki przeprowadzonego testu Baia–Perrona potwierdziły, że w analizowanych relacjach występowały zmiany strukturalne, a kierunek badanych zależności przybierał różny znak.

Otrzymane wyniki empiryczne mogą stanowić źródło informacji nie tylko dla naukowców zajmujących się rynkiem finansowym czy towarowym, ale także praktyków między innymi inwestorów, analityków finansowych, doradców inwestycyjnych.

Literatura

- Abbott, P.C., Hurt, C., Tyner, W.E. (2009). What's Driving Food Prices? Farm Foundation Report. Oak Brook, IL.
- Ahumada, H., Cornejo, M. (2016). Forecasting food prices: The case of corn, soybeans and wheat. *International Journal of Forecasting*, 32(3), 838–848. <https://doi.org/10.1016/j.ijforecast.2016.01.002>
- Alghalith, M. (2010). The interaction between food prices and oil prices. *Energy Economics*, 32(6), 1520–1522.
- Andrews, D.W.K. (1993). Tests for Parameter Instability and Structural Change with Unknown Change Point. *Econometrica*, 61(4), 821–856. <https://doi.org/10.2307/2951764>
- Andrews, D.W.K., Ploberger, W. (1994). Optimal Tests When a Nuisance Parameter is Present Only Under The Alternative. *Econometrica*, 62(6), 1383–1414. <https://doi.org/10.2307/2951753>
- Arshad, F.M., Hameed, A.A.A. (2009). The Long Run Relationship Between Petroleum and Cereals Prices. In *Global Economy and Finance Journal*, 2, 91–100.
- Baffes, J., Haniotis, T. (2016). What Explains Agricultural Price Movements? *Journal of Agricultural Economics*, 67(3), 706–721. <https://doi.org/10.1111/1477-9552.12172>
- Baffes, J., Kose, M., Ohnsorge, F., Stocker, M. (2015). The great plunge in oil prices: causes, consequences, and policy responses. Policy Research Note PRN/15/01. World Bank Group, Washington, DC.
- Bai, J., Perron, P. (1998). Estimating and Testing Linear Models with Multiple Structural Changes, *Econometrica*, 66(1), 47–78. [https://doi.org/0012-9682\(199801\)66:1<47:EATLMW>2.0.CO;2-3](https://doi.org/0012-9682(199801)66:1<47:EATLMW>2.0.CO;2-3)
- Bai, J., Perron, P. (2003a). Computation and Analysis of Multiple Structural Change Models. *Journal of Applied Econometrics*, 18, 1–22. <https://doi.org/10.1002/jae.659>
- Bai, J., Perron, P. (2003b). Critical Values for Multiple Structural Change Test. *Econometrics Journal*, 6(1), 72–78. <https://doi.org/10.1111/1368-423X.00102>
- Bai, J., Perron, P. (2004). Multiple Structural Change Models: A Simulation Analysis. [W:] *Econometric Essays*. Ed. D. Corbea, S. Durlauf, B.E. Hansen. Cambridge University Press, Cambridge.
- Balcilar, M., Chang, S., Gupta, R., Kasongo, V., Kyei, C. (2016). The relationship between oil and agricultural commodity prices in South Africa: A quantile causality approach. *The Journal of Developing Areas*, 50(3), 93–107. <https://doi.org/10.1353/jda.2016.0117>
- Bampinas, G., Panagiotidis, T. (2015a). Are gold and silver a hedge against inflation? A two century perspective. *International Review of Financial Analysis*, 41, 267–276. <https://doi.org/10.1016/j.irfa.2015.02.007>
- Bampinas, G., Panagiotidis, T. (2015b). On the relationship between oil and gold before and after financial crisis: linear, nonlinear and time-varying causality testing. *Studies in Nonlinear Dynamics & Econometrics*, 19(5), 657–668. <https://doi.org/10.1515/snnde-2014-0060>
- Baumeister, C., Kilian, L. (2014). Do oil price increases cause higher food prices? *Economic Policy*, 29(80). <https://doi.org/10.1111/1468-0327.12039>

- Beckmann, J., Czudaj, R. (2013). Oil and gold price dynamics in a multivariate cointegration framework. *International Economics and Economic Policy*, 10(3), 453–468. <https://doi.org/10.1007/s10368-013-0237-8>
- Ben Aïssa, M.S., Boutahar, M., Jouni, J. (2004). Bai and Perrons's and spectral density methods for structural change detection in the US inflation process. *Applied Economics Letters*, 11, 109–115. <https://doi.org/10.1080/1350485042000200213>
- Ben Aïssa, M.S., Jouni, J. (2003). Structural breaks in the US inflation process. *Applied Economics Letters*, 10, 633–636. <https://doi.org/10.1080/1350485032000136360>
- Chen, H., Liao, H., Tang, B.J., Wei, Y.M. (2016). Impacts of OPEC's political risk on the international crude oil prices: An empirical analysis based on the SVAR models. *Energy Economics*, 57, 42–49. <https://doi.org/10.1016/j.eneco.2016.04.018>
- Chen, S.T., Kuo, H.I., Chen, C.C. (2010). Modeling the relationship between the oil price and global food prices. *Applied Energy*, 87(8), 2517–2525. <https://doi.org/10.1016/j.apenergy.2010.02.020>
- Cholewiński, R. (2008). Wpływ zmian kursu walutowego na dynamikę procesów inflacyjnych. *Materiały i Studia*. Materiały i Studia 226. NBP, Warszawa.
- Chow, G.C. (1960). Tests of Equality between Sets of Coefficients in Two Linear Regressions. *Econometrica*, 28, 591–605.
- Ciaian, P., Kanacs, D. (2011). Interdependencies in the energy-bioenergy food price systems: a cointegration analysis. *Resource and Energy Economics*, 33(1), 326–348.
- Ciner, C., Gurdgiev, C., Lucey, B.M. (2013). Hedges and safe havens: An examination of stocks, bonds, gold, oil and exchange rates. *International Review of Financial Analysis*, 29, 202–211.
- Curtis, B.C., Rajaram, S., Gómez Macpherson, H. (2002). Bread wheat: improvement and production. *FAO Plant Production and Protection* 30.
- Darst, D.M. (2013). *Wiley RealTime Finance: Portfolio Investment Opportunities in Precious Metals*. John Wiley & Sons, Oxford.
- Daugherty, K., Kelly, K. (2014). Stocks and the Stocks-to-Use Ratio: Are They Meaningful for Price Determination? GROWMARK Research. Pobrane z <http://www.zimmcomm.biz/growmark/growmark-stocks-report.pdf>.
- De Nicola, F., De Pace, P., Hernandez, M.A. (2016). Co-movement of major energy, agricultural, and food price returns: A time-series assessment. *Energy Economics*, 57, 28–41.
- De Schryder, S., Peersman, G. (2013). The US dollar exchange rate and the demand for oil. *CESifo Working Paper* 4126.
- Domanski, D., Heath, A. (2007). Financial investors and commodity markets. *BIS Quarterly Review*, March, 53–67.
- Dowgiałło, Z. (2004). *Słownik ekonomiczny dla przedsiębiorcy*. Wydawnictwo Znicz, Szczecin.
- Du, X., Yu, C.L., Hayes, D.J. (2011). Speculation and Volatility Spillover in the Crude Oil and Agricultural Commodity Markets: A Bayesian Analysis. *Energy Economics*, 33(3), 497–503. <https://doi.org/10.1016/j.eneco.2010.12.015>
- Dutta, A. (2018). Impacts of oil volatility shocks on metal markets: A research note. *Resources Policy*, 55, 9–19. <https://doi.org/10.1016/j.resourpol.2017.09.003>
- El Hedi Aroui, M., Lahiani, A., Nguyen, D.K. (2015). World gold prices and stock returns in China: insights for hedging and diversification strategies. *Economic Modelling*, 44, 273–282. <https://doi.org/10.1016/j.econmod.2014.10.030>

- Eller, R., Sagerer, Ch. (2008). An Overview of Commodity Sectors. *The Handbook of Commodity Investing*. John Wiley & Sons, Chichester, West Sussex.
- Engdahl, F.W. (2008). World Bank Secret report confirms biofuels cause of world food crisis. *Global Research*. Pobrane z <https://www.globalresearch.ca/world-bank-secret-report-confirms-biofuel-cause-of-world-food-crisis/9547>.
- Enghiad, A., Ufer, D., Countryman, A.M., Thilmany, D.D. (2017). An Overview of Global Wheat Market Fundamentals in an Era of Climate Concerns. *International Journal of Agronomy*, #3931897. <https://doi.org/10.1155/2017/3931897>
- Engle, R. (2002). Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. *Journal of Business & Economic Statistics*, 20(3), 339–350. <https://doi.org/10.1198/073500102288618487>
- Eni (2017). Annual Statistics Report. World Oil, Gas and Renewables Review 2017. Rome.
- Eni (2018). Annual Statistics Report. World Oil, Gas and Renewables Review 2018. Rome.
- Fabozzi, J., Füss, R., Kaiser, D.G. (2008). A Primer on Commodity Investing. *The Handbook of Commodity Investing*. John Wiley & Sons, Chichester, West Sussex.
- Falkowski, M. (2011). Financialization of commodities. *Contemporary Economics*, 5(4), 4–17. <https://doi.org/10.5709/ce.1897-9254.24>
- FAO (2008). Commodity market review 2007–2008. Rome.
- FAO (2011). Recent trends in world food commodity prices: costs and benefits. Past and future trends in world food prices. [W:] *The State of Food Insecurity in the World. How does international price volatility affect domestic economies and food security?* FAO, Rome, 11–20.
- FAO Statistics (2014–2015). Pobrane z http://faostat3.fao.org/browse/T/*/E.
- Fattouh, B. (2007). The drivers of oil prices: the usefulness and limitations of non-structural models, supply-demand frameworks, and informal approaches. *EIB Papers*, 12(1), 128–156.
- Fattouh, B., Kilian, L., Mahadeva, L. (2013). The role of speculation in oil markets: What have we learned so far? *The Energy Journal*, 34(3), 7–33. <https://doi.org/10.5547/01956574.34.3.2>
- Fournier, J.M., Koske, I., Wanner, I., Zipperer, V. (2013). The Price of Oil – Will it Start Rising Again? OECD Economic Department Working Paper 1031. OECD Publishing. <http://dx.doi.org/10.1787/5k49q186vxnp-en>
- Fowowe, B. (2016). Do oil prices drive agricultural commodity prices? Evidence from South Africa. *Energy*, 104, 149–157. <https://doi.org/10.1016/j.energy.2016.03.101>
- Fratzscher, M., Schneider, D., Van Robays, I. (2014). Oil prices, exchange rates and asset prices. ECB Working Paper 1689. European Central Bank, Frankfurt am Main.
- Fretheim, T. (2019). An empirical analysis of the correlation between large daily changes in grain and oil futures prices. *Journal of Commodity Markets*, 14, 66–75. <https://doi.org/10.1016/j.jcomm.2018.07.002>
- Geman, H. (2007). *Commodities and Commodity Derivatives*. John Wiley & Sons, Chichester, West Sussex.
- Ghaith, Z., Awad, I.M. (2011). Examining the long term relationship between crude oil and food commodity prices: Co-integration and causality. *International Journal of Economics and Management Sciences*, 5(1), 62–72.
- Gilbert, C.L. (2010). How to understand high food prices. *Journal of Agricultural Economics*, 61(2), 398–425. <https://doi.org/10.1111/j.1477-9552.2010.00248.x>
- Global Energy Statistical Yearbook 2018. Enerdata.

- Gocłowska-Bolek, J. (2018). Proces uzależnienia gospodarki Wenezueli od przemysłu naftowego. *Studia – Eseje. Ameryka Łacińska. Kwartalnik Analityczno-Informacyjny*, 2(100), 107–132.
- Goczek, Ł. (2012). Podejście wektorowej autoregresji na próbie przekrojowo-czasowej do szacowania skutków niestabilności polityki fiskalnej. *Roczniki Kolegium Analiz Ekonomicznych*, 26, 103–116.
- Gohin, A., Chantret, F. (2010). The long-run impact of energy prices on world agricultural markets: The role of macro-economic linkages. *Energy Policy*, 38(1), 333–339. <https://doi.org/10.1016/j.enpol.2009.09.023>
- Gorton, G., Rouwenhorst, K.G. (2004). Facts and Fantasies About Commodity Futures. Yale ICF Working Paper 04-20. Yale International Center for Finance, New Haven, CT.
- Gorton, G., Rouwenhorst, K.G. (2006). Facts and Fantasies about Commodity Futures. *Financial Analysts Journal*, 62(2), 47–68. <https://doi.org/10.2469/faj.v62.n2.4083>
- Granger, C.W.J. (1969). Investing Casual Relationships by Econometric Models and Cross-spectral Methods. *Econometrica*, 37(3), 424–438.
- Gujarati, D.N. (2003). *Basic Econometrics*. McGraw-Hill, Boston.
- Hamilton, J.D. (2008). Understanding crude oil prices. NBER Working Paper 14492. <http://doi.org/10.3386/w14492>
- Hamulczuk, M., Gędek, S., Klimkowski, C., Stańko, S. (2012). Prognozowanie cen surowców rolnych na podstawie zależności przyczynowych. Wydawnictwo Instytutu Ekonomiki Rolnictwa i Gospodarki Żywnościowej, Warszawa.
- Hamulczuk, M., Klimkowski, C. (2011). Powiązania między cenami ropy a cenami pszenicy w Polsce. *Roczniki Nauk Rolniczych*, 98(3), 176–191.
- Hanson, K., Robinson, S., Schluter, G. (1993). Sectorial effects of a world oil price shock: Economy wide linkages to the agricultural sector. *Journal of Agricultural and Resource Economics*, 18, 96–116.
- Harri, A., Nalley, L., Hudson, D. (2009). The Relationship between Oil, Exchange Rates, and Commodity Prices. *Journal of Agricultural and Applied Economics*, 41(2), 501–510. <https://doi.org/10.1017/S1074070800002959>
- Hennemuth, L. (2012). 1980 U.S. Partial Grain Embargo: Pragmatism's Centrality to Argentine Refusal to Cooperate. *The Monitor*, 17(2), 44–55.
- Hertel, Th.W., Beckman, J. (2011). Commodity price volatility in the biofuel era: an examination of the linkage between energy and agricultural markets. NBER Working Paper 16824. <http://doi.org/10.3386/w16824>
- Hochman, G., Kaplan, S., Rajagopal, D., Zilberman, D. (2012). Biofuel and Food-Commodity Prices. *Agriculture*, 2(3), 272–281. <http://dx.doi.org/10.3390/agriculture2030272>
- Hymel, M.L. (2007). Globalisation, Environmental Justice, and Sustainable Development: The Case of Oil. *Macquarie Law Journal*, 7, 125–153.
- Irwin, S.H., Sanders, D.R. (2012). Financialization and structural change in commodity futures markets. *Journal of Agricultural and Applied Economics*, 44(3), 371–396. <http://doi.org/10.1017/S1074070800000481>
- Jagusiak, K. (2015). Zboża, rośliny strączkowe i warzywa w źródłach medycznych antyku i wczesnego Bizancjum (II–VII w.) Praca doktorska. Uniwersytet Łódzki, Łódź [manuskrypt].

- Jain, A., Biswal, P.C. (2016). Dynamic linkages among oil price, gold price, exchange rate, and stock market in India. *Resources Policy*, 49, 179–185. <https://doi.org/10.1016/j.resourpol.2016.06.001>
- Jankowiak, L., Makiela, M. (1968). Pszenica na rynku światowym. *Ruch Prawniczy, Ekonomiczny i Socjologiczny*, 31(2), 77–93.
- Jeong, K., Härdle, W.K., Song, S. (2012). A consistent nonparametric test for causality in quantile. *Econometric Theory*, 28(4), 861–887. <https://doi.org/10.1017/S0266466611000685>
- Jewulski, J. (2006). Specyfika eksploatacji ropy ciężkiej ze złoża „Lubaczów”. *Wiertnictwo, Nafta, Gaz*, Tom 23(2), 659–666.
- Jouni, J., Boutahar, M. (2005). Evidence on Structural Changes in US Time Series. *Economic Modelling*, 22, 391–422.
- Kaliski, M., Jedynek, Z. (2009). Czynniki kształtujące ceny ropy naftowej w świecie w roku 2008. *Wiertnictwo, Nafta, Gaz*, 26, 205–212.
- Kanjilal, K., Ghosh, S. (2017). Dynamics of crude oil and gold price post 2008 global financial crisis – New evidence from threshold vector error-correction model. *Resources Policy*, 52, 358–365. <https://doi.org/10.1016/j.resourpol.2017.04.001>
- Khalifaoui, R. (2018). Oil–gold time varying nexus: A time–frequency analysis. *Physica A: Statistical Mechanics and its Applications*, 503(1), 86–104. <https://doi.org/10.1016/j.physa.2018.02.198>
- Kłaczyński, R. (2010). Ropa naftowa i gaz ziemny obszaru postradzieckiego. Rola i znaczenie surowców energetycznych w polityce Kremla. Wydawnictwo Naukowe Uniwersytetu Pedagogicznego, Kraków.
- Krawiec, M. (2016). Formy i efektywność inwestowania w towary w warunkach polskiego rynku. Wydawnictwo SGGW, Warszawa.
- Kristoufek, L., Janda, K., Zilberman, D. (2012). Correlations between biofuels and related commodities before and during the food crisis: a taxonomy perspective. *Energy Economics*, 34, 1380–1391.
- Kumar, S. (2017). On the nonlinear relation between crude oil and gold. *Resources Policy*, 51, 219–224. <https://doi.org/10.1016/j.resourpol.2017.01.003>
- Kusideł, E. (2000). Modele wektorowo-autoregresyjne VAR. Metodologia i zastosowania. Absolwent, Olsztyn.
- Laidi, A. (2012). Międzyrynkowa analiza kursów walutowych. Forex, złoto, ropa i globalne rynki finansowe. Wydawnictwo Linia, Warszawa.
- Liu, L. (2014). Cross-correlations between crude oil and agricultural commodity markets. *Physica A: Statistical Mechanics and its Applications*, 395, 293–302.
- Liu, M-L., Ji, Q., Fan, Y. (2013). How does oil market uncertainty interact with other markets? An empirical analysis of implied volatility index. *Energy*, 55, 860–868. <https://doi.org/10.1016/j.energy.2013.04.037>
- Łęt, B. (2012). Ekonometryczne modelowanie czynników ryzyka na rynku surowców energetycznych. Uniwersytet Ekonomiczny w Poznaniu, Poznań.
- Lucotte, Y. (2016). Co-movements between crude oil and food prices: A post-commodity boom perspective. *Economics Letters*, 147, 142–147. <https://doi.org/10.1016/j.econlet.2016.08.032>
- Lütkepohl, H. (2005). *New introduction to multiple time series analysis*. Springer, Berlin–Heidelberg–New York

- Lütkepohl, H., Krätzig, M. (2007). *Applied Time Series Econometrics*. Cambridge University Press, New York.
- Ma, Z., Xu, R., Dong, X. (2015). World oil prices and agricultural commodity prices: The evidence from China. *Agricultural Economics (Czech Republic)*, 61(12), 564–576.
- McCalla, A.F. (2009). World food prices: Causes and consequences. *Canadian Journal of Agricultural Economics (Revue Canadienne d'Agroeconomie)*, 57(1), 23–34. <https://doi.org/10.1111/j.1744-7976.2008.01136.x>
- Melvin, M., Sultan, J. (1990). South African political unrest, oil prices, and the time varying risk premium in the gold futures market. *Journal of Futures Markets*, 10(2), 103–111. <https://doi.org/10.1002/fut.3990100202>
- Mikita, M., Pełka, W. (2009). *Rynki inwestycji alternatywnych*. Wydawnictwo POLTEXT, Warszawa.
- Mitchell, D. (2008). A note on rising food prices. World Bank Policy Research Working Paper 4682. World Bank, Washington, DC.
- Mo, B., Nie, H., Jiang, Y. (2018). Dynamic linkages among the gold market, US dollar and crude oil market. *Physica A: Statistical Mechanics and its Applications*, 491, 984–994. <https://doi.org/10.1016/j.physa.2017.09.091>
- Moy, J. (1985). Recent trends in unemployment and the labor force, 10 countries. *Monthly Labor Review*, 108(8), 9–22.
- Murphy, J.J. (1998). *Międzyrynkowa analiza techniczna*. WIG-Press, Warszawa.
- Narayan, P.K., Narayan, S., Zheng, X. (2010). Gold and oil futures markets: Are markets efficient? *Applied Energy*, 87(10), 3299–3303. <https://doi.org/10.1016/j.apenergy.2010.03.020>
- Nazlioglu, S., Soytas, U. (2011). World oil prices and agricultural commodity prices: Evidence from an emerging market. *Energy Economics*, 33(3), 488–496. <https://doi.org/10.1016/j.eneco.2010.11.012>
- Nazlioglu, S., Soytas, U. (2012). Oil price, agricultural commodity prices, and the dollar: A panel cointegration and causality analysis. *Energy Economics*, 34(4), 1098–1104. <https://doi.org/10.1016/j.eneco.2011.09.008>
- Nazlioglu, S., Erdem, C., Soytas, U. (2013). Volatility spillover between oil and agricultural commodity markets. *Energy Economics*, 36, 658–665. <https://doi.org/10.1016/j.eneco.2012.11.009>
- Norton, G.W., Alwang, J., Masters, W.A. (2010). *Economics of Agricultural Development*. Routledge, New York.
- Obadi, S.M., Korček, M. (2014). Are Food Prices Affected by Crude Oil Price? Causality Investigation. *Review of Integrative Business and Economics Research*, 3(1), 391–407. <https://doi.org/10.13140/2.1.2822.2407>
- Önel, G. (2005). Testing for Multiple Structural Breaks: An Application of Bai-Perron Test to the Nominal Interest Rates and Inflation in Turkey. *Dokuz Eylül University Faculty of Economics and Administrative Sciences Journal (D.E.Ü.Ý.Ý.B.F. Dergisi)*, 20(2), 81–94.
- OPEC Annual Statistical Bulletin 2018. Organization of the Petroleum Exporting Countries, Vienna. Pobrane z https://www.opec.org/opec_web/en/publications/202.htm
- Osikowicz, R. (2012). Rynek ropy naftowej na świecie. *Paliwa i Energetyka*, 3, 29–51.
- Osińska, M. (2008). *Ekonometryczna analiza zależności przyczynowych*. Wydawnictwo Naukowe Uniwersytetu Mikołaja Kopernika, Toruń.

- Pal, D., Mitra, S.K. (2018). Interdependence between crude oil and world food prices: A detrended cross correlation analysis. *Physica A: Statistical Mechanics and Its Applications*, 492, 1032–1044. <https://doi.org/10.1016/j.physa.2017.11.033>
- Papież, M., Śmiech, S. (2015). Modelowanie i prognozowanie cen surowców energetycznych. Wydawnictwo C.H. Beck, Warszawa.
- Perron, P. (1989). The Great Crash, the Oil-Price Shock, and the Unit-Root Hypothesis. *Econometrica*, 57, 1361–1401.
- Phillips, P.C.B. (1986). Understanding spurious regressions in econometrics. *Journal of Econometrics*, 33, 311–340.
- Pirrong, C. (2008). Structural models of commodity prices. [W:] *Risk Management in Commodity Markets: From Shipping to Agriculturals and Energy*. Red. H. Geman. John Wiley & Sons, Hoboken, NJ.
- Płókarz, R. (2013). *Globalne rynki finansowe. Praktyka funkcjonowania*. Wydawnictwo Naukowe PWN, Warszawa.
- Pring, M. (1998). *Podstawy analizy technicznej*. WIG-Press, Warszawa.
- Quandt, R.E. (1958). The Estimation of Parameters of a Linear Regression System Obeying Two Separate Regimes. *Journal of the American Statistical Association*, 53(284), 873–880.
- Quandt, R.E. (1960). Tests of The Hypothesis that a Linear Regression Obeys Two Separate Regimes. *Journal of the American Statistical Association*, 55, 324–330. <https://doi.org/10.1080/01621459.1960.10482067>
- Ramanathan, R. (2002). *Introductory Econometrics with Applications*. South-Western Thomson Learning, Mason, Ohio.
- Rapsomanikis, G. (2009). Policies for the effective management of food price swings. *FAO Commodity and Trade Policy Technical Paper 12*. Food and Agriculture Organization of the United Nations, Rome.
- Reboredo, J.C. (2012). Do food and oil prices co-move? *Energy Policy*, 49, 456–467. <https://doi.org/10.1016/j.enpol.2012.06.035>
- Reboredo, J.C. (2013). Is gold a hedge or safe haven against oil price movements? *Resources Policy*, 38(2), 130–137. <https://doi.org/10.1016/j.jbankfin.2013.03.020>
- Rezitis, A.N. (2015). Empirical Analysis of Agricultural Commodity Prices, Crude Oil Prices and US Dollar Exchange Rates Using Panel Data Econometric Methods. *International Journal of Energy Economics and Policy*, 5(3), 851–868.
- Rosegrant, M. (2008). *Biofuels and Grain Prices: Impacts and Policy Responses*. Testimony for the U.S. Senate Committee on Homeland Security and Governmental Affairs. International Food Policy Research Institute, Washington, DC.
- Sadorsky, P. (2014). Modeling volatility and correlations between emerging market stock prices and the prices of copper, oil and wheat. *Energy Economics*, 43, 72–81. <https://doi.org/10.1016/j.eneco.2014.02.014>
- Saghaian, S.H. (2010). The Impact of the Oil Sector on Commodity Prices: Correlation or Causation? *Journal of Agricultural and Applied Economics*, 42(3), 477–485. <https://doi.org/10.1017/S107407080003667>
- Samuelson P., Nordhaus W. (2004). *Ekonomia*. Wydawnictwo Naukowe PWN, Warszawa.
- Schiller, B. (1989). *The economy today*. Random Mouse Business Division, New York.
- Sephton, P., Mann, J. (2018). Gold and crude oil prices after the great moderation. *Energy Economics*, 71, 273–281. <https://doi.org/10.1016/j.eneco.2018.02.022>

- Shafiee, S., Topal, E. (2010). An overview of global gold market and gold price forecasting. *Resources Policy*, 35(3), 178–189. <https://doi.org/10.1016/j.resourpol.2010.05.004>
- Shahbaz, M., Balcilar, M., Ozdemir, Z.A. (2017). Does oil predict gold? A nonparametric causality-in-quantiles approach. *Resources Policy*, 52, 257–265. <https://doi.org/10.1016/j.resourpol.2017.03.004>
- Sierakowska, D. (2016). *Świat surowców*. Wydawnictwo Trend Edukacja Finansowa, Warszawa.
- Sims, C.A. (1980). Macroeconomics and Reality. *Econometrica*, 48(1), 1–48.
- Socha, R., Wdowiński, P. (2018). Tendencje zmian cen na światowym rynku ropy naftowej po 2000 roku. *Gospodarka Narodowa*, (1), 103–135.
- Sorrell, S., Speirs, J., Bentley, R., Miller, R., Thompson, E. (2012). Shaping the global oil peak: a review of the evidence on field sizes, reserve growth, decline rates and depletion rates. *Energy*, 37(1), 709–724. <https://doi.org/10.1016/j.energy.2011.10.010>
- Srinivasan, S. (2009). The food vs. fuel debate: A nuanced view of incentive structures. *Renewable Energy*, 34(4), 950–954. <http://doi.org/10.1016/j.renene.2008.08.015>
- Summary, E. (2014). Stocks and the Stocks to Use Ratio: Are They Meaningful for Price Determination?, 1–32.
- Szajner, P., Bodył, M., Łopaciuk, W., Rosiak, E. (2015). Sytuacja na światowym rynku zbóż, roślin oleistych, cukru i biopaliw oraz jej wpływ na krajowe rynki produktów roślinnych i możliwości ich rozwoju. Instytut Ekonomiki Rolnictwa i Gospodarki Żywnościowej – Państwowy Instytut Badawczy, Warszawa.
- Tekliński, M. (2018). Złoto zakończyło najlepszy rok od 2010. *Mysaver. Magazyn o Twoich Pieniądzach*. Pobrane z <https://goldenmark.com/pl/mysaver/zloto-zakonczylo-najlepszy-rok-od-2010/>
- Tomaszewski, J. (2011). Commodity risk and commodity risk management. [W:] *Ryzyko w działalności podmiotów gospodarczych*. Red. A. Włodarczyk. Wydawnictwo Politechniki Częstochowskiej, Częstochowa.
- Tomaszewski, J. (2013). Instrumenty towarowe jako forma inwestycji alternatywnych w portfelach inwestorów finansowych. *Oficyna Wydawnicza Szkoły Głównej Handlowej w Warszawie*, Warszawa.
- Tomaszewski, J. (2015). Finansjalizacja a zmiany strukturalne na rynku towarów rolnych w pierwszych latach XXI w. *Annales Universitatis Mariae Curie-Skłodowska Lublin – Polonia*, H, 49(4), 601–610. <http://dx.doi.org/10.17951/h.2015.49.4.601>
- Tomaszewski, J. (2016). Finansjalizacja rynku towarowego a regulacja rynku towarowych instrumentów pochodnych Unii Europejskiej. *Finanse, Rynki Finansowe, Ubezpieczenia*, 1(79), 137–147. <http://doi.org/10.18276/frfu.2016.79-10>
- Tully, E., Lucey, B.M. (2007). A power GARCH examination of the gold market. *Research in International Business and Finance*, 21(2), 316–325. <http://doi.org/10.1016/j.ribaf.2006.07.001>
- U.S. Geological Survey (2001–2018). *Mineral commodity summaries 2001–2018*. U.S. Geological Survey, Reston, Virginia. Pobrane z <https://www.usgs.gov/centers/nmic/mineral-commodity-summaries>
- Ulatowski, R. (2014). *Geoekonomia surowców energetycznych*. Wydawnictwo Rambler, Warszawa.
- Vilayil, S.I., Tiwari, A., Sahadudheen, I. (2015). Understanding the nexus between oil and gold. *Resources Policy*, 46, 85–91. <https://doi.org/10.1016/j.resourpol.2015.09.003>

- Wang, Y., Wu, C., Yang, L. (2014). Oil price shocks and agricultural commodity prices. *Energy Economics*, 44, 22–35. <https://doi.org/10.1016/j.eneco.2014.03.016>
- Wei, C.C., Chen, S.M. (2016). Examining the relationship of crude oil future price return and agricultural future price return in US. *International Journal of Energy Economics and Policy*, 6(1), 58–64.
- Witkowska, D., Matuszewska, A., Kompa, K. (2008). *Wprowadzenie do ekonometrii dynamicznej i finansowej*. Wydawnictwo SGGW, Warszawa.
- Wójcik, A. (2014). Modele wektorowo-autoregresyjne jako odpowiedź na krytykę strukturalnych wielorównaniowych modeli ekonometrycznych. *Studia Ekonomiczne*, 193, 112–128.
- Xiaoping, H., Wentao, T., & Xingming, F. (2004). An Analysis and Comparison of Wheat Production Competitiveness between China and the USA. *Journal of Economic Issues*, 38(4), 1074–1082. <https://doi.org/10.1080/00213624.2004.11506762>
- Xiaodong, D., Hayes, D. (2009). The impact of ethanol production on us and regional gasoline markets. *Energy Policy*, 37, 3227–3234.
- Yaya, O.S., Tumala, M.M., Udomboso, Ch.G. (2016). Volatility persistence and returns spillovers between oil and gold prices: Analysis before and after the global financial crisis. *Resources Policy*, 49(C), 273–281. <https://doi.org/10.1016/j.resourpol.2016.06.008>
- Yousefi, A., Wirjanto, T.S. (2003). Exchange rate of the US dollar and the J curve: the case of oil exporting countries. *Energy Economics*, 25(6), 741–765. [https://doi.org/10.1016/S0140-9883\(03\)00044-6](https://doi.org/10.1016/S0140-9883(03)00044-6)
- Zawojcka, A. (2011). Czy spekulacje finansowe wpływają na międzynarodowe ceny towarów rolno-żywnościowych? *Zeszyty Naukowe Szkoły Głównej Gospodarstwa Wiejskiego w Warszawie. Problemy Rolnictwa Światowego*, 11(26), 1, 177–192.
- Zeng, D., Bobenrieth, E., Wright, B.D. (2013). Stocks-to-use ratios and prices as indicators of vulnerability to spikes in global cereal markets. *Agricultural Economics*, 44. <https://doi.org/10.1111/agec.12049>
- Zhang, Y-J., Wei, Y-M. (2010). The crude oil market and the gold market: Evidence for cointegration, causality and price discovery. *Resources Policy*, 35(3), 168–177. <https://doi.org/10.1016/j.resourpol.2010.05.003>
- Zhang, Z., Lohr, L., Escalante, C., Wetzstein, M. (2010). Food versus fuel: What do prices tell us? *Energy Policy*, 38(1), 445–451. <https://doi.org/10.1016/j.enpol.2009.09.034>
- Zivot, E., Andrews, D.W.K. (1992). Further Evidence on the Great Crash, the Oil-Price Shock, and the Unit-Root Hypothesis. *Journal of Business and Economic Statistics*, 10, 251–270. <http://dx.doi.org/10.2307/1391541>

