



**INSTYTUT EKONOMIKI ROLNICTWA  
I GOSPODARKI ŻYWNOŚCIOWEJ  
PAŃSTWOWY INSTYTUT BADAWCZY**

**nr 114**  
**Warszawa 2014**

**Wybrane problemy  
prognozowania  
detaicznych  
cen żywności**

**KONKURENCYJNOŚĆ POLSKIEJ GOSPODARKI  
ŻYWNOŚCIOWEJ W WARUNKACH GLOBALIZACJI  
I INTEGRACJI EUROPEJSKIEJ**



**Wybrane problemy  
prognozowania  
detailed  
cen żywności**





INSTYTUT EKONOMIKI ROLNICTWA  
I GOSPODARKI ŻYWNOŚCIOWEJ  
PAŃSTWOWY INSTYTUT BADAWCZY

# Wybrane problemy prognozowania detalicznych cen żywności

*Autorzy:*

*dr inż. Mariusz Hamulczuk (red.)*

*mgr Katarzyna Hertel*

*mgr Cezary Klimkowski*

*dr hab. Stanisław Stańko, prof. SGGW*



KONKURENCYJNOŚĆ POLSKIEJ GOSPODARKI  
ŻYWNOŚCIOWEJ W WARUNKACH GLOBALIZACJI  
I INTEGRACJI EUROPEJSKIEJ

**Warszawa 2014**

Mgr Katarzyna Hertel jest pracownikiem Narodowego Banku Polskiego

Pozostali autorzy publikacji są pracownikami Instytutu Ekonomiki Rolnictwa i Gospodarki Żywnościowej – Państwowego Instytutu Badawczego

Pracę zrealizowano w ramach tematu

**Zastosowanie modelowania ekonomicznego w analizie przesłanek konkurencyjnego rozwoju sektora rolno-żywnościowego**

w zadaniu *System prognostyczny służący podnoszeniu konkurencyjności sektora rolno-żywnościowego*

Celem opracowania było przedstawienie podstaw teoretycznych kształtowania się cen żywności oraz możliwości analizy i krótkookresowego prognozowania detalicznych cen żywności w Polsce na podstawie modeli ilościowych.

Recenzent

*dr hab. Hanna Dudek, Szkoła Główna Gospodarstwa Wiejskiego w Warszawie*

Korekta

*Joanna Gozdera*

Redakcja techniczna

*Leszek Ślipiński*

Projekt okładki

*AKME Projekty Sp. z o.o.*

ISBN 978-83-7658-493-5

*Instytut Ekonomiki Rolnictwa i Gospodarki Żywnościowej*

*– Państwowy Instytut Badawczy*

*ul. Świętokrzyska 20, 00-002 Warszawa,*

*tel.: (22) 50 54 444*

*faks: (22) 50 54 636*

*e-mail: [dw@ierigz.waw.pl](mailto:dw@ierigz.waw.pl)*

*<http://www.ierigz.waw.pl>*

## Spis treści

Wstęp.....	7
1. Aspekty teoretyczne popytu na żywność.....	9
1.1. Żywność – definicja, znaczenie i rodzaje .....	9
1.2. Klasyfikacja produktów żywnościowych .....	10
1.3. Cechy rynku żywności i jego kategorie .....	11
1.4. Trendy w konsumpcji.....	17
1.5. Wskaźnik cen żywności a struktura wydatków .....	22
2. Teoretyczne uwarunkowania zmian cen w łańcuchu marketingowym – mechanizmy.....	26
2.1. Ogniwa łańcucha marketingowego .....	26
2.2. Rozstęp cenowy i marża marketingowa.....	29
2.2.1. Definicje .....	29
2.2.2. Analityczne ujęcie rozstępu cenowego .....	31
2.3. Ceny żywności i ich determinanty .....	34
2.3.1. Ogólne prawidłowości.....	34
2.3.2. Koszty pozarolnicze .....	36
2.3.3. Determinanty zmian rozstępów cenowych.....	39
2.4. Transmisja cen w łańcuchu marketingowym.....	41
2.4.1. Pionowa transmisja cen .....	41
2.4.2. Asymetria transmisji.....	43
3. Metody analizy i krótkookresowego prognozowania cen detalicznych żywności....	46
3.1. Koncepcje prognozowania cen detalicznych .....	46
3.2. Prawidłowości i zależności w czasie.....	50
3.2.1. Szeregi czasowe i ich struktura .....	50
3.2.2. Przyczynowość i zależności długookresowe.....	54
3.3. Metody i modele analizy i prognozowania szeregów czasowych .....	56
3.3.1. Model ekonometryczny .....	56
3.3.2. Modele ARIMA i regARIMA .....	58
3.3.3. Metody i modele wygładzania wykładniczego .....	60
3.4. Metody prognozowania uwzględniające interakcje z innymi zmiennymi.....	65
3.4.1. Modele jednorównaniowe .....	65
3.4.2. Modele VAR i VECM.....	68
4. Empiryczna analiza zmian wybranych cen produktów rolnych i cen detalicznych..	71
4.1. Zboża i produkty zbożowe .....	72
4.2. Mięso wołowe .....	76
4.3. Mięso wieprzowe .....	80
4.4. Mięso drobiowe.....	82
4.5. Mleko i produkty mleczne .....	85
4.6. Rynek jaj .....	88
4.7. Rzepak i tłuszcze roślinne .....	91
4.8. Rynek cukru .....	93

5. Prognozowanie cen detalicznych na podstawie modeli regARIMA oraz ETS .....	97
5.1. Wprowadzenie.....	97
5.2. Estymacja modeli wykładniczego ETS .....	100
5.3. Specyfikacja i estymacja modeli regARIMA .....	105
5.4. Dokładność prognoz.....	112
6. Prognozowanie cen detalicznych na podstawie zależności przyczynowo-skutkowych .....	119
6.1. Szeregi czasowe oraz ich właściwości.....	119
6.2. Specyfikacja dynamicznych modeli zgodnych dla poziomów .....	122
6.3. Specyfikacja modeli korekty błędem.....	128
6.4. Specyfikacja modeli VAR/VECM.....	131
6.5. Porównanie dokładności prognoz ex post.....	134
7. Prognozowanie wskaźników detalicznych cen żywności z wykorzystaniem modeli szeregów czasowych .....	137
7.1. Wprowadzenie.....	137
7.2. Dane .....	138
7.3. Specyfikacja i estymacja modeli ETS.....	145
7.4. Specyfikacja i estymacja modeli regARIMA .....	148
7.5. Prognozy i ich dokładność .....	154
8. Prognozowanie wskaźników detalicznych cen żywności na podstawie zależności przyczynowych .....	160
8.1. Wprowadzenie do modelowania.....	160
8.2. Dane statystyczne.....	164
8.3. Specyfikacja, estymacja i weryfikacja modeli jednorównaniowych .....	168
8.4. Specyfikacja, estymacja i weryfikacja modeli VAR/VECM.....	175
8.5. Prognozy i ich weryfikacja.....	180
Podsumowanie .....	184
Literatura.....	187
Aneks.....	197

## Wstęp

Potrzeby żywnościowe należą do podstawowych potrzeb zaspokajanych przez człowieka. Konieczność konsumowania żywności oraz kwestie bezpieczeństwa żywnościowego skutkują tym, że analizom cen żywności poświęca się ciągle sporo miejsca. Dzieje się tak mimo malejącego w czasie udziału wydatków na żywność gospodarstw domowych. O znaczeniu problemów związanych z ekonomicznym dostępem do żywności można było się przekonać w ostatnich pięciu latach, kiedy w świecie doświadczonego gwałtownego wzrostu cen produktów rolno-żywnościowych oraz ich zmienności. Powszechnie zaczęto używać pojęcia *globalny kryzys żywnościowy*. Równocześnie pojawiło się szereg pytań dotyczących przyczyn, implikacji i potencjalnych działań polityki ekonomicznej mających na celu zarówno niwelowanie, jak i przeciwdziałanie negatywnym konsekwencjom niestabilności cenowej.

Fakt, że rolnictwo i jego sektory zostają poddane znacznie większemu oddziaływaniu praw popytu i podaży skutkuje wzrostem zapotrzebowania na informacje rynkowe. Jednym z pytań jest, czy możliwe jest przewidywanie cen rolnych i cen żywności zarówno w ujęciu globalnym, jak i krajowym. Zagadnieniu prognozowania cen surowców rolnych poświęcono trzy lata prac badawczych w temacie *System prognostyczny w podnoszeniu konkurencyjności sektora rolno-żywnościowego* w ramach Programu Wieloletniego (PW) prowadzonego w IERiGŻ-PIB. Niniejsze opracowanie przedstawia wyniki prac poświęconych modelowaniu i krótkookresowemu prognozowaniu cen detalicznych żywności i stanowi uzupełnienie badań wcześniejszych. Efektem prac jest przedstawienie mechanizmów leżących u podstaw kształtowania się cen żywności, metod umożliwiających analizę i prognozowanie oraz ocena ich przydatności. Badania takie obok warstwy poznawczej mają również przesłanki praktyczne. Z jednej strony, pozwalają bowiem ułatwiać podejmowanie indywidualnych wyborów uczestnikom poprzez głębokie zrozumienie mechanizmów, jakim podlega rynek. Z drugiej strony wnioski o charakterze aplikacyjnym mogą służyć analitykom oraz uczestnikom rynku w konstruowaniu prognoz opartych na metodach ilościowych.

Zasadniczym celem badań jest sformułowanie wniosków na temat możliwości prognozowania cen detalicznych żywności w Polsce z wykorzystaniem modeli ilościowych. Mamy tutaj na myśli zarówno prognozowanie cen indywidualnych produktów, jak i prognozowanie wskaźników cen żywności (inflacji). Wnioski obejmują zarówno trudności metodyczne, problemy z dostępnością danych oraz zawierają propozycje praktycznych rozwiązań.



Opracowanie obejmuje osiem rozdziałów, z czego trzy pierwsze poświęcono przeglądowi literatury, zaś kolejne pięć wynikiem analiz empirycznych. W rozdziale pierwszym zdefiniowano pojęcie „żywność”, omówiono cechy rynku żywności, czynniki kształtujące popyt, a także występujące prawidłowości w zakresie poziomu i struktury wydatków na żywność. Rozdział drugi stanowi uzupełnienie tych rozważań o mechanizmy leżące u podstaw kształtowania cen żywności w łańcuchu marketingowym. Ważną częścią rozdziału są zagadnienia pionowej transmisji cen.

W rozdziale trzecim przedstawiono metodyczne koncepcje, które stanowić mogą podstawę prognozowania cen detalicznych żywności. Zostały one uzupełnione krótkim przeglądem narzędzi, które mogą być wykorzystane w analizach empirycznych i krótkookresowym prognozowaniu. Rozdział czwarty zawiera wyniki analiz empirycznych cen w łańcuchu marketingowym wybranych produktów rolno-żywnościowych. Dokonano w nim analizy zmian dynamiki cen surowców rolnych, cen detalicznych oraz rozstępów cenowych między nimi z wykorzystaniem modeli dekompozycji szeregu czasowego X-12-ARIMA.

W rozdziale piątym podjęto próbę implementacji modeli regARIMA oraz modeli wygładzania wykładniczego ETS do prognozowania cen detalicznych wybranych produktów żywnościowych. W rozdziale zawarto wyniki estymacji tych modeli oraz zaprezentowano prognozy detalicznych cen wybranych produktów żywnościowych oraz dokonano oceny *ex-post* tychże prognoz. W kolejnym rozdziale przedstawiono ważniejsze problemy prognozowania cen detalicznych wybranych produktów żywnościowych na podstawie modeli opartych na zależnościach przyczynowo-skutkowych. Przybliżono tam problemy specyfikacji i prognozowania na podstawie modeli zgodnych, modeli korekty błędem oraz VAR/VECM.

Rozdziały siódmy i ósmy poświęcono prognozowaniu wskaźników cen detalicznych żywności w Polsce. Z jednej strony posłużono się modelami szeregów czasowych, zaś z drugiej modelami bazującymi na związkach przyczynowo-skutkowych. Nawiązano do bezpośredniego prognozowania zagregowanego wskaźnika cen żywności lub też prognozowania wskaźników cen różnych kategorii żywności i ich agregacji.

Autorzy pragną serdecznie podziękować recenzentowi opracowania w osobie Pani dr hab. Hanny Dudek, za cenne uwagi i sugestie, jakie była skłonna zgłosić do pierwotnej wersji tekstu.

# 1. Aspekty teoretyczne popytu na żywność

Współcześnie występuje wiele kategorii pojęciowych słowa „żywność”. W rozdziale przedstawiono w miarę jednoznacznie definicję pojęcia „żywność” i jej różne klasyfikacje. Omówiono cechy rynku żywności, czynniki kształtujące popyt, a także występujące prawidłowości w zakresie poziomu i struktury wydatków na żywność. Przedstawiono grupy żywności oraz wagi stosowane w obliczeniach wskaźników cen żywności.

## 1.1. Żywność – definicja, znaczenie i rodzaje

Istnieje szeroka gama terminów pojęciowych definiujących „żywność” tworzona na potrzeby różnych sfer życia. Według Encyklopedii Popularnej żywność to „artykuły żywnościowe, środki spożywcze, wszelkie produkty pochodzenia roślinnego i zwierzęcego, które w stanie naturalnym lub po obróbce stanowią materiał budulcowy i energetyczny człowieka” [1982, s. 909], a w Nowej Encyklopedii Powszechnej określono: „żywność (jako) produkt pochodzenia roślinnego lub zwierzęcego, który w stanie naturalnym lub po przetworzeniu jest spożywany przez ludzi” [2004, s. 908]. Określenia te współcześnie nie w pełni przedstawiają istotę pojęcia „żywność”.

Ogólniejszą definicję można znaleźć w prawie żywnościowym Unii Europejskiej, które obowiązuje w naszym kraju. Zgodnie z regulacjami UE „Żywność (lub produkty spożywcze) oznacza substancje lub produkty przetworzone, częściowo przetworzone lub nieprzetworzone, przeznaczone do spożycia przez ludzi lub których spożycia przez ludzi można się spodziewać” [art. 2 Rozp. WE nr 178/2002]<sup>1</sup>. Do żywności zalicza się również napoje, gumę do żucia oraz każdą substancję włączoną w sposób zamierzony w skład żywności podczas produkcji, przygotowania lub przetwarzania, jak również wodę. Tak określona definicja żywności oznacza, że dotyczy ona produktów, które są konsumowane przez ludzi.

Żywność jest dobrem szczególnym, gdyż zaspokaja nie tylko najbardziej elementarne spośród fizjologicznych potrzeb człowieka, ale także służy zaspokojeniu różnorodnych potrzeb indywidualnych i społecznych, materialnych i duchowych [Kosicka-Gębska i inni 2011]. Oczekiwania konsumentów wobec produktów żywnościowych w rozwoju historycznym ulegały zmianom.

---

<sup>1</sup> Rozporządzenie Parlamentu Europejskiego i Rady (WE) nr 178/2002 z 28 stycznia 2002 ustalające ogólne zasady i wymagania prawa żywnościowego, ustanawiające Europejski Urząd ds. Bezpieczeństwa Żywności oraz ustanawiające procedury w sprawie bezpieczeństwa żywnościowego.

Współczesny konsument z krajów wysoko rozwiniętych wymaga produktów, które będą dla niego bezpieczne i atrakcyjne. Coraz częściej poszukuje się także produktów, które korzystnie wpływają na zdrowie, posiadają atrakcyjne cechy sensoryczne i są łatwe do przygotowania.

## 1.2. Klasyfikacja produktów żywnościowych

Produkty żywnościowe stanowią dużą i niejednorodną grupę. Produkty żywnościowe można klasyfikować według różnych kryteriów. Może to być: pochodzenie, skład chemiczny, stopień przetworzenia, skala potrzeb itp.

Ze względu na pochodzenie produktu wyróżniamy:

- produkty pochodzenia roślinnego,
- produkty pochodzenia zwierzęcego.

Ze względu na stopień przetworzenia możemy wyróżnić:

- żywność nieprzetworzoną (np. świeże owoce czy warzywa);
- żywność przetworzoną, w tym;
  - produkty wstępnie przetworzone np. mąka, kasza;
  - produkty wysoko przetworzone np. makarony, wędliny.

Ze względu na dominujący składnik odżywczy możemy wyróżnić:

- produkty białkowe,
- produkty bogate w sacharydy,
- tłuszcze jadalne,
- owoce i warzywa [*Chemia...2002*, s. 29, Świetlik 2008, s. 29].

Według skali potrzeb, produkty żywnościowe dzieli się na :

- podstawowe (np. chleb, mleko i jego przetwory);
- wyższego rzędu (np. czekolada, lepsze gatunki mięsa);
- luksusowe (np. kawior) [*Jeznach 2007*, s. 16].

Jeszcze inne podziały żywności występują w nauce o żywieniu człowieka. Najczęściej przyjmuje się tu podział żywności na kilka lub kilkanaście grup w zależności od wartości odżywczej, czy składu chemicznego [*Kunachowicz, Czarnocka-Misztal, Turlejska 2000*]. Podstawowe kryteria klasyfikacji przedstawiła Świetlik [2008, s. 28-35].

Różnorodność klasyfikacji powoduje, że występuje wiele terminów charakteryzujących żywność. Oprócz przedstawionych podziałów mamy także takie terminy, jak: żywność wygodna, funkcjonalna, zdrowa, konwencjonalna, ekologiczna, organiczna, genetycznie modyfikowana, bezglutenowa, liofilizowana itd. Opis tych rodzajów żywności przedstawiają różni autorzy [np. Rutkowski 1993, Świetlik 2008, Kosicka-Gębska i inni 2011].

Przedstawione podziały rzadko wykorzystuje się w badaniach statystyczno-ekonomicznych. Ze względu na możliwość pozyskania danych bardziej przydatne są klasyfikacje dokonywane przez statystykę, zwłaszcza GUS. W badaniu budżetów gospodarstw domowych prowadzonych przez GUS, w klasyfikacji wydatków przeznaczonych na żywność i napoje bezalkoholowe wyróżnia się następujące grupy żywności:

- 1) pieczywo i produkty zbożowe (wszystkie gatunki i rodzaje pieczywa, makarony, mąki, wyroby ciastkarskie, kasze i płatki);
- 2) mięso (surowe, drób, wędliny i pozostałe przetwory mięsne, podroby);
- 3) ryby (morskie i słodkowodne, przetwory rybne);
- 4) mleko, sery, jaja (mleko – różne rodzaje, sery twarogowe, dojrzewające i topione, śmietana i śmietanka, jaja kurze i innych ptaków);
- 5) oleje i pozostałe tłuszcze (tłuszcze zwierzęce, masło, margaryna i pozostałe tłuszcze roślinne);
- 6) owoce (południowe, pozostałe, orzechy i przetwory owocowe);
- 7) warzywa (warzywa i grzyby, ziarno roślin strączkowych, ziemniaki, przetwory warzywne i grzybowe);
- 8) cukier, dżem, miód, czekolada i inne wyroby cukiernicze;
- 9) pozostałe artykuły żywnościowe;
- 10) napoje bezalkoholowe (kawa, herbata, kakao i czekolada w proszku, wody mineralne i źródlane, soki) [*Budżety...2013*, s. 248-250].

Żywność jest jednym z podstawowych dóbr zaspokajających potrzeby konsumpcyjne człowieka. Należy dodać, że żywność zaspokaja nie tylko fizjologiczną potrzebę głodu, ale również szereg innych potrzeb, np. bezpieczeństwa, przynależności i szacunku [Gutkowska, Ozimek 2005]. Część potrzeb konsumpcyjnych żywnościowych zaspokajana jest poprzez dobra zakupywane na rynku, a część w wyniku wytwarzania we własnym zakresie (np. spożycie naturalne). We współczesnych gospodarkach rynkowych dominująca część potrzeb konsumpcyjnych zaspokajana jest dzięki wykorzystaniu wymiany handlowej.

### **1.3. Cechy rynku żywności i jego kategorie**

Rynek produktów żywnościowych (rynek żywnościowy, rynek żywności) obejmuje ogół stosunków ekonomicznych, w jakie wchodzi między sobą producenci oraz nabywcy końcowi żywności [Wojciechowska-Ratajczak 1998, Woś 1996, Świetlik 2008]. Jest on segmentem rynku towarów i usług konsumpcyjnych. Rynek produktów żywnościowych podlega uniwersalnym prawom gospodarki rynkowej, ale jednocześnie charakteryzuje się specyficznymi cechami,

które powodują pewne odmienne zachowania rynkowe w porównaniu do rynków artykułów przemysłowych czy usług.

Podstawowymi elementami rynku są popyt, podaż i cena. Wzajemne oddziaływanie popytu, podaży i cen oraz kształtowanie się zależności przyczynowo-skutkowych, jakie zachodzą między nimi w krótkich i długich okresach to mechanizm rynkowy [Woś 1998, Pietras 2005, Wrzosek 2002]. Zależności popytowo-podażowe powstają za pośrednictwem cen między podmiotami gospodarczymi, dążącymi do osiągnięcia korzyści ekonomicznych poprzez dokonywanie dobrowolnych transakcji kupna i sprzedaży towarów i usług.

Stosunkami rynkowymi rządzą dwie główne zasady: równowagi i optymalizacji. Zasada równowagi polega na ciągłym dostosowywaniu się poprzez ceny ilości produktów i usług żądanych przez kupujących do ich ilości oferowanej przez sprzedających. Zasada optymalizacji oznacza wybór najlepszego z wariantów. Uczestnicy rynku podejmując decyzje o zakupie towarów, dążą do maksymalizacji swego zadowolenia. W tej sytuacji muszą tak dzielić dostępne ilości dobra między różne potrzeby, aby krańcowe pożytki były równe we wszystkich zastosowaniach. Mechanizm rynkowy w gospodarce spełnia ważne funkcje, będące siłą sprawczą procesów ekonomicznych i weryfikatorem ich efektywności. Najczęściej wymienia się następujące funkcje: informacyjną, efektywnościową, równoważącą i dochodotwórczą [Jabłońska 2002, Wilczyński 1995, Kowalski, Rembisz 2005].

Rynek można rozpatrywać z punktu widzenia różnych cech (kryteriów). W zależności od przyjmowanych kryteriów można wyodrębnić wiele poziomów (rodzajów) rynku [Mynarski 1987, Mruk 2003]. Klasyfikacja rynków nie ma znaczenia tylko formalnego. Umożliwia ona określenie istotnych cech poszczególnych rynków. Według przedmiotu obrotu możemy wyróżnić rynek produktów, usług oraz rynek czynników produkcji (ziemi, pracy i kapitału) [Jabłońska 2002, s. 97, Wrzosek 2002, s. 34]. W odniesieniu do kryterium przedmiotowego można bardziej szczegółowo klasyfikować rynki. Na przykład w odniesieniu do rynku dóbr można wyodrębnić rynek dóbr i usług konsumpcyjnych, dalej wśród dóbr konsumpcyjnych można wydzielić rynek dóbr żywnościowych i nieżywnościowych. Wśród żywności możemy wyodrębnić rynek mięsa, mleka, owoców, warzyw itp. [Mruk 2003, s. 18, Świetlik 2008, s. 49].

Według zasięgu przestrzennego (geograficznego) można wyróżnić rynek lokalny, regionalny, krajowy, międzynarodowy oraz światowy [Pietras 2005, Mynarski 1993, Jabłońska 2002]. Często łączy się wymienione kryteria określając jednocześnie zasięg geograficzny wymiany. Mamy wtedy do czynienia

z, przykładowo, lokalnym rynkiem zboża, krajowym rynkiem zboża czy światowym rynkiem zboża [Pietras 2005, s. 156].

W zależności od sytuacji rynkowej możemy mówić o rynku sprzedawcy i rynku nabywcy [Jabłońska 2002, s. 97]. W zależności od stopnia jednorodności przedmiotu transakcji wyróżnić możemy rynek homogeniczny (jednorodny), np. rynek pszenicy, oraz heterogeniczny, np. rynek pracy. Biorąc pod uwagę kryterium skali (wielkości transakcji) i podmiotów uczestniczących możemy wyodrębnić: rynek hurtowy i detaliczny [Wilczyński 1995].

Ze względu na stopień zorganizowania (sformalizowania) istnieją rynki swobodne (niesformalizowane) i zorganizowane (sformalizowane, zinstytucjonalizowane). Na rynkach sformalizowanych uczestnicy kontaktują się ze sobą w ściśle określonym miejscu oraz czasie w celu zawarcia transakcji. Muszą się oni podporządkować prawodawstwu obowiązującemu w danym państwie, a także wielu dodatkowym regulaminom i regułom obowiązującym na danym rynku [Jerzak 1998, s. 19]. Do tych rynków zaliczamy giełdy, aukcje i przetargi. Na rynkach swobodnych sposób zawierania i realizacji transakcji ustalany jest przez uczestników (np. targowiska).

W zależności od zakresu kontroli wyróżnia się rynek wolny i regulowany [Pietras 2005, s. 156]. Rynek wolny to taki, nad którym władze gospodarcze nie sprawują bezpośredniej kontroli. Z rynkiem regulowanym mamy do czynienia wówczas, kiedy gospodarka rozwija się według podstawowych praw rynku, ale jednocześnie dopuszcza się interwencję państwa [Woś 1994, s. 9].

W zależności od stopnia wyrównywania się ceny możemy wyróżnić rynek doskonały i niedoskonały [Jabłońska 2002, s. 98]. W zależności od intensywności konkurencji na poszczególnych rynkach w literaturze ekonomicznej wyróżnia się różne modele rynku [Kamerschem, McKenzie, Nardeli 1991, s. 560-634]. Są to: konkurencja doskonała, czysty monopol, konkurencja monopolistyczna i oligopol. Szersze klasyfikacje rynku sporządzone według wielu kryteriów można znaleźć w pracach Mynarskiego [1987], Kramer [1999], Mruk [2003], Wrzoska [2002], Świetlik [2008] i innych.

Niezależnie od rynku, najważniejszą regułą, jaka kształtuje poziom cen jest prawo popytu i podaży. Zgodnie z nim cena jest wypadkową popytu i podaży rynkowej na dane dobro. Potrzeby konsumpcyjne ujawniają się na rynku w postaci popytu. Popyt jest zapotrzebowaniem na dane dobro lub usługę zgłaszanym przez nabywców przy danym poziomie cen i dochodów. W teorii wyboru konsumenta wymienia się preferencje, które pośrednio wynikają z potrzeb. Konsumenty są więc ostatecznym nabywcą produktów żywnościowych. Relacje między potrzebami, popytem a konsumpcją przedstawiono na rys. 1.1.

### Rysunek 1.1. Relacje między potrzebami, popytem, zakupem i konsumpcją (spożyciem)



Źródło: Opracowanie własne.

Potrzeby człowieka można klasyfikować według różnych kryteriów, np. stopnia niezbędności ich zaspokojenia, funkcji społeczno-ekonomicznych, podmiotów, przedmiotów [Maslov 1990, Kotler 1994, Szwacka-Salmonowicz, Zielińska 1996]. Jednymi z podstawowych są potrzeby żywnościowe, których źródłem są biologiczne (fizjologiczne) wymogi organizmu. Potrzeby warunkują życie człowieka i przejawiają się na rynku w postaci popytu (potencjalnego lub efektywnego).

Popyt jest zapotrzebowaniem na dane dobro lub usługę zgłaszanym przez nabywców przy danym poziomie cen i dochodów. Zakup to forma zrealizowanego popytu. Jego realizacja wymaga od konsumenta poniesienia wydatków. Konsumpcja (spożycie) to proces zaspokajania potrzeb ludzkich przy wykorzystaniu dóbr i usług. Proces ten obejmuje także w swym zakresie naturalne spożycie żywności [Gałązka, Grzelak 2011].

Popyt na żywność kształtuje wiele różnych czynników, które można rozpatrywać z punktu widzenia indywidualnego konsumenta lub w skali gospodarki krajowej czy światowej. W rozważaniach ekonomicznych najczęściej analizuje się wielkości zagregowane. Badania empiryczne w tym zakresie są dosyć skomplikowane. Przegląd literatury i wybrane problemy estymacji modeli popytu na żywność opisuje np. Dudek [2011].

Związek, jaki występuje między popytem na żywność (w ujęciu makroekonomicznym) a czynnikami go kształtującymi może być przedstawiony w postaci równania 1.1. Zagregowana funkcja popytu na dane dobro żywnościowe pozwala określić związki, jakie występują między popytem a czynnikami go kształtującymi jest następująca:

$$Q_{z,i} = f(Y, V, L, S, G, C_p, C_{i...n}), \quad (1.1)$$

gdzie:

$Q_{z,i}$  – poszukiwana ilość dobra żywnościowego  $i$ ,

$Y$  – dochód całkowity,

$V$  – podział dochodu,

$L$  – liczba ludności,

$S$  – struktura ludności,

$G$  – gusty i preferencje,

$C_p$  – cena danego produktu,

$C_{i...n}$  – ceny innych produktów (w tym substytucyjnych i komplementarnych).

Niektóre prawidłowości związane z poziomem dochodu i efektywnym popytem przedstawiono w podrozdziale 1.4. Inną miarą zależności dochodu i popytu jest elastyczność dochodowa popytu. Jest to reakcja w wydatkach na żywność na zmiany w dochodach konsumenta. Elastyczność zmienia się w zależności od zmiany dochodów. Rachunkowo jest to relatywna zmiana popytu do relatywnej zmiany dochodu. Elastyczność dochodowa popytu może przyjmować różne wartości. Sytuacja, gdy elastyczność dochodowa popytu jest równa zero ( $E_{dp} = 0$ ) oznacza, że popyt nie reaguje na zmiany dochodu. Najczęściej wyodrębnia się cztery sytuacje:

- wskaźnik elastyczności jest wyższy od jedności ( $E_{dp} > 1$ ). Oznacza to, że wydatki rosną bardziej niż proporcjonalnie w stosunku do wzrostu dochodów. W przypadku żywności taka sytuacja może dotyczyć pojedynczych produktów o wysokiej jakości. Jest to sytuacja, w której popyt jest elastyczny względem dochodu;
- wydatki i dochód rosną w takiej samej proporcji. Wskaźnik elastyczności dochodowej popytu jest równy jedności ( $E_{dp} = 1$ ). Taka sytuacja może występować przy relatywnie niskim poziomie konsumpcji żywności;
- wydatki rosną wolniej niż dochody. Wskaźnik elastyczności dochodowej popytu jest niższy od jedności, ale dodatni ( $0 < E_{dp} < 1$ ). Jest to klasyczna sytuacja dla wzrostu popytu na żywność dla większości produktów żywnościowych;
- wydatki spadają przy wzroście dochodów. Wskaźnik elastyczności dochodowej popytu jest mniejszy od zera ( $E_{dp} < 0$ ). Ujemna elastyczność dochodowa popytu może dotyczyć dóbr podrzędnych (pośledniejszych), które mają lepsze jakościowo substytuty, np. zastępowanie wędlin niższej jakości wędlinami lepszymi jakościowo. Dotyczy to także niektórych podstawowych produktów żywnościowych, np. chleba czy ziemniaków.

Zerowa wartość współczynnika jest podstawą podziału dóbr na dwie grupy: *normalne* charakteryzujące się dodatnim współczynnikiem elastyczności dochodowej popytu ( $E_{dp} > 0$ ) i dobra *podrzędne*, dla których współczynnik elastyczności dochodowej popytu jest ujemny ( $E_{dp} < 0$ ). W przypadku wartości współczynnika równego jedności ( $E_{dp} = 1$ ) pozwala podzielić dobra na: podstawowe, dla których współczynnik elastyczności dochodowej popytu jest mniejszy od jedności ( $E_{dp} < 1$ ), i dobra wyższego rzędu charakteryzujące się współczynnikiem elastyczności dochodowej popytu większym od jedności ( $E_{dp} > 1$ ).



Ogólnie jednak elastyczność dochodowa zagregowanego popytu na żywność w krajach rozwiniętych gospodarczo jest niska ( $E_{dp} = 0,1-0,3$ ) [Ritson 1977, s. 31-38, Tracy 1997, s. 105-107, Heijman i in. 1997, s. 137-141].

Oszacowania elastyczności popytu na żywność w Polsce (analiza przeprowadzona na mikrodanych) pokazują, że jest on relatywnie sztywny w stosunku do popytu na inne grupy towarów i usług [Urbaniec 2011]. Elastyczności dla różnych grup towarów żywnościowych nie przekraczają 1 (w większości przypadków kształtują się w przedziałach 0,3-0,8), a w przypadku pieczywa mogą osiągać wartości ujemne<sup>2</sup>.

Określone prawidłowości występują także między popytem a cenami produktów żywnościowych. Ogólnie zależność między popytem a ceną jest zależnością odwrotną. Należy jednak dodać, że zmiana ceny powoduje dwójaki efekt: substytucyjny i dochodowy. W przypadku działania efektu substytucyjnego produkty, których cena relatywnie wzrosła zastępowane są produktami tańszymi. Efekt dochodowy polega na tym, że wzrost ceny powoduje spadek realnych dochodów, wobec tego konsumenci będą mogli kupić mniej tego dobra.

Miarą reakcji względnej zmiany popytu na względną zmianę cen jest cenowa elastyczność popytu ( $E_{cp}$ ). Na ogół cenowa elastyczność popytu jest ujemna. Gdy współczynnik elastyczności cenowej popytu jest niższy od -1 ( $E_{cp} < -1$ ) mówimy o elastycznym popycie względem ceny. Gdy nie reaguje na zmianę ceny, określamy, że jest doskonale nieelastyczny (sztywny). Najczęściej dotyczy to dóbr, które zaspokajają niezbędne potrzeby i nie mają substytutów. Na produkty spożywcze, które zaspokajają podstawowe potrzeby człowieka elastyczność cenowa popytu jest niska. Należy także zaznaczyć, że elastyczność cenowa popytu zależna jest także od stopnia przetworzenia produktu. Generalnie, wartość bezwzględna elastyczności cenowej na produkty żywnościowe jest tym wyższa, im dany produkt jest bardziej przetworzony [Heijman i in. 1997]

Współczynnik elastyczności cenowej popytu w wyjątkowych sytuacjach może być także dodatni. Przy wzroście cen może następować wzrost popytu na elementarne dobra żywnościowe, przy ograniczeniu zakupów mniej ważnych produktów (paradoks Giffena). Oprócz paradoksu Giffena wyróżnia się także paradoks Veblena (dobra luksusowe, efekt prestiżu) oraz paradoks spekulacyjny [Milewski 2002, s. 101, Tracy 1997, s. 111].

---

<sup>2</sup> W oszacowaniach [Urbaniec 2011] dla 2009 r. najbardziej elastycznymi grupami żywnościowymi okazały się napoje bezalkoholowe ( $E_{dp} > 0,7$ ), oraz owoce i warzywa ( $E_{dp}$  znacznie niższe niż 0,7). Z kolei wśród grup o niskiej elastyczności, poza pieczywem, znajdują się oleje i pozostałe tłuszcze oraz mięso drobiowe.

Znajomość elastyczności dochodowej i cenowej popytu dla różnych produktów żywnościowych może być przydatna przy przewidywaniu sytuacji na rynku żywnościowym. Ważnym elementem wpływającym na popyt na żywność jest czynnik demograficzny (poziom i zmiany liczby i struktury ludności, wykształcenie itp.). Czynnik ten ma ważne znaczenie w przewidywaniu popytu w dłuższych okresach. Istotnymi elementami popytu na żywność są także inne czynniki, które trudno jest ująć wymiennie. Należą do nich: gusty, preferencje, wartości, przekonania, względy dietetyczne czy zdrowotne. Na ogół czynniki te podlegają ewolucji równoległe ze zmianami zamożności społeczeństw.

Popyt tworzą głównie gospodarstwa domowe, które kupują produkty niezbędne do konsumpcji np. pieczywo, makarony, wędliny, sery. Dokonujące się procesy przekształceń w gospodarkach powodują, że współcześnie produkty rolne rzadko nadają się do bezpośredniego spożycia. Stanowią one surowiec do wytwarzania produktów, na które jest zapotrzebowanie ze strony konsumentów. Powoduje to zaangażowanie w produkcję żywności podmiotów wykonujących różną działalność w celu wytworzenia finalnych produktów żywnościowych, które posiadają walory użytkowe spełniające oczekiwania konsumentów. Również produkty rolnicze nieprzetworzone mogą służyć do zaspokojenia potrzeb żywnościowych, np. świeże ziemniaki, owoce, warzywa, ale i wtedy najczęściej udostępniane są konsumentom po uprzednim sortowaniu, pakowaniu czy magazynowaniu.


## 1.4. Trendy w konsumpcji

Biologiczna sfera organizmu ludzkiego wymaga pewnego poziomu minimalnego konsumpcji żywności, który jest niezbędny do przeżycia. Konsumpcja żywności cechuje się jednak pewnym poziomem nasycenia wynikającego z ograniczonej pojemności konsumpcyjnej człowieka [Grzelak, Gałązka 2011]. W zakresie konsumpcji żywności obok kwestii fizjologicznych należy uwzględnić także szereg innych czynników z zakresu psychologii i socjologii [Sojkin 1994, Gutkowska, Ozimek 2005, Grzelak, Gałązka 2011]. W prawidłowościach spożycia żywności coraz większą uwagę zwraca się na zasady racjonalnego żywienia [Gutkowska, Ozimek 2005, s. 24].

Kierunki zmian spożycia niektórych grup żywności na przestrzeni ostatnich dwóch dekad w Polsce przedstawiono na rysunku 1.2. Poziom konsumpcji artykułów żywnościowych różni się między krajami czy grupami gospodarstw domowych [Kwasek 2010]. Na podstawie struktury spożycia żywności można wyodrębnić w UE dziesięć wzorców konsumpcji żywności [Kwasek 2008]. Polska wraz z Estonią, Łotwą, ze względu na położenie, tworzą bałtycki model

konsumpcji żywności. Charakteryzuje on się stosunkowo niską wartością energetyczną spożywanej żywności i niskim spożyciem białka zwierzęcego. W Polsce w latach 1990-2012 najsilniej wzrosło spożycie mięsa drobiowego (ponad 3-krotnie), ryb (ponad 2-krotnie), owoców (prawie 1,6-krotnie) i nieznacznie wieprzowiny. Spożycie pozostałych grup produktów żywnościowych charakteryzowało się tendencją spadkową. Najsilniej zmniejszyło się spożycie wołowiny (o 90%). Pomimo to spożycie mięsa w tych latach zwiększyło się o 3%, przy zmianie struktury jego spożycia. W 1990 r. udział wieprzowiny w konsumpcji wynosił 59,1% i zmniejszył się do 58,2% w 2012 r., dla wołowiny odpowiednio: 25,8 i 2,3%, drobiu: 11,9 i 38,8%, pozostałe mięsa: 3,2 i 0,7%. Spowodowane to było między innymi zmianami relacji cen poszczególnych grup mięsa. W latach 1990-2010 najszybciej zwiększały się ceny żywca wołowego i baraniego w stosunku do cen żywca drobiowego i wieprzowego. Ceny żywca powiązane są z cenami detalicznymi. Ceny wołowiny i baraniny relatywnie wzrosły w stosunku do mięsa drobiowego i wieprzowego, co skutkowało ograniczeniem ich konsumpcji [Stańko 2013].

**Rysunek 1.2. Wskaźniki zmian spożycia niektórych artykułów żywnościowych w Polsce w latach 1990-2012 [1990 = 100]**



Źródło: Obliczenia własne na podstawie: *Rocznik Statystyczny Rolnictwa 2001*, tab. 20 (291), s. 233 i 2013, tab. 67 (240), s. 334.

Zwiększa się relatywnie popyt na produkty żywnościowe bardziej przetworzone, posiadające wyższe walory użytkowe, które można łatwo przechowywać i szybko przygotować do spożycia. Jednocześnie zmniejsza się popyt na

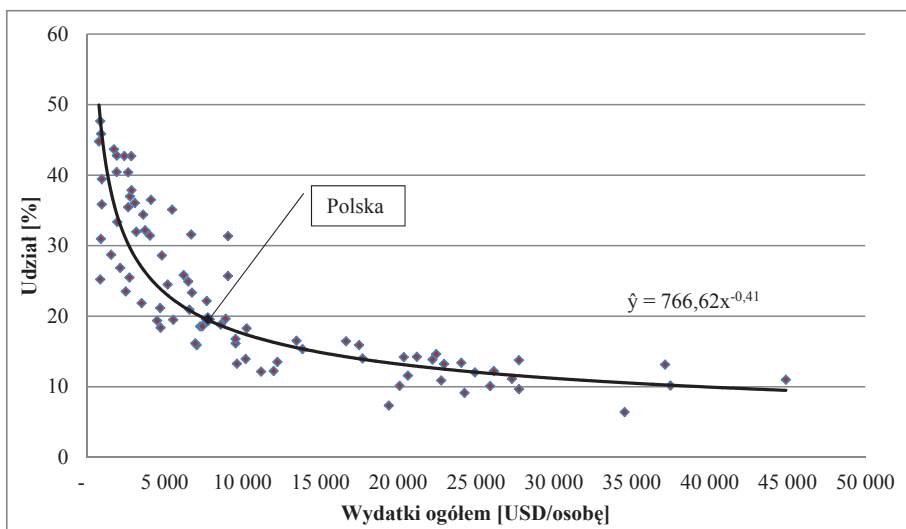
produkty przygotowane w sposób tradycyjny. Na przykład spożycie nieprzetworzonych ziemniaków w Polsce w 1990 r. wynosiło 148 kg/osobę, przetworów ziemniaczanych 3,9 kg, natomiast w 2010 r. odpowiednio 97,4 kg i 16 kg. W Wielkiej Brytanii spożycie ziemniaków nieprzetworzonych w latach 1994-2009 zmniejszyło się z 65 kg/osobę w 1994 r. do 43 kg/osobę w 2009 r. Spożycie przetworów w tym okresie wzrosło odpowiednio z 42 do 49 kg/osobę [Stańko 2013]. Podobne prawidłowości dotyczą także innych artykułów. Ogółem w procesach rozwojowych zmniejsza się spożycie surowca nieprzetworzonego a wzrasta produktów przetworzonych [Stańko 2013]. Takie tendencje oznaczają, że w innych ogniwach łańcucha marketingowego dokonuje się transformacja surowca rolnego w produkty uzyskujące nowe walory jakościowe, użytkowe, smakowe itp.

W zakresie zmian struktury konsumpcji mięsa ważne są także zmiany gustów konsumentów i zalecenia nauki o zdrowym żywieniu. Ogólnie tendencje zmian spożycia grup artykułów żywnościowych w Polsce są zbieżne ze zmianami w większości krajów UE, z wyjątkiem spożycia warzyw. W większości krajów UE ich spożycie zwiększa się [Kwasek 2010], a w Polsce nieznacznie zmniejszyło się. W Polsce ukształtowały się dwa wzorce konsumpcji żywności: miejski oraz wiejski [Kwasek 2012, s. 180]. Miejski wzorzec konsumpcji żywności charakteryzuje się spożyciem produktów wysoko przetworzonych, w tym przetworów ziemniaczanych, soków owocowych i warzywnych, serów dojrzewających i topionych, jogurtów i napojów mlecznych, mięsa wołowego, pieczywa żytniego, wyrobów ciastkarskich, a także wód mineralnych i źródlanych. Ogólnie model ten charakteryzuje się spożyciem droższych i lepszych jakościowo produktów żywnościowych. Z kolei wiejski model konsumpcji żywności charakteryzuje się wysokim poziomem spożycia tańszych produktów żywnościowych: mąki, kaszy, płatków, makaronu, wędlin podrobowych, podrobów i tłuszczów roślinnych oraz produktów pochodzących z własnego gospodarstwa [Kwasek 2012, s. 180].

Niezależnie od modelu konsumpcji, w kształtowaniu się wydatków na żywność występują określone prawidłowości. Dotyczą one związków poziomu rozwoju społeczno-gospodarczego z poziomem i strukturą spożycia oraz udziałem wydatków na żywność w wydatkach konsumentów. Kraje o niskim poziomie rozwoju, mierzonego produktem krajowym brutto (PKB) na mieszkańca, charakteryzują się niskim poziomem wydatków i znacznym udziałem osób niedożywionych [Gulbicka 1998, s. 941]. Kraje o wysokim poziomie PKB na mieszkańca charakteryzują się wysokim poziomem konsumpcji żywności. Wraz z rozwojem społeczno-gospodarczym i poprawą sytuacji dochodowej ludności następują zmiany w wydatkach na żywność i ich strukturze. Następuje

zastępowanie stosunkowo tańszych produktów na ogół roślinnych (np. mąk, kasz, ziemniaków) relatywnie droższymi produktami zwierzęcymi (różnego rodzaju mięso, wędliny, przetwory mleczne itp.).

**Rysunek 1.3. Udział wydatków na żywność w wydatkach konsumpcyjnych [84 kraje, 2012 r.]**



Źródło: opracowanie własne na podstawie danych United States Department of Agriculture – Economic Research Service (USDA-ERS).

Związki między wzrostem dochodów gospodarstw domowych a zmianami udziału wydatków na żywność określił Engel<sup>3</sup>. W kształtowaniu wydatków na żywność i ich udziału w wydatkach możemy wyróżnić trzy sytuacje: przedengłowska, engłowska i poengłowska. W społeczeństwach bardzo biednych (sytuacja przedengłowska), w których występuje głód, przyrost dochodów wydatkowany jest przede wszystkim na poprawę poziomu zaspokojenia potrzeb żywnościowych. Rosną one szybciej niż pozostałe wydatki. W efekcie udział wydatków na żywność w wydatkach ogółem zwiększa się. Zaspokojenie głodu i wzrost dochodów powoduje zwiększanie się ogólnej sumy wydatków, w tym także na żywność. Wydatki na żywność rosną jednak stosunkowo wolniej, tak że ich udział w ogólnej sumie wydatków zmniejsza się<sup>4</sup> (sytuacja engłowska). W procesach tych następuje także zmiana struktury wydatków na żywność. W gospodarstwach (społeczeństwach) bardzo zamożnych zwiększają się

<sup>3</sup> Niemiecki statystyk (1821-1896), który prowadził badania z dziedziny budżetów gospodarstw domowych i statystyki konsumpcji.

<sup>4</sup> Prawdliwość ta nazywana jest w ekonomii prawem Engla.

wydatki na żywność droższą (tzw. zdrową), której ceny są wyższe niż żywności standardowej (sytuacja poengłowska). Równocześnie udział wydatków na żywność w wydatkach ogółem zmniejsza się. Z przyrostu dochodu tylko część przeznaczona jest na taką żywność, a pozostała na inne cele konsumpcyjne. Powoduje to zmniejszanie się udziału wydatków na żywność w wydatkach ogółem. Graficzny obraz prawa Engla przedstawia rysunek 1.3.

Poziom i struktura wydatków na żywność warunkowana jest jednoczesnym oddziaływaniem wielu różnych czynników. Możemy je podzielić na dwie grupy: ekonomiczne i pozaekonomiczne. Do czynników ekonomicznych można zaliczyć: dochody ludności, oszczędności/kredyty, zasoby materialne, ceny dóbr i ich relacje, podaż i jakość żywności, poziom i strukturę dochodu narodowego, poziom inflacji, stopę bezrobocia, źródła pozyskiwania dochodów itp. Do czynników pozaekonomicznych można zaliczyć: czynniki demograficzne (np. płeć, wiek, faza cyklu życia rodziny, liczebność gospodarstwa), czynniki biologiczne i ekologiczne, społeczno-cywilizacyjne (np. grupy społeczne, religia, kultura, obyczaje, tradycje, przyzwyczajenia), informacyjno-edukacyjne (np. informacje rynkowe, edukacja konsumenta), społeczno-zawodowe (np. poziom wykształcenia, aktywność zawodowa, styl życia), geograficzne (np. warunki klimatyczne, ukształtowanie terenu), społeczno-psychologiczne (moda, naśladownictwo, oczekiwania) i inne. Wpływ różnych czynników na poziom i strukturę wydatków przedstawiają między innymi Kramer [1993], Sojkin [1994], Gulbicka [2000], Smyczek, Sowa [2005], Słaby [2006], Bywalec [2007], Dudek [2011], Zalega [2012], Gulbicka, Kwasek [2007, 2012] i inni.<sup>5</sup>

Dokonujące się we współczesnym świecie procesy integracji i globalizacji nie pozostają obojętne na zachowania konsumentów i wydatki na żywność. Szczególne znaczenie mają takie procesy jak: homogenizacja, heterogenizacja, ekologizacja, czy wirtualizacja [Kwasek 2008, s. 5-7]. Homogenizacja konsumpcji (czyli unifikacja) polega na upowszechnianiu się wzorców konsumpcji, to jest upodabnianiu się stylów życia różnych grup i społeczeństw. Procesowi temu sprzyja rozwój telewizji satelitarnej, Internetu, standaryzacja dóbr i usług, czy ekspansja międzynarodowych sieci handlowych. Proces ten dokonuje się poprzez rozwój transnarodowych sieci handlowych, unifikację

---

<sup>5</sup> W szerszym kontekście tymi zagadnieniami zajmuje się statystyka społeczna. Jej celem jest dostarczanie informacji umożliwiających analizę różnych aspektów rozwoju społecznego, np. procesów demograficznych, na rynku pracy, warunków życia czy pracy. Wśród tych zagadnień również znajdują się badania relacji między dochodami i konsumpcją (m.in. wykorzystanie metody Engla do wyznaczania skal ekwiwalentności) czy kwestie ubóstwa i wykluczenia społecznego (np. oszacowania granic ubóstwa). Szerzej o tym można znaleźć w: [Statystyka społeczna, red. T. Panek 2014].

ofert handlowych, wizualizację standardów konsumpcyjnych [Kielczewski 2004, Gulbicka, Kwasek 2007, Gałązka, Grzelak 2012].

Homogenizacji towarzyszą procesy przeciwne, polegające na heterogenizacji, czyli tendencji do różnicowania postaw konsumenckich. Ujednolicanie postaw konsumenckich napotyka na pewne bariery, które zaznaczają się w przypadku konsumpcji żywności. Część konsumentów podkreśla i podtrzymuje odrębności narodowe, kulturowe, co określane jest jako etnocentryzm konsumencki [Limański, Drabik 2010, s.143]. Najczęściej związane jest to z tym, że o strukturze spożycia żywności w znacznej mierze decyduje tradycja oraz nawyki [Karcz 1999]. Ekologizacja oznacza wzrost zainteresowania zdrowymi aspektami konsumpcji i zakupami żywności ekologicznej, zaś wirtualizacja konsumpcji oznacza dokonywanie zakupów żywności za pośrednictwem elektronicznych środków przekazu (np. poprzez Internet) [Kwasek 2008, s. 5-7].

Ogólnie o wydatkach na żywność decyduje wiele różnorodnych czynników, wymiernih, jak i niewymiernih. Ich znaczenie zmienia się w czasie. Ogólną prawidłowością jest zmniejszanie się udziału wydatków na żywność wraz z rozwojem gospodarczym, co ilustruje rysunek 1.3. Zmienia się także spożycie artykułów żywnościowych i ich struktura, co przedstawiono na rysunku 1.2. Wszystko to powoduje, że następuje zmiana poziomu i struktury wydatków na poszczególne produkty żywnościowe.

## 1.5. Wskaźnik cen żywności a struktura wydatków

Od wielu lat w budżetach gospodarstw domowych w Polsce najważniejszą pozycję stanowią wydatki na żywność i napoje bezalkoholowe. Zmiany cen w tej grupie wydatków mają więc ważne znaczenie dla kształtowania wskaźnika cen towarów i usług konsumpcyjnych. Wyrażenie zmian w niejednorodnej zbiorowości (na przykład dynamiki zmian cen artykułów żywnościowych) wymaga posługiwania się wielkościami agregatowymi, które w odpowiedni sposób wyrażałyby łączne zmiany zachodzące w czasie w całej zbiorowości, między innymi w cenach żywności. Z tym zagadnieniem wiąże się kwestia znalezienia odpowiedniego systemu wag służącego do wyznaczenia takiej zmiany.

Klasycznym przykładem takiego agregatu są wskaźniki cen towarów i usług konsumpcyjnych (CPI)<sup>6</sup>, czy jego głównego elementu, jakim są wskaźniki zmian cen żywności. Podstawową formułą służącą do wyznaczenia wskaźników cen towarów i usług konsumpcyjnych jest formuła agregatowego indeksu cen, przedstawiająca ten indeks jako średnią indywidualnych indeksów cen

---

<sup>6</sup> Praktycznie są to indeksy kosztów utrzymania.

ważonych wartościami poszczególnych elementów agregatu [Józwiak, Podgórski 1998]. Ze względu na to, że niemożliwe jest ujęcie wszystkich dóbr i usług, które konsumują gospodarstwa domowe, stosuje się w miarę jednorodne grupy artykułów i usług wymienionych w podrozdziale 1.2. W każdej grupie prowadzi się obserwacje wybranych reprezentantów. Ich wykaz przedstawiony jest w klasyfikacji wydatków na towary i usługi konsumpcyjne w opracowaniach dotyczących budżetów gospodarstw domowych.

Badanie cen artykułów konsumpcyjnych realizowane jest przez GUS w oparciu o listę reprezentantów wytypowaną metodą doboru celowego. Notowania cen towarów i usług prowadzone są przez ankieterów urzędów statystycznych w punktach sprzedaży wybranych do badania na obszarze poszczególnych rejonów badania cen. Na podstawie informacji o cenach obliczane są średnie miesięczne ceny wszystkich reprezentantów w rejonie jako średnie arytmetyczne z uwzględnieniem liczby notowań. Wskaźnik cen reprezentanta w rejonie wynika z odniesienia jego średniej miesięcznej ceny do średniej ceny z okresu bazowego. Ogólnopolskie wskaźniki cen wszystkich reprezentantów objętych notowaniami obliczane są jako średnie geometryczne wskaźników cen reprezentantów ze wszystkich rejonów. Na ich podstawie, stosując średnią geometryczną, oblicza się wskaźniki cen grup towarów i usług konsumpcyjnych na najniższym szczeblu agregacji systemu wag (ponad 300 grup elementarnych w 2013 r.). Stanowi to bazę do obliczenia wskaźników na wyższych szczeblach agregacji [*Ceny ... 2014*] <sup>7</sup>.

Wskaźniki cen towarów i usług konsumpcyjnych (CPI) obliczane są comiesięcznie według formuły Laspeyres'a. Przy obliczaniu wskaźników zmian cen ważny jest system stosowanych wag. Są nimi udziały wydatków gospodarstw domowych na poszczególne grupy towarów i usługi w ogólnej sumie wydatków w budżetach gospodarstw domowych w roku poprzednim. W badaniach do określenia struktury wydatków stosowana jest Klasyfikacja Spożycia Indywidualnego według Celu zaadaptowana na potrzeby HICP (COICOP/HICP) [*Ceny...2014*]. Wybór takiej formuły jest uzasadniany łatwością obliczeń i komunikacji opinii publicznej. Z drugiej strony, sposób konstrukcji oraz obliczania tej miary ma swoje ograniczenia. Szerzej na ten temat piszą m.in. Hałka i Leszczyńska [2011].

Zmiany w poziomie konsumpcji artykułów żywnościowych i wydatkach na różne produkty powodują, że systemy wag nie są stałe i aktualizowane co

---

<sup>7</sup> NBP szacuje i publikuje również cztery miary inflacji bazowej, które pozwalają częściowo odróżnić skutki przejściowe od trwałych zmian presji inflacyjnej. Są to inflacja po wyłączeniu cen administrowanych, inflacja po wyłączeniu cen najbardziej zmiennych, inflacja po wyłączeniu cen żywności i energii, 15% średnia obciążenia [NBP 2014].



roku. Ich wielkości dla żywności i napojów bezalkoholowych w Polsce w latach 2006-2013 przedstawiono w tabeli 1.1.

Ceny żywności i napojów bezalkoholowych podzielone na 10 głównych kategorii. Wewnątrz tych kategorii na grupy bardziej szczegółowe. Dla każdego z tych pod-agregatów obliczane są odpowiednie wskaźniki cen (m/m, r/r, wskaźniki jednopodstawowe). Największy udział w koszyku żywnościowym w Polsce ma mięso, pieczywo i produkty zbożowe oraz mleko, sery i jaja. W sumie wydatki na te trzy grupy towarów stanowią ponad 60% wydatków na żywność. Z systemu wag wynika ogólna prawidłowość, polegająca na zmniejszaniu się znaczenia wydatków na żywność w wydatkach budżetów rodzinnych. Waga tych wydatków w kształtowaniu zmian cen jest coraz mniejsza. Kolejna prawidłowość wiąże się z pewną zmiennością tych udziałów będącą efektem zmienności cen produktów żywnościowych.

**Tabela 1.1. Systemy wag stosowane w obliczaniach wskaźników cen i usług konsumpcyjnych w Polsce dla żywności i napojów bezalkoholowych\***

Grupy produktów żywnościowych	Rok							
	2006	2007	2008	2009	2010	2011	2012	2013
Żywność i napoje bezalkoholowe	27,18	26,20	25,67	24,64	24,14	23,98	24,20	24,33
Żywność	25,05	23,98	23,46	22,49	22,02	21,83	22,03	22,10
Pieczywo i produkty zbożowe	4,62	4,38	4,41	4,35	4,15	4,05	4,17	4,14
Mięso	7,6	7,02	6,78	6,5	6,57	6,25	6,35	6,52
Ryby	0,82	0,82	0,81	0,78	0,78	0,77	0,76	0,79
Mleko, sery, jaja	3,83	3,65	3,59	3,48	3,33	3,39	3,42	3,48
Oleje i pozostałe tłuszcze	1,53	1,37	1,29	1,25	1,19	1,16	1,20	1,18
Owoce	1,34	1,33	1,40	1,35	1,23	1,28	1,28	1,27
Warzywa	2,5	2,62	2,52	2,28	2,29	2,51	2,31	2,13
Cukier, dżem, miód, czekolada i wyroby cukiernicze	1,84	1,82	1,69	1,55	1,53	1,45	1,59	1,61
Pozostałe artykuły żywnościowe	0,97	0,97	0,97	0,95	0,95	0,97	0,96	0,97
Napoje bezalkoholowe	2,13	2,22	2,21	2,15	2,12	2,15	2,17	2,23

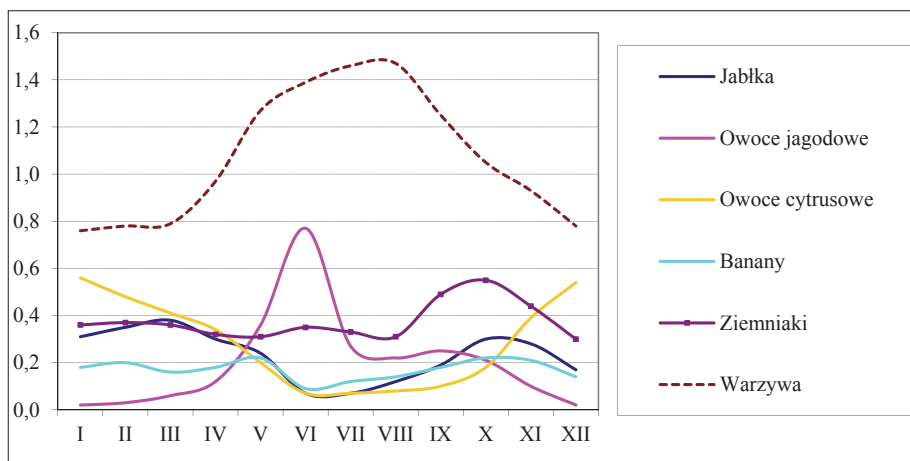
\* Wagi określone są nie tylko dla grup produktów, ale także bardziej szczegółowo. Na przykład dla 2012 r. w grupie mięso, waga wynosiła 6,35 w tym dla mięsa surowego wynosiła – 2,86 w tym wołowego – 0,19, wieprzowego – 1,42, drobiu – 1,16.

Źródło: *Ceny w gospodarce narodowej ...*, GUS, Warszawa 2013, 2014.

Do 2010 r. wagi mogły również ulegać zmianom w ciągu roku w zależności od struktury wydatków. W ramach grup „warzywa” i „owoce” uwzględniano sezonowość spożycia i pojawiania się na rynku tych produktów. Stosowana była tzw. metoda Rothwell’a, polegająca na przyjęciu stałych wag dla wszystkich miesięcy w danym roku, przy zmiennej wewnętrznej strukturze tych agregatów

w poszczególnych miesiącach roku [Ceny...2014]. Przykład zmiennych wag dla wybranych grup towarów z przedstawiono na rysunku 1.4. Zauważyć można znaczące wahania wydatków na poszczególne produkty będące wynikiem sezonowości podaży.

**Rysunek 1.4. Udział wydatków na wybrane grupy towarów w poszczególnych miesiącach 2010 r. (%)**



Źródło: opracowanie na podstawie danych NBP.

Niedostępność produktów dla konsumentów lub ich zbyt mała ilość w ofercie, w pewnych okresach uniemożliwia lub utrudnia obserwację cen w tych okresach. Z tego powodu począwszy od 2011 r. GUS zdecydował się na zmianę metodyki obliczeniach zarówno krajowych wskaźników cen towarów i usług konsumpcyjnych (CPI), jak i zharmonizowanych (HICP). Wiązało się to z przyjęciem, podobnie jak w przypadku pozostałych wyrobów i usług, stałych rocznych wag.

## **2. Teoretyczne uwarunkowania zmian cen w łańcuchu marketingowym – mechanizmy**

W rozdziale przedstawiono schemat przepływu produktów rolnych od producenta surowców do konsumenta żywności, poprzez różne kanały i ogniwa. Omówiono także główne czynniki powodujące zmniejszanie się udziału surowca rolniczego w cenie detalicznej żywności. Ważną częścią rozdziału są również zagadnienia przekazu sygnałów cenowych między różnymi ogniwami łańcucha marketingowego, tj. pionowej transmisji cen. Przedstawiono różne rodzaje asymetrii transmisji cen i czynniki je determinujące.

### **2.1. Ogniwa łańcucha marketingowego**

Produkty rolnicze wytworzone w gospodarstwie rzadko nadają się do bezpośredniego spożycia. By nadać im cechy, dzięki którym konsumenci będą chcieli nabyć te produkty, konieczne jest przeprowadzenie szeregu działań przez wyspecjalizowane podmioty. Ogólny schemat przepływu produktów rolnych od producenta surowców do konsumenta produktów żywnościowych przedstawia rysunek 2.1.

Struktura i długość łańcucha, przez który przechodzi surowiec rolniczy i wytworzone z niego produkty, nie jest stała. W procesach rozwoju społeczno-gospodarczego następują zmiany liczby ogniw, jak i powiązań między nimi. Zależy to jednak przede wszystkim od: rodzaju surowca, stopnia koncentracji produkcji, poziomu rozwoju kraju i rynku, preferencji konsumentów w zakresie produktów żywnościowych, powiązań między ogniwami, postępu technologicznego itp. Powoduje to, że przepływ surowca od producenta do konsumenta następuje poprzez różne kanały, które przypominają raczej sieć lub „pajęczynę” niż łańcuch [rys. 2.1, Baker 2003].

Struktura instytucjonalna przepływu produktu od producenta surowca do konsumenta żywności może być bardzo zróżnicowana. Obejmuje ona producentów rolnych, różne ogniwa skupu surowców rolnych (hurt pierwotny, np. spółdzielnie ogrodnicze, rynki hurtowe, kupców hurtowych, działy zaopatrzenia w przedsiębiorstwach przetwórczych), przetwórców surowców, ogniwa hurtu wtórnego (np. sieci hurtowni, hurtownie detalistów, targowiska hurtowe, agenci handlowi) i ogniwa detalu (np. pojedyncze sklepy i sieci, sklepy ogólnospożywcze, supermarkety), sklepy specjalistyczne (mięsne, piekarniczo-ciastkarskie itp.), hale targowe, targowiska, restauracje, bary, stolówki. Oprócz tych

ogniwi występują także podmioty wspomagające (przykładowo różne systemy informacji rynkowej).

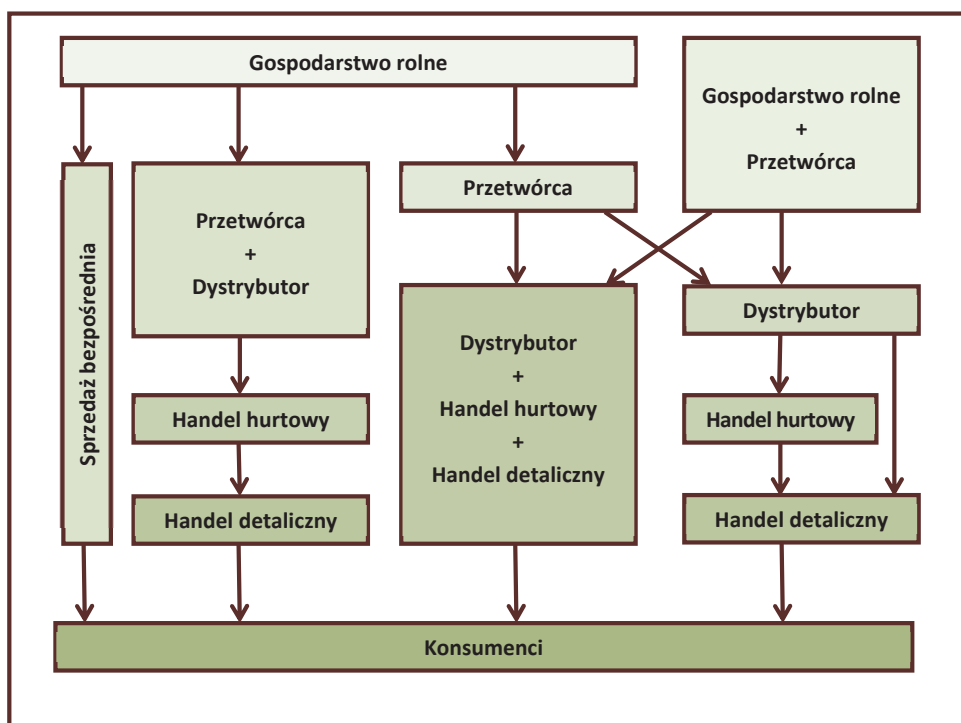
Liczba ogniwi, przez które przechodzi surowiec rolniczy, zależy jest od specyfiki produktowej, poziomu rozwoju gospodarczego kraju i rynku. Na wielu rynkach część produkcji rolniczej może być sprzedawana w postaci nieprzetworzonej (np. świeże owoce i warzywa). Dla takich produktów transakcje pomiędzy producentem a konsumentem mogą być zawierane bezpośrednio w gospodarstwie lub na targowisku. Producenci mogą też łączyć się w grupy i sprzedawać produkty rozwijając własny punkt sprzedaży. Możliwa jest także sprzedaż poprzez Internet. Dla takich produktów liczba ogniwi jest mała (tzw. krótki łańcuch marketingowy). Produkty niewymagające przetworzenia mogą być także sprzedawane przez producentów lub ich grupy do dużych sklepów (np. hipermarkety, supermarkety i dyskonty czy inne). Natomiast tradycyjne sklepy spożywcze mogą zaopatrywać się w takie produkty bezpośrednio u producentów, poprzez różnych dystrybutorów lub handel hurtowy.

Znacznie większa liczba ogniwi i kierunków przepływu występuje na rynkach tych produktów, które wymagają mniejszego lub większego stopnia przetworzenia, zanim nadają się do konsumpcji. Ogólnie, wraz ze wzrostem stopnia przetworzenia zwiększa się liczba ogniwi łańcucha marketingowego. Dla takich produktów żywnościowych łańcuch marketingowy jest złożony i ma postać „sieci” (rys. 2.1). Struktura i liczba ogniwi łańcucha marketingowego zależy jest także od cech produktów, ich przeznaczenia i możliwości przechowywania. Na przykład, na rynku mleka i jego artykułów niewielka liczba ogniwi („krótkie kanały”) występuje przy sprzedaży bezpośredniej. Wielkość takiej sprzedaży jest jednak niewielka ogółem w obrotach rynkowych. Rozmiar sprzedaży bezpośredniej w roku kwotowym 2013/14 można oszacować na 1,45% produkcji towarowej, a pozostała ilość surowca przechodziła przez różne ogniwa łańcucha marketingowego<sup>8</sup>. Dotyczy to sposobu pozyskiwania mleka surowego przez zakłady przetwórcze (np. odbiór bezpośredni przez przetwórcę, wyspecjalizowane podmioty transportowe, a także zlewnie). Z kolei dystrybucja produktów mleczarskich jest bardziej rozwinięta i zróżnicowana. Kanały te różnią się w zależności od tego czy dotyczy to produktów masowych, codziennego zakupu, czy produktów o ograniczonej trwałości, kupowanych rzadziej, czy też produktów o relatywnie większej trwałości, kupowanych w dłuższych odstępach czasu, czy też produktów o szczególnych walorach smakowych [Seremak-Bulge 2005].

---

<sup>8</sup> Obliczenia własne na podstawie informacji ARR o wysokości kwoty krajowej dostaw i „sprzedaży bezpośredniej” w roku kwotowym 2013/2014 ([www.arr.gov.pl](http://www.arr.gov.pl), odczyt 3.11.2014 r.).

Rysunek 2.1. Sieć marketingowa produktów żywnościowych



Źródło: opracowanie własne na podstawie Baker [2003, s. 29].

W poszczególnych ogniwach podmioty prowadzą określone działania w celu wytworzenia takiego produktu, który będzie spełniał oczekiwania nabywców. W wyniku tych działań następuje dostosowanie do siebie produkcji i konsumpcji co do rodzaju towaru, miejsca, czasu, ilości i jakości produktu. Działania w ogniwach marketingowych nazywa się funkcjami i można podzielić je na kilka grup:

- funkcje wymienne (np. kupno, gromadzenie, sortowanie, sprzedaż),
- funkcje fizyczne (np. transport, przetwórstwo, magazynowanie, sprzedaż),
- funkcje wspierające (np. sortowanie i standaryzacja, ponoszenie ryzyka, informacja rynkowa) [Cramer, Jensen 1991, s. 322-323].

Niezależnie od liczby ogniw i powiązań między nimi, zanim produkty rolne uzyskają przydatność do spożycia, podlegają wielorakiej transformacji (temporalnej, przestrzennej i rzeczowej) [Świetlik 2008, s. 93]. Jednocześnie, w procesach tych zużywa się różnego rodzaju nakłady i usługi, ponosi ryzyko, co pociąga za sobą określone koszty.

## 2.2. Rozstęp cenowy i marża marketingowa

### 2.2.1. Definicje

Transformacja surowca rolniczego w produkt żywnościowy dokonuje się w poszczególnych ogniwach łańcucha marketingowego i wiąże się z wykorzystaniem pracy, środków produkcji i innych surowców. Powoduje to, że surowiec rolniczy jest tylko częścią składową produktu o nowych walorach użytkowych, smakowych, wizualnych, zdolnych do zaspokajania potrzeb konsumenta. W wyniku tych procesów powstają różnice pomiędzy ceną płaconą przez konsumentów (ceną detaliczną) za produkty spożywcze a otrzymywaną przez producentów surowca rolniczego. Różnice między cenami równowagi na rynku surowca rolniczego a cenami na rynku produktów żywnościowych wytworzonych z surowców rolniczych określa się jako: **marżę marketingową** (*marketing margin*), **marżę cenową** (*price margin*) lub **rozstęp cenowy** (*price spread*).

W literaturze ekonomicznej są jednak zróżnicowane poglądy w zakresie poprawności tej terminologii. Część ekonomistów różnice między cenami detalicznymi żywności a cenami surowca rolniczego określa mianem rozstępu cenowego, np. Gardner [1975], Elitzak [1999], Rembisz [2007]. Z kolei Heijmann i inni [1997] Wohlgenant i Haidacher [1989], Tomek i Robinson [2001] różnicę tą nazywają marżą marketingową. Jeszcze inni np. Figiel [2002], Reed, Elitzak i Wohlgenant [2002], Schnepf [2009], czy Kuosmanen i Niemi [2009] używają tych terminów zamiennie.

Zdaniem niektórych ekonomistów np. [Elitzak 1999] terminy: rozstęp cenowy i marża powinny być rozróżnione. Rozstęp cenowy prezentuje różnice, jakie występują między cenami detalicznymi żywności a cenami surowca rolniczego zawartego w danych produktach lub ich grupach w danym okresie. Nie jest on obserwowany bezpośrednio. Jego oszacowanie wymaga odpowiednich danych w celu określenia wartości surowca rolniczego w danym produkcie żywnościowym lub ich grupach (np. jaka jest wartość żywca wieprzowego w 1 kg szynki). Ma to wymiar czysto statystyczny i jest związany z przyjęciem szeregu założeń.

Marża to kategoria prezentująca różnice między wartością sprzedaży a kosztami sprzedanych towarów [Elitzak 1999]. Ceny możemy obserwować i mierzyć marżę pomiędzy różnymi ogniwami łańcucha marketingowego. Na tej podstawie można wyróżnić różne rodzaje marży (np. przetwórcza, handlowa, detaliczna). Rozstęp cenowy reprezentuje wszystkie wartości w przetwórstwie, transporcie i obrotach rynkowych dodane do wartości surowca rolniczego po opuszczeniu gospodarstwa [Elitzak 1999]. Natomiast marża

jest bardziej związana z praktyką gospodarczą i rachunkowym ujęciem kosztów w łańcuchu marketingowym.

Mimo że kwestia rozstępu cenowego czy marż na gruncie teoretycznym jest w znacznej mierze wyjaśniona, problemem jest ich praktyczne oszacowanie. Wynika to z niewystarczających danych statystyki publicznej w tym zakresie, a także braku informacji o obrotach wewnętrznych między producentami żywności [Urban 2002, s. 10-11]. Trudności te wynikają z faktu, że w istocie nie wiadomo, ile i jakiego surowca jest w produkcie finalnym.

Formalnie różnice między cenami detalicznymi a cenami surowca rolniczego można mierzyć w różny sposób, w wielkościach absolutnych lub względnych [Gardner 1975; Figiel, Rembisz 2009]. W wielkościach absolutnych pomiaru rozstępu cenowego ( $R_C$ ), dokonujemy obliczając różnice między przeciętną ceną detaliczną produktu żywnościowego ( $C_Z$ ) a ceną surowca rolnego opuszczającego gospodarstwo rolne (tzw. cena na bramie gospodarstwa rolnego) wykorzystanego do jego produkcji ( $C_R$ ):

$$R_C = C_Z - C_R. \quad (2.1)$$

Za rozstęp w ujęciu względnym można przyjąć relację cen detalicznych danego produktu żywnościowego do cen surowca rolnego wykorzystanego w jego produkcji:

$$R_C = C_Z / C_R. \quad (2.2)$$

Jako relacja cen określa ona, ile razy cena detaliczna produktu żywnościowego różni się od cen surowca rolniczego wykorzystanego w produkcji artykułu żywnościowego. Miarą rozstępu cenowego jest także udział wartości dodanej w przetwórstwie i obrotach rynkowych do ceny surowca rolniczego:

$$R_C = (C_Z - C_R) / C_R \quad \text{lub} \quad R_C = C_Z / C_R - 1. \quad (2.3)$$

Rozstęp cenowy można także ujmować jako relację wartości dodanej poza rolnictwem do ceny produktu żywnościowego. Można to zapisać w następujący sposób:

$$R_C = (C_Z - C_R) / C_Z. \quad (2.4)$$

Jeszcze inną miarą rozstępu cenowego jest relacja wartości produkcji rolniczej do wartości sprzedaży produktów żywnościowych lub wydatków na żywność [Gardner 1975]. Jest to miara, która określa udział wartości surowca rolniczego w wydatkach na żywność. Znajduje ona zastosowanie w analizach w skali mikro- i makroekonomicznej [Rembisz, Figiel 2009].

## 2.2.2. Analityczne ujęcie rozstępu cenowego

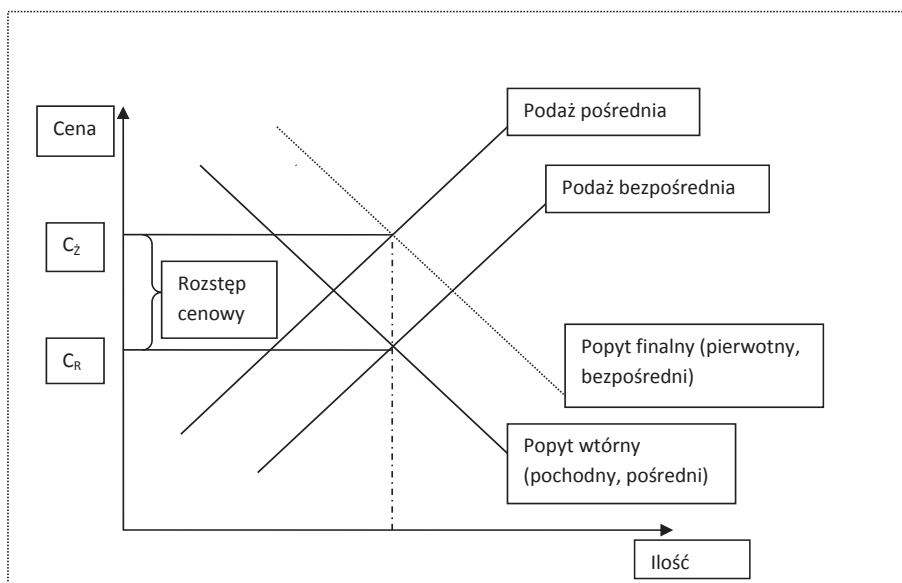
Równowaga na rynku determinowana jest relacjami popytowo-podażowymi. Dotyczy to rynku produktów finalnych, rynku surowców rolnych i rynku nakładów i usług marketingowych. Rynki te są z sobą powiązane poprzez podaż, popyt, a co za tym idzie także ceny i tworzą określoną strukturę.

Równowaga jest zachowana jeżeli [Wohlgenant 2001]:

- popyt na żywność ( $D_Z$ ) = podaży żywności ( $S_Z$ ),
- popyt na surowce rolne ( $D_R$ ) = podaży surowców ( $S_R$ ),
- popyt na nakłady i usługi marketingowe ( $D_M$ ) = podaży nakładów i usług ( $S_M$ ).

Te wyjściowe założenia są podstawą do analizy czynników determinujących równowagę na poszczególnych rynkach, kształtowanie marż marketingowych i transmisję cen. Ogólną ideę równowagi na rynku żywności i surowca rolniczego w warunkach statycznych przedstawiono graficznie na rys. 2.2.

Rys. 2.2. Równowagi na rynku surowca i produktu żywnościowego



Źródło: opracowanie własne na podstawie na podstawie: Ritson [1977], Cramer, Jensen [1991], Tomek, Robinson [2001].

Popyt na produkty żywnościowe, który tworzą konsumenci, określa się mianem popytu finalnego (pierwotnego lub bezpośredniego). Teoretycznie jest to popyt na komponenty wytworzone w rolnictwie i komponenty zrealizowane w różnych ogniwach marketingowych w celu uzyskania produktu żywnościowego spełniającego oczekiwania konsumentów. Do wytworzenia artykułów

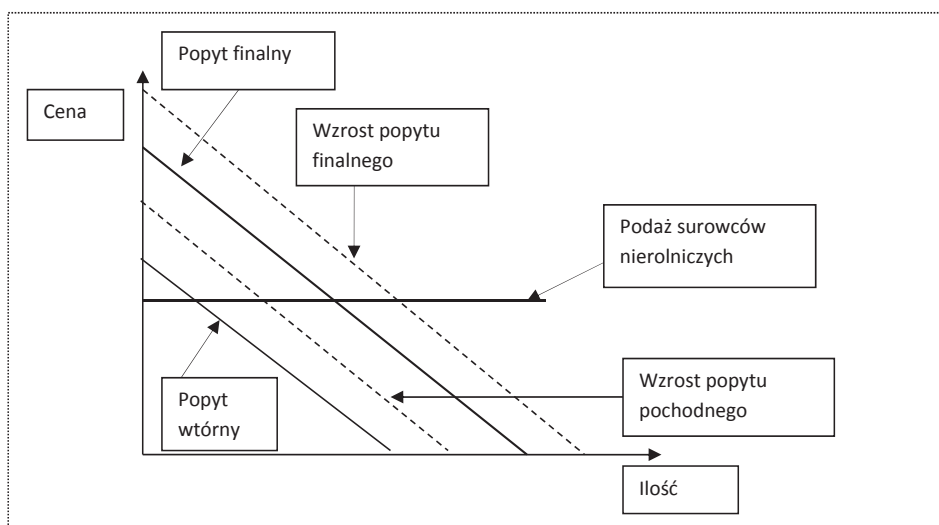


żywnościowych niezbędna jest określona ilość surowców rolniczych i pozarolniczych (np. energia, usługi, różne dodatki, opakowania, materiały bezpośrednie). Z tego powodu popyt na surowce do produkcji żywności określa się mianem popytu pośredniego (wtórnego lub pochodnego), bo wynika on z popytu na poziomie konsumenckim [Ritson 1977, s. 152, Cramer, Jensen 1991, s. 326, Heijman...1997, s. 145]. Z kolei od strony producenta rolnego mamy podaż bezpośrednią oraz dodane wartości w ogniwach łańcucha marketingowego tworzące podaż pośrednią.

Na rynku produktów żywnościowych cena równowagi wynika z popytu pierwotnego i podaży wtórnej (cena  $C_Z$ , rys. 2.2), natomiast na poziomie producenta rolnego cena równowagi wynika z relacji popyt wtórny: podaż pierwotna (cena  $C_R$  na rys. 2.2). Uwzględniając równowagi na rynku surowców rolnych i produktów żywnościowych, można przyjąć, że rozstęp cenowy (rozstęp, marża marketingowa) jest pewną funkcją różnic cen równowagi na rynku detalicznym i surowców rolnych [Wohlgenant 2001].

Rozważania teoretyczne [Wohlgenant 2001] i empiryczne wskazują, że marże marketingowe determinowane są wieloma czynnikami. Do podstawowych można zaliczyć: elastyczność popytu pochodnego, siłę rynkową podmiotów, skalę produkcji, lukę czasową między podażą surowców a popytem na żywność, ryzyko cenowe, postęp technologiczny, zmiany strukturalne w poszczególnych ogniwach, substytucyjność nakładów itp.

**Rysunek 2.3. Krzywa podaży surowca nierolniczego doskonale elastyczna**

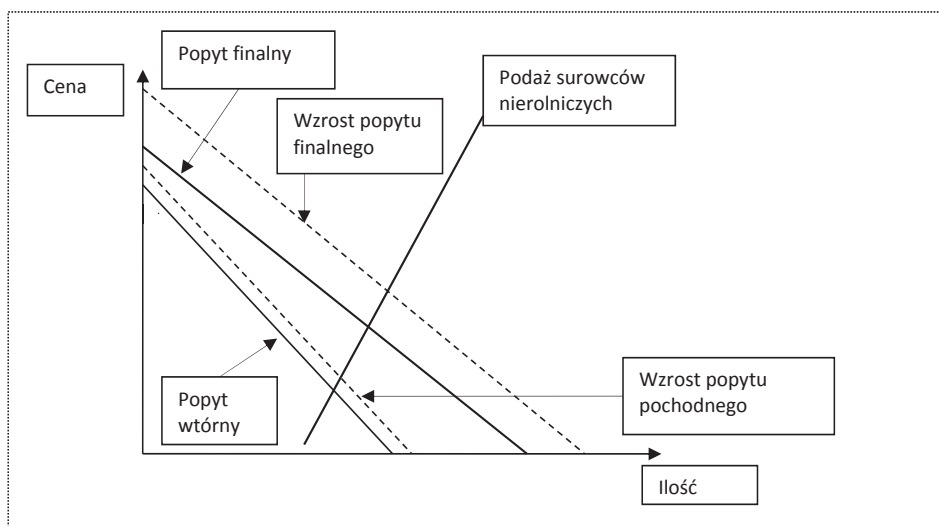


Źródło: opracowanie własne na podstawie Ritson 1977, s. 154.

Załóżmy, że następuje wzrost popytu na żywność (przesunięcie krzywej popytu na rys. 2.3. Powoduje to odpowiedni wzrost popytu pochodnego na surowiec rolniczy i usługi marketingowe. Kiedy podaź na usługi marketingowe jest doskonale elastyczna, marża marketingowa pozostaje taka sama przy różnej podaży i krzywa popytu pochodnego na surowiec rolniczy ma takie samo nachylenie jak krzywa popytu finalnego. Przy takim założeniu absolutne zmiany cen surowca są takie same, jak zmiany cen produktu żywnościowego. Przy tych założeniach zmiana w podaży surowca będzie powodować proporcjonalnie większą zmianę w cenach surowca niż cenach produktu żywnościowego.

Kiedy podaź usług marketingowych staje się mniej elastyczna, to mniejsze są relatywne przyrosty popytu na surowce od wzrostu popytu finalnego. Taką sytuację przedstawiono graficznie na rys. 2.4. Ogólnie można stwierdzić, że im mniej elastyczna jest podaź nakładów marketingowych, tym relatywnie mniejsze są przyrosty popytu na surowiec rolniczy w stosunku do wzrostu popytu finalnego.

**Rysunek 2.4. Krzywa podaży surowca nierolniczego mało elastyczna**



Źródło: opracowanie własne na podstawie Ritson 1977, s. 154.

Założenie o doskonałej elastyczności podaży surowców nierolniczych rzadko jest spełnione. Wynika to najczęściej z określonej siły rynkowej różnych podmiotów poszczególnych ogniw łańcucha marketingowego. Prowadzi to do określonych skutków w kształtowaniu się popytu pochodnego na surowce rolnicze. Staje on się mniej elastyczny niż popyt finalny. Podmioty o określonej sile

rynkowej posiadają zdolność do ustalania cen na swoje usługi ponad poziom wynikający z doskonałej konkurencji<sup>9</sup>.

Marża marketingowa może być stała lub zmieniać się w zależności od wielkości obrotów (czy skali przetwórstwa) [Tomek, Robinson 2001]. Niski poziom obrotów może powodować niepełne wykorzystanie potencjału, co powoduje wysokie koszty jednostkowe, a tym samym zmniejszenie marż. Wysoka skala obrotów może prowadzić do zwiększenia wydajności, a także zmniejszenia kosztów jednostkowych. Efektem tego jest wzrost marż.

Krzywe popytu pierwotnego zmieniają się wraz ze wzrostem zakresu usług w przetwórstwie i obrocie towarowym. Ich wzrost, na przykład poprzez zwiększenie stopnia przetworzenia, skutkuje powstaniem nowego produktu na szczeblu detalicznym. Wzbogacenie usług najczęściej powoduje przesunięcie krzywej popytu finalnego. Z drugiej strony nowe usługi powodują wzrost kosztów marketingowych. W takiej sytuacji konsumenci mogą nabywać stary produkt po dotychczasowej cenie lub nowy po cenie wyższej o koszty dodatkowych usług. Jeżeli nowy produkt lepiej spełniać będzie oczekiwania konsumentów, może spowodować to wzrost popytu finalnego. Z drugiej strony dotychczasowy popyt na stare usługi zmaleje, a tym samym zmniejszy się popyt pierwotny, co skutkować będzie zmniejszeniem się marż [Tomek, Robinson 2001]. Skutki wprowadzenia nowego produktu uwidaczniają się w przebiegu funkcji popytu pierwotnego i wtórnego. Stają się one dość skomplikowane w przypadku produktów substytucyjnych. Zmiany dotychczasowych kosztów usług skutkują zarówno na szczeblu detalicznym, jak i producenta. Zmiana wartości marży powoduje przesunięcie krzywej popytu wtórnego oraz wtórnej podaży. Wzrost marży skutkuje spadkiem popytu wtórnego oraz wtórnej podaży produktu, co powoduje wzrost ceny detalicznej i jednocześnie spadek ceny producenta. Z kolei spadek marży skutkuje efektami odwrotnymi.

## **2.3. Ceny żywności i ich determinanty**

### **2.3.1. Ogólne prawidłowości**

Ocenę wpływu różnych uwarunkowań, a zwłaszcza relacji cen surowców rolnych i cen detalicznych żywności można rozpatrywać w krótkim lub dłuższym okresie. Na konieczność uwzględniania czasu w ocenie równowagi rynkowej zwrócił uwagę Marshall. Według niego spór o to, co decyduje o cenie tj. podaż czy popyt jest nieistotny, ponieważ obie wielkości wpływają na ceny,

---

<sup>9</sup> Na przykład siła monopolistyczna rynku odbiega od konkurencji doskonałej. Jej miarą jest nadwyżka cen ponad utarg i koszt krańcowy przedsiębiorstwa [Begg i in. 1999, s. 492].

a działanie ich zależy od rozpatrywanego czasu. Na tym tle Marshall rozróżnia krótkie i długie okresy (za: [Taylor 1958]).

Ujęcie czasu w ocenie tych zagadnień jest ważnym rozwiązaniem merytorycznym. W okresie krótkim mogą zmieniać się ceny nakładów (w tym i surowców rolnych) i usług marketingowych, na przykład energii, innych surowców, pracy. W tym okresie podmioty nie są w stanie dokonać zmian w technologii produkcji, w proporcjach wykorzystywanych nakładów itp. w przypadku zmian sytuacji na rynku surowców rolniczych lub/i innych nakładów pozarolniczych. Brak możliwości dostosowania wynika z istniejącego potencjału technicznego i technologii wytwarzania. W takiej sytuacji zmiany cen detalicznych żywności wynikają ze zmienności cen nakładów. Brak możliwości reakcji podmiotów na zmiany sytuacji rynkowej oznacza, że muszą one stosować w swojej działalności dotychczasowe nakłady w takiej proporcji jak dotychczas. Przy takim założeniu ceny detaliczne żywności zmieniać się będą zależnie od ruchów cen nakładów pozarolniczych i surowców rolniczych.

Z uwagi na to, że żywność stanowi pewien agregat różnych produktów, przy wytwarzaniu których zużywa się różne ilości surowca rolniczego i nakładów pozarolniczych, niezbędne jest uwzględnienie znaczenia poszczególnych nakładów. Wymaga to zastosowania odpowiedniego systemu wag. Najczęściej wagami są udziały danego rodzaju nakładu w kosztach produkcji. Przyjmując takie rozwiązanie, względne zmiany cen żywności będą średnią ważoną względnych zmian cen nakładów, których wagami są udziały w kosztach wytwarzania produktów żywnościowych [Reed i in. 1997].

$$C_Z = C_M U_M + C_R U_R \quad (2.5)$$

gdzie:

$R_Z$  – ceny żywności,

$C_M$  – ceny nakładów pozarolniczych,

$C_R$  – ceny surowców rolnych,

$U_M$  – udział kosztów pozarolniczych w kosztach wytwarzania,

$U_R$  – udział surowców rolniczych w kosztach wytwarzania.

Zastosowanie takiego rozwiązania w ocenie wpływu zmian cen surowców rolniczych i pozarolniczych na zmiany cen żywności wymaga informacji o kosztach produkcji dla różnych grup produktów żywnościowych, a także o wielkości zużycia poszczególnych rodzajów nakładów. Wynika to z konieczności uwzględnienia bezpośredniego i pośredniego wpływu zmian cen danego nakładu. Dotyczy to zwłaszcza cen energii, która wykorzystywana jest w wielu ogniach łańcucha marketingowego (np. przetwórstwie, transporcie, przechowywaniu). Zmiany cen

tak wykorzystywanego nakładu wpływają bezpośrednio i pośrednio na zmiany cen żywności [Reed i in. 1997]. Przedstawiony model może stanowić podstawę teoretyczną do określania zmian cen żywności dla krótkiego okresu. W dłuższym okresie, do przewidywania wpływu zmian cen nakładów na ceny żywności można zastosować model oparty na idei przepływów międzygałęziowych (Input-Output Model) lub uwzględniający zmiany w zużyciu różnych nakładów. Szczegółowe informacje zastosowania tych modeli na przykładzie USA przedstawia Reed i in. [1997].

Popyt na surowce i produkty żywnościowe w kraju kreuje także zapotrzebowanie eksportowe. W warunkach swobodnych obrotów handlowych popyt na towary krajowe zależy między innymi od relacji popytowo-podażowych na rynkach zagranicznych. Niskie ceny krajowe stwarzają szanse wzrostu popytu i eksportu towaru. Odwrotna sytuacja może zachęcać do importu. Determinuje to sytuację rynkową w krótkich okresach i oznacza, że na popyt krajowy wpływa także sytuacja popytowo-podażowa i poziom cen w innych krajach. Do czynników determinujących obroty handlowe (np. wzrost popytu eksportowego lub jego obniżenie) należeć będą także kierunki zmian kursów walutowych. Osłabienie krajowej waluty może skłaniać przedsiębiorców do wywozu towaru na rynki zagraniczne. Powoduje to zwiększenie popytu eksportowego na surowiec lub produkt żywnościowy krajowy. Z kolei umocnienie waluty może zachęcać do przywozu tańszego towaru (surowca lub produktu żywnościowego) z zagranicy. Te dodatkowe rodzaje zapotrzebowania na surowce rolnicze mogą także wpływać na ceny żywności.


### **2.3.2. Koszty pozarolnicze**

Ogólnie, rozstęp cenowy (marża marketingowa) obejmuje różne komponenty nakładów i usług ponoszonych w ogniwach przetwórstwa i handlu, a także renty, opłatę za ryzyko. Dokonujące się procesy rozwoju społeczno-ekonomicznego nie pozostają bez wpływu na wzorce konsumpcji, czy organizację przetwórstwa i dystrybucji żywności. Ogólną prawidłowością jest powiększanie się różnic między ceną surowca rolniczego a ceną detaliczną. Taka prawidłowość wynika z różnych przyczyn. Są to: stałe zwiększanie stopnia przetworzenia produktów rolnych i wzrost wartości usług przetwórczych zawartych w produktach żywnościowych, zwiększanie roli sektora usług w wytwarzaniu produktu krajowego brutto oraz relatywne tanienie żywności i produktów rolnych [Urban 2002]. Skutkiem tych procesów jest zmniejszanie się udziału wartości surowca rolniczego w cenie detalicznej żywności. Taka tendencja

powoduje, że długookresowy związek między cenami surowców rolniczych a cenami detalicznymi żywności jest coraz słabszy.

Udział kosztów pozarolniczych w cenie detalicznej żywności stanowi dominującą jej część. Na przykład udział jej komponentów w cenie detalicznej w USA wynosi średnio: praca – 38,7%, opakowania – 8%, zyski – 4,5%, transport – 4%, energia – 3,8%, odsetki 4,3%, koszty reklamy – 4%, amortyzacja – 3,6%, renty -2,7%, naprawy – 1,5%, podatki 3,5%, inne koszty 2,9% [dane ERS, USDA]. W Polsce badania nad strukturą cen detalicznych głównych produktów żywnościowych prowadził Urban [2002]. Z badań wynika, że udział marży przetwórczej, handlowej i podatków pośrednich w cenie detalicznej głównych produktów żywnościowych w badanym okresie stanowił: mięso i przetwory – 53%, drób i przetwory – 48%, mleko i przetwory – 63%, przetwory owocowo-warzywne – 72%, mąki i kasze – 60%, przetwory ziemniaczane – 78%, cukier – 75%<sup>10</sup> [Urban 2002, s. 40].

**Rysunek 2.5. Wydatki ludności na żywność oraz wartość produkcji rolniczej w USA w latach 1955-2010 [mln USD]**



Źródło: opracowanie własne na podstawie: Ritson 1977, Brandson, Norvel 1983, Tracy 1997, Cramer i Jensen 1991, Drummond i Goodwin 2004, *Prices spread ...* <http://www.ers.usda.gov>. May 2014.

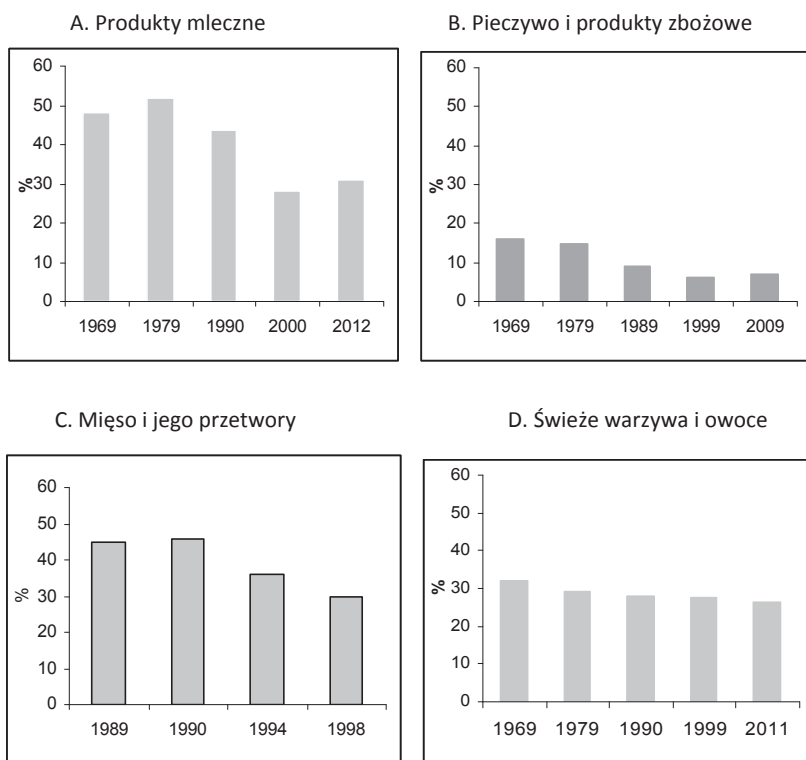
Dla ilustracji tej tezy na rysunku 2.5. przedstawiono zmiany w wydatkach na żywność i wartość produkcji rolniczej w niej zawartej w długim okresie na przykładzie USA. Udział wartości produkcji rolniczej w cenach detalicznych przeciętnego koszyka spożywczego w USA wynosił w roku: 1950 – 47%, 1960

<sup>10</sup> Razem elementy te odpowiadają terminowi marża marketingowa.

– 39%, 1970 – 39%, 1989 – 24%, w 1998 – 22%, a w 2000 wynosił – 19% [Cramer i in. 2001, s. 323; Drummond, Goodwin 2004, s. 322]. Natomiast w Niemczech w sezonie 1950/1951 udział ten wynosił 64%, 1970/1971 – 49%, 1980/1981 – 44,4%, 1991/1992 – 32,9%. Podobne prawidłowości dotyczące kształtowania się cen żywności i udziału w nich wartości produkcji rolniczej występują także w innych krajach. Wyniki badań z tego zakresu można znaleźć w pracach m.in. Ritsona [1977], Stańko [1999] czy Urbana [2002].

Udział wartości produkcji rolniczej w cenach detalicznych towarów jest zróżnicowany w zależności od stopnia przetworzenia produktu. Udział producenta surowców w cenach detalicznych wybranych grup produktów przedstawiono na rys. 2.6.

**Rysunek 2.6. Udział wartości surowca rolnego w cenie detalicznej w latach 1969-2012 [%]<sup>11</sup>**



Źródło: jak rys. 2.5.

<sup>11</sup> Różny zakres czasowy prezentowany na rysunku wynika z dostępności danych.

Jak już wspomniano, ogólną prawidłowością jest tendencja zmniejszania się udziału surowca rolniczego w cenie detalicznej produktu żywnościowego. Tendencja ta występuje niezależnie od poziomu udziału surowca w cenie detalicznej. Wyższy udział surowca w cenie detalicznej występuje na rynkach tych produktów żywnościowych, których forma produktu finalnego niewiele się różni od surowca otrzymanego w gospodarstwach rolnych (np. świeże owoce i warzywa), lub też wytwarzane jest niewiele różnych produktów żywnościowych z danego surowca. Natomiast im więcej różnorodnych produktów żywnościowych wytwarzanych jest z surowców rolniczych, tym udział jego w cenie detalicznej tych produktów jest mniejszy (przykład stanowią tu różnorodne rodzaje pieczywa, czy inne produkty piekarnicze i piekarskie ze zbóż).

Prawidłowości dotyczące kształtowania się udziału surowca rolniczego w cenie detalicznej mają wpływ na pionową transmisję cen w łańcuchu marketingowym. Naturalne jest, że w przypadku produktów o niskim udziale surowca rolnego będzie słabszą siłą przenoszenia zmian cen rolnych na ceny detaliczne i vice versa. Występować będą również coraz większe różnice między elastycznością popytu i podaży między tymi dwoma poziomami.

### **2.3.3. Determinanty zmian rozstępów cenowych**

Do głównych czynników wpływających na zmniejszanie się udziału surowca rolniczego, albo wzrostu udziału kosztów marketingowych w cenie detalicznej żywności, należą [Ritson 1977, Tracy 1997, Stańko 1999, Cramer i in. 2001, Urban 2002]:

- zmiany struktury popytu (por. rozdz. 1.4),
- stopień przetwórstwa produktów,
- wzrastające koszty przetwórstwa i dystrybucji żywności,
- zróżnicowane tempo postępu technologicznego w różnych ogniwach,
- koncentracja ludności w ośrodkach przemysłowych,
- siła rynkowa przedsiębiorstw w wielu ogniwach łańcucha marketingowego,
- wzrastająca liczba ogniw pośrednich w łańcuchu marketingowym,
- wzrastające wymagania w zakresie bezpieczeństwa i higieny żywności,
- wzrastająca produktywność w rolnictwie,
- polityka interwencji w rolnictwie,
- procesy globalizacji,
- inne (np. wzrost ryzyka).

Wzrastające koszty przetwórstwa i dystrybucji surowców rolnych wynikają nie tylko ze zmian struktury popytu, ale także koncentracji ludności w aglomeracjach miejskich. Powoduje to, że główni konsumenci żywności nie



mieszkają tam, gdzie wytwarza się surowce rolne. Bez odpowiedniej organizacji i dystrybucji żywności z miejsc wytwarzania do miejsc spożycia nie byłoby możliwe przetworzenie i przygotowanie żywności (dotyczy to zwłaszcza mrozonek, gotowych przetworzonych produktów).

W ostatnich latach wzrastają też wymogi w zakresie standardów jakościowych i higienicznych żywności. By je zapewnić, podmioty w poszczególnych ogniwach marketingowych ponoszą określone koszty, które znajdują swój wyraz w cenach detalicznych. W przetwórstwie i dystrybucji dokonuje się także postęp technologiczny. Przetwórstwo surowców rolniczych jest zlokalizowane bliżej bazy surowcowej, co powoduje, że możliwy jest szybszy transport gotowych produktów spożywczych. Także te procesy prowadzą do wzrostu kosztów przetwórstwa i dystrybucji.

Przy nasyconym rynku niezbędne są działania przedsiębiorstw zachęcające konsumentów do zakupu określonych produktów (np. reklama, doradztwo, pokazy), co zwiększa koszty marketingu. Tworzenie produktów o nowych walorach smakowych, zapachowych, pozwalających na wydłużenie okresu przechowywania itp. jest możliwe poprzez zastosowanie w produkcji żywności surowców niewytwarzanych w rolnictwie. Ich wykorzystanie zwiększa koszty produkcji żywności.

Zmniejszanie udziału surowca rolniczego w cenach detalicznych żywności wynika także z polityki interwencji i wzrostu produktywności rolnictwa. Odchodzenie od polityki podtrzymywania cen rolnych ku wspieraniu bezpośredniemu dochodów producentów rolnych powoduje obniżanie się cen rolnych. Z kolei wzrost produktywności rolnictwa powoduje spadek realnych cen rolnych, co też skutkuje obniżeniem udziału surowca w cenach detalicznych.

Obniżanie udziału surowca rolnego w cenach detalicznych żywności może wynikać także z liberalizacji handlu i rosnącego powiązania rynku lokalnego z rynkami regionalnymi i światowymi. Brak ograniczeń w obrotach handlowych może prowadzić do zaopatrywania się podmiotów na rynkach, na których występują najniższe ceny surowca. Prowadzi to stopniowej integracji rynków i wyrównywania się cen surowców. Nie chodzi tutaj o jednakowy poziom cen, ale o podobne kierunki zmian i różnice w poziomie wynikające z kosztów transakcyjnych (np. koszty transportu, załadunku i rozładunku, ubezpieczeń przewozów oraz zyski handlujących). Należy dodać, że pomimo integracji rynków surowców rolnych i stopniowego wyrównywania się ich cen nie oznacza to, że takie same procesy występują w kształtowaniu się cen żywności w poszczególnych krajach. Surowce rolnicze są tylko jednym z elementów kształtującym ceny detaliczne żywności. Podstawowe znaczenie w kształtowaniu cen żywności mają

koszty nakładów i usług nierolniczych ponoszonych w poszczególnych ogniwach łańcucha marketingowego (por. rys. 2.5).

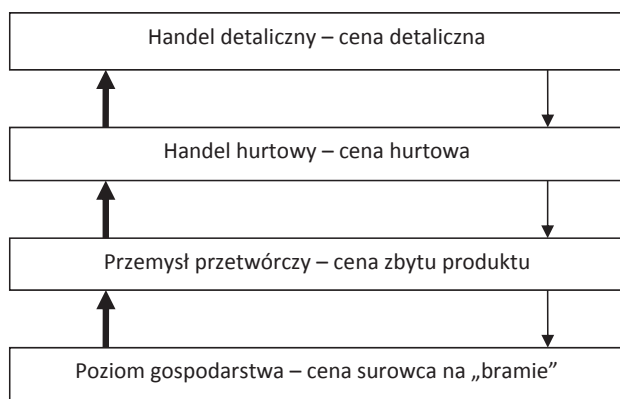
Ważnym determinantem kształtującym marżę marketingową jest ryzyko cenowe. Przetwórcy muszą mieć określony zapas surowców niezbędny do wytwarzania produktów finalnych. Zakup surowców musi uwzględniać stopień niepewności w odniesieniu do cen surowców i produktów finalnych w przyszłości. Wzrost ryzyka powoduje zwiększenie marży.

## 2.4. Transmisja cen w łańcuchu marketingowym

### 2.4.1. Pionowa transmisja cen

Przepływ surowców rolnych przez różne ogniwa łańcucha marketingowego wiąże się z zagadnieniem przekazu sygnałów cenowych między tymi ogniwami, co określane jest jako pionowa transmisja cen. Jest to przenoszenie sygnałów z jednego poziomu na drugi (w górę i dół). Teoretycznie zmiany cen obserwowane w ogniwach marketingowych powinny odzwierciedlać ruchy cen na rynku towaru stanowiącego jego pierwsze ogniwo. Kierunek tych ruchów przedstawiono na rys. 2.7<sup>12</sup>.

**Rysunek 2.7. Kierunki przekazu sygnałów cenowych między ogniwami łańcucha marketingowego – pionowa transmisja cen**



*Źródło: opracowanie własne.*

<sup>12</sup> Oprócz transmisji cen w łańcuchu marketingowym (pionowej) można także analizować transmisję w czasie i przestrzeni.

Transmisja cen w łańcuchu marketingowym rodzi także pytanie o kierunek, w którym przenoszone są sygnały. Większość badań empirycznych wskazuje na pionowy przepływ impulsów, od cen surowca do cen produktu finalnego (w górę). Możliwy jest też przekaz zmian cen od produktu finalnego do cen surowca (w dół). Pewnych wskazań o kierunku transmisji może dostarczyć analiza przyczynowości.

Przedmiotem analiz długookresowych są zmiany (tendencje) rozstępów cenowych (marż marketingowych)<sup>13</sup>. W krótszym okresie przedmiotem zainteresowania jest ocena reakcji cen detalicznych na zmiany cen surowców. Występuje szereg pytań w kwestii kształtowania się marż i transmisji cen. Do podstawowych można zaliczyć:

- dlaczego mamy do czynienia ze zróżnicowaniem marż między różnymi produktami żywnościowymi?
- jak szybko zmiany ceny surowca są przenoszone na ceny detaliczne?
- jak szybko zmiany cen detalicznych są przenoszone na ceny surowców rolnych?
- czy ruchy cen obserwowane w pierwszym ogniwie znajdują w pełni odzwierciedlenie w ewolucji cen produktów żywnościowych?
- czy mamy do czynienia z takimi samymi reakcjami na wzrost i na spadek ceny o jednakowej sile?

Większość badań zasadniczo potwierdza, że główny kierunek transmisji ma miejsce od cen rolnych do cen detalicznych. Oczywiście jest, że przenoszenie cen z jednego poziomu na drugi nie będzie następowało z elastycznością wynoszącą 1. Również zmiana cen detalicznych w odpowiedzi na zmiany cen rolnych nie następuje natychmiast i jest rozłożona w czasie. Są różne czynniki, które powodują te opóźnienia. Na przykład wzrost podaży mięsa drobiowego skutkuje najczęściej spadkiem cen producenta. Efekt obniżki tej ceny nie od razu będzie widoczny w obrocie detalicznym. Wynika to najczęściej z posiadania zapasów przez sieci handlowe, stworzonych wówczas, gdy ceny były wyższe. Wydłużenie okresu reakcji może być powodowane także niechęcią przeceny towarów, kiedy znajdują się one na „półce” [Tomek, Robinson 2001]. Powodowane jest to dodatkowymi kosztami związanymi z wprowadzeniem tych zmian (np. zmiana cenników, tzw. koszty menu). Badania empiryczne pokazują, że pełne przeniesienie cen rolnych na ceny detaliczne wynosi od kilku do kilkunastu miesięcy [Leibtag 2009, Davidson i in. 2011]. Zależy to od charakteru produktu, stopnia jego przetworzenia oraz agregatu jaki jest rozpatrywany.

---

<sup>13</sup> Zagadnienia z tego zakresu przedstawiono w podrozdziałach 2.2 i 2.3.

## 2.4.2. Asymetria transmisji

O charakterze transmisji i panujących relacjach w łańcuchu marketingowym świadczy między innymi sposób, w jaki ceny detaliczne produktów żywnościowych reagują na zmiany cen surowców rolniczych (wzrosty lub spadki) stanowiących ich podstawę. Teoretycznie w warunkach doskonałej konkurencji i natychmiastowego przepływu informacji ceny detaliczne żywności powinny reagować z taką samą siłą na wzrost, jak i spadek cen surowców rolnych. Jeśli tak nie jest, to mamy do czynienia z transmisją asymetryczną. Może być ona powodowana przez różne czynniki. Zaliczyć do nich można:

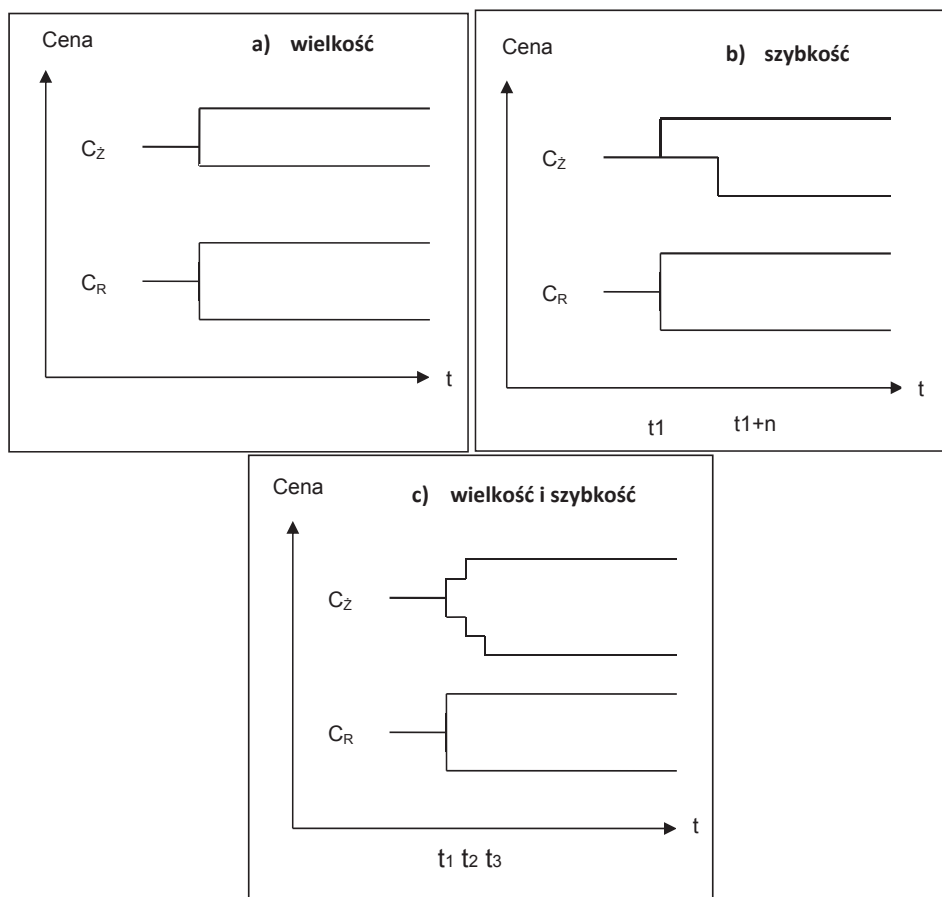
- niedoskonałą konkurencję rynkową [Foker 1987, Sexton 2013],
- siłę rynkową podmiotów [Wohlgenant 1985, Kinnucan, Forker 1987, Cramon-Taubadel 1999, Paulsen 2007, *The Gap...* 2007, Schnepf 2009],
- niedoskonałą informację rynkową [Borestein 1987],
- koncentrację w zakresie obrotów i przetwórstwa [Goodwin 1994, Paulsen 2007, *The Gap...* 2007],
- politykę interwencji rynkowej [Gardner 1975, Kinnucan, Forker 1987, *The Gap...* 2007],
- koszty dostosowań i tzw. koszty menu [Ward 1982, Bailey, Borsen 1989, Schnepf 2009],
- zmienność cen i szoki rynkowe [Schnepf 2009, OECD 2014],
- udział wartości surowca rolniczego w cenie detalicznej [*The Gap...* 2007],
- preferencje zakupowe konsumentów [Schnepf 2009, *The Gap...* 2007],
- stopień samowystarczalności kraju i wymianę handlową [*The Gap...* 2007],
- ryzyko związane z kursami walutowymi [Houck 1986],
- nietrwałość produktów [*The Gap...* 2007],
- inne czynniki.

Analiza asymetrii jest jedną z ważniejszych, jakie wykonuje się w ramach badań nad transmisją cen. Niektórzy [Peltzman 2000, OECD 2014] uważają, że asymetria jest cechą charakterystyczną dla transmisji cen wzdłuż łańcucha marketingowego. Jednak nie wszystkie badania potwierdzają występowanie asymetrii. Duży wpływ na wyniki badań ma bowiem stopień agregacji czasowej i przestrzennej wykorzystywanych danych oraz stosowana metodyka [Mayer, Cramon-Taubadel 2002]

Istnieją różne rodzaje asymetrii. Można rozpatrywać asymetrię ze względu na wielkość reakcji, jej szybkość, ze względu na wielkość i szybkość (kombinowana), dodatnią i ujemną [Mayer, Cramon-Taubadel 2002, Paulsen 2007]. Rodzaje asymetrii w transmisji cen przedstawiono na rysunkach 2.8 i 2.9.

Kombinację asymetrii transmisji cen surowca w zakresie szybkości i wielkości reakcji przedstawia trzeci schemat na rys. 2.8. Asymetria kombinowana łączy czas i wielkość reakcji ceny detalicznej na zmiany cen surowca. Reakcja cen detalicznych na wzrost cen surowca nie jest natychmiastowa, potrzeba jest dwóch okresów, by wzrost cen surowca został przełożony na zmianę cen detalicznych i nie jest on pełny (asymetria wielkości i szybkości). Z kolei transmisja spadku cen surowca jest asymetryczna ze względu na szybkość, ponieważ potrzeba jest trzech okresów, by obniżenie cen surowca zostało przeniesione na zmiany cen detalicznych żywności.

**Rysunek 2.8. Asymetria transmisji cen ze względu na wielkość i szybkość reakcji**



Źródło: opracowanie na podstawie Paulsen 2007.

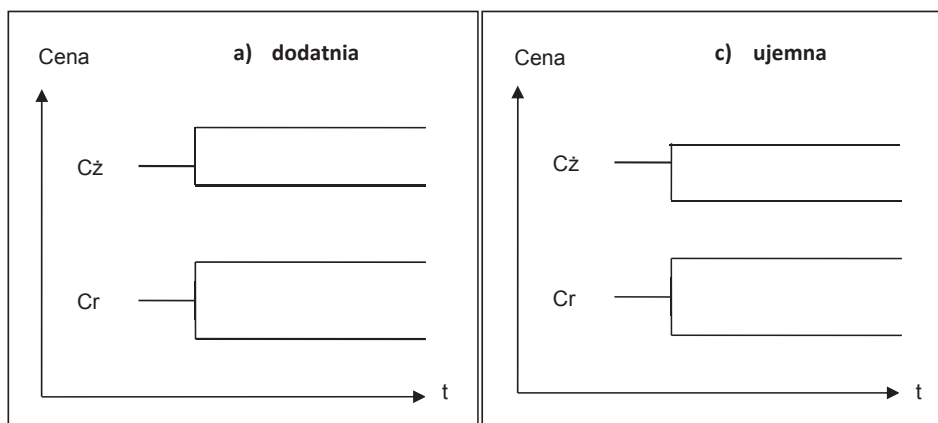
Na lewym górnym schemacie rys. 2.8 przedstawiono reakcję cen detalicznych żywności ( $C_Z$ ) na zmiany cen surowców rolnych ( $C_R$ ), w której wielkość reakcji cen detalicznych jest zależna od kierunku zmian cen surowca. Przy ich

wzroście obserwujemy relatywnie większą reakcję w cenach detalicznych, a przy spadku cen surowca obniżenie cen detalicznych jest relatywnie mniejsze.

Z kolei na prawym górnym schemacie rysunku 2.8 zobrazowano asymetrię transmisji cen ze względu na szybkość reakcji zmian cen surowca. Szybkość reakcji cen detalicznych zależna jest od kierunku zmian cen surowców rolnych. Wzrost cen surowca skutkuje natychmiastową reakcją cen detalicznych. Natomiast spadek cen surowca rolnego nie powoduje natychmiastowego obniżenia cen detalicznych żywności.

Można także wyróżnić asymetrię dodatnią i ujemną (rys. 2.9). O dodatniej asymetrii transmisji cen mówimy wtedy, gdy cena detaliczna produktu żywnościowego ( $C_Z$ ) reaguje pełniej i szybciej na wzrost cen surowca ( $C_R$ ), niż na jego spadek. Taki rodzaj transmisji cen jest niekorzystny dla konsumenta. Ceny detaliczne produktów żywnościowych obniżają się relatywnie wolniej niż ceny surowców rolnych. Asymetria negatywna (ujemna) charakteryzuje się tym, że cena detaliczna produktu żywnościowego ( $C_Z$ ) reaguje pełniej i szybciej na spadek cen surowca ( $C_R$ ) niż na jego wzrost. Taki sposób reakcji cen detalicznych na zmiany cen surowców rolnych jest korzystny dla konsumentów.

**Rysunek 2.9. Dodatnia i ujemna transmisja cen w łańcuchu marketingowym**



Źródło: opracowanie na podstawie Paulsen 2007.

Ocena transmisji cen w łańcuchu marketingowym powiązana jest z różnymi obszarami ekonomii. Z reguły pozwala ona formułować wnioski odnośnie konkurencyjności rynku, wykorzystywania przewag konkurencyjnych czy reakcji podmiotów na informacje płynące z rynku. Uwzględnienie potencjalnej asymetrii pozwala także na pełniejszą specyfikację modeli ekonometrycznych, które mogą służyć również do celów krótkookresowego prognozowania.

### **3. Metody analizy i krótkookresowego prognozowania cen detalicznych żywności**

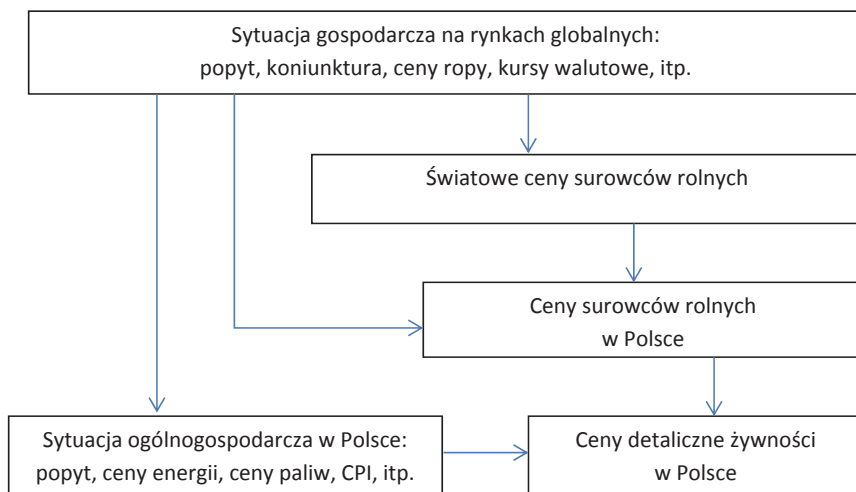
Pisząc o cenach detalicznych produktów żywnościowych będziemy mieli na myśli zarówno produkty indywidualne, jak i agregaty cenowe. W pierwszym przypadku dotyczą one produktów o różnych parametrach jakościowych, różnej wielkości opakowania czy zróżnicowanej przestrzennej lokalizacji (np. schab wieprzowy za 1 kg czy też śmietana o zawartości tłuszczu 18% w opakowaniu 0,5 litra). Agregaty cenowe w naszym przypadku to tzw. wskaźniki cen detalicznych (CPI), przedstawiają w sposób syntetyczny kształtowanie się zmian cen pewnej grupy towarów, najczęściej w ujęciu miesiąc do miesiąca, rok do roku czy też w postaci indeksu jednopodstawowego. Wskaźniki te również mogą być w różnym stopniu zagregowane (w ujęciu przestrzennym, temporalnym czy produktowym). Danymi statystycznymi przedstawiającymi zmiany cen w obydwu przypadkach są szeregi czasowe. Tym samym można uznać, że metody wykorzystywane do analizy i prognozowania tych cen mogą być takie same. Poniżej przedstawiono koncepcje i metody ich krótkookresowego prognozowania. Część z nich została wykorzystana w analizie ekonometrycznej.

#### **3.1. Koncepcje prognozowania cen detalicznych**

Poziom cen detalicznych jest funkcją wielu czynników (informacje na ten temat przedstawiono w rozdziałach 1 i 2). W praktyce nie jest możliwe uwzględnienie w modelu analitycznym wszystkich (a nawet większości) czynników i ich zaimplementowanie w modelu empirycznym w postaci zmiennych objaśniających. Wynika to z wielu ograniczeń m.in. wysokich kosztów, braku danych statycznych dla większości czynników czy też niemożliwości oszacowania bardzo skomplikowanych modeli. Stąd stosuje się pewne założenia pozwalające na uproszczenie procesu modelowania i prognozowania.

Można uznać, wychodząc od teorii ekonomicznej, że zmiany w czasie cen detalicznych żywności są funkcją zmian uwarunkowań podażowych i popytowych. Z jednej strony zależą one od cen czynników wykorzystywanych do produkcji żywności i jej dystrybucji (surowiec, praca, kapitał, energia itp.), a z drugiej zależą od sytuacji dochodowej konsumentów. Jeśli zechcemy podejść do zagadnienia w sposób bardziej kompleksowy, to należałoby obok uwarunkowań krajowych uwzględnić również sytuację na rynkach UE czy na rynku globalnym. Uproszczony schemat powiązań krajowych cen detalicznych żywności z poszczególnymi czynnikami zawarto na rysunku 3.1.

**Rysunek 3.1. Czynniki kształtujące zmiany detalicznych cen żywności w Polsce**



Źródło: opracowanie własne.

Mając na uwadze powyższe zależności oraz znając właściwości poszczególnych grup modeli prognostycznych, do krótkookresowego prognozowania cen detalicznych można podejść na kilka sposobów. Różnią się one między sobą kompleksowością (liczba zmiennych prognozowanych), stopniem powiązania między prognozami poszczególnych zmiennych w ramach całego systemu czy też liczbą czynników uwzględnionych w modelu.

**W pierwszym** i najprostszym podejściu można wyjść od założenia, że szeregi czasowe cen detalicznych poszczególnych produktów (lub grup produktowych) zawierają w sobie wszystkie dostępne informacje. Wychodzi się od powszechnie stosowanego założenia opartego na racjonalności uczestników rynku i braku trudności w przepływie informacji rynkowych. Można wówczas zastosować jednorównaniowe modele szeregów czasowych np. SARIMA, regARIMA czy model wygładzania wykładniczego. Tym samym nie ma konieczności budowy skomplikowanych modeli, w których rolę zmiennych objaśniających pełniłyby czynniki popytowe, ceny rolne czy kursy walutowe. Taki model traktuje się jak czarną skrzynkę – *black box* [Box, Jenkins 1983].

Zaletą tego podejścia są przede wszystkim niskie koszty (dane, czas, wiedza). Koszty te są związane z zakresem danych statystycznych (wykorzystuje się tylko wartości zmiennych prognostycznych), relatywnie niewielką złożonością modeli szeregów czasowych i dostępnością często automatycznych procedur w wielu pakietach statystycznych. Najważniejszą zaletą jednak jest to, że nie są wymagane prognozy zmiennych objaśniających, gdyż jedyną zmienną, od



której zależy wartość szeregu czasowego (w zakresie próby jak i w okresie prognostycznym), jest czas. W przeciwieństwie do modeli bazujących na zależnościach przyczynowo-skutkowych specyfikacja modeli szeregów czasowych jest prostsza i nie musi przekładać się na pogorszenie dokładności prognoz.

Mankamentem zastosowania jednorównaniowych modeli szeregów czasowych jest wspomniany wcześniej brak objaśniania przyczyn zmian oraz niezależność prognoz powiązanych ze sobą zjawisk. W tym drugim przypadku chodzi o to, że przy prognozowaniu wielu zjawisk jednocześnie uzyskane prognozy nie tworzą jednolitego (zgodnego) systemu prognoz i mogą zachowywać się niezależnie od siebie. Ma to jednak taką zaletę, że istnieje mniejsze ryzyko popełnienia błędów systematycznych polegających na zawyżeniu lub zaniżeniu większości prognoz.

**W ujęciu drugim** również nie wykorzystuje się danych statystycznych innych niż szeregi czasowe cen detalicznych produktów żywnościowych czy CPI żywności. W odróżnieniu od pierwszego podejścia można założyć, że ceny poszczególnych produktów żywnościowych są ze sobą skorelowane lub między nimi zachodzą zależności o charakterze przyczynowym. Zależności te są pochodną wspólnych czynników oddziałujących na poziom cen (np. popytu, cen energii czy cen surowców rolnych) czy też pochodną powiązań substytucyjnych i komplementarnych między produktami lub grupami produktów. Zatem w modelach tych ceny jednych produktów żywnościowych są funkcją cen innych produktów żywnościowych. Podczas specyfikacji modeli ważne jest określenie kierunku zależności przyczynowo-skutkowych, opóźnień między zmiennymi oraz opóźnień o charakterze autoregresyjnym. Takie podejście zapewnia nam większą zgodność prognoz jako całości.

W tym przypadku można wykorzystać dynamiczne modele zgodne, model regARIMA, modele kointegracji Engla-Grangera (EG) czy model wektorowej autoregresji VAR/VECM. Jednak tylko w ostatnim przypadku nie ma konieczności ustalania (przyjmowania) wartości zmiennych objaśniających na okres prognostyczny. W pozostałych przypadkach nie jest możliwe obliczenie prognozy bez wcześniejszego oszacowania prognoz zmiennych objaśniających. Niemniej jednak przy odpowiednim określeniu kolejności estymacji równań, można przyjmować, że zmienne prognozowane we wcześniejszych etapach będą pełniły rolę zmiennych objaśnianych w kolejnych modelach.

**W trzecim podejściu** specyfikację modeli prognostycznych można oprzeć na zależnościach przyczynowo-skutkowych na rynku krajowym. Zatem można przyjąć, że ceny detaliczne zależą od cen surowców rolnych notowanych

w Polsce, cen pozostałych nakładów oraz innych uwarunkowań ogólnogospodarczych w naszym kraju. Tutaj można przyjąć kilka wariantów postępowania:

1. Zakłada się, że w krótkim okresie dominujący kierunek przepływu informacji (sygnałów) następuje w kierunku cen detalicznych, a informacje zwrotne mają niewielkie znaczenie. Wymaga to w pierwszej kolejności oszacowania modeli i prognoz dla zmiennych makroekonomicznych (sytuacja ogólnogospodarcza oraz ceny nakładów pozasurowcowych) oraz modeli i prognoz dla cen surowców rolnych. Można w tym celu zastosować np. modele VAR/VECM czy model szeregów czasowych. Zmienne te pełniłyby rolę zmiennych objaśniających w modelach korekty błędem (ECM), modelach regARIMA, dynamicznych modelach zgodnych, lub też mogłyby pełnić rolę zmiennych egzogenicznych w wektorowych modelach autoregresyjnych VAR/VECM. Zaletą tego podejścia jest stosowanie jednakowych prognoz zmiennych egzogenicznych dla wszystkich przypadków. Wadą jest przyjęcie jednokierunkowego przepływu informacji (transmisji) podczas gdy w rzeczywistości, a szczególnie w przypadku produktów niskoprzetworzonych, może być inaczej.
2. Przyjmujemy wzajemne (wielokierunkowe) powiązania między cenami detalicznymi, cenami surowców rolnych oraz czynnikami makroekonomicznymi. W ramach modeli VAR/VECM można oszacować wzajemne powiązania między powyższymi czynnikami w ramach jednego modelu. W praktyce modele VAR/VECM są szacowane dla 2-4 zmiennych, co oznacza, że dla każdej ceny detalicznej należy szacować oddzielny model, w ramach którego brano by pod uwagę cenę surowca rolnego, zmienną wyrażającą zdolności nabywcze oraz zmienną wyrażającą koszty pozasurowcowe. Pewnym sposobem powiązania prognoz cen detalicznych ze sobą jest wykorzystanie wcześniej wykonanych prognoz zmiennych (detalicznych) jako zmiennych egzogenicznych w kolejnych modelach lub włączenie w tej roli niektórych zmiennych makroekonomicznych.

**Czwarte podejście** ma charakter najbardziej kompleksowy, ale też jest najbardziej czasochłonne i kosztochłonne. Mimo to nie gwarantuje, że prognozy cen detalicznych będą dokładniejsze niż na podstawie prostszych założeń. Punktem wyjścia jest tu sytuacja w gospodarce światowej (makroekonomiczna oraz na poszczególnych rynkach rolnych). W pierwszym kroku można oszacować modele i obliczyć prognozy wskaźników (zmiennych) obrazujących makroekonomiczne uwarunkowania w świecie. Prognozy niektórych zmiennych można przyjąć za innymi instytucjami (np. Europejskim Bankiem Centralnym czy Międzynarodowym Funduszem Walutowym). Stanowi to podstawę do oszacowania modeli i prognoz zmiennych makroekonomicznych w Polsce oraz światowych

cen surowców rolnych. Można wówczas informacje te wykorzystać do prognozowania cen rolnych w Polsce, a następnie cen krajowych detalicznych. Uproszczenie tego procesu polegać mogłoby na uzależnieniu krajowych cen żywności od czynników makroekonomicznych w Polsce (wraz z kursem walutowym) oraz światowych cen surowców rolnych (z pominięciem cen rolnych w Polsce). W ramach tej koncepcji można skorzystać z modeli opisanych poprzednio.

Oczywiście istnieje szereg innych możliwości rozwiązań prognozowania cen detalicznych opartych na danych miesięcznych czy kwartalnych. Niemniej należy pamiętać, że nie zawsze zastosowanie złożonych modeli prowadzi do uzyskania dokładniejszych prognoz. Ważną rolę odgrywa prognosta (analityk), który decyduje o zakresie zastosowanych danych, okresie estymacji, specyfikacji modelu, czy też dokonuje merytorycznej akceptacji uzyskanych wyników (prognoz).

## 3.2. Prawidłowości i zależności w czasie

Modele krótkookresowego prognozowania cen należą do modeli dynamicznych wykorzystujących czas jako podstawowy element opisu zjawiska w jego powiązaniu ze zdarzeniami występującymi wcześniej i później. Podstawą ich konstrukcji są szeregi czasowe. Stąd w niniejszym podrozdziale przybliżono definicje i koncepcje stosowane przy opisie prawidłowości występujących w szeregach czasowych oraz zależności między różnymi szeregami czasowymi.

### 3.2.1. Szeregi czasowe i ich struktura

Istnieją różne definicje szeregów czasowych. W najprostszym ujęciu można przyjąć, że szereg czasowy to uporządkowany chronologicznie zbiór wartości badanej cechy lub określonego zjawiska zaobserwowanych w różnych momentach (przedziałach) czasu.

Inna, bardziej przydatna definicja określa **szereg czasowy** jako realizację procesu stochastycznego  $\{Y_t\}$ , którego dziedziną jest czas. **Proces stochastyczny** definiowany jest wtedy jako rodzina zmiennych losowych o wartościach rzeczywistych indeksowanych przez  $t$ , a szereg czasowy jest wtedy jego pojedynczą realizacją [Charemza, Deadman 1997]. Mówiąc inaczej, proces stochastyczny jest opisem statystycznym zmienności pewnego zjawiska w czasie. Szereg czasowy natomiast, będący realizacją tego procesu, jest serią uporządkowanych w czasie pomiarów zmiennej charakteryzującej to zjawisko [Osińska 2006].

Kluczową właściwością zarówno procesu stochastycznego, jak i szeregu czasowego, jest jego **stacjonarność**. Proces stochastyczny jest ściśle stacjonarny,

gdy jego wielowymiarowy rozkład prawdopodobieństwa nie zmienia się w czasie. Z przyczyn praktycznych wygodniej jest posługiwać się pojęciem słabej stacjonarności procesu stochastycznego, definiowanej spełnieniem równocześnie trzech warunków [Box, Jenkins 1983]:

- skończona i stała w czasie wartość oczekiwana –  $E(X_t) = const$ ,
- skończona i stała w czasie wariancja –  $V(X_t) = const$ ,
- wartość kowariancji pomiędzy obserwacjami z dwóch okresów zależy jedynie od odległości (odstępu) między nimi –  $Cov(X_t, X_{t-p}) = const$ , dla każdego  $t$ .

Innymi słowy procesy stacjonarne charakteryzują się tym, że mają stałą wariancję, a ich wartości w poszczególnych momentach kształtują się wokół względnie stałego poziomu (średniej). Z kolei wartość kowariancji nie zależy od czasu, lecz wyłącznie od odstępu pomiędzy dwoma momentami obserwacji. Szczególnym rodzajem procesu stacjonarnego jest proces białego szumu. W jego przypadku średnia procesu jest równa zero, wariancja jest stała w czasie, natomiast kowariancja między obserwacjami z okresu  $t$  oraz  $t-i$  jest równa zero. Jest to jednoznaczne z brakiem istotnych zależności autokorelacyjnych.

Proces stochastyczny niespełniający tych trzech warunków jest procesem niestacjonarnym. Stacjonarność szeregów czasowych definiowana jest analogicznie jak stacjonarność procesów stochastycznych. Szereg czasowy jest ściśle stacjonarny, gdy wszystkie jego charakterystyki nie zmieniają się w czasie, i słabo stacjonarny, gdy nie zmieniają się w czasie jego wartość oczekiwana, wariancja i kowariancja. Niestacjonarny szereg czasowy zmiennej  $X_t$  nazywany jest zintegrowanym rzędu  $d$  i oznaczany jest jako  $X_t \sim I(d)$ . Wartość  $d$  oznacza krotność różnicowania szeregu czasowego, w wyniku którego uzyskiwany jest szereg stacjonarny.

Szeregi czasowe mogą również zawierać wahania sezonowe i, co za tym idzie, mogą być zintegrowane sezonowo. W takim przypadku w celu doprowadzenia szeregu do stacjonarności należy obliczyć  $D$ -krotne różnice między oddalonymi o jeden rok ( $s$  okresów) obserwacjami. Operację taką nazywamy różnicowaniem sezonowym. Często różnicowanie sezonowe usuwa również trend (w przypadku addytywnej sezonowości). Stąd mamy do czynienia z szeregiem niestacjonarnym  $SI_s(d, D)$  zintegrowanym w stopniu  $(d, D)$  wówczas, jeśli można go sprowadzić do szeregu stacjonarnego obliczając sezonowe przyrosty  $D$ -krotnie, a potem wyznaczając  $d$ -krotnie pierwsze przyrosty [Charemza, Deadman 1997].

Stacjonarność szeregów czasowych jest badana za pomocą wielu testów statystycznych. Najpopularniejszymi testami stacjonarności są: rozszerzony test

Dickeya-Fullera (*ADF*) oraz test Kwiatkowskiego, Phillipsa, Schmidta i Shina (*KPSS*). Szczegółowy opis testów i procedur testowania można znaleźć m.in. w [Maddala 2006, Osińska 2006]. Istotne znaczenie odgrywa również fakt, że obok komponentów stochastycznych również trend oraz sezonowość mogą mieć charakter deterministyczny.

Wygodną koncepcją stanowiącą podstawę analizy dynamiki zjawisk i ich prognozowania jest **dekompozycja szeregu czasowego**. Przyjmuje się, że szereg czasowy ( $Y_t$ ) można rozłożyć na następujące komponenty nazywane składowymi szeregu czasowego: trend-cykl ( $TC_t$ ), wahania sezonowe ( $S_t$ ) i wahania przypadkowe ( $I_t$ ). Wyróżnić można dwa podstawowe modele: addytywny (3.1) i multiplikatywny (3.2):

$$Y_t = TC_t + S_t + I_t \quad (3.1)$$

$$Y_t = TC_t \times S_t \times I_t. \quad (3.2)$$

Obok tych prawidłowości można również wyróżnić tzw. zmiany strukturalne (np. skokowe zmiany zjawiska), obserwacje nietypowe (wartości odbiegające od typowych) oraz efekty kalendarzowe (efekt ruchomych świąt czy efekty różnej liczby dni roboczych). Szereg czasowy może być skorygowany o te wahania przed dokonaniem właściwej dekompozycji.

Modele dekompozycji szeregów czasowych stanowią dogodny punkt wyjścia do określenia prawidłowości występujących w zjawisku. Stwierdzona struktura szeregu czasowego determinuje dobór modelu. Oprócz możliwości wykorzystania do celów analitycznych, szereg czasowy rozłożony na poszczególne komponenty lub skorygowany o pewne wahania może stanowić punkt wyjścia do prognozowania zjawisk.

W zastosowaniach aplikacyjnych rozwinięto różne procedury aplikacyjne umożliwiające dekompozycję szeregu czasowego. Zaliczymy do nich m.in.: klasyczną dekompozycję, model STL [Cliveland i in. 1990], procedurę Berlińską BV4.1 [*The BV4.1 Procedure...*2006], metodę X-12-ARIMA [X-12-ARIMA...2011], czy procedurę TRAMO/SEATS [Gómez, Maravall 2001]. Największą popularność w ostatnich latach zdobyły dwie ostatnie procedury i te pokrótce scharakteryzujemy również z uwagi na ich zastosowanie w części empirycznej. Szerzej są one omówione w opracowaniu pod red. Hamulczuka [2011] czy też w pracy Grudkowskiej [2013]. W ostatnim czasie rozwijana jest nowa wersja modelu nazywana X-13-ARIMA-SEATS, która stanowi integrację tych dwóch podejść [*X-13ARIMA-SEATS...*2013]. Procedury te są zawarte w programach statystycznych, np. GRETL, DEMETRA+, czy J-Demetra+.

**Metoda X-12-ARIMA** składa się z trzech etapów. W pierwszym kroku stosuje się model regARIMA celem m.in. oczyszczenia szeregu czasowego z wpływu zaburzeń o charakterze szokowym i jego linearyzacji. Wstępne modelowanie szeregu czasowego polega na identyfikacji różnego rodzaju obserwacji nietypowych, a także na testowaniu wpływu świąt stałych i ruchomych oraz innych czynników zewnętrznych na analizowane dane. Czynniki te powodują występowanie nieliniowości w modelu, toteż są one szacowane i usuwane z szeregu czasowego przed rozpoczęciem zasadniczej estymacji, co nazywamy linearyzacją szeregu czasowego. Po zakończeniu dekompozycji usunięte wcześniej elementy są dodawane do odpowiednich komponentów szeregu czasowego lub są wykazywane w osobnych kategoriach. Ponadto na tym etapie określany jest rodzaj zależności pomiędzy komponentami szeregu czasowego oraz wyliczane są prognozy wykorzystywane na dalszym etapie estymacji modelu [X-12-ARIMA...2011].

W drugim kroku w ramach algorytmu X-11 przeprowadzana jest właściwa dekompozycja szeregu czasowego w dziedzinie czasu za pomocą odpowiednio dobranych średnich ruchomych, które służą do oszacowania trendu-cyklu i komponentu sezonowego. Symetryczne średnie ruchome umożliwiają eliminację określonych częstości z szeregu czasowego oraz nie powodują wystąpienia efektu fazowego. Wykorzystując różnego rodzaju filtry o różnej długości oraz stosując dwie iteracje coraz bardziej przybliżamy się do ostatecznych oszacowań tych dwóch komponentów. W trzecim kroku, przeprowadzana jest kompleksowa diagnostyka modelu. Testuje się między innymi: istotność komponentu sezonowego i jego typ w wyjściowym szeregu czasowym, charakterystyki zmian i udział poszczególnych komponentów w wyjściowym szeregu, stabilność otrzymanych wyników czy właściwości składnika resztowego (np. rozkład, autokorelacje, sezonowość rezydualną).

**TRAMO-SEATS** jest metodą, w której wyodrębnienie komponentów z szeregu czasowego dokonywane jest na podstawie odpowiednio dobranych modeli ARIMA [Gómez, Maravall 2001]. Zatem zasadnicza różnica w porównaniu do X-12-ARIMA polega na tym, że dekompozycja ta przeprowadzana jest w dziedzinie częstości, a nie dziedzinie czasu. TRAMO/SEATS jest również metodą dwuetapową. W pierwszej fazie stosowany jest algorytm TRAMO (*Time Series Regression with ARIMA Noise, Missing Observations and Outliers*), który zasadniczo polega na tym samym i ma podobny cel jak model regARIMA w metodzie X-12-ARIMA.

W drugiej fazie, poprzez algorytm SEATS (*Signal Extraction in Arima Time Series*), następuje właściwa dekompozycja szeregu czasowego poprzez określenie postaci modelu ARIMA dla każdego ze składników. Procedura

SEATS polega na dekompozycji szeregu czasowego opisanego modelem ARIMA na nieobserwowalne komponenty: trend-cykl, czynnik sezonowy, komponent przejściowy i komponent nieregularny. W procesie estymacji zakłada się, że składowe szeregu czasowego są do siebie ortogonalne, przyjmując tym samym, że zachowaniu poszczególnych komponentów odpowiadają różne, niezależne od siebie przyczyny. Dekompozycja polega na podziale funkcji gęstości spektralnej szeregu  $x_t$  na funkcje gęstości spektralnych poszczególnych składowych. Do trendu-cyklu są włączane wartości skupione wokół zerowej częstości spektralnej. Komponent sezonowy tworzą wartości funkcji gęstości spektralnej znajdujące się w określonym przedziale wokół częstości sezonowych. Na składnik przejściowy składają się cykliczne fluktuacje o okresie zmian większym niż rok. Komponent nieregularny jest procesem białego szumu.

### 3.2.2. Przyczynowość i zależności długookresowe

Drugi sposób prognozowania wiąże się z próbą uchwycenia prawidłowości w postaci modelu o charakterze przyczynowo-skutkowym. Jednak specyfikacja takich modeli jest bardzo trudna, z uwagi na problemy regresji pozornych oraz jednoznaczny podział zmiennych na egzogeniczne i endogeniczne. W większości przypadków specyfikując model należy wskazać, co jest zmienną zależną, a co zmienną niezależną. W tym celu należy wykorzystać teorię ekonomiczną oraz wyniki analiz empirycznych.

Problem regresji pozornej wiąże się z faktem, że szeregi czasowe wykorzystywane w analizach (zmienne objaśniane i zmienne objaśniające) są z reguły niestacjonarne, przez co modele objaśniające kształtowania się cen mogą dawać pozornie dobre wyniki. Objawia się to wysokimi wartościami współczynnika determinacji i istotnością parametrów strukturalnych modelu. Z reguły jednak wartość statystyki testu Durбина-Watsona jest niska. W celu uniknięcia niebezpieczeństw wynikających z występowania regresji pozornej wykorzystuje się tak zwaną analizę kointegracyjną.

Analiza kointegracyjna służy do wykrywania i opisu zależności długookresowych [Enders 2010, Kusideł 2000]. Kointegracja szeregów czasowych dwóch zmiennych ( $X_t$ ,  $Y_t$ ) występuje, gdy są one zintegrowane w stopniu  $d$ , a ich liniowa kombinacja  $-\beta_1 X_t + \beta_2 Y_t$  jest zintegrowana rzędu  $d-b$  ( $d \geq b \geq 0$ ). Wektor  $[\beta_1 \beta_2]$  jest nazywany wektorem kointegracyjnym. Najczęściej w praktyce spotykana jest sytuacja, że szeregi czasowe obserwacji na zmiennych są zintegrowane stopnia pierwszego, a ich liniowa kombinacja jest stacjonarna.

Do określenia występowania zależności długookresowych można wykorzystać np. test Engle'a-Grangera [Engle, Granger 1987]. Po stwierdzeniu

w pierwszym kroku niestacjonarności zmiennych, bada się stacjonarność reszt następującego modelu:

$$Y_t = \beta_0 + \beta_2 X_t + \varepsilon_t, \quad (3.3)$$

gdzie:

$X_t, Y_t$  są zmiennymi potencjalnie skointegrowanymi,

$\beta_0, \beta_2$  są parametrami strukturalnymi,

$\varepsilon_t$  – składnik losowy.

Jeśli szereg czasowy reszt jest stacjonarny, to zmienne  $X_t$  i  $Y_t$  są skointegrowane. Model ten można uzupełnić o zmienne deterministyczne uwzględniające trend czy sezonowość. Relację pomiędzy zmiennymi skointegrowanymi można zapisać za pomocą modelu korekty błędem o postaci [Engle, Granger 1987]:

$$\Delta Y_t = \alpha_0 + \alpha_1 \Delta X_t + \gamma ECT_{t-1} + \varepsilon_t, \quad (3.4)$$

gdzie wartości  $ECT_t$  (*Error Correction Term*) wyznaczone są z równania 3.3:

$$ECT_t = Y_t - \beta_0 - \beta_2 X_t.$$

Jeżeli model korekty błędem wykazuje autokorelację, należy go zmodyfikować przez dodanie opóźnionych wartości pierwszych różnic, tak zmiennej  $X$ , jak i  $Y$  [Osińska 2006, s. 189]. Parametr  $\alpha_1$  modelu (3.4) informuje o dostosowaniach krótkookresowych w momencie  $t$  do stanu równowagi w momencie  $t-1$ . O dostosowaniach do długookresowej ścieżki równowagi informuje parametr  $\gamma$ . Wskazuje on, jaka część odchylenia od ścieżki długookresowej korygowana jest w kolejnym okresie. Układ będzie wracał do równowagi, jeżeli wartość tego parametru będzie się zawierała w przedziale (0;-1).

Drugą ważną kwestią jest **przyczynowość**, która zasadniczo ma wymiar filozoficzny i jest próbą zrozumienia następstwa zdarzeń. Poznanie prawidłowości w zakresie przyczynowości oznacza jednocześnie możliwość przewidywania przyszłości (przyczyna-skutek). Formalnie przyczynowość można zdefiniować jako związek, który występuje pomiędzy dwiema zmiennymi losowymi, przy czym jedna ze zmiennych wyznacza wartość drugiej zmiennej.

Najbardziej znana w dziedzinie ekonometrii jest definicja przyczynowości w sensie Grangera. Według niej zmienna  $X$  jest przyczyną dla zmiennej  $Y$ , jeśli bieżące wartości  $Y$  są lepiej objaśniane przy użyciu opóźnionych (i bieżących) wartości  $X$  niż bez ich wykorzystania. Idea tego testu polega na sprawdzeniu, czy wprowadzenie danej zmiennej do modelu wraz ze wszystkimi opóźnieniami zmniejszy istotnie wariancję resztową [Charemza, Deadman 1997]. Przyczynowość może być testowana w różnych modelach (ARDL, VAR, czy ECM) na



podstawie oceny istotności parametrów modelu za pomocą statystyk t-Studenta, statystyki  $F$  czy statystyki Walda.

Istotne znaczenie w testowaniu przyczynowości ma kwestia stacjonarności badanych zmiennych oraz występowania zależności długookresowych (kointegracyjnych). Zależności przyczynowe w znaczeniu omówionym powyżej mogą być testowane tylko w przypadku stacjonarnych szeregów czasowych. W przypadku niestacjonarnych szeregów czasowych możliwe jest to wówczas, gdy niestacjonarność można usunąć, wprowadzając zmienne deterministyczne odnoszące się do trendu czy sezonowości, lub transformując szeregi czasowe przez wyznaczenie pierwszych różnic bądź logarytmowanie [Enders 2010]. Z kolei Toda i Yamamoto [1995] wskazują, że nie powinno się przeprowadzać badań na przyrostach, tylko zwiększyć liczbę opóźnień modelu VAR (składającego się z dwóch modeli ARDL) o stopień integracji szeregów czasów  $m$ , a następnie badać wpływ nakładanych restrykcji (restrykcji nie nakłada się dodatkowe  $m$  opóźnień) za pomocą statystyki  $F$ .

Odmienne do testowania przyczynowości należy podejść w przypadku stwierdzenia kointegracji szeregów czasowych. Już sam ten fakt jest podstawą do uznania przyczynowości co najmniej w jednym kierunku, ale nie wiadomo, w którym. Osińska [2008] wskazuje, że w przypadku niestacjonarnych szeregów czasowych, które są skointegrowane, wnioskować o przyczynowości powinno się na podstawie modeli ECM lub VECM. Z kolei Toda i Yamamoto [1995] wskazują, że zaproponowana przez nich procedura (opisana w poprzednim akapicie) może być stosowana zarówno w przypadku szeregów skointegrowanych, jak i stacjonarnych, czy też nieskointegrowanych. Test ten pozwala również testować przyczynowość w przypadku, gdy np. jedna zmienna jest stacjonarna, a druga jest niestacjonarna.

### **3.3. Metody i modele analizy i prognozowania szeregów czasowych**

Poniżej omówiono najważniejsze modele szeregów czasowych wykorzystane w niniejszym opracowaniu lub mogące znaleźć zastosowanie w prognozowaniu cen detalicznych. Punktem wyjścia w ich wyborze jest struktura szeregu czasowego.

#### **3.3.1. Model ekonometryczny**

Wiedząc, że szeregi czasowe cen detalicznych charakteryzują się złożoną strukturą trudno jest dopasować odpowiedni model ekonometryczny, który

będzie odzwierciedlał prawidłowości występujące w danych. W niniejszym opracowaniu do prognozowania zarówno cen detalicznych, jak i cen surowców rolnych proponujemy wyjść od następującego modelu ekonometrycznego [Falk, Roy 2005; Kufel 2007]:

$$\begin{cases} Y_t = \sum_{i=0}^T \alpha_i t_{ii}^i + \sum_{i=1}^k \beta_i D_{it} + \sum_{i=1}^{r-1} \gamma_i S_{it} + u_t & (3.5) \\ u_t = \phi_1 u_{t-1} + \phi_2 u_{t-2} + \dots + \phi_p u_{t-p} + \varepsilon_t & (3.6) \end{cases}$$

gdzie:

$\sum_{i=0}^T \alpha_i t_{ii}^i$  – wielomian funkcji trendu rzędu  $T$  (łącznie z wyrazem wolnym),

$\sum_{i=1}^k \beta_i D_{it}$  – komponent odpowiedzialny za zmiany strukturalne i obserwacje odstające, gdzie  $k$  to liczba tych zmiennych,

$\sum_{i=1}^{r-1} \gamma_i S_{it}$  – komponent sezonowy nakładający się ze zmiennych zero-jedynkowych, gdzie  $r$  oznacza liczbę sezonów w roku,

$u_t$  – reszty modelu podlegające procesowi autoregresyjnemu rzędu  $p$ ,

$\alpha, \beta, \gamma, \phi$  – parametry modelu,

$\varepsilon_t$  – składnik losowy.

Jest to model funkcji trendu rozszerzony o potencjalne zmiany strukturalne, wahania sezonowe oraz komponent autoregresyjny. Wahania sezonowe ujęto za pomocą  $r-1$  zmiennych zero-jedynkowych, zakładając ich niezmiennosc w czasie. Krótko- i średniookresowe odchylenia od trendu w postaci wahań quasi-cyklicznych ujęto za pomocą komponentu autoregresyjnego.

Potencjalne zmiany strukturalne skokowe (*level shift*, LS) lub też obserwacje odstające (*additive outlier*, AO) można uchwycić za pomocą zmiennych zero-jedynkowych. Momenty, w których mamy do czynienia z takimi zmianami, można ustalić na podstawie wiedzy eksperckiej, wykorzystując procedurę X-12-ARIMA bądź też analizując reszty wstępnie oszacowanego modelu bez tego komponentu. Jeżeli występują opóźnienia, specyfikacja  $D_{it}$  musi uwzględniać dodatkowo rząd opóźnień. Szerzej na ten temat pisze m.in. [Joyeux 2007].

Do estymacji parametrów modelu można wykorzystać m.in. następujące podejścia [Falk, Roy 2005; Kufel 2007]:

- Dwustopniową KMNK, gdzie najpierw szacujemy równanie 3.5, obliczamy prognozy oraz zapisujemy reszty  $u_t$ . Następnie dobieramy liczbę opóźnień  $p$  i szacujemy model autoregresji dla  $u_t$  (równanie 3.6) oraz obliczamy na jego podstawie prognozy reszt. Ostateczna prognoza jest równa sumie wielkości otrzymanych z obydwu równań.
- Uogólnioną MNK, np. procedurę Cochrane-Orcutta.

- Bezpośrednią estymację modelu, w którym efekty autoregresyjne ujęte są w postaci opóźnionych wartości zmiennej prognozowanej:

$$Y_t = \sum_{i=0}^T \alpha_i t^i + \sum_{i=1}^k \beta_i D_{it} + \sum_{i=1}^{r-1} \gamma_i S_{it} + \sum_{j=1}^p \phi_j Y_{t-j} + \varepsilon_t . \quad (3.7)$$

Praktyczne zastosowanie tego podejścia wymaga, aby reszty  $u_t$  charakteryzowały się stacjonarnością. Brak stacjonarności objawia się m.in. bliskim jedności współczynnikiem  $\phi_1$  w modelu autoregresji rzędu pierwszego. Oznacza to, że odchylenia od długookresowego trendu nie mają tendencji do zanikania. W takim przypadku równanie 3.7 można oprzeć na danych różnicowanych lub zastosować modele klasy ARIMA.

W modelach dynamicznych należy zdecydować o liczbie opóźnień  $p$  oraz ewentualnym zredukowaniu liczby zmiennych zero-jedynkowych. Można tego dokonać z wykorzystaniem metody regresji krokowej wstecz. Polega ona na tym, że najpierw szacuje się model ze wszystkimi potencjalnymi zmiennymi i ich opóźnieniami, a następnie pojedynczo (po kolejnych estymacjach) usuwa się zmienne statystycznie nieistotne.

### 3.3.2. Modele ARIMA i regARIMA

Modele klasy ARIMA stanowią szeroką klasę stacjonarnych i niestacjonarnych procesów autoregresji i średniej ruchomej. Zakłada się, że szereg czasowy jest realizacją procesu stochastycznego  $\{Y_t\}$ , który z kolei jest sekwencją zmiennych losowych ( $Y_t$ ) indeksowanych przez czas ( $t$ ) [Osińska (red.) 2007]. Wyróżnić można następujące modele tej klasy, biorąc pod uwagę stacjonarność i obecność składnika sezonowego:

1. Model ARMA(p,q),
2. Model ARIMA(p,d,q),
3. Model SARMA(p,q)(P,Q)s,
4. Model SARIMA(p,d,q)(P,D,Q)s,

gdzie:

$p$  i  $q$  – to niesezonowy rząd odpowiednio autoregresji i średniej ruchomej,

$P$  i  $Q$  – to sezonowy rząd odpowiednio autoregresji i średniej ruchomej,

$d$  i  $D$  – to krotność różnicowania odpowiednio: niesezonowego i sezonowego.

Modele 1. i 3. stosujemy wówczas, gdy mamy do czynienia z szeregami stacjonarnymi, a modele 2. i 4. dla zjawisk niestacjonarnych (zintegrowanych). Na stopień integracji wskazują parametry  $d$  i  $D$ . Decydując się na różnicowanie zakłada się, że zarówno trend, jak i sezonowość mają charakter stochastyczny (losowo zmieniający się w czasie), a nie deterministyczny

(stały). Modele 1. i 2. wykorzystywane są do prognozowania zjawisk niesezonowych, z kolei model 3. i 4. służą prognozowaniu zjawisk z wahaniami sezonowymi. Zasadniczo, we wszystkich modelach prognoza jest funkcją przeszłych obserwacji i przeszłych błędów prognoz.

Z uwagi na to, że pierwsze trzy modele są „zagnieżdżone” (zawierają się w modelu czwartym, omówimy tutaj jedynie model SARIMA(p,d,q)(P,D,Q)<sub>s</sub>). Wygodnym sposobem zapisu modelu jest wykorzystanie operatorów przesunięcia wstecz oraz operatorów różnicowania. Szereg czasowy zróżnicowany z krokiem sezonowym i niesezonowym zapiszemy jako iloczyn dwóch operatorów  $(1-B)^d(1-B^S)^D Y_t$ . Stanowi on podstawę do ustalenia opóźnień autoregresyjnych i opóźnień średniej ruchomej (sezonowych i niesezonowych). Stąd ogólny zapis modelu SARIMA(p,d,q)(P,D,Q)<sub>s</sub> będzie następujący [Box, Jenkins 1983, Tsay 2010]:

$$\phi(B)\Phi(B^S)(1-B)^d(1-B^S)^D Y_t = \phi_0 + \theta(B)\Theta(B^S)\varepsilon_t, \quad (3.8)$$

gdzie:

$\phi_0$  – wyraz wolny (przy dwóch różnicowaniach modele te są bez stałej),

$\phi(B)$ ,  $\theta(B)$  – niesezonowe operatory przesunięcia odpowiednio: autoregresji i średniej ruchomej,

$\Phi(B^S)$ ,  $\Theta(B^S)$  – sezonowe operatory przesunięcia odpowiednio: autoregresji i średniej ruchomej.

W szeregach czasowych cen rolno-żywnościowych często dochodzi do zmian strukturalnych, stąd też modele te można rozbudować o dodatkowe regresory, otrzymując model regARIMA<sup>14</sup>. Model 3.8 może być rozszerzony o dodatkowe zmienne deterministyczne celem uchwycenia zmian strukturalnych, wartości odstających czy efektów kalendarzowych. Dokonuje się tego przede wszystkim po to, aby dokonać linearyzacji szeregów czasowych. Automatyczne procedury regARIMA wbudowane są w metody: X-12-ARIMA oraz TRAMO-SEATS. Stanowi to wstępny etap modelowania przed dokonaniem właściwej dekompozycji (por. rozdz. 3.2.1).

Jeżeli przyjmiemy oryginalny szereg czasowy jako punkt wyjścia, wówczas jego poziom zapiszemy jako [Findley i in. 1998, X-12-ARIMA ... 2011]:

$$Y_t = \sum_i \beta_i X_{i,t} + Z_t, \quad (3.9)$$

gdzie:  $\beta_i$  – parametr stojący przy  $i$ -tej zmiennej objaśniającej  $X_{i,t}$ ,  $Z_t$  to reszty modelu szacowane za pomocą modelu SARIMA(p,d,q)(P,D,Q)<sub>s</sub> danego równa-

<sup>14</sup> Inna nazwa stosowana do opisu tych modeli to ARIMAX.

niem 3.8. Po podstawieniu modelu 3.9 do 3.8, model regARIMA można zapisać następująco [X-12-ARIMA ... 2011]:

$$\phi(B)\Phi(B^S)(1-B)^d(1-B^S)^D\left(Y_t - \sum_i \beta_i X_{i,t}\right) = \phi_0 + \theta(B)\Theta(B^S)\varepsilon_t. \quad (3.10)$$

Do regresorów regresji liniowej zalicza się przede wszystkim stałą, zmienne odpowiadające obserwacjom nietypowym (zdarzenia jednorazowe, permanentne/skokowe, przejściowe, rozłożone w czasie mające niesezonowy charakter lub związane z efektami sezonowymi), sezonowe zmienne zero-jedynkowe oraz efekty kalendarzowe (szczegółowy opis tych zmiennych – zob. w Hamulczuk red. [2011]). Obserwacje nietypowe, których wystąpienia w przypadku szeregow wskaźników cen można spodziewać się najczęściej, to zdarzenia jednorazowe mające wpływ na szereg wyłącznie w jednym okresie (zapisane jako AO – ang. *additive outlier*) i zdarzenia, których wpływ po momencie wystąpienia jest wygasający w czasie (TC – ang. *transitory change*, zmiana przejściowa). Do zdarzeń, które również mogą wystąpić, ale ze względu na ich charakter są mniej oczekiwane w przypadku naszego zbioru danych, należą trwała, jednorazowa zmiana poziomu (LS, ang. *level shift*, przesunięcie poziomu) oraz trwała zmiana poziomu czynnika sezonowego (SO, ang. *seasonal outlier*).

Wykorzystanie modeli ARIMA i regARIMA w praktyce wymaga przejścia 3 faz: identyfikacji modelu, jego estymacji i walidacji oraz jego aplikacji (prognozowanie). Sam dobór modelu (identyfikacja) zmierza do określenia zbioru regresorów włączonych do modelu oraz krotności różnicowań opóźnień części autoregresyjnej i średniej ruchomej. W praktyce dokonuje się tego najczęściej w sposób automatyczny w programach komputerowych z wykorzystaniem odpowiednich algorytmów (np. metoda TRAMO) lub w oparciu o kryteria informacyjne modelu (m. in. AIC, BIC) [Lütkepohl, Krätzig 2007]. Należy zwrócić uwagę, że istnieje wiele alternatywnych specyfikacji modeli dla tego samego zjawiska. Panuje przekonanie, że modele oszczędne (z niewielką liczbą opóźnień) generują dokładniejsze prognozy niż modele rozbudowane.

### 3.3.3. Metody i modele wygładzania wykładniczego

#### Metody wygładzania wykładniczego

Alternatywą dla ekonometrycznych modeli szeregów czasowych są metody adaptacyjne, wśród których najważniejszą rolę pełnią metody wygładzania wykładniczego. Brak jest w nich założeń co do postaci analitycznej mechanizmu opisującego zjawisko, zaś parametry modeli dostosowują się do zmian w czasie. Metody wygładzania wykładniczego można klasyfikować z uwagi na właściwości trendu oraz charakter wahań sezonowych (brak (N),

addytywny (A) i multiplikatywny (M)), co zawarto w postaci dwuwymiarowej klasyfikacji Pegela. W ostatnich latach rozbudowano te modele o czynnik tłumiący trend (*damping factor*), które oznaczono dla trendu addytywnego i multiplikatywnego odpowiednio jako:  $A_d$  oraz  $M_d$  [Ord, Fildes 2013]. Przegląd metod wygładzania wykładniczego wg zmodyfikowanej klasyfikacji Pegela zawarto w tabeli 3.1.

Metody wygładzania wykładniczego, bazując na rekursywnych algorytmach, pozwalają na obliczenie tylko prognoz punktowych. Nie przyjmuje się w nich założenia co do mechanizmu generującego dane. Prognoza jest po prostu ważoną (wykładniczo) średnią z przeszłych obserwacji. Aby wyznaczyć prognozę dokonuje się wygładzania danych, przez co uzyskuje się takie komponenty jak: poziom zjawiska w czasie  $t$  ( $l_t$ ), szacunek zmian trendu w czasie  $t$  ( $b_t$ ), szacunek sezonowości w czasie  $t$  ( $s_t$ ) przy  $m$ -liczbie sezonów w roku. Do wygładzania danych (poszczególnych komponentów) należy przyjąć wartości stałych wygładzania z przedziału  $(0;1)$ :  $\alpha$  – do wygładzania poziomu zjawiska,  $\beta^*$  – do wygładzania zmian trendu,  $\gamma$  – do wahań sezonowych.

Dodatkowo w analizowanych modelach występuje jeszcze czwarta stała  $\phi$  służąca do tłumienia trendu z przedziału  $(0;1)$ . Jej włączenie wynika z faktu, że nie zawsze poprawne jest założenie, że ostatni szacunek trendu będzie odpowiedni przy prognozowaniu na dalsze okresy. Jeżeli przyjmuje ona wartości niższe od 1, wówczas wraz z horyzontem prognozowania następuje sukcesywne obniżanie tempa trendu. Im niższa wartość  $\phi$ , tym trend jest wygaszany szybciej. Najbardziej znane spośród metod zaprezentowanych w tabeli 3.1 to metoda Browna rzędu pierwszego (N,N), metoda Holta (A,N) oraz addytywna (A,A) i multiplikatywna (A,M) metoda Holta-Wintersa. Praktyczne obliczenie prognoz na podstawie modelu Holta wymaga przyjęcia wartości startowych (szerzej na ten temat traktuje praca: [Ord, Fildes 2013]).

Tabela 3.1. Specyfikacja metod wygładzania wykładniczego

Trend	Sezonowość		
	N	A	M
<b>N</b>	$\ell_t = \alpha y_t + (1 - \alpha) y_{t-1}$ $\hat{y}_{t+h t} = \ell_t$	$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)\ell_{t-1}$ $s_t = \gamma(y_t / \ell_{t-1}) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t + s_{t-m+h_m^+}$	$\ell_t = \alpha(y_t / s_{t-m}) + (1 - \alpha)\ell_{t-1}$ $s_t = \gamma(y_t / \ell_{t-1}) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t s_{t-m+h_m^+}$
<b>A</b>	$\ell_t = \alpha y_t + (1 - \alpha)(\ell_{t-1} + b_{t-1})$ $b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}$ $\hat{y}_{t+h t} = \ell_t + hb_t$	$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1})$ $b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}$ $s_t = \gamma(y_t - \ell_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t + hb_t = s_{t-m+h_m^+}$	$\ell_t = \alpha(y_t / s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1})$ $b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}$ $s_t = \gamma(y_t / (\ell_{t-1} + b_{t-1})) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = (\ell_t + hb_t) s_{t-m+h_m^+}$
<b>A<sub>d</sub></b>	$\ell_t = \alpha y_t + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1})$ $b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1}$ $\hat{y}_{t+h t} = \ell_t + \phi_h b_t$	$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1})$ $b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1}$ $s_t = \gamma(y_t - \ell_{t-1} - \phi b_{t-1}) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t + \phi_h b_t = s_{t-m+h_m^+}$	$\ell_t = \alpha(y_t / s_{t-m}) + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1})$ $b_t = \beta^*(\ell_t / \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1}$ $s_t = \gamma(y_t / (\ell_{t-1} + \phi b_{t-1})) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = (\ell_t + \phi_h b_t) s_{t-m+h_m^+}$
<b>M</b>	$\ell_t = \alpha y_t + (1 - \alpha)\ell_{t-1} b_{t-1}$ $b_t = \beta^*(\ell_t / \ell_{t-1}) + (1 - \beta^*)b_{t-1}$ $\hat{y}_{t+h t} = \ell_t b_t^h$	$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)\ell_{t-1} b_{t-1}$ $b_t = \beta^*(\ell_t / \ell_{t-1}) + (1 - \beta^*)b_{t-1}$ $s_t = \gamma(y_t - \ell_{t-1} b_{t-1}) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t b_t^h + s_{t-m+h_m^+}$	$\ell_t = \alpha(y_t / s_{t-m}) + (1 - \alpha)\ell_{t-1} b_{t-1}$ $b_t = \beta^*(\ell_t / \ell_{t-1}) + (1 - \beta^*)b_{t-1}$ $s_t = \gamma(y_t / (\ell_{t-1} b_{t-1})) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t b_t^h s_{t-m+h_m^+}$
<b>M<sub>d</sub></b>	$\ell_t = \alpha y_t + (1 - \alpha)\ell_{t-1} b_{t-1}^\phi$ $b_t = \beta^*(\ell_t / \ell_{t-1}) + (1 - \beta^*)b_{t-1}^\phi$ $\hat{y}_{t+h t} = \ell_t b_t^{\phi h}$	$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)\ell_{t-1} b_{t-1}^\phi$ $b_t = \beta^*(\ell_t / \ell_{t-1}) + (1 - \beta^*)b_{t-1}^\phi$ $s_t = \gamma(y_t - \ell_{t-1} b_{t-1}^\phi) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t b_t^{\phi h} + s_{t-m+h_m^+}$	$\ell_t = \alpha(y_t / s_{t-m}) + (1 - \alpha)\ell_{t-1} b_{t-1}^\phi$ $b_t = \beta^*(\ell_t / \ell_{t-1}) + (1 - \beta^*)b_{t-1}^\phi$ $s_t = \gamma(y_t / (\ell_{t-1} b_{t-1}^\phi)) + (1 - \gamma)s_{t-m}$ $\hat{y}_{t+h t} = \ell_t b_t^{\phi h} s_{t-m+h_m^+}$

Źródło: Hyndman i inni [2008].

## Modele wygładzania wykładniczego ETS

W niniejszym podrozdziale dokonujemy rozróżnienia na „metodę” i „model”. Wygładzanie wykładnicze jest prostą adaptacyjną metodą prognozowania, która sama w sobie nie zakłada, że dany szereg czasowy jest realizacją procesu stochastycznego. Jest ona algorytmem przekształcania danych w celu uzyskania prognozy punktowej, niepozwalającym jednak na dyskutowanie stochastycznej natury szeregu i np. wynikającej z niej niepewności prognozy. Dopiero ujęcie metod wygładzania wykładniczego w ramach klasy modeli przestrzeni stanów ETS (Error, Trend, Seasonality), opracowane przez Ord i.in. [1997] i Hyndman i.in. [2002], umożliwia przedstawienie szeregów w postaci procesów stochastycznych. Założenie stochastycznej postaci modelu umożliwia odczytanie zarówno prognozy punktowej, jak i przedziałów ufności. W modelach ETS istnieje również możliwość obliczania wartości funkcji wiarygodności i zaimplementowanie procedur wyboru najlepszego modelu na podstawie jednego z kryteriów informacyjnych.

Liczba modeli przedstawionych w tabeli 3.1, którymi można opisać różne kombinacje poszczególnych komponentów wynosi 15. W ramach metodyki ETS, uwzględnienie w modelach czynnika stochastycznego, który może być addytywnie lub multiplikatywnie powiązany z pozostałymi komponentami, zwiększa do 30 liczbę modeli, które można rozważać jako punkt wyjścia do prognozowania.

Modele przestrzeni stanów (*state space models*) charakteryzują się znaczącą elastycznością. Przyjmując, że  $y_t$  jest obserwacją w czasie  $t$ , zaś  $\mathbf{x}_t$  to wektor stanu zawierający nieobserwowalne komponenty  $\mathbf{x}_t = (l_t, b_t, s_t, s_{t-1}, \dots, s_{t-m+1})$ , które opisują poziom, trend, sezonowość, równania modeli przestrzeni stanu można ująć następująco:

$$y_t = w(\mathbf{x}_{t-1}) + r(\mathbf{x}_{t-1})\varepsilon_t \quad (3.11)$$

$$\mathbf{x}_t = \mathbf{f}(\mathbf{x}_{t-1}) + \mathbf{g}(\mathbf{x}_{t-1})\varepsilon_t \quad (3.12)$$

gdzie  $w(\cdot)$  oraz  $r(\cdot)$  to skalary, zaś  $\mathbf{f}(\cdot)$  oraz  $\mathbf{g}(\cdot)$  to wektory, a  $\{\varepsilon_t\}$  jest procesem o właściwościach białoszumowych z wariancją  $\sigma^2$  oraz wartością oczekiwaną  $\mu_t = w_t(\mathbf{x}_{t-1})$ . W obydwu równaniach zakłada się identyczny rodzaj błędu (innowacji), stąd przyjmuje się, że model ten ma charakter „innowacyjny” lub inaczej, że jest to model o jednym wspólnym źródle błędów<sup>15</sup>. W modelu

---

<sup>15</sup> Modele takie noszą również w literaturze nazwę SSOE (*single source of error*). Inną grupą modeli przestrzeni stanów są modele opisane skrótem MSOE (*multiple source of error*) do których należą np. modele strukturalne rozwinięte przez Harveya [1989].



z błędami addytywnymi przyjmujemy że,  $r(x_{t-1})=1$ , stąd  $y_t = \mu_t + \varepsilon_t$ . Z kolei w modelu z błędami multiplikatywnymi  $r(x_{t-1})=\mu_t$ , stąd w konsekwencji  $y_t = \mu_t(1 + \varepsilon_t)$  [Hyndman i.in. 2008].

**Tabela 3.2. Specyfikacja modeli ETS dla addytywnych błędów**

Trend	Sezonowość		
	N	A	M
N	$\mu_t = \ell_{t-1}$ $\ell_t = \ell_{t-1} + \alpha\varepsilon_t$	$\mu_t = \ell_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + \alpha\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = \ell_{t-1}s_{t-m}$ $\ell_t = \ell_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t / \ell_{t-1}$
A	$\mu_t = \ell_{t-1} + b_{t-1}$ $\ell_t = \ell_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t$	$\mu_t = \ell_{t-1} + b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = (\ell_{t-1} + b_{t-1})s_{t-m}$ $\ell_t = \ell_{t-1} + b_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $b_t = b_{t-1} + \beta\varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t / (\ell_{t-1} + b_{t-1})$
A <sub>d</sub>	$\mu_t = \ell_{t-1} + \phi b_{t-1}$ $\ell_t = \ell_{t-1} + \phi b_{t-1} + \alpha\varepsilon_t$ $b_t = \phi b_{t-1} + \beta\varepsilon_t$	$\mu_t = \ell_{t-1} + \phi b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + \phi b_{t-1} + \alpha\varepsilon_t$ $b_t = \phi b_{t-1} + \beta\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = (\ell_{t-1} + \phi b_{t-1})s_{t-m}$ $\ell_t = \ell_{t-1} + \phi b_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $b_t = \phi b_{t-1} + \beta\varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t / (\ell_{t-1} + \phi b_{t-1})$
M	$\mu_t = \ell_{t-1}b_{t-1}$ $\ell_t = \ell_{t-1}b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t / \ell_{t-1}$	$\mu_t = \ell_{t-1}b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t / \ell_{t-1}$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = \ell_{t-1}b_{t-1}s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $b_t = b_{t-1}\beta\varepsilon_t / (s_{t-m}\ell_{t-1})$ $s_t = s_{t-m} + \gamma\varepsilon_t / (\ell_{t-1}b_{t-1})$
M <sub>d</sub>	$\mu_t = \ell_{t-1}b_{t-1}^\phi$ $\ell_t = \ell_{t-1}b_{t-1}^\phi + \alpha\varepsilon_t$ $b_t = b_{t-1}^\phi + \beta\varepsilon_t / \ell_{t-1}$	$\mu_t = \ell_{t-1}b_{t-1}^\phi + s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1}^\phi + \alpha\varepsilon_t$ $b_t = b_{t-1}^\phi + \beta\varepsilon_t / \ell_{t-1}$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = \ell_{t-1}b_{t-1}^\phi / s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1}^\phi + \alpha\varepsilon_t / s_{t-m}$ $b_t = b_{t-1}^\phi + \beta\varepsilon_t / (s_{t-m}\ell_{t-1})$ $s_t = s_{t-m} + \gamma\varepsilon_t / (\ell_{t-1}b_{t-1}^\phi)$

gdzie:  $\mu_t, \ell_t, b_t, s_t, \varepsilon_t$  – to kolejno: wartość oczekiwana (prognoza), poziom trendu, zmiana kierunku trendu, sezonowość, błąd; natomiast  $\alpha, \beta, \gamma, \phi$  to parametry modelu.

Źródło: Hyndman i inni [2008].

W tabeli 3.2 przedstawiono wzory określające 15 specyfikacji modeli ETS, przy założeniu addytywnych błędów. Zapis jest analogiczny do modeli przedstawionych w tabeli 3.1. Dla uproszczenia przyjęto, że  $\beta = \alpha\beta^*$ . Modele multiplikatywne mają formę podobną, przy czym przyjmuje się, o czym napisano wyżej, że  $\varepsilon_t$  jest zastępowane przez  $\mu_t\varepsilon_t$ . Prognozy punktowe stanowią

warunkową wartość oczekiwaną w poszczególnych modelach przestrzeni stanu, co można zapisać  $\mu_{t+h|t} = E(y_{t+h}|x_t)$ . Zakłada się przy tym zerową wartość błędu.

Oprócz określenia charakteru trendu i sezonowości, notacja charakteryzująca modele ETS zawiera też informację o typie błędu (A – addytywny, M – multiplikatywny). Przykładowo, notacja ETS (A,A,N) oznacza specyfikację kolejno: addytywny błąd, addytywny trend, brak sezonowości. Innymi słowy, jest to zwykły model Holta (z addytywnym błędem). Z kolei zapis ETS (A,A<sub>d</sub>,A) oznacza, że mamy do czynienia z addytywnym modelem Holta-Wintersa z czynnikiem tłumiącym trend (i z addytywnym błędem).

Na chwilę obecną modele ETS są zaimplementowane w programie R czy wykorzystanym w niniejszej pracy pakiecie statystycznym EViews 8. Estymacja modeli ETS obejmuje dobór odpowiednich parametrów  $\alpha$ ,  $\beta$ ,  $\gamma$ ,  $\phi$  oraz wartości początkowych. Podobnie jak w metodach wykładniczego, wszystkie parametry powinny należeć do przedziału (0;1). Aby zagwarantować stabilność modelu, nakłada się dodatkowe restrykcje na parametry:  $0 \leq \beta \leq \alpha$  oraz  $0 \leq \gamma \leq (1 - \alpha)$ . Estymacja parametrów przeprowadzana jest z wykorzystaniem metody największej wiarygodności. Wyboru najlepszego modelu można dokonać na podstawie jednego z kryteriów informacyjnych.

### 3.4. Metody prognozowania uwzględniające interakcje z innymi zmiennymi

Drugi rodzaj modeli stosowanych do prognozowania to modele, w których stan pewnych zmiennych zależy od innych zmiennych. Z uwagi, że modele statyczne rzadko dają zadowalające rezultaty przy objaśnianiu i prognozowaniu zjawisk zachodzących w czasie, często rozbudowuje się je do postaci dynamicznej. Dynamizacja modelu ekonometrycznego wiąże się z włączeniem do zmiennych objaśniających: zmiennej czasowej, opóźnionych wartości zmiennej endogenicznej czy zmiennych odpowiedzialnych za wahania sezonowe.

#### 3.4.1. Modele jednorównaniowe

##### Modele ARDL i ECM

Modele, w których występują zarówno bieżące, jak i opóźnione wartości zmiennej objaśnianej oraz opóźnione wartości zmiennej objaśniającej, nazywane są autoregresyjnymi modelami o rozłożonych opóźnieniach ARDL (*autoregressive distributed lag*). Model  $ARDL(p,q)$  można zapisać w postaci równania

3.13 (zauważymy, że jest to model 3.7 rozszerzony o dodatkowe zmienne egzogeniczne X):

$$y_t = \mu + \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{j=0}^k \sum_{i=0}^q \beta_{ij} X_{j,t-i} + \varepsilon_t, \quad (3.13)$$

gdzie:

$\mu$  – deterministyczna część równania obejmująca wyraz wolny, trend, sezonowość i inne zmienne dla uchwycenia wartości nietypowych,

$Y_t, X_{ij}$  – odpowiednio zmienna objaśniana i zmienne objaśniające,

$\alpha_i, \beta_{ij}$  – parametry strukturalne modelu,

$\varepsilon_t$  – reszty modelu,

$k$  – liczba zmiennych objaśniających,

$q$  – rząd opóźnienia.

Wykorzystanie modeli *ARDL* w prognozowaniu wymaga: specyfikacji modelu, estymacji jego parametrów, interpretacji wyników oraz wykorzystania ich w prognozowaniu. Problemy związane ze specyfikacją modeli dynamicznych dotyczą dwóch zagadnień: potencjalnego występowania regresji pozornej oraz kwestii ustalenia rzędu opóźnień, tak dla zmiennych objaśniających, jak i dla zmiennej objaśnianej.

Rząd opóźnień zależy od charakterystyki szeregów czasowych wykorzystanych w budowie modelu. Wyboru rzędu opóźnienia można dokonać, stosując dwa rozwiązania. Pierwszym jest wykorzystanie wspomnianych już powyżej kryteriów informacyjnych, które określają stopień utraty informacji związany z przyjęciem danego rzędu opóźnienia. Niezależnie od tego, które z kryteriów informacyjnych zostanie przyjęte, przyjmuje się ten rząd opóźnienia, dla którego wartość kryterium informacyjnego jest najmniejsza<sup>16</sup>. Drugie rozwiązanie jest mniej sformalizowane, a bardziej intuicyjne – budując model *ARDL* zwiększa się rząd opóźnień dotąd, aż nie doprowadzi się do wyeliminowania autokorelacji w resztach modelu.

Jeżeli zmienne są niestacjonarne w wariancji to istnieje ryzyko wystąpienia regresji pozornych. W takiej sytuacji model może być oparty na przyrostach (najczęściej pierwszych) zmiennych. Ma on wówczas postać:

$$\Delta Y_t = \mu + \sum_{i=1}^p \alpha_i \Delta Y_{t-i} + \sum_{j=0}^k \sum_{i=0}^q \Delta \beta_{ij} X_{j,t-i} + \varepsilon_t, \quad (3.14)$$

gdzie: oznaczenia jak w 3.13.

<sup>16</sup> Więcej na temat kryteriów informacyjnych i ich stosowania pisze Osińska [2005, s. 54-55].

Bazowanie na pierwszych przyrostach jest zasadne wówczas, jeśli stwierdzony zostanie brak skointegrowania zmiennych. W przypadku, gdy występują zależności długookresowe lepszym rozwiązaniem jest rozbudowa tego modelu o czynnik korekty błędem (por. równanie 3.4). Nosi on nazwę modelu korekty błędem i posiada formę [Engle, Granger 1987]:

$$\Delta Y_t = \mu + \sum_{i=1}^p \alpha_i \Delta Y_{t-i} + \sum_{j=0}^k \sum_{i=0}^q \beta_{ij} \Delta X_{j,t-i} + \gamma ECT_{t-1} + \varepsilon_t, \quad (3.15)$$

gdzie:

$ECT_{t-1}$  – element korekty błędem pochodzący z równania  $ECT_{t-1} = Y_{t-1} - \sum_{j=1}^k \theta_j X_j$ ,

gdzie  $\theta_j$  to parametry długookresowe,

$\gamma$  – współczynnik mierzący szybkość konwergencji do ścieżki równowagi długookresowej, pozostałe oznaczenia jak w 3.13.

### Modelowanie zgodne

Dynamiczny zgodny model przyczynowo-skutkowy uwzględnia informacje o wewnętrznej strukturze badanych procesów objaśnianych i objaśniających (trend, sezonowość, autoregresja), tak aby proces resztowy miał własności białego szumu [Zieliński 1991].

Modelowanie zgodne jest koncepcją specyfikacji modeli dynamicznych danych równaniami 3.13-3.15. Sam proces doboru poszczególnych komponentów i opóźnień, tzw. specyfikacja dynamicznego modelu zgodnego, obejmuje pięć etapów [Kufel 2004, Osińska (red.) 2007]. W pierwszym kroku następuje badanie wewnętrznej struktury procesu endogenicznego i procesów egzogenicznych. Zmierzają to na początku do określenia charakteru trendu i jego wyodrębnienia oraz stwierdzenia, czy mamy do czynienia z wahaniami sezonowymi a następnie wyodrębnienia składnika sezonowego. Na podstawie danych bez trendu i bez sezonowości następuje ustalenie rzędów opóźnień poszczególnych procesów wynikających z ich struktury autoregresyjnej.

W drugim kroku ma miejsce specyfikacja ogólnego modelu zawierającego maksymalny stopień wielomianu trendu, sezonowość oraz maksymalny rząd autoregresji dla każdego procesu. Problem polega na tym, że możemy zastosować zasadniczo trzy rodzaje modeli w zależności od właściwości szeregów czasowych (3.13-3.15). Stąd pojawia się pytanie, który model wybrać. Niemniej jednak, jak wskazuje Piłatowska [2005], modele dla poziomów i modele dla przyrostów procesów (w tym modele korekty błędem) mogą ze sobą konkurować nawet w sytuacji błędnej identyfikacji procesów niestacjonarnych

w średniej czy w wariancji, o ile modele te realizują postulat zgodności. Należy podkreślić, że stosując podejście „zawsze brać poziomy” należy zwiększyć o jeden liczbę opóźnień autoregresyjnych dla zmiennych niestacjonarnych (zintegrowanych w stopniu 1).

W kroku trzecim dokonuje się oszacowania postaci pierwotnej modelu zgodnego uwzględniającej wszystkie wyspecyfikowane składniki. W czwartym etapie ma miejsce weryfikacja modelu na podstawie badania istotności zmiennych (metoda regresji krokowej do tyłu) oraz własności reszt. Ostatni etap to interpretacja ocen parametrów strukturalnych oraz ocena dopasowania modelu do danych.

Obok procedury Zielińskiego opisanej wyżej, najbardziej znane podejście to procedura LSE (*London Economic School*). Znana jest szerzej pod nazwą *Gets* (*general-to-specific*). Ma ona charakter jeszcze bardziej formalny i wiąże się z zastosowaniem szeregu reguł na każdym z pięciu etapów [Hendry 2005]. Obecnie można ją znaleźć w procedurze *Autometrics* w oprogramowaniu *PcGive*. Więcej informacji na ten temat można znaleźć w pracach: [Hendry, Krolzig 2005; Castle i in. 2013; Hendry, Pretis 2012].

Wyznaczenie prognozy w tym przypadku, podobnie jak w zdecydowanej większości metod ze zmiennymi objaśniającymi, wymaga znajomości procesów (zmiennych) objaśniających w okresie prognozowanym. Pewnym rozwiązaniem może być włączenie zmiennych o charakterze wyprzedzającym. Wówczas prognoza może być wykonana bez dodatkowych obliczeń lub założeń na okres równy wielkości wyprzedzenia. W pozostałych przypadkach należy przyjąć lub prognozować zmienne objaśniające, np. na podstawie jednorównaniowych modeli szeregów czasowych.

### 3.4.2. Modele VAR i VECM

Modele przedstawione do tej pory nie uwzględniały faktu, że zmienne wpływają na siebie wzajemnie (dwukierunkowe zależności). Aby ująć współzależności między zmiennymi można zastosować modele VAR (*Vector Autoregressive*) opracowane przez Simsa [1980], stanowiące alternatywę dla klasycznego modelu wielorównaniowego o równaniach współzależnych. Wektorowy model autoregresyjny (VAR) zawiera zestaw regresji każdej ze zmiennych prognozowanych (nieopóźnionych) względem pewnej liczby opóźnień wszystkich zmiennych wchodzących w jego skład. Można to zapisać w postaci wzoru [Kusideł 2000]:

$$Y_t = A_0 D_t + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + e_t, \quad (3.16)$$

gdzie:  $Y_t$  jest wektorem obserwacji na bieżących wartościach wszystkich  $n$  zmiennych,  $D$  jest wektorem deterministycznych składników (wyraz wolny, zmienna czasowa, zmienne sezonowe zero-jedynkowe),  $A_0, A_1, \dots, A_p$  to wektory parametrów modelu,  $e_t$  to wektor stacjonarnych zakłóceń losowych, zaś  $p$  to optymalne opóźnienie w modelu VAR.

W modelu tym prognoza dowolnej zmiennej zależy od poprzednich  $p$  wartości tej zmiennej i pozostałych zmiennych. Zaletą tego podejścia jest brak konieczności prognozowania zmiennych objaśniających. Rząd opóźnienia  $p$  powinien być dobrany tak, aby odzwierciedlał naturalne zależności oraz aby wyeliminowana została autokorelacja reszt modelu.

Model VAR znajduje zastosowanie w przypadku zmiennych stacjonarnych (i trendostacjonarnych). Jeżeli zmienne nie są stacjonarne, należy je doprowadzić do stacjonarności poprzez operację różnicowania. Jeżeli jednak między zmiennymi występuje zależność kointegracyjna wyznaczająca równowagę długookresową, to wówczas stosuje się modele VECM (*Vector Error Correction Models*). Model wektorowej korekty błędem (VECM) stanowi transformację modelu VAR do postaci danej wzorem [Kusideł 2000, Tsay 2010]:

$$\Delta Y_t = A_0 D_t + \Pi Y_{t-1} + \Gamma_1 \Delta Y_{t-1} + \dots + \Gamma_{p-1} Y_{t-p+1} + e_t \quad (3.17)$$

gdzie:  $\Pi = -(\mathbf{I}_K - A_1 - \dots - A_p)$ , jest macierzą, którą można zdekomponować na: macierz parametrów zawierających efekty długookresowe (wektory kointegracyjne) i macierz szybkości dostosowań zmiennych do relacji długookresowej;  $\Gamma_i = -(A_{i+1} + \dots + A_p)$  jest macierzą parametrów krótkookresowych;  $i = 1, \dots, p-1$ .

Prognoza uzyskiwana na podstawie modelu VECM jest efektem zależności długo- i krótkookresowych między zmiennymi (np. cenami). O ile w krótkich okresach występują odchylenia od równowagi długookresowej, to wraz ze wzrostem horyzontu prognozowania cały układ się stabilizuje.

Model VAR i VECM można rozszerzyć o zmienne egzogeniczne, które wpływają na system, ale nie są w ramach systemu wyjaśniane i prognozowane. Mogą one wchodzić zarówno do relacji kointegrującej, jak i do części krótkookresowej. Jeśli wchodzi do relacji kointegrującej, to noszą nazwę wymuszeń długookresowych. Pozwala to na uwzględnianie innych czynników, np. makroekonomicznych czy światowych w modelu sektorowym. Dodatkowo umożliwia ona zastosowanie tych samych założeń, jeśli jednocześnie wykonujemy prognozy dla wielu zmiennych jednocześnie.

Generalnie, specyfikacja równań modeli VAR i VECM jest dosyć trudna. Główne problemy wiążą się z ustaleniem zestawu zmiennych endogenicznych, składu zmiennych egzogenicznych czy opóźnień wśród zmiennych endo- i egzogenicznych. Pomocne w specyfikacji modelu są kryteria informacyjne

(w szczególności zmodyfikowane o długość próby) oraz testowanie opóźnień i analiza rozkładu składnika losowego. Szerzej na ten temat pisze m.in. Kusideł [2000]. Znaczącym problemem są również zmiany strukturalne, o czym piszą m.in. Joyeux [2007] czy Maddala, Kim [1998].

Modele 3.16 i 3.17 zazwyczaj charakteryzują się powiązaniem między składnikami resztowymi poszczególnych równań. Umożliwia strukturalizację tych modeli, co w dalszej konsekwencji pozwala na poznanie prawidłowości rządzących rynkiem, które mogą być wykorzystywane przy nieformalnym (uwzględniającym opinie ekspertów) prognozowaniu cen. W tym celu wykorzystać można analizę odpowiedzi na impuls oraz dekompozycje wariancji błędów prognoz. Szerzej na ten temat pisze m.in. Enders [2010].

## 4. Empiryczna analiza zmian wybranych cen produktów rolnych i cen detalicznych

Niniejszy rozdział poświęcony zostanie przybliżeniu procesów zachodzących na wybranych rynkach surowców rolnych i rynkach detalicznych żywnościowych produktów wytwarzanych z analizowanych surowców. Badane będą również zależności cenowe występujące pomiędzy tymi rynkami, jak również zmiany rozstępów cenowych. Lepsze zrozumienie mechanizmów odpowiedzialnych za zmiany cen surowców rolnych i detalicznych cen żywności, a także kształtowanie relacji między nimi pozwoli na dobór bardziej odpowiednich metod prognozowania tych cen. To zaś z kolei wpłynie korzystnie na trafność sporządzonych w dalszych częściach pracy prognoz.

Dla większości rynków analizowany okres obejmuje 14 lat od stycznia 1999 roku do grudnia 2013 r. Za każdym razem, gdy dane obejmują inny okres, zostało to wyraźnie zaznaczone na początku podrozdziału.

Każdy z podrozdziałów poświęcony jest jednemu rynkowi. W celu zwiększenia przejrzystości treści, kolejne części rozdziału mają podobną strukturę. Po omówieniu sytuacji popytowo-podażowej na danym rynku prezentowane jest analiza struktury szeregów czasowych cen i rozstępów cenowych. Dekompozycję przeprowadzono używając metody X-12-ARIMA z opcją automatycznej procedury typu RSA3 w programie Demetra+. Procedura ta umożliwia dobór najlepiej pasującego do struktury szeregu czasowego modelu, a także umożliwia wykrycie obserwacji nietypowych. Wyniki dekompozycji prezentowane są na rysunkach składających się z 3-6 wykresów – w zależności od liczby badanych szeregów czasowych i istotności statystycznej składnika sezonowego.

W drugiej części każdego z podrozdziałów analizowane są zmiany wielkości rozstępu cenowego pomiędzy badanymi cenami. Wartość rozstępu cenowego dana jest wzorem (2.3) opisanym w rozdziale 2, gdzie rozstęp cenowy  $R_C$  definiuje się jako iloraz różnicy ceny detalicznej produktu żywnościowego  $C_Z$  i ceny surowca rolnego  $C_R$  do ceny surowca rolnego:  $R_C = (C_Z - C_R) / C_R$ .<sup>17</sup>

Następnie, szeregi czasowe rozstępów cenowych są analizowane w podobny sposób, jak miało to miejsce w przypadku szeregów czasowych cen. Podobnie też przedstawione są wykresy obrazujące przebieg rozstępów, jak i szeregi czasowe będące wynikiem dekompozycji przeprowadzonej za pomocą programu Demetra+.

---

<sup>17</sup> W części empirycznej pracy, czyli w rozdziałach od 4. do 8. symbolem wyróżniającym szeregi czasowe cen detalicznych będzie oznaczenie CR. W przypadku cen zbytu będzie to oznaczenie CZ, dla cen detalicznych – CD, dla rozstępów cenowych – RC



## 4.1. Zboża i produkty zbożowe

W ramach rynku zbóż analizie poddano ceny skupu pszenicy i żyta oraz ceny detaliczne mąki pszennej oraz razowego chleba żytniego. Wybór surowców rolnych podyktowany był przede wszystkim ich dominującym znaczeniem na rynku zbóż w całym analizowanym okresie. Istotne było też to, że te dwa rodzaje zbóż dominują w produkcji produktów żywnościowych<sup>18</sup>. Tłumaczy to chociażby wybór cen żyta, a nie jęczmienia, który wykorzystywany jest przede wszystkim na cele paszowe, pomimo faktu, że wolumen oraz wartość produkcji jęczmienia przewyższa spadający z roku na rok wolumen produkcji żyta. Doboru produktów detalicznych dokonano arbitralnie, kierując się znaczeniem wybranych dóbr oraz dostępnością danych<sup>19</sup>.

Na rysunku 4.1 przedstawiono sześć wykresów. W górnej lewej części zaprezentowano przebieg wyjściowych szeregów czasowych (ceny wybranych surowców rolnych) oraz wartości trendu-cyklu obliczone przy użyciu metodyki X-12-ARIMA. Po prawej stronie przedstawiono podobne wykresy dotyczące cen detalicznych wybranych produktów. W środkowym rzędzie przedstawiono wartości składników sezonowych szeregów cen artykułów rolnych (po lewej) i cen detalicznych (po prawej). W ostatnim rzędzie wykresy przedstawiają wpływ wszystkich poszczególnych obserwacji nietypowych, jakie wykryto na etapie szacowania modelu RegARIMA. Zawarte w tytule oznaczenie MA oznacza, że dekompozycję przeprowadzono wykorzystując model addytywny. MM oznacza wykorzystanie modelu multiplikatywnego. Taki schemat prezentacji graficznej przyjęto także dla danych dotyczących innych rynków.

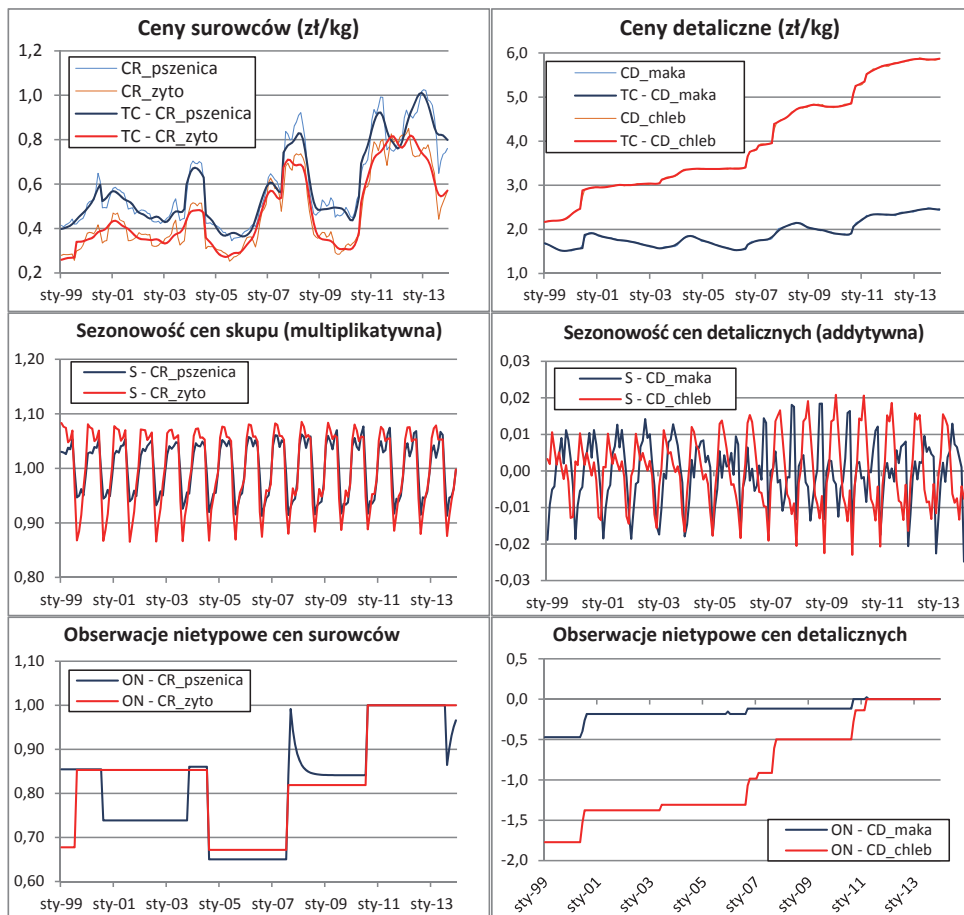
Wszystkie ceny wyrażone są w złotych za kilogram. W wyniku automatycznego doboru struktury modelu, w przypadku szeregów cen detalicznych przyjęty został model addytywny, natomiast dla cen produktów rolnych – model multiplikatywny, co oznacza, że dane wyjściowe zostały zlogarytmowane.

---

<sup>18</sup> Pszenica i żyto stanowiły w latach 2009-2013 ponad 96% zużywanego ziarna na cele spożywcze [Rynek zbóż... 2014].

<sup>19</sup> Choć liczba szeregów czasowych cen produktów detalicznych gromadzonych przez GUS jest znaczna, z uwagi na zmiany metodyki, nie wszystkie z nich obejmują nieprzerwanie analizowane w pracy lata 1999-2013.

**Rysunek 4.1. Dekompozycja szeregu cen pszenicy i żyta (lewa strona - MM) oraz mąki pszennej i chleba żytniego (prawa strona - MA) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

Już wstępna analiza graficzna zmian cen zbóż w latach 1999-2013 pozwala dostrzec wyraźną zbieżność przebiegu cen pszenicy oraz cen żyta (to dotyczy cen surowców). Zauważyć można dodatni trend oraz pewną cykliczność, której wynikiem są kolejne maksima lokalne występujące przeciętnie co 4 lata. Rosnący trend jest wynikiem przede wszystkim światowego wzrostu cen zbóż, wywołanego m.in. takimi czynnikami jak wzrost zużycia zbóż na biopaliwa, niekorzystne warunki pogodowe przy małym stanie zapasów zbóż, czy słaby dolar [Tyner 2010, Abbott i inni 2011]. Trudno natomiast zidentyfikować źródła zauważalnej cykliczności.

Charakter składnika sezonowego w analizowanych 14 latach nie uległ znaczącym zmianom, co oznacza, że przez cały okres maksimum cenowe

przypadało na czerwiec, zaś minimum na sierpień-wrzesień. Jedyłą zauważalną różnicą – w przypadku cen pszenicy – pozostaje zwiększenie amplitudy zmian (0,11 – w 1999 roku; 0,15 – w 2013 roku), co można tłumaczyć oddziaływaniem systemu interwencji w latach przed wstąpieniem Polski do UE<sup>20</sup>.

Pomimo zbieżności przebiegu cen w analizowanym okresie w ramach procedury automatycznej, liczba wykrytych obserwacji nietypowych jest różna. Dla obu szeregów cenowych przeważają jednak zmiany permanentne skokowe. Obserwacje nietypowe odzwierciedlają zmiany sytuacji popytowo-podażowej<sup>21</sup>.

Po prawej stronie rysunku 4.1 przedstawiono analogiczne wykresy do wyżej omówionych, z tym że dotyczące cen detalicznych. Z uwagi na znacznie mniejszą krótkookresową zmienność cen detalicznych, różnice pomiędzy wyjściowym szeregiem czasowym a krzywą przedstawiającą wartości trendu-cyklu są praktycznie niezauważalne. Warto zauważyć, że zróżnicowanie cen detalicznych analizowanych towarów jest znacząco wyższe niż zróżnicowanie cen surowców, z których są one wytwarzane. Wynika to z kilku czynników. Przede wszystkim mamy tu do czynienia z oczywistą różnicą wynikającą z faktu, że mąka stanowi produkt mniej przetworzony niż chleb. Równie istotny pozostaje także fakt, że o ile przebieg cen mąki pszennej może zostać uznany za reprezentatywny dla całego sektora produktów zbożowych, o tyle w przypadku razowego chleba żytniego mamy do czynienia z pewną specyfiką. Wraz ze wzrostem dochodów w społeczeństwie dochodzi do zmian wzorców konsumpcji, skutkiem czego popyt na produkty zbożowe maleje. Nie dotyczy to jednak wybranych produktów, uznawanych za szczególnie zdrowe, do których zalicza się m.in. pieczywo żytnie<sup>22</sup>. W ostatnich latach stosunek cen chleba do cen mąki wzrastał

<sup>20</sup> W 1999 roku wprowadzono w życie system skupu zbóż z dopłatami dla producentów, którego głównym celem było niwelowanie nadmiernego sezonowego zróżnicowania cen zbóż. W ramach prowadzonej interwencji skupowano pszenicę i żyto w okresie od lipca do października. Zgromadzone zapasy zbóż kierowano na rynek dopiero w okresie wiosennym, kiedy to tradycyjnie wartość podaży zbóż obniżała się. Przykładowo w roku 2001 interwencją objęto 3,5 mln ton pszenicy, co stanowiło ponad 38% zbiorów. Agencja Rynku Rolnego prowadziła też okresowo bezpośredni skup po cenach minimalnych [*Rynek zbóż...* 2002].

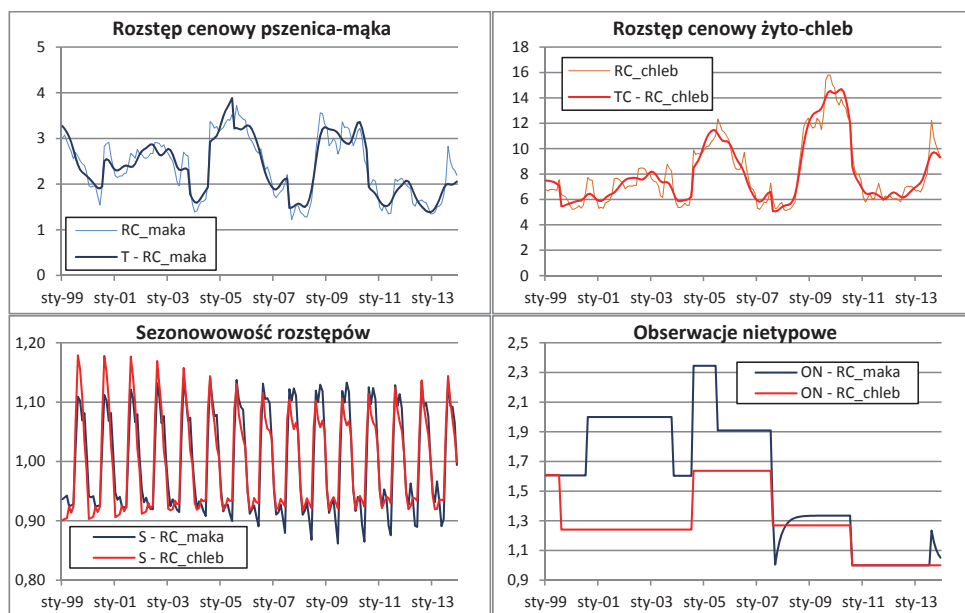
<sup>21</sup> Przykładowo, wzrost cen pszenicy w roku 2000 był następstwem dotkliwej suszy z kwietnia i maja, która obniżyła znacząco podaż zbóż jarych i uprawianych na słabszych glebach. Z kolei znaczący wzrost cen w I połowie 2004 roku to wynik spadku produkcji (o 13%) i wysokich cen na rynku światowym. Spadek cen nastąpił wraz ze wzrostem podaży w roku 2005. Wejście do UE stworzyło całkowicie nowe warunki popytowo-podażowe, w których produkcja krajowa przestała odgrywać kluczową rolę w kształtowaniu się cen zbóż w Polsce. Stąd kolejne drastyczne wzrosty cen krajowych zapoczątkowane pod koniec roku 2007 i 2010 były wynikiem wzrostu cen zbóż na rynku światowym i unijnym.

<sup>22</sup> Przeciętne miesięczne spożycie produktów zbożowych w kg na osobę w roku 1999 wyniosło 9,19 (w tym mąki 1,25), podczas gdy w roku 2012 już tylko 6,56 (w tym mąki 0,81). W tym samym czasie spożycie pieczywa żytniego wzrosło z 0,18 kg na osobę do 0,22 kg [*Popyt na żywność* 2014].

niezależnie od rodzaju chleba. W przypadku cen chleba żytniego proces ten jest szczególnie silny, co widać na prawym górnym wykresie. Jednocześnie przebieg cen obu tych produktów jest uzależniony od wahań na rynkach artykułów rolnych, co zauważyć można porównując przebieg trendów-cykli analizowanych szeregów czasowych.

Zastosowanie opisanych wcześniej automatycznych procedur wskazało, że w przypadku cen detalicznych właściwsze będą modele addytywne, stąd inne niż w przypadku cen surowców rolnych wartości czynnika sezonowego. Wydaje się, że zmiany sezonowe nie należą do szczególnie istotnych w przypadku cen detalicznych. Ich procentowy udział w przypadku cen mąki nie przekracza 3% średniej wartości, dla cen chleba jest jeszcze niższy. Dodatkowo, brak jest stałego wzorca sezonowości.

**Rysunek 4.2. Dekompozycja szeregu rozstępu cenowego pszenicy i mąki pszennej (MM) oraz żyta i chleba żytniego (MM) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

Wykryte obserwacje nietypowe są w dużej części pochodną sytuacji na rynku surowców, przy czym zmiany cen detalicznych występują z opóźnieniem najczęściej 1 miesiąca. Pewna liczba zmian, szczególnie w pierwszej części analizowanego okresu, wynika ze zmian w opodatkowaniu żywności i surowców rolnych (podatek VAT).

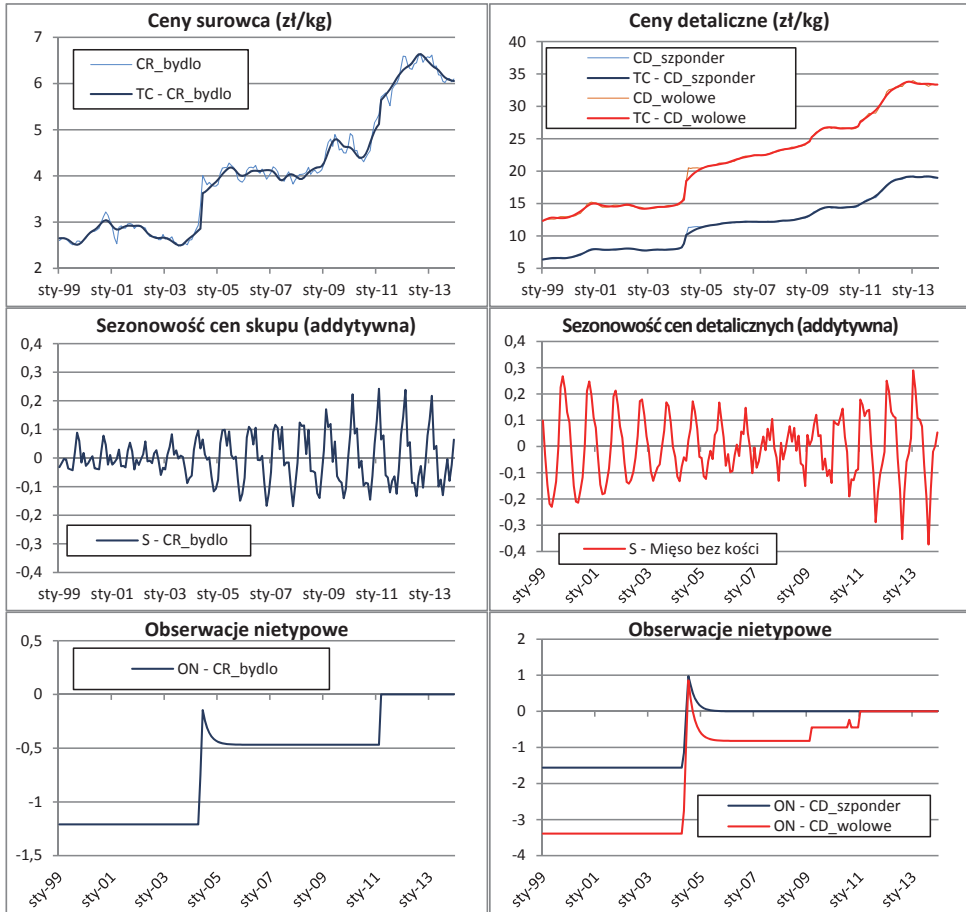
Przedstawiona powyżej skrócowa analiza zmian cen surowców rolnych i detalicznych cen żywności pozwala na wychwycenie źródeł wybranych zmian wielkości rozstępów cenowych pszenica-mąka pszenna oraz żyto-chleb żytni. Analiza graficzna najważniejszych składowych badanych rozstępów cenowych przedstawionych na rysunku 4.2, wskazuje wyraźnie, że zgodnie z oczekiwaniami, na zmiany trendu-cyklu rozstępów cenowych mają wpływ w głównej mierze cykle obserwowane na rynku surowców, co wynika z ich znacznej amplitudy. W okresach nagłych wzrostów cen zbóż (przełom lat 2003/04 oraz lata 2007-08) mamy do czynienia z niższymi wartościami rozstępów cenowych, i *vice versa* spadki cen zbóż skutkują zwiększeniem rozstępów cenowych.

W ramach procedury automatycznej do opisu zmian rozstępów cenowych wybrano model multiplikatywny. Sezonowość analizowanych szeregów czasowych jest determinowana głównie sezonowością cen skupu zbóż, co uwidacznia się maksimum rocznym w sierpniu i wrześniu, czyli w okresie, gdy ceny zbóż osiągają swe roczne minima. Także kształt zagregowanego wpływu obserwacji nietypowych jest w dużej mierze pochodną tego, co obserwowano przy okazji analizy szeregów czasowych cen skupu zbóż. Wynika to ze znacząco wyższej zmienności cen surowców niż cen detalicznych.

## 4.2. Mięso wołowe

Zmiany cen żywca wołowego przedstawiono w lewym górnym wykresie rysunku 4.3. Widać wyraźnie, że pomiędzy rokiem 1999 a 2013 wydzielić można trzy fazy kształtowania się cen żywca, przedzielone okresem nagłego wzrostu cen w połowie 2004 roku. W pierwszym okresie, którego koniec przypada na moment wstąpienia Polski do UE, ceny kształtowały się na najniższym poziomie, który oscylował w granicach 2,44-3,22 zł/kg. Jedynym odstępstwem pozostają skokowe zmiany cen w 2000 r. wywołane załamaniem podaży w wyniku choroby BSE. Ponad 40% wzrost cen do którego doszło pomiędzy marcem a lipcem 2004 roku, był wynikiem otwarcia do jednolitego rynku europejskiego po integracji z UE. Okres względnej stabilizacji cen trwał do końca 2008 roku. Jednak dopiero w ostatniej fazie, rozpoczętej na przełomie lat 2008/2009 dochodziło do znaczących wahań cen. Pierwszy wzrost wiąże się z nagłą, znaczącą deprecjacją polskiej waluty względem euro, jaka miała miejsce pod koniec 2008 roku. Natomiast od marca 2011 roku wzrost cen wołowiny jest wynikiem globalnych tendencji na rynku żywca wołowego, w wyniku których zarówno na rynku międzynarodowym, jak i unijnym, ceny wołowiny ukształtowały się na bardzo wysokim poziomie.

**Rysunek 4.3. Dekompozycja szeregu cen żywca wołowego oraz szpondra wołowego z kością i mięsa wołowego bez kości z udźca w latach 1999-2013 (MA)**



Źródło: Opracowanie własne na podstawie danych GUS.

Analiza z wykorzystaniem metody X-12-ARIMA wskazała, że w przypadku cen wołowiny – inaczej niż w przypadku cen zbóż – bardziej odpowiednim modelem pozostaje ten o strukturze addytywnej. W procesie linearyzacji szeregu cen wołowiny włączono do modelu dwa regresory (obserwacje nietypowe) typu „zmiany permanentne skokowe”, oraz jeden typu „zmiana przejściowa”. Potwierdzają one występowanie szoków w momencie wstąpienia do UE oraz związanych ze wzrostem cen światowych w I kwartale 2011 roku. Warto jednak podkreślić, że liczba wykrytych obserwacji nietypowych zależy od sposobu dekompozycji szeregu. Szerzej o tym na przykładzie cen wołowiny w Polsce pisze Hamulczuk [2013].

Analiza sezonowości wskazuje, że w badanym okresie doszło do znaczącej zmiany w zakresie oddziaływania składnika sezonowego. Przed przystąpieniem do UE ceny żywca wołowego cechowały się wahaniami sezonowymi o niewielkiej amplitudzie, a maksimum cenowe przypadało na wrzesień. Po roku 2004 wahania tego typu w coraz większym stopniu decydują o całkowitej zmienności, a schemat tych wahań ulega całkowitej zmianie z maksimum w I kwartale roku. Warto jednak pamiętać, że w znacznej części wzrost znaczenia sezonowości jest wynikiem przyjęcia w ramach metody X-ARIMA-12 addytywnego modelu i nominalnego wzrostu cen.

Do analizy cen detalicznych mięsa wołowego wybrano dwa produkty: mięso wołowe z kością (szponder) oraz mięso wołowe bez kości z udźca. Przebieg trendu-cyklu cen detalicznych pozostaje w dużym stopniu zbieżny z trendem-cyklem cen wołowiny na rynku wtórnym. Wyraźnie widoczny jest wzrost cen związany z wejściem na jednolity rynek unijny oraz spowodowany wzrostem cen na rynku światowym po roku 2011.

Czynnik sezonowy nie odgrywa znaczącego znaczenia w zmienności cen detalicznych. W szczególności, stwierdzenie to jest prawdziwe dla okresu po wstąpieniu Polski do UE. W ostatnich latach objętych analizą amplituda zmian sezonowych nie przekroczyła dla mięsa bez kości i szpondra odpowiednio 2,5% oraz 1,5% średniego poziomu cen. Testy sezonowości wskazują, że w przypadku szpondra czynnik sezonowy nie jest istotny statystycznie, dlatego też nie przedstawiono go na rysunku 4.3. W przypadku mięsa bez kości istotność statystyczną wykazać można dopiero przy 10% poziomie istotności.

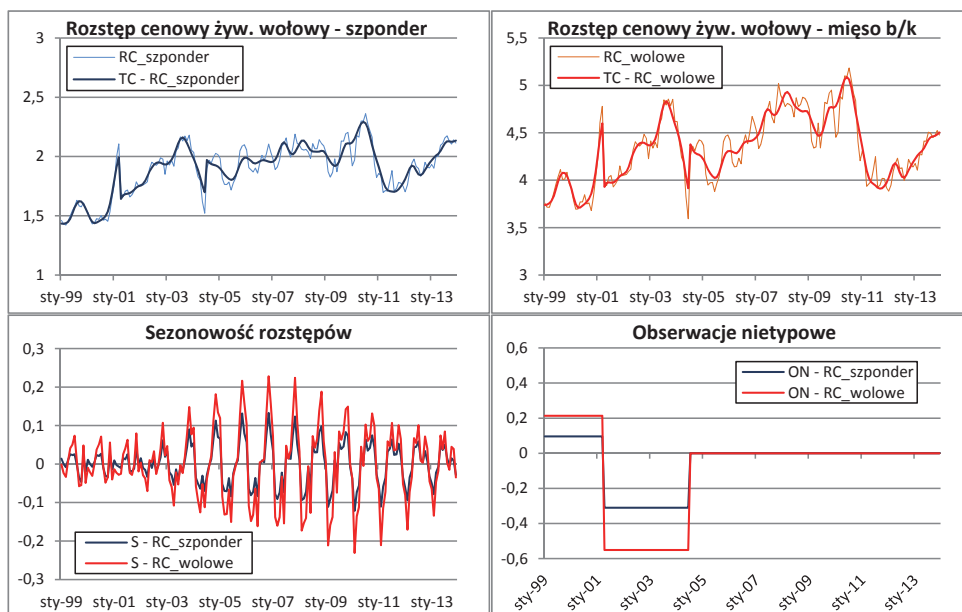
W ramach procedury automatycznej w cenach mięsa wołowego bez kości wykryto 6 regresorów, z czego aż trzy dotyczą zmian wywołanych przystąpieniem Polski do UE. Są to następujące po sobie miesiące po miesiącu regresory: typu „zdarzenie jednorazowe” w maju 2004, typu „zmiana permanentna” miesiąc później oraz typu „zmiany przejściowe” w lipcu. Spośród kolejnych wykrytych obserwacji nietypowych warto zwrócić uwagę na „zmianę permanentną” odpowiadającą podniesieniu podatku VAT na początku 2011 r. W przypadku szeregu cen szpondra obserwacje nietypowe dotyczą wyłącznie zmian cen wynikających z przystąpienia do UE, a ich przebieg jest podobny do tych obserwowanych dla mięsa bez kości.

Na górnym wykresie rysunku 4.4 przedstawiono przebieg dwóch szeregów czasowych przedstawiających rozstęp cenowy pomiędzy żywcem wołowym a szpondrem z kością oraz żywcem wołowym a mięsem bez kości z udźca. W przebiegu wartości rozstępów wyróżnić można 2 fazy. W okresie poprzedzającym wstąpienie do UE uwidacznia się trend wzrostowy. Dodatkowo, na początku 2001 roku, czyli w okresie perturbacji związanych z epidemią BSE,

zaobserwować można krótkotrwały nagły wzrost wartości rozstępów, co spowodowane było nagłym spadkiem cen wołowiny. Na silny wpływ BSE na ceny wołowiny w Hiszpanii wskazuje również Serra [2011]. Objawia się to w znacznej mierze wzrostem zmienności w okresach „kryzysowych” w stosunku do okresów „normalnych”.

Połowa 2004 roku to kolejny moment, w którym doszło do zmiany typu szokowego. Nagłe ruchy cen związane z dostosowaniem do poziomu unijnego wystąpiły najpierw na rynku żywca wołowego, a dopiero z pewnym opóźnieniem na rynku detalicznym, czego konsekwencją są wahania wartości rozstępów. Okres po wstąpieniu do UE cechuje względna stałość wartości rozstępów, choć zaobserwować można zmiany wynikające ze zmian cen wołowiny na rynku unijnym. Wzrosty cen żywca wołowego w połowie 2009 roku oraz w pierwszych kwartałach 2011 roku skutkowały obniżeniem wartości analizowanych rozstępów.

**Rysunek 4.4. Dekompozycja szeregu rozstępu cenowego żywca wołowego i szpondera z kością (MA) oraz mięsa bez kości z udźca (MA) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

Na wartość składnika sezonowego rozstępów cenowych – amplituda zmian sezonowych nie przekracza 0,3 – decydujący wpływ ma sezonowość cen żywca wołowego. Dopiero zmiana kształtu sezonowości szeregów cen, objawiająca się z nałożeniem się sezonowych maksimum w pierwszych miesiącach



roku, a do której doszło pod koniec analizowanego okresu, sprawiła, że amplituda zmian sezonowych uległa zmniejszeniu.

Wpływ obserwacji nietypowych na oszacowania modelu ARIMA-X-12 ogranicza się do uwzględnienia dwóch zmian. Pierwsza z nich jest związana ze zmianami wartości różnic cenowych w okresie wystąpienia choroby BSE (wpływ ujemny). Ciekawy efekt ten nie był statystycznie istotny w szeregach czasowych cen żywca i cen detalicznych. Drugi (wpływ dodatni) jest powiązany bezpośrednio ze zmianami relacji cenowych po wstąpieniu Polski do UE.

### 4.3. Mięso wieprzowe

Specyfika rynku wieprzowiny odmienna jest od omawianego wcześniej rynku wołowiny. Inny też jest przebieg cen żywca wieprzowego. Dominujące są w tym przypadku tzw. „cykle świńskie”, czyli cykliczne wahania cen, wywołane zmianami podaży żywca wieprzowego, o długości ok. 4 lat. Są one następstwem krótkookresowej sztywności podaży, w wyniku której producenci z opóźnieniem reagują zarówno na spadki, jak i wzrosty opłacalności chowu trzody [Hamulczuk 2006]. Ich przebieg jest wyraźnie widoczny na rysunku 4.5. Zmiany cen będące wynikiem „cyklu świńskiego” wydają się determinować większość długookresowych wahań cen. Dodatkowo zauważyć można postępujący od roku 2011 wzrost cen będący efektem globalnego wzrostu cen surowców rolnych pochodzenia zwierzęcego, za który odpowiada m.in. postępujący wzrost cen pasz.

Przy wykorzystaniu automatycznej procedury do opisu zachowania cen żywca wieprzowego wybrano model addytywny. Nie wykryto żadnych obserwacji nietypowych. W analizowanym okresie nie doszło też do zmiany charakteru sezonowości. Przez cały okres maksimum cen przypadało na sierpień, podczas gdy najniższe ceny odnotowywano w dwóch pierwszych miesiącach roku. Warto również zwrócić uwagę na dużą – acz malejącą – wielkość amplitudy wahań sezonowych.

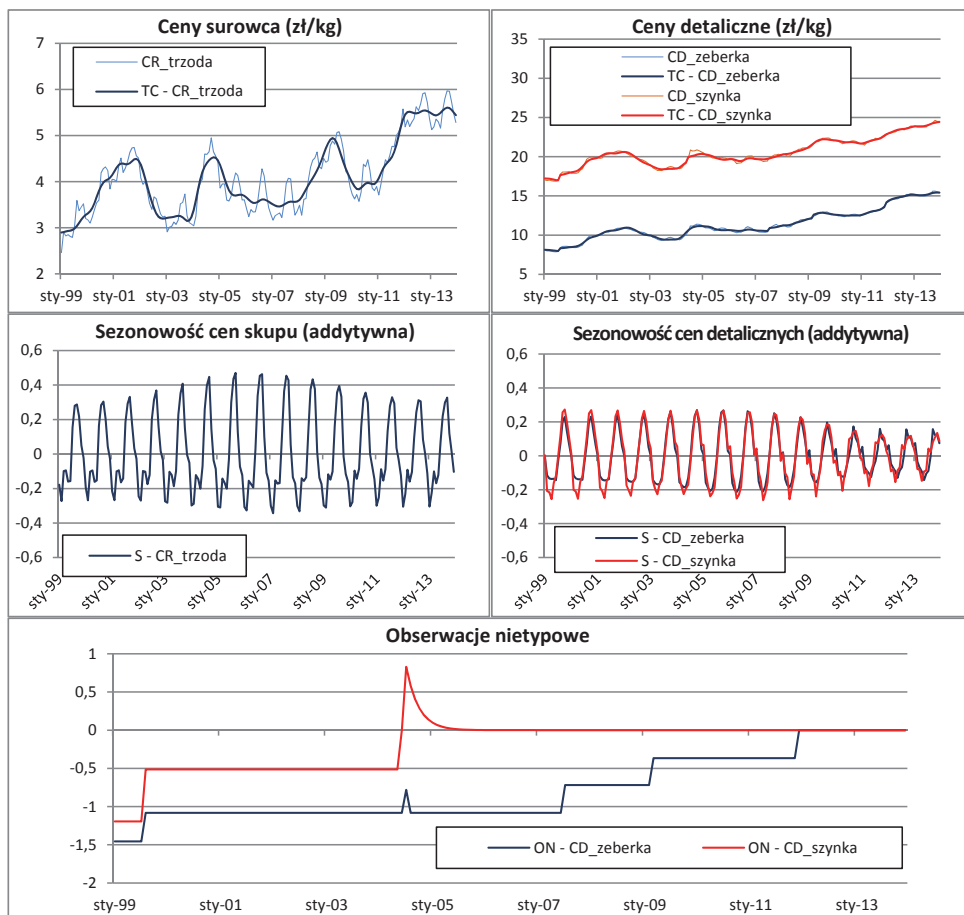
Do analizy cen na rynku detalicznym wybrano dwa produkty: żeberka wieprzowe oraz szynkę wieprzową gotowaną. Zmiany cen tych produktów w latach 1999-2013 pozostawały w bardzo wysokim stopniu zbieżne ze sobą<sup>23</sup>. Analiza graficzna (rys. 4.5) pozwala przede wszystkim zauważyć podobieństwo kształtu cykli cenowych, przy czym na rynku detalicznym są one zdecydowanie bardziej wygładzone. Kształt czynnika sezonowego w dużym stopniu przypomina ten obserwowany na rynku żywca wieprzowego, jedynie maksimum cenowe jest przesunięte o jeden do dwóch miesięcy. W kolejnych latach amplituda zmian sezonowych staje się coraz mniejsza. Spośród wykrytych obserwacji

---

<sup>23</sup> Współczynnik korelacji dla cen żeberek oraz szynki wieprzowej wyniósł ok. 0,98.

nietypowych największy wpływ miały „zmiany permanentne” z sierpnia 1999 roku oraz zmiany cen detalicznych żywności w lipcu 2004 roku.

**Rysunek 4.5. Dekompozycja szeregu ceny żywca wieprzowego (po lewej - MA) oraz żeberk wieprzowych i szynki wieprzowej gotowanej (po prawej - MA) w latach 1999-2013**




Źródło: Opracowanie własne na podstawie danych GUS.

Na rysunku 4.6 przedstawiono dekompozycję szeregu czasowego rozstępów cenowych żywca wieprzowego i żeberk oraz żywca wieprzowego i szynki gotowanej (modele multiplikatywne). Brak wykresu prezentującego wpływ zmian nietypowych wynika z niewykrycia zmian szokowych w analizowanych szeregach czasowych.

Przebieg wartości rozstępów cenowych na rynku wieprzowiny wynika bezpośrednio ze zmian cen obserwowanych na rynku detalicznym i na rynku surowców rolnych. Z uwagi, że tendencje cen detalicznych mięsa i cen żywca

wieprzowego są podobne rozstępy cenowe między nimi wykazują względnie stałym poziomem. Jak wspomniano, zmiany cen detalicznych produktów cechują tak samo umiejscowione cykle o podobnej długości, lecz niższej amplitudzie niż te obserwowane na rynku żywca. Wskutek tego poziom rozstępów jest uzależniony od fazy cyklu świńskiego. W okresie zwyżki cen wieprzowiny, wartość rozstępów cenowych ulega obniżeniu, a wzrasta, gdy ceny wieprzowiny spadają.

**Rysunek 4.6. Dekompozycja szeregu rozstępu cenowego żywca wieprzowego i żeberk wieprzowych (MM) oraz szynki wieprzowej gotowanej (MM) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

Wyraźnie widoczny jest wpływ czynnika sezonowego na kształtowanie się poziomu rozstępów cenowych. Amplituda zmian sezonowych przekracza 20% średniej wartości w analizowanym okresie. Maksimum osiągane jest w pierwszych dwóch miesiącach roku, zaś minima przypadają na sierpień, co jest lustrzanym odbiciem kształtu sezonowości obserwowanego na rynku żywca wieprzowego.

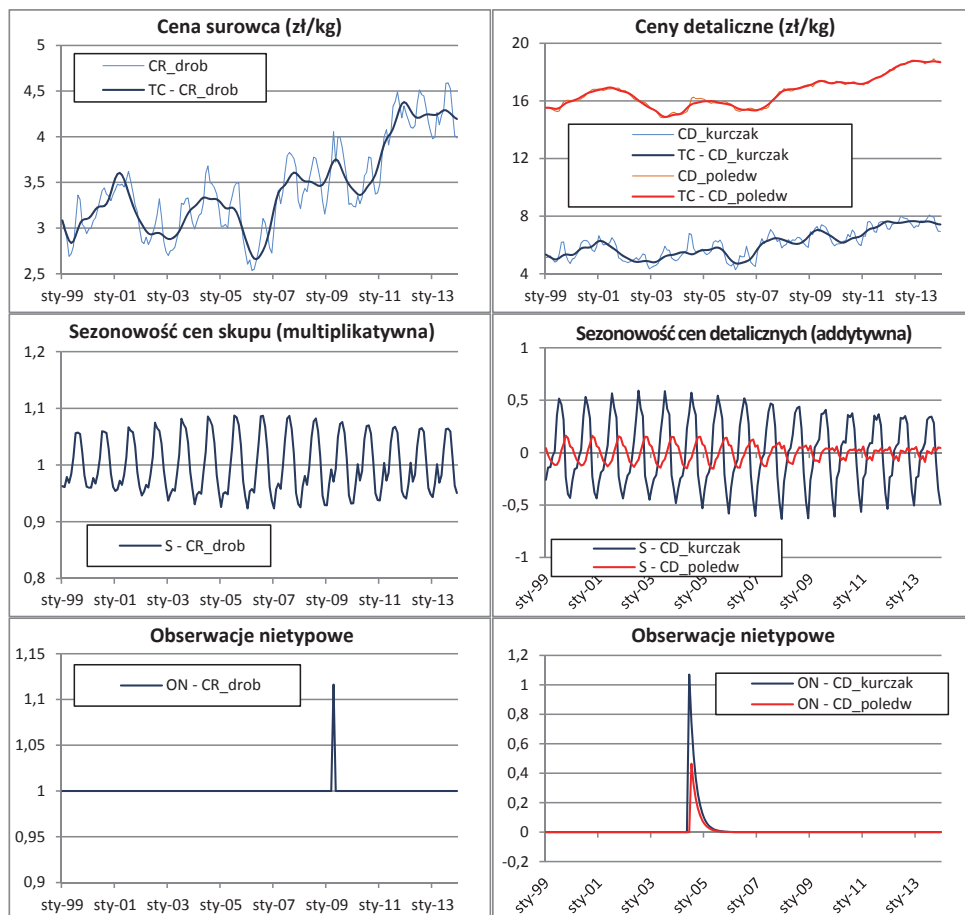
#### 4.4. Mięso drobiowe

Analizowana cena mięsa drobiowego jest średnią ważoną wybranych gatunków drobiu, spośród których największe znaczenie odgrywiają ceny drobiu kurzego. Cena ta w analizowanym okresie podlegała istotnym wahaniom cyklicznym o długości zbliżonej do cykli obserwowanych na rynku mięsa wieprzowego. Wynika to z wysokiego stopnia substytucyjności obu tych rodzajów mięsa. Stąd też cykliczne maksima i minima występują w tych samych momentach, co na rynku żywca wieprzowego. Obserwowany wzrost cen w ostatnich latach spowodowany jest – poza czynnikami, które wymienione zostały w części poświęconej zmianom cen wieprzowiny – postępującym dostosowywaniem krajowych cen drobiu do poziomu unijnego [Dybowski 2014].

Do dekompozycji szeregu czasowego cen drobiu zastosowano model multiplikatywny. Wykryto jedną obserwację odstającą typu „zdarzenie

jednorazowe” w kwietniu 2009 r., co wynika z nadspodziewanie wysokiego poziomu cen w tym okresie. Amplituda wahań sezonowych oscylowała od ok. 10% na początku i pod koniec analizowanego okresu do ponad 16% w roku 2006. Podobnie jak w przypadku szeregu cen wieprzowiny, najwyższe ceny odnotowywane były w miesiącach letnich, zaś minima roczne występowały na przełomie roku (styczeń i grudzień).

**Rysunek 4.7. Dekompozycja szeregu ceny żywca drobiowego (po lewej - MM) oraz kurczęcia patroszonego i polędwicy drobiowej (po prawej - MA) w latach 1999-2013**



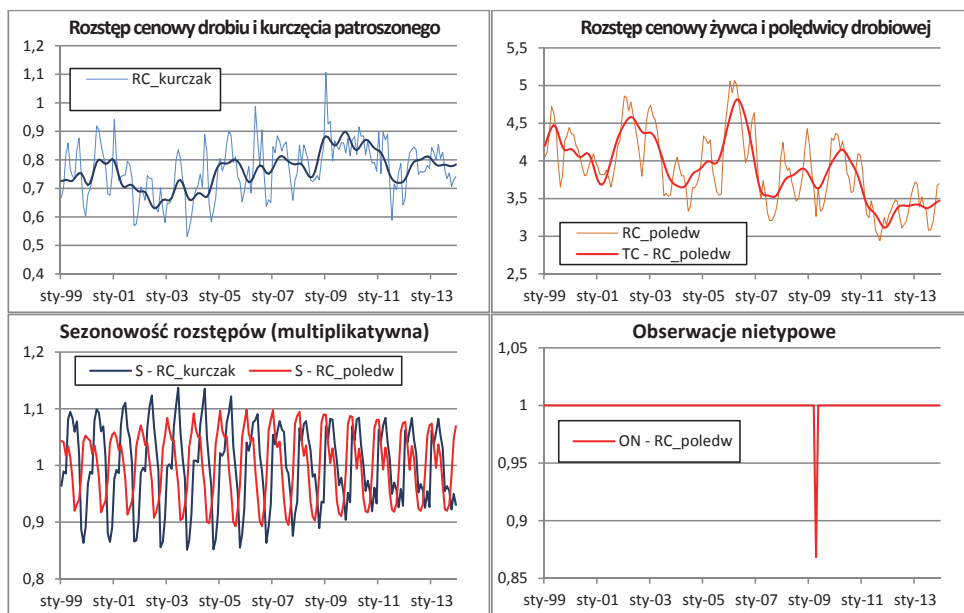
Źródło: Opracowanie własne na podstawie danych GUS.

Do analizy cen detalicznych wybrano kurczę patroszone i polędwicę drobiową. Już analiza graficzna prawej strony rysunku 4.7 pozwala na wychwycenie podobieństw cykliczności cen produktów detalicznych z cyklicznością cechującą ceny żywca drobiowego. Ceny produktu bardziej przetworzonego,

czyli polędwicy, cechują się większą stabilnością. W przypadku cen kurczęcia patroszonego przebieg zmian cyklicznych jest bardziej widoczny. Widać też większą krótkookresową zmienność.

Dekompozycję cen produktów detalicznych przeprowadzono przy wykorzystaniu modeli addytywnych. W obu analizowanych przypadkach wykryto występowanie „zmiany przejściowej”, która związana była z perturbacjami rynkowymi wywołanymi przystąpieniem Polski do UE. W przypadku kurczęcia patroszonego „zmiana przejściowa” nastąpiła w czerwcu 2004 r. Miesiąc później i ze znacząco mniejszą siłą wystąpiła dla dobra mocniej przetworzonego, czyli polędwicy drobiowej. Czynniki sezonowy jest statystycznie istotny w obu szeregach czasowych. Amplituda zmian sezonowych cen kurczęcia patroszonego oscyluje w granicach 0,8-1 złotego i jest znacząco wyższa niż w przypadku cen polędwicy drobiowej (maksymalnie 0,25 zł). Biorąc pod uwagę niższy poziom cen średnich kurczęcia patroszonego, widać, jak istotne znaczenie mają zmiany typu sezonowego w zmienności cen kurczęcia patroszonego.

**Rysunek 4.8. Dekompozycja szeregu wzrostu cenowego żywca drobiowego i kurczęcia patroszonego (MM) polędwicy drobiowej (MM) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

Na rysunku 4.8 przedstawiono przebiegi szeregów czasowych rozstępów cenowych pomiędzy żywcem drobiowym a analizowanymi powyżej produktami żywnościowymi. W obu przypadkach procedura automatyczna wskazała na

zasadność zastosowania do dekompozycji modeli multiplikatywnych. Analiza graficzna pozwala zauważyć pewne podobieństwo w przebiegach obu analizowanych wzrostów cenowych, niemniej pewne różnice w kształtowaniu się cen detalicznych w latach 2001-03 oraz 2005-06, sprawiają, że oba analizowane szeregi nie są wysoce skorelowane.

Amplituda zmian sezonowych szeregu wzrostu cen drobiu i kurczenia patroszonego ulega zmniejszeniu po roku 2006. Roczne minima osiągnęte są w III kwartale, zaś maksima przypadają na czerwiec do roku 2006 i kwiecień w późniejszych latach. Kształt czynnika sezonowego wzrostu cenowego drobiu i polędwicy jest bardziej stabilny w całym analizowanym okresie, przyjmując wartości maksymalne na przełomie lat, zaś minima w czerwcu i lutym. W tym szeregu czasowym wykryto też jedną zmianę typu szokowego, która jest pochodną zmian na rynku cen żywca drobiowego.

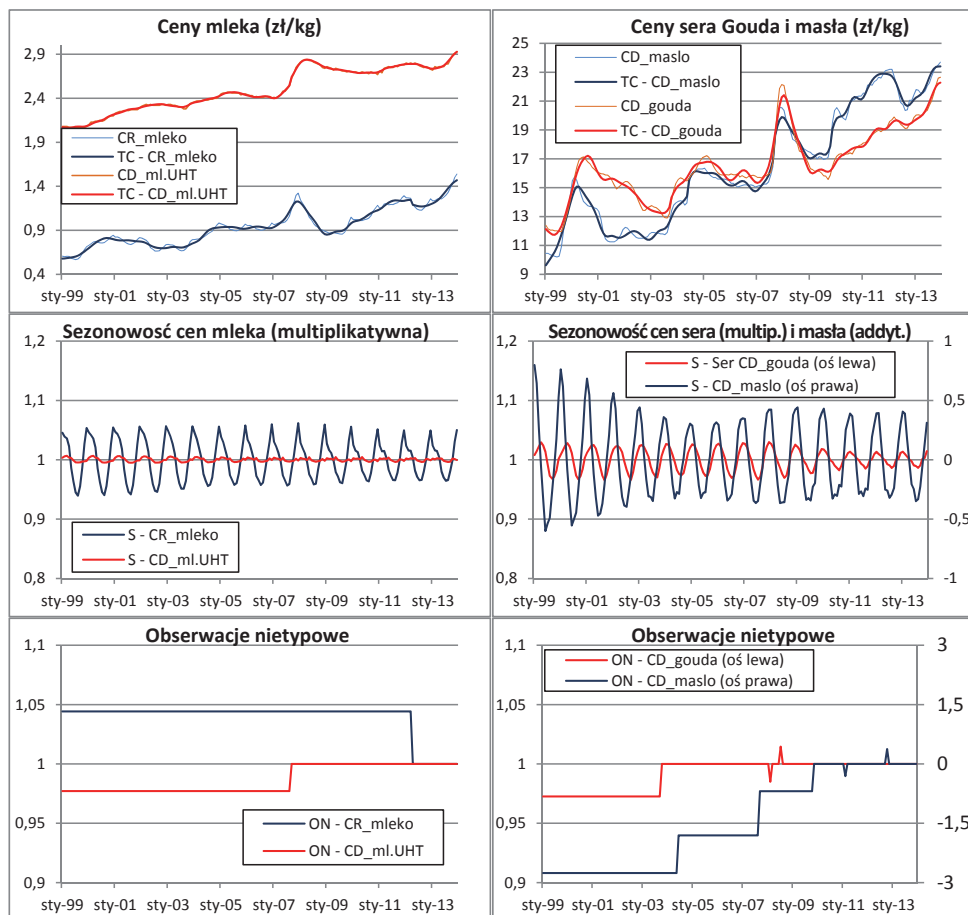
#### **4.5. Mleko i produkty mleczne**

W tym podrozdziale oprócz cen mleka jako surowca analizowane będą ceny detaliczne trzech produktów. Są to ceny: mleka UHT o zawartości tłuszczu 3-3,5%, ceny masła „Extra” oraz ceny sera Gouda. Większa liczba poddanych analizie cen produktów żywnościowych wymaga pewnej modyfikacji schematu prezentowanych rysunków. Stąd szeregi czasowe związane z cenami produktu najmniej przetworzonego, czyli mleka UHT, przedstawione będą na wykresach wspólnie z szeregami czasowymi odnoszącymi się do cen mleka w skupie.

W analizowanym okresie ceny uzyskiwane przez wytwórców mleka wykazywały wyraźny długookresowy trend wzrostowy, a także – podobnie jak większość pozostałych surowców rolnych – uległy wyraźnemu wzrostowi na przełomie lat 2007/08 i później po roku 2011. Pomimo że samo mleko nie jest przedmiotem wymiany międzynarodowej, ceny krajowe mleka są ściśle uzależnione od sytuacji popytowo-podażowej w Unii oraz na świecie, gdyż jego ceny są zależne od cen masła, serów i mleka w proszku, będących przedmiotem handlu zagranicznego. Wpływ cen światowych wynika z faktu, że kraje unijne pozostają jednym z najważniejszych globalnych eksporterów masła, serów i mleka w proszku. Warto też pamiętać, że rynek mleka jest jednym z najsilniej regulowanych w ramach polityki rolnej UE – obowiązują limity produkcyjne, chroniony jest rynek wewnętrzny. Także przed przystąpieniem do UE ważną rolę odgrywały interwencyjne zakupy/sprzedaje mleka w proszku czy masła prowadzone przez ARR. Niemniej pomimo tego typu stosowanych narzędzi interwencji rynkowych największy wpływ na ceny – szczególnie w ostatnich latach – ma sytuacja popytowo-podażowa na rynku globalnym. Ceny produktów mlecznych ulegały drastycznym zmianom głównie wskutek zmian kosztów prowadzenia

produkcji oraz w wyniku wzrostu popytu na produkty mleczne w krajach rozwijających się, w szczególności w Chinach [Abbott i in. 2011].

**Rysunek 4.9. Dekompozycja szeregu ceny mleka surowego i mleka UHT (po lewej – MM) oraz masła (po prawej – MA) i sera gouda (po prawej – MM) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

Dekompozycji szeregu cen mleka dokonano przy wykorzystaniu modelu multiplikatywnego. Wykryto jedną zmianę typu szokowego w kwietniu 2012 roku. Widać też wyraźnie, że kształt czynnika sezonowego nie uległ zmianie i przez cały okres najwyższe ceny notowano w grudniu, podczas gdy minima roczne przypadają na lipiec i sierpień. Amplituda zmian sezonowych osiągała wartości od 12% w pierwszych latach analizy do 9% pod jej koniec.

Pierwsza z analizowanych cen detalicznych dotyczy mleka UHT. Analiza graficzna wskazuje na dużą zbieżność tych cen z cenami mleka uzyskiwanymi

przez producentów. Najistotniejsza różnica pomiędzy tymi szeregami cen dotyczy zmienności sezonowej, której amplituda w przypadku cen mleka UHT nie przekracza 1% (pozostaje jednak statystycznie istotna).

Ceny zarówno masła „Extra”, jak i sera Gouda charakteryzuje wyraźny trend wzrostowy. Oba szeregi czasowe cechują się też cyklicznością o podobnym przebiegu, ze szczytem cenowym w latach 2000, 2004, 2007 i 2011. Trend wzrostowy jest silniejszy w przypadku cen masła, które na początku analizowanego okresu osiągało niższą cenę od sera, co uległo trwałej zmianie około roku 2008. Oba szeregi czasowe cechują się istotną statystycznie zmiennością sezonową, której znaczenie w ostatnich latach ulega osłabieniu. Należy zwrócić uwagę, że dekompozycji cen masła dokonano przy użyciu modelu addytywnego, zaś cen sera – modelu multiplikatywnego. Amplituda zmian sezonowych w przypadku cen masła – kształt zmienności analogiczny jak w przypadku cen mleka – wynosiła od około 0,7 zł w roku 2013 do blisko 1,5 zł w roku 1999. Kształt zmienności sezonowej dla cen sera ulegał zmianom. Początkowo maksymalne cenowe przypadały na kwiecień, by zmienić się wraz z przystąpieniem Polski do UE i upodobnić do sezonowości obserwowanej na rynku mleka. Maksymalna wartość amplitudy zmian sezonowych wyniosła 6%. Wykryto dużą liczbę obserwacji nietypowych w obu szeregach czasowych, niemniej ich znaczenie – biorąc pod uwagę wartości – nie jest znaczne. Odzwierciedlają one niektóre z dynamicznych wzrostów cen w analizowanym okresie. Przykładowo, dla cen sera Gouda, jest to blisko 3-procentowy wzrost w październiku 2003 roku, a dla cen masła szokowy wzrost o blisko 1 zł związany ze wstąpieniem do UE.

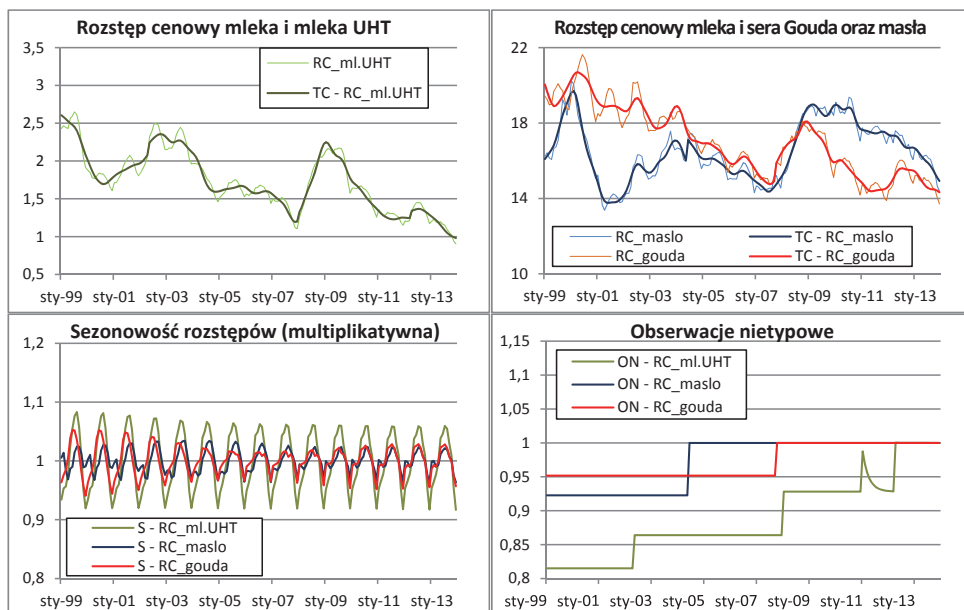
W ramach rynku produktów mlecznych analizie poddano przebieg trzech szeregów czasowych odnoszących się do rozstępów cenowych między ceną mleka i jego wyrobów. Analiza graficzna (rys. 4.10) umożliwia wychwycenie istotnych różnic pomiędzy analizowanymi szeregami czasowymi, niemniej obecne są też pewne podobieństwa. Należy do nich choćby ciągły spadek wartości rozstępów rozpoczęty w 2009 roku, czy lokalne minimum w II połowie 2007 roku, kiedy notowano szczególnie wysokie ceny mleka. Rozstęp pomiędzy cenami mleka i masła jako jedyny nie ma wyraźnej spadkowej tendencji, natomiast w przypadku rozstępu cen mleka i mleka UHT, spadek wartości, jak i zmienność całkowita jest największa.

Przy dekompozycji wszystkich analizowanych rozstępów cenowych wykorzystano modele multiplikatywne. Z uwagi na zbieżność kształtu zmienności sezonowej szeregów czasowych cen mleka, masła i sera, największa amplituda zmian sezonowych – wynosząca około 14% – w przypadku rozstępów cenowych dotyczy tego tworzonego na bazie cen mleka UHT.



Z powodu wyraźnej odrębności zmian trendu-cyklu cen mleka UHT (znaczną sztywność cen) od cen mleka liczba największa wykrytych obserwacji nietypowych dotyczy rozstępu między tymi cenami i odzwierciedla większość dynamicznych zmian cen mleka w analizowanym okresie. Z kolei w przypadku dwóch pozostałych rozstępów cenowych obserwacje nietypowe dotyczą zmian po wstąpieniu do Unii oraz perturbacji związanych ze wzrostem cen światowych pod koniec 2007 roku.

**Rysunek 4.10. Dekompozycja szeregu rozstępu cenowego mleka i mleka UHT (MM), masła (MM) oraz sera Gouda (MM) w latach 1999-2013**



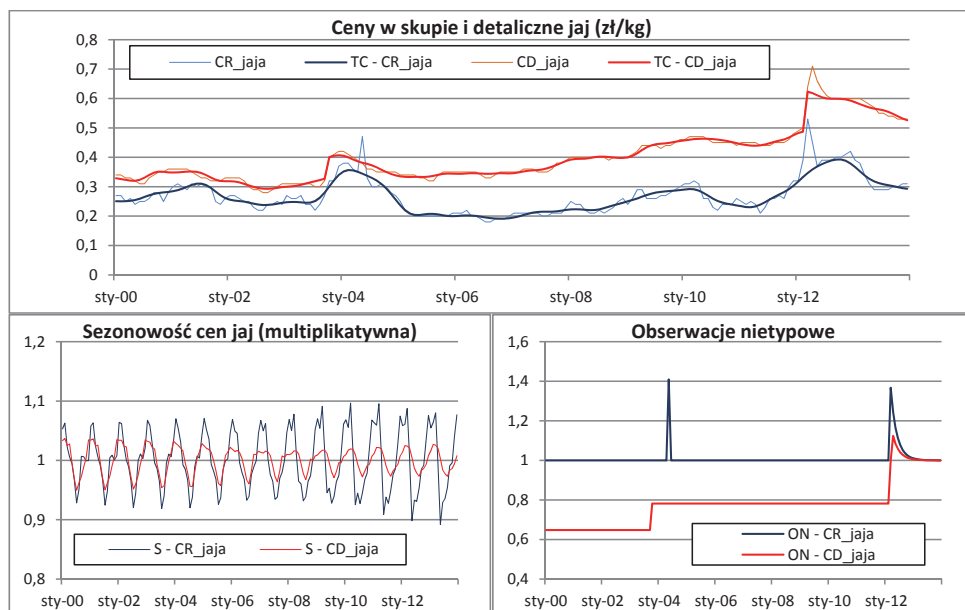
Źródło: Opracowanie własne na podstawie danych GUS.

## 4.6. Rynek jaj

Analizę na rynku jaj ograniczono do cen dwóch produktów: notowanych w zakładach pakujących i tych płaconych przez konsumentów na rynku detalicznym. Inaczej niż było to w przypadku dotychczas analizowanych rynków, surowiec rolny nie jest tu poddawany przetworzeniu. Na kolejnych etapach łańcucha marketingowego przedsiębiorcy ponoszą zaś koszty związane z kontrolą surowca, pakowaniem, dystrybucją itp. Brak kosztów związanych z procesami przetwórczymi wpływa widocznie na wielkość odnotowywanych marż. Należy zwrócić uwagę, że z powodu dostępności danych, analizę przeprowadzono dla okresu od stycznia 2000 roku do końca 2013 roku.

Ceny jaj uzyskiwane przez producentów przez cały analizowany okres pozostawały na względnie stałym poziomie. W szczególności, uwagę przyciąga brak zauważalnego trendu wzrostowego cen, co w przypadku szeregu cen nominalnych nie jest zjawiskiem powszechnym. W tym kontekście wynika to ze wzrostu efektywności produkcji, pozwalającej na dostarczanie na rynek towarów po coraz niższych cenach realnych. Okresowe wyżki cen zanotowano w roku 2001, na przełomie lat 2003/04, a następnie w latach 2009/10 oraz w 2012 roku. Dwukrotnie dochodziło też do nagłych, skokowych wzrostów cen – w maju 2004 r. oraz w marcu 2012 r. Pierwszy z nich związany był z perturbacjami na rynku, do których doszło po przystąpieniu Polski do UE. Drugi z nich należy wiązać z zawirowaniami wywołanymi upłynięciem terminów przejściowych, zawartych w dyrektywie 1999/74/EC ustanawiającej minimalne normy ochrony kur niosek. Konieczność dostosowania produkcji do podwyższonych standardów dobrostanu kur niosek w połączeniu z przedsięwziętym wzrostem popytu doprowadziły do znacznego i nagłego wzrostu cen. W przypadku wzrostu cen w roku 2004 warto zwrócić uwagę, że doszło wtedy do krótkotrwałej sytuacji, w której ceny płacone producentom przewyższyły te notowane w tym czasie na rynku detalicznym.

**Rysunek 4.11. Dekompozycja szeregu cen jaj w zakładach pakujących (MM) oraz cen detalicznych jaj (MM) w latach 1999-2013**

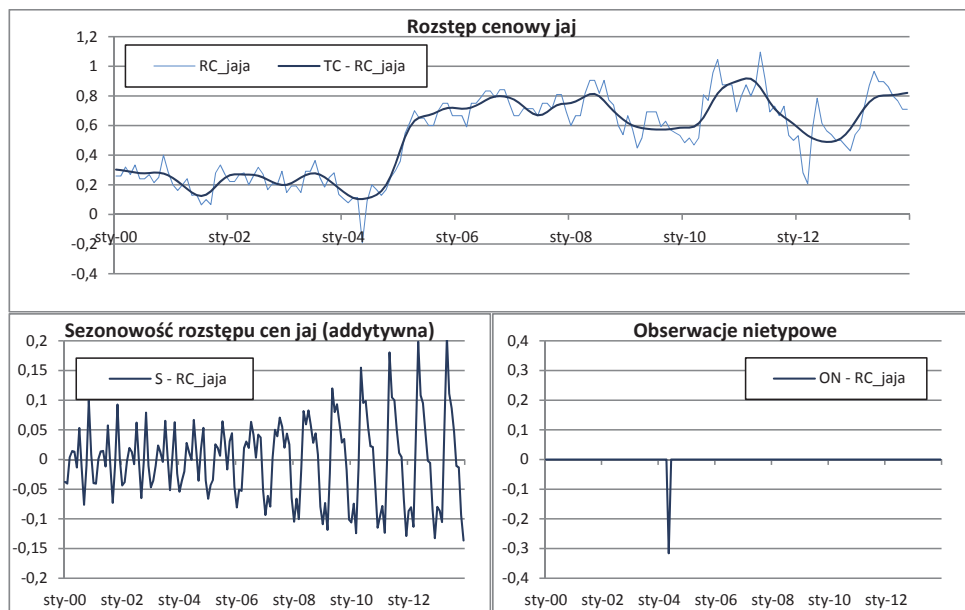


Źródło: Opracowanie własne na podstawie danych GUS.

Analiza z wykorzystaniem metody X-12-ARIMA (rys. 4.11) wskazała, że w przypadku cen jaj dekompozycję należy przeprowadzić przy wykorzystaniu modelu multiplikatywnego. Zarówno ceny producenta, jak i detaliczne, cechują się wyraźną sezonowością. Do roku 2004 najwyższe ceny otrzymywali producenci w styczniu i lutym. W następnych latach maksima roczne notowano w marcu i kwietniu. Kolejne miesiące cechował nagły spadek cen z minimum w lipcu, a od roku 2009 już w maju. W kolejnych latach rosła amplituda zmian sezonowych, która w roku 2013 wyniosła blisko 18%. Podobny kształt sezonowości charakteryzuje ceny na rynku detalicznym, przy czym amplituda jest tu znacznie niższa i dodatkowo maleje ona w kolejnych latach.

W przypadku cen notowanych w zakładach pakujących, wykryte zmiany szokowe – „zdarzenie jednorazowe” w maju 2004 r. i „zmiany przejściowe” w marcu 2014 r. – obrazują zmiany w wyniku opisanych wcześniej zdarzeń. Dla szeregu czasowego cen detalicznych nie wykryto zmian w maju 2004 r., natomiast odnotowano „zmianę permanentną” w październiku 2003 r. W tym okresie ceny jaj uległy wzrostowi w wyniku szoku podażowego związanego z pojawieniem się epidemii ptasiej grypy, wywołanej wirusem H5N1.

**Rysunek 4.12. Dekompozycja szeregu czasowego rozstępu cen na rynku jaj (MA) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

Na rysunku 4.12 przedstawiono szeregi czasowe uzyskane w wyniku dekompozycji szeregu rozstępu cen jaj na rynku rolnym i detalicznym. Analiza graficzna pozwala zauważyć względną stałość wartości rozstępu w okresach 1999-2004 oraz 2005-2013 a także zmianę poziomu na przełomie lat 2004/05, kiedy to wzrosła różnica pomiędzy cenami jaj na obu rynkach. Kształt czynnika sezonowego jest odbiciem niższej amplitudy zmian sezonowych na rynku detalicznym, co sprawia, że maksimum roczne przypada na miesiąc maj, gdy ceny uzyskiwane przez producenta są najniższe. Wbrew temu, na co wskazywałaby analiza graficzna, nie wykryto zmiany permanentnej na przełomie lat 2004/05, a jedynie „zdarzenie jednorazowe” w maju 2004 roku, kiedy to wartość rozstępu spadła poniżej zera, na skutek nagłej, krótkotrwałej zmiany cen uzyskiwanych przez producentów.

#### **4.7. Rzepak i tłuszcze roślinne**

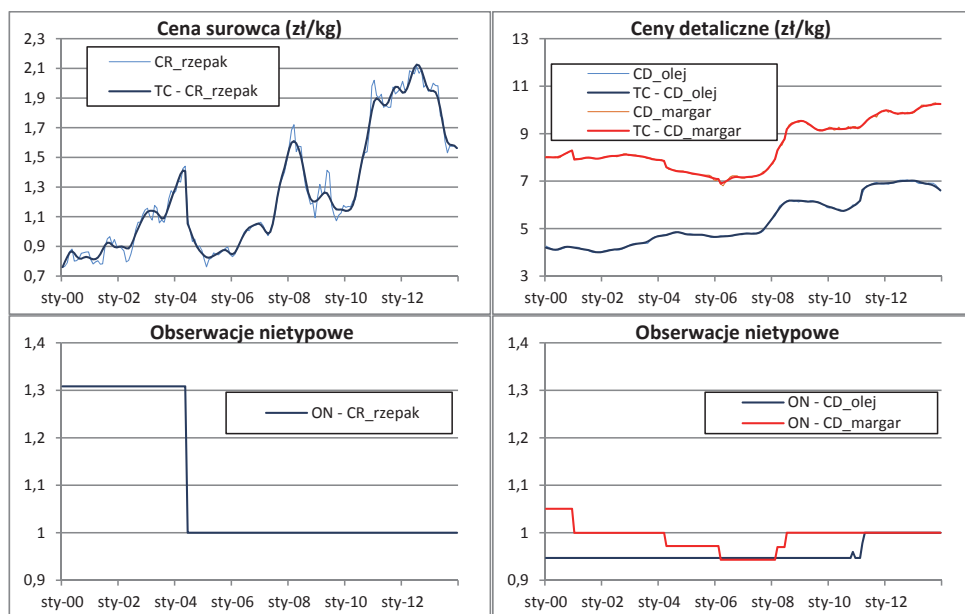
Analiza cen na rynku rzepaku – podobnie jak było w poprzednim podrozdziale – obejmuje krótszy niż standardowy okres, rozpoczynający się w roku 2000. Inna jest też metodyka zbierania danych odnoszących się do cen surowca. W przypadku krajowych cen rzepaku dostępne szeregi są bardzo okrojone i zawierają dane jedynie z kilku wybranych miesięcy następujących po okresie zbiorów. Z tego też powodu analizę przeprowadzono posiłkując się danymi z rynku europejskiego – są to miesięczne ceny CIF rzepaku w porcie w Hamburgu notowane pierwotnie w dolarach za tonę. W pracy przeliczono te wartości tak, by cena rzepaku odpowiadała wartości w złotych za kilogram. Wybór ceny w Hamburgu podyktowany jest jej wiodącą rolą na unijnym rynku, a także ścisłym uzależnieniu – szczególnie po wstąpieniu do UE – cen krajowych od cen notowanych w Unii. Ceny produktów detalicznych – oleju rzepakowego jadalnego krajowego w litrowej butelce oraz margaryny do smarowania pieczywa – odnoszą się do rynku krajowego.

Analiza graficzna cen rzepaku (rys. 4.13) wskazuje na dużą jego zmienność w analizowanym okresie. Kształt zmian cen rzepaku po roku 2006 pozostaje w dużym stopniu zbieżny ze zmianami cen zbóż – wyraźny wzrost cen na przełomie lat 2007/08 i później w roku 2011. Ceny oleju rzepakowego i margaryny są zdecydowanie mniej zmienne, przy czym zauważyć można podążanie za zmianami cen na rynku surowca, w szczególności wzrosty cen na początku roku 2008 i 2011. Największe różnice pomiędzy cenami detalicznymi obserwuje się w okresie 2000-04, gdy ceny margaryny obniżały się, zaś ceny oleju rzepakowego rosły.

Dekompozycji analizowanych szeregów dokonano przy wykorzystaniu modeli multiplikatywnych. W żadnym z trzech szeregów zmiany typu sezonowego nie

były statystycznie istotne, stąd też na rysunku 4.13 nie zawarto przebiegu zmian czynników sezonowych. W przypadku cen rzepaku wykryto jedną zmianę typu szokowego – w czerwcu 2004 r. Jest to skokowa zmiana poziomu o wartości ponad 30% odzwierciedlająca wyraźny wzrost podaży rzepaku w tym okresie. Światowe zbiory rzepaku w roku 2003/04 wzrosły bowiem o blisko 18% w porównaniu z sezonem poprzednim. W przypadku cen detalicznych liczba wykrytych obserwacji nietypowych jest większa, jednak ich wartość pozostaje znacząco mniejsza [Rosiak i in. 2011]. Widać też różnice pomiędzy analizowanymi szeregami – przykładowo, ceny margaryny mocniej zareagowały na wzrost rzepaku w roku 2008, a ceny oleju na wzrosty w roku 2011.

**Rysunek 4.13. Dekompozycja szeregu ceny rzepaku (po lewej - MM) oraz oleju rzepakowego i margaryny (po prawej - MM) w latach 1999-2013**

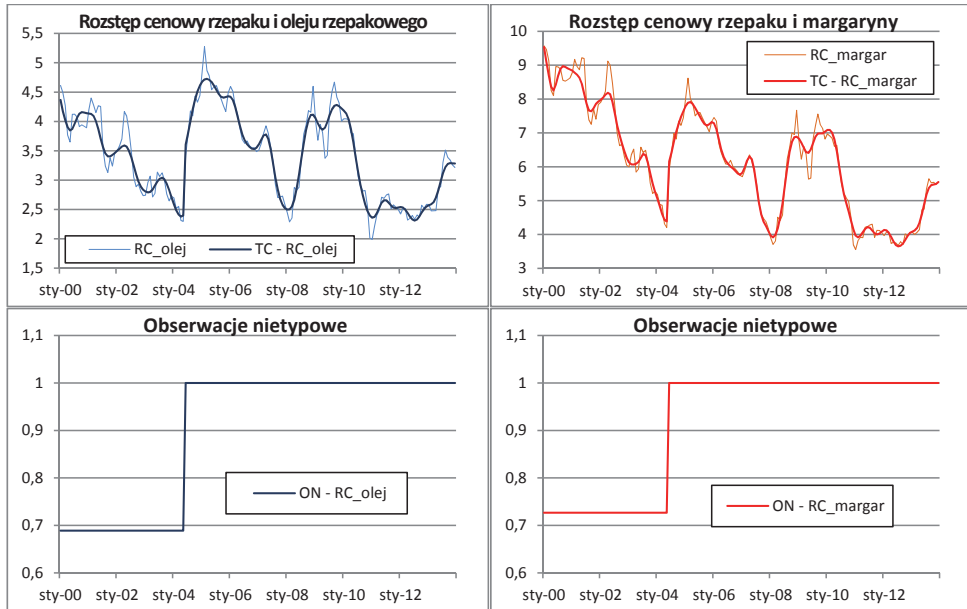


Źródło: Opracowanie własne na podstawie danych GUS.

Dekompozycja rozstępów cenowych – przedstawiona na rysunku 4.14 – została przeprowadzona przy użyciu modeli multiplikatywnych. Podobnie jak w przypadku cen poszczególnych towarów, brak tu statystycznie istotnej sezonowości. Rozstęp pomiędzy cenami rzepaku i oleju dla okresu przed przystąpieniem Polski do UE cechuje mniejsza zmienność niż pomiędzy cenami rzepaku i margaryny. W tym okresie ceny margaryny i rzepaku podlegały odmiennym trendom. Biorąc pod uwagę cały analizowany okres, różnice w zmienności są niewielkie. W obu przypadkach wartości rozstępów są najwyższe dla okresów spadku cen rzepaku, czyli od drugiej połowy roku 2004 do początków roku

2007 i później w roku 2009. Dla obu szeregów czasowych wykryto po jednej obserwacji nietypowej przypadającej na czerwiec 2004 roku, kiedy to ceny rzepakowego drastycznie spadły. Niewielka różnica dotyczy jedynie siły oddziaływania tej obserwacji.

**Rysunek 4.14. Dekompozycja szeregu rozstępu cenowego rzepakowego i oleju rzepakowego (MM) i margaryny (MM) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

## 4.8. Rynek cukru

Analiza cen cukru obejmuje standardowy dla prowadzonej analizy okres od stycznia 1999 roku do końca 2013 roku. Podobnie jak w przypadku rynku jaj, ograniczono się do analizy zmienności dwóch cen. Pierwsza z nich to cena notowana na rynku terminowym na giełdzie w Londynie w dolarach za tonę, którą przeliczono – tak jak w przypadku cen rzepakowego – na zł/kg. Druga odnosi się do krajowych cen cukru białego kryształ w opakowaniu 1 kg. Warto wyjaśnić, że analiza cen z rynku londyńskiego jest wynikiem braku dostępu do analogicznych cen na rynku krajowym. Podobnie brak jest możliwości analizowania cen uzyskiwanych przez producenta – historyczne ceny buraków cukrowych notowane są tylko dla wybranych miesięcy. Stwarza to oczywiście szereg istotnych problemów. Ceny z rynku terminowego w Londynie oddają w istocie trendy na

rynku globalnym<sup>24</sup>. Tymczasem rynek cukru w UE uzależniony jest nie tylko od sytuacji na rynku światowym. Należy pamiętać, że prawie we wszystkich państwach rynek cukru jest chroniony i dotowany z budżetu państwa. W przypadku UE stopień ochrony krajowych producentów buraka cukrowego był przez lata na szczególnie wysokim poziomie. Dopiero niedawno przeprowadzono reformę, której najważniejszymi elementami było obniżenie kwot produkcji cukru (od sezonu 2009/10), czy obniżenie minimalnej ceny skupu buraków cukrowych. Wciąż regulacji podlega wymiana handlowa z krajami spoza UE [Hryszko, Szajner 2013]. Dodatkowo, ceny krajowe podlegały innym – choć wzorowanym na unijnych – regulacjom przed przystąpieniem Polski do UE.

W analizowanym okresie obie ceny podlegały niewielkiemu trendowi wzrostowemu. Cena z giełdy londyńskiej była bardziej stabilna, podczas gdy krajowa cena cukru na rynku detalicznym podlegała silnym wahaniom okresowym (rys. 4.15). Najwyraźniej widoczne tego typu wahania to nagły wzrost ceny cukru po przystąpieniu do UE, a także krótkookresowy wyraźny wzrost cen w I kwartale 2011 roku. W tym okresie odnotowano dynamiczne wzrosty cen cukru nie tylko na rynku krajowym, lecz również na rynku globalnym. Wiązało się to między innymi z niepewnością odnośnie wielkości podaży cukru w Brazylii (czołowy producent), ze stratami typu katastroficznego w Australii (jeden z większych eksporterów światowych) oraz perturbacjami na rynku cukru w Indiach (największy światowy konsument). Na rynku krajowym doszło dodatkowo do podwyższenia podatku VAT.

Analiza z wykorzystaniem metody X-12-ARIMA wskazała, że w przypadku cen cukru w Londynie dekompozycję należy przeprowadzić przy wykorzystaniu modelu multiplikatywnego, a cukru krajowego – addytywnego. Brak jest istotnej statystycznie sezonowości zmian cen na krajowym rynku detalicznym. Wykryto ją natomiast dla cen londyńskich, niemniej kształt i amplituda zmian sezonowych tych cen ulegały w analizowanym okresie znaczącym zmianom. Duża liczba – ponad dwudziestu – wykrytych obserwacji nietypowych cen detalicznych potwierdza niejako wnioski z analizy graficznej. Odnotowano m.in. „zmiany permanentne” dla września 1999 r. oraz kwietnia 2004 r., czy „zmianę przejściową” dla marca 2011 r.

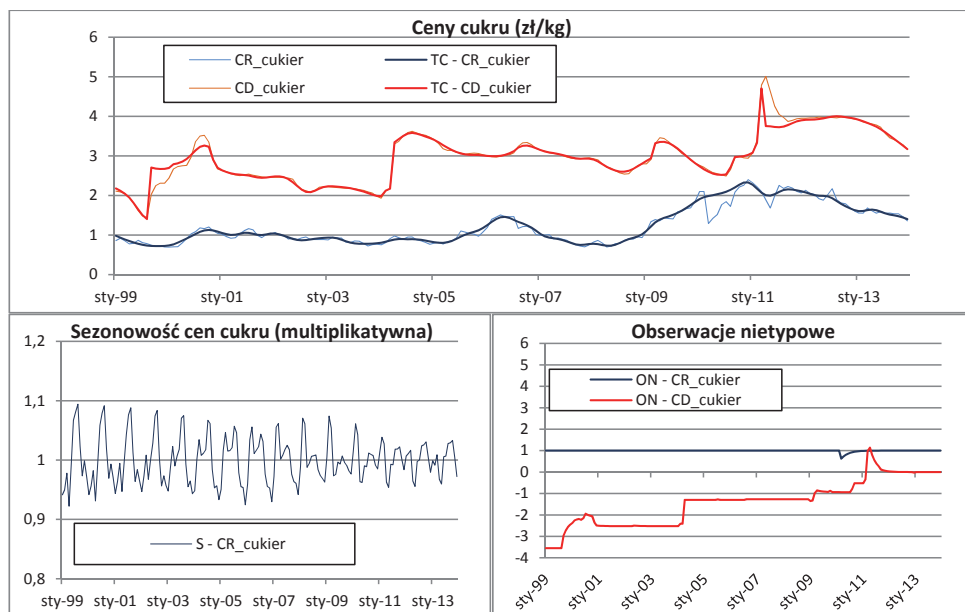
Zmienność analizowanych w tym rozdziale cen jest o tyle nietypowa, w porównaniu do wcześniej przedstawianych rynków, że to ceny detaliczne

---

<sup>24</sup> Na rynku globalnym, na którym przedmiotem handlu jest ok. 35% światowej produkcji cukru, blisko 58% wymiany handlowej dotyczy cukru surowego. Tymczasem na rynku unijnym handluje się cukrem białym po rafinacji. Różnice wynikają z braku dostępu do odpowiedniej technologii rafinacji sporej grupy państw rozwijających się, będących ważnymi eksporterami cukru [Hryszko, Szajner 2013].

cechują się wyższą zmiennością niż ceny mające przedstawiać sytuację na rynku wtórnym. Zapewne jest to w dużym stopniu wynikiem doboru danych. Ceny notowane na rynku terminowym, dotyczącym dodatkowo sytuacji na rynku globalnym, cechują się stosunkowo małą zmiennością. Niezależnie jednak od tego warto zauważyć, że detaliczne ceny cukru są bardzo zmienne tak w długim, jak i w krótkim okresie. To wszystko sprawia, że wartości rozstępu cenowego na rynku cukru – szereg przedstawiony na rysunku 4.16 – są niezwykle silnie uzależnione od zmian cen na rynku detalicznym. Widać to na przykładzie wzrostu wartości rozstępu na przełomie lat 1999/2000 czy w roku 2004. Dopiero wzrosty cen detalicznych cukru po roku 2010 nie odnajdują bezpośredniego odzwierciedlenia we wzroście wartości rozstępu, gdyż były one następstwem wzrostu cen światowych, obrazowanych przez ceny londyńskie.

**Rysunek 4.15. Dekompozycja szeregu cen cukru na giełdzie w Londynie (MM) oraz cen detalicznych cukru (MA) w latach 1999-2013**



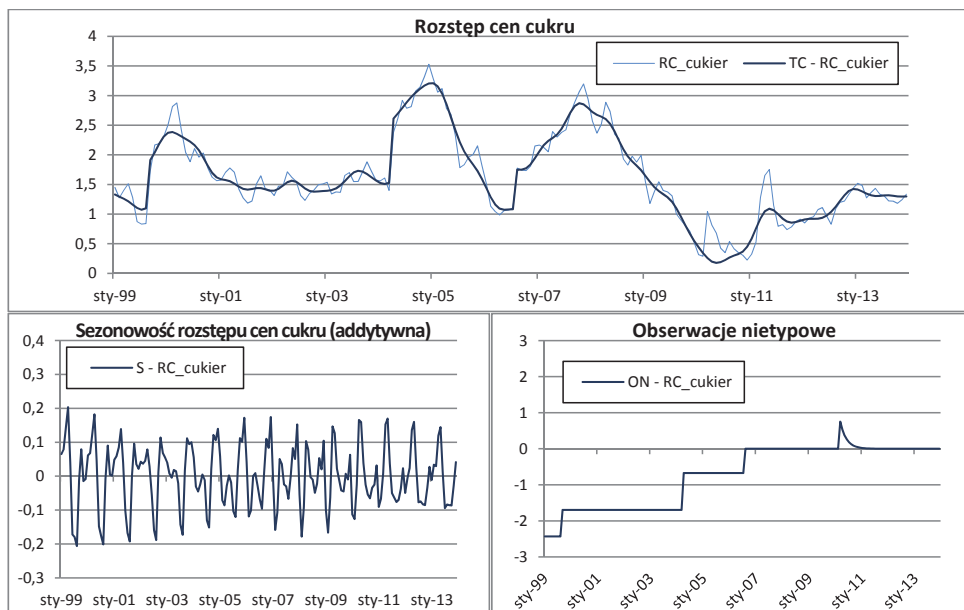
Źródło: Opracowanie własne na podstawie danych GUS.

Dekompozycji rozstępu cenowego dokonano przy użyciu modelu addytywnego. Składnik sezonowy – podobnie jak miało to miejsce w przypadku szeregu cen cukru z giełdy londyńskiej – nie ma stałego kształtu. Do roku 2006 minimum sezonowe przypada na lipiec/sierpień, natomiast w kolejnych latach jest notowane w lutym. W ostatnich dwóch latach kształt czynnika sezonowego ulega kolejnym zmianom. Procedura automatyczna wskazała na istnienie czterech obserwacji nietypowych. Pierwsze trzy to zmiany szokowe, do których doszło



we wrześniu 1999 r., kwietniu 2004 roku oraz sierpniu 2006 r. Pierwsze dwie to efekt nagłych zmian cen na rynku detalicznym. Ostatnia odzwierciedla jednoczesny spadek cen na rynku w Londynie i wzrost cen na rynku w Polsce. Ostatnia zmiana to pokłosie nagłych spadków cen na rynku detalicznym.

**Rysunek 4.16. Dekompozycja szeregu rozstępu cen na rynku cukru (MA) w latach 1999-2013**



Źródło: Opracowanie własne na podstawie danych GUS.

## 5. Prognozowanie cen detalicznych na podstawie modeli regARIMA oraz ETS

Celem rozdziału jest próba implementacji modeli regARIMA oraz modeli wygładzania wykładniczego ETS do prognozowania cen detalicznych wybranych produktów żywnościowych analizowanych w rozdziale 4. Przedstawiono wyniki estymacji tych modeli oraz wyznaczono prognozy detalicznych cen tych produktów. Dokonano także oceny *ex-post* tychże prognoz.

### 5.1. Wprowadzenie

W poprzednim rozdziale przedstawiono zmiany cen na wybranych rynkach rolnych i produktów żywnościowych. Niniejszy rozdział koncentruje się wyłącznie na cenach detalicznych żywności, a analiza prowadzona dotychczas jedynie na podstawie modeli X-12-ARIMA poszerzona zostanie o modele wygładzania wykładniczego ETS. W poprzednim rozdziale dekompozycję szeregów czasowych dokonywano przy wykorzystaniu procedury automatycznej RSA3 zawartej w programie Demetra+. W tej części opracowania głównym celem nie jest dekompozycja sama w sobie, lecz generowanie jak najtrafniejszych prognoz. Stąd wymogi stawiane przed modelami są znacząco wyższe. Z tego też powodu posłużono się tu bardziej zaawansowanym oprogramowaniem JDemetra+, które daje większe możliwości tworzenia modeli o pożądanym cechach dotyczących m.in. rozkładu składnika losowego. Dodatkowo, automatyczna procedura estymacji modeli została w przypadku wybranych szeregów czasowych cen rozszerzona o „ręczne” ingerowanie w postać modelu polegające na włączenie dodatkowych regresorów, co pozwoliło zoptymalizować statystyki reszt modeli.

Wstępna analiza przebiegu cen detalicznych została przeprowadzona już w rozdziale poprzednim. W tej części pracy zostanie ona pogłębiona. Wynika to z konieczności przybliżenia dokładniejszej charakterystyki statystycznych cech badanych szeregów czasowych, przed przeprowadzeniem procedury specyfikacji i estymacji modeli, na bazie których sporządzone zostaną prognozy.

Analizie poddano 15 szeregów czasowych cen detalicznych różnych produktów żywnościowych. Dane o cenach detalicznych żywności gromadzone są przez GUS. Baza danych GUS jest niezwykle szeroka. Przykładowo, w roku 2013 zgromadzono informacje o miesięcznym przebiegu cen 363 artykułów żywnościowych. Z uwagi na wypadanie niektórych produktów z rynku, a także pojawianie się nowych, wcześniej na nim nieobecnych, liczba stosownie długich

szeregów czasowych zawierających dane z lat 1999-2013 jest znacząco krótsza. Mimo to dobór analizowanych szeregów polegał przede wszystkim na wyselekcjonowaniu odpowiednich produktów.

Dobór szeregów cen detalicznych przeprowadzono wedle trzech głównych zasad. Pierwsza z nich stanowi, by na analizowany szereg cen surowca przypadło nie więcej niż dwa szeregi cen produktów żywnościowych. Została ona uchylona wyłącznie dla produktów mlecznych. Kolejna zasada ograniczała zbiór produktów do tych, które są stosunkowo mało przetworzone, tak by merytorycznie uzasadnione było upatrywanie przyczyn zmian ceny tego produktu w zmianie ceny surowca. Z tego też powodu, przykładowo, w grupie produktów wieprzowych znalazły się żeberka i szynka wieprzowa, a nie parówki wieprzowe, czy konserwa „turystyczna” wieprzowa. W tych dwóch ostatnich – mocniej przetworzonych – produktach udział surowca w składzie jest znacząco niższy. Dodatkowo, skład produktu może ulegać dużym zmianom wraz z wahaniami cen na rynku żywca, co dodatkowo osłabia relację pomiędzy cenami surowca rolnego a produktem żywnościowym. Trzecia zasada sprowadzała się do wyboru tych produktów, które są spożywane przez możliwie jak najszersze grono konsumentów.

Ostatecznie wybrano 15 szeregów czasowych następujących produktów żywnościowych, których skrótowe nazwy używane w dalszej części pracy podano w nawiasach: chleb żytni razowy (CD\_chleb); mąka pszenna (CD\_maka); mięso wołowe z kością – szponder (CD\_szponder); mięso wołowe bez kości z udźca (CD\_wolowe); mięso wieprzowe – żeberka (CD\_zeberka); szynka wieprzowa gotowana (CD\_szynka); kurczę patroszone (CD\_kurczak); poledwica drobiowa (CD\_poledw); mleko krowie o zawartości 3-3,5% tłuszczu o przedłużonym okresie trwałości w opakowaniu kartonowym (CD\_ml.UHT); masło o zawartości 82-82,5% tłuszczu „Extra”, świeże w kostkach 200 g (CD\_maslo); ser dojrzewający „Gouda” o zawartości 45% tłuszczu, krajowy, na wagę 1 kg (CD\_gouda); jaja świeże, z wyjątkiem małych, fermowe (CD\_jaja); olej jadalny, rzepakowy, krajowy, w butelce 1 l (CD\_olej); margaryna do smarowania pieczywa 400 g (CD\_margar); cukier biały kryształ 1 kg (CD\_cukier)<sup>25</sup>. Wszystkie ceny przeliczono w taki sposób, by odpowiadały wartości w złotych na kilogram/litr. Jedyne w przypadku jaj dotyczy to wartości w złotych za sztukę.

Podstawowe statystyki badanych szeregów przedstawiono w tabeli 5.1. Jak opisano w rozdziale 4., ceny detaliczne żywności podlegają istotnym wahanom o różnym charakterze. Obserwowany był przede wszystkim trend, w przypadku niektórych szeregów czasowych – chociażby ceny chleba, produktów

---

<sup>25</sup> Wszystkie rozszerzone nazwy produktów zaczerpnięto z terminologii stosowanej przez GUS.

z wołowiny czy produktów mleczarskich – był on bardzo silny. Brak istotnego trendu dotyczył wyłącznie cen kurcząt. W kilku przypadkach dodatni trend można zaś uznać za istotnie słabszy niż dla reszty grupy. Tak było w przypadku cen mąki, połędwicy drobiowej czy jaj. W większości przypadków istotny okazał się też czynnik sezonowy. Jak zaznaczono to w tabeli 5.1. czynnik sezonowy okazał się nieistotny dla szeregów czasowych cen szpondra, oleju, margaryny i cukru. Z kolei w przypadku drugiego z produktów z wołowiny – mięsa bez kości – składnik sezonowy okazał się istotny dopiero przy 10% poziomie istotności, stąd oznaczenie „słaba” odnoszące się do sezonowości tego szeregu.

**Tabela 5.1. Podstawowe statystyki opisowe analizowanych szeregów cen żywności w latach 1999-2013**

Skrót	Trend	Sezonowość	Zmiany struktur.	Udział spadków [%]	Udział wzrostów [%]	Średnia wartość spadku [%]	Średnia wartość wzrostu [%]
CD_chleb	dodatni	TAK	LS	15,6	57,0	-0,33	1,08
CD_maka	dodatni	TAK	LS, AO	40,8	35,8	-0,97	1,74
CD_szponder	dodatni	NIE	LS, TC	29,1	63,7	-0,34	1,13
CD_wolowe	dodatni	SŁABA	LS, TC, AO	26,8	68,7	-0,36	0,97
CD_zeberka	dodatni	TAK	TC, AO	43,0	52,0	-0,79	1,36
CD_czynka	dodatni	TAK	LS, TC	42,5	54,7	-0,56	0,82
CD_kurczak	brak	TAK	TC	49,7	49,2	-4,02	4,77
CD_poledw	dodatni	TAK	TC	44,1	49,7	-0,44	0,61
CD_ml.UHT	dodatni	TAK	LS	27,9	39,7	-0,48	0,82
CD_maslo	dodatni	TAK	LS, AO	41,9	44,1	-1,24	2,29
CD_gouda	dodatni	TAK	LS, AO	46,9	51,4	-1,10	1,70
CD_jaja	dodatni	TAK	TC, AO	25,1	23,5	-3,10	4,97
CD_olej	dodatni	NIE	LS, AO	40,2	49,2	-0,82	0,94
CD_margar	dodatni	NIE	LS, AO	34,1	44,1	-0,74	0,90
CD_cukier	dodatni	NIE	LS, TC, AO	62,0	30,7	-2,10	5,62

Źródło: obliczenia własne na podst. danych GUS.

Dekompozycja szeregów wykazała istnienie wielu różnego rodzaju zmian typu szokowego, do których najczęściej dochodziło przy okazji zmian otoczenia rynkowego, np. związanego z przystąpieniem Polski do UE. Szczegółowo omówione zostały one w rozdziale poprzednim. W tabeli 5.1. wymieniono tylko typy szoków, jakim ulegały poszczególne szeregi cen detalicznych: LS – zmiana permanentna; TC – zmiana przejściowa; AO – zdarzenie jednorazowe.

Dominujący dodatni trend odpowiada za przewagę wzrostów cen nad ich spadkami dla 11 szeregów. Spośród czterech szeregów, w których częściej

dochodziło do spadków cen niż wzrostów (CD\_maka, CD\_kurczak, CD\_jaja, CD\_cukier), tylko w przypadku danych dotyczących cen cukru liczba spadków cen występowała w ponad połowie obserwacji. Natomiast w przypadku cen jaj, najczęściej obserwowanym zjawiskiem (51,2%) było utrzymywanie się ceny z poprzedniego okresu. Stosunkowo nieliczne zmiany cen były jednak jednymi z najwyższych. Warto też zauważyć, że w przypadku każdego z szeregów, średnia procentowa wartość wzrostu przewyższa wartość średniego spadku ceny. Najwyższe średnie wzrosty dotyczą cen kurcząt (4,77%), jaj (4,97%) i cukru (5,62%), natomiast najniższe średnie wzrosty odnotowano w przypadku cen polewicy drobiowej (0,61%), szynki (0,82%), mleka (0,82%) i margaryny (0,9%). Zgodnie z oczekiwaniami, szeregi cechujące się najsilniejszym trendem – ceny chleba, produktów z wołowiny i mleczarskich – wykazują jednocześnie przewagę liczby wzrostów nad spadkami, jak i znaczącą dodatnią różnicę pomiędzy średnią wartością wzrostów i spadków cen w analizowanym okresie.

## 5.2. Estymacja modeli wygładzania wykładniczego ETS

W ramach automatycznej procedury doboru optymalnego modelu, zawartej w programie EViews 8.1, należy na początku wybrać jedno z czterech dostępnych kryteriów oceny poszczególnych modeli. Są to: kryterium informacyjne Akaikego (AIC), kryterium informacyjne Hannana-Quinna (HQ), bayesowskie kryterium Schwarzera (BIC) i błąd średniokwadratowy. W niniejszym opracowaniu przy wyborze modelu kierowano się minimalizacją kryterium Akaikego. Do estymacji wykorzystano metodę największej wiarygodności. Na parametry modeli nałożono restrykcje, dzięki którym modele pozostają stabilne<sup>26</sup>. Stosowany w dalszej części opracowania zapis konstrukcji modelu składa się z trzech elementów, gdzie pierwszy dotyczy opisu błędu w modelu, drugi trendu a ostatni sezonowości. Litera A oznacza addytywny charakter, M – multiplikatywny, zaś N – brak danego elementu w modelu. Litera D wskazuje na istnienie czynnika tłumiącego trend (szerszy opis w rozdziale 3).

Prezentacja wyników estymacji w programie EViews 8.1 obejmuje nie tylko pełną specyfikację modelu optymalnego, lecz także porównanie z modelami alternatywnymi. W dalszej części przedstawiono wybrane elementy analizy porównawczej dla modeli szeregu czasowego cen chleba żytniego.


Na rysunku 5.1. zaprezentowano wykres, który pozwala porównać różnice wartości preferowanego kryterium informacyjnego analizowanych automatycznie modeli. Można zaobserwować, że różnica pomiędzy optymalnym modelem

---

<sup>26</sup> Każdy z parametrów zawiera się w przedziale od 0 do 1, dodatkowo parametr gamma nie powinien być większy niż różnica pomiędzy jednością a parametrem alfa.

(A,AD,A), zakładającym trend addytywny z czynnikiem tłumiącym a drugim najlepszym, czyli modelem z trendem multiplikatywnym i czynnikiem tłumiącym jest niewielka. Najwyższa wartość AIC dotyczy zaś modeli nieuwzględniających trendu, gdzie błąd miał charakter multiplikatywny.

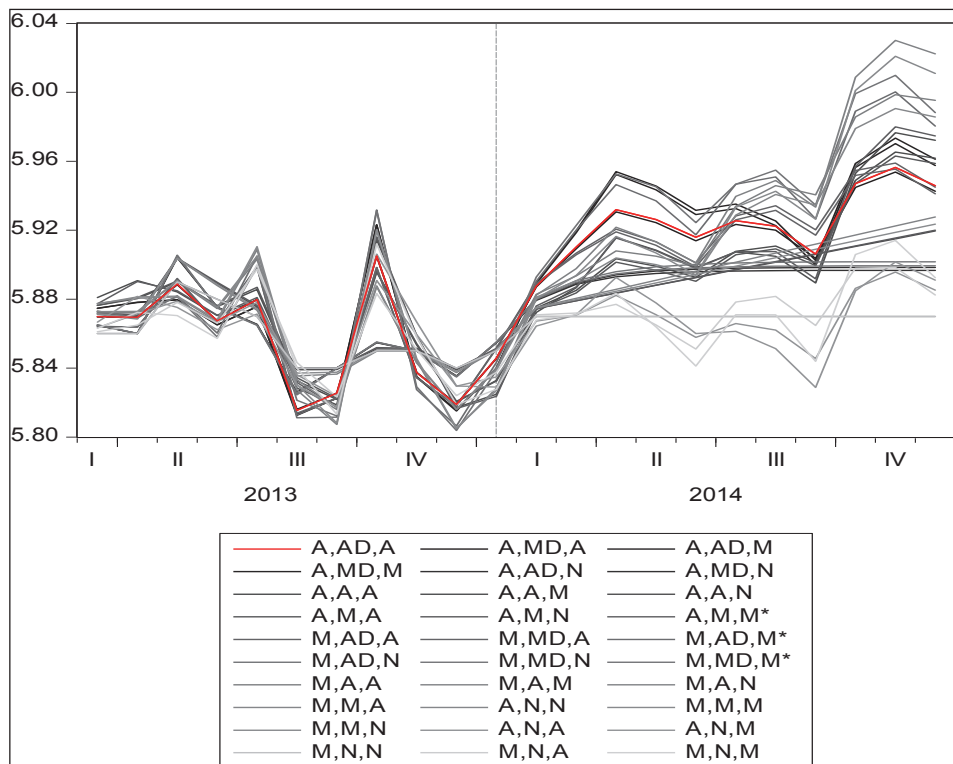
**Rysunek 5.1. Wartość AIC wybranych modeli ETS szeregu cen chleba żytniego**



Źródło: Opracowanie programu EViews 8.1 na podstawie danych GUS.

Drugim wartym przedstawienia wykresem, który oferuje program EViews 8.1, jest ten ukazujący przebieg modelowanych cen w ostatnim roku, dla którego dostępne są dane, oraz prognoz cen na rok kolejny (rys. 5.2.). Na wykresie prezentowane są modelowane i prognozowane ceny wszystkich analizowanych modeli. Ich duża liczba sprawia, że sam wykres nie pozwala w czytelny sposób przypisać przebiegu cen każdemu z modeli, poza wyróżnionym kolorem czerwonym modelem optymalnym. Niemniej kształt przebiegu cen modelowanych przez wszystkie alternatywne modele pomaga uzmysłowić sobie źródła różnic w wartościach prognozowanych cen kształtowanych przez różne grupy modeli. W szczególności dotyczy to modeli, w których brak jest trendu lub sezonowości. Czerwonym kolorem wyróżniony jest wyłącznie model optymalny, tak jak zostało to przedstawione na rys. 5.2.

**Rysunek 5.2. Modelowane i prognozowane wartości cen chleba żytniego na podstawie alternatywnych modeli wykładniczego w latach 2013-14 [zł/kg]**



Źródło: Opracowanie programu EVIEWS 8.1 na podstawie danych GUS.

Dla zdecydowanej większości szeregów czasowych optymalnymi modelami są te, które zakładają addytywny charakter błędu. Warto wspomnieć, że zazwyczaj różnica wartości AIC pomiędzy najlepszym modelem o wybranym charakterze błędu a modelem z alternatywną specyfikacją błędu była znaczna. Tylko w trzech przypadkach na piętnaście wartość parametru alfa nie równa się jedności (patrz tab. 5.2). Dodatkowo, tylko w przypadku modelu szeregu cen mleka UHT parametr alfa był znacząco niższy od 1, co oznacza, że w tym modelu prognoza poziomu nie jest całkowicie uzależniona od ostatniej obserwacji, a zależy od przeszłych prognoz.

Specyfikacja modeli w zakresie występowania i charakteru trendu wydaje się być zgodna z oczekiwaniami (tab. 5.2). Tylko w jednym modelu – dla szeregu czasowego cen kurczenia patroszonego – zakłada się brak występowania trendu. W pozostałych przypadkach, optymalny jest model z trendem, co zapewne wynika z obserwowanego wzrostu cen detalicznych żywności w analizowanych latach. Należy zauważyć, że we wszystkich tych modelach zakłada

się występowanie czynnika tłumiącego trend. Addytywny charakter trendu jest najlepszy dla 11, a multiplikatywny dla 3 szeregów czasowych. Należy jednak zauważyć, że aż w 13 przypadkach różnice wartości AIC pomiędzy modelami z multiplikatywnym a addytywnym trendem były bardzo niskie, a w 12 przypadkach model różniący się wyłącznie charakterem trendu był drugim najlepszym. Jedynie w przypadku modelu cen margaryny różnica ta była wysoka, a model z trendem addytywnym, a nie optymalnym – multiplikatywnym – dopiero czwartym w kolejności stanowiącej wartość AIC.

W połowie z rozpatrywanych modeli z trendem wartość parametru beta wynosi 1, czyli obowiązuje założenie równości ostatnio obserwowanemu trendowi z jego prognozą na kolejny okres. Nie oznacza to jednak automatycznie, że prognoza jest ściśle zależna od ostatnio obserwowanej wielkości trendu, gdyż dla każdego analizowanego szeregu czasowego jako optymalny wskazany został model z czynnikiem tłumiącym trend. Im niższa wartość współczynnika  $\phi$ , tym tłumienie trendu jest silniejsze. Trend jest więc tłumiony szczególnie mocno w przypadku modelu cen cukru ( $\phi=0,385$ ) oraz cen jaj ( $\phi=0,430$ ). Niemniej jednak nawet w tych modelach, w których wartość parametru  $\phi$  jest stosunkowo wysoka, ostatnio obserwowany trend jest szybko tłumiony. Należy bowiem pamiętać, że wartość graniczna prognozy równa się sumie poziomu i trendu, przy czym wartość trendu mnożona jest przez iloraz:  $\phi/(1-\phi)$ . Oznacza to przykładowo, że dla wartości  $\phi=0,8$  graniczna wartość prognozy, czyli przy długości prognozy biegnącej do nieskończoności, równa jest poziomowi i czterokrotności ostatnio obserwowanego trendu.

Spośród modeli, dla których wartość beta równa jest jedności, najwyższa wartość  $\phi$  występuje dla modelu cen sera Gouda ( $\phi=0,82$ ). W tym przypadku maksymalna wartość prognozy nie przekroczy sumy poziomu i 4,6-krotności ostatnio odnotowanego trendu. Generalnie należy zauważyć, że występowanie czynnika tłumiącego w każdym modelu zakładającym istnienie trendu wydaje się być zgodne z oczekiwaniami w przypadku szeregów czasowych, które podlegają silnym wahaniom cyklicznym.

W siedmiu modelach parametr beta jest mniejszy od jedności, co oznacza, że na poziom prognozowanego trendu większy wpływ mają wcześniejsze prognozy. W przypadku modeli cen mięsa wołowego i oleju rzepakowego, dla których wartość beta jest bliska 1, znaczenie wcześniejszych prognoz jest ledwie zauważalne. Na drugim krańcu są modele cen margaryny ( $\beta=0,296$ ) oraz cen polędwicy drobiowej ( $\beta=0,350$ ), gdzie inercja całego modelu jest zdecydowanie wyższa.



**Tabela 5.2. Specyfikacja wybranych modeli, oszacowane wartości parametrów oraz wartości początkowe zmiennych stanu otrzymane w wyniku zastosowania metody wykładniczego ETS**

	Wybrana postać modelu				Wartości parametrów										Wartości początkowe zmiennych stanu									
	błąd	trend	sezonowość	alfa	beta	gamma	phi	poziom	trend	s1	s2	s3	s4	s5	s6	s7	s8	s9	s10	s11	s12			
CD_maka	A	AD	M	1	1	0	0,677	1,674	-0,008	0,995	1,006	1,009	1,008	1,001	1,002	0,997	0,997	0,995	1,000	0,997	0,995			
CD_chleb	A	AD	A	1	1	0	0,540	2,162	0,022	-0,002	0,013	0,024	0,014	-0,026	-0,010	-0,006	-0,014	0,000	0,011	0,000	-0,004			
CD_szpander	A	AD	N	1	1		0,691	6,371	0,042															
CD_wolowe	A	AD	M	0,994	0,987	0,010	0,708	12,125	0,292	0,996	0,999	1,001	1,002	0,998	1,003	1,000	1,000	0,998	1,000	1,000	1,003			
CD_zeberka	A	AD	A	1	0,558	0	0,723	8,089	0,014	0,044	0,123	0,201	0,215	0,110	-0,003	-0,131	-0,170	-0,151	-0,138	-0,122	0,020			
CD_szynka	A	AD	A	1	0,404	0	0,748	16,937	0,130	0,046	0,184	0,249	0,241	0,160	0,048	-0,148	-0,209	-0,236	-0,186	-0,145	-0,004			
CD_kureczak	A	N	A	1		0		5,373		-0,530	-0,379	-0,138	0,292	0,460	0,405	0,330	0,106	-0,016	-0,057	-0,220	-0,253			
CD_poledw	A	AD	A	0,1	0,350	0	0,803	15,434	0,043	0,052	0,098	0,098	0,091	0,042	-0,013	-0,075	-0,132	-0,104	-0,082	-0,027	0,051			
CD_mlUHT	M	MD	A	0,770	0,536	0	0,829	2,074	0,999	-0,004	0,000	-0,002	-0,007	-0,012	-0,008	-0,003	0,006	0,004	0,009	0,009	0,008			
CD_maslo	M	AD	A	1	1	0	0,723	9,662	0,333	0,493	0,325	0,153	-0,114	-0,376	-0,442	-0,421	-0,396	-0,200	0,068	0,365	0,545			
CD_gouda	M	MD	A	1	1	0	0,820	12,340	0,973	0,234	0,119	-0,096	-0,363	-0,440	-0,312	-0,154	0,006	0,152	0,245	0,291	0,318			
CD_jaja	M	AD	A	1	1	0	0,430	0,310	-0,048	0,010	0,002	-0,001	-0,014	-0,018	-0,016	-0,008	0,001	0,012	0,013	0,009	0,010			
CD_olej	M	AD	M	0,983	0,930	0,006	0,802	5,264	-0,011	0,995	1,001	1,001	1,000	0,999	1,000	1,001	1,002	1,002	1,003	0,999	0,997			
CD_margar	A	MD	N	1	0,296		0,839	3,185	0,998															
CD_cukier	A	AD	N	1	1		0,385	2,162	-0,135															

Źródło: obliczenia własne na podst. danych GUS.

Tylko w trzech przypadkach za optymalny uznano model bez dodatkowego równania zmian sezonowych. Dotyczy to cen margaryny, cukru i szpondra wołowego. Z dwunastu pozostałych modeli jedynie trzy włączają do modelu sezonowość w sposób multiplikatywny – są to modele cen mąki, mięsa wołowego i oleju rzepakowego. W dwu ostatnich modelach wartość parametru  $\gamma$  jest różna od zera, co oznacza, że kształt czynnika sezonowego ulega zmianom w czasie. Są to jednak zmiany niewielkie, co wynika z niskiej wartości tego parametru ( $CD_{wołowe} - \gamma=0,01$ ;  $CD_{olej} - \gamma=0,06$ ). Pozostałe 9 modeli zakłada addytywną niezmienną sezonowość, której wartości przedstawione są po prawej stronie tabeli 5.2.

### 5.3. Specyfikacja i estymacja modeli regARIMA

W tej części przedstawione zostaną specyfikacje modeli regARIMA, które wyjaśniają zmiany cen w analizowanych szeregach czasowych wybraną grupą zmiennych objaśniających, a reszty z równania regresji estymowane są za pomocą modelu SARIMA (p,d,q)(P,D,Q). Szerzej ta klasa modeli przedstawiona jest w opracowaniu [Hamulczuk red. 2011]. Do grupy zmiennych objaśniających zalicza się tu przede wszystkim zmienne dotyczące obserwacji nietypowych (zarówno te wykrywane automatycznie jak i dodawane później ręcznie), stałą, efekty kalendarzowe i sezonowe zmienne zero-jedynkowe. Spośród wielu możliwych do wyboru efektów kalendarzowych w ramach oprogramowania JDemetra+ analizowano wpływ wyłącznie Wielkanocy. Jest to jedyne z wielu świąt, które nie może zostać włączone do specyfikacji w ramach zmiennych sezonowych (w różnych latach ma miejsce w różnych miesiącach), a którego wpływ na zmienność cen, z uwagi na wzrost popytu i działania marketingowe sieci sprzedaży, wydaje się mieć duże znaczenie w kształtowaniu cen. Zmiennymi objaśniającymi są też obserwacje nietypowe, których charakterystyka została wyjaśniona w rozdziale 4 i pierwszej części rozdziału 5<sup>27</sup>.

Wpływ tych zmiennych na kształt modelu regresji, z którego reszty estymowane są w kolejnej fazie za pomocą modelu SARIMA, zostały przedstawione w tabeli 5.3. W górnej części tabeli zamieszczona jest postać modelu oraz informacja dotycząca uwzględnienia, bądź nie, jako dodatkowego regresora, świąt wielkanocnych. W kolejnym wierszu umieszczono listę wszystkich automatycznie dobranych regresorów, a poniżej te, które zostały włączone dodatkowo poza

---

<sup>27</sup> W ramach oprogramowania JDemetra+ na etapie specyfikacji modelu badany też jest wpływ nieomawianej wcześniej obserwacji typu SO (*seasonal outlier*), działającej podobnie jak zmiana typu AO tylko wobec czynnika sezonowego. Nie została ona jednak wykryta w żadnym z analizowanych modeli.

procedurą automatyczną. Dolna część tabeli zawiera *wartości p* testów statystycznych odnoszących się do cech składnika resztowego modeli. Pierwszy wiersz – oznaczony jako normalność – przedstawia *wartość p* testu Doornika-Hansena; kolejny – „autokorelacja” – to *wartości p* testów Ljung-Boxa (LB) oraz Boxa-Pierce’a (BP) liczone dla 24 opóźnień; trzeci wiersz zawiera *wartość p* testu serii Walda-Wolfowitza na losowość reszt; czwarty wiersz – „liniowość” – to *wartości p* testów Ljung-Boxa i Boxa-Pierce’a dla kwadratów reszt liczone dla 24 opóźnień. Ostatni z testów – *out-of-sample* – to niemający szeroko rozpowszechnionej polskiej nazwy test hipotezy zakładającej, że średniookresowy błąd prognoz modelu zbliżony jest do średniej z kwadratów reszt próby. Dokładny opis powyższych testów można znaleźć w: [Gomez Maravall 2001; Maddala 2006; Lütkepohl, Krätzig 2007; Enders 2010].

Z informacji przedstawionych w tabeli 5.3 wynika, że w każdym modelu dane są różnicowane. Dodatkowo w siedmiu przypadkach różnicowane są one również sezonowo. Jedynie w modelu cen artykułów drobiowych w zróżnicowanym szeregu brak było autoregresji. W przypadku modelu cen sera gouda i margaryny rząd autoregresji wyniósł 3. Maksymalna wielkość opóźnienia średniej ruchomej dotyczy modelu cen polędwicy drobiowej.

W zaledwie jednym przypadku – dla cen oleju rzepakowego – efekt Wielkanocy okazał się statystycznie istotny. Duża jest natomiast liczba wykrytych automatycznie obserwacji nietypowych. Największa ich liczba – 11 występuje dla modelu cen chleba i 6 dla modelu cen mąki, mięsa wołowego i cukru. Z kolei dla cen żeberek, szynki, kurcząt, mleka, sera i oleju liczba tych regresorów nie przekracza 2. Pozostaje to w zgodzie z wynikami opisanymi w rozdziale 4., gdzie liczba regresorów w modelach cen produktów zbożowych, mięsa wołowego, czy cukru również była wysoka.

Listę regresorów w tabeli 5.3, zarówno tych wykrytych automatycznie, jak i dobranych ręcznie, podano nie w kolejności chronologicznej ich oddziaływania na model cen, lecz w kolejności istotności statystycznej, co uznano za ważniejszy czynnik. Niemniej ustawienie ich w kolejności chronologicznej pozwoliłoby zaobserwować, że w znaczącej większości przypadków liczba obserwacji nietypowych w modelach opisanych w tym rozdziale, jak i w rozdziale czwartym przypada na te same lub bliskie sobie okresy. Jedynym większym odstępstwem od tej zasady pozostają obserwacje nietypowe dla modelu cen masła.

**Tabela 5.3. Specyfikacja modeli regARIMA dla detalicznych cen żywności oraz wyniki testów**

Wyszczególnienie	CD_chleb	CD_maka	CD_szczynder	CD_wolowe	CD_zeberka	CD_szynka	CD_poledw	CD_kurczak
Postać modelu	(1,1,1)(0,0,0)	(2,1,0)(0,1,1)	(1,1,0)(0,0,0)	(1,1,0)(0,1,1)	(1,1,1)(0,1,1)	(2,1,0)(0,1,1)	(0,1,3)(0,0,0)	(0,1,1)(0,1,1)
Efekt Wielkanocy	nie	nie	nie	nie	nie	nie	nie	nie
Observacje niety- powe wykryte automatycznie	LS (9-2007) LS (9-2006) LS (6-2000) LS (9-2010) LS (7-2000) LS (10-2010) LS (3-2011) LS (10-2007) LS (10-2006) LS (2-2007) LS (6-2003)	LS (9-2010) LS (9-2006) AO (12-2005) LS (7-2000) TC (5-2000) TC (8-2000)	AO (7-2004) LS (6-2004) LS (5-2004) AO (8-2004)	AO (7-2004) LS (6-2004) AO (8-2000) LS (9-2004) LS (5-2004) LS (1-2011)	AO (7-2004) LS (8-1999)	AO (7-2004) LS (8-1999)	LS (7-2004) LS (6-2004) LS (7-2007)	TC (6-2004)
Regresory zdefiniowane „ręcznie”	TC (2-2011) AO (8-2009) AO (1-2000)	-	AO (1-2011) AO (8-2011) AO (8-1999) AO (12-2011) AO (9-2000) AO (7-2000)	-	AO (6-2008) AO (7-2007) AO (3-2009) AO (11-2011) AO (6-2004)	-	AO (3-2006) AO (8-1999)	AO (1-2007)
Normalność	0,707	0,4849	0,5629	0,286	0,2093	0,1134	0,1625	0,4251
Autokorelacja: LB(24) BP(24)	0,3887 0,5003	0,0814 0,1503	0,323 0,4209	0,5288 0,624	0,2027 0,3247	0,4135 0,5607	0,2397 0,3352	0,2957 0,3973
Losowość	0,7663	0,8162	0,1069	0,0675	0,4845	0,3993	0,9238	0,8191
Liniowość: LB(24) BP(24)	0,4856 0,6038	0,0123 0,0249	0,2269 0,2841	0,7804 0,832	0,0998 0,1676	0,5475 0,6659	0,9489 0,9589	0,1564 0,2538
Test out-of-sample	0,7058	0,9956	0,9065	0,933	0,5316	0,5452	0,376	0,9998

statystyki dla reszt (wartości p):

**Tabela 5.3. Specyfikacja modeli regARIMA dla detalicznych cen żywności oraz wyniki testów cd.**

	CD_ml.UHT (2,1,0)(0,1,1)	CD_gouda (3,1,0)(0,0,0)	CD_maslo (2,1,1)(0,0,0)	CD_jajka (2,1,0)(0,1,1)	CD_olej (1,1,0)(0,0,0)	CD_margar (3,1,0)(0,0,0)	CD_cukier (2,1,0)(0,0,0)
Wyszczególnienie postać modelu	nie	nie	nie	nie	tak	Nie	nie
Wielkanoc							
Observacje nietypowe wykryte automatycznie	AO(2-2011) LS(9-2007)	LS(10-2003) TC(9-2009)	LS(6-2004) LS(9-2007) LS(11-2009) LS(9-1999) TC(1-2000)	LS(3-2012) TC(4-2012) LS(10-2003) LS(12-1999) LS(8-2000)	AO(11-2010)	LS(1-2001) LS(4-2004) TC(4-2006) LS(7-2008) AO(4-2008)	LS(4-2004) LS(9-1999) LS(3-2011) LS(2-2004) LS(3-2009) LS(11-2000)
Regresory zdefiniowane ręcznie	-	AO(8-2007) AO(9-2007) AO(7-2007) TC(6-2007)	TC(12-1999) TC(8-1999)	AO(9-2003)	TC(2-2011) AO(3-2008) TC(9-2003)	AO(3-2006) AO(3-2008)	-
statystyki dla reszt (wartości p):							
Normalność	0,0058	0,0525	0,0804	0,7737	0,0876	0,8575	0,0000
Autokorelacja: LB(24) BP(24)	0,0618 0,1174	0,6264 0,7296	0,143 0,2276	0,2311 0,3495	0,2601 0,3759	0,0858 0,1549	0,3025 0,4032
Losowość	0,0392	0,6609	0,34	0,3148	0,2456	0,2027	0,0475
Limowość: LB(24) BP(24)	0,6238 0,7050	0,4619 0,5392	0,0021 0,0040	0,2103 0,3110	0,0667 0,0981	0,0001 0,0005	0,0000 0,0000
Test out-of-sample	0,0040	0,7673	0,1032	0,9885	0,6079	0,2661	0,9992

Źródło: obliczenia własne na podstawie danych GUS.

Jedyna istotna różnica dotyczy liczby obserwacji nietypowych dla modelu cen żeberek wieprzowych, która przy procedurze automatycznej w programie JDemetra+ wyniosła jedynie 2, podczas gdy uprzednio było ich 5. W tym jednak przypadku duża jest liczba dodatkowych regresorów zdefiniowanych poza procedurą automatyczną. Warto w tym miejscu wyjaśnić, czym kierowano się przy doborze tych zmiennych objaśniających. Z uwagi na fakt, że specyfikacja i estymacja modeli regARIMA służy tu w pierwszym rzędzie generowaniu prognoz, starano się uniknąć sytuacji, w której rozkład reszt z modelu nie miałby cech rozkładu normalnego. Dotyczyło to, oprócz zaprezentowanej w tabeli *wartości p* testu na normalność składnika resztowego, także nieumieszczonego powyżej wyniku testu dotyczącego zbieżności skośności badanych rozkładów z rozkładem normalnym.

Dla zobrazowania tej procedury, a także w celu przybliżenia graficznej prezentacji wyników w programie JDemetra+ przedstawiony zostanie przykład modelu cen jaj. *Wartości p* testu na normalność reszt zaraz po automatycznej procedurze obserwacji nietypowych oraz po doborze dodatkowego regresora przedstawiono w tabeli 5.4. „Ręczne” zdefiniowanie dodatkowego regresora znacząco zbliżyło rozkład reszt do rozkładu normalnego, co było głównym celem tych działań. Oczywiście, nie oznacza to, że procedura automatyczna jest niedoskonała i wymaga ciągłej kontroli i dostosowań ze strony użytkującego program. Algorytm optymalizuje po prostu inne cechy modelu niż te, które w danym momencie były dla nas istotne.


**Tabela 5.4. Wartość p testów na normalność rozkładu reszt modelu cen jaj**

Wyszczególnienie	Model automatyczny	Model z dodatkowym regresorem
Postać modelu	(3,1,1)(0,0,0)	(2,1,0)(0,1,1)
Średnia	0,8047	0,9295
Skośność	0,0936	0,5791
Kurtoza	0,0032	0,9401
Normalność	0,0095	0,7737

*Źródło: obliczenia własne na podst. danych GUS.*


Należy również dodać, że sam dobór dodatkowych regresorów jest procedurą żmudną i nie zawsze przynoszącą oczekiwane rezultaty. W analizowanym przypadku skorzystano z informacji wynikających z histogramu składnika resztowego, który wskazywał na istnienie zbyt dużej liczby reszt o wysokiej wartości (prawa strona histogramu – ponad czerwoną linią przedstawiającą wykres rozkładu normalnego). Histogram rozkładu reszt dla automatycznie wyspecyfikowanego modelu cen jaj (lewa strona), a także modelu z dodatkową zmienną objaśniającą (prawa strona) przedstawiono na rysunku 5.3.

**Rysunek 5.3. Histogram reszt automatycznie wskazanego (lewa strona) oraz zmodyfikowanego (prawa strona) modelu cen jaj**



Źródło: wydruk z programu *JDemetra+* na podstawie danych GUS.

**Rysunek 5.4. Rozkład reszt w automatycznie dobranym modelu cen jaj**



Źródło: wydruk z programu *JDemetra+* na podstawie danych GUS.

Kolejnym etapem jest wskazanie, w którym miejscu szeregu czasowego należałoby wstawić dodatkową zmienną objaśniającą tak, by rozkład reszt z nowego modelu w większym stopniu przypominał reszty rozkładu normalnego. Pomocny jest tu wykres przedstawiający wartości wszystkich reszt. Warto w tym miejscu dodać, że nie zawsze najbardziej oczywisty wybór wartości maksymalnie oddalonej od średniej jest wyborem trafnym. Istotną kwestią pozostaje też typ regresora – czy ma to być zmiana przejściowa, zdarzenie jednorazowe, czy inny. Należy pamiętać, że dodatkowa zmienna w istotny sposób wpływa na wartości wszystkich reszt. Ponadto estymacja parametrów przy wskazanym regresorze może wpłynąć na składnik resztowy

w sposób odmienny od planowanego przez prognostę. Rozkład wartości reszt dla modelu cen jaj zaprezentowano na rysunku 5.4.

W analizowanym przypadku dobór dodatkowego regresora typu zdarzenie jednorazowe w marcu 2009 roku korzystnie wpłynęło na cechy składnika resztowego, jednak w przypadku innych modeli dobór był znacznie trudniejszy. Przykładowo, dla modelu cen szpondra wołowego zdefiniowano aż sześć nowych regresorów, a dla żeberek wieprzowych – pięć, zanim rozkłady reszt uzyskały odpowiednie cechy. Za każdym razem dbano o to, by regresory były statystycznie istotne i by ich liczba była możliwie jak najmniejsza. Ręczne dodawanie zmiennych objaśniających nie w każdym przypadku przynosiło oczekiwane efekty. Przykładowo, dla modelu cen sera, masła i oleju *wartość p* testu Doornika-Hansena pozostała na niskim poziomie, a w przypadku cen mleka i cukru, nawet dobór dużej ilości dodatkowych regresorów nie przynosił poprawy cech rozkładu reszt.

Zawarte w tabeli 5.3 informacje dotyczące *wartości p* przeprowadzonych testów wskazują wyraźnie, że w przypadku większości modeli można mówić o normalności reszt. Brak normalności dotyczy zaś modeli cen produktów mleczarskich oraz cukru. W przypadku modeli cen mąki, mleka i margaryny zachodzi też wysokie ryzyko występowania autokorelacji w resztach.

Większość modeli – poza modelem cen mleka i cukru – cechuje się wysoką *wartością p* testu serii Walda-Wolfowitza. Niepożądane są też niskie *wartości p* testu liniowości reszt. Brak liniowości wpływa niekorzystnie na trafność prognoz. Z sytuacją taką mamy do czynienia w modelach cen masła, margaryny i cukru. Brak liniowości może być też przejawem heteroskedastyczności składnika losowego, czyli występowania okresów podwyższonej zmienności. Jest to typowe zjawisko w szeregach czasowych instrumentów notowanych na giełdach. Również w szeregach czasowych cen surowców rolnych mamy często do czynienia z grupowaniem zmienności. Warto dodać, że im większa częstotliwość analizowanych danych, tym większe prawdopodobieństwo wykrycia tego zjawiska.

Ogólna ocena jakości modeli cen analizowanych produktów żywnościowych jest raczej pozytywna. W szczególności dotyczy to modeli cen produktów zbożowych, mięsnych i jaj. W przypadku modeli cen sera, masła, margaryny i oleju pewne niewielkie niedoskonałości nie wpływają na całościową pozytywną ocenę. Istotne problemy z właściwym dopasowaniem modelu wystąpiły zaś w przypadku szeregów czasowych cen mleka UHT i cukru.




## 5.4. Dokładność prognoz

Ostatni podrozdział poświęcony jest prezentacji prognoz wygenerowanych przez omówione wcześniej modele, a także ocenie *ex post* tychże prognoz. W przypadku każdego z analizowanych szeregów czasowych cen detalicznych produktów żywnościowych, mamy do czynienia z dwoma alternatywnymi prognozami. Pierwsza z nich stworzona została na bazie modelu wygładzania wykładniczego, druga – modelu regARIMA. Estymacja modeli została wykonana na podstawie wyjściowych szeregów czasowych obejmujących okres od I 1999 do XII 2013. Następnie, przy wykorzystaniu powyższych modeli wygenerowano prognozy, których horyzont wynosił od 1 do 12 miesięcy. Dodatkowo, w celu weryfikacji trafności prognoz uzupełniono wyjściowe dane o 6 obserwacji miesięcznych z I połowy 2014 roku.

Analiza trafności prognoz *ex post* polegała na porównaniu faktycznie obserwowanych cen w I połowie 2014 roku z prognozami generowanymi przez badane modele. Należy w tym miejscu wyraźnie zastrzec, że ocena trafności prognoz wygasłych z tak krótkiego okresu nie może być podstawą do definitywnego stwierdzenia przewagi któregośkolwiek z modeli pod względem możliwości prognostycznych. Jest to jedynie przykład możliwości konfrontacji prognoz z danymi rzeczywistymi. Warto w tym miejscu zaznaczyć, że standardowa procedura zawarta w pakiecie statystycznym JDemetra+ obejmuje prognozy przedziałowe (95% przedział ufności), których przykładowe wartości dla modelu cen mąki oraz sposób prezentacji przedstawiono na rysunku 5.5.


**Rysunek 5.5. Ceny detaliczne mąki [zł/kg] w okresie I 2011-XII 2013 wraz z prognozami na rok 2014**



Źródło: Opracowanie programu JDemetra+ na podstawie danych GUS.

Z uwagi na przejrzystość opracowania w dalszej części rozdziału ograniczymy się do oceny prognoz punktowych. Prognozy cen produktów zbożowych generowane przez oba analizowane modele przedstawiono na rysunku 5.6. Wiadac wyraźnie, że w przypadku obu produktów wartość prognoz modelu ETS jest niższa, co wynika między innymi z istnienia czynnika tłumiącego trend. Dodatkowo, w przypadku cen chleba prognozy modelu regARIMA nie zakładają zmian o charakterze sezonowym, co sprawia, że szczególnie dla cen w drugiej połowie roku różnice pomiędzy prognozami różnią się znacznie. Trafność prognoz cen chleba pochodzących z obu modeli w badanym okresie była zbliżona do siebie. W przypadku cen mąki błędy prognoz modelu ETS były znacząco mniejsze. Dla każdej z prognoz cen detalicznych produktów zbożowych mamy do czynienia z przeszacowaniem. Szczegółowe dane dotyczące wartości błędów prognoz wygasłych omówiono pod koniec tej części pracy i przedstawiono w tabeli 5.5.


**Rysunek 5.6. Ceny detaliczne produktów zbożowych [zł/kg] w okresie I 2012-VI 2014 i prognozy na rok 2014**



Źródło: Opracowanie własne na podstawie danych GUS.

Brak sezonowości w prognozach cen szpandra obu modeli, a także bliski zeru trend dla modelu ETS upodabniają obie prognozy do prognoz naiwnych. W przypadku cen mięsa wołowego również brak jest większych różnic wartości prognoz dla pierwszej połowy 2014 roku. Stąd też wartości błędów prognoz wygasłych generowanych przez oba modele przyjmują podobne wartości. Minimalnie trafniejsze okazały się prognozy modelu regARIMA. Wszystkie prognozy cen detalicznych produktów z wołowiny są przeszacowane (rys. 5.7).


**Rysunek 5.7. Ceny detaliczne produktów z wołowiny [zł/kg]  
w okresie I 2012-VI 2014 i prognozy na rok 2014**



Źródło: Opracowanie własne na podstawie danych GUS.

Wartości każdej z prognoz cen detalicznych produktów wieprzowych wskazywały na przejście od trendu spadkowego ku wzrostowemu (rys. 5.8). Ceny żeberka spadły jednak w wyniku utrudnień w handlu z Rosją już w pierwszych miesiącach 2014 r., co znacznie obniżyło trafność prognoz. Ceny szynki, czyli produktu bardziej przetworzonego, reagującego z opóźnieniem na zmiany cen surowca, spadły dopiero pod koniec II kwartału 2014 r., dzięki czemu wartości błędów prognoz są tu bardzo niskie. Podobnie jak dla dotychczas omawianych cen, różnice pomiędzy prognozami obu modeli są raczej niewielkie. Dla cen żeberka trafniejsze okazały się prognozy modelu ETS, dla cen szynki wieprzowej – modelu regARIMA.


**Rysunek 5.8. Ceny detaliczne produktów wieprzowych [zł/kg]  
w okresie I 2012-VI 2014 i prognozy na rok 2014**



Źródło: Opracowanie własne na podstawie danych GUS.

Różnice pomiędzy wartościami prognoz cen produktów drobiowych (rys. 5.9) generowanych przez oba modele są nieznaczne. W przypadku cen kurczęcia patroszonego trafnie prognozowano wzrostowy cykl cen. Natomiast wartości prognoz cen polędwicy wskazywały na spadek cen, do którego faktycznie nie doszło. Trafnie prognozowano natomiast moment wzrostu cen pod koniec II kwartału 2014 r. Wartości MAPE wskazują na minimalną większą trafność prognoz modelu ETS.

**Rysunek 5.9. Ceny detaliczne produktów drobiowych [zł/kg] w okresie I 2012-VI 2014 i prognozy na rok 2014**

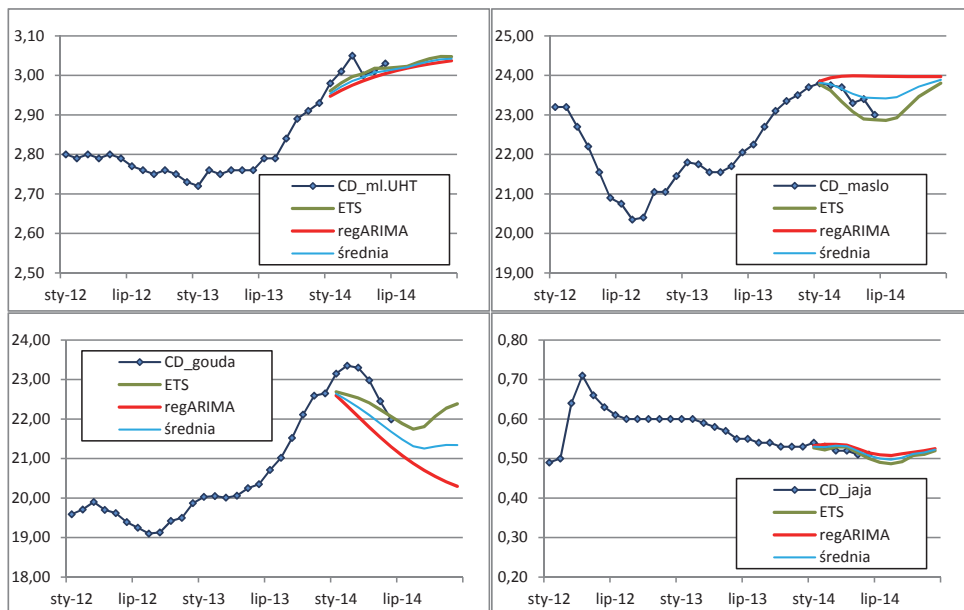


Źródło: Opracowanie własne na podstawie danych GUS.

Na rysunku 5.10 przedstawiono wartości prognoz cen detalicznych produktów mleczarskich i jaj. Prognozy cen mleka UHT i jaj obu modeli pozostają ze sobą zbieżne – zakładana jest kontynuacja trendu na poziomie obserwowanym w poprzednich miesiącach. Za ciekawsze uznać należy różnice w wartościach prognoz cen masła. Prognozy uzyskane na podstawie modelu regARIMA wskazują na stabilizację cen, podczas gdy te uzyskane na podstawie modelu ETS trafnie sygnalizują odwrócenie trendu. Dla cen masła oraz cen jaj mamy do czynienia z jedynymi dwoma przykładami przewagi prognoz będących wypadkową tych z obu analizowanych modeli. Na zmianę trendu wskazują również prognozy cen sera Gouda, przy czym prognozy z modelu regARIMA wskazują na mocniejszą tendencję spadkową cen. Do spadków cen doszło zaś dopiero po trzech miesiącach, co spowodowało niższe wartości błędów prognoz tworzonych na podstawie modelu ETS.


Przedstawione na rysunku 5.11 uzyskane z obu modeli wartości prognoz cen oleju rzepakowego i margaryny nie różnią się między sobą znacznie, co implikuje niskie różnice w wartości błędów prognoz. Dla obu cen minimalnie trafniejsze okazały się prognozy generowane przez model ETS.

**Rysunek 5.10. Ceny detaliczne produktów mleczarskich [zł/kg] i jaj [zł/szt] w okresie I 2012-VI 2014 i prognozy na rok 2014**



Źródło: Opracowanie własne na podstawie danych GUS.


**Rysunek 5.11. Ceny detaliczne oleju rzepakowego i margaryny [zł/kg] w okresie I 2012-VI 2014 i prognozy na rok 2014**



Źródło: Opracowanie własne na podstawie danych GUS.

Najmniej trafnymi okazały się prognozy cen detalicznych cukru. Ich wartości dla obu modeli wskazywały na zatrzymanie spadkowego trendu i ustabilizowanie się cen na poziomie ok 3,2 zł/kg. Tymczasem w I połowie 2014 roku doszło do dalszego obniżenia się cen. Z tego też powodu wartość błędów prognoz wygasłych cen detalicznych cukru dla obu modeli okazała się wysoka.

**Rysunek 5.12. Ceny detaliczne cukru [zł/litr]  
w okresie I 2012-VI 2014 i prognozy na rok 2014**



Źródło: Opracowanie własne na podstawie danych GUS.

W tabeli 5.5 zawarto dane dotyczące wartości prognoz wygasłych analizowanych cen detalicznych. Dla każdej ceny podano wartości trzech miar błędów prognoz wygasłych dla trzech prognoz: uzyskanych na podstawie modelu ETS, uzyskanych na podstawie modelu regARIMA i wartości średniej tych dwóch prognoz. Pierwszym miernikiem jest średni błąd prognoz (*mean error* – ME) określony wzorem  $ME = (\sum(Y_t - \hat{Y}_t)) / n$ , gdzie  $Y_t$  jest rzeczywistą wartością zmiennej w czasie  $t$ ,  $\hat{Y}_t$  – prognozowaną wartością zmiennej w czasie  $t$ , a  $n$  – horyzontem prognozy. Średni absolutny błąd prognoz (*mean absolute error* – MAE) dany jest wzorem  $MAE = (\sum |Y_t - \hat{Y}_t|) / n$ , natomiast średni absolutny błąd procentowy (*mean absolute percentage error* – MAPE) definiowany jest następująco:  $MAPE = (\sum (|Y_t - \hat{Y}_t| / Y_t)) / n$  [Cieślak 2005].

Ujemna wartość błędu ME wskazuje na przeszacowanie prognozy. Miało to miejsce dla prognoz 8 szeregów cen. Czterokrotnie prognozy uzyskane z obu modeli były niedoszacowane. Natomiast w przypadku cen masła, szynki i jaj prognozy uzyskane z modelu ETS były przeszacowane, zaś te uzyskane z modelu regARIMA były niedoszacowane. Najniższe wartości błędów prognoz *ex post* MAE dotyczą cen jaj. Wynika to jednak między innymi z niskiego poziomu tych cen. Błędy liczone wielkością MAPE wskazują, że najtrafniejsze były prognozy cen szynki wieprzowej i szpondra wołowego. Są to dwa z trzech przypadków (trzecim są ceny cukru) w przypadku których prognozy uzyskane z modelu regARIMA okazały się trafniejsze niż te generowane przez model ETS.

**Tabela 5.5. Wartość błędów prognoz wygasłych dla analizowanych modeli cen detalicznych produktów żywnościowych**

.Model	ETS	ARIMA	średnia	ETS	ARIMA	średnia	ETS	ARIMA	średnia
zmienna	CD_chleb			CD_maka			CD_szponder		
ME	-0,078	-0,077	-0,078	-0,019	-0,042	-0,03	-0,16	-0,129	-0,144
MAE	0,078	0,077	0,078	0,022	0,042	0,03	0,16	0,129	0,144
MAPE	1,34	1,33	1,33	0,89	1,74	1,25	0,85	0,68	0,77
zmienna	CD_wolowe			CD_zeberka			CD_szynka		
ME	-0,483	-0,473	-0,478	-0,232	-0,356	-0,294	0,017	-0,022	-0,002
MAE	0,485	0,478	0,482	0,232	0,356	0,294	0,099	0,083	0,091
MAPE	1,47	1,44	1,45	1,54	2,37	1,96	0,41	0,34	0,37
zmienna	CD_kurczak			CD_poledw			CD_ml.UHT		
ME	-0,079	-0,124	-0,101	0,167	0,189	0,178	0,017	0,035	0,026
MAE	0,117	0,133	0,125	0,167	0,189	0,178	0,021	0,035	0,026
MAPE	1,59	1,8	1,69	0,89	1,01	0,95	0,69	1,15	0,85
zmienna	CD_maslo			CD_gouda			CD_jaja		
ME	0,228	-0,461	-0,117	0,445	0,932	0,689	0,001	-0,008	-0,003
MAE	0,228	0,461	0,131	0,468	0,932	0,689	0,009	0,01	0,008
MAPE	0,97	1,98	0,57	2,02	4,07	2,99	1,7	1,97	1,51
zmienna	CD_olej			CD_margar			CD_cukier		
ME	0,112	0,151	0,132	-0,032	-0,046	-0,039	-0,444	-0,321	-0,382
MAE	0,112	0,151	0,132	0,046	0,053	0,049	0,444	0,329	0,385
MAPE	1,71	2,32	2,02	0,45	0,53	0,48	16,94	12,59	14,71

Źródło: obliczenia własne na podst. danych GUS.

Podsumowując, na piętnaście prognozowanych zmiennych w 10 przypadkach trafniejsze okazały się prognozy uzyskane z modelu ETS, dla dwóch przypadków różnice były bliskie zera i tylko w trzech przypadkach model regARIMA generował trafniejsze prognozy. Należy jednak zaznaczyć, że tylko w przypadku cen masła i sera goudy różnice pomiędzy prognozami uzyskanymi z obu modeli były znaczące.

## 6. Prognozowanie cen detalicznych na podstawie zależności przyczynowo-skutkowych

W niniejszym rozdziale przedstawimy ważniejsze problemy prognozowania cen detalicznych wybranych produktów żywnościowych na podstawie modeli opartych na zależnościach przyczynowo-skutkowych. Ogólne koncepcje dotyczące tych zagadnień zostały opisane w rozdziale 3.1. Tutaj przybliżymy problemy analizy empirycznej związanej ze specyfikacją wybranych modeli ekonometrycznych oraz prognozowania na ich podstawie.

### 6.1. Szeregi czasowe oraz ich właściwości


Prognozując ceny detaliczne produktów rolnych zastosowano kilka alternatywnych koncepcji. Punktem wyjścia jest model popytowo-podażowy, w którym cena detaliczna (CD) jest wynikiem równowagi rynkowej. Zatem wśród zmiennych, obok cen detalicznych, są zmienne reprezentujące stronę popytową oraz stronę podażową (kosztową). Reprezentantem możliwości zakupowych konsumentów są przeciętne wynagrodzenia brutto w sektorze przedsiębiorstw ogółem ( $M_{\text{wynagrodz}}$ ). Zmienna ta również reprezentuje stronę kosztową, ponieważ wynagrodzenia są istotnym elementem marży marketingowej. Inną możliwością jest przyjęcie miesięcznych skorygowanych sezonowo i zdetrendyzowanych wskaźników koniunktury wg OECD. Wśród zmiennych reprezentujących stronę kosztową będą ceny surowców rolnych (CR) oraz ceny innych zmiennych o charakterze makroekonomicznym lub sektorowym takich jak ceny energii ( $M_{\text{energia}}$ ) czy ceny oleju napędowego ( $M_{\text{olej.n}}$ ). W ostatnich latach szczególnie podkreśla się rosnący wpływ cen energii na ceny surowców rolnych i ceny żywności [Abbott i in. 2011, Irz i in. 2013]. Oczywiście można byłoby ten zestaw zmiennych rozszerzyć o inne, natomiast może to stwarzać dodatkowe kłopoty związane ze specyfikacją i estymacją modeli. Dynamikę zmiennych makroekonomicznych przedstawiono na rys 6.1, w postaci indeksów jednopodstawowych.

Niniejsza analiza dotyczy wybranych produktów będących reprezentantami trzech grup: pieczywa i produktów zbożowych, mięsa oraz mleka i produktów mlecznych. Wydatki na te trzy grupy produktowe stanowią ponad 60% wydatków na żywność w gospodarstwach domowych w Polsce (por rozdz. 1.4). Podjęto próbę wykonania modeli i prognoz dla następujących produktów (ceny za 1 kg, oprócz masła i mleka): chleb żytni razowy (CD\_chleb), mąka pszenna (CD\_maka), szponder wołowy (CD\_szponder), szynka wieprzowa gotowana (CD\_szynka), kurczę patroszone (CD\_kurczak), mleko płynne UHT o zawartości tłuszczu 3,0-3,5% za



1 litr (CD\_ml.UHT), masło o zawartości tłuszczu 82% w kostce 200g (CD\_maslo). Należy zwrócić uwagę, że są to produkty o różnym stopniu przetworzenia, stąd wnioski pochodzące z analizy można w pewnym stopniu uogólnić na inne produkty spożywcze nie będące przedmiotem analiz.

**Rysunek 6.1. Dynamika zmian wynagrodzeń oraz cen oleju napędowego i energii**



Źródło: Opracowanie własne na podstawie danych GUS.

W analizach wykorzystano również ceny surowców rolnych, które stanowią podstawę dla wyrobu wyżej wymienionych produktów żywnościowych. Powinny one w znaczącym stopniu determinować cen detaliczną. Dla poszczególnych surowców rolnych przyjęto następujące oznaczenia: ceny skupu pszenicy (CR\_pszenica), ceny skupu żyta (CR\_zyto), ceny skupu żywca wołowego (CR\_wołowina), ceny skupu żywca wieprzowego (CR\_wieprzowina), ceny skupu żywca drobiowego (CR\_drob), ceny skupu mleka (CR\_mleko). Ceny żywca były wyrażone w zł/1 kg, ceny zbóż w zł/100 kg zaś ceny mleka w zł/1 litr. Analiza dynamiki tych zmiennych została przeprowadzona w rozdziale 4, gdzie zamieszczono wykresy dotyczące kształtowania się w latach 1999-2013 wartości rozważanych tu cech.

Analizowany okres obejmuje 14 lat od stycznia 1999 roku do grudnia 2013 r. Wstępna analiza cen rolnych i cen detalicznych została przedstawiona w rozdziale 4. Wskazuje ona, że szeregi czasowe cen surowców rolnych oraz cen detalicznych charakteryzują się złożoną strukturą. Największy udział w zmienności całkowitej ma składnik trendo-cykliczny. Wahania sezonowe mają mniejsze znaczenie, ale w większości przypadków są statystycznie istotne. To co należy podkreślić, to duże prawdopodobieństwo pojawiania się wartości nietypowych w szeregach czasowych.

**Tabela 6.1. Wyniki testów ADF dla analizowanych szeregów czasowych**

Zmienna	opóźnienia	model	tau	p-value	model	tau	p-value
<u>l</u> _CR_pszen	2	c	-2,017	0,280	c+t	-2,602	0,279
<u>d</u> _l_CR_pszen	3	bez	-5,837	0,000	c	-3,955	0,002
<u>l</u> _CR_zyto	2	c	-2,048	0,267	c+t	-2,410	0,374
<u>d</u> _l_CR_zyto	3	bez	-5,551	0,000	c	-3,724	0,004
<u>l</u> _CR_bydlo	6	c	-0,702	0,845	c+t	-2,510	0,323
<u>d</u> _l_CR_bydlo	9	bez	-3,366	0,001	c	-6,332	0,000
<u>l</u> _CR_trzoda	1	c	-1,555	0,506	c+t	-2,214	0,481
<u>d</u> _l_CR_trzoda	2	bez	-6,722	0,000	c	-3,023	0,033
<u>l</u> _CR_drob	7	c	-1,141	0,702	c+t	-2,815	0,192
<u>d</u> _l_CR_drob	1	bez	-8,174	0,000	c	-3,914	0,002
<u>l</u> _CR_mleko	8	c	-1,079	0,727	c+t	-3,179	0,089
<u>d</u> _l_CR_mleko	10	bez	-2,667	0,007	c	-4,006	0,001
<u>l</u> _CD_chleb	1	c	-1,313	0,626	c+t	-2,195	0,492
<u>d</u> _l_CD_chleb	7	bez	-2,796	0,005	c	-3,807	0,003
<u>l</u> _CD_maka	2	c	-1,064	0,732	c+t	-2,497	0,330
<u>l</u> _CD_maka	3	bez	-4,236	0,000	c	-4,319	0,000
<u>l</u> _CD_szponder	2	c	-0,688	0,848	c+t	-2,568	0,295
<u>d</u> _l_CD_szponder	9	bez	-2,913	0,003	c	-5,486	0,000
<u>l</u> _CD_szynka	1	c	-0,966	0,767	c+t	-1,995	0,604
<u>d</u> _l_CD_szynka	10	bez	-2,509	0,012	c	-2,919	0,043
<u>l</u> _CD_kurczak	5	c	-1,385	0,592	c+t	-2,348	0,407
<u>d</u> _l_CD_kurczak	1	bez	-9,358	0,000	c	-10,628	0,000
<u>l</u> _CD_ml_UHT	1	c	-0,839	0,808	c+t	-1,991	0,606
<u>d</u> _l_CD_ml_UHT	3	bez	-3,418	0,001	c	-3,601	0,006
<u>l</u> _CD_maslo	10	c	-0,724	0,839	c+t	-3,168	0,091
<u>d</u> _l_CD_maslo	1	bez	-6,314	0,000	c	-6,125	0,000
<u>l</u> _M_wynagr.	10	c	-0,894	0,791	c+t	-2,288	0,440
<u>d</u> _l_M_wynagr.	1	bez	-17,237	0,000	c	-3,145	0,023
<u>l</u> _M_olej_n	2	c	-2,383	0,147	c+t	-3,527	0,037
<u>d</u> _l_M_olej_n	10	bez	-3,949	0,000	c	-7,783	0,000
<u>l</u> _M_energia	4	c	-1,142	0,702	c+t	-2,222	0,477
<u>d</u> _l_M_energia	10	bez	-2,242	0,024	c	-5,859	0,000

Specyfikacja modeli: *bez* – bez wyrazu wolnego i stałej, *c* – z wyrazem wolnym, *c+t* – z wyrazem wolnym i trendem.

*Źródło: obliczenia własne na podstawie danych GUS.*

W rozdziale 4 nie przeprowadzono analizy stacjonarności poszczególnych zmiennych. Fakt, że w modelach regARIMA przedstawionych w rozdziale 5 istniała konieczność różnicowania zmiennych wskazuje na występowanie pierwiastka jednostkowego. W tabeli 6.1 zawarto wyniki testowania pierwiastka jednostkowego z wykorzystaniem rozszerzonego testu Dickeya-Fullera (ADF). Badania przeprowadzono dla całej próby na danych logarytmowanych, z uwagi na fakt, że tak przekształcone zmienne są podstawą szacowania modeli w dalszej części.

Również w przypadku zmiennych z wahaniami sezonowymi (większość) do modeli włączano sezonowe zmienne zero-jedynkowe. Liczbę opóźnień dobrano na podstawie zmodyfikowanego kryterium Akaikiego (AICC) [szerzej na temat Hamulczuk (red.). 2011, rodz. 2].

W świetle uzyskanych wyników (tab. 6.1) nie można odrzucić hipotezy zerowej stanowiącej, że poziomy szeregi czasowych są niestacjonarne. Jedynie w przypadku szeregu czasowego oleju napędowego można taką hipotezę odrzucić dla modelu z wyrazem wolnym i trendem liniowym i uznać, że szereg ten ma charakter trendostacjonarny. Dopiero zróżnicowanie danych z krokiem pierwszym pozwoliło odrzucić hipotezę praktycznie dla wszystkich szeregów czasowych. Wyniki dla cen detalicznych potwierdzają automatyczny dobór modeli regARIMA, które były specyfikowane w rozdziale 5.

Do uzyskanych wyników należy podchodzić z pewną ostrożnością, z uwagi na fakt możliwych zmian strukturalnych (por rozdz. 4), które osłabiają moc testów pierwiastka jednostkowego. Szczególnie w przypadku szeregów czasowych CR\_wołow, CD\_szponder należy podchodzić ostrożnie, z uwagi na silny wpływ zmian strukturalnych związanych z BSE i wstąpieniem Polski do UE (wołowina). Jednak w tym przypadku analiza wykonana na danych od 2005 roku również wskazuje na niestacjonarność szeregów czasowych. Generalnie ceny detaliczne mięsa wołowego (szponder) modelowano na podstawie danych od roku 2005. Również ceny energii (M\_energia) charakteryzują się skokowymi zmianami, co jest wynikiem regulacji rynkowych.

## 6.2. Specyfikacja dynamicznych modeli zgodnych dla poziomów

W pierwszym kroku do prognozowania cen detalicznych wybranych produktów wykorzystano jednorównaniowe modele dynamiczne, które specyfikowano opierając się na koncepcji modelowania zgodnego opisanej w skrócie w rozdziale 3.4.1. Zasadniczo dyskusja, jaka ma ciągle miejsce, dotyczy pytania, czy lepiej badać „poziomy” czy lepiej „różnicować” niestacjonarne zmienne. Główny czynnik, jaki leży u podstaw oparcia modeli na danych różnicowanych wiąże się z uzyskaniem zależności pozornych, jeśli szacujemy modele „na poziomach” dla danych niestacjonarnych. Jednak prawidłowe uwzględnienie wewnętrznej struktury procesów wedle koncepcji modelowania zgodnego prowadzi do specyfikacji równania pozwalającej na odkrycie prawdziwych zależności. Tym samym nie są obserwowane negatywne skutki w postaci regresji pozornej, a proces resztowy ma własności białosumowe [Piłatowska 2004].

Piłatowska [2005] wskazuje na brak pełnej przewagi w prognozowaniu po-dejść „zawsze brać poziomy” oraz „zawsze różnicować”. Stąd w praktycznych

zastosowaniach można stosować zarówno modele dla poziomów, jak i modele dla przyrostów (modele EC), niezależnie od tego, czy procesy są niestacjonarne w średniej, czy w wariancji oraz czy występuje między nimi kointegracja. Warunkiem jest realizacja postulatu zgodności. Sprowadza się to tego, aby budować modele jednocześnie dla poziomów i przyrostów procesów, a następnie wybierać model o lepszych własnościach statystycznych oraz o większym uzasadnieniu ekonomicznym. Z prognostycznego punktu widzenia ostateczna prognoza może być średnią ważoną prognoz cząstkowych.

W naszym przypadku szacowano modele, w których cena detaliczna była zmienną zależną, ceny zaś odpowiednich surowców rolnych, ceny oleju napędowego, energii oraz przeciętne wygrodzienia były zmiennymi niezależnymi. W analizie uwzględniono logarytmy poziomów zmiennych, co jest często stosowaną praktyką. Etapem wstępnym badań było określenie struktury szeregów czasowych: charakteru trendu, istotności sezonowości oraz opóźnień autoregresyjnych. Specyfikacja opóźnień przez sprawdzanie każdego procesu indywidualnie pozwala na ograniczenie liczby szacowanych parametrów. Innym podejściem byłoby oszacowanie modelu uwzględniającego wszystkie potencjalne opóźnienia (np. do 12), co powodowałoby rozbudowę modelu i zmniejszenie liczby stopni swobody.

**Tabela 6.2. Struktura wewnętrznych składników procesów – analiza wstępna**

Zmienna	Wielomian	Zmiana trendu liniowego	Sezonowość	Rząd autoregresji	Wartość p testu ADF
I_CR_pszen	2	1.2006	tak	2	0,056
I_CR_zyto	2	1.2006	tak	5	0,160
I_CR_bydlo	2	1.2006	tak	4	0,410
I_CR_bydlo (2005r.)	1	-	tak	11	0,830
I_CR_trzoda	2	1.2006	tak	10	0,004
I_CR_drob	2	1.2006	tak	9	0,013
I_CR_mleko	1	-	tak	3	0,089
I_CD_chleb	1	-	nie	6	0,492
I_CD_maka	2	1.2006	tak	10	0,013
I_CD_szponder	1	-	tak	3	0,526
I_CD_szponder (2005r.)	2	-	tak	3	0,726
I_CD_szynka	2	1.2006	tak	10	0,002
I_CD_kurczak	2	1.2006	tak	10	0,002
I_CD_ml.UHT	2	-	tak	6	0,067
I_CD_maslo	2	-	tak	2	0,042
I_M_wynagr.	2	-	tak	3	0,087
I_M_olej.n	2	-	tak	2	0,226
I_M_energia	2	-	tak	2	0,881

Źródło: obliczenia własne na podstawie danych GUS.

Wyniki tych analiz przedstawiono w tabeli 6.2. Test ADF został wykonany – dla modelu z trendem wielomianowym (linowym lub kwadratowym) oraz periodycznymi zmiennymi sezonowymi. Opóźnienia ustalono na podstawie kryterium AIC. Praktycznie w każdym szeregu czasowym mamy od czynienia trendem liniowym lub wielomianowym stopnia drugiego. Alternatywną specyfikacją modelu jest wybór trendu liniowego przy założeniu jego strukturalnej zmian. Dotyczy to głównie produktów bezpośrednio (surowiec) lub pośrednio (koszty pasz) związanych z rynkiem zbóż, gdzie od roku 2006 nastąpił wzrost cen w wyniku alternatywnego wykorzystywania zbóż do produkcji biopaliw. Wydaje się, że taka specyfikacja trendu jest lepsza, jeśli chodzi o właściwości prognostyczne modelu. Struktura autoregresyjna – oceniana na podstawie funkcji autokorelacji cząstkowej (PACF) – nie różniła się zasadniczo między tymi dwiema specyfikacjami (w tab. 6.2 przedstawiono rząd autoregresji dla trendu wielomianowego). Dane skorygowane z trendu i wahań sezonowych w części przypadków mają charakter stacjonarny, zaś w części są niestacjonarne. Należy podkreślić, że ocena struktury autoregresyjnej oraz wnioskowanie o pierwiastku jednostkowym mogą być obciążone z uwagi na zmiany strukturalne. Szczególnie dotyczy to cen energii, wołowiny (rolnych i detalicznych), chleba czy produktów mlecznych.

Wyniki przedstawione w tabeli 6.2 stanowiły podstawę do wstępnej estymacji jednorównaniowych modeli zgodnych. Wstępny model zawierał zmienne czasowe (w tym, jeśli zachodziła potrzeba, rozpatrywano czas począwszy od roku 2006), zmienne zero-jedynkowe dotyczące sezonowości oraz wartości bieżące i opóźnienia procesów objaśniających oraz opóźnienia procesu objaśnianego. Opóźnienia poszczególnych procesów (objaśnianego i objaśniających) są pochodną badania istotności współczynnika PACF oraz integracji zmiennych. Tam, gdzie istniało prawdopodobieństwo niestacjonarności procesów, po eliminacji części deterministycznej liczbę opóźnień zwiększono o jeden. Również w przypadku, gdy występowało podejrzenie zmian strukturalnych w zmiennych, dokonywano zwiększenia opóźnień o jeden lub dwa okresy.

Bieżące i opóźnione procesy objaśniające pełnią z jednej strony rolę czynników przyczynowych a z drugiej – rolę czynników zastępczych uzgadniających lewą i prawą stronę modelu. Z kolei opóźnienia procesu objaśnianego mają charakter zastępczy i pojawiają się, gdy w modelu pominięto ważne czynniki dla wyjaśnienia procesu objaśnianego, lub też gdy zależność między procesem objaśnianym a procesami objaśniającymi po częstościach nie jest jednakowa [Kufel 2002].

Po estymacji pełnego modelu w kolejnym kroku dokonywano wizualnej oceny reszt w poszukiwaniu wartości odstających. W przypadku ich występowania

model uzupełniano o zmienne zero-jedynkowe typu AO dla wybranych okresów (wraz z opóźnieniami) w celu opisania nietypowej sytuacji. Zmienne tego typu przyczyniają się do uzgodnienia struktur harmonicznych między procesem objaśnianym a procesami objaśniającymi i resztowym. Warunek zgodności jest spełniony, jeżeli proces resztowy ma własności białego szumu.

Po oszacowaniu nowego modelu oceniano normalność rozkładu oraz istotność autokorelacji reszt. W przypadku braku normalności rozkładu dalej analizowano reszty w poszukiwaniu wartości odstających. W przypadku istotności autokorelacji (co występowało względnie rzadko) dokonywano zwiększenia opóźnień. Jeśli model spełniał powyższe warunki, dokonywano eliminacji nieistotnych zmiennych metodą regresji krokowej do tyłu przyjmując jako wartość krytyczną  $p=0,05$ .

W tabeli 6.3 zawarto specyfikację poszczególnych modeli wraz z oceną ich jakości. Dla każdej zmiennej oszacowano dwa modele przyjmując różne założenia. W pierwszym modelu (numery nieparzyste) cena detaliczna była funkcją cen surowca rolnego oraz cen nakładów pozarolniczych (olej, energia wynagrodzenia). Drugi model (numery parzyste) miał prostszą konstrukcję, gdzie jedyną zmienną o charakterze przyczynowym były ceny surowca rolnego (CR). Chciano tym samym ocenić, czy jest możliwe oszacowanie bardziej oszczędnych modeli, ale o zbliżonych właściwościach prognostycznych. Punktem wyjścia było założenie, że w dynamice tych dwóch zmiennych jest już w dużej mierze zawarta informacja o wspólnych czynnikach kształtujących ceny rolne i ceny detaliczne. Jak wiadomo potencjalny efekt pominiętych zmiennych będzie miał swoje odzwierciedlenie w opóźnianych procesach objaśnianych.

Ważnym problemem podczas specyfikacji modeli okazała się niezgodność znaków stojących przy zmiennych objaśnianych w relacji kointegracyjnej z teorią ekonomiczną i oczekiwaniami. Najczęściej chodziło tutaj o zmienną  $M_{olej.n}$ . W takim przypadku decydowano się na usunięcie tej zmiennej z zestawu zmiennych objaśnianych. Najczęściej jednak proces ten i jego opóźnienia okazywały się być nieistotne. Można zauważyć (tab. 6.3), że zmienna ta nie znalazła się w żadnym modelu wśród zmiennych wyjaśniających kształtowanie się cen detalicznych produktów żywnościowych.

Tabela 6.3. Specyfikacja wybranych modeli dynamicznych dla poziomów cen detalicznych

Wyszczególnienie		Zmienna zależna													
		I_CD_maka		I_CD_chleb		I_CD_szynka		I_CD_kurczak		I_CD_ml_UHT		I_CD_maslo		I_CD_szponder	
		MD1	MD2	MD1	MD2	MD1	MD2	MD1	MD2	MD1	MD2	MD1	MD2	MD1	MD2
Zm. zależna	opóźnienia	1,2	1,2, 7, 8	1,2	1,2	1,5	1,11	1	1,6	1,2,3	1,2,3	1,2, 7,9	1,2	1,4	1,4
I_CR	opóźnienia	1,3	1,5, 8	1	1,2	1,2, 9	1,2, 4, 9	1,2, 5	0, 1, 2	0	0, 2, 3	0, 2	0, 2	1	1
I_M_wynagr.	opóźnienia	2	-	1,2	-	3	-	0, 1, 2	-	0, 1, 2	-	-	-	1	-
I_M_energia	opóźnienia	-	-	-	-	1,2	-	-	-	-	-	4	-	-	-
Trend	typ	t	t	-	-	t_2006	t_2006	-	-	t	-	-	t	-	t^2
Sezonowość	liczba zmiennych 0/1	7	8	2	2	1	2	6	5	0	3	2	5	0	2
Obs. nietypowe	liczba zmiennych 0/1	8	8	13	13	2	2	2	2	6	7	8	8	0	0
Statystyki modelu															
Normalność reszt	Chi-kwadrat	0,2336	0,9913	1,0689	5,4230	5,8256	7,2909	4,3248	5,2155	5,3052	2,2556	2,1421	5,1482	1,8316	1,6250
	p	0,8898	0,6092	0,5860	0,0664	0,0543	0,0261	0,1150	0,0737	0,0705	0,3238	0,3426	0,0762	0,4002	0,4438
Autokorelacja reszt 12 rzędu	LMF	1,6058	1,5300	0,6920	0,7084	0,8172	0,5669	0,4684	0,3256	1,3935	1,2996	1,2574	0,1602	0,6868	0,8510
	p	0,0963	0,1206	0,7571	0,7414	0,6324	0,8658	0,9303	0,9837	0,1748	0,2246	0,2507	0,6895	0,7601	0,5985
Dopasowanie	Se	0,0062	0,0061	0,0037	0,0039	0,0054	0,0055	0,0425	0,0319	0,0045	0,0044	0,0086	0,0085	0,0056	0,0052

LMF test – (Langrange Multiplier F-test) statystyka testu Breusch-Godfrey na autokorelację do rzędu 12,

Chi kwadrat – statystyka testu Doornika-Hansena na normalność rozkładu reszt.

Źródło: obliczenia własne na podstawie danych GUS.

W modelach cen detalicznych istotna była co najmniej jedna zmienna powiązana z cenami produktów rolnych. Tylko w przypadku cen kurcząt oraz cen produktów mlecznych istotne okazały się zmienne wyrażające ceny rolne bez opóźnień. W pozostałych przypadkach ceny rolne „wchodziły” do modeli tylko i wyłącznie z opóźnieniami (najczęściej rzędu 1-3). Spośród zmiennych makroekonomicznych, które potencjalnie służą do wyjaśniania rozstępu cenowego, najczęściej istotny wpływ na ceny detaliczne poszczególnych produktów żywnościowych miała zmienna  $M_{\text{wynagr}}$ . W dwóch przypadkach istotne były również ceny energii.

Wyspecyfikowane i oszacowane modele dynamiczne charakteryzowały się zróżnicowanym stopniem złożoności. W najprostszym modelu cen mięsa włowego (CD\_szponder, dane od 2005 roku) uwzględniono 4 zmienne, zaś w najbardziej rozbudowanym (CD\_chleb) – aż 26. W przypadku połowy modeli stwierdzono występowanie statystycznie istotnego trendu. Tylko w dwóch modelach na 14 nie znalazła się żadna zmienna sezonowa. Co jest charakterystyczne, że tylko w modelach cen detalicznych wołowiny (CD\_szponder) nie znalazła się żadna zmienna sztuczna dla uchwycenia wartości nietypowych (ale tylko ze względu na fakt, że próba została skrócona z uwagi na wartości odstające). Najwięcej tego typu zmiennych było w modelach cen detalicznych: chleba, mąki, masła i mleka UHT.

Można zatem uznać, że praktycznie nie jest możliwe oszacowanie dynamicznego modelu poprawnego pod względem rozkładu składnika losowego bez korekt uwzględniających obserwacje odstające. Często dodanie jednej lub dwóch zmiennych sztucznych diametralnie zmieniało statystyki testu normalności. Mimo uwzględnienia wielu zmiennych tego typu, rozkład reszt w niektórych modelach mógłby być lepszy. Pytanie, czy rozbudowanie modelu o kolejne zmienne zero-jedynkowe rzeczywiście poprawiłoby właściwości prognostyczne, jest nadal otwarte. Zasadniczo ten typ specyfikacji modeli gwarantował brak autokorelacji reszt dla pierwszych 12 miesięcy. Natomiast dla niektórych zmiennych (np. model cen szynki i kurczaka), mimo zwiększania opóźnień, nie udawało się zmniejszyć współczynników ACF czy PACF.

Porównując właściwości modeli prostszych z modelami bardziej złożonymi, nie można zauważyć większych różnic, jeśli chodzi o dopasowanie, rozkład reszt czy autokorelacje (wyjątek to modele dla cen kurcząt). Zatem dodatkowe zmienne, oprócz cen surowca rolnego, nie powodują znaczącej poprawy jakości modelu. Można dodać, że istnieje wiele alternatywnych specyfikacji modeli, które gwarantują podobną jakość modelu. Natomiast niekoniecznie prognozy uzyskiwane na ich podstawie będą takie same.



### 6.3. Specyfikacja modeli korekty błędem

W podrozdziale przedstawiono wyniki specyfikacji modeli korekty błędem. Większość badań wskazuje na występowanie długookresowych relacji między cenami detalicznymi a cenami rolnymi. Wskazuje to na zasadność uwzględnienia w modelach zarówno krótkookresowych związków, jak i zależności długookresowych w całym systemie.

Stąd w pierwszym kroku dokonano próby oszacowania relacji kointegrującej zgodnie z dwustopniową procedurą Engle'a-Grangera wykorzystując KMNK (opis metody w rozdz. 3). Wartości zmiennej objaśnianej stanowiły logarytmy cen detalicznych, a wartości zmiennych objaśniających – zlogarytmowane wartości cen rolnych, energii, oleju napędowego oraz wynagrodzeń. Zgodnie z teorią ekonomiczną oczekiwano dodatnich współczynników przy tych zmiennych. Jednak w wyniku estymacji okazało się, że współczynniki stojące przy zmiennej  $l\_M\_olej.n$  były ujemne (większość przypadków) lub dodatnie i bliskie zeru (a co za tym idzie nieistotne). Stąd ostatecznie w żadnym modelu zmienna ta nie pojawiła się. Wyniki oszacowań zawarto w tabeli 6.4.

**Tabela 6.4. Relacja kointegrująca oraz test kointegracji EG**

Zmienna objaśniana	Statystyki	Zmienne				Test kointegracji: $\tau$ oraz $p$
		Const.	$l\_CR\_$	$l\_M\_wynagr.$	$l\_M\_energia$	
$l\_CD\_maka$	Współczynnik	-2,604	0,232	0,212	0,132	-3,649
	Wartość $p$	0,000	0,000	0,050	0,167	0,142
$l\_CD\_chleb$	Współczynnik	-5,748	0,097	0,465	0,648	-3,808
	Wartość $p$	0,000	0,000	0,000	0,000	0,101
$l\_CD\_szynka$	Współczynnik	1,497	0,229	0,077	0,127	-3,330
	Wartość $p$	0,000	0,000	0,047	0,000	0,255
$l\_CD\_kurczak$	Współczynnik	0,272	0,987	-	0,067	-6,210
	Wartość $p$	0,000	0,000	-	0,002	0,000
$l\_CD\_ml\_UHT$	Współczynnik	-1,418	0,057	0,217	0,131	-4,328
	Wartość $p$	0,000	0,008	0,000	0,003	0,026
$l\_CD\_maslo$	Współczynnik	-1,327	0,642	0,228	0,158	-5,498
	Wartość $p$	0,053	0,000	0,119	0,169	0,000
$l\_CD\_szponder$	Współczynnik	-0,858	0,656	0,217	0,152	-2,816
	Wartość $p$	0,012	0,000	0,006	0,065	0,510

*Źródło: obliczenia własne na podstawie danych GUS.*

Można uznać, że oszacowane współczynniki są zgodne z intuicją i wiedzą ekonomiczną. Wraz ze wzrostem stopnia przetworzenia produktu i wzrostem wartości dodanej współczynniki (interpretowane jako elastyczności) stojące przy cenach rolnych ulegają zmniejszeniu (np. dla cen chleba – wynoszą 0,097, a dla cen kurczaka – 0,987). Równocześnie wzrastają wartości współczynników

stojących przy zmiennych  $l\_M\_wynagr.$  i  $l\_M\_energia$ . Z uwagi, że weryfikacja merytoryczna stanowiła główne kryterium doboru zmiennych do relacji kointegrującej, w modelu również pozostały zmienne nieistotne statystycznie, a posiadające sensowną interpretację (należy mieć świadomość, że z uwagi na autokorelację błędy oszacowań są obciążone).

Generalnie potwierdzeniem występowania zależności długookresowych mogą być wyniki testowania reszt relacji kointegrującej. W ich świetle pojawiają się wątpliwości co do istotności długookresowego związku na rynku wołowiny oraz wieprzowiny. Co ciekawe, redukcja zestawu zmiennych objaśniających i pozostawienie w relacji tylko cen rolnych znacząco zmienia wnioski. Ze względów merytorycznych, postanowiono pozostawić tak oszacowane relacje długookresowe. Należy też zwrócić uwagę na fakt, że współczynniki relacji kointegrującej mogą być przyjęte na podstawie oszacowań eksperckich. Jeśli mamy wystarczającą wiedzę, to dla celów praktycznych można przyjąć współczynniki (elastyczności) i posłużyć się resztami na etapie szacowania modeli prognostycznych ECM.

W kolejnym kroku dokonano specyfikacji modeli dla pierwszych różnic logarytmów (tab. 6.5). Wśród zmiennych objaśniających nie uwzględniono cen oleju napędowego, gdyż zmienna je reprezentująca nie znalazła się w równaniu kointegrującym. Jednak należy mieć świadomość, że to nie wyklucza potencjalnie zależności krótkookresowych i ta zmienna w modelu może się znaleźć. Również wśród zmiennych objaśniających były zmienne sezonowe oraz zmienne sztuczne dla obserwacji odstających. Specyfikacji modeli dokonano metodą regresji krokowej, wychodząc od modeli z pełnym zestawem zmiennych objaśniających, podobnie jak w rozdziale 6.2.

We wszystkich oszacowanych modelach czynnik korekty błędem ( $ECT\_1$ ) okazał się być statystycznie istotny, mimo że w świetle dwustopniowej procedury EG nie zawsze udało się dowieść występowania relacji kointegrującej. Na rynku wołowiny i wieprzowiny współczynniki należały do najwyższych. Jest to dosyć często pojawiający się problem w badaniach empirycznych – brak stacjonarności reszt relacji długookresowej przy jednoczesnej istotności opóźnionego ECT w modelu ECM (i czasami *vice versa*). W naszym przypadku szybkość dostosowań do równowagi długookresowej (na co wskazują współczynniki przy  $ECT\_1$ ) jest zgodna z oczekiwaniami. Najszybsza jest na rynku drobiu (-0,28), zaś najwolniejsza w łańcuchu marketingowym chleba (-0,02). Zatem szybkość powrotu do równowagi zależy od stopnia przetworzenia produktu. Szybkość reakcji zależy zatem od stopnia przetworzenia produktu oraz długości cyklu produkcyjnego (w przypadku drobiu jest on najkrótszy, stąd dostosowania popytowe są najszybsze).

Tabela 6.5. Specyfikacja wybranych modeli korekty błędem

Wyszczególnienie	Zmienna zależna									
	d_I_CD maka	d_I_CD chleb	d_I_CD szynka	d_I_CD kureczak	I_CD ml UHT	d_I_CD masło	d_I_CD szponder			
ECT_1	współczynnik	-0,0209	-0,0967	-0,2798	-0,0458	-0,0493	-0,1203			
	wartość p	0,0208	0,0000	0,0000	0,0040	0,0000	0,0000			
Zmienna zależna	opóźnienia	1	4,9	3	2,4	1,3,7	2			
	d_I_CR	1	0,1,3,8,9	0,1	0	0,1,3	-			
d_I_M_wynagr.	opóźnienia	2	-	4	-	4	-			
d_I_M_energia	opóźnienia	0	1	-	-	-	-			
Sezonowość	liczba zmiennych 0/1	2	2	3	1	4	1			
	Obs. nietypowe	11	13	4	3	10	0			
<b>Statystyki modelu</b>										
Normalność reszt	Chi-kwadrat	0,2565	6,4465	4,4675	8,4011	8,1812	2,4654			
	p	0,8796	0,0398	0,1071	0,0150	0,0167	0,2915			
Autokorelacja reszt 12 rzędu	LMF	1,1379	1,0087	1,1555	0,8016	1,6655	0,6175			
	p	0,3346	0,4441	0,3205	0,6484	0,0814	0,8223			
Dopasowanie	Se	0,0068	0,0038	0,0301	0,0049	0,0081	0,0054			

Źródło: obliczenia własne na podstawie danych GUS.

Nie można stwierdzić również, aby modele ECM były lepiej dopasowane do danych niż dynamiczne modele na poziomach (dla części produktów niższe wartości  $Se$  były w przypadku modeli ECM, a dla części w przypadku modeli dynamicznych szacowanych na poziomach). Również tutaj napotkano trudności z zagwarantowaniem rozkładu normalnego, mimo znaczącej liczby dodatkowych sztucznych zmiennych zero-jedynkowych.

## 6.4. Specyfikacja modeli VAR/VECM

Trzeci typ modeli, jaki próbowano zastosować do modelowania i prognozowania cen detalicznych, stanowiły wielorównaniowe modele wektorowej autoregresji (VAR) i wektorowe modele korekty błędem. Ich zaletą jest brak konieczności prognozowania zmiennych objaśniających w celu wykonania prognozy interesującego nas zjawiska, bowiem prognoza jest wykonywana dla całego zestawu zmiennych endogenicznych.

Próby budowy modeli rozpoczynały się od pełnego zestawu zmiennych dla danego produktu: ceny detalicznej, ceny surowca rolnego, cen energii, cen oleju napędowego oraz wynagrodzeń. Problemy związane z estymacją modeli dynamicznych i ECM – przedstawione w dwóch poprzednich rozdziałach – były niewielkie w porównaniu do tych związanych z szacowaniem modeli wektorowych. Odnoszą się one zarówno do merytorycznej interpretacji wyników, jak i specyfikacji i estymacji poprawnego pod kątem statystycznym modelu. Modele tej klasy są bardzo złożone i istnieje wiele możliwości specyfikacji (ograniczone lub nieograniczone zmienne deterministyczne, zmienne sezonowe, zmiany strukturalne i zmienne sztuczne, liczba opóźnień), co praktycznie uzależnia wynik od subiektywnych decyzji badacza. Jest to główny wniosek będący wynikiem badań empirycznych.

Analizy empiryczne rozpoczęto od testowania kointegracji z wykorzystaniem procedury Johansena (test śladu). Jest on oparty na równaniu modelu VECM opisanym w rozdziale 3.4. Statystyka testu śladu służy do testowania hipotezy zerowej, iż liczba różnych wektorów kointegracyjnych jest mniejsza lub równa  $R$ , wobec hipotezy alternatywnej mówiącej, że liczba wektorów kointegracyjnych jest większa od  $R$ . Szerzej ten test opisuje np. Kusideł [2000].

Badania oparto na danych logarytmicznych. Liczbę opóźnień dobrano na podstawie kryterium informacyjnego AIC (większe prawdopodobieństwo braku autokorelacji). Wstępnie testowano istnienie kointegracji bez żadnych dodatkowych zmiennych sztucznych, a jedynie ze zmiennymi sezonowymi. Próbowano różnych kombinacji zmiennych (cena detaliczna, cena rolna i co najmniej jedna ze zmiennych makroekonomicznych). W tabeli 6.6 przedstawiono wybrane

specyfikacje modeli, ale należy mieć świadomość, że istnieją inne alternatywne. Dwa modele (ceny szynki i ceny mleka UHT) zostały oszacowane na poziomach, jako że rząd macierzy w teście śladu był pełny.

Można zauważyć, że w przedstawionych w tabeli 6.6 modelach brakuje zmiennej  $M_{olej.n}$ . Zmienna ta była nieistotna praktycznie we wszystkich relacjach kointegrujących (z nieograniczonym wyrazem wolnym), stąd nie znalazła się w żadnym modelu. Również nie uwzględniano zazwyczaj cen energii (model cen mleka jest wyjątkiem). Zmienna ta cechuje się szeregiem zmian strukturalnych (skokowe zmiany na skutek decyzji administracyjnych, rys. 6.1), dlatego praktycznie nie jest możliwe oszacowanie sensownego modelu z jej udziałem.

Generalnie można zauważyć, że jedynym poprawnym pod względem statystycznym jest model VECM oszacowany dla cen wołowiny ( $l_{CD\_szponder}$ ,  $l_{CR\_bydlo}$   $l_{M\_wynagr}$ ). Jest to w dużej mierze zasługą ograniczenia próby do okresu 2005-2013, co pozwoliło pominąć zmiany strukturalne związane z chorobą BSE oraz integracją z UE.

W pozostałych przypadkach napotkano trudności z zagwarantowaniem przede wszystkim normalności rozkładu reszt. Uzyskanie w przybliżeniu zadowalających wyników w większości równań, wynika z faktu włączenia do systemu równań bardzo dużej ilości zmiennych sztucznych. Najwięcej zmiennych sztucznych było w modelach produktów zbożowych oraz cen masła. W pierwszym przypadku, ceny chleba i ceny mąki charakteryzują się skokowymi zmianami, co powoduje występowanie wartości odstających w resztach modeli. W drugim przypadku, w modelu znajdują się ceny energii charakteryzujące się podobnymi zmianami. Gdyby włączyć  $M_{energia}$  do innych modeli, wówczas liczba zmiennych sztucznych zapewne uległaby zwiększeniu o około 10.

Mimo to, hipoteza zerowa w teście normalności rozkładu reszt Doornika-Hansena często była odrzucana. Włączanie większej liczby sztucznych zmiennych 0/1 poprawia rozkład, ale nie ma praktycznie sensu szacowanie modelu z kilkudziesięcioma dodatkowymi zmiennymi. Dodatkowo zwiększa to autokorelację reszt. Zatem należy podejść w pewien racjonalny sposób do modelowania. W naszym podejściu do specyfikacji decydowano się na włączanie zmiennych sztucznych tylko wówczas, gdy występowały wartości odstające w resztach (kwestie skośności). Równie dobrze prognoza może zostać obliczona na podstawie modelu, który nie spełnia wszystkich wymagań. Po prostu należy do niej podchodzić bardziej ostrożnie.

Tabela 6.6. Specyfikacja wybranych modeli VAR/VECM

Zmienne w modelu	I_CD_maka I_CR_pszem I_M_wynagr.	I_CD_chleb I_CR_zyto I_M_wynagr.	I_CD_szynka I_CR_trzoda I_M_wynagr.	I_CD_kurczak I_CR_drob I_M_wynagr.	I_CD_ml_UHT I_CR_mleko I_M_wynagr.	I_CD_maslo I_CR_mleko I_M_wynagr. I_M_energia	I_CD_szponder I_CR_bydlo I_M_wynagr.
Liczba wektorów	1	1	3	1	3	2	1
Model	VECM	VECM	VAR (poziom)	VECM	VAR (poziom)	VECM	VECM
Liczba opóźnień	3	6	3	4	3	3	3
Sezonowość	tak	tak	tak	tak	tak	tak	tak
Liczba zmiennych 0/1	13	16	8	6	5	13	0
Autokorelacja: test Ljung-Boxa dla 12 opóźnień (wartość p)							
Równanie 1	0,2800	0,0058	0,2010	0,9320	0,1560	0,0148	0,4300
Równanie 2	0,1700	0,7460	0,9520	0,9910	0,0906	0,9050	0,3030
Równanie 3	0,0001	0,5860	0,0016	0,0652	0,0001	0,1850	0,4040
Równanie 4	-	-	-	-	-	0,0034	-
Normalność: test Doornika-Hansena (wartość p)							
Równanie 1	1,1379	0,0746	0,0093	0,0112	0,0198	0,0001	0,3150
Równanie 2	0,3346	0,0000	0,8722	0,7708	0,1117	0,1544	0,0511
Równanie 3	0,0068	0,0036	0,0351	0,1361	0,0519	0,0411	0,0195
Równanie 4	-	-	-	-	-	0,0003	-
Całość	0,0104	0,0000	0,0162	0,0068	0,0526	0,0000	0,0132

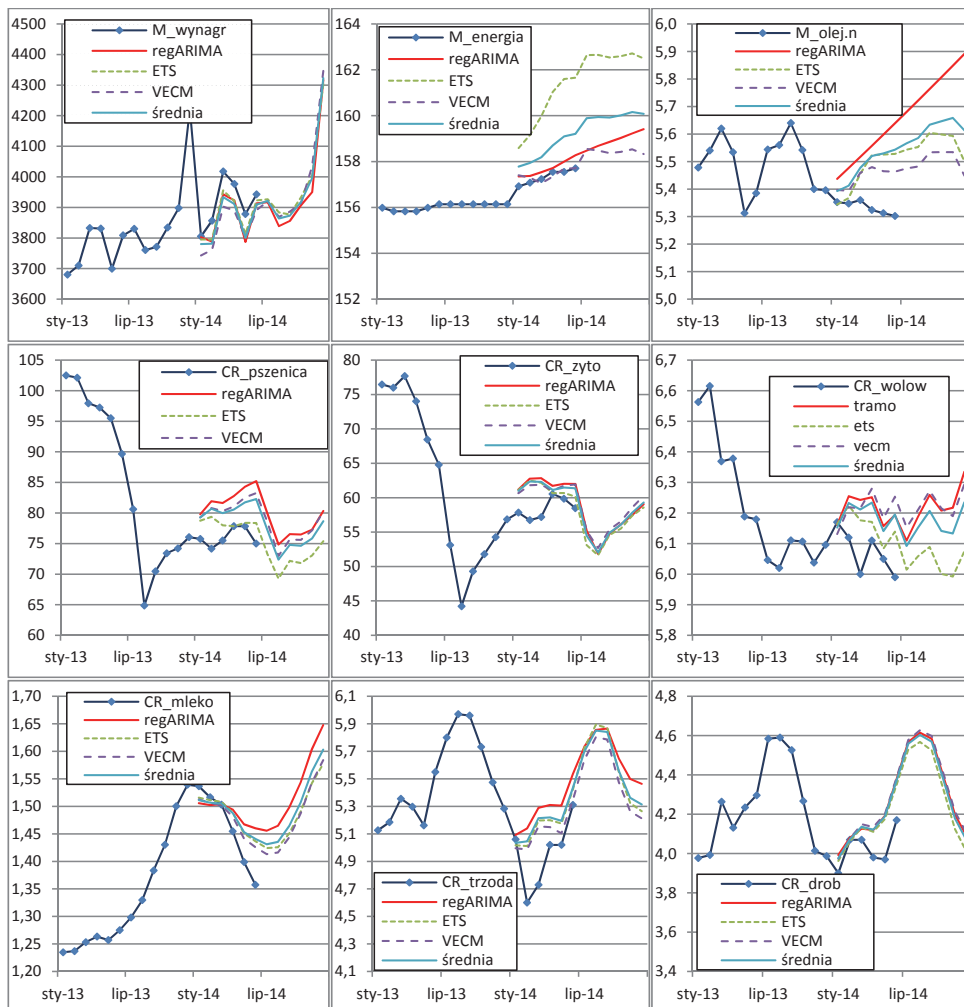
Liczba opóźnień – dla modelu VAR. W przypadku modeli VECM (na pierwszych różnicach) jest ona niższa o jeden.

Źródło: obliczenia własne na podstawie danych GUS.

## 6.5. Porównanie dokładności prognoz ex post

Prognozując ceny detaliczne na podstawie modeli przedstawionych w rozdziałach 6.2-6.4, wychodzi się od różnych założeń, jeśli chodzi o wartości zmiennych objaśniających w okresie prognostycznym. O ile w modelach VAR/VECM wszystkie zmienne endogeniczne są prognozowane w ramach systemu, to w modelach jednorównaniowych wartości zmiennych objaśniających dla okresów przyszłych należy założyć (prognozy z modeli ilościowych, opinie ekspertów, bądź też przyjmując prognozy ze źródeł zewnętrznych).

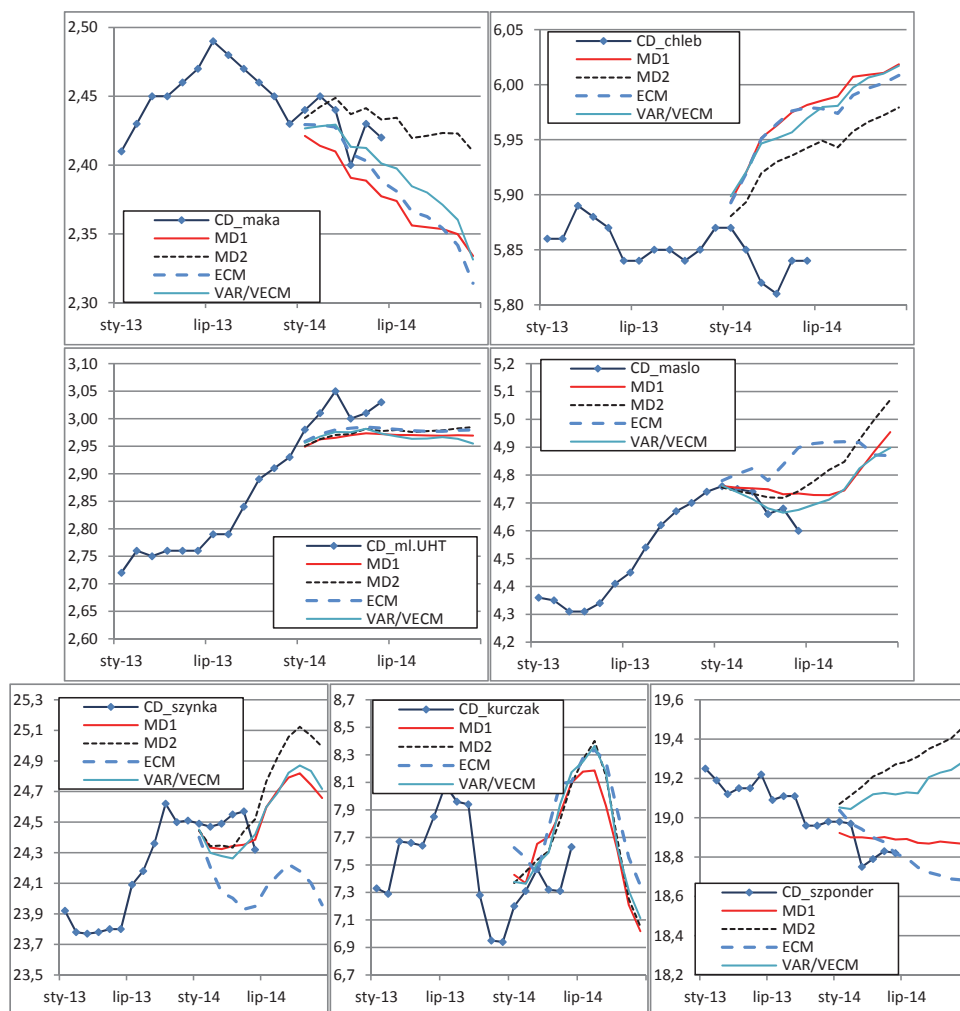
Rysunek 6.2. Prognozy pomocnicze zmiennych objaśniających



Źródło: obliczenia własne na podstawie danych GUS.

W przypadku naszych modeli dynamicznych oraz modeli ECM potrzebne były również prognozy cen surowców rolnych oraz prognozy zmiennych makroekonomicznych. Prognozy pomocnicze wykonano na podstawie modeli regARIMA, modeli ETS oraz modeli VAR/VECM. Za ostateczną prognozę przyjęto wartość średnią prognoz cząstkowych. Przebieg tych prognoz przedstawiono na rysunku 6.2. Należy pamiętać, że niedokładność prognoz pomocniczych stanowi dodatkowe źródło błędów prognoz interesującej nas zmiennej, obok ewentualnej błędnej specyfikacji modelu.

**Rysunek 6.3. Prognozy cen detalicznych na tle danych rzeczywistych**



Źródło: obliczenia własne na podstawie danych GUS.



Na podstawie poszczególnych modeli (rozdział 6.2-6.4) obliczono prognozy na kolejne 12 miesięcy. Zostały one przedstawione na rysunku 6.3. Oceniając jakość prognoz, można zauważyć, że jedynie w przypadku cen detalicznych chleba żytniego prognozy kierunkowo nie są zgodne z wartościami rzeczywistymi. Dzieje się tak mimo względnie prawidłowych prognoz pomocniczych cen żyta przy nieco zawyżonych prognozach cen energii. W pozostałych przypadkach co najmniej jeden model wskazuje prawidłową ścieżkę. Generalnie zauważyć też można, że mimo zastosowania różnych modeli przebieg prognoz jest podobny.

**Tabela 6.7. Błędy prognoz ex post w okresie styczeń-czerwiec 2014**

Model	MD1	MD2	ECM	VAR/VECM	MD1	MD2	ECM	VAR/VECM
Zmienna	CD_maka				CD_ml.UHT			
ME	0,030	-0,010	0,016	0,011	0,048	0,044	0,037	0,042
MAE	0,030	0,014	0,018	0,016	0,048	0,044	0,037	0,042
MAPE	1,221	0,575	0,758	0,654	1,585	1,464	1,210	1,382
Zmienna	CD_chleb				CD_maslo			
ME	-0,109	-0,079	-0,109	-0,102	-0,049	-0,037	-0,122	-0,007
MAE	0,109	0,079	0,109	0,102	0,049	0,043	0,122	0,025
MAPE	1,872	1,348	1,865	1,752	1,046	0,936	2,626	0,540
Zmienna	CD_szynka				CD_szponder			
ME	0,118	0,077	0,394	0,140	-0,045	-0,320	-0,067	-0,234
MAE	0,140	0,143	0,394	0,173	0,087	0,320	0,068	0,234
MAPE	0,571	0,586	1,607	0,708	0,463	1,698	0,362	1,244
Zmienna	CD_kurczak				X			
ME	-0,314	-0,272	-0,388	-0,285				
MAE	0,314	0,272	0,402	0,285				
MAPE	4,247	3,675	5,464	3,853				

MD, MD2 – modele dynamiczne z tab. 6.3; ECM – tab. 6.5; VAR/VECM – tab. 6.6.

*Źródło: obliczenia własne na podstawie danych GUS.*

W tabeli 6.7 zawarto syntetyczne podsumowanie dokładności prognoz. Na 28 modeli w 17 przypadkach prognozy były przeszacowane. Wielkość błędów prognoz w okresie styczeń-czerwiec 2014 nie była wysoka, z wyjątkiem prognoz cen kurcząt (błędy 3,7-5,5). Trudno jednoznacznie wskazać metodę dającą najniższe błędy. Niemniej jednak można stwierdzić, że na 7 przypadków tylko w dwóch model dynamiczny specyfikowany ze wszystkimi zmiennymi (MD1) okazał się być bardziej dokładny od modelu dynamicznego, w którym jedyną zmienną objaśniającą o charakterze przyczynowym była cena surowca rolnego (MD2). Porównując wyniki zawarte w tab. 5.5 oraz 6.7, również nie można uznać, aby modele bazujące na związkach przyczynowych wykazywały się wyższą dokładnością w analizowanym okresie. Wskazuje to, że modele prostsze stanowią alternatywę dla modeli złożonych.

## 7. Prognozowanie wskaźników detalicznych cen żywności z wykorzystaniem modeli szeregów czasowych

### 7.1. Wprowadzenie

Z punktu widzenia makroekonomicznego, prognozowanie wskaźników cen żywności można traktować jako prognozowanie dynamiki zmian ważnego składnika wydatków gospodarstw domowych. Żywność i napoje bezalkoholowe stanowią ok. 25% tych wydatków. Taka jest również waga nadana cenom żywności w procesie konstrukcji wskaźnika cen towarów i usług konsumpcyjnych (CPI), będącego miernikiem zmian cen konsumpcyjnych w gospodarce (czyli tzw. inflacji). Wysokość udziału cen żywności w koszyku CPI zależy zarówno od relatywnego poziomu cen żywności w porównaniu z cenami innych kategorii dóbr i usług, jak i od relatywnej wielkości popytu na te towary. Warto również zwrócić uwagę na fakt, że waga ceny żywności w koszyku CPI jest ujemnie skorelowana z poziomem rozwoju gospodarczego: jej spadek jest symptomem poprawiającego się poziomu życia (przy zaspokojonych potrzebach żywieniowych można przeznaczyć więcej środków pieniężnych na potrzeby wyższego rzędu) a także postępującego procesu konwergencji z gospodarkami wyżej rozwiniętymi (waga żywności i napojów bezalkoholowych w niemieckim CPI wyniosła w 2013 r. 10,3% a w Luksemburgu i Wielkiej Brytanii poniżej 10%<sup>28</sup>). Ponadto, ponieważ produkty spożywcze należą do najczęściej kupowanych przez konsumentów, dynamika ich cen ma wpływ nie tylko na bieżący poziom inflacji, ale również na kształtowanie się oczekiwań inflacyjnych.

Wskaźniki cen żywności stanowią grupę heterogeniczną. Na tle innych wskaźników cen wyróżnia je duża zmienność, często również sezonowość, a niektóre wskaźniki cechuje także duża liczba obserwacji nietypowych, informujących o występowaniu trudnych do przewidzenia szoków. Również źródła wahań są często inne niż w przypadku towarów nieżywnościowych i usług. Popyt na żywność jest najczęściej relatywnie sztywny, przez co jej ceny słabiej reagują na ogólną koniunkturę gospodarczą niż ceny dóbr i usług luksusowych, takich jak restauracje i hotele czy rekreacja i kultura. Ceny żywności reagują natomiast silnie na sytuację podażową na rynku rolno-spożywczym, zależącą m.in. od warunków meteorologicznych, występowania chorób zwierzęcych i innych zdarzeń losowych. Ponieważ rynek ten przez ostatnie 15 lat podlegał

---

<sup>28</sup> Federal Statistical Office of Germany, "Regular Adaptation of the consumer Price Index 2013", dostęp luty 2013. [https://www.destatis.de/EN/Publications/Specialized/Prices/PriceIndex2013\\_5611107139004.pdf?\\_\\_blob=publicationFile](https://www.destatis.de/EN/Publications/Specialized/Prices/PriceIndex2013_5611107139004.pdf?__blob=publicationFile)

znacznym zmianom strukturalnym, m.in. wynikającym ze zmiany otoczenia prawnego (przystąpienie do UE i związane z nim dostosowanie polskiego prawodawstwa, następnie kolejne zmiany uwarunkowań spowodowane reformami Wspólnej Polityki Rolnej, a niezależnie od tego reorientacja poszczególnych gałęzi rolnictwa w kierunku eksportu, poszerzenie rynków zbytu, itp.), procesy cenotwórcze również modyfikowały się. Ceny żywności są więc, między innymi poprzez swoją specyfikę, ciekawym obiektem analizy.

Przy prognozowaniu wskaźników cen żywności stosować można dwojaki podejście: prognozowanie bezpośrednio zagregowanego wskaźnika cen żywności lub też prognozowanie wskaźników cen różnych kategorii żywności, które następnie, już po sformułowaniu prognozy, agregowane są do wskaźnika cen żywności ogółem. Podejście od szczegółu do ogółu umożliwia uwzględnienie charakterystyki każdego z podkomponentów, które mogą się między sobą niezwykle różnić. Jednocześnie jednak procedura ta jest bardziej zasobochłonna, dlatego procedurę prognostyczną należy dobrać stosownie do celu, jaki przyświeca prognoście.

## 7.2. Dane

W rozdziałach 7 i 8 podstawowym przedmiotem modelowania, a następnie formułowania prognoz, są wskaźniki cen żywności w ujęciu miesiąc poprzedni = 100 (dane o częstotliwości miesięcznej), obliczane przez GUS lub uzyskane poprzez agregację danych GUS. Wskaźniki takie w niniejszym rozdziale poprzedzono oznaczeniem WM\_. Wskaźniki żywności stanowią część wskaźnika cen towarów i usług konsumpcyjnych (inflacja ogółem) i metodyka ich uzyskiwania jest zbieżna z metodyką obowiązującą w przypadku wskaźników cen innych towarów i usług konsumpcyjnych. Ze wskaźników o powyższej postaci można odczytać, o ile procent zmienił się przeciętnie (wzrósł lub spadł) poziom cen danej grupy towarów, przy czym grupa towarów może być rozumiana wężiej lub szerzej, w zależności od poziomu agregacji. Przykładowo, wskaźnik cen żywności i napojów bezalkoholowych jest grupą na wyższym poziomie agregacji niż grupa mięso, w skład której z kolei wchodzić mogą wskaźniki cen różnych gatunków mięsa oraz wędlin. Sposób agregowania danych przez GUS poprzez zaliczanie poszczególnych towarów do coraz bardziej ogólnych kategorii jest zgodny z klasyfikacją Spożycia Indywidualnego według Celu (COICOP)<sup>29</sup>.

---

<sup>29</sup> Klasyfikacja COICOP jest oparta na międzynarodowych standardach wprowadzonych przez departament statystyki Narodów Zjednoczonych i jest stosowana m.in. do konstruowa-

Analiza danych na różnym poziomie agregacji umożliwia, po pierwsze, dokładniejsze opisanie procesów generujących dane w poszczególnych grupach produktów, które mogą bardzo się od siebie różnić. Ponieważ wskaźnik cen żywności ogółem jest efektem agregacji dużej grupy wskaźników cen, od żywności mocno przetworzonej i dań gotowych po surowe owoce i warzywa, mogłoby zdarzyć się, że jego proces generujący dane będzie miał skomplikowaną postać, np. być zintegrowany ułamkowo<sup>30</sup>. Może się jednak zdarzyć, że znalezienie „uproszczonej” wersji procesu generującego dane jest możliwe i wystarcza do opisu zagadnień, którymi się interesujemy.

Po drugie, w kontekście prognozowania warto jest zwrócić uwagę na szeroko komentowane w literaturze zagadnienie<sup>31</sup>, czy bezpośrednie prognozowanie agregatu jest bardziej skuteczne niż prognozowanie poszczególnych podagregatów i składanie wyników w celu uzyskania prognozy agregatu w pośredni sposób. Z jednej strony, błędy prognoz dużej liczby podagregatów mogłyby znosić się i prowadzić do niższego błędu agregatu. Jednocześnie, w tym układzie możliwe jest bardziej dokładne ujęcie postaci modeli procesów generujących dane w poszczególnych podagregatach, co może być przydatne wówczas, gdy odbiorców interesuje np. wskazanie komponentów będących źródłem zmian prognozy. Z drugiej jednak strony prognozowanie szczegółów potrafi być znacznie bardziej zasobochłonne (czaso- i pracochłonne), a jeśli na zmienne na niższym stopniu agregacji wpływają wspólne szoki, to błędy prognoz, zamiast się znosić, mogą się potęgować, prowadząc do silniejszej pomyłki w przypadku agregatu. Zagadnienie „agregować czy nie agregować” ma więc implikacje praktyczne w postaci możliwości wyboru modelu lub grupy modeli charakteryzujących się niższymi błędami prognozy.

Listę wskaźników objętych modelowaniem w rozdziałach 7 i 8, wraz z podstawowymi statystykami opisowymi, przedstawiono w tabeli 7.2, natomiast wszystkie wykresy wskaźników m/m zamieszczono na rysunku 7.1. Wśród analizowanych wskaźników znajdują się wskaźniki publikowane bezpośrednio przez GUS, jak również kilka wskaźników autorskich obliczonych metodą GUS, powstałych w wyniku zagregowania kilku grup mniejszych grup produktów, których waga z osobna byłaby niewielka (np. mleko, pozostałe produkty mleczne, tłuszcze roślinne i wyroby cukiernicze). Wskaźnik *zywnosc\_ogr* powstał natomiast w wyniku zagregowania wskaźników odnoszących się do

---

nia przez Eurostat wskaźników HICP a także jako podstawa do budowania wskaźników CPI w wielu krajach.

<sup>30</sup> Granger [1980] wykazał, że przy spełnieniu pewnych założeń agregacja pojedynczych procesów stacjonarnych może dać w końcowym wyniku proces z długą pamięcią.

<sup>31</sup> Zob. np. Hubrich [2003] lub Benalal i in. [2004].

analizowanych w niniejszym opracowaniu grup produktów: jest to wskaźnik cen żywności GUS z pominięciem owoców, warzyw, ryb i pozostałej żywności<sup>32</sup>. Został on skonstruowany w celu weryfikacji hipotezy o wyższej skuteczności prognoz skonstruowanych na zasadzie agregacji nad bezpośrednimi prognozami agregatu w naszej próbie kontrolnej (styczeń-czerwiec 2014 r.). Szczegółowy skład wymienionych wyżej wskaźników został opisany w tabeli 7.1.

**Tabela 7.1. Autorskie wskaźniki wykorzystywane w badaniu**

Pełna nazwa	Skrót	Skład wskaźnika
<b>Żywność:</b> w tym wybrane prognozowane grupy	zywnosc_ogr	wszystkie podkomponenty grup: pieczywo i produkty zbożowe; mięso; mleko, sery i jaja; oleje i pozostałe tłuszcze; cukier, dżem, miód i wyroby cukiernicze
<b>Mleko</b>	mleko	mleko pełne, świeże, mleko świeże niskotłuszczowe, mleko zagęszczone i w proszku
<b>Pozostałe produkty mleczne</b>	poz_prod_ml	jogurt, śmietana, napoje i inne produkty mleczne
<b>Tłuszcze roślinne</b>	tl_rosl	margaryna i inne tłuszcze roślinne, oliwa z oliwek, pozostałe oleje jadalne
<b>Wyroby cukiernicze</b>	wyr_cuk	dżemy, marmolady i miód, czekolada, wyroby cukiernicze, lody, sztuczne substytuty cukru

*Źródło: obliczenia własne na podstawie danych GUS<sup>33</sup>.*

Jak zaobserwować można w tabeli 7.2, ceny żywności są mocno heterogeniczną grupą. Średnia dynamika cen w wymienionych wyżej grupach waha się od 0,19 miesięcznie w przypadku mięsa drobiowego (czyli średnio ok. 2,3 wzrostu w ciągu roku) do 0,59 miesięcznie dla mięsa wołowego (średnio w roku ok. 7,3). Jednocześnie jednak stwierdzono, że mediana, czyli wartość środkowa w próbie obejmującej wszystkie miesiące, najczęściej kształtuje się poniżej wartości średniej. Oznacza to, że częściej możemy spotkać dynamikę cen niższą niż średnia, a rozkład zmian cen jest skośny, o grubszym prawym ogonie. Potwierdzają to dane na temat skośności, która w większości przypadków ma wartość wyższą od 0 (skośność prawostronna). Oznacza to również, że po prawej stronie rozkładu możemy oczekiwać wartości silniej odchylających się od dominanty (wartości najbardziej prawdopodobnej) niż po lewej stronie. Skrajne wzrosty będą więc silniejsze niż skrajne spadki. Co ciekawe, wskaźnik cen żywności i napojów bezalkoholowych, jako jedyny spośród analizowanych (jeszcze z wyjątkiem agregatu wyroby cukiernicze) cechuje się skośnością lewostronną,

<sup>32</sup> Dla powyższych grup znacznie trudniej jest dobrać dane dot. odpowiednich cen surowców rolnych. Ponieważ w kolejnych rozdziałach analizowane są przykładowe modele o charakterze przyczynowo-skutkowym, w których ceny surowców stanowią ważną zmienną objaśniającą, dla zachowania spójności w niniejszym rozdziale brane są pod uwagę również tylko te grupy, dla których tego typu modele mogą być stworzone.

<sup>33</sup> Autorzy pragną podziękować Pawłowi Maciasowi z NBP za pomoc w automatycznej agregacji wskaźników.

a więc gwałtownymi, silnymi spadkami i łagodniejszymi wzrostami. Wynika to najprawdopodobniej z sezonowego zachowania cen warzyw, w przypadku których wzrost podaży w miesiącach letnich prowadzi do silnych spadków cen, natomiast dodatnia dynamika w pozostałych miesiącach nie jest aż tak silna. Ceny owoców również cechują się nieznaczną ujemną skośnością. Jednak wskaźniki obu tych grup nie są objęte niniejszą analizą.

Największą zmiennością (wahaniem wokół średniej) charakteryzuje się cukier (wartości dynamiki miesięcznej odchylają się przeciętnie od średniej o 6,37 p.p.) oraz mięso drobiowe i jaja (przeciętne odchylenie od średniej wynosi 3,66 p.p.). Z kolei najmniejszą zmiennością cechują się ceny grupy obejmującej dżem, miód, czekoladę i wyroby cukiernicze. Generalnie, z wyjątkiem cukru, silniejszą zmiennością charakteryzują się ceny towarów niżej przetworzonych, bardziej podatne na szoki ze strony podaży (np. surowe mięso), tymczasem żywność przetworzona (produkty mleczarskie, wyroby cukiernicze, tłuszcze roślinne, wędliny) cechuje się większą stabilnością. Ceny cukru zmieniają się bardzo silnie pod wpływem współwystępowania ograniczenia podażowego ze skokowym wzrostem popytu wynikającym z czynników psychologicznych.

Kurtoza jest miarą rozkładu mówiącą o tym, jak bardzo rozkład jest spłaszczony lub jak często występują w próbie obserwacje silnie odchylające się od średniej. W rozkładzie normalnym wartość kurtozy wynosi 3. Z informacji przedstawionych w tabeli 7.1 wynika, że większość wskaźników cen żywności charakteryzuje się wyższą kurtozą, niż gdyby były one generowane przez rozkład normalny. Najniższą kurtozą charakteryzują się wskaźniki bardziej zagregowane (np. ceny żywności i napojów bezalkoholowych). Relatywnie niską kurtozą zaobserwować możemy również w przypadku wyrobów cukierniczych, surowego mięsa wieprzowego i drobiowego oraz tłuszczów roślinnych.

Na koniec analizy opisowej warto zwrócić uwagę na częstości wzrostów i spadków cen w poszczególnych grupach towarowych oraz na ich relatywną siłę. W przypadku cen żywności znacznie częściej zaobserwowano wzrosty cen aniżeli spadki (liczba wskaźników większych niż 100 jest wyższa niż tych poniżej 100). Istnieje kilka grup, w których występuje tendencja odwrotna, należą do nich: cukier, jaja, mięso wieprzowe i drobiowe, mąka i pozostałe produkty zbożowe. W przypadku cukru, po krótko trwającym okresie bardzo gwałtownych wzrostów najczęściej występuje długotrwały okres spadku, co tłumaczy powyższą dysproporcję. W przypadku pozostałych wskaźników różnice pomiędzy liczbą wzrostów i spadków nie są tak wyraźne.

**Tabela 7.2. Analizowane wskaźniki cen żywności w ujęciu m/m na różnym poziomie agregacji na tle wskaźnika CPI: podstawowe statystyki opisowe**

Pełna nazwa	Skróć	Średnia	Mediana	Odch stand	Skosność	Kurtozja	Liczba spadków	Liczba wzrostów	Udział spadków	Udział wzrostów	Średni spadek	Średni wzrost
Żywność i napoje bezalkoholowe	WM_zywnosc_i_napoje	100,29	100,50	1,02	-0,64	0,37	55	125	69	31	99,05	100,83
żywność - wybrane grupy	WM_zywnosc_ogr	100,30	100,15	0,69	1,55	2,79	77	103	57	43	99,76	100,71
pieczywo i produkty zbożowe	WM_piecz_i_prod	100,38	100,13	0,85	4,99	31,76	40	140	78	22	97,42	100,51
mąka i pozostałe produkty zbożowe	WM_maka_i_poz_zb	100,33	99,99	1,30	1,84	3,84	92	88	49	51	99,47	101,23
pieczywo	WM_pieczyo	100,44	100,10	1,29	5,69	39,28	49	131	73	27	99,90	100,64
mięso	WM_mieso	100,27	100,07	1,17	1,54	4,72	83	97	54	46	99,39	101,02
mięso wstowe i ciętące	WM_mies_wol_ciel	100,59	100,28	1,45	6,00	44,66	35	145	81	19	99,76	100,79
mięso wieprzowe	WM_mies_wiep	100,26	99,92	1,63	1,24	2,66	95	85	47	53	99,14	100,33
wędliny	WM_wedliny_razem	100,28	100,09	0,87	2,08	7,95	72	108	60	40	99,61	100,74
wędliny z wyjątkiem drobiowych	WM_wedliny_bezdrob	100,29	100,09	0,91	2,10	8,00	74	106	59	41	99,59	100,77
wędliny drobiowe	WM_wedl_drob	100,24	100,19	0,61	1,23	4,43	51	129	72	28	99,60	100,49
mięso drobiowe	WM_mies_drob	100,19	99,90	3,66	0,80	2,22	95	85	47	53	97,73	102,94
mleko, sery i jaja	WM_mleko_sery_jaja	100,28	100,17	0,81	2,46	8,55	69	111	62	38	99,68	100,64
mleko	WM_mleko	100,33	100,21	0,53	3,13	15,10	37	143	79	21	99,89	100,44
sery i twarogi	WM_sery	100,26	100,13	0,79	2,36	9,98	70	110	61	39	99,67	100,63
pozostałe produkty mleczne	WM_poz_prod_ml	100,22	100,18	0,44	0,46	2,91	49	131	73	27	99,75	100,40
jaja	WM_jaja	100,36	99,94	3,66	3,83	22,56	98	82	46	54	97,52	101,31
masło	WM_maslo	100,43	100,08	2,12	1,62	5,01	87	93	52	48	99,10	101,67
łuszczone roślinne	WM_tl_rosl	100,23	100,14	0,52	0,88	2,26	60	120	67	33	99,76	100,47
cukier, dżem, miód, czekolada i wyroby	WM_cuk_i_wyr	100,31	99,98	2,01	4,78	30,91	96	84	47	53	99,46	101,29
cukier	WM_cukier	100,50	99,53	6,37	5,20	33,59	117	63	35	65	98,33	104,54
wyroby cukiernicze	WM_wyr_cuk	100,24	100,24	0,27	-0,14	1,09	25	155	86	14	99,82	100,31
Wskaźnik CPI	WM_wskCPI	100,28	100,27	0,42	0,46	0,47	45	135	75	25	99,77	100,46

Wartość wskaźnika poniżej 100 oznacza spadek średniej ceny w danej grupie, zaś wartość powyżej 100 – wzrost średniej ceny w danej grupie. Skosność – współczynnik skosności z próby, korygowany o obciążenie. W przypadku rozkładu normalnego współczynnik skosności wynosi 0. Wartość kurtozy w przypadku rozkładu normalnego wynosi 3.

Źródło: obliczenia własne na podst. danych GUS.

Powyższe informacje dostarczają wstępnej wiedzy na temat analizowanych szeregów, przydatnej do zrozumienia ich charakteru i pozwalającej na wstępnym etapie ocenić skalę trudności, jakich można oczekiwać przy prognozowaniu. Dla przykładu, szeregi o większej zmienności, zwłaszcza jeśli zmienność ta wynika z szoków o różnym charakterze, mogą być trudniejsze do prognozowania. Podobnie szeregi cechujące się silną asymetrią mogą czasem wymagać zastosowania modeli o charakterze nieliniowym.

Ponieważ analizowana przez nas dynamika cen żywności ma charakter szeregów czasowych, inne ważne z punktu widzenia prognozowania cechy związane ze zmianami zachodzącymi w czasie obejmują występowanie trendu (w tym zarówno trendów stochastycznych, jak i deterministycznych), ewentualnie cykli oraz sezonowości. Prognozy powinny uwzględniać charakter szeregów w tym zakresie. W pierwszym kroku zbadano występowanie w danych szeregach tendencji stochastycznych oraz deterministycznych. Choć te drugie w przypadku dynamiki cen w Polsce w ostatnich latach są trudne do uzasadnienia, to jeszcze w latach 90. można było zauważyć spowalnianie tempa wzrostu cen, które objawiało się obniżającą się dynamiką miesięczną. Występowanie tendencji stochastycznej (pierwiastka jednostkowego) w szeregu sugeruje, że wpływ szoków kształtujących go nie wygasa z czasem, lecz utrzymuje się w nieskończoność. Tymczasem wartości szeregów nie poddanych trendowi stochastycznemu (stacjonarne) kształtują się wokół pewnej średniej, do której po wystąpieniu szoku mają tendencję po pewnym czasie powracać.

Do weryfikacji hipotezy o stacjonarności (bądź niestacjonarności) wykorzystane zostały popularne testy: parametryczny rozszerzony test Dickeya-Fullera (ADF), test nieparametryczny Phillipsa-Perrona (PP) oraz test Kwiatkowskiego-Phillipsa-Schmidta-Shina (KPSS). Dwa pierwsze testy mają tę wspólną cechę, że ich hipoteza zerowa zakłada niestacjonarność szeregu czasowego i dopiero jej odrzucenie umożliwia stwierdzenie jego stacjonarności. W teście KPSS hipotezą zerową jest z kolei stacjonarność szeregu. Opis pierwszego testu znajduje się w rozdz. 3 z kolei pozostałe testy przedstawiają m.in. Charemza, Deadman [1997] czy Lütkepohl, Krätzig [2007].

Wyniki testów ADF, PP i KPSS znajdują się w tabeli 7.3. Liczba opóźnień w teście ADF została wybrana dla każdego szeregu na podstawie korelogramu (wartości funkcji i przedziałów ufności PACF – częściowych autokorelacji). Przyjęto 0,05 poziom istotności dla podjęcia decyzji w każdym z testów. W przypadku testu KPSS wartość krytyczna dla statystyki testowej wynosi 0,463 na poziomie istotności 0,05. W przypadku wszystkich szeregów i testów stała okazywała się istotna, natomiast trend deterministyczny był nieistotny.



Na podstawie powyższych wyników testów można stwierdzić, że dynamika miesięczna różnych grup cen żywności nie charakteryzuje się ani trendem stochastycznym, ani deterministycznym, lecz fluktuuje wokół średniej. Testy pierwiastka jednostkowego pozwoliły na odrzucenie hipotezy zerowej o ich niestacjonarności, a w przypadku testu KPSS nie było podstaw do odrzucenia hipotezy mówiącej o stacjonarności szeregów. Wyniki testów pierwiastka jednostkowego i stacjonarności potwierdziły się więc wzajemnie. W przypadku wszystkich szeregów i we wszystkich testach stała (dodatnia) okazała się istotna. Ponieważ analizowane przez nas zmienne mówią o średniej zmianie cen produktów w danej grupie towarowej, stała dodatnia średnia sugeruje, że poziomy cen cechują się dodatnim trendem.

**Tabela 7.3. Wyniki testów ADF, PP i KPSS dla wybranych wskaźników cen żywności**

Zmienna	ADF			PP		KPSS
	liczba opóźnień	wartość statystyki	wartość p	wartość statystyki	wartość p	wartość statystyki
WM_piecz_i_prod	4	-4,33	0,00	-7,59	0,00	0,09
WM_maka_i_poz_zb	3	-3,51	0,01	-5,06	0,00	0,06
WM_pieczywo	4	-4,79	0,00	-8,40	0,00	0,10
WM_mieso	3	-5,79	0,00	-8,62	0,00	0,05
WM_mies_wol_ciel	2	-5,72	0,00	-5,51	0,00	0,05
WM_mies_wiepr	2	-5,86	0,00	-7,95	0,00	0,04
WM_wedliny_razem	1	-5,87	0,00	-6,66	0,00	0,06
WM_wedliny_bezdrob	1	-5,84	0,00	-6,74	0,00	0,05
WM_mies_drob	4	-6,80	0,00	-10,22	0,00	0,06
WM_wedl_drob	2	-5,31	0,00	-6,38	0,00	0,12
WM_mleko_sery_jaja	2	-5,68	0,00	-5,99	0,00	0,04
WM_mleko	3	-4,39	0,00	-5,64	0,00	0,05
WM_sery	1	-5,56	0,00	-4,57	0,00	0,06
WM_poz_prod_ml	2	-3,94	0,00	-6,91	0,00	0,07
WM_maslo	2	-6,01	0,00	-5,02	0,00	0,03
WM_jaja	2	-6,48	0,00	-7,48	0,00	0,03
WM_tl_rosl	3	-3,01	0,04	-5,99	0,00	0,13
WM_cuk_i_wyr	5	-5,41	0,00	-9,23	0,00	0,08
WM_cukier	5	-5,43	0,00	-9,64	0,00	0,06
WM_wyr_cuk	3	-3,57	0,01	-10,40	0,00	0,18

wartość p – empiryczny poziom istotności

Źródło: obliczenia własne na podstawie danych GUS.

Ceny wielu produktów żywnościowych charakteryzują się sezonowością. Im bardziej nieprzetworzony jest produkt, tym w większym stopniu sezonowość cen wynikać może z sezonowości podaży (poprzez udział ceny surowca w cenie finalnej produktu). Oczywiście jest, że podaż produkcji rolniczej w Polsce jest sezonowa ze względu na klimat i charakter procesów produkcyjnych. Stąd,

w okresach gdy podaż jest relatywnie niska, ceny mogą być wyższe i na odwrót, w czasie wysokiej podaży (np. w przypadku produkcji roślinnej – bezpośrednio po zbiorach) ceny spadają. Z drugiej strony, daje się również dostrzec sezonowy wpływ czynnika popytowego (np. niższe ceny wielu produktów w okolicach świąt Bożego Narodzenia z powodu promocji przedświątecznych, wynikające z okresowych zmian preferencji konsumentów i dostosowania polityki cenowej w branży detalicznej). W przypadku analizowanych szeregów zależność taką można często dostrzec na wykresach „gołym okiem”.

### 7.3. Specyfikacja i estymacja modeli ETS

Do prognozowania wskaźników cen żywności w niniejszym badaniu wybrano dwie duże klasy metod prognostycznych: metody wygładzania wykładniczego oraz modele regARIMA (rozdz. 3). Obie te metody są szeroko wykorzystywane w prognozowaniu szeregów czasowych, jednak istnieją między nimi istotne różnice. Pierwsza z nich nawiązuje do rozróżnienia na „metodę” i „model”. Wygładzanie wykładnicze jest prostą adaptacyjną metodą prognozowania, która sama w sobie nie zakłada, że dany szereg został wygenerowany przez proces generujący dane o pewnej strukturze. Jest ona algorytmem przekształcania danych w kierunku uzyskania prognozy punktowej, niepozwalającym jednak na dyskutowanie stochastycznej natury szeregu i np. wynikającej z niej niepewności prognozy. Dopiero ujęcie metod wygładzania wykładniczego w ramach klasy modeli przestrzeni stanów, opracowane przez Ord et al. [1997] i Hyndman i in. [2002] (ETS, ang. *error, trend, seasonality* – błąd, trend, sezonowość), umożliwia przedstawienie szeregów w postaci procesów stochastycznych.

Alternatywna metoda – prognozowanie na podstawie modeli regARIMA – od samego początku zakłada właśnie stochastyczną naturę procesu, która może zostać przybliżona modelem o pewnej postaci. Założenie stochastycznej postaci modelu umożliwia określenie zarówno prognozy punktowej, jak i przedziałów ufności. Hyndman i inni [2008] pokazują, że w metodzie ETS liniowe modele przestrzeni stanów przy pewnych założeniach można przekształcić w taki sposób, aby uzyskać odpowiednią postać modelu ARIMA i odwrotnie. W metodach wygładzania wykładniczego, również przedstawionych w ramach klasy modeli przestrzeni stanów, komponenty, takie jak poziom, trend, sezonowość można odczytać wprost z postaci modelu, podczas gdy w przypadku modelu ARIMA nie jest to takie proste, choć oczywiście możliwe przy pewnych założeniach, jak to dzieje się np. w przypadku dekompozycji szeregu w ramach procedury TRAMO/SEATS, zob. Gómez, Maravall [1996].

Do prognozowania zarówno przy pomocy modeli regARIMA, jak i przy pomocy metody ETS wykorzystano surowe dane, niepoddane żadnej transformacji. W przypadku metody ETS konieczne jest uprzednie zdefiniowanie kryterium doboru modelu (spośród kryteriów informacyjnych AIC, HQ, BIC lub minimalizując błąd średniokwadratowy) oraz metodę estymacji parametrów. W niniejszym opracowaniu przyjęto w tym celu kryterium informacyjne AIC (zgodnie z [Hyndman i in. 2002]). Estymacji parametrów modelu dokonano za pomocą metody największej wiarygodności. Wartości początkowe do optymalizacji parametrów modelu zostały obliczone za pomocą metody *ad hoc* również zaproponowanej przez powyższych autorów. Wybrane specyfikacje modeli, wartości parametrów wygładzania oraz wartości początkowe zmiennych stanu zostały przedstawione w tabeli 7.4. Najczęściej w procesie doboru odpowiedniej postaci modelu wartości kryterium AIC dla przynajmniej połowy z 30 rozważanych wersji modeli nie różniły się od siebie znacząco, natomiast dla kilku były wyraźnie wyższe.

Większość specyfikacji okazała się zgodna z intuicją. W przypadku wszystkich modeli wybrana została specyfikacja bez trendu, co pozostaje w zgodzie z przytoczonymi powyżej wynikami testów stacjonarności. Większość modeli wskaźników cen żywności okazała się lepiej dopasowana do danych, jeżeli wybierana była specyfikacja uwzględniająca sezonowość. Jednak w przypadku różnych grup produktów sezonowość ta miała inny charakter. Dla przykładu, w większości grup z kategorii mięso sezonowość wchodziła do modelu w sposób multiplikatywny, podczas gdy w większości szeregów produktów mleczarskich zaobserwowano sezonowość addytywną. Wskaźniki cen żywności, dla których specyfikacja sezonowa okazała się nieoptymalna dotyczą pieczywa, mięsa wołowego i cielęcego, pozostałych produktów mlecznych, cukru, co również wydaje się zgodne z intuicją.

Nieco zaskakujące wydają się różnice w wybranej specyfikacji modeli dla żywności i napojów bezalkoholowych oraz agregatu żywności, składającego się z prognozowanych grup produktów (*zywnosc\_ogr*). Biorąc jednak pod uwagę fakt, iż do grup wyłączanych ze wskaźnika cen żywności i napojów bezalkoholowych należą warzywa i owoce, których ceny charakteryzują się najsilniejszymi wahaniami sezonowymi, może się zdarzyć, że ich charakter będzie inny<sup>34</sup>.

---

<sup>34</sup> Różnice widać już na oszacowanych wartościach początkowych dla stanów określających poszczególne miesiące. Nawet po uwzględnieniu odmiennego charakteru składnika sezonowego w modelu, w przypadku wskaźnika *zywnosc\_ogr* różnice pomiędzy miesiącami na początku próby były bardzo niewielkie, podczas gdy w przypadku cen żywności i napojów alkoholowych – znacząco większe.

Tabela 7.4. Specyfikacja wybranych modeli, oszacowane wartości parametrów oraz wartości początkowe zmiennych stanu otrzymane w wyniku zastosowania modeli wykładniczego ETS

Wyszczególnienie	Wybrana postać modelu			Wartości parametrów		Wartości początkowe zmiennych stanu												
	błąd	trend	sez.	alpha	gamma	s1	s2	s3	s4	s5	s6	s7	s8	s9	s10	s11	s12	
																		poziom
WM_piecz_i_prod	M	N	N	0,42	-	-	-	-	-	-	-	-	-	-	-	-	-	-
WM_maka_i_poz_zb	M	N	M	0,98	0,00	99,26	0,99	1,00	1,01	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
WM_pieczyno	M	N	N	0,26	-	100,22	-	-	-	-	-	-	-	-	-	-	-	-
WM_mieso	M	N	M	0,29	0,00	99,67	0,99	0,99	1,00	1,01	1,01	1,01	1,00	1,00	1,00	1,00	1,00	1,00
WM_mies_wol_ciel	M	N	N	1,00	-	100,09	-	-	-	-	-	-	-	-	-	-	-	-
WM_mies_wiep	M	N	M	0,40	0,00	99,58	0,99	0,99	1,00	1,01	1,01	1,02	1,01	1,00	1,00	1,00	0,98	1,00
WM_wedliny_razem	M	N	M	0,54	0,00	99,64	0,99	1,00	1,00	1,01	1,01	1,01	1,00	1,00	1,00	1,00	0,99	1,00
WM_wedliny_bezdro	M	N	M	0,53	0,00	99,62	0,99	1,00	1,00	1,01	1,01	1,01	1,00	1,00	1,00	1,00	0,99	1,00
WM_mies_drob	M	N	M	0,00	0,00	100,19	0,98	0,97	0,96	0,99	1,01	1,01	1,02	1,01	1,00	1,02	1,00	1,03
WM_wedl_drob	M	N	A	0,57	0,00	99,92	-0,21	-0,14	0,12	0,36	0,37	0,37	0,18	-0,01	-0,16	-0,36	-0,44	-0,08
WM_mleko_sery_jaj	M	N	A	0,88	0,00	99,69	0,33	0,32	0,65	0,36	-0,21	-0,40	-0,67	-0,51	-0,17	0,06	-0,07	0,30
WM_mleko	M	N	A	0,74	0,00	100,06	0,09	0,11	0,17	0,25	-0,16	-0,19	-0,27	-0,10	-0,18	-0,03	0,04	0,28
WM_sery	M	N	A	1,00	0,00	99,71	0,15	0,40	0,53	0,21	-0,27	-0,34	-0,42	-0,23	-0,24	-0,06	0,02	0,25
WM_poz_prod_ml	A	N	N	0,50	-	100,33	-	-	-	-	-	-	-	-	-	-	-	-
WM_maslo	M	N	M	1,00	0,00	100,54	1,01	1,01	1,02	1,01	1,00	1,00	1,00	0,99	0,99	0,99	0,99	1,00
WM_jaja	M	N	M	0,71	0,00	97,96	1,02	1,01	1,02	1,01	0,99	0,98	0,97	0,98	1,00	1,01	0,99	1,01
WM_tl_rosl	M	N	A	0,68	0,00	100,19	-0,37	0,10	0,07	0,08	0,04	0,10	0,03	0,12	-0,30	-0,03	0,00	0,16
WM_cuk_i_wyr	M	N	N	0,00	-	100,31	-	-	-	-	-	-	-	-	-	-	-	-
WM_cukier	A	N	N	0,00	-	100,50	-	-	-	-	-	-	-	-	-	-	-	-
WM_wyr_cuk	A	N	A	0,36	0,00	100,29	-0,28	-0,08	0,01	0,05	-0,01	0,11	0,08	0,11	-0,03	-0,03	-0,08	0,17
WM_zynwosc_i_napoj	A	N	A	0,15	0,00	100,28	0,26	0,26	0,65	0,57	-1,34	-1,75	-0,63	0,46	0,54	0,39	-0,02	0,60
WM_zynwosc_ogr	M	N	M	0,59	0,00	99,70	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00

Rodzaj powiązań pomiędzy komponentami w modelach ETS: M – multiplikatywny, A – addytywny, N – brak komponentu.

Źródło: obliczenia własne na podstawie danych GUS.

Ponieważ wśród wybranych modeli nie było modeli z trendem, jedynymi parametrami, które musiały być estymowane, były parametry wygładzania z równania poziomu ( $\alpha$ ) oraz równania sezonowości ( $\gamma$ ). Na wartości parametrów są nałożone automatyczne restrykcje powodujące, że model pozostaje stabilny ( $0 \leq \alpha \leq 1$ ;  $0 \leq \gamma \leq (1 - \alpha)$ ). Wartość parametrów  $\alpha$  lub  $\gamma$  równa 0 lub 1 oznacza, że zbieżność algorytmu optymalizacyjnego została osiągnięta na granicy dopuszczalnych dla nich wartości. Wartość 0 dla powyższych parametrów oznacza, że poziom oraz komponent sezonowy w całej próbie pozostają przy swoich początkowych wartościach. Wartość  $\alpha$  bliska 1 oznacza natomiast, że wartości ostatniego błędu (odchylenia wartości rzeczywistej szeregu od prognozy) przenoszą się silniej (niemal w całości) na wartości bieżącego poziomu szeregu, a wagi przypisane poprzednim obserwacjom bardzo szybko się zmniejszają wraz z odległością od momentu bieżącego. Wśród modeli o parametrze  $\alpha$  równym 1 znalazły się wskaźniki cen mięsa wołowego i cielęcego, serów i masła. Wysoką wartość tego parametru zaobserwowano też w przypadku cen mąki i pozostałych produktów zbożowych. Wartość  $\alpha$  równą 0 zaobserwowano z kolei w przypadku cen mięsa drobiowego, cukru i wyrobów cukierniczych.

## 7.4. Specyfikacja i estymacja modeli regARIMA

Drugą metodą, którą wykorzystano do prognozowania wskaźników cen żywności są modele z klasy regARIMA, czyli modele tłumaczące zmienność szeregu przy pomocy modelu regresji liniowej z resztami zachowującymi cechy modelu SARIMA (ang. *seasonal autoregressive integrated moving average*, czyli sezonowe autoregresyjne zintegrowane modele średniej ruchomej). Do regresorów regresji liniowej zalicza się przede wszystkim stałą, zmienne odpowiadające obserwacjom nietypowym, sezonowe zmienne zero-jedynkowe oraz efekty kalendarzowe (szczegółowy opis tych zmiennych – zob. w Hamulczuk red. [2011]). Modele te umożliwiają rozważanie szeregów cechujących się zarówno występowaniem pierwiastków jednostkowych, jak i szeregów stacjonarnych oraz biorą pod uwagę występowanie sezonowych pierwiastków jednostkowych. Za pomocą modeli regARIMA można więc modelować szeregi o bardzo zróżnicowanej formie. Opierają się one wyłącznie na wewnętrznej strukturze szeregu i odwołują do danych przeszłych (wejściowych), są więc bardzo wygodne przy prognozowaniu i bardzo często do tego celu wykorzystywane.

W celu uzyskania prognoz na podstawie modelu regARIMA w pierwszej kolejności należy znaleźć jego postać najbardziej odpowiadającą analizowanemu szeregowi (specyfikacja) oraz oszacować parametry wynikające z przyjętej

struktury modelu (estymacja). Aby można było zastosować wyestymowany model do prognozowania, należy uprzednio sprawdzić jego „jakość”, a więc zweryfikować go pod kątem spełniania wybranych własności statystycznych. Specyfikacji modelu można próbować dokonać „ręcznie”, ustalając stopień integracji zwykłej i sezonowej przy pomocy odpowiednich testów statystycznych, oraz korzystając ze statystyk informujących o stopniu autokorelacji szeregu (funkcje ACF i PACF), jednakże w przypadku bardziej skomplikowanej postaci szeregu proces ten jest żmudny i skomplikowany. Powszechnie stosowaną metodą stało się więc korzystanie z tzw. kryteriów informacyjnych, obliczanych dla wszystkich potencjalnych postaci modelu regARIMA, a następnie porównywanych ze sobą w celu wyodrębnienia modelu, który najlepiej dopasowuje się do danych (model o najniższej wartości wybranych kryteriów informacyjnych). Cały ten proces został zautomatyzowany w pakiecie JDemetra+<sup>35</sup>, z którego skorzystano w procesie prognozowania.

Metody obróbki danych zaimplementowane w pakiecie JDemetra+ umożliwiają uwzględnienie w modelu obserwacji odstających w dwojaki sposób: o ile badacz dysponuje wiedzą na ich temat, można określić ręcznie datę ich wystąpienia i ich charakter (ich wpływ zostanie oszacowany automatycznie), albo też można pozwolić na ich automatyczne wyróżnienie przez program na podstawie kryteriów statystycznych. Skład zbioru regresorów może mieć wpływ na dobór postaci i wartości parametrów docelowego modelu. Równolegle ustalany jest również rodzaj zależności pomiędzy komponentami szeregu czasowego (log-addytywny lub multiplikatywny) – w niniejszym badaniu był on dobierany automatycznie, choć można go również ustalić „ręcznie”.

Oszacowany model jest następnie poddany szeregowi statystycznych testów mających na celu określenie jakości jego dopasowania do danych oraz ocenę spełnienia kryteriów ważnych z punktu widzenia celu, jakiemu będzie służył. W niniejszym badaniu nacisk został położony na statystyki reszt. Wykorzystano testy weryfikujące brak autokorelacji (testy Ljung-Boxa i Boxa-Pierce’a), losowość (test serii Walda-Wolfowitza), liniowość (testy Ljung-Boxa i Boxa-Pierce’a dla kwadratów reszt), oraz normalność (test Doornika-Hansena). Obecność autokorelacji w resztach modelu może świadczyć o niedostatecznym wyspecyfikowaniu modelu, np. o pominięciu pewnych zmiennych objaśniających, ważnych dla dynamiki

---

<sup>35</sup> JDemetra+ jest pakietem statystycznym umożliwiającym sezonową korektę danych opartą na metodach X-12-ARIMA oraz TRAMO/SEATS. W obu tych metodach krokami pośrednimi do uzyskania korekty sezonowości są m.in.: przygotowanie szeregu czasowego poprzez wyróżnienie obserwacji odstających, efektów kalendarzowych itp. (linearyzacja), specyfikacja modelu SARIMA oraz jego estymacja, a także dokonanie na jego podstawie prognoz, wykorzystywanych później w kolejnych krokach desezonalizacji.

badanego szeregu lub o niewłaściwej postaci modelu (np. o potrzebie zastosowania modelu nieliniowego). W efekcie, prognozy pochodzące z modelu cechującego się autokorelacją mogą być nieefektywne, nie tylko z powodu nieefektywnej estymacji parametrów modelu, ale również dlatego, że różnice między wartościami teoretycznymi i rzeczywistymi z ostatnich obserwacji mogą przenosić się na okres prognozy. Jeśli chodzi o normalność rozkładu reszt, to nie jest ona wymagana w przypadku formułowania prognoz punktowych, ale jest to własność bardzo przydatna, jeśli chcemy uzyskać prognozy przedziałowe, jak również do przeprowadzania wnioskowania statystycznego na podstawie otrzymanego modelu. Ponadto, testowano również istotność parametrów (jej brak prowadził do usunięcia odpowiadających im zmiennych z modelu), a także przeprowadzono testy sprawdzające jakość prognoz (tzw. testy *out-of-sample*). Więcej informacji na temat weryfikacji modeli można znaleźć w pracach [Gomez Maravall 2001, Hamulczuk red. 2011]. Wyniki powyższych testów, a także specyfikację i listę obserwacji nietypowych dla każdego z szeregów zawiera tabela 7.5.

Dla wszystkich szeregów w wyniku optymalizacji przyjęta została multiplikatywna postać zależności między komponentami modelu. W modelach nie brano pod uwagę możliwości występowania efektów dni roboczych ani dni tygodnia, testowane było wyłącznie występowanie efektu Wielkanocy (potencjalny wpływ czynników popytowych przed świętami). Efekt ten jednak okazał się bez znaczenia w przypadku niemal wszystkich szeregów.

Wybrane na etapie specyfikacji postacie modeli dla poszczególnych szeregów bardzo się różniły między sobą. Podobieństwa istniały niekiedy między modelami dotyczącymi szeregów powiązanych ze sobą, np. poprzez rodzaj surowca (takie same struktury modeli dla mięsa wieprzowego i wędlin z wyłączeniem drobiowych oraz dla mięsa drobiowego i wędlin drobiowych). Dla większości szeregów uzasadnione okazało się włączenie części sezonowej ARIMA. Wyjątek stanowiły właściwie tylko szeregi wskaźników cen pieczywa, mięsa cielęcego i wołowego, wskaźnik cen agregatu mleko, sery, jaja oraz pozostałych produktów mlecznych, cukru i agregatu cukier i wyroby cukiernicze. W ogromnej większości przypadków były to te same szeregi, dla których wybrana postać modelu ETS również nie zawierała komponentu sezonowego.

Dla wielu wskaźników cen wybrana postać modelu uwzględniała występowanie pierwiastków jednostkowych, zarówno zwykłych, jak i sezonowych. Tymczasem tradycyjne testy (nie)stacjonarności w przypadku wszystkich szeregów wskazywały na stacjonarność. Dobór modelu za pomocą kryteriów informacyjnych, opierający się na mierze dopasowania modelu do danych, może więc dawać inne wyniki niż testy statystyczne.

Tabela 7.5. Specyfikacja modeli regARIMA dla wskaźników cen żywności m/m oraz wyniki testów

Wyszczególnienie	WM pocz_i_prod	WM maka_i_pocz_zh	WM pieczywo	WM mięso	WM mies_wol_ciel	WM mies_wiepr	WM wedliny_razem	WM wedliny_bezdrob	WM mies_drob	WM wedl_drob	WM mleko_sery_jajka
	[(0,1,0)(0,1,1)] nie	[(0,1,0)(0,1,1)] nie	[(0,1,1)(0,0,0)] nie	[(0,1,1)(0,1,1)] nie	[(1,0,0)(0,1,1)] nie	[(1,0,0)(0,1,1)] nie	[(1,0,0)(0,1,1)] nie	[(1,0,0)(0,1,1)] nie	[(0,1,1)(0,1,1)] nie	[(0,1,1)(0,1,1)] nie	[(3,0,1)(0,0,0)] nie
Postać modelu	TC 2000-6	AO 2000-6	TC 2000-1	AO 1999-8	AO 1999-8	AO 1999-8	AO 1999-8	AO 1999-8	AO 2004-6	TC 1999-8	TC 1999-9
Efekt Wielkanocy	TC 2000-8	TC 2000-7	TC 2000-6	TC 2004-6	TC 2000-7	AO 2004-6	TC 2000-7	TC 2000-7	AO 2004-8	AO 2000-7	TC 1999-12
Observacje odstające	AO 2003-6	AO 2004-5	TC 2000-7	AO 2004-8	TC 2000-9	AO 2004-7	AO 2000-8	AO 2000-9	TC 2007-1	AO 2004-6	TC 2003-9
	TC 2006-9	AO 2006-4	TC 2000-8	AO 2004-9	AO 2004-4	AO 2007-7	AO 2001-4	AO 2001-4	AO 2009-1	AO 2004-7	AO 2003-10
	TC 2007-9	TC 2006-9	AO 2003-6	AO 2004-5	AO 2004-5	AO 2008-1	AO 2004-4	AO 2004-4	AO 2009-1	TC 2007-7	TC 2007-9
	TC 2007-11	AO 2007-9	TC 2004-1	AO 2004-6	AO 2004-6	AO 2008-6	AO 2004-6	AO 2004-6	AO 2007-10	TC 2007-10	TC 2007-10
	AO 2010-9	TC 2007-10	AO 2006-9	AO 2004-7	AO 2004-7	AO 2010-6	AO 2004-7	AO 2004-7	AO 2007-7	TC 2012-3	TC 2007-9
	AO 2010-10	TC 2010-9	AO 2006-10	TC 2009-3	TC 2009-3	AO 2010-6	AO 2007-7	AO 2007-7	AO 2008-6	TC 2012-5	TC 2012-5
	AO 2011-3	AO 2011-3	AO 2007-2	AO 2011-1	AO 2011-1	AO 2010-6	AO 2008-6	AO 2008-6	AO 2008-6	TC 2013-9	TC 2013-9
		AO 2013-7	TC 2007-9	TC 2011-9	TC 2011-9		TC 2009-3	AO 2009-3			
			TC 2007-10								
			TC 2007-11								
			TC 2008-5								
			AO 2010-9								
			AO 2010-10								
			AO 2011-2								
			AO 2011-3								
statystyki dla reszt:											
Normalność (p-value testu Doornika-Hansena)	0,365	0,078 (kurtoza)	0,249	0,241	0,371	0,111	0,280	0,280	0,132	0,251	0,310
Autokorelacja (p-value dla testów Ljung-Boxa i Boxa-Pierce'a dla 24 opóźnień)	LB(24): 0,164 BP(24): 0,262	LB(24): 0,429 BP(24): 0,537	LB(24): 0,193 BP(24): 0,281	LB(24): 0,174 BP(24): 0,288	LB(24): 0,783 BP(24): 0,842	LB(24): 0,170 BP(24): 0,279	LB(24): 0,217 BP(24): 0,324	LB(24): 0,188 BP(24): 0,291	LB(24): 0,107 BP(24): 0,167	LB(24): 0,257 BP(24): 0,357	LB(24): 0,171 BP(24): 0,279
Losowość (p-value dla testu serii Waldra-Wolforta)	0,697	0,819	0,819	0,313	0,913	0,642	0,913	0,900	0,024	0,145	0,648
Linijność (p-value dla testów Ljung-Boxa i Boxa-Pierce'a dla kwadratów reszt)	LB(24): 0,189 BP(24): 0,284	LB(24): 0,753 BP(24): 0,833	LB(24): 0,705 BP(24): 0,794	LB(24): 0,778 BP(24): 0,843	LB(24): 0,712 BP(24): 0,804	LB(24): 0,794 BP(24): 0,868	LB(24): 0,300 BP(24): 0,392	LB(24): 0,184 BP(24): 0,257	LB(24): 0,873 BP(24): 0,918	LB(24): 0,053 BP(24): 0,108	LB(24): 0,128 BP(24): 0,208
Testy out-of-sample (p-value dla H <sub>0</sub> że MSE błąd prognoz jest zbliżony do średniej z kwadratów reszt z próby)	0,719	0,192	0,624	0,961	0,700	0,225	0,979	0,963	0,999	0,915	0,859



Tabela 7.5. cd.

Wyszczególnienie	WM_mleko	WM_sery	WM_poz_prod_ml	WM_maslo	WM_jajka	WM_dl_rosl	WM_cukr_i_wyr	WM_calkier	WM_wyr_calk	WM_zywosc_i_napoje	WM_zywosc_ogr
Postać modelu	[(0,1,1) (0,1,1)]	[(0,1,0) (0,1,1)]	[(1,0,1) (0,0,0)]	[(2,0,0) (1,1,1)]	[(0,1,0) (0,1,1)]	[(0,1,1) (0,1,1)]	[(2,0,1) (0,0,0)]	[(1,0,0) (0,0,0)]	[(1,1,0) (0,1,1)]	[(1,0,0) (0,1,1)]	[(0,1,1) (0,1,1)]
Efekt Wielkonozy	nie	nie	tak p-val=0,0143 efekt ujemny	nie	nie	nie	nie	nie	nie	nie	nie
Observacje odsajace	TC 1999-12 TC 2000-9 TC 2007-9 AO 2007-12 AO 2011-1 AO 2011-3 AO 2013-7 TC 2013-9	TC 2003-10 TC 2007-8 TC 2007-9	TC 2007-9 AO 2010-3 AO 2010-4	AO 1999-9 AO 2004-6 TC 2007-9 AO 2009-10 AO 2009-11	TC 1999-9 TC 1999-12 TC 2000-2 TC 2000-8 TC 2003-9 TC 2003-10 AO 2011-3 AO 2005-9 AO 2006-9 TC 2012-3 TC 2012-4 TC 2012-5	AO 2007-11 TC 2008-3 TC 2008-6 TC 2009-11 TC 2010-9 TC 2010-10 TC 2011-2 TC 2012-3 AO 2013-12	AO 1999-6 AO 1999-9 AO 1999-10 TC 2000-2 TC 2000-6 TC 2000-7 AO 2000-10 TC 2000-11 AO 2004-2 AO 2004-4 AO 2009-3 TC 2010-8 TC 2010-8 AO 2010-9 TC 2011-1 AO 2011-3 AO 2011-5 AO 2011-5	AO 2002-6 TC 2004-2 AO 2004-4 AO 2006-8 TC 2008-10 AO 2011-4 AO 2009-2 AO 2013-1 AO 2013-11	AO 2004-6 TC 2007-10 AO 2004-6 AO 2009-4 TC 2011-1 AO 2011-4 AO 2013-1 AO 2013-11	AO 2000-7 AO 2004-6 AO 2006-8	AO 1999-8 TC 2000-6 AO 2004-4 TC 2004-6 TC 2004-8 TC 2007-9 AO 2011-3
statystyki dla reszty:											
Normalność (p-value testu Doornika-Hansena)	0,494	0,838	0,155	0,735	0,490	0,885	0,032 (kurtoza)	0,087 (kurtoza)	0,203	0,328	0,431
Autokorelacja (p-value dla testów Ljung-Boxa i Boxa-Pierce'a dla 24 opóźnień)	LB(24): 0,608 BP(24): 0,726	LB(24): 0,692 BP(24): 0,755	LB(24): 0,096 BP(24): 0,179	LB(24): 0,641 BP(24): 0,729	LB(24): 0,216 BP(24): 0,300	LB(24): 0,372 BP(24): 0,498	LB(24): 0,462 BP(24): 0,571	LB(24): 0,559 BP(24): 0,715	LB(24): 0,444 BP(24): 0,568	LB(24): 0,847 BP(24): 0,909	LB(24): 0,058 BP(24): 0,121
Losowość (p-value dla testu serii Walda-Wolfowitz)	0,5946	0,9378	0,4943	0,3531	0,9414	0,4984	0,1864	0,2013	0,2206	0,1422	0,4917
Liniowość (p-value dla testów Ljung-Boxa i Boxa-Pierce'a dla kwadratów reszty)	LB(24): 0,872 BP(24): 0,927	LB(24): 0,964 BP(24): 0,981	LB(24): 0,061 BP(24): 0,088	LB(24): 0,587 BP(24): 0,677	LB(24): 0,009 BP(24): 0,024	LB(24): 0,278 BP(24): 0,385	LB(24): 0,927 BP(24): 0,952	LB(24): 0,230 BP(24): 0,346	LB(24): 0,137 BP(24): 0,220	LB(24): 0,027 BP(24): 0,056	LB(24): 0,942 BP(24): 0,961
Testy out-of-sample (p-value dla H <sub>0</sub> : że MSE błąd prognoz jest zbliżony do średniej z kwadratów reszty z próby)	0,809	0,930	0,101	0,687	0,762	0,117	0,336	0,859	0,292	0,576	0,995

Źródło: obliczenia własne na podstawie danych GUS.

We wszystkich modelach występują obserwacje odstające, jednak ich liczba zmienia się w zależności od grupy COICOP. Część tych obserwacji jest wspólna dla większości szeregów czasowych (np. obserwacje odstające występujące w miesiącach kwiecień-sierpień 2004 to cenowe skutki akcesji Polski do UE; natomiast te z miesięcy wrzesień-listopad 2007 to bezprecedensowy wzrost cen większości surowców rolnych na rynkach światowych), część z nich jest charakterystyczna dla danej grupy produktów.

Największa liczba obserwacji nietypowych wystąpiło w przypadku wskaźnika cen pieczywa, wskaźnika cen cukru i wyrobów cukierniczych (agregat) oraz wskaźnika cen cukru. Relatywnie dużo jest ich również w modelach dla szeregów: mąka i pozostałe produkty zbożowe, mięso wołowe i cielęce, wędliny razem oraz wędliny z wyłączeniem drobiowych, a także jaja. Duża liczba obserwacji nietypowych w przypadku cen produktów zbożowych wiąże się z tym, że cechują się one gwałtownymi wzrostami w sytuacji silnego wzrostu ceny zbóż (obserwacje odstające w lecie lub na jesieni 2000 – spadek zbiorów, 2006 – susza i spadek zbiorów, 2007 i 2010 – wzrosty cen na rynkach światowych). Natomiast gdy ceny zbóż obniżają się, ceny produktów zbożowych zachowują się dużo bardziej stabilnie. Taką cechą posiadają zwłaszcza ceny pieczywa, natomiast ceny mąki reagują na spadki cen surowca bardziej elastycznie (por. tabela 7.2). W modelu regARIMA trudno jest oddać tego rodzaju asymetrię. Sytuacje gwałtownych wzrostów cen są więc traktowane jako obserwacje odstające, a dynamika cen poza tymi okresami – modelowana za pomocą zależności typu regARIMA. Trzeba to mieć na uwadze przy prognozowaniu tej grupy produktów: model ten będzie prognozował względnie dobrze wyłącznie w sytuacjach stabilności na rynku zbóż. Zawirowania prowadzące do gwałtownych wzrostów cen surowca (np. na skutek występowania niekorzystnych warunków atmosferycznych) skutkują niedoszacowaniem prognoz. Być może w przypadku tego szeregu lepszymi okazałyby się modele ze zmianą reżimu (Markov-Switching) lub modele progowe, w których dwa stany można modelować przy pomocy procesów stochastycznych o odmiennej postaci.

Z kolei gwałtowne wzrosty cen cukru, których przyczyny zostały opisane wcześniej, również są niemożliwe do przewidzenia w ramach podejścia z tak ograniczoną bazą informacyjną, jak model regARIMA. Zostały więc one wyodrębnione jako obserwacje odstające (poza okresem przed przystąpieniem do UE także kilka obserwacji nietypowych w sezonie 1999/2000 oraz, pod wpływem zmieniających się uwarunkowań regulacyjnych na rynku cukru, obserwacje nietypowe w sezonie 2010/11). W przypadku ogromnej większości wskaźników cen mięsa obserwacje odstające wystąpiły w sierpniu 1999 oraz w miesiącach bliskich momentowi akcesji do UE. W przypadku poszczególnych gatunków

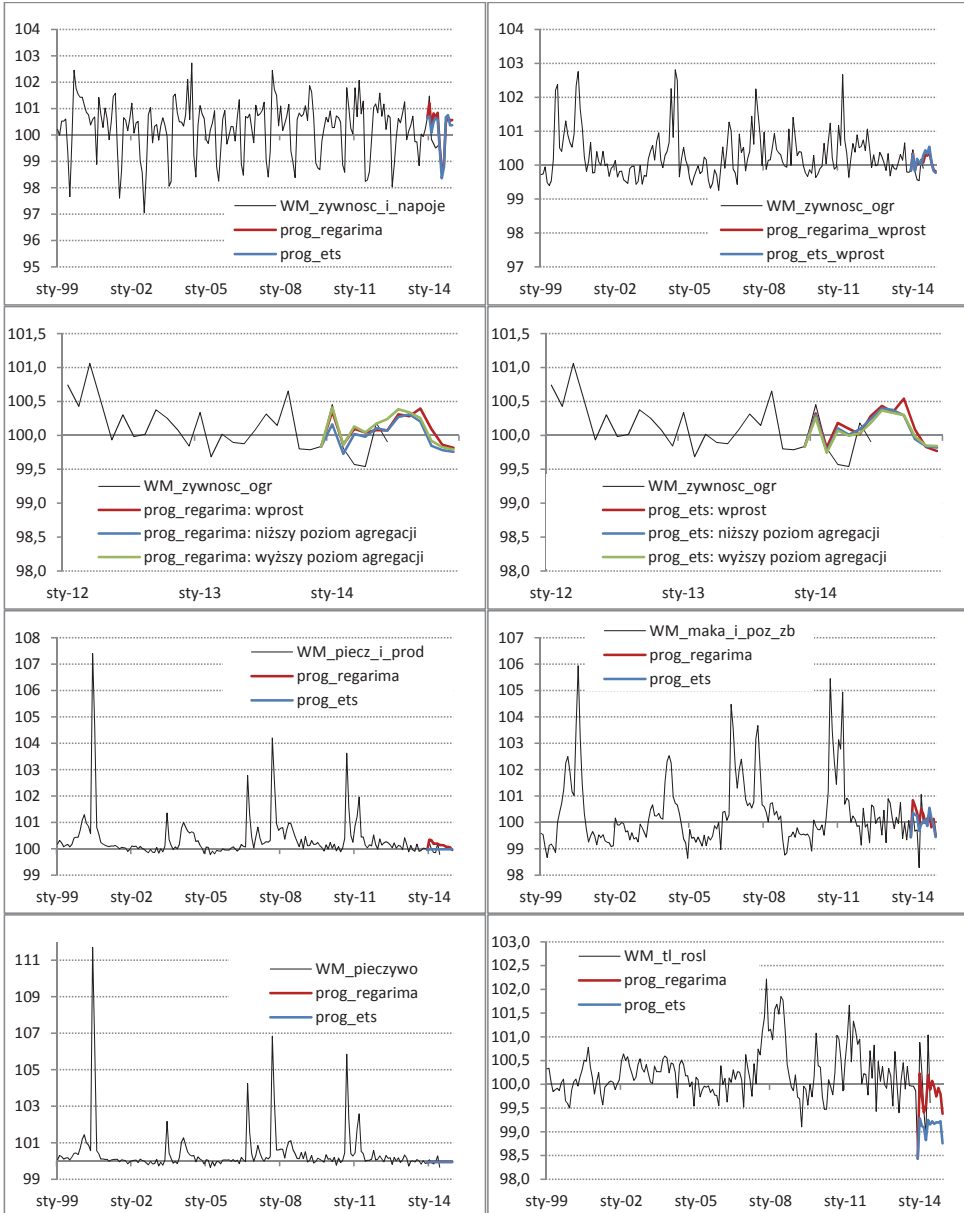
mięś silne okazały się również czynniki sektorowe, np. w przypadku wołowiny w 2011 r. zaobserwowano silny wzrost cen związany z rozpoczęciem eksportu do Turcji. Ceny wieprzowiny w 2007 i 2008 r. rosły silniej niż zazwyczaj na skutek załamywania się popytów trzody chlewnej, natomiast ceny drobiu, cechujące się znaczną zmiennością, wzrosły gwałtownie na początku 2009 r. w wyniku dostosowań podaży. W cenach jaj na początku 2012 r. zaobserwowano silny nietypowy wzrost na skutek wprowadzenia ostrzejszych regulacji unijnych dotyczących dobrostanu kur niosek. Obserwacje nietypowe w przypadku produktów mleczarskich obejmują przede wszystkim, podobnie jak we wskaźnikach cen mięsa, wrzesień oraz grudzień 1999, sierpień-wrzesień 2007 oraz początek 2011 r. – skutki silnego wzrostu cen mleka w proszku i masła na rynku międzynarodowym, a także koniec lata 2013 r. ze względu na napięcia podaży na krajowym rynku mleka. Ceny tłuszczów roślinnych charakteryzowały się nietypową dynamiką między innymi w 2007 i 2008 r. oraz na przełomie lat 2010/2011 na skutek silnych wzrostów cen olejów w świecie.

Weryfikacja powyższych modeli dawała zazwyczaj satysfakcjonujące wyniki. Tylko model dla wskaźnika cen cukru nie spełnił warunku normalności reszt na poziomie istotności 0,05. Problemem była wyższa niż w rozkładzie normalnym kurtoza. Warunek braku autokorelacji na poziomie istotności 0,05 spełniły wszystkie szeregi. Testu liniowości nie spełnił model dla wskaźnika cen jaj, a testu losowości wg pierwszego kryterium – model wskaźnik cen mięsa drobiowego. Testy *out-of-sample* były spełnione dla wszystkich szeregów.

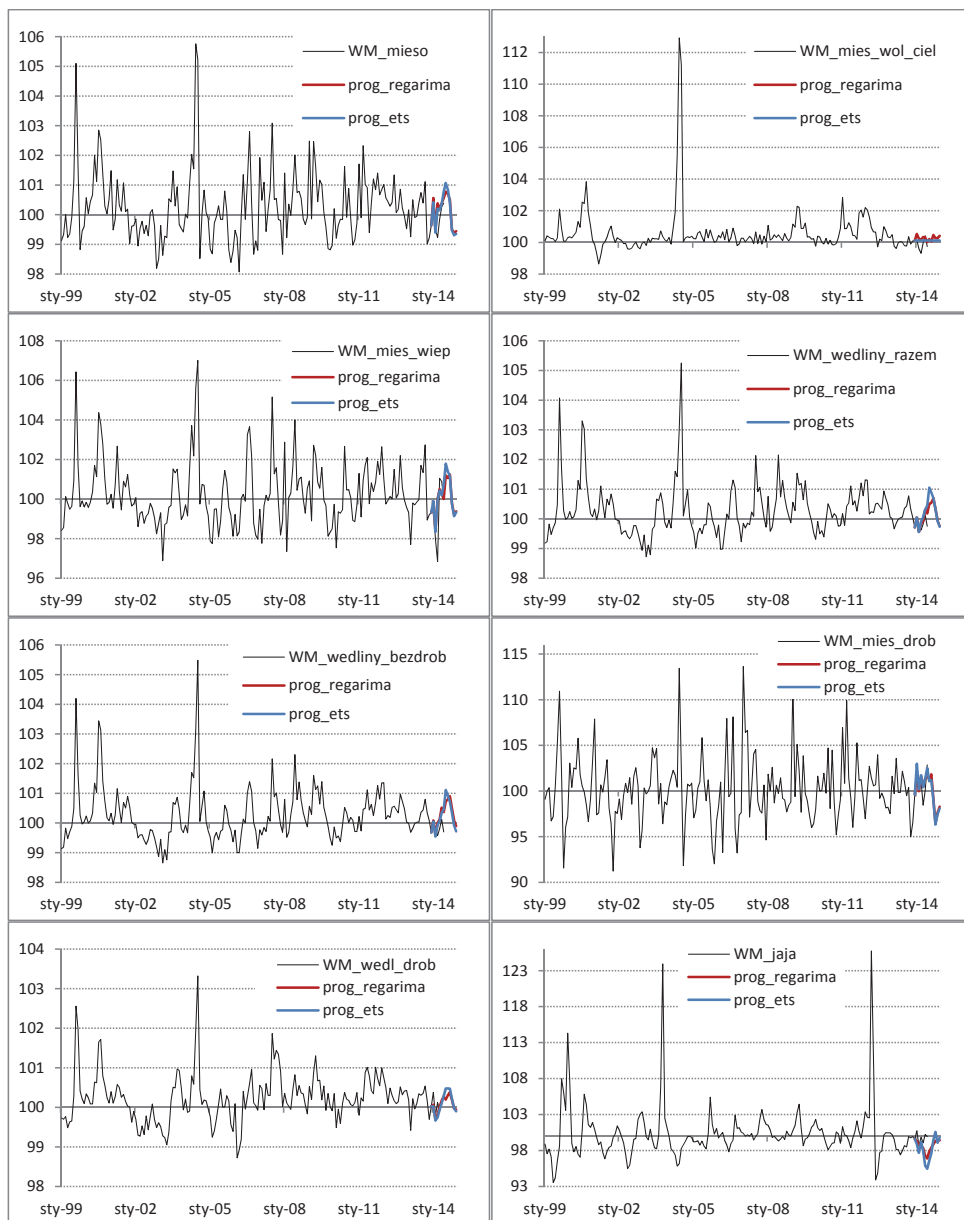
## 7.5. Prognozy i ich dokładność

Po przetestowaniu powyższych modeli wygenerowano na ich podstawie prognozy dla okresu styczeń-grudzień 2014. Zestawienie prognoz znajduje się na rysunku 7.1. Dla miesięcy styczeń-czerwiec 2014 r. dostępne są rzeczywiste dane dotyczące dynamiki cen żywności. Dla tego okresu można więc ocenić, na jakim poziomie kształtowały się błędy prognoz *ex post* oraz porównać je między metodami. Oczywiście ogólna ocena, czy dana metoda prognostyczna daje zazwyczaj lepsze wyniki niż inna, możliwa jest wówczas, gdy wygenerowanych prognoz byłoby odpowiednio dużo. Jedne metody prognostyczne mogą sprawdzać się lepiej w jednych okresach, drugie – w innych. Na podstawie analizowanych danych można wyłącznie ocenić, jak dana metoda sprawdziła się w analizowanym przez nas I półroczu 2014 r.

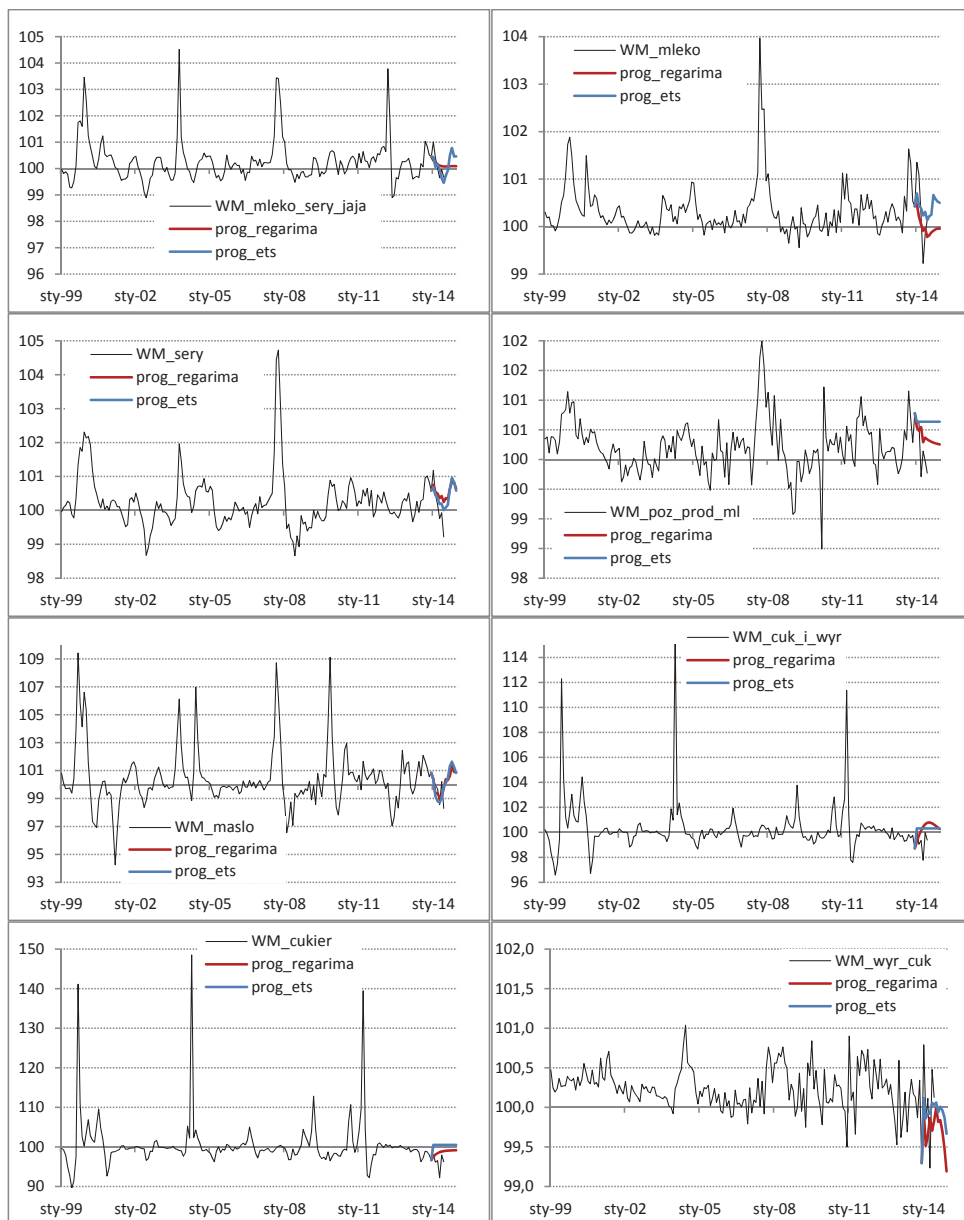
**Rysunek 7.1. Wskaźniki cen detalicznych (m/m) w latach 1999-2014 i ich prognozy**



Rysunek 7.1. cd.



Rysunek 7.1. cd.



Źródło: Opracowanie własne na podstawie danych GUS.

Wartości błędów prognoz oraz kilka miar błędów dla całej ścieżki prognozy łącznie przedstawione są w tabelach 7.6 i 7.7. Błąd prognozy (ME) obliczany jest jako różnica między realizacją a prognozą. Ujemna jego wartość oznacza przeszacowanie prognozy (realizacja niższa niż prognoza), a dodatnia –

niedoszacowanie. Błąd średni, średni błąd absolutny (MAE) i pierwiastek błędu średniokwadratowego (RMSE) obliczone zostały dla analizowanych ścieżek prognozy jako syntetyczne miary ich jakości.

Wartości błędów, przedstawione w tabelach 7.6 i 7.7, nie dają możliwości jednoznacznego rozstrzygnięcia, która z metod skutkuje błędami prognoz o niższej wartości. Na 22 prognozowane szeregi, w przypadku 12 miary błędów wskazywały na metodę ETS, w 9 zaś – na modele regARIMA. Różnice te nie są jednak duże. W analizowanym okresie prognozy częściej były przeszacowane, jednak nie ma właściwie żadnego zróżnicowania efektów wykorzystanych metod w tym kontekście. Zależało to raczej od dynamiki konkretnego szeregu czasowego. Można stwierdzić, że w I kwartale 2014 r. dynamika większości grup cen żywności była niższa niżby wynikała z opisanych w modelach zależności. Być może jest to efektem oddziaływania pewnego wspólnego dla wszystkich szeregów czynnika, nieuwzględnionego *explicite* w powyższych modelach.

**Tabela 7.6. Miary błędów dla prognoz na okres styczeń-czerwiec 2014 r.**

Model / Błąd	WM_zywnosc_i_napoje		WM_zywnosc_ogr					
	ETS	regARIMA	ETS			regARIMA		
	wprost	wprost	wprost	niższy poziom agregacji	wyższy poziom agregacji	wprost	niższy poziom agregacji	wyższy poziom agregacji
sty-14	0,77	0,26	0,13	0,15	0,19	0,10	0,29	0,04
lut-14	-0,25	-0,49	-0,01	0,05	0,06	-0,06	0,08	-0,05
mar-	-0,82	-1,15	-0,61	-0,53	-0,50	-0,52	-0,45	-0,56
kwi-	-1,15	-1,18	-0,56	-0,47	-0,45	-0,50	-0,44	-0,50
maj-	-0,99	-1,26	0,16	0,09	0,15	0,10	0,08	0,01
cze-14	0,21	0,12	-0,38	-0,33	-0,28	-0,17	-0,17	-0,34
ME	-0,37	-0,62	-0,21	-0,17	-0,14	-0,17	-0,10	-0,23
MAE	0,70	0,74	0,31	0,27	0,27	0,24	0,25	0,25
RMSE	0,78	0,88	0,38	0,33	0,32	0,31	0,29	0,34

Źródło: obliczenia własne na podstawie danych GUS.

Nie można również jednoznacznie osądzić, czy agregowanie wskaźników cen żywności na niższym poziomie w klasyfikacji COICOP dało w tym przypadku lepsze wyniki jeśli chodzi o prognozy niż prognozowanie wskaźnika wprost. W tabeli 7.7 porównano prognozy autorskiego wskaźnika cen żywności (zagregowane wybrane grupy) pochodzące z modeli opisujących bezpośrednio dynamikę tego wskaźnika, jak również prognozy powstałe w wyniku agregacji wskaźników poszczególnych grup cen żywności. Prognoza powstała na wyższym poziomie agregacji składa się z prognoz wskaźników na poziomie 4 cyfrowego podziału w klasyfikacji COICOP, natomiast prognoza na niższym poziomie agregacji dotyczy wskaźników najbardziej zdezagregowanych spośród

objętych niniejszą analizą. W zależności od użytej metody, raz lepiej w danym okresie wypadły prognozy wprost (regARIMA), innym razem wyższą skuteczność miały prognozy szczegółowych wskaźników. Zatem jeśli dezagregacja (z czym wiążą się dodatkowe koszty) nie wpływa wyraźnie na poprawę jakości prognoz, to nie ma wówczas sensu jej przeprowadzać, jeśli naszym celem jest prognozowanie inflacji.

**Tabela 7.7. Miary błędów dla prognoz wybranych wskaźników cen żywności na okres styczeń-czerwiec 2014 r.**

Model	ETS	regARIMA	ETS	regARIMA	ETS	regARIMA	ETS	regARIMA
Zmienna	piecz_i_prod		maka_i_poz_zb		pieczywo		mieso	
ME	0,01	-0,24	-0,24	-0,59	0,01	0,00	-0,28	-0,33
MAE	0,15	0,25	0,62	0,78	0,15	0,15	0,32	0,34
RMSE	0,17	0,28	0,81	0,90	0,19	0,19	0,45	0,51
Zmienna	mies_wol_ciel		mies_wiep		wedliny_razem		wedliny_bezdrob	
ME	-0,26	-0,41	-0,49	-0,37	-0,20	-0,12	-0,23	-0,29
MAE	0,36	0,44	0,93	0,81	0,29	0,21	0,33	0,35
RMSE	0,45	0,51	1,36	1,35	0,35	0,24	0,39	0,39
Zmienna	mies_drob		wedl_drob		mleko_sery_jaja		mleko	
ME	-0,66	-0,25	0,15	0,10	0,16	-0,04	-0,06	0,25
MAE	0,89	1,00	0,16	0,14	0,32	0,34	0,49	0,52
RMSE	1,06	1,14	0,22	0,19	0,35	0,39	0,59	0,61
Zmienna	sery		poz_prod_ml		maslo		jaja	
ME	-0,19	-0,35	-0,50	-0,29	0,18	0,00	2,23	1,54
MAE	0,37	0,49	0,50	0,36	0,77	0,65	2,23	1,60
RMSE	0,44	0,57	0,62	0,45	0,94	0,80	2,74	1,93
Zmienna	tl_rosl		cuk_i_wyr		cukier		wyr_cuk	
ME	0,90	0,19	-1,03	-0,89	-4,32	-2,21	0,11	0,35
MAE	0,90	0,50	1,03	1,19	4,32	2,39	0,35	0,56
RMSE	1,11	0,56	1,29	1,39	4,74	3,09	0,44	0,60

Źródło: obliczenia własne na podstawie danych GUS.



## **8. Prognozowanie wskaźników detalicznych cen żywności na podstawie zależności przyczynowych**

W niniejszym rozdziale przedstawiono wyniki prognozowania wybranych wskaźników cen detalicznych żywności, będących podzbiorem zmiennych analizowanych w rozdziale 7. Tym razem jednak wykorzystano modele opisujące zależności między cenami żywności a innymi zmiennymi. Zastosowano przy tym dwa dominujące podejścia teoretyczne. Pierwsze polegało na opisanu zmienności cen żywności poprzez zmienność szeregów wchodzących w skład potencjalnych kosztów produkcji i dystrybucji żywności: cen surowców rolnych lub cen produktów niżej przetworzonych, wynagrodzeń, kosztów energii elektrycznej, cen paliw. Tak sformułowane modele nawiązują do procesu transmisji cenowej, opisaney w rozdziale 2. Drugim podejściem, mającym charakter uzupełniający w stosunku do analizy transmisji impulsów cenowych, jest analiza współmienności wskaźników cen żywności mogących stanowić swoje substytuty. Modele czerpiące z obydwu tych podejść zostały następnie wykorzystane w celu dokonania prognoz punktowych wskaźników cen detalicznych na okres jednego roku (styczeń-grudzień 2014 r.).

Niniejszy rozdział zawiera w pierwszej kolejności ogólny opis procesu analityczno-prognostycznego (8.1). Następnie przedstawiono charakterystykę danych wykorzystanych w badaniu (8.2). Zbiór zmiennych opisanych w rozdziale 7 został uzupełniony o informacje dotyczące zmiennych pozostających z nimi w potencjalnych relacjach przyczynowo-skutkowych. Podrozdziały 8.4 i 8.5 zawierają informacje nt. wyników specyfikacji, estymacji i weryfikacji, odpowiednio, jednorównaniowych modeli przyczynowo-skutkowych oraz modeli VAR/VECM. Na koniec (podrozdział 8.5) przedstawiono wyniki ćwiczenia prognostycznego z udziałem opisanych wcześniej modeli oraz porównano ich możliwości prognostyczne w okresie styczeń-czerwiec 2014 r.

### **8.1. Wprowadzenie do modelowania**

W poprzednim rozdziale przedstawiono zastosowanie przykładowych metod prognozowania szeregów czasowych opierających się na modelach jednowymiarowych. Oznacza to, że do wykonania poszczególnych prognoz wykorzystano informacje wyłącznie na temat poszczególnych analizowanych szeregów: ich dynamicznej struktury oraz charakterystyki jej ukrytych komponentów (trendu/cyklu, wahań sezonowych). Podejście to jest bardzo wygodne do zastosowania, gdyż w sposób automatyczny ogranicza zasób wiedzy konieczny do

sformułowania prognozy. W efekcie prognozę wykonać mogą nawet osoby niemające żadnej wiedzy eksperckiej na temat badanego zjawiska (choć oczywiście jest ona pożądana w celu interpretacji uzyskanych wyników). Jednocześnie, cechą tych metod jest brak konieczności przyjmowania dodatkowych założeń na temat kształtowania się otoczenia wybranych zmiennych.

Istnieją jednak sytuacje, w których badacz potrzebuje nie tylko uzyskać informację na temat najbardziej prawdopodobnego kształtowania się poziomu wybranej zmiennej, ale również na temat tego, z czego ten poziom wynika. Inaczej mówiąc, może chcieć rozpoznać mechanizm, który pomoże wyjaśnić oczekiwaną dynamikę tej zmiennej. W tym celu potrzebny jest już większy zasób informacji, dotyczący m.in. zachowania się innych zmiennych mających wpływ na dane zjawisko, jak również na temat zależności między nimi.

Z drugiej strony, nawet jeśli zbudowanie scenariusza nie jest konieczne, dynamika innych zmiennych może wzbogacić wiedzę o analizowanym szeregu czasowym. Do sformułowania prognoz można wtedy wykorzystać informacje nie tylko na temat dynamiki badanej zmiennej, ale także dynamiki zmiennych z nią powiązanych. Często w tym celu wykorzystuje się modele typu VAR (modele wektorowej autoregresji), w których proces generujący dane obejmuje nie tylko analizowany szereg, ale także inną zmienną czy zmienne, które mogą być z nim i między sobą powiązane. Najczęściej zmiennych tych wybiera się niedużo, aby opis dynamiki i wzajemnych współzależności był jak najbardziej przejrzysty. Dobór zmiennych wchodzących w skład modelu VAR często oparty jest na przesłankach teoretycznych, np. w odniesieniu do pewnej teorii opisującej związek badanej zmiennej z jej otoczeniem. W kontekście prognozowania modele VAR w swojej podstawowej postaci posiadają tę samą zaletę, co opisane w rozdziale 7 jednorównaniowe metody prognozowania, a mianowicie generują wartości poza próbę opierając się wyłącznie na informacjach dostępnych w próbie. Nie potrzeba tu formułować żadnych dodatkowych założeń dotyczących kształtowania się zmiennych egzogenicznych, gdyż wszystkie zmienne wchodzące w skład modelu VAR mają charakter endogeniczny i są opisane przez jeden wspólny proces generujący dane [Lütkepohl, Krätzig 2004].

Ponieważ charakter analizowanych zmiennych może być bardzo różny: mogą się one cechować sezonowością, trendami deterministycznymi i stochastycznymi, zmianami strukturalnymi, itp., postać modeli VAR musi je uwzględnić [Lütkepohl Krätzig 2004]. Jeśli zmienne są zintegrowane w jednakowym stopniu, może się okazać, że niektóre z nich charakteryzują się wspólnymi trendami stochastycznymi (są skointegrowane). Występowanie tej cechy podlega testowaniu. W celu uwzględnienia kointegracji bezpośrednio, wyjściowe modele

VAR zapisuje się w nieco innej formie, w której relacja kointegrująca występuje *explicite*. Są to modele VECM (modele wektorowej korekty błędem).

Budowa modeli prognostycznych uwzględniających relacje długookresowe między zmiennymi wymaga w pierwszej kolejności przetestowania występowania między nimi kointegracji. W niniejszym badaniu dokonano tego na dwa sposoby: korzystając z testu kointegracji Engle'a-Grangera oraz testu Johansena.

Pierwszy test opiera się na analizie reszt jednorównaniowego modelu opisującego związku między interesującymi nas zmiennymi. Nadaje się on szczególnie do analizowania sytuacji, w której oczekujemy wystąpienia tylko jednej relacji kointegrującej między zmiennymi. Tak też jest i w naszym przypadku: chcielibyśmy poznać relację między cenami detalicznymi a kosztami produkcji, przy czym zmienną objaśnianą są właśnie ceny detaliczne żywności. Do estymacji parametrów powyższego modelu wykorzystano metodę DOLS (*dynamic ordinary least squares* – dynamiczna metoda najmniejszych kwadratów). Polega ona na włączaniu do równania wcześniejszych oraz późniejszych wartości zmiennej objaśnianej i ma na celu rozwiązanie potencjalnego problemu autokorelacji reszt i endogeniczności zmiennych objaśniających (ich skorelowania ze składnikiem losowym) [Maddala 2006].

Następnie, zgodnie z metodyką Engle'a-Grangera, na resztach z oszacowanego modelu wykonywano test pierwiastka jednostkowego (analogiczny do testu ADF, z automatycznym doбором liczby opóźnień na podstawie kryterium AIC) w celu oceny, czy reszty te kształtują się wokół pewnej stałej średniej, czy mają charakter błędzenia losowego. Jeśli wynik testu sugerował ich stacjonarność, były one wykorzystywane do oszacowania jednorównaniowego modelu korekty błędem (ECM), w którym zmienną objaśnianą były dynamiki cen detalicznych żywności. Do modeli włączano również, tam gdzie wydawało się to konieczne, sezonowe zmienne zero-jedynkowe oraz zmienne zero-jedynkowe opisujące obserwacje nietypowe dla cen detalicznych na danym rynku. Biorąc pod uwagę możliwość reakcji krótkookresowej rozłożonej w czasie, maksymalne opóźnienia zmiennych objaśnianych oraz zmiennej objaśnianej ustalano na 6, a następnie zgodnie z metodyką „od ogólnego do szczegółowego” usuwano zmienne nieistotne, a także zmienne, których parametr miał znak odbiegający od sugerowanego przez teorię. Wypcyfikowany i oszacowany w ten sposób model był następnie modyfikowany w celu możliwości uwzględnienia asymetrycznej reakcji na odchylenia od równowagi długookresowej o różnych znakach (zob. podrozdział 8.4).

W celach prognostycznych dokonano prognoz z obydwu typów modeli – z symetryczną i asymetryczną reakcją na nierównowagę. Wartości zmiennych

objaśniających musiały zostać zaprognozowane na zewnątrz modelu ECM. Część z tych prognoz pochodzi z modeli opisanych w rozdziale 6 (ceny pszenicy – nazwa zmiennej w modelach: CR\_pszen, ceny żywca wołowego: CR\_bydło, ceny trzody chlewnej: CR\_trzoda, ceny drobiu w skupie: CR\_drob, ceny mleka w skupie: CR\_mleko). Pozostałe pochodzą z modeli pomocniczych stworzonych na potrzeby wyłącznie niniejszej analizy (CR\_cukier, CZ\_masło – prognoza stworzona przez uśrednienie wyników prognoz z procedury regARIMA oraz modeli ETS).

Alternatywne prognozy powstały przy wykorzystaniu modeli VAR, a tam, gdzie prawdopodobne było wystąpienie relacji długookresowej pomiędzy zmiennymi – przy użyciu modeli VECM. W pierwszym kroku, w celu ustalenia, który typ modelu wektorowej autoregresji zostanie wykorzystany, przeprowadzono testy kointegracji Johansena. Do wyjściowego modelu VAR (wyspecyfikowanego na poziomach zmiennych) wybierano interesujący nas wskaźnik cen żywności oraz pewne potencjalne zmienne objaśniające – najczęściej cenę odpowiedniego surowca rolnego, a także inne omawiane wcześniej składniki kosztów. W przypadku możliwych alternatywnych specyfikacji w niniejszej pracy prezentowano ten model, który dawał w końcowej fazie najlepiej wyspecyfikowany model VECM pod względem spełnienia testów autokorelacji i normalności oraz dopasowanego współczynnika  $R^2$ . Liczbę opóźnień ustalano na podstawie standardowych kryteriów informacyjnych (AIC, SIC, HQ), przy czym jeżeli kryteria te sugerowały różną liczbę opóźnień, wybierano tę wyższą. Liczba opóźnień mogła być następnie skorygowana, jeżeli zmiana ta umożliwiała redukcję autokorelacji w resztach. Niekiedy modele VAR/VECM opierały się również na współzależnościach pomiędzy cenami dóbr substytucyjnych. W przypadku ewidentnych obserwacji odstających w danych wejściowych, do modelu VAR włączano odpowiednie zmienne zero-jedynkowe.

Decyzję o potencjalnej kointegracji pomiędzy zmiennymi i o liczbie występujących relacji kointegrujących podejmowano na podstawie testu śladu, który wydaje się odporniejszy na potencjalny brak normalności reszt modelu [Cheung, Lai 1993] – problem ten dość często występował w przypadku wybranych zestawów zmiennych. Test śladu opiera się na sekwencji hipotez, poczynając od testowania hipotezy zerowej mówiącej o zerowej liczbie równań kointegracyjnych i alternatywnej (liczba równań kointegracyjnych  $>0$ ), poprzez kolejne pary hipotez mówiące o liczbie równań kointegracyjnych równych 1, 2, ..., aż do pary hipotez odnoszącej się do liczby potencjalnych równań kointegracyjnych równej liczbie zmiennych w modelu minus 1. Liczbę równań kointegracyjnych sprawdzano poczynając od najniższej możliwej (0), odrzucając, bądź

nie, odpowiednią hipotezę zerową. Testowanie kończy się w momencie, w którym po raz pierwszy nie jesteśmy w stanie odrzucić hipotezy zerowej.

W przypadku występowania przynajmniej jednej relacji kointegrującej z wybranych zmiennych budowany był model VECM. Jego własności testowane były na podstawie testów autokorelacji Portmanteau i testu LM Breusch-Godfrey, a także testu normalności reszt Doornika-Hansena. Szerzej o wspomnianych testach statystycznych piszą Lütkepohl i Krätzig [2004].

Jeżeli pomiędzy wybranymi zmiennymi nie znajdowano relacji kointegrującej, podejmowano próbę wyspecyfikowania modelu VAR na pierwszych przyrostach badanych zmiennych (dane stacjonarne), aby uwzględnić przynajmniej zachodzące interakcje krótkookresowe. Na podstawie wyspecyfikowanych powyżej modeli generowano prognozy na okres od stycznia do grudnia 2014 r.

## 8.2. Dane statystyczne

Analizę relacji pomiędzy cenami żywności a ich potencjalnymi determinantami przeprowadzono na zbiorze wskaźników ograniczonym w stosunku do tego rozważanego w rozdziale 7. Z jednej strony, w grupach towarów, gdzie zbiór potencjalnych determinantów był podobny, modele budowane były dla agregatu (np. pieczywo i produkty zbożowe). Tam, gdzie agregat zaproponowany przez GUS był niejednorodny lub istniała możliwość wykorzystania różnych determinantów do opisu zachowania poszczególnych podkomponentów (np. agregat „mleko, sery, jaja” lub „mięso”), skupiano się na prognozowaniu wskaźników na niższym poziomie agregacji. Jednocześnie, podobnie jak w rozdziale 7, starano się zapewnić możliwość zagregowania powyższego zbioru danych do wskaźnika cen żywności zawierającego wszystkie omawiane grupy towarów żywnościowych (zywnosc\_ogr).

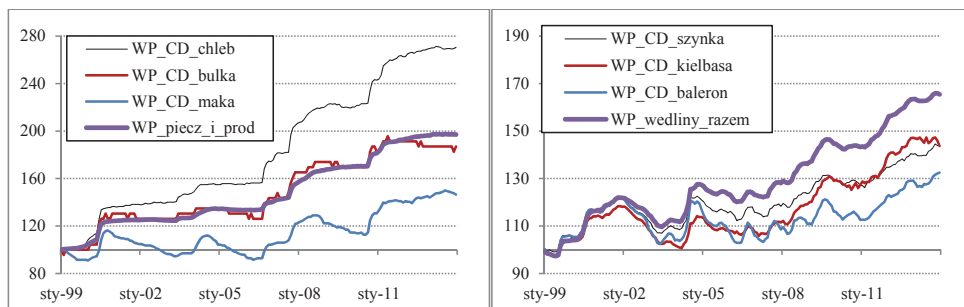
Cechy wskaźników cen detalicznych żywności m/m zostały opisane w rozdziale 7.2. Aby w modelach prognostycznych móc uwzględnić nie tylko oddziaływania krótkookresowe między badanymi zmiennymi, ale również ich związki długookresowe, należałoby rozważać nie tyle comiesięczne zmiany, co poziomy cen. W niniejszym badaniu średni poziom cen danej grupy towarów przybliżono wskaźnikami jednopodstawowymi tych cen. Dokonano więc przeliczenia wskaźników miesięcznych na wskaźniki jednopodstawowe wg poniższej formuły, wyznaczając na podstawie grudzień 1998 r.:

$$WP_t^i = WP_{t-1}^i \cdot WM_t^i / 100, \quad (8.1.)$$

gdzie:  $WP_t^i$  to wskaźnik jednopodstawowy zmiennej  $i$  w okresie  $t$ , zaś  $WM_t^i$  to wskaźnik m/m zmiennej  $i$  w okresie  $t$ .

Analizowane wskaźniki GUS nie dotyczą jednego i tego samego fizycznego dobra, ale są wskaźnikami agregatowymi, tj. prezentują średnie zmiany cen pewnego zbioru towarów. Ponadto, sposób konstruowania wskaźników cen towarów i usług konsumpcyjnych przez GUS implikuje, że skład szczegółowo wyróżnionych towarów wchodzących do agregatu może teoretycznie zmieniać się nawet co roku (w praktyce zmiany następują znacznie rzadziej, ale przyjęta przez GUS metodyka, mająca na celu dostosowywanie reprezentantów do faktycznie konsumowanych przez nabywców towarów oraz jednocześnie uwzględniająca dostępność tych towarów w sklepach, umożliwia takie zmiany). Dlatego wskaźniki agregatowe mogą zachowywać się nieco inaczej niż pojedyncze szeregi wchodzące w ich skład i warto traktować je jako zmienne oddające dynamikę cen abstrakcyjnych towarów, np. dobra zwanego „pieczywo i produkty zbożowe”, czy „mięso”. Ponieważ agregat jest średnią ważoną dynamiki cen wielu produktów, dobra o większym udziale w wydatkach gospodarstw domowych będą w nich silniej reprezentowane niż dobra o niskim udziale. Dlatego też przebieg agregatu może być zbliżony do niektórych dóbr bardziej niż do innych. Na rysunku 8.1 przedstawiono kształtowanie się dwóch przykładowych wskaźników jednopodstawowych agregatów cen: pieczywa i produktów zbożowych oraz wędlin łącznie.

**Rysunek 8.1. Wskaźniki jednopodstawowe cen pieczywa i produktów zbożowych oraz cen wędlin na tle wskaźników jednopodstawowych cen przykładowych reprezentantów tych grup towarów**



Źródło: Opracowanie własne na podstawie danych GUS.

Wskaźniki jednopodstawowe cen ze względu na swoją konstrukcję (złożenie wielu zmian cen w ujęciu m/m) zgodnie z intuicją powinny charakteryzować się niestacjonarnością. Przeprowadzone testy ADF, PP i KPSS wskazują, że w ogromnej większości przypadków można je scharakteryzować poprzez obecność pierwiastka jednostkowego (zob. tabela 8.1.). Wyjątek stanowią ceny sera, w przypadku których dwa z trzech testów sugerują stacjonarność wokół trendu

deterministycznego<sup>36</sup>. Trend deterministyczny był istotny na 5 poziomie istotności również w przypadku cen detalicznych mleka i masła, jednak mimo to zmienne te cechowała obecność pierwiastka jednostkowego (choć w przypadku cen masła wartość statystyki testowej kształtowała się blisko wartości krytycznej). Pewne wątpliwości budzą również wyniki testów dla cen detalicznych cukru: testy ADF i PP sugerują obecność pierwiastka jednostkowego, podczas gdy test KPSS sugeruje stacjonarność wokół trendu deterministycznego. Pierwsze przyrosty wszystkich zmiennych okazały się stacjonarne. Warto przy tym podkreślić, że różnice zlogarytmowanych wartości wskaźników jednopodstawowych pomiędzy kolejnymi obserwacjami mówią o procentowych zmianach wartości tych zmiennych z miesiąca na miesiąc i, jeśli chodzi o stacjonarność, powinny mieć własności bardzo zbliżone do wskaźników m/m, rozważanych w rozdziale 7.

**Tabela 8.1. Wyniki testów ADF, PP i KPSS dla wybranych wskaźników jednopodstawowych cen żywności**

Wyszczególnienie	ADF				PP			KPSS
	l. opóz.	zm. determ.	wartość stat.	wart. p	zm. determ.	wartość stat.	wart. p	wartość stat.
WP_piecz_i_prod	1	-	3,07	1,00	-	3,77	1,00	0,27
WP_mies_wol_ciel	2	-	2,80	1,00	-	3,50	1,00	0,18
WP_mies_wiep	1	-	0,75	0,87	-	-2,67	0,25	0,15
WP_mies_drob	3	-	0,47	0,81	-	0,56	0,84	0,29
WP_wedliny_razem	1	-	2,06	0,99	-	2,71	1,00	0,24
WP_mleko	2	c+t	-2,81	0,20	-	5,73	1,00	0,17
WP_sery	2	c+t	-3,84	<b>0,02</b>	-	2,14	0,99	<b>0,07</b>
WP_poz_prod_ml	2	-	2,37	1,00	-	3,31	1,00	0,16
WP_jaja	4	-	0,80	0,88	-	0,61	0,85	0,24
WP_maslo	2	c+t	-3,38	0,06	-	1,45	0,96	<b>0,13</b>
WP_tl_rosl	3	-	1,68	0,98	-	2,72	1,00	0,30
WP_cukier	1	c	-2,54	0,11	-	-0,07	0,66	<b>0,06</b>
WP_wyr_cuk	2	-	4,01	1,00	-	6,55	1,00	0,15
WP_zywnosc_i_napoje	2	-	2,28	0,99	-	2,72	1,00	0,29
WP_zywnosc_ogr	1	-	3,05	1,00	-	3,52	1,00	0,26

Istotność zmiennych deterministycznych w równaniach testowych sprawdzana była na poziomie istotności 0,05. W teście KPSS przyjęto specyfikację z trendem i stałą. Wartość krytyczna dla statystyki testowej na poziomie istotności 0,05 wynosiła 0,146. Zaznaczono wyniki wskazujące na stacjonarność szeregów na poziomie istotności 0,05.

*Źródło: Opracowanie własne na podstawie danych GUS.*

<sup>36</sup> Istotność komponentów deterministycznych była sprawdzana przed weryfikacją hipotez o obecności bądź braku pierwiastka jednostkowego. Wartości krytyczne dla testu istotności trendu i stałej pochodzą z [Lardic, Mignon 2002, s. 137].

Ponieważ badanie opiera się na analizie związków pomiędzy cenami detalicznymi żywności w formie wskaźników a pewnymi determinantami tych cen, analiza stacjonarności dotyczy również tych determinantów. Wyniki testów stacjonarności niektórych ze zmiennych (ceny pszenicy, bydła, trzody, drobiu, mleka w skupie, wynagrodzenia, energia, olej napędowy) zostały przedstawione w rozdz. 6, w tabeli 6.1. Właściwie wszystkie szeregi tam wymienione można określić jako niestacjonarne w poziomie, niezależnie od tego, czy rozważana będzie specyfikacja testu z komponentami deterministycznymi, czy też nie. Jedyne wątpliwości powstają w przypadku cen skupu mleka, w których wynik testu z trendem i stałą sugeruje stacjonarność na poziomie istotności 0,1.

**Tabela 8.2. Wyniki testów ADF, PP i KPSS dla poziomów cen wybranych surowców**

Oznaczenia	ADF					PP			KPSS
	Poziom /przyrost	l. opóz.	zm. det.	wartość stat.	wart. p	zm. det.	wartość stat.	wart. p	wartość stat.
CR_olej_rzep	poziom	4	-	-0,25	0,59	-	-0,21	0,61	<u>0,11</u>
	przyrost	3	-	<u>-3,54</u>	<u>0,00</u>	-	<u>-10,29</u>	<u>0,00</u>	-
CR_rzepak *M_usd	poziom	1	-	-0,10	0,65	-	-0,06	0,66	<u>0,12</u>
	przyrost	3	-	<u>-5,61</u>	<u>0,00</u>	-	<u>-10,25</u>	<u>0,00</u>	-
CR_cukier *M_usd	poziom	2	-	-0,15	0,63	-	-0,17	0,62	0,15
	przyrost	5	-	<u>-5,56</u>	<u>0,00</u>	-	<u>-10,00</u>	<u>0,00</u>	<u>0,09</u>
CZ_maslo	poziom	2	-	0,10	0,71	-	0,06	0,70	<u>0,10</u>
	przyrost	6	-	<u>-4,77</u>	<u>0,00</u>	-	<u>-5,14</u>	<u>0,00</u>	-
CR_jaja	poziom	2	-	-0,10	0,65	c+t	<u>-3,47</u>	<u>0,05</u>	<u>0,04</u>
	przyrost	3	-	<u>-6,23</u>	<u>0,00</u>	-	-	-	-
CR_indeks	poziom	1	-	0,15	0,73	-	0,30	0,77	0,28
	przyrost	4	-	-6,11	<u>0,00</u>	-	-10,90	0,00	<u>0,08</u>

Źródło: Opracowanie własne na podstawie danych GUS.

Jedynymi zmiennymi, niepodlegającymi analizie w rozdziale 6, a wykorzystanymi w niniejszym badaniu, są ceny rzepaku, oleju rzepakowego, cukru, masła w zbycie oraz jaj w zakładach pakujących. Z braku łatwo dostępnych danych na temat krajowych cen cukru na niższym poziomie łańcucha marketingowego niż ceny detaliczne i cen rzepaku (zob. podrozdział 4.7), do niniejszej analizy wykorzystano ceny cukru na giełdzie w Londynie i ceny rzepaku w porcie w Hamburgu, notowane w dolarach i przeliczone za pomocą kursu walut NBP na złote. Ponadto, wśród potencjalnych zmiennych zewnętrznych, wykorzystywanych do modelowania agregatowych wskaźników cen żywności, znajduje się także indeks cen surowców rolnych (CR\_indeks). Jest to indeks



ważonych cen różnych surowców rolnych na giełdach europejskich i światowych, przeliczonych na złote, wykorzystywany w projekcji inflacji NBP<sup>37</sup>.

Z uwagi na dostępność danych, w niektórych przypadkach ograniczono długość próby stosowanej do estymacji. Dane dotyczące cen jaj rozpoczynają się w styczniu 2004 r., w przypadku ceny rzepaku w porcie w Hamburgu dane są dostępne od stycznia 2000 r. Z kolei w przypadku cen bydła i cen wołowiny dane są dostępne od początku 1999 r., ale ze względu na gwałtowną zmianę strukturalną mającą miejsce podczas przystępowania do UE próba ta została skrócona i rozpoczyna się de facto w styczniu 2005 r., co znacznie upraszcza modelowanie.

### **8.3. Specyfikacja, estymacja i weryfikacja modeli jednorównaniowych**

W tej części pracy przedstawiono wyniki testów kointegracji Engle'a-Grangera, a także wnioski płynące z modeli korekty błędem zbudowanych na podstawie oszacowanych relacji długookresowych. Tabela 8.3 zawiera wyniki estymacji relacji długookresowych wraz z wynikami testu Engle'a-Grangera. Ponieważ niekiedy potencjalnych zestawów zmiennych wchodzących w skład relacji kointegrujących było więcej niż 1, w tabeli zamieszczono wyniki tego równania, które było wybierane do dalszej analizy (model ECM zbudowany na jej podstawie miał lepsze własności pod względem zgodności wartości parametrów z teorią ekonomii i intuicją, statystyki testowe autokorelacji lub normalności dawały wyniki bliższe pożądanym itd.).

Większość wybranych relacji długookresowych opiera się na związkach między poziomem cen surowca wykorzystywanego do produkcji towarów żywnościowych należących do rozważanej grupy. Wyjątkiem są ceny wyrobów cukierniczych, w których analizowane surowce nie miały wyraźnego przełożenia w długim okresie, oraz ceny cukru. Wydaje się, że te pierwsze zależą przede wszystkim od wynagrodzeń (intuicyjnie, nie są to dobra pierwszej potrzeby, ale raczej towary o wyższej elastyczności dochodowej popytu) oraz od innych kosztów produkcji (istotny okazał się długoterminowy wpływ cen oleju napędowego). Ceny detaliczne cukru w Polsce nie są związane z cenami na giełdzie w Londynie bezpośrednią relacją kosztową – związek taki istniałby, gdybyśmy jako cenę surowca wykorzystywali ceny buraków cukrowych, które jednak nie spełniają warunków dostępności na potrzeby niniejszej analizy. W przypadku cen jaj oraz cen tłuszczów roślinnych nie znaleziono relacji pomiędzy

---

<sup>37</sup> Autorzy pragną podziękować Karolowi Szafrankowi z NBP za udostępnienie szeregu czasowego indeksu cen surowców rolnych na potrzeby niniejszej analizy.

zmiennymi, dla której test Engle'a-Grangera dawałby wynik pozytywny, dlatego też nie są one wykazane w Tabeli 8.3. Zmienne te są jednak wykorzystywane w podrozdziale 8.5. i modelowane w ujęciu wielowymiarowym.

**Tabela 8.3. Oszacowane relacje długookresowe oraz wyniki testu Engle'a-Grangera dla wybranych wskaźników cen żywności**

Wskaźnik	Relacja długookresowa	Statystyka testu E-G	Liczba opóz.	Wart. p
piecz_i_prod	$I\_WP\_piecz\_i\_prod = -1,36 + 0,12*I\_CR\_pszen + 0,74*I\_M\_wynagr$	-4,1831	12	0,0178
mies_wol_ciel	1) Cała próba: $I\_WP\_mies\_wol\_ciel = 3,71 + 1,07*I\_CR\_bydlo$	-3,622	1	0,0262
	2) Od stycznia 2005 r. $I\_WP\_mies\_wol\_ciel = 0,65 + 0,57*I\_CR\_bydlo + 0,48*I\_M\_wynagr$	-3,8529	12	0,0476
mies_wiepi	$I\_WP\_mies\_wiepi = 3,23 + 0,45*I\_CR\_trzcina + 0,21*I\_M\_energia$	-4,3385	13	0,0114
	$I\_WP\_mies\_wiepi = 2,54 + 0,44*I\_CR\_trzcina + 0,21*I\_M\_wynagr$	-4,4022	12	0,0094
wedliny_razem	$I\_WP\_wedliny\_razem = 2,96 + 0,39*I\_CR\_trzcina + 0,34*I\_M\_energia$	-3,8700	12	0,0409
mies_drob	$I\_WP\_mies\_drob = 3,56 + 0,91*I\_CR\_drob$	-4,9940	0	0,0003
mleko	$I\_WP\_mleko = 4,98 + 0,74*I\_CR\_mleko$	-3,4160	13	0,0450
sery	$I\_WP\_sery = 2,49 + 0,18*I\_CR\_mleko + 0,30*I\_M\_wynagr$	-5,4056	12	0,0003
poz_prod_ml	$I\_WP\_poz\_prod\_ml = 2,09 + 0,10*I\_CR\_mleko + 0,34*I\_M\_wynagr$	-4,4047	13	0,0093
maslo	$I\_WP\_maslo = 1,76 + 0,54*I\_CR\_mleko + 0,41*I\_M\_wynagr$	-4,3080	13	0,0124
	$I\_WP\_maslo = 2,71 + 0,95*I\_CZ\_maslo$	-4,0550	1	0,0013
cukier	$I\_WP\_cukier = 3,46 + 0,12*(I\_CR\_cukier*M\_usd) + 0,60*I\_M\_olej.n$	-4,7307	6	0,0033
wyr_cuk	$I\_WP\_wyr\_cuk = 1,79 + 0,37*I\_M\_wynagr + 0,14*I\_M\_olej.n$	-4,6860	13	0,0038

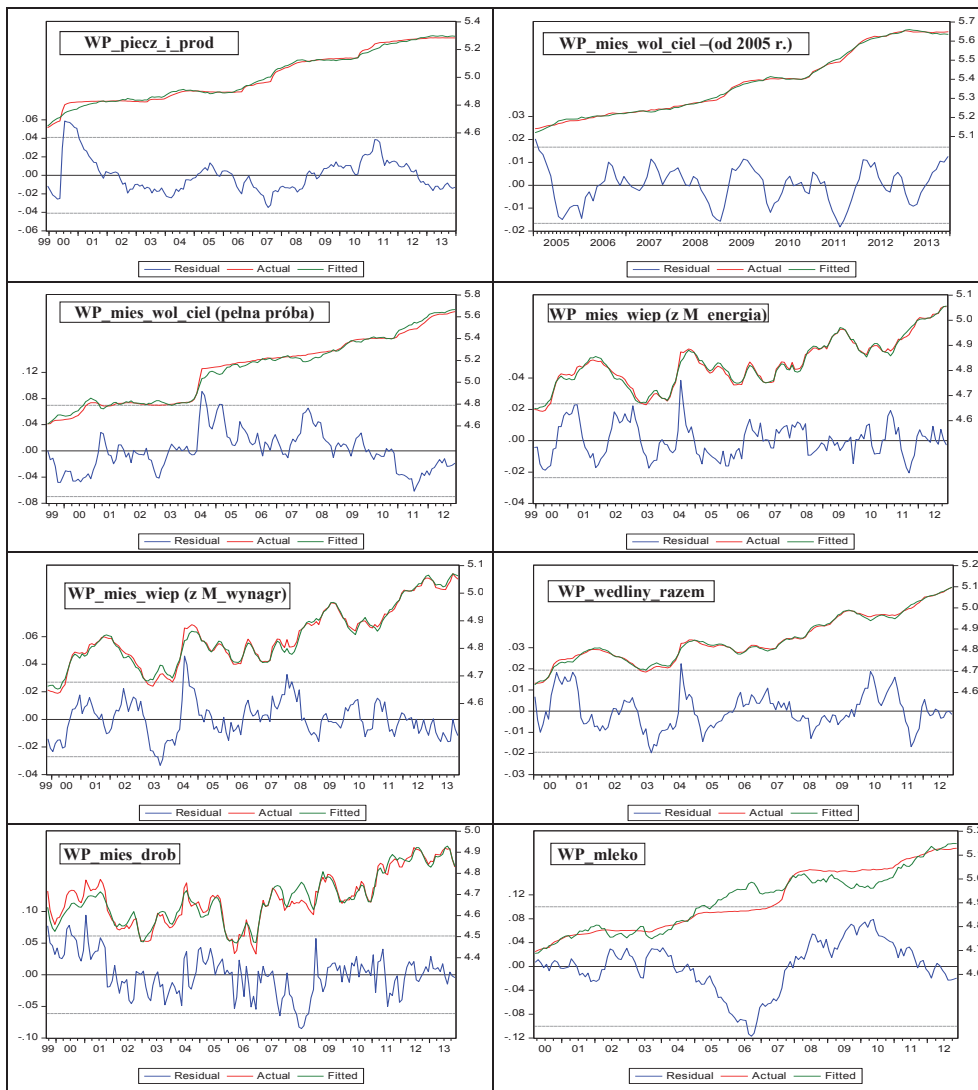
Przedrostek WP\_ oznacza wykorzystanie zmiennej w postaci wskaźnika jednopodstawowego.

Źródło: opracowanie własne.

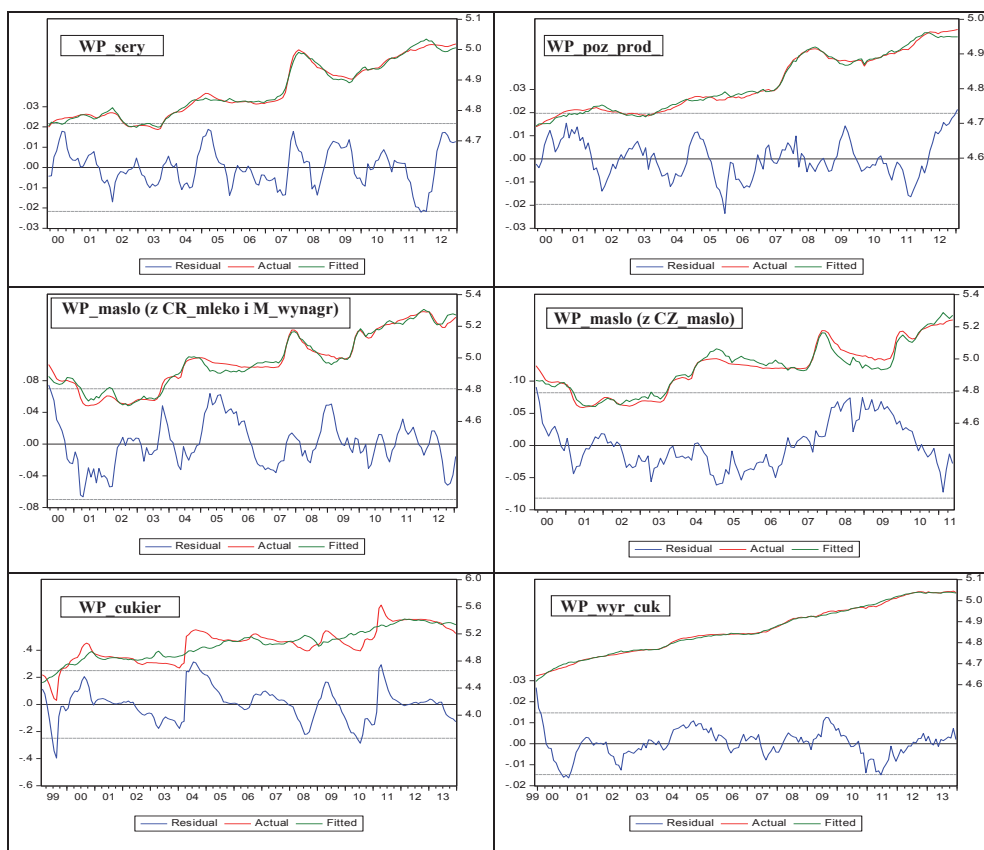
Oszacowane wartości parametrów równań długookresowych w większości przypadków są zgodne z intuicją. Dla produktów niżej przetworzonych obserwujemy silniejsze przełożenie zmian cen surowca na ceny detaliczne i na odwrót – dla tych wyżej przetworzonych wpływ zmian cen surowca jest mniejszy (por. np. ceny mięsa surowego i ceny wędlin czy niski wpływ zmian cen pszenicy na cenę pieczywa). W przypadku cen masła oszacowane relacje pokazują także, zgodnie z oczekiwaniami, że im surowiec podlega mniejszemu

przetworzeniu, tym udział jego ceny w cenie detalicznej jest większy. Na rysunku 8.2. zaprezentowano obok wartości rzeczywistych wskaźników jednopodstawowych oraz modeli oszacowanych metodą DOLS równań długookresowych również reszty relacji kointegrujących.

**Rysunek 8.2. Reszty z relacji kointegrujących (residual – lewa oś) oraz wartości zmiennej objaśnianej (prawa oś): rzeczywiste (actual) i dopasowane (fitted)**



Rysunek 8.2. Reszty z relacji kointegrujących ... cd.



Źródło: Opracowanie własne na podstawie danych GUS.

Wykorzystując oszacowane powyżej relacje kointegrujące dla każdej zmiennej z osobna, zbudowano następnie modele korekty błędem (ECM). Użyte równania opisują dynamikę krótkookresową w analizowanych grupach cen (procentowe zmiany cen), odnosząc się jednocześnie do reakcji na odchylenie od poziomu wyznaczonego przez relację długookresową.

Dla celów analitycznych zbudowano dwa rodzaje modeli ECM. W pierwszym reakcja cen detalicznych na odchylenie od wartości wyznaczonej przez relację długookresową jest symetryczna: ceny reagują identycznie na dodatnie i ujemne odchylenia (por wzór 3.15). W drugim przypadku, w zależności od znaku odchylenia, mechanizm korekty błędem rozbito na dwie zmienne: obejmujące dodatnie oraz ujemne odchylenia od relacji kointegrującej:

$$ECT_t^+ = \begin{cases} ECT_t & \text{dla } ECT_t > 0 \\ 0 & \text{w p.p.} \end{cases} \quad \text{oraz} \quad ECT_t^- = \begin{cases} ECT_t & \text{dla } ECT_t < 0 \\ 0 & \text{w p.p.} \end{cases} \quad (8.2)$$

Działanie to miało na celu zweryfikowanie hipotezy o asymetrycznej reakcji cen detalicznych na zmiany cen surowca, sugerowanej m.in. przez [Roeger, Leibtag 2011]. W przypadku, gdy jedna ze zmiennych okazywała się ewidentnie nieistotna, nie wykazywano jej w tabeli z wynikami. Ponadto, w przypadku cen pieczywa zastosowano jeszcze dodatkowo asymetryczną reakcję krótkookresową na bardzo silne zmiany cen pszenicy (postać zależności została ustalona empirycznie – na podstawie dopasowania do danych w okresach, których dotyczyła)<sup>38</sup>.

Dla wszystkich zmiennych, dla których test Engle'a-Grangera wskazał na możliwość wystąpienia relacji kointegrującej, udało się sformułować modele ECM, w których parametr przy komponencie ECT (mechanizmie korekty błędem, ang. *error correction term*) ma znak ujemny (po odchyleniu od równowagi długookresowej system do niej stopniowo powraca). Reakcja asymetryczna okazała się istotna w przypadku cen pieczywa i produktów zbożowych, mięsa wołowego, wieprzowego, drobiowego, wędlin, serów, cukru i wyrobów cukierniczych. Przyjmowała ona generalnie dwie formy: albo jeden z parametrów przy odchyleniach okazywał się nieistotny – wówczas reakcja na nierównowagę uwzględniona w modelu była jednostronna (najczęściej była to reakcja na relatywny wzrost czynników wyznaczających równowagę długookresową względem zmiennej objaśnianej, np. pieczywo i produkty zbożowe, wołowina, cukier, wyroby cukiernicze; wyjątkiem jest mięso drobiowe, w którym wystąpiła reakcja na odchylenia dodatnie, czyli dostosowanie w dół), albo też istotne okazywały się reakcje odchylenia w obie strony (mięso wieprzowe, sery). W przypadku mięsa wieprzowego różnica pomiędzy prędkością dostosowania była wyraźnie większa niż w przypadku cen serów. Jeśli wprowadzano jednostronną reakcję asymetryczną, parametr przy tej zmiennej miał najczęściej wartość zbliżoną lub wyższą niż parametr w relacji symetrycznej. Jeśli natomiast pozostawały reakcje w obie strony, to parametr relacji symetrycznej zgodnie z intuicją kształtował się pomiędzy parametrami reakcji na odchylenia ujemne i dodatnie. Generalnie, spośród analizowanych zmiennych najszybsze dostosowania (najwyższa wartość parametru dostosowania przy komponencie ECT) mają miejsce w przypadku mięsa wieprzowego i drobiowego.

Wprowadzenie asymetrii do modelu najczęściej nie zmieniało w sposób znaczący jakości modelu. Najczęściej delikatnie wzrastało dopasowanie modelu do danych, mierzone dopasowanym  $R^2$ . Jednak wpływ na autokorelację i normalność reszt modeli pozostawał nieznaczący.

---

<sup>38</sup> Komponent  $(dl\_CR\_pszen_{t-1} > 0,1437)$  występujący w równaniu  $piecz\_i\_prod$  oznacza zmienną zero-jedynkową, która przyjmuje wartość 1, gdy spełniony jest warunek podany w nawiasie  $(0,1437 - 2\text{-krotność przeciętnego wzrostu cen pszenicy w próbie})$ .

Tabela 8.4. Wyniki estymacji modeli korekty błędem dla wskaźników cen żywności

Zmienna	Postać modelu	R <sup>2</sup>	Własności reszt	
			Autokorelacja	Normalność
piecz_1_prod	Symetryczny ECT: dl_WP_piecz_1_prod = 0,00 - 0,03*ECT <sub>t-1</sub> + 0,53*dl_WP_piecz_1_prod <sub>t-1</sub> + 0,01*dl_CR_pszem <sub>t-1</sub> + 0,16*dl_CR_pszem <sub>t-1</sub> *(dl_CR_pszem <sub>t-1</sub> > 0,1437) + 0,002*S9 + 0,07*D2000-6 - 0,02*D2000-8 + 0,01*D2003-6 - 0,02*D2003-12 + 0,02*D2006-9 + 0,02*D2010-9 + 0,01*D2011-3	0,945	Q(1) = 0,40 (0,53) Q(2) = 0,47 (0,79) Q(12) = 14,06 (0,50)	S = 0,03 K = 4,73 JB = 22,22 (0,00)
	Niesymetryczny ECT: dl_WP_piecz_1_prod = 0,00 - 0,03*ECT <sub>t-1</sub> + 0,53*dl_WP_piecz_1_prod <sub>t-1</sub> + 0,01*dl_CR_pszem <sub>t-1</sub> + 0,16*dl_CR_pszem <sub>t-1</sub> *(dl_CR_pszem <sub>t-1</sub> > 0,1437) + 0,001*S9 + 0,07*D2000-6 - 0,02*D2000-8 + 0,01*D2003-6 - 0,02*D2003-12 + 0,02*D2006-9 + 0,02*D2010-9 + 0,01*D2011-3	0,948	Q(1) = 0,17 (0,68) Q(2) = 0,17 (0,92) Q(12) = 11,28 (0,51)	S = 0,07 K = 5,08 JB = 32,35 (0,00)
wol_ciel	Symetryczny ECT – na probie od stycznia 2005 r.: dl_WP_mies_wol_ciel = 0,00 - 0,08*ECT <sub>t-1</sub> + 0,32*dl_WP_mies_wol_ciel <sub>t-1</sub> + 0,03*dl_CR_bydlo <sub>t-1</sub> + 0,01*D2009-3 + 0,01*D2011-1	0,695	Q(1) = 0,01 (0,94) Q(2) = 3,57 (0,17) Q(12) = 10,63 (0,56)	S = 0,54 K = 3,08 JB = 5,21 (0,07)
	Niesymetryczny ECT: dl_WP_mies_wol_ciel = 0,00 - 0,09*ECT <sub>t-1</sub> + 0,31*dl_WP_mies_wol_ciel <sub>t-1</sub> + 0,03*dl_CR_bydlo <sub>t-1</sub> + 0,01*D2009-3 + 0,01*D2011-1	0,705	Q(1) = 0,05 (0,83) Q(2) = 3,54 (0,17) Q(12) = 9,39 (0,67)	S = 0,52 K = 3,02 JB = 4,95 (0,08)
mies_wiep	Symetryczny ECT: dl_WP_mies_wiep = 0,00 - 0,22*ECT <sub>t-1</sub> + 0,06*dl_CR_trzoda <sub>t-1</sub> - 0,007*S2 - 0,006*S10 - 0,004*S11 + 0,04*D1999-8 + 0,03*D2000-7 + 0,04*D2004-7 + 0,04*D2007-7 + 0,03*D2008-1 + 0,02*D2008-6	0,788	Q(1) = 2,38 (0,12) Q(2) = 3,85 (0,15) Q(12) = 15,77 (0,20)	S = 0,51 K = 3,96 JB = 14,46 (0,00)
	Niesymetryczny ECT: dl_WP_mies_wiep = 0,00 - 0,17*ECT <sub>t-1</sub> - 0,26*ECT <sub>t-1</sub> + 0,06*dl_CR_trzoda <sub>t-1</sub> - 0,007*S2 - 0,006*S10 - 0,004*S11 + 0,04*D1999-8 + 0,03*D2000-7 + 0,04*D2004-7 + 0,04*D2007-7 + 0,03*D2008-1 + 0,02*D2008-6	0,790	Q(1) = 2,25 (0,13) Q(2) = 4,14 (0,13) Q(12) = 16,07 (0,19)	S = 0,49 K = 4,09 JB = 16,08 (0,00)
wedliny_razem	Symetryczny ECT: dl_WP_wedliny_razem = 0,00 - 0,04*ECT <sub>t-1</sub> + 0,35*dl_WP_wedliny_razem <sub>t-1</sub> + 0,04*dl_CR_trzoda <sub>t-1</sub> + 0,02*dl_CR_trzoda <sub>t-1</sub> + 0,05*dl_M_energia <sub>t-2</sub> + 0,05*dl_M_energia <sub>t-1</sub> + 0,003*S1 + 0,002*S5 + 0,02*D2000-7 + 0,02*D2004-6 + 0,03*D2004-7 - 0,02*D2004-8 + 0,02*D2007-7	0,864	Q(1) = 0,32 (0,57) Q(2) = 3,62 (0,16) Q(12) = 12,58 (0,40)	S = 0,30 K = 3,32 JB = 3,45 (0,18)
	Niesymetryczny ECT: dl_WP_wedliny_razem = 0,00 - 0,07*ECT <sub>t-1</sub> + 0,35*dl_WP_wedliny_razem <sub>t-1</sub> + 0,05*dl_CR_trzoda <sub>t-1</sub> + 0,02*dl_M_energia <sub>t-2</sub> + 0,05*dl_M_energia <sub>t-1</sub> + 0,003*S1 + 0,002*S5 + 0,03*D1999-8 + 0,03*D2000-7 + 0,02*D2004-6 + 0,03*D2004-7 - 0,02*D2004-8 + 0,02*D2007-7	0,864	Q(1) = 0,09 (0,77) Q(2) = 4,19 (0,12) Q(12) = 12,52 (0,41)	S = 0,17 K = 3,29 JB = 1,46 (0,48)
mies_drob	Symetryczny ECT: dl_WP_mies_drob = 0,00 - 0,14*ECT <sub>t-1</sub> + 0,31*dl_WP_mies_drob <sub>t-1</sub> - 0,13*dl_WP_mies_drob <sub>t-1</sub> + 0,14*dl_WP_mies_drob <sub>t-1</sub> + 0,02*S1 + 0,02*S5 + 0,02*S6 - 0,02*S10 + 0,10*D2004-6 - 0,08*D2004-8 + 0,10*D2007-1 + 0,10*D2009-1	0,533	Q(1) = 1,86 (0,17) Q(2) = 2,60 (0,27) Q(12) = 15,42 (0,22)	S = 0,14 K = 3,94 JB = 6,94 (0,03)
	Niesymetryczny ECT: dl_WP_mies_drob = 0,00 - 0,29*ECT <sub>t-1</sub> + 0,32*dl_WP_mies_drob <sub>t-1</sub> - 0,14*dl_WP_mies_drob <sub>t-1</sub> + 0,14*dl_WP_mies_drob <sub>t-1</sub> + 0,02*S1 + 0,02*S5 + 0,02*S6 - 0,02*S10 + 0,10*D2004-6 - 0,08*D2004-8 + 0,10*D2007-1 + 0,11*D2009-1	0,538	Q(1) = 1,49 (0,22) Q(2) = 1,71 (0,43) Q(12) = 15,12 (0,24)	S = 0,13 K = 3,78 JB = 4,97 (0,08)

Tabela 8.4. cd. Wyniki estymacji ...

Zmienna	Postać modelu	R <sup>2</sup>	Własności reszt	
			Autokorelacja	Normalność
mleko	Symetryczny ECT: dl_WP_mleko <sub>t</sub> = 0,00 - 0,01*ECT <sub>t-1</sub> + 0,46*dl_WP_mleko <sub>t-1</sub> + 0,16*dl_WP_mleko <sub>t-2</sub> + 0,04*dl_CR_mleko <sub>t-1</sub> + 0,002*S1 + 0,002*S9 + 0,03*D2007-9 - 0,01*D2007-12	0,775	Q(1) = 0,00 (1,00)	S = 1,08
			Q(2) = 0,74 (0,69)	K = 5,66
			Q(12) = 8,09 (0,78)	JB = 86,5 (0,00)
sery	Symetryczny ECT: dl_WP_sery <sub>t</sub> = 0,00 - 0,05*ECT <sub>t-1</sub> + 0,76*dl_WP_sery <sub>t-1</sub> - 0,28*dl_WP_sery <sub>t-2</sub> + 0,21*dl_WP_sery <sub>t-3</sub> + 0,05*dl_CR_mleko <sub>t-1</sub> + 0,003*S9 + 0,003*S10 + 0,01*D2007-8 + 0,02*D2007-9	0,899	Q(1) = 0,06 (0,80)	S = 0,33
			Q(2) = 0,17 (0,92)	K = 3,49
			Q(12) = 22,13 (0,04)	JB = 4,87 (0,09)
poz_prod_ml	Symetryczny ECT: dl_WP_poz_prod_ml <sub>t</sub> = 0,00 - 0,02*ECT <sub>t-1</sub> + 0,52*dl_WP_poz_prod_ml <sub>t-1</sub> + 0,14*dl_WP_poz_prod_ml <sub>t-2</sub> + 0,03*dl_CR_mleko <sub>t-1</sub> + 0,001*S7 - 0,01*D2010-3 + 0,02*D2010-4	0,596	Q(1) = 0,01 (0,91)	S = 0,64
			Q(2) = 1,23 (0,54)	K = 3,88
			Q(12) = 10,68 (0,56)	JB = 18,05 (0,00)
maslo	Symetryczny ECT: dl_WP_maslo <sub>t</sub> = 0,00 - 0,03*ECT <sub>t-1</sub> + 0,68*dl_WP_maslo <sub>t-1</sub> - 0,22*dl_WP_maslo <sub>t-2</sub> + 0,12*dl_CR_mleko <sub>t-1</sub> + 0,07*D1999-9 + 0,04*D1999-12 - 0,04*D2001-3 + 0,06*D2004-6 + 0,06*D2007-9 + 0,04*D2009-10 + 0,05*D2009-11	0,798	Q(1) = 0,99 (0,32)	S = 0,67
			Q(2) = 3,96 (0,14)	K = 5,72
			Q(12) = 21,36 (0,05)	JB = 67,94 (0,00)
cukier	Symetryczny ECT: dl_WP_cukier <sub>t</sub> = 0,00 - 0,04*ECT <sub>t-1</sub> + 0,66*dl_WP_cukier <sub>t-1</sub> + 0,38*D2004-4 - 0,18*D2004-5 + 0,04*D2009-2 + 0,10*D2009-3 + 0,07*D2011-2 + 0,28*D2011-3 - 0,13*D2011-4 -- 0,09*D2011-5	0,906	Q(1) = 4,30 (0,04)	S = 1,15
			Q(2) = 9,20 (0,01)	K = 7,62
			Q(12) = 17,83 (0,12)	JB = 173,16 (0,00)
wyr_cuk	Niesymetryczny ECT: dl_WP_cukier <sub>t</sub> = 0,01 - 0,07*ECT <sub>t-1</sub> + 0,55*dl_WP_cukier <sub>t-1</sub> + 0,38*D2004-4 - 0,19*D2004-5 + 0,04*D2009-2 + 0,10*D2009-3 + 0,07*D2011-2 + 0,28*D2011-3 - 0,13*D2011-4 -- 0,10*D2011-5	0,907	Q(1) = 4,47 (0,03)	S = 0,82
			Q(2) = 8,85 (0,01)	K = 6,52
			Q(12) = 17,16 (0,14)	JB = 97,94 (0,00)
wyr_cuk	Symetryczny ECT: dl_WP_wyr_cuk <sub>t</sub> = 0,00 - 0,04*ECT <sub>t-1</sub> + 0,21*dl_WP_wyr_cuk <sub>t-1</sub> + 0,39*dl_WP_wyr_cuk <sub>t-2</sub> - 0,03*dl_M_wyagr <sub>t-1</sub> + - 0,04*dl_M_wyagr <sub>t-2</sub> + 0,03*dl_M_wyagr <sub>t-3</sub> + 0,005*S1 - 0,005*S3 + 0,006*S5 + 0,001*S8 + 0,001*S9	0,426	Q(1) = 0,31 (0,58)	S = 0,19
			Q(2) = 0,60 (0,74)	K = 3,71
			Q(12) = 9,35 (0,67)	JB = 4,74 (0,09)
jabla	Niesymetryczny ECT: dl_WP_wyr_cuk <sub>t</sub> = 0,00 - 0,04*ECT <sub>t-1</sub> + 0,21*dl_WP_wyr_cuk <sub>t-1</sub> + 0,39*dl_WP_wyr_cuk <sub>t-2</sub> - 0,03*dl_M_wyagr <sub>t-1</sub> + - 0,04*dl_M_wyagr <sub>t-2</sub> + 0,03*dl_M_wyagr <sub>t-3</sub> + 0,005*S1 - 0,005*S3 + 0,006*S5 + 0,001*S8 + 0,001*S9	0,425	Q(1) = 0,33 (0,57)	S = 0,19
			Q(2) = 0,65 (0,72)	K = 3,70
			Q(12) = 9,41 (0,67)	JB = 4,70 (0,10)
jabla	ADL: dl_WP_jabla <sub>t</sub> = 0,00 + 0,26*dl_WP_jabla <sub>t-1</sub> + 0,06*dl_WP_jabla <sub>t-2</sub> + 0,10*dl_CR_jabla <sub>t-1</sub> + 0,12*dl_CR_jabla <sub>t-2</sub> + 0,06*dl_CR_jabla <sub>t-3</sub> + 0,17*D2012-3 - 0,08*D2012-5	0,942	Q(1) = 0,20 (0,66)	S = 0,44
			Q(2) = 0,40 (0,82)	K = 4,13
			Q(12) = 6,37 (0,90)	JB = 10,00 (0,01)
tl_rosl	ADL: dl_WP_tl_rosl <sub>t</sub> = 0,00 + 0,40*dl_WP_tl_rosl <sub>t-1</sub> + 0,22*dl_WP_tl_rosl <sub>t-2</sub> + 0,03*dl_CR_olej_rzep <sub>t-3</sub> + 0,03*dl_CR_olej_rzep <sub>t-4</sub>	0,493	Q(1) = 0,32 (0,57)	S = 0,19
			Q(2) = 0,39 (0,82)	K = 3,68
			Q(12) = 7,42 (0,83)	JB = 3,05 (0,22)

Normalność: skosność (S), kurtozja (K), statystyka JB (p-value), Autokorelacja: statystyka Q Ljung-Boxa oraz (p-value).

Źródło: Opracowanie własne na podstawie danych GUS.

Najczęstszym problemem przy ocenie jakości oszacowanych modeli ECM był brak normalności reszt. Wydaje się, że częściej była ona zaburzana kurtozą silniejszą niż w rozkładzie normalnym. Niekiedy również pojawiał się problem ze skośnością, a szczególnie poważny okazał się w przypadku cen cukru. W niektórych przypadkach występuje autokorelacja (przede wszystkim dotyczy to cukru, a także serów dla większych opóźnień reszt). Model dla cen cukru miał więc generalnie słabe właściwości. Ma to związek z mocno nieliniowym zachowaniem się tej zmiennej. Gwałtowne reakcje konsumentów na występujące w niektórych sytuacjach nierównowagi rynkowe, czyli zakupy „na zapas”, w dramatyczny sposób pogłębiają istniejącą lub oczekiwaną różnicę pomiędzy popytem a podażą. W takiej sytuacji dobranie adekwatnego modelu liniowego jest wyjątkowo trudne. Ponadto, bardzo trudno jest przewidzieć wystąpienie takich sytuacji, w związku z czym jest z góry wiadome, że model ten w okresach szokowych będzie dawał prognozy silnie mijające się z rzeczywistością. Może być ewentualnie używany w sytuacji relatywnego spokoju na tym rynku.

#### **8.4. Specyfikacja, estymacja i weryfikacja modeli VAR/VECM**

Pierwszym krokiem do zweryfikowania hipotezy o występowaniu relacji długookresowej przy wykorzystaniu testu Johansena jest wyspecyfikowanie wyjściowego modelu VAR na poziomach zmiennych. Do tego celu ponownie wykorzystano wskaźniki jednopodstawowe cen detalicznych żywności, jak również poziomy innych zmiennych objaśniających. Wszystkie zmienne poddano transformacji logarytmicznej. Wybrane modele VAR obejmowały dwie do trzech zmiennych, wśród których, poza wskaźnikiem cen żywności, znajdowały się ceny surowca rolnego, a spośród innych kosztów produkcji – najczęściej wartość wynagrodzeń w sektorze przedsiębiorstw. Wyjątkiem okazał się wskaźnik cen grupy „dżem, miód, czekolada i wyroby cukiernicze”, w którym ceny cukru na giełdzie w Londynie nie wchodziły do relacji długookresowej, natomiast inne składniki kosztów wydawały się być informacją, która mogłaby wzbogacić zasób przydatny do wykonania prognozy. Warto tu wspomnieć, że wynagrodzenia, poza tym, że przybliżają w modelach koszty pracy, niosą również informację o potencjalnym popycie. W przypadku wskaźnika cen masła jedyną specyfikacją, która skutkowała wykryciem relacji długookresowej, była specyfikacja z cenami tłuszczów roślinnych, a więc z towarami, które są do pewnego stopnia substytutami. Żaden zestaw zmiennych nie dawał pozytywnego wyniku testu kointegracji w przypadku cen cukru.

Praktycznie we wszystkich modelach uwzględnione zostały sezonowe zmienne zero-jedynkowe, jeśli nie ze względu na sezonowość wskaźników cen



rolnych lub żywności, to na obecność wynagrodzeń podlegających silnym wahaniom sezonowym. Do modeli włączano zmienne zero-jedynkowe reprezentujące obserwacje odstające, często pokrywające się ze zmiennymi omawianymi w rozdziale 7 przy okazji specyfikacji modeli regARIMA. Jednak niektóre zmienne zero-jedynkowe są pochodną nietypowych obserwacji występujących w cenach surowców czy wynagrodzeniach. Najwięcej zmiennych tego typu koniecznych było do wprowadzenia w przypadku modelu obejmującego ceny pieczywa i produktów zbożowych, ze względu na cechy szeregu opisywane już w rozdziale 7. W pozostałych modelach liczba ta była bardziej ograniczona. Wszystkie specyfikacje zostały opisane w tabeli 8.5.

**Tabela 8.5. Test kointegracji Johansena**

Postać wyjściowego modelu VAR				Test śladu		
Zmienne w modelu VAR	Opóź.	Zmienne 0-1	Sez.	I. relacji kointegr.	Stat. testu	wart. p
L_WP_piecz_i_prod l_CR_pszen l_M_wynagr	3	D2000-6 D2000-8 D2003-6 D2003-11 D2004-8 D2005-11 D2006-8 D2006-9 D2007-8 D2007-9 D2008-12 D2009-1 D2010-3 D2010-8 D2010-9 D2011-3 D2012-1	tak	0 1	73,36 14,12	0,00 0,08
l_WP_mies_wol_ciel l_CR_bydlo l_M_wynagr	4	D2006-8 D2008-12 D2009-3 D2011-1	tak	0 1 2	44,79 16,15 1,30	0,00 0,04 0,25
l_WP_mies_wiepr l_CR_trzoda	3	D1999-8 D2000-7 D2004-6 D2004-7 D2007-7 D2008-1 D2009-3	tak	0 1	25,11 0,11	0,00 0,74
l_WP_wedliny_razem l_CR_trzoda l_M_wynagr	5	D1999-8 D2000-7 D2004-6 D2004-7 D2007-7 D2007-8 D2008-6	tak	0 1	68,83 14,55	0,00 0,07
l_WP_mies_drob l_CR_drob	4	D2009-1	tak	0 1	15,58 2,52	0,05 0,11
l_WP_sery l_CR_mleko l_M_wynagr	5	D1999-12 D2002-5 D2003-10 D2007-8 D2007-9 D2012-4	tak	0 1	37,49 9,72	0,01 0,30
l_WP_tl_roln l_CR_rzepak*m_usd	2	D2004-6 D2009-11	tak	0 1	23,86 1,95	0,00 0,16
l_WP_tl_roln l_WP_maslo	3	D1999-9 D1999-12 D2004-6 D2007-9 D2009-11 D2011-3	tak	0 1	20,72 0,17	0,01 0,68
l_WP_jaja l_CR_jaja l_M_wynagr	5	D2008-12 D2012-3	tak	0 1 2	64,85 18,97 2,03	0,00 0,01 0,15
l_WP_wyr_cuk l_M_olej.n l_M_wynagr	3	brak	tak	0 1 2	44,29 17,70 3,39	0,00 0,02 0,07

Źródło: Opracowanie własne na podstawie danych GUS.

Najczęściej napotykanne problemy przy wyborze specyfikacji modeli VAR to brak normalności reszt. Często, wprowadzanie zmiennych zero-jedynkowych redukowało problem skończoności (szoki oddziałujące na ceny detaliczne znacznie częściej wpływają na ich wzrost niż na spadek), jednak kurtoza pozostawała

wysoka, rzutując na całościowy wynik testów. Należy o tym pamiętać, interpretując wyniki testów kointegracji Johansena. Jednocześnie wprowadzenie zbyt wielu takich zmiennych niekiedy pogarszało wyniki testów autokorelacji.

W przypadku niektórych modeli z trzema zmiennymi test śladu na poziomie istotności 0,05 sugerował występowanie dwóch relacji kointegrujących (ceny detaliczne wołowiny, ceny jaj, ceny wyrobów cukierniczych). W takich sytuacjach do modelu VECM i tak włączano jedną relację kointegrującą, aby specyfikacja równania kointegrującego w modelu VECM była porównywalna do specyfikacji uwzględnionej w modelu ECM (wpływ wszystkich potencjalnie istotnych kosztów produkcji w jednym równaniu).

Ostateczny dobór zmiennych w modelach VAR (tab. 8.6) niekiedy różnił się od tego uwzględnionego w równaniach relacji długookresowych wykorzystanych do testu Engle'a-Grangera i budowy modeli ECM. Często było to wynikiem faktu, że dla zmiennych z modelu Engle'a-Grangera kointegracja sprawdzana testem Johansena nie zachodziła. Zdarzało się również, że tam, gdzie test Engle'a-Grangera dawał wyniki negatywne (ceny detaliczne jaj i tłuszczów roślinnych), test Johansena sugerował wynik odwrotny. Jednak w przypadku, gdy równania kointegracyjne w obu metodach zawierały te same zmienne, oszacowane parametry były porównywalnego rzędu wielkości, choć nie identyczne, np. jednoprocenowy wzrost cen pszenicy w relacji długookresowej modelu ECM przekłada się na 0,12 zmianę cen pieczywa i produktów zbożowych, podczas gdy analogiczna zmiana w modelu VECM wynosi 0,18 (por. tabela 8.3 i 8.6). Zbliżone były również wartości parametrów dostosowań w równaniach wskaźników cen detalicznych.

W przypadku modeli, w których wynik testu Johansena był pozytywny (znajdowano przynajmniej jedną relację kointegrującą), przechodząco do estymacji modelu wektorowej korekty błędem (VECM). Jeżeli nie stwierdzono obecności relacji kointegrującej (np. wskaźnik cen mleka czy pozostałych produktów mlecznych), do celów prognostycznych konstruowano modele VAR na pierwszych przyrostach analizowanych zmiennych. Istniały jednak przypadki (np. wskaźnik cen cukru), dla których nie udało się wyspecyfikować nawet relacji krótkoterminowych między zmiennymi. Proste modele VAR zbudowano również dla cen żywności i napojów bezalkoholowych oraz dla agregatu *zynosc\_ogr*. Miały one służyć jako podstawa do porównania z prognozą powstałą jako agregat prognoz poszczególnych grup cen żywności analizowanych w niniejszym rozdziale. Poza rzeczonymi wskaźnikami cen żywności, w ich skład wchodziły wynagrodzenia oraz indeks cen surowców rolnych.

Tabela 8.6. Specyfikacja modeli VECM/VAR

Zmienne w modelu VAR/VECM	Relacja kointegrująca	Beta (t-stat)	liczba opóź.	Zmienne 0-1	Sez.	Autokorelacja (wart. p)	Normalność (wart. p)
I_WP_piecz_i_prod I_CR_pszren I_M_wynagr	$I\_WP\_piecz\_i\_prod$ $-0,18*I\_CR\_pszren$ $-0,66*I\_M\_wynagr + 0,99$	-0,03 (-6,68)	2	D2000-6 D2000-8 D2003-6 D2003-11 D2004-8 D2005-11 D2006-8 D2006-9 D2007-8 D2007-9 D2008-12 D2009-1 D2010-3 D2010-8 D2010-9 D2011-3 D2012-1	tak	Stat(1) 0,65 Stat(2) 0,51 Stat(12) 0,06	S 0,07 K 0,00 Łączny 0,00
I_WP_mies_wol_ciel I_CR_bydlo I_M_wynagr dl_WP_mies_wol_ciel dl_CR_bydlo	$I\_WP\_mies\_wol\_ciel$ $-0,59*I\_CR\_bydlo$ $-0,48*I\_M\_wynagr -0,60$ -	-0,09 (-4,62)	3	D2006-8 D2008-12 D2009-3 D2011-1	tak	Stat(1) 0,12 Stat(2) 0,22 Stat(12) 0,13	S 0,25 K 0,11 Łączny 0,12
I_WP_mies_wiep I_CR_trzoda	$I\_WP\_mies\_wiep$ $-0,80*I\_CR\_trzoda - 3,71$	-0,03 (-2,77)	2	D2011-1	nie	Stat(1) 0,88 Stat(2) 0,96 Stat(12) 0,22	S 0,02 K 0,68 Łączny 0,08
I_WP_wedliny_razem I_CR_trzoda I_M_wynagr	$I\_WP\_mies\_wiep$ $-0,80*I\_CR\_trzoda - 3,71$	-0,03 (-2,77)	2	D1999-8 D2000-7 D2004-6 D2004-7 D2007-7 D2008-1 D2009-3	tak	Stat(1) 0,36 Stat(2) 0,94 Stat(12) 0,89	S 0,10 K 0,31 Łączny 0,14
I_WP_mies_drob I_CR_drob	$I\_WP\_wedliny\_razem$ $-0,40*I\_CR\_trzoda$ $-0,41*I\_M\_wynagr -1,04$	-0,06 (-4,56)	4	D1999-8 D2000-7 D2004-6 D2004-7 D2007-7 D2007-8 D2008-6	tak	Stat(1) 0,09 Stat(2) 0,16 Stat(12) 0,05	S 0,04 K 0,02 Łączny 0,01
dl_WP_mleko dl_CR_mleko	$I\_WP\_mies\_drob$ $-0,98*I\_CR\_drob - 3,48$ -	-0,12 (-1,86)	3	D2009-1	tak	Stat(1) 0,41 Stat(2) 0,41 Stat(12) 0,33	S 0,11 K 0,01 Łączny 0,01
		-	3	D1999-12 D2000-9 D2002-5 D2007-9 D2013-9	tak	Stat(1) 0,09 Stat(2) 0,90 Stat(12) 0,17	S 0,07 K 0,00 Łączny 0,00

Tabela 8.6. Specyfikacja modeli VECM/VAR cd.

Zmienne w modelu VAR/VECM	Relacja kointegrująca	Beta (t-stat)	liczba opóź.	Zmienne 0-1	Sez.	Autokorelacja (wart. p)	Normalność (wart. p)
I_WP_sery	I_WP_sery	-0,03 (-2,73)	4	D1999-12 D2002-5	tak	Stat(1) 0,18	S 0,42
I_CR_mleko	-0,11*I_CR_mleko			D2003-10 D2007-8		Stat(2) 0,27	K 0,00
I_M_wynagr	-0,36*I_M_wynagr - 2,02			D2007-9 D2012-4		Stat(12) 0,06	Łączny 0,00
dl_WP_poz_prod_ml	-		3	D2002-5 D2008-4	tak	Stat(1) 0,35	S 0,22
dl_CR_mleko	-			D2010-3 D2010-4		Stat(2) 0,92	K 0,00
						Stat(12) 0,10	Łączny 0,00
I_WP_tl_rosl	I_WP_tl_rosl	-0,02 (-4,33)	1	D2004-6 D2009-11	tak	Stat(1) 0,24	S 0,21
I_(CR_rzepak*M_usd)	-0,53*I_(CR_rzepak*M_usd)					Stat(2) 0,26	K 0,00
	-1,06					Stat(12) 0,80	Łączny 0,00
I_WP_tl_rosl	I_WP_tl_rosl	-0,01 (-2,14)	2	D1999-9 D1999-12	tak	Stat(1) 0,41	S 0,26
I_WP_maslo	-0,74*I_WP_maslo - 1,11	0,03 (2,96)		D2004-6 D2007-9		Stat(2) 0,40	K 0,00
				D2009-11 D2011-3		Stat(12) 0,11	Łączny 0,00
I_WP_jajaja	I_WP_jajaja - 0,46*I_CR_jajaja	-0,09 (-5,94)	4	D2008-12 D2012-3	tak	Stat(1) 0,17	S 0,89
I_CR_jajaja	-0,55*I_M_wynagr + 0,98					Stat(2) 0,48	K 0,02
I_M_wynagr						Stat(12) 0,64	Łączny 0,09
I_WP_wyr_cuk	I_WP_wyr_cuk	-0,04 (-3,52)	2	-	tak	Stat(1) 0,55	S 0,17
I_M_olej.n	-0,38*I_M_wynagr					Stat(2) 0,87	K 0,03
I_M_wynagr	-0,13*I_M_olej.n - 1,68					Stat(12) 0,00	Łączny 0,03
dl_WP_zywnosc_ogr	-		2	D1999-8 D1999-12	tak	Stat(1) 0,47	S 0,01
dl_CR_indeks				D2004-4 D2004-6		Stat(2) 0,82	K 0,62
dl_M_wynagr				D2004-8 D2007-9		Stat(12) 0,02	Łączny 0,05
				D2008-12 D2011-3			
dl_WP_zywnosc_i_napoje	-		5	D2004-6 D2008-12	tak	Stat(1) 0,06	S 0,06
dl_CR_indeks						Stat(2) 0,86	K 0,15
dl_M_wynagr						Stat(12) 0,23	Łączny 0,05

Beta – parametr dostosowań w równaniu wskaźnika cen; Autokorelacja: Test LM; Normalność: Test Doornika-Hansena; S – skośność; K – kurtozja.


Źródło: Opracowanie własne na podstawie danych GUS.

Wybrane modele VAR i VECM podlegały następnie weryfikacji pod kątem występowania autokorelacji i normalności reszt. Najczęstszym diagnozowanym problemem była leptokurtyczność reszt, wpływająca na odrzucenie hipotezy o normalności ich rozkładu. Dla prognoz punktowych ma ona jednak pomniejsze znaczenie. W niektórych modelach zaobserwowano również występowanie skośności (na poziomie istotności 0,05: VAR dla cen wołowiny, VECM dla cen wędlin, VAR dla agregatu zywnosc\_ogr). W kilku przypadkach (wskaźniki cen serów, jaj, wędlin) o autokorelacji reszt świadczyły wyniki testu Portmanteau, test LM był w tym kontekście mniej restrykcyjny. Należy mieć świadomość niedoskonałości modeli. Jeśli dopuszczamy dany model do prognozowania, wiedza na ich temat czasem pozwala na przewidzenie, jakiego typu błędy mogą wystąpić i kiedy. W przypadku, gdy proces prognostyczny nie jest zautomatyzowany i jest możliwość ręcznego naniesienia korekt, można tę wiedzę uwzględnić w sposób ekspercki.

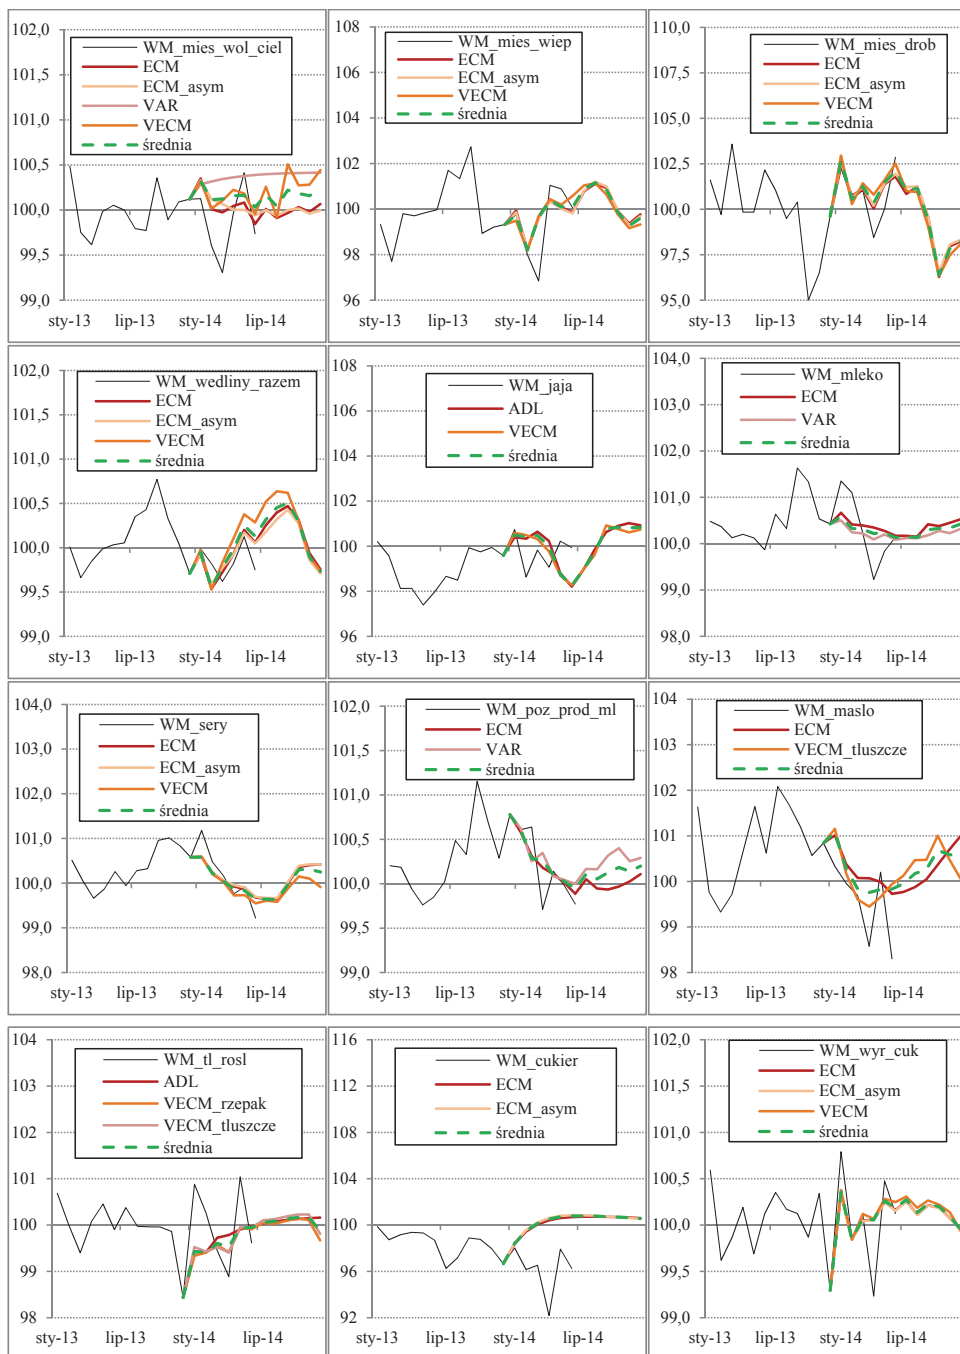
## 8.5. Prognozy i ich weryfikacja

Przy wykorzystaniu opisanych w podrozdziałach 8.4 i 8.5 modeli wygenerowano prognozy miesięcznej dynamiki cen żywności na okres od stycznia do grudnia 2014 r. (zob. rysunek 8.3) Następnie, prognozy wskaźników cen detalicznych żywności porównano z ich realizacjami za okres styczeń-czerwiec 2014 r. i w ten sposób uzyskano wartości błędów prognoz. Dla poszczególnych ścieżek prognoz obliczono, podobnie jak w rozdziale 7 (zob. tabela 8.7), syntetyczne miary błędów: błędy średnie (ME), średnie błędy absolutne (MAE) i pierwiastki błędów średniokwadratowych (RMSE). Miary te umożliwiają porównanie skuteczności prognostycznej zastosowanych metod między sobą, również tych opisanych w rozdziale 7.

**Rysunek 8.3. Wskaźniki m/m cen detalicznych żywności w okresie styczeń 2011- czerwiec 2014 i ich prognozy**



Rysunek 8.3. cd.



Źródło: Opracowanie własne na podstawie danych GUS.

Dla wskaźnika agregatowego wybranych grup cen żywności (zyw-nosc\_ogr) obliczono zarówno błędy prognoz z modelu VAR, jak i błędy prognozy powstałej w wyniku zagregowania prognoz poszczególnych analizowanych wskaźników cen na niższym poziomie agregacji. Dla wskaźników węższych grup żywnościowych do prognozowania użyto przynajmniej dwóch modeli. Dlatego w pierwszej kolejności obliczane były arytmetyczne średnie otrzymanych na ich podstawie ścieżek prognozy i dopiero te średnie były agregowane do wskaźnika cen żywności zyw-nosc\_ogr. Błędy prognoz średnich również zostały przedstawione w tabeli 8.7.

**Tabela 8.7. Miary błędów prognozy analizowanych wskaźników cen żywności m/m na okres styczeń-czerwiec 2014 r.**

Wyszczególnienie	ECM	ECM as	VAR	VECM	średnia	ADL	ECM	ECM as	VAR	VECM	średnia
Zmienna	WM piecz i prod					WM jaja					
ME	-0,15	-0,13	-	-0,14	-0,14	-0,03	-	-	-	0,05	0,01
MAE	0,17	0,16	-	0,19	0,17	1,19	-	-	-	1,06	1,13
RMSE	0,2	0,18	-	0,21	0,2	1,29	-	-	-	1,24	1,26
Zmienna	WM mies wol ciel					WM maslo					
ME	-0,19	-0,22	-0,49	-0,28	-0,29	-	-0,7	-	-	-0,49	-0,59
MAE	0,3	0,36	0,5	0,35	0,38	-	0,77	-	-	0,7	0,72
RMSE	0,36	0,43	0,61	0,41	0,44	-	0,92	-	--	0,86	0,87
Zmienna	WM mies drob					WM cukier					
ME	-0,38	-0,48	-	-0,74	-0,53	-3,83	-3,75	-3,9	-	-	-
MAE	0,73	0,78	-	0,93	0,79	3,83	3,75	3,9	-	-	-
RMSE	0,96	1	-	1,22	1,04	4,5	4,43	4,58	-	-	-
Zmienna	WM wedliny razem					WM wyr cuk					
ME	-0,04	-0,05	-	-0,16	-0,09	-	-0,02	-0,01	-	-0,06	-0,03
MAE	0,16	0,15	-	0,26	0,19	-	0,27	0,27	-	0,26	0,26
RMSE	0,19	0,17	-	0,3	0,22	-	0,39	0,39	-	0,39	0,39
Zmienna	WM mies wiep					WM tl rosl					
ME	-0,25	-0,21	-	-0,32	-0,26	0,32	-	-	-	0,39	0,38
MAE	0,8	0,82	-	0,85	0,74	0,83	-	-	-	0,7	0,76
RMSE	1,21	1,23	-	1,25	1,22	0,93	-	-	-	0,83	0,88
Zmienna	WM mleko					WM zyw-nosc i napoje					
ME	-0,06	-	0,09	-	0,01	-	-	-	-0,47	-	-
MAE	0,52	-	0,5	-	0,5	-	-	-	0,72	-	-
RMSE	0,63	-	0,62	-	0,62	-	-	-	0,82	-	-
Zmienna	WM sery					WM zyw-nosc ogr					
ME	0,07	0,05	-	0,15	0,09	-	-	-	-0,2	-	-0,22
MAE	0,27	0,27	-	0,26	0,26	-	-	-	0,27	-	0,26
RMSE	0,33	0,34	-	0,31	0,32	-	-	-	0,34	-	0,33
Zmienna	WM poz prod ml					X					
ME	-0,04	-	-0,08	-	-0,06						
MAE	0,17	-	0,23	-	0,2						
RMSE	0,24	-	0,32	-	0,28						

Źródło: Opracowanie własne na podstawie danych GUS.

Generalnie można stwierdzić, że podobnie jak w przypadku modeli bez zmiennych zewnętrznych wykorzystane w rozdziale 8 modele przeszacowały ogromną większość wskaźników cen żywności w I półroczu 2014 r. (średni błąd

prognozy ujemny, z wyjątkiem mleka, serów, jaj i tłuszczów roślinnych). Porównanie błędów prognozy z modeli ECM symetrycznych i asymetrycznych (ECMas) na analizowany okres nie daje jednoznacznej odpowiedzi na pytanie, który z typów modeli jest lepszy – zależy to od konkretnej zmiennej. Najczęściej różnice w wartościach błędów prognozy są nieznaczne. Można jednak stwierdzić, że dla I półrocza 2014 r. średnio lepiej prognozowały modele oparte na zmiennych zewnętrznych niż modele oparte wyłącznie na cechach szeregu czasowego (częściej cechowały się niższym absolutnym błędem prognozy). Być może dostarczenie dodatkowych informacji nt. determinantów cen detalicznych umożliwiło redukcję wartości błędów. Jeśli porównać z kolei skuteczność prognostyczną modeli VAR/VECM i ECM/ADL, to znów trudno określić, który typ był optymalny, pomimo całkiem odmiennego charakteru zmiennych zewnętrznych wykorzystanych do prognozowania. Generowanie prognoz na zewnątrz modelu dla wskaźników cen żywności nie zwiększyło w naszym przypadku znacząco błędów prognozy. Może warto w tym momencie przypomnieć, że takie podejście zapewnia spójność wartości zmiennych egzogenicznych dla modeli różnych zmiennych. Modelowanie VAR/VECM w najprostszej formie (bez określenia zmiennych egzogenicznych) powoduje, że te same zmienne występujące w różnych modelach mogą mieć różne wartości w prognozie.

Jeśli porównać błędy prognozy ścieżki wskaźnika cen żywności (*zywnosc\_org*) wygenerowanej przy użyciu modelu VAR oraz powstałej jako średnia ważona z prognoz wskaźników na niższym poziomie agregacji, to można zauważyć, że oba modele dają średni błąd absolutny o niemalże tej samej wartości (MAE dla agregatu jest niższe o 0,01 p.p.). Oznacza to, że zastosowanie bardzo prostego modelu VAR nie pogorszyło znacząco skuteczności prognozy. Należy jednak podkreślić, że wyniki te pozwalają ocenić wyłącznie jakość sprawowania się poszczególnych modeli w analizowanym okresie czasu. Nie powinno się na ich podstawie wyciągać wniosków generalnych na temat dominacji jednego typu modeli nad innym. Do tego celu lepiej byłoby wykonać ćwiczenie prognostyczne *out-of-sample*, generując znacznie większą liczbę hipotetycznych ścieżek prognozy i porównując je do realizacji wskaźników cen.



## Podsumowanie

Nikogo nie należy przekonywać o wyjątkowym znaczeniu żywności dla egzystencji człowieka. Z ekonomicznego punktu widzenia istotna rola żywności znajduje odzwierciedlenie choćby w dość wysokim udziale wydatków na żywność w ogóle wydatków gospodarstw domowych (np. w Polsce na poziomie około  $\frac{1}{4}$ ). Ceny produktów żywnościowych odgrywają istotne znaczenie także z powodu wysokiej częstotliwości dokonywanych zakupów żywnościowych przez konsumentów. Poziom cen żywności wraz z dochodami stanowią główne determinanty zaspokojenia potrzeb żywnościowych. W szerszym, makroekonomicznym kontekście poziom oraz zmienność cen produktów żywnościowych wpływa na bezpieczeństwo żywnościowe. Z drugiej strony poziom cen poszczególnych produktów żywnościowych determinuje możliwości uzyskiwania przychodów czy zysków przez producentów surowców rolnych, przetwórców i handlowców.

Prognozowanie cen produktów rolnych i detalicznych może przynieść wymierne korzyści uczestnikom rynku rolno-żywnościowego. Każdy uczestnik tego rynku jest bowiem narażony na ryzyko cenowe i zmuszony jest dokonywać szacunku przyszłej sytuacji rynkowej. Zatem przewidywanie jest elementem procesu zarządzania ryzykiem (prognozy krótkookresowe) oraz stanowić może podstawę podejmowania decyzji produkcyjnych czy inwestycyjnych w okresach średnich i długich. Rola państwa sprowadza się do stworzenia systemu informacyjnego (integracji), w którym dane oraz inne informacje rynkowe pochodzące z różnych źródeł będą ogólnodostępne. Korzystnie wpłynie to zarówno na trafność prognoz, jak i racjonalność decyzji rynkowych.

Prognozowanie cen detalicznych jest ma duże znaczenie dla różnorodnych agend państwowych. Decyzje administracyjne czy decyzje w zakresie poszczególnych instrumentów polityki makroekonomicznej opierają się najczęściej na przewidywaniu przyszłości. Jednym z najważniejszych obszarów działań jest polityka stóp procentowych, dla prowadzenia której wymagana jest znajomość szacunku przyszłej inflacji, w tym cen agregatu żywnościowego.

Podstawą prognozowania cen jest znajomość mechanizmu rynkowego. W warunkach globalizacji – których doświadcza obecnie gospodarka polska – poziom cen krajowych jest w niewielkim stopniu uwarunkowany czynnikami wewnętrznymi. Z analiz i przeglądu literatury wynika, że to czynniki globalne – zarówno makroekonomiczne, jak i sektorowe – kreują ceny w Polsce. Z uwagi na szybką transmisję impulsów cenowych z rynków światowych, ceny krajowe produktów w miarę w pełni odzwierciedlają te informacje.

W dalszej kolejności impulsy z rynków rolnych są transmitowane na ceny detaliczne żywności. Szybsza i pełniejsza transmisja ma miejsce w przypadku produktów słabo przetworzonych. Tam też udział kosztów pozasurowcowych w cenach finalnych (tzw. rozstęp cenowy) jest najniższy. W miarę wzrostu stopnia przetworzenia produktów wzrasta udział wartości dodanej, a tym samym wzrasta wpływ czynników takich jak koszty pracy czy ceny energii. To znajduje odzwierciedlenie również w modelach prognostycznych o charakterze przyczynowo-skutkowym.

Do krótkookresowego prognozowania cen detalicznych żywności można wykorzystać szereg podejść, zarówno jakościowych, jak i ilościowych. Ich wybór zależy od wiedzy analityka, dostępności danych statystycznych, czy prawidłowości występujących tak w ramach poszczególnych zmiennych, jak i między nimi. Jednym z ograniczeń w zastosowaniu modeli ilościowych jest sezonowy charakter produkcji niektórych surowców rolnych, co skutkuje brakiem pełnych miesięcznych danych na temat cen surowca wykorzystywanego do produkcji. Generalnie jednak żywność należy do tych produktów konsumpcyjnych, dla których istnieje względnie obszerna baza miesięcznych danych cenowych odzwierciedlających koszty produkcji.

Jeżeli chodzi o prawidłowości występujące w szeregach czasowych cen detalicznych produktów żywnościowych oraz wskaźnikach cen detalicznych żywności, to są one zbliżone do charakterystyk obserwowanych w szeregach czasowych cen surowców rolnych. Chodzi tutaj o podobne charakterystyki trendów, zmian cyklicznych czy sezonowych. Natomiast warto podkreślić niższą zmienność cen detalicznych w stosunku do zmienności cen surowców rolnych. W szeregach cen detalicznych mamy do czynienia z wieloma zmianami strukturalnymi (np. gwałtowne zmiany poziomu) i obserwacjami nietypowymi. Stanowi to pewne utrudnienie w aplikacji modeli szeregów czasowych. Jednymi z modeli, które w takich warunkach mogą być stosowane są modele regARIMA oraz modele wygładzania wykładniczego ETS. Wśród przesłanek leżących u podstaw zastosowania modeli szeregów czasowych leży założenie, zgodnie z którym cena odzwierciedla wszystkie dostępne informacje. Również wyniki badań przez nas prowadzonych wskazują, że modele o charakterze przyczynowo-skutkowym nie generują dokładniejszych prognoz niż modele szeregów czasowych.

Specyfikacja modeli szeregów czasowych dla cen detalicznych żywności, mimo wielu nietypowych obserwacji, jest względnie prosta, w porównaniu do specyfikacji modeli o charakterze przyczynowym. Wynika to z faktu, że również w pozostałych szeregach czasowych (przyczynach) mamy do czynienia z obserwacjami nietypowymi. Utrudnia to zarówno wstępne wnioskowanie

o prawidłowościach (stacjonarność, kointegracja), jak i cały proces specyfikacji i estymacji modelu. Przykładowo, oczekuje się występowania kointegracji w ramach układu: ceny detaliczne, ceny rolne i ceny nakładów pozasurowcowych. Jednak występowanie zmian strukturalnych powoduje, że liczba przyjętych wektorów kointegracyjnych może się różnić od prawdziwej. W świetle prowadzonych badań praktycznie nie udało się oszacować tego typu modeli na podstawie całej próby bez wprowadzenia dodatkowych sztucznych zmiennych korygujących nietypowe zachowania. W niektórych modelach ich liczba wynosiła nawet kilkanaście. Mimo to nie zawsze udawało się zagwarantować odpowiednie właściwości reszt. Prognozując ceny detaliczne na podstawie modeli o charakterze przyczynowym, należy się pogodzić z faktem, że nie uda się wyspecyfikować sensownych modeli spełniających wszystkie kryteria statystyczne.

Wiodącą rolę przy specyfikacji modeli przyczynowo-skutkowych odgrywa doświadczenie analityka. Można przyjąć, że istnieje wiele alternatywnych specyfikacji w ramach tej samej klasy modeli, ale to analityk/prognosta, biorąc pod uwagę zarówno kryteria merytoryczne, jak i statystyczne, decyduje ostatecznie, który model będzie wybrany. W świetle badań nie udało się potwierdzić przewagi któregośkolwiek rodzajów z modeli przyczynowo-skutkowych. Również wprowadzenie asymetrii do modeli najczęściej nie zmieniał w sposób znaczący jakości modelu. Proces specyfikacji modeli jednorównaniowych z reguły był prostszy niż modeli wielowymiarowych VAR/VECM. Z kolei zaletą tych drugich jest brak konieczności ustalenia wartości zmiennych objaśniających w okresie prognozowanym.

Modelując ceny detaliczne (w tym wskaźniki) należy kierować się pragmatyzmem polegającym na wykorzystaniu wielu różnych metod służących do wyznaczenia alternatywnych prognoz. Stanowi to bowiem punkt wyjścia do dalszej ich oceny przez ekspertów czy analityków. To oni powinni decydować (niekoniecznie uśredniając prognozy, chociaż nie należy tego wykluczać), która ścieżka jest najbardziej realna w świetle pozostałych informacji, które nie zostały ujęte w modelach. Zatem informacje statystyczne (prognozy z modeli ilościowych) powinny być integrowane z wiedzą ekspercką, mając na względzie realność i dopuszczalność prognoz.

## Literatura

- Abbott P.C., Hurt C., Tyner W.E., *What's Driving Food Prices in 2011?* Farm Foundation Issue Report, 2011, <http://purl.umn.edu/112927>.
- Baek J., Koo W.W., *Analyzing factors affecting U.S. food price inflation*, Canadian Journal of Agricultural Economics, 58, 2010.
- Baek J., Koo W.W., *On the upsurge of U.S. food prices revisited*, *Economic Modelling*, 42, 2014.
- Bailey D., Brorsen B.W., *Price Asymmetry in Spatial Fed Cattle Markets*, Western Journal of Agricultural Economics, Nr 14, 1989.
- Baker D., *The Danish food marketing chain: developments and policy choice*. Fodevatekonomisk Institut, Repport nr 154, Copenhagen 2003.
- Begg D., Fisher S., Dornbusch R., *Mikroekonomia*, PWE, Warszawa 2003.
- Benalal N., Diaz del Hoyo J.L., Landau B., Roma M., Skudelny F., *To Aggregate or not to Aggregate? Euro Area Inflation Forecasting*, ECB Working Paper no. 374, 2004.
- Błażejowski M., Kufel P., Kufel T., *Automatic procedure of building congruent dynamic model in Gretl*, [w:] I. Díaz-Empananza, P. Mariel, M.V. Esteban (red.) *Econometrics with Gretl: Proceedings of the Gretl Conference 2009*, Bilbao, Spain, May 28-29, 2009.
- Borkowski B., Dudek H., Szczesny W., *Ekonometria. Wybrane zagadnienia*, PWN, Warszawa, 2004.
- Box G.E.P., Jenkins G.M., *Analiza szeregów czasowych. Prognozowanie i sterowanie*, PWN, Warszawa 1983.
- Brandson R.E., Norvell D.G., *Introduction to agricultural marketing*, Mc. Grow Hill 1983.
- *Budżety gospodarstw domowych w 2012*, Informacje i opracowania statystyczne, Warszawa 2013.
- Bywalec C., *Konsumpcja a rozwój gospodarczy i społeczny*, Wydawnictwo C.H. Beck, Warszawa 2010.
- Bywalec C., *Konsumpcja w teorii i praktyce gospodarowania*, PWN, Warszawa 2007.
- Bywalec C., Rudnicki L., *Konsumpcja*, PWE, Warszawa 2002.
- Castle J.L., Hendry D.F., Kitov O.I., *Forecasting and Nowcasting Macroeconomic Variables: A Methodological Overview*, University of Oxford, Economics Series Working Papers no 674, 2013.
- *Ceny w gospodarce narodowej w 2013 r.*, GUS, Warszawa 2014.

- Charemza W.W., Deadman D.F., *Nowa ekonometria*, PWE, Warszawa 1997.
- *Chemia żywności*, praca zbiorowa, red. Z. Sikorski, Wydawnictwo Naukowo-Techniczne, Warszawa 2002.
- Cheung Y.W., Lai K.S., *Finite sample sizes of Johansen's likelihood ratio tests for cointegration*, Oxford Bulletin of Economics and Statistics, 55 (3), 1993.
- Cieślak M. (red.), *Prognozowanie gospodarcze. Metody i zastosowania*, Wydawnictwo Naukowe PWN, Warszawa 2005.
- Cleveland R.B., Cleveland W.S., McRae J.E., Terpenning I., *STL: A Seasonal-Trend Decomposition Procedure Based on Loess*, Journal of Official Statistics, 6, 1990.
- Cramer G.L., Jensen C.W., *Agricultural Economics and Agribusiness*, John Wiley & Sons, Inc. Fifth Edition, New York, Chichester, Brisbane, Toronto, Singapore 2011.
- Cramer G.L., Jensen C.W., Southgate D.D., *Agricultural Economics and Agribusiness* John Wiley & Sons, Inc. Eighth Edition. New York, Chichester, Weinheim, Brisbane, Singapore, Toronto 2001.
- Davidson J., Halunga A., Lloyd T.A., McCorriston S., Morgan C.W. *Explaining UK Food Price Inflation*, Working Paper No. 1, Transparency of Food Pricing TRANSFOP, University of Exeter 2011.
- Doornik J.A., *Autometrics*, [w:] J.L. Castle and N. Shephard (red.), *The Methodology and Practice of Econometrics: Festschrift in Honour of David F. Hendry*, Oxford University Press, Oxford 2009.
- Drummond H.E., Goodwin J.W., *Agricultural Economics*, Copyright by Prentice-Hall, Upper Saddle River, New Jersey 07458, 2004.
- Dudek H., *Skale ekwiwalentności – estymacja na podstawie kompletnych modeli popytu*, Rozprawy naukowe i monografie: tom 377, Wydawnictwo SGGW, 2011.
- Dybowski G., *Podstawy konkurencyjności polskiej branży drobiarskiej*. Studia i Monografie, nr 160, IERiGŻ-PIB, Warszawa, 2014.
- Elitzak H., *Food Cost Review, 1950-97*, USDA, Economic Research Service. Agriculture Economic Report, No 780 June 1999.
- Encyklopedia Popularna PWN, *Żywność*, Wydanie czternaste, PWN, Warszawa 1982.
- Enders W., *Applied Econometric Time Series*, Willey, New York 2010.
- Engle R.F., Granger C.W.J., *Co-integration and Error Correction*, Econometrica, vol. 55, 1987.

- Falk B., Roy A., *Forecasting using the trend model with autoregressive errors*. International Journal of Forecasting 21, 2005.
- Figiel S., *Cenowa efektywność rynku towarowego na przykładzie zbóż w Polsce*, Wydawnictwo Uniwersytetu Warmińsko-Mazurskiego, Olsztyn 2002.
- Figiel S., Rembisz W., *Przesłanki wzrostu produkcji w sektorze rolno-spożywczym – ujęcie analityczne i empiryczne*. Nr 169. IERiGŻ-PIB, Warszawa 2009.
- Findley D., Monsell B., Bell W., Otto M., Chen M., *New Capabilities and Methods of the X-12-ARIMA Seasonal Adjustment Program*, Journal of Business and Economic Statistics, 1998.
- Gałązka M., Grzelak A., Referat na panelu ekonomicznym „Człowiek i ekonomia”, konferencji pt. „Jeden świat-wiele kultur”. 25-26 październik 2012, Bydgoszcz, 2012.
- Gałązka M., Grzelak A., *Związki potrzeb, popytu i konsumpcji żywności, ujęcie teoretyczne*, Roczniki Ekonomiczne Kujawsko-Pomorskiej Szkoły Wyższej w Bydgoszczy, Nr 4, Bydgoszcz 2011.
- Gardner B.L., *The Farm-Retail Price Spread in a Competitive Food Industry*, American Journal of Agricultural Economics, Vol 57, No 3, August, 1975.
- Gómez V., Maravall A., *Programs TRAMO and SEATS, Instructions for the user*, Banco de España, Documento de Trabajo no. 9628, 1996.
- Gómez V., Maravall A., *Seasonal Adjustment and Signal Extraction in Economic Time Series*, [w:] Tsay, R.S. (red.), *A Course in Advanced Time Series Analysis*, Wiley and Sons, New York 2001.
- Goodwin B. K., Holt M. T., *Prices transmission and Asymmetric Adjustment of the US Beef Sector*, American Journal of Agricultural Economics, No 73, 1999.
- Goodwin B.K., *Marketing Margin. Agricultural Price analysis and forecasting*, John Wiley Sons Inc, 1994.
- Granger C. W. J., *Long memory relationships and the aggregation of dynamic models*, Journal of Econometrics, 14, 1980.
- Grudkowska S., *Demetra+ User Manual*, 2013.
- Grzelak A., Gałązka M., *Ocena wydatków na żywność gospodarstw domowych w Polsce w latach 2005-2009*, [w:] *Ekonomia i jej społeczne otoczenie*. red. A. Czyżewski, A. Matuszczak, Wydawnictwo Kujawsko-Pomorskiej Szkoły Wyższej w Bydgoszczy Bydgoszcz 2012.
- *Guide to Seasonal Adjustment with X-12-ARIMA*, Office for National Statistics (ONS), 2007.
- Gulbicka B., Kwasek M., *Wpływ globalizacji na wyżywienie ludności w Polsce*, Program wieloletni 2005-2009, IERiGŻ-PIB, Warszawa 2007.

- Gulbicka B., Kwasek M., *Zróżnicowanie spożycia żywności w Polsce w świetle badań budżetów gospodarstw domowych*, IERiGŻ, Warszawa, 2000.
- Gulbicka B., *Wyżywienie*, [w:] *Encyklopedia agrobiznesu*. Fundacja Innowacja, red. A. Woś. Warszawa 1998.
- Gutkowska K., Ozimek I., *Wybrane aspekty zachowań konsumentów na rynku żywności kryteria zróżnicowania*, Wydawnictwo SGGW, Warszawa 2005.
- Hałka A., Leszczyńska A., *Wady i zalety wskaźnika cen towarów i usług konsumpcyjnych – szacunki obciążenia dla Polski*, Gospodarka Narodowa Nr 9, 2011.
- Hamulczuk M. (red.), *Prognozowanie cen surowców rolnych z wykorzystaniem modeli szeregów czasowych*, PW nr 10, IERIGŻ-PIB, Warszawa 2011.
- Hamulczuk M., Gędek S., Klimkowski C., Stańko S., *Prognozowanie cen surowców rolnych na podstawie zależności przyczynowych*, PW nr 52, IERIGŻ-PIB, Warszawa 2012.
- Hamulczuk M., Stańko S., *Prognozowanie cen surowców rolnych – uwarunkowania i metody*, Komunikaty, Raporty Ekspertyzy, nr 547, IERiGŻ-PIB. Warszawa 2011.
- Hamulczuk M., *Cykliczne zmiany na rynku trzody chlewnej w Polsce*, Roczniki Nauk Rolniczych, Seria G, T. 92, z. 2, 2006.
- Hamulczuk M., *Structural Breaks in Farm and Retail Prices of Beef Meat in Poland*, *Quantitative Methods in Economics*, Vol. XIV, No. 1, 2013.
- Harvey A.C., *Forecasting. Structural Time Series Models and the Kalman Filter*, Cambridge University Press 1989.
- Heijman W., Krzyżanowska Z., Gędek S., Kowalski Z., *Ekonomika rolnictwa, Zarys teorii*, Fundacja Rozwój SGGW, Warszawa 1997.
- Hendry D.F., *Dynamic Econometrics*, Oxford University Press 1995.
- Hendry D.F., Krolzig H.-M., *The properties of automatic Gets modelling*. *Economic Journal*, 115, 2005.
- Hendry D.F., Pretis F., *Anthropogenic influences on atmospheric CO<sub>2</sub>*, [w:] Fouquet R. (red.), *Handbook on Energy and Climate Change*, Cheltenham: Edward Elgar 2012.
- Holt C.C., *Forecasting seasonal and trends by exponentially weighted moving averages*, Office of Naval Research, Research memorandum 52, 1957.
- Houck J.P., *Elements of Agricultural Trade Policies*. McMillan Publishing Company, 1986.
- Hryszko K., Szajner P., *Sytuacja na światowym rynku cukru i jej wpływ na możliwości uprawy buraków cukrowych w Polsce*. IERiGŻ-PIB, Warszawa 2013.

- Hubrich K. *Forecasting Euro-Area Inflation: Does aggregating forecasts by HICP component improve accuracy?*, ECB Working Paper No. 247, 2003.
- Hyndman R., Koehler A.B., Ord J.K., Snyder R.D., *Forecasting with Exponential Smoothing: The State Space Approach*, Springer, 2008.
- Hyndman R.J., Koehler A.B., Snyder R.D., Grose S., *A state space framework for automatic forecasting using exponential smoothing methods*, International J. Forecasting, 18(3), 2002.
- Irz X. T., Niemi J., Liu X., *Determinants of food price inflation in Finland – The role of energy*, Energy Policy, 63 (C), 2013.
- Jabłońska A., *Rynek, popyt podaż*, [w:] *Podstawy ekonomii*, red. R. Milewski, PWN, Warszawa 2002.
- Jerzak M., *Gięda towarowa na rynku rolnym*, Fundacja na Rzecz Giełdy Zbożowo-Paszowej, Warszawa 1998.
- Jeznach M., *Artykuły żywnościowe jako produkt marketingowy*, [w:] *Podstawy marketingu rynku*, red. M. Jeznach, Wyd. SGGW, Warszawa 2007.
- Joyeux R. *How to deal with structural breaks in practical cointegration analysis?* [w:] B.B. Rao (red.) *Cointegration for the Applied Economist*, Second Ed. Palgrave Macmillan, New York, 2007
- Józwiak J., Podgórski J., *Statystyka od podstaw*, PWE, Warszawa 1998.
- Juchniewicz M., *Zmienność i transmisja cen na rynku wieprzowiny*, Rozprawy i monografie, Wydawnictwo Uniwersytetu Warmińsko-Mazurskiego, Olsztyn 2002.
- Kamerschen D., McKenzie R., Nardinelli C., *Ekonomia*, Fundacja Gospodarcza NSZZ „Solidarność” Gdańsk 1991.
- Karcz A., *Podstawy konsumentów wobec produktów zagranicznych a strategię działania przedsiębiorstw międzynarodowych*, [w:] *Konsument i przedsiębiorstwa w przestrzeni europejskiej – etnocentryzm czy globalizacja?* CBiE, AE w Katowicach, Katowice 1999.
- Kinnucan H.W., Forker O.O., *Asymmetry in Farm-Retail Price Transmission for Major Dairy Products*, American Journal of Agricultural Economics, No 69, 1987.
- Kosicka-Gębska M., Tul-Krzyszczak A., Gębski J., *Handel detaliczny żywnością w Polsce*, Wyd. II., Wydawnictwo SGGW, Warszawa 2011.
- Kotler P., *Marketing. Analiza, planowanie, wdrażanie i kontrola*, Wyd. Felberg SJA, Warszawa 1990.
- Kowalski A., Rembisz W., *Rynek rolny i interwencjonizm a efektywność i sprawiedliwość społeczna*, IERiGŻ-PIB, Warszawa 2005.
- Kramer J., *Zachowania podmiotów rynkowych*, PWE, Warszawa 1999.



- Kufel T., *General-to-Specific Modelling vs. Congruent Modelling in PcGets*, [w:] Zieliński Z. (red.) *Dynamic Econometric Models*, vol. 6, pp. 83–92. Nicolaus Copernicus University Press, Toruń 2004.
- Kufel T., *Postulat zgodności w dynamicznych modelach ekonometrycznych*, Wydawnictwo UMK, Toruń 2002.
- Kunachowicz H., Czarnocka-Misztal E., Turlejska H., *Zasady żywienia człowieka*, Wydawnictwa Szkolne i Pedagogiczne S.A. 2000.
- Kuosmanen T., Niemi J., *What explains the widening gap between the retail and producer prices of food?*, *Agricultural and Food Science*, Vol. 18, 2009.
- Kusideł E., *Modelowanie wektorowo-autoregresyjne VAR. Metodologia i zastosowanie w badaniach ekonomicznych*, Absolwent, Łódź 2000.
- Kwasek M., *Tendencje w spożyciu żywności w krajach Unii Europejskiej*, IERiGŻ-PIB, nr 180, Warszawa 2010.
- Kwasek M., *Typologia krajów Unii Europejskiej według wzorców konsumpcji żywności*, *Studia i Monografie*, Nr 144 IERiGŻ-PIB, Warszawa 2008.
- Kwasek M., *Wzorce konsumpcji żywności w Polsce*, *Studia i Monografie*, IERiGŻ-PIB, nr 153, Warszawa 2012.
- Lardic S., Mignon V., *Économétrie des séries temporelles macroéconomiques et financières*, *Economica*, Paris 2002.
- Leibtag E., *How much and how quick? Pass through of commodity and input cost changes to retail food prices*, *American Journal of Agricultural Economics*, 91(5), 2009.
- Limański A., Drabik I., *Marketing międzynarodowy*, Difin, Warszawa 2010.
- Lütkepohl H., Krätzig M., (red.) *Applied Time Series Econometrics*, Cambridge University Press, 2007.
- Maddala G.S., *Ekonometria*, PWN, Warszawa 2006.
- Maddala G.S., Kim I.-M., *Unit Roots, Cointegration, and Structural Change*, Cambridge University Press, 1998.
- Masłowski A.M., *Motywacja i osobowość*, Instytut Wydawniczy PAX, Warszawa 1990.
- Mayer J., von Cramon-Taubadel S., *Asymmetric price transmission: fact or artefact?*, Working Paper Institute for Agricultural Economy, University Göttingen 2002.
- Milewski R., red. *Podstawy ekonomii*, Wydawnictwo Naukowe PWN, Warszawa 2002.
- Mruk H., red., *Analiza rynku*, PWE Warszawa 2003.
- Mynarski S., *Analiza rynku. Problemy i metody*, PWN, Warszawa 1987.

- *Nowa Encyklopedia Powszechna PWN: Żywność*, Wydawnictwo Naukowe PWN, T. 2, Warszawa, 2004.
- OECD Working Party on Agricultural and markets. Food Price Formation, 18-20 November 2014, Paris, France 2014.
- Ord J.K., Koehler A.B., Snyder R.D., *Estimation and prediction for a class of dynamic nonlinear statistical models*, Journal of the American Statistical Association, 92, 1997.
- Ord K., Fildes R., *Principles of Business Forecasting*, South-Western Cengage Learning 2013.
- Osińska M. (red.), *Ekonometria współczesna*. Dom Organizatora, Toruń, 2007.
- Panek T. (red.), *Statystyka społeczna*, PWE Warszawa 2007.
- Paulsen O., *Testing the Farm – Retail Price Transmission in Norwegian Salmon Export to France*, Norwegian College of Fishery Science, University of Tromsø, May 2007.
- Pegels C.C., *Exponential forecasting: some new variations*. Management Science, 12, 1969.
- Peltzman S., *Prices Rise Faster than They Fall*, Journal of Political Economy, 108(3), 2000.
- Pietras C., Rynek. Rodzaje konkurencji, [w:] *Makro- i mikroekonomia. Podstawowe Problemy*, red. S. Marciniak, PWN, Warszawa 2005.
- Piłatowska M., *Efekty błędnej identyfikacji niestacjonarności procesów ekonomicznych dla wariacji błędu prognozy*, [w:] T. Kufel, M. Piłatowska (red.), *Dynamiczne modele ekonometryczne: materiały na IX Ogólnopolskie Seminarium Naukowe*, 6-8 września 2005, UMK Toruń 2005.
- Piłatowska M., *Realization of the Congruence Postulate as a Method of Avoiding the Effect of a Spurious Relationship*, [w:] Z. Zieliński (red.) *Dynamic Econometric Models* vol. 6, Nicolaus Copernicus University Press, Toruń 2004.
- Piłatowska M., *The econometric models satisfying the congruence postulate: an overview*, Dynamic Econometric Models, Vol. 8, 2008.
- *Popyt na żywność. Stan i perspektywy*. nr 15, seria „Analizy Rynkowe”, IERiGŻ-PIB, Warszawa, 2014.
- Reed A.J., Elitzak H., Wohlgenant M.H., *Retail Farm Price Margin and Consumer Product Diversity*, USDA, Economic Research Service, Technical Bulletin Number 1899, 2002, April 2002.
- Reed A.J., Hanson K., Elitzak H., Schluter G., *Changing Consumer Food Price: A Users Guide to ERS Analyses*, Consumer Economic Division, Eco-

- onomic Research Service, US Department of Agriculture, Technical Bulletin No 1862, Washington 1997, DC 200054788.
- Rembeza J., Seremak-Bulge J., *Ewolucja podstawowych rynków rolnych i jej wpływ na transmisje cen w latach 1990-2008*, IERiGŻ-PIB, Nr 131, Warszawa 2009.
  - Rembeza J., *Transmisja cen w gospodarce polskiej*, Monografia Nr 175, Wydawnictwo Uczelniane Politechniki Koszalińskiej, Koszalin 2010.
  - Rembisz W., *Mikroekonomiczne podstawy wzrostu dochodów producentów rolnych*, VIZJA PRESS&IT, Warszawa 2007.
  - Ritson Ch., *Agricultural Economics. Principles and Policy*, Collins, London 1977.
  - *Rocznik Statystyczny Rolnictwa (2001-2013)*, GUS, Warszawa 2014.
  - Roeger E., Leibtag E., *How Retail Beef and Bread Prices Respond to Changes in Ingredient and Input Costs*, USDA Economic Research Report Nr 112.
  - Rosiak E., Łopaciuk W., Krzemiński M., *Produkcja biopaliw i jej wpływ na światowy rynek zbóż oraz roślin oleistych i tłuszczów roślinnych*. IERiGŻ-PIB, Warszawa 2011.
  - Rutkowski A., *Żywność dietetyczna i lecznicza*, Przemysł Spożywczy nr 4, Warszawa 1993.
  - *Rynek zbóż. Stan i perspektywy*. Nr 23, seria „Analizy Rynkowe”, IERiGŻ-PIB, Warszawa 2002.
  - *Rynek zbóż. Stan i perspektywy*. Nr 47, seria „Analizy Rynkowe”, red. J. Seremak-Bulge, IERiGŻ-PIB, Warszawa 2014.
  - Schnepf R., *Farm – to Food Price Dynamics*, Congressional Research Service, 7-5700, 2009.
  - Seremak Bulge J. (red.), *Rozwój rynku mleczarskiego i zmiany jego funkcjonowania w latach 1990-2005*, IERiGŻ-PIB, nr 21, Warszawa 2005.
  - Serra T., *Food scare crises and price volatility: The case of the BSE in Spain*, Food Policy, 36 (2), 2011.
  - Sexton P., *Market Power, Misconception and Modern Agricultural Market*, American Journal of Agricultural Economists, No 95, 2013.
  - Sims C.A., *Macroeconomics and Reality*, Econometrica, vol. 49, 1980.
  - Słaby T., *Konsumpcja. Eseje statystyczne*, Gifin, Warszawa 2006.
  - Smyczek S., Sowa I., *Konsument na rynku. Zachowania, modele, aplikacje*, Difin, Warszawa 2005.

- Sojkin B., *Determinanty konsumpcji żywności. Analiza hierarchiczna*, Zeszyty Naukowe –seria II, Prace habilitacyjne, Zeszyt 135, Wyd. AE w Poznaniu, Poznań 1994.
- Stańko S. (red.), *Prognozowanie w agrobiznesie. Przykłady zastosowania*. Wyd. SGGW, 2013.
- Stańko S., *Tendencje zmian cen produktów rolnych żywnościowych w krajach gospodarczo rozwiniętych i w Polsce*, Roczniki Nauk Rolniczych, Seria G, T. 88, Zeszyt 1, 1999.
- Stańko S., *Zmiany i projekcje rozwoju na podstawowych rynkach rolnych w Polsce*, Wydawnictwo SGGW, Warszawa 2013.
- Świetlik K., *Ceny żywności w procesie rynkowych przemian polskiej gospodarki (1994-2004)*, Studia i Monografie nr 141, IERiGŻ-PIB, Warszawa 2008.
- Szwacka-Salmonowicz J., Zielińska Z., *Hierarchia potrzeb żywnościowych w 1993 roku na tle 1986 roku*, IRWIR PAN, Warszawa 1996.
- Taylor E., *Historia rozwoju ekonomiki*, Tom 1 i 2, PWN, Poznań 1958.
- The BV4.1 Procedure for Decomposing and Seasonally Adjusting Economic Time Series, Statistisches Bundesamt, Wiesbaden 2006.
- *The Gap between Producer Prices and the Prices paid by the Consumer*, Policy Department B: Structural and Cohesion Policies, European Commission 2007.
- Toda, H.Y., Yamamoto T., *Statistical inferences in vector autoregressions with possibly integrated processes*. Journal of Econometrics, 66, 1995.
- Tomek W.G., Robinson K.L., *Kreowanie cen artykułów rolnych*, PWN Warszawa 2001.
- Tracy M., *Polityka rolno-żywnościowa w gospodarce rynkowej*, Centrum Edukacji i Rozwoju Biznesu, Warszawa 1997.
- Tsay R.S., *Analysis of Financial time series*, John Wiley & Sons, 2010.
- Tyner W.E., *The Integration of Energy and Agricultural Markets*, Agricultural Economics, Volume 41 s1, November 2010,
- Urban R., *Wartość dodana i marże w przetwórstwie głównych produktów rolnych*, IERiGŻ, Warszawa 2002, Projekt badawczy nr 5 HO2C 070 21.
- Urbaniec A., *Wrażliwość wydatków na zmiany w dochodach w gospodarstwach domowych w Polsce*, Bank i Kredyt 42(4), 2011.
- Von Cramon-Taubadel S., *Estimating Asymmetric Price Response with the Error Correction Representation. An Application to the German pork market*, European Review of Agricultural Economics, No 25, 1999.

- Ward R.W., *Asymmetry in Retail Wholesale and Shipping Point Prices for Fresh Fruits and Vegetables*, American Journal of Agricultural Economics, 1982, No 62.
- Wilczyński W., *Rynek, Encyklopedia biznesu*, Tom 2, Fundacja Innowacja, Warszawa 1995.
- Wohlgenant M.,K., *Marketing Margins: Empirical Analysis*, [w:] *Handboock of Agricultural Economics*, Volume I, red. B. Gardner, G. Rausser, Elsevier Science B.V., 2001.
- Wohlgenant M.K., *Competitive Storage. Rational Expectations and Short Run Price Determination*, American Journal of Agricultural Economics. 1985, No 67.
- Wohlgenant M.K., Haidacher R.C., *Retail to Farm Linkage for a Complete Demand System of Food Commodities*, USDA, Economic Research Service, Technical Bulletin Number 1775, December 1989.
- Wojciechowska-Ratajczak B., *Rynek rolny*, [w:] *Encyklopedia Agrobiznesu*. Wydanie pierwsze, red. A. Woś, Fundacja Innowacja, Warszawa 1998.
- Woś A., *Podstawy agrobiznesu*, Wydawnictwo Prywatnej Wyższej Szkoły Biznesu i Administracji, Warszawa 1998.
- Woś A., *Tendencje rozwoju rolnictwa w warunkach rynkowych*, Prace i Materiały Instytutu Rozwoju Gospodarczego SGH 37, Warszawa 1994.
- Woś J., *Wprowadzenie do ekonomii*, Wydawnictwo Wyższej Szkoły Bankowej w Poznaniu, Poznań 1998 .
- Wrzosek W., *Funkcjonowanie rynku*, PWE, Warszawa 2002.
- *X-12-ARIMA Reference Manual*, Time Series Research Staff, Centre for Statistical Research and Methodology, US Census Bureau, 2011, <http://www.census.gov/ts/x12a/v03/x12adocV03.pdf>.
- *X-13ARIMA-SEATS Reference Manual*, Time Series Research Staff, Centre for Statistical Research and Methodology, US Census Bureau, 2013, <http://www.census.gov/ts/x13as/docX13ASHTML.pdf>.
- Zalega T., *Konsumpcja. Determinanty, teorie i modele*, PWE, Warszawa 2012.
- Zieliński Z., *Liniowe modele ekonometryczne jako narzędzie opisu i analizy przyczynowych zjawisk ekonomicznych*, Wyd. UMK Toruń 1991.

# Aneks

**Tabela A1. Oznaczenia stosowane w pracy**

Oznaczenie	Kategoria ekonomiczna/ transformacja	Oznaczenie	Kategoria ekonomiczna/ transformacja
<b>Zmienne makroekonomiczne</b>			
M_wynagr	Średnie przeciętne miesięczne wynagrodzenie	M_energia	Cena energii dla odbiorców przemysłowych
M_olej.n	Cena detaliczna oleju napędowego	M_usd	Kurs USD/PLN
<b>Ceny surowców rolnych</b>			
CR_pszen	Cena skupu pszenicy	CR_jaja	Cena jaj w zakładach pakujących
CR_zyto	Cena skupu żyta	CR_mleko	Cena skupu mleka
CR_bydlo	Cena żywca wołowego	CR_rzepak	CR rzepaku w Hamburgu
CR_trzoda	Cena żywca wieprzowego	CR_drob	Cena skupu drobiu
CR_cukier	Cena cukru na giełdzie w Londynie	CR_olej_rzepak	Cena sprzedaży oleju rzepakowego w zakładach tłuszczowych
CR_indeks	Indeks ważonych cen różnych surowców rolnych na giełdach europejskich i światowych (w PLN)		
<b>Ceny detaliczne i zbytu</b>			
CD_chleb	Chleb żytni	CD_zeberka	Żeberka wieprzowe
CD_maka	Mąka pszenna	CD_poledw	Polędwica drobiowa
CD_szponder	Szponder wołowy	CD_gouda	Ser gouda
CD_szynka	Szynka wieprzowa	CD_jaja	Jaja – detaliczne
CD_kurczak	Kurczę patroszone	CD_cukier	Cukier – detaliczne
CD_ml.UHT	Mleko UHT	CD_olej	Olej rzepakowy
CD_maslo	Masło	CD_margar	Margaryna
CD_wolowe	Mięso wołowe bez kości z udźca	CZ_maslo	Cena zbytu masła
CD_bulka	Bulka pszenna	CD_baleron	Baleron gotowany
CD_kielbasa	Kielbasa „Toruńska”		
<b>Rozstępy cenowe</b>			
RC_chleb	Rozstępy cen chleba i żyta	RC_zeberka	Rozstępy cen żeberek i żyw. wiep.
RC_maka	Rozstępy cen mąki i pszenicy	RC_poledw	Rozstępy cen polędwicy i żyw. drob.
RC_szponder	Rozstępy cen szpondra i żyw. woł.	RC_gouda	Rozstępy cen sera gouda i mleka
RC_szynka	Rozstępy cen szynki i żyw. wiep.	RC_jaja	Rozstępy cen jaj
RC_kurczak	Rozstępy cen kurczęcia i żyw. drob.	RC_cukier	Rozstępy cen cukru
RC_ml.UHT	Rozstępy cen mleka UHT i mleka	RC_olej	Rozstępy cen oleju rzepak. i rzepaku
RC_maslo	Rozstępy cen masła i mleka	RC_margar	Rozstępy cen margaryny i rzepaku
RC_wolowe	Rozstępy cen mięsa wołowego bez kości z udźca i żyw. woł.		
<b>Wskaźniki cen detalicznych</b>			
WM	Wskaźniki m/m	WP	Wskaźniki jednopodstawowe
piecz_i_prod	Pieczyno i produkty zbożowe	cukier	Cukier
maka_i_poz_zb	Mąka i pozostałe produkty zbożowe	cuk_i_wyr	Cukier, dżem, miód, czekolada i wyroby cukiernicze
pieczywo	Pieczyno	wyr_cuk	Wyroby cukiernicze
mieso	Mięso ogółem	jaja	Jaja
mies_wol_ciel	Mięso wołowe i cielęce	maslo	Masło
mies_wiep	Mięso wieprzowe	mleko_sery_jaja	Mleko, sery i jaja
mies_drob	Mięso drobiowe	tl_rol	Tuszcze roślinne
wedliny_razem	Wędliny	mleko	Mleko
wedliny_bezdrob	Wędliny z wyjątkiem drobiowych	sery	Sery i twarogi
wedl_drob	Wędliny drobiowe	zywnosc_i_napoje	Żywność i napoje bezalkoholowe
poz_prod_ml	Pozostałe produkty mleczne	zywnosc_ogr	Żywność ogółem
<b>Przekształcenia i ich przykłady</b>			
l	Logarytmowanie, np. l CD olej	X <sub>t-1</sub> lub X l	Opóźnienia, np. CD olej l
d	Różnicowanie, np. d CD olej	dl	Różnicowanie i logarytmowanie

Źródło: opracowanie własne.

**EGZEMPLARZ BEZPŁATNY**

*Nakład 480 egz., ark. wyd. 12,96  
Druk i oprawa: EXPOL Włocławek*