

**METODY ILOŚCIOWE
W BADANIACH EKONOMICZNYCH**

QUANTITATIVE METHODS
IN ECONOMICS

Vol. XVII, No. 1

Warsaw University of Life Sciences – SGGW
Faculty of Applied Informatics and Mathematics
Department of Econometrics and Statistics

METODY ILOŚCIOWE
W BADANIACH EKONOMICZNYCH

**QUANTITATIVE METHODS
IN ECONOMICS**

Volume XVII, No. 1

Warsaw 2016

EDITORIAL BOARD

Editor-in-Chief: Bolesław Borkowski

Deputy Editor-in-Chief: Hanna Dudek

Theme Editors:

Econometrics: Bolesław Borkowski

Multidimensional Data Analysis: Wiesław Szczesny

Mathematical Economy: Zbigniew Binderman

Analysis of Labour Market: Joanna Landmesser

Financial Engineering: Grzegorz Koszela

Statistical Editor: Wojciech Zieliński

Technical Editors: Jolanta Kotlarska, Elzbieta Saganowska

Language Editor: Agata Cienkusz

Native Speaker: Yochanan Shachmurove

Editorial Assistant: Monika Krawiec

SCIENTIFIC BOARD

Peter Friedrich (University of Tartu, Estonia)

Paolo Gajo (University of Florence, Italy)

Vasile Glavan (Moldova State University, Moldova)

Francesca Greselin (The University of Milano-Bicocca, Italy)

Yuriy Kondratenko (Black Sea State University, Ukraine)

Vassilis Kostoglou (Alexander Technological Educational Institute of Thessaloniki, Greece)

Robert Kragler (University of Applied Sciences, Weingarten, Germany)

Karol Kukuła (University of Agriculture in Krakow)

Alexander N. Prokopenya (Brest State Technical University, Belarus)

Yochanan Shachmurove (The City College of The City University of New York, USA)

Mirbulat B. Sikhov (al-Farabi Kazakh National University, Kazakhstan)

Ewa Syczewska (Warsaw School of Economics, Poland)

Achille Vernizzi (University of Milan, Italy)

Andrzej Wiatrak (University of Warsaw, Poland)

Dorota Witkowska (University of Lodz, Poland)

ISSN 2082 – 792X

© Copyright by Department of Econometrics and Statistics WULS – SGGW
(Katedra Ekonometrii i Statystyki SGGW)

Warsaw 2016, Volume XVII, No.1

The original version is the paper version

Journal homepage: qme.sggw.pl

Published by Warsaw University of Life Sciences Press

SPIS TREŚCI

Karol Kukuła – 60 Lat Istnienia Katedry Statystyki i Ekonometrii w Uniwersytecie Rolniczym im. Hugona Kołłątaja w Krakowie	7
Iwona Bąk – Sytuacja Kobiet na Rynku Pracy w Polsce na Tle Krajów Unii Europejskiej – Analiza Statystyczna	20
Hanna Dudek – Ocena Trudności Finansowych w Zakresie Nabywania Żywności – Zastosowanie Modelu Probitowego ze Zmiennymi Efektami	31
Włodzimierz Kołodziejczak, Feliks Wysocki – Metoda Przepływów na Rynku Pracy (IOA) i Wielomianowa Analiza Logitowa w Badaniach Aktywności Ekonomicznej Ludności	42
Sławomir Lisek – Analiza Zgodności Wniosków Wynikających z Zastosowania Wybranych Funkcji Dyskryminacyjnych	51
Lidia Luty – Regionalne Zróżnicowanie Struktury Obszarowej Użytków Rolnych w Polsce	62
Kesra Nermend, Danuta Miłaszewicz – Zróżnicowanie Obszarów Wiejskich w Polsce – Ujęcie Regionalne	72
Aldona Skarżyńska, Konrad Jabłoński – Zastosowanie Modeli Trendu do Projekcji Opłacalności Produkcji Mleka w Perspektywie Średnioterminowej	84
Agnieszka Sompolska-Rzechuła – Rolnictwo w Regionach. Wielowymiarowe Spojrzenie w Ujęciu Dynamicznym	98
Przemysław Szczuciński – Zastosowanie Metod Porządkowania Liniowego do Oceny Poziomu Rozwoju Społeczno-Gospodarczego Powiatów Województwa Lubuskiego	109
Maria Szmuksta-Zawadzka , Jan Zawadzki – Prognozowanie na Podstawie Szeregów Czasowych o Wysokiej Częstotliwości Oczyszczonych z Sezonowości dla Luk Niesystematycznych	121

**60 LAT ISTNIENIA KATEDRY STATYSTYKI I EKONOMETRII
W UNIWERSYTECIE ROLNICZYM
IM. HUGONA KOLLĄTAJA W KRAKOWIE**

Karol Kukuła

Katedra Statystyki i Ekonometrii
Uniwersytet Rolniczy w Krakowie
e-mail: ksm@ur.krakow.pl

Streszczenie: Sześćdziesiąt lat istnienia (1956-2016) Katedry Statystyki Matematycznej to szmat czasu. Jej działalność wpisuje się niemal od samych początków w funkcjonowanie nowopowstałej Wyższej Szkoły Rolniczej w Krakowie, która datuje swe początki na rok 1953. Szkoła ta bazuje na pracownikach wywodzących się z kadr Uniwersytetu Jagiellońskiego. Z tego też uniwersytetu pochodzi założyciel i twórca Katedry prof. zw. Stefan Schmidt. Kolejnym kierownikiem Jednostki zostaje doc. dr hab. Jan Pocij (1964-1987). Od 1992 roku do chwili obecnej Katedrą kieruje prof. zw. dr hab. Karol Kukuła. W tym okresie powstaje wiele prac naukowych: monografii, artykułów i podręczników o zasięgu ogólnokrajowym. Od 2015 roku nazwa Katedry zostaje zmieniona na Katedrę Statystyki i Ekonometrii.

Słowa kluczowe: Katedra Statystyki i Ekonometrii, monografie, podręczniki, artykuły

Motto:

*Co skraca mi czas? Działanie!
Co wydłuża go niemiłosiernie? Bezczywność!
/ Johann Wolfgang Goethe /*

Co było przyczyną wyboru tego motto? Otóż powodem zamieszczenia tego a nie innego motto jest zawarty w nim problem wykorzystania mijającego czasu. Czas, w którym tak wiele się dzieje, zachodzą różne zdarzenia ważne i mniej ważne ale w przyszłości znaczenie tych mniej ważnych w danej chwili może się zwielokrotnić. Wszystko to o czym chcę pisać w tym artykule jest osadzone

w czasie i dotyczy dziejów Katedry, którą przyszło mi kierować już prawie ćwierć wieku. Ponadto chcę podkreślić znamiennej rzecz, ludzie pracujący w Katedrze, często fluktuując, zwłaszcza w pierwszym okresie jej istnienia, stworzyli jednak znaczący dorobek naukowy i rzetelnie wypełnili powierzone im obowiązki dydaktyczne. Kierowali się zatem pierwszą częścią przejętej od J.W. Goethe maksymy, to znaczy czas im się nie dłużył, wybrali działanie.

Katedra Statystyki Matematycznej (KSM) powstała w 1956 roku w okresie tzw. „odwilży politycznej”. Na jej czele stanął wywodzący się z kręgu kadr profesorskich Uniwersytetu Jagiellońskiego prof. zw. dr hab. Stefan Schmidt. Dzieje Katedry od 2015 roku przemianowanej na Katedrę Statystyki i Ekonometrii (KSiE) wpisują się w historię ówczesnej Wyższej Szkoły Rolniczej w Krakowie, która została powołana zaledwie trzy lata wcześniej tj w 1953 roku. Z porównania tych dat wynika, iż KSM funkcjonuje niemal od samych początków istnienia Wyższej Szkoły Rolniczej w Krakowie.

*

Twórcą programów dydaktycznego i naukowego Katedry był jej założyciel prof. zw. dr hab. Stefan Schmidt. Profesor Schmidt był osobowością o wybitnych osiągnięciach naukowych oraz wspaniałym charakterze. Snując rozważania na temat osobowości Profesora, trzeba mieć na uwadze, iż okres Jego działalności przypada na niezwykle trudne czasy po drugiej wojnie światowej. Okres ten nazywany jest przez historyków „okresem stalinowskim”. Profesor był człowiekiem wielkiej odwagi osobistej i nieugiętego charakteru. Trzeźwo oceniał stosunki społeczno-gospodarcze panujące w ówczesnej Polsce. W swoich poglądach i wypowiedziach zachowywał niezmiennie dużą dozę niezależności. W okresie tuż powojennym nie było to mile widziane przez komunistyczne władze, przysparzając Profesorowi wiele kłopotów, również na niwie pracy zawodowej. Ze względu na niepodważalne zasługi Profesora w rozwoju opisywanej Katedry, chcę poświęcić trochę miejsca na omówienie ważniejszych momentów Jego życia. Przyszedł na świat 26 lipca 1889 roku we wsi Krzywaczka w powiecie myślenickim. Był synem Wincentego i Klementyny z Konopków. Jego rodzice doceniali znaczenie wykształcenia dla przyszłego życia swych dzieci, stąd nie żalowali pieniędzy na ich edukację. Oprócz Stefana mieli jeszcze trzech synów. Stefan junior wykształcenie średnie zdobywał w Gimnazjum św. Anny w Krakowie. Po maturze zapisał się na studia rolnicze, które w owych czasach były prowadzone na Uniwersytecie Jagiellońskim. Studia te kontynuował przez jeden rok po czym przeniósł się do Fryderycjańskiego Uniwersytetu w Halle w ówczesnym cesarstwie niemieckim. Studia te, ukończył w 1912 roku wieńcząc je doktoratem. Tematyka rozprawy doktorskiej dotyczyła problemów sezonowych robotników rolnych w Saksonii. Zagadnienie to wiązało się w dużej mierze z Polakami. Polacy stanowili wówczas dużą grupę populacji sezonowych robotników rolnych pracujących w Saksonii. Ich ilość sięgała liczby pół miliona.

Promotorem tej pracy był profesor Steinbruck. W okresie swych studiów w Halle, profesor opanował biegle języki niemiecki i angielski a także w mniejszym stopniu francuski, włoski, czeski i rosyjski. Rolnicze praktyki odbywał w Polsce i zagranicą. Po odbyciu praktyk powraca na gospodarstwo ojca do Krzywaczki. Przez kolejne 10 lat prowadzi to gospodarstwo. Profesor przejawiał przez całe swe życie skłonność do prowadzenia badań naukowych. Stąd też po kilkuletniej przerwie podejmuje prowadzenie prac naukowo-badawczych. Doskonale znał bolączki gospodarstw rolnych w dawnej Galicji wynikające z ogromnego ich rozdrobnienia. W swoich badaniach naukowych był zwolennikiem dużych, dynamicznie się rozwijających gospodarstw chłopskich, które egzystowałyby na zasadzie niepodzielności. W podziale spadkowym gospodarstw chłopskich dopatrywał się ich słabości twierdząc, że małe gospodarstwa przestają być liczącym się partnerem na rynku towarowym. Uważał, iż bez zachowania zasady niepodzielności gospodarstw ani parcelacja ani komasacja nie będą stwarzać dostatecznych warunków stałego rozwoju gospodarstw. Poglądy te artykułuje w swej rozprawie habilitacyjnej nt. „Własność folwarczna w Zachodniej Małopolsce w chwili wskrzeszenia Państwa Polskiego”. Przewód ten zostaje otwarty na Wydziale Rolniczym Uniwersytetu Jagiellońskiego w 1924 roku. Zamknięcie przewodu następuje w 1927 roku, co łączy się z uzyskaniem stopnia naukowego docenta. W tym samym roku otrzymuje stypendium z Fundacji Rockefellera i wyjeżdża do Stanów Zjednoczonych. Pracuje jako resident doctor w dwóch ośrodkach uniwersyteckich: w stanie New York w Cornell University-Ithaca oraz w stanie Illinois w Western University w Chicago. Pobyt w tych ośrodkach zaowocował kontaktami z czołowymi statystykami i ekonometrykami w skali światowej. Byli to: F.A. Pearson, E.O. Heady i M. Ezekiel. Tu spotyka również znanego ekonomistę zajmującego się problematyką rolnictwa G.F. Warrena. W ten sposób profesor wkracza do grona ekonomistów stanowiących elitę łączącą zainteresowania problematyką rolniczą z wykorzystywaniem nowoczesnych wówczas metod statystyczno-ekonometrycznych. Staje się członkiem stowarzyszeń naukowych najwyższej rangi światowej, takich, jak: International Association of Agricultural Economic (IAAE) oraz Royal Economic Society (RES). W 1928 roku wraca do kraju już jako znana postać w świecie nauki. Podejmuje pracę w macierzystej uczelni prowadząc wykłady z takich przedmiotów, jak: elementy statystyki matematycznej, ekonomia, polityka agrarna, taksacje rolnicze oraz metodyka kalkulacji rolniczych. Przejmując zwyczajnie podpatrzone na uniwersytetach amerykańskich utrzymuje bliskie kontakty ze studentami zainteresowanymi problematyką wykładów. Zaprasza studentów do swego mieszkania na cotygodniowe „herbatki” połączone z dyskusją na przerabiane ale również i aktualne tematy. W 1933 roku zostaje mianowany profesorem nadzwyczajnym UJ zaś w 1935 roku obejmuje kierownictwo Katedry Ekonomii Rolnej, którą kieruje (poza wojenną przerwą) do 1950 roku. Pełni ponadto funkcję dyrektora Wyższego Naukowego Kursu Spółdzielczego w latach 1937-1939 przy Wydziale Rolniczym Uniwersytetu Jagiellońskiego.

Kres tej działalności przynosi dzień 6 listopada 1939 roku. Wraz ze 183 osobową grupą profesorów jest zaproszony do auli Collegium Novum na rzekomy odczyt niemieckiego profesora Muellera, który miał wygłosić referat na temat stosunków polsko-niemieckich. Był to podstęp ze strony niemieckiej, mający na celu zgromadzenie elity naukowej uniwersytetu w jednym miejscu by następnie wszystkich aresztować. Ta podstępna gra jest nazywana przez historyków Sonderaktion Krakau. W wyniku tego podstępu jest aresztowany i wraz z pozostałymi profesorami Uniwersytetu Jagiellońskiego zostaje wywieziony do obozu koncentracyjnego zbudowanego celem więzienia przeciwników rządów hitlerowskich w Sachsenhausen koło Berlina. Profesor stara sobie radzić z warunkami panującymi w obozie koncentracyjnym organizując wzajemną pomoc wśród uwięzionych. W dniu 15 kwietnia zostaje zwolniony i powraca do Krakowa. Fakt zwolnienia należy łączyć z ogromną presją, jaką wywarł świat nauki na władze niemieckie. Środowisko uczonych na całym świecie było oburzone nieludzkim traktowaniem polskich uczonych w obozie koncentracyjnym. Po swoim powrocie nie pozostaje bezczynny lecz szybko włącza się w akcję tajnego nauczania prowadzonego przez pracowników UJ. Wykłada również w Szkole Nauk Politycznych. W 1943 roku Rząd Emigracyjny w Londynie zwraca się do polskich uczonych o opracowanie planu zagospodarowania ziem, mających znaleźć się w granicach państwa polskiego po klęsce Hitlera. Profesor zgłasza swój udział w pracach nad tym planem.

Od stycznia 1945 roku tuż po wyzwoleniu trwają prace nad uruchomieniem uczelni. Profesor bierze czynny udział w tych pracach, uczestniczy w pierwszych zebraniach organizacyjnych kadr uniwersytetu. W kwietniu 1945 roku zostaje powołany na prodziekana Wydziału Rolniczego, funkcję tę pełni do 15 lipca tego roku. W dniu 15 lipca 1945 roku zostaje dziekanem wydziału. Na stanowisku tym pozostaje do 1 lipca 1947. W dniu 15 lutego 1946 otrzymuje tytuł profesora zwyczajnego. Okres, w którym przyszło działać wskrzesicielom uniwersytetu należy do niezwykle trudnych. Bowiem Niemcy dążąc do unicestwienia polskiej inteligencji zniszczyli struktury uniwersytetu. Ponadto w kraju po najeździe hitlerowców panowała bieda brak było wszelkich środków materialnych, co utrudniało w szczególnie dotkliwy sposób działanie na rzecz uruchomienia uczelni. Pełniąc funkcję dziekana profesor uczestniczy w Radzie Naukowej dla Zagadnień Ziemi Odzyskanych, która miała swą siedzibę w Krakowie. Jego zainteresowanie Ziemiami Odzyskanymi skutkują powołaniem Go na wicedyrektora Kursów Naukowo-Informacyjnych o Ziemach Zachodnich. Podejmuje się i opracowuje temat badawczy o możliwościach wyżywienia Niemiec bez Ziemi Odzyskanych. Rezultaty tych badań są publikowane i zostają wykorzystane na forum międzynarodowym. Stanowią skuteczny kontrargument do rozpowszechnianych w Niemczech opinii o zagrażającym im widmie głodu po utracie części terytorium. Wszelkie zainteresowania Profesora sięgają także do problematyki spółdzielczości. W 1948 roku uruchamia Studium Spółdzielczości przy Uniwersytecie Jagiellońskim i pełni funkcję dyrektora tej jednostki w latach 1948-

1949. Swe doświadczenia w zakresie metod ilościowych wyniesione z pobytu w Stanach Zjednoczonych wykorzystuje podejmując wykłady ze statystyki matematycznej w ówczesnej Akademii Handlowej w Krakowie (dziś Uniwersytecie Ekonomicznym). Blisko współpracuje z pracownikiem tamtejszej uczelni profesorem Jerzym Fierichem. Szerokie spectrum działań, w których Profesor uczestniczy ukazuje z jednej strony skalę Jego możliwości dokonania z drugiej zaś niezwykle ożywienie i pracowitość. Będąc człowiekiem w wieku dość zaawansowanym po obozowych przejściach i niespokojnej egzystencji w Generalnej Guberni staje się tytanem pracy. Jego aktywność naukowa zostaje brutalnie przerwana na skutek smutnych wydarzeń o zabarwieniu politycznym, jakie miały miejsce w Polsce w latach 1950-1955. Zarzucono profesorowi chęć szerzenia idei związanych z ekonomią burżuazyjną. Ów zarzut stał się wystarczającą przyczyną przeniesienia Go w stan spoczynku od 1 września 1950 roku. Akt zwolnienia Profesora ze służby państwowej podpisał prezydent Bolesław Bierut. Katedra Ekonomii Rolnej, którą kierował Profesor została przemianowana na Katedrę Socjalistycznych Przedsiębiorstw Rolnych. Katedrę o zmienionej nazwie powierzono nowemu kierownikowi. Kadry dawnej Katedry uległy rozproszeniu. Studium Spółdzielcze, którego założycielem był Profesor przeniesiono do Wyższej Szkoły Ekonomicznej w Krakowie. W ten sposób niezwykle aktywny naukowiec został przeniesiony w stan spoczynku, miał wówczas 61 lat. W owych czasach odwaga w wypowiedaniu swoich opinii (nawet słuszych) nie była w cenie. Wprost przeciwnie, postawa profesora gotowego świadczyć o prawdzie, była niewygodna dla ówczesnych władz. Stąd Profesor Schmidt stał się niebezpieczny dla komunistycznej władzy i dlatego musiał odejść z życia uczelni. Wydarzenia te, skoncentrowane w krótkim okresie jednego roku, fatalnie wpłynęły na psychikę Profesora, który będąc w pełni sił twórczych, musi zrezygnować ze swoich ambitnych planów. Pewną pomoc w sensie psychicznym stanowi zamówienie, jakie otrzymał na napisanie podręcznika o zastosowaniach metod statystycznych w zootechnice. Praca nad tą pozycją pozwala Profesorowi powoli dochodzić do siebie i wejść na powrót w rytm pracy.

Mija długie 6 lat od momentu wykluczenia Profesora z pracy naukowo-dydaktycznej, nadchodzi rok 1956. Rok ten zapoczątkował okres odwilży politycznej w Polsce, co skutkuje powrotem Profesora do uczelni. Uczelnią tą jest nowopowstała w 1953 roku Akademia Rolnicza, która została zasilona kadrami dawnego Wydziału Rolniczego Uniwersytetu Jagiellońskiego. Profesor rozpoczyna pracę na Wydziale Rolniczym obejmując Katedrę Statystyki Matematycznej. W momencie objęcia Katedry Profesor ma 65 lat. Mimo swego wieku rzuca się w wir pracy naukowej i organizacyjnej. Kończy podręcznik rozpoczęty w okresie przymusowego urlopu. Książka ta ukazuje się w wydawnictwie centralnym PWRiL i nosi tytuł „Zastosowanie metod statystycznych w zootechnice” (2 tomy). Recenzuje kilka rozpraw doktorskich i habilitacyjnych. Jest Go znowu wszędzie pełno. Na twórczość naukową Profesora składa się około 200 prac opublikowanych w kraju i za granicą. W dorobku tym skoncentrowanym na najważniejszych

problemach polskiego rolnictwa można wyróżnić pięć podstawowych nurtów badawczych.

Pierwszy a zarazem zasadniczy problem dotyczy ustroju polskiego rolnictwa. Badania obejmują strukturę obszarową gospodarstw, ich wyposażenie w środki techniczne, kierunki produkcji rolniczej, odległości od rynków zbytu a także stosunki własnościowe oraz sposoby dziedziczenia ziemi. Zagadnienia te pozostają nadal w pełni aktualne biorąc pod uwagę wolne tempo zachodzących zmian w strukturze agrarnej naszego kraju. Owe powolne przeobrażenia stanowią hamulec rozwoju towarowości polskiego rolnictwa. Profesor uważał, że pewna doza interwencjonizmu państwowego w sferze rolnictwa jest potrzebna. Dotyczy to w pierwszym rzędzie obniżenia cen środków produkcji stosowanych w rolnictwie oraz stymulacji eksportu płodów rolnych. Interesował się także optimum wielkości gospodarstwa rolnego. Zauważył, iż nie ma jednego optimum dla każdego przypadku bowiem korzystna dla rolnika wielkość zależy od wielu czynników i może się różnić zależnie od współwystępowania całej ich gamy.

Drugi wątek Jego prac badawczych jest związany z zagadnieniami rynku rolnego, relacją popyt – podaż produktów rolnych ze szczególnym naciskiem na ich ceny oraz organizacją tegoż rynku. Profesor zajmował się analizą rynku rolnego przy zastosowaniu nowoczesnych, jak na owe czasy, metod statystyczno – ekonometrycznych. Tu współpracował z początkującym adeptem nauki Janem Steczkowskim – późniejszym znanym i uznanym w całej Polsce profesorem statystyki – pracownikiem Uniwersytetu Ekonomicznego. Zastosowanie metod statystyki matematycznej pozwoliło na wykrycie występującego w Polsce „cyklu świńskiego”. Podobne wyniki osiągnęli M. Ezekiel w Stanach Zjednoczonych i A. Hann w Niemczech.

Trzecia grupa problemów, którą można wyróżnić w Jego twórczości naukowej dotyczy ekonomiki i organizacji gospodarstw rolnych. Profesor Schmidt od dłuższego czasu zajmował się badaniami wydajności pracy w rolnictwie a zwłaszcza pracochłonności poszczególnych upraw. Badania te miały służyć w procesie ustalania norm pracy. W rezultacie tych badań powstaje praca we współautorstwie z M. Kosieradzkim nt. „*Metodyka technicznego normowania pracy w rolnictwie*” wydana w 1959 roku przez oficynę wydawniczą PWRiL w Warszawie.

Czwarty rodzaj zagadnień badawczych, niezwykle aktualny i ważny w owym czasie, jest związany z procesem zagospodarowania Ziemi Odzyskanych. Tu wymienić należy artykuł z 1947 roku zamieszczony w serii zeszytów SGGW poświęconych problematyce Ziemi Odzyskanych zatytułowanej „*Gospodarstwo wiejskie na Ziemiach Odzyskanych*”. Publikacja Profesora zapełniła w całości pierwszy numer zeszytów z tej serii. Również w tej serii ukazał się drugi Jego artykuł pt. „*Charakterystyka produkcji roślinnej Ziemi Odzyskanych*.”

Piąty nurt badawczy Profesora dotyczy zastosowań metod statystyki matematycznej na gruncie aplikacji rolniczych. Profesor jako pierwszy lub jeden z pierwszych w Polsce połączył dwie orientacje metodologiczne a mianowicie

biometrię i ekonometrię w zastosowaniu do badań w rolnictwie. Uznawany jest za prekursora agroekonometrii w Polsce. Zwieńczeniem Jego działalności na tym odcinku był wspomniany już dwutomowy podręcznik pt. „Zastosowanie metod statystycznych w zootechnice” (1964). Jako pierwszy w Polsce z prof. J. Fierichem docenili rolę *badań operacyjnych* w rolnictwie.

W 1960 roku Profesor Stefan Schmidt, mający wówczas 71 lat, przechodzi na emeryturę. Nadal pozostaje niezwykle aktywnym naukowo człowiekiem. Dużo publikuje, wykonuje recenzje rozpraw doktorskich i habilitacyjnych i współpracuje z młodszymi pracownikami naukowymi. Profesor nigdy nie był uhonorowany żadnym z odznaczeń państwowych. Posiadał natomiast odznaki przynależności do krajowych i międzynarodowych towarzystw naukowych. Był członkiem honorowym Komitetu Ekonomiki Rolnictwa PAN, członkiem Komitetu Zagospodarowania Ziem Górskich PAN, członkiem Komisji Nauk Rolniczych i Leśnych PAN Oddział w Krakowie, członkiem Towarzystwa Naukowego Rozwoju Ziem Zachodnich, członkiem założycielem Polskiego Towarzystwa Biometrycznego, członkiem dożywotnim Rogal Economic Society (od 1936), członkiem International Center of Scientific Latour Organization in Agriculture oraz International Association of Agriculture Economists. Wyjeżdżał na międzynarodowe kongresy ekonomistów rolnych (Indie, Francja, Meksyk i Szwecja). Dzisiaj można określić Go postacią światowego formatu zarówno od strony naukowej, jak i moralnej. Po przejściu Profesora Schmidta w stan spoczynku, stanowisko kierownika Katedry nie było obsadzone. Patronat nad jednostką sprawował do 1964 roku profesor Jan Czarkowski, pełniący jednocześnie funkcję kierownika Katedry Ekonomii Politycznej. Katedra w tym okresie schodzi do rangi zakładu o tej samej nazwie.

**

Kolejnym szefem Katedry Statystyki Matematycznej zostaje doc. dr hab. Jan Pocięj. Katedrę obejmuje w 1964 roku po czteroletniej przerwie, kiedy to jednostką zarządzał tymczasowo prof. Jan Czarkowski. Doc. dr hab. Jan Pocięj urodził się 18 października 1916 roku w maleńkim miasteczku Opatowiec nad Wisłą. Do czteroletniej podstawówki uczęszczał w latach 1923 – 1927 by następnie podjąć naukę w Staroklasycznym Gimnazjum w Tarnowie, które ukończył w 1935 roku. W tym samym roku rozpoczyna studia na Wydziale Rolniczym Uniwersytetu Jagiellońskiego w Krakowie. Studia przerywa II wojna światowa. Swoją edukację kończy dopiero po wojnie uzyskując magisterium na podstawie pracy dyplomowej nt. „*Oplacalność melioracji gruntów ornych*”. Okres II wojny światowej to czas udręki dla wszystkich polskich obywateli. W okresie wojny Jan Pocięj podejmował się różnych prac aby zarobić na swe utrzymanie. Był członkiem tajnej organizacji Związku Jaszczurczego a następnie Narodowych Sił Zbrojnych. Jego droga życiowa nie była łatwa. Losy młodego człowieka w tych czasach nie były usłane różami. Absorbowała Go praca konspiracyjna zaś praca naukowa została odsunięta

na bok. Nie mógł zajmować się nauką, która była Jego przeznaczeniem. Dopiero po wojnie kończy studia i wreszcie osiąga to o czym marzył. Zostaje przyjęty do Katedry Ekonomii Rolnej pod kierownictwem Profesora Schmidta. Jednocześnie pracuje w Biurze Studiów Osadniczo – Przesiedleńczych Ministerstwa Ziemi Odzyskanych w Krakowie. Również w tym okresie pracuje nad rozprawą doktorską nt. „*Struktura inwentarza żywego w zależności od warunków przyrodniczych i gospodarczych*”. Uwieńczeniem prac nad rozprawą jest uzyskanie stopnia doktora nauk rolniczych w 1950 roku. Będąc uczniem Profesora Stefana Schmidta przez kilka lat pracuje w Jego Katedrze na stanowisku asystenta. Razem z Profesorem odchodzi z uczelni w 1950 roku. W 1957 roku powraca do nowoutworzonej Wyższej Szkoły Rolniczej by objąć stanowisko adiunkta w nowopowstałej Katedrze Statystyki Matematycznej kierowanej przez Profesora Schmidta.

Jan Pociąg wkrótce napisał rozprawę habilitacyjną nt. „*Preliminowanie pracy żywej w rolnictwie metodą zasadniczych spięrzeń*”. Rozprawa ta stała się podstawą do nadania mu stopnia doktora habilitowanego przez Radę Wydziału Rolniczego Wyższej Szkoły Rolniczej w Krakowie w 1964 roku. Wraz ze stopniem dr hab. Jan Pociąg otrzymuje nominację na stanowisko docenta i kierownika Katedry. Po wydarzeniach marcowych w 1968 roku Katedra Statystyki Matematycznej traci prawa Katedry i tworzy tylko Zespół Statystyki Matematycznej, który wchodzi w skład Instytutu Ekonomiki i Organizacji Rolnictwa Wyższej Szkoły Rolniczej. Lata siedemdziesiąte i osiemdziesiąte ubiegłego stulecia można nazwać „latami chudymi” w całych dziejach jednostki. Pracownicy Zespołu mają olbrzymie obciążenia zajęciami dydaktycznymi, wykonując program zarówno z przedmiotu statystyki, jak i z nowo wprowadzonej elektronicznej techniki obliczeniowej. Prowadzą dydaktykę w uczelni macierzystej ale także w nowo powstałych Punktach Konsultacyjnych w Łąncucie i Przemysłu oraz w zamiejscowym Wydziale Ekonomiki w Rzeszowie. W okresie tym obserwuje się stosunkowo dużą fluktuację Kadr w Zespole. Wszystkie te zaszczyty skutkowały niewielkim liczebnie dorobkiem naukowym pracowników. Pod kierunkiem doc. Jana Pociąga obroniono cztery prace doktorskie oraz kilkanaście prac magisterskich. Jednym z doktorantów docenta jest dzisiaj już były adiunkt Katedry Statystyki Matematycznej dr Jan Krawontka. Docent dr hab. Jan Pociąg wydał następujące pozycje książkowe:

- Rolnictwo Polski Południowo – Wschodniej, PWRiL, Warszawa 1970,
- Metody statystyki opisowej, skrypt AR, wyd. I w 1972 (ogółem 3 wydania),
- Wybrane tablice statystyczne, wyd. AR, 1979.

Przez wiele lat doc. Jan Pociąg pełnił funkcję redaktora *Zeszytów Naukowych* – Seria Ekonomiki w Akademii Rolniczej w Krakowie. W latach 1970-1974 jest sekretarzem naukowym Komitetu Zagospodarowania Ziemi Górskich. Władze uczelni w uznaniu Jego zasług wystąpiły z wnioskiem o nadanie Mu państwowych odznaczeń:

- Złoty Krzyż Zasługi,
- Krzyż Kawalerski Orderu Odrodzenia Polski,
- Medal Komisji Edukacji Narodowej.

Docent Jan Pociąg odchodzi na zasłużoną emeryturę w 1987 roku. Nie pozostawia żadnego samodzielnego pracownika, który mógłby przejąć kierownictwo jednostki. Od 1987 do lutego 1992 roku opiekę nad Zakładem Statystyki Matematycznej sprawuje ówczesny kierownik Katedry Ekonomiki i Organizacji Rolnictwa, dziś już nieżyjący, prof. zw. dr hab. Eugeniusz Otoliniński.

W lutym 1992 roku do Akademii Rolniczej przychodzi z ówczesnej Akademii Ekonomicznej w Krakowie dr hab. Karol Kukuła. Zostaje w tym samym roku powołany na stanowisko profesora nadzwyczajnego i jednocześnie powierzono Mu funkcję kierownika Zakładu Statystyki Matematycznej. Zakład prowadzi obsługę dydaktyczną trzech wydziałów: Wydziału Rolniczego, Wydziału Ogrodniczego oraz Wydziału Technologii Żywności. Powiększa się liczba przedmiotów wykładanych przez pracowników Zakładu. Do przedmiotów tych należą: statystyka matematyczna, statystyka opisowa, matematyka, informatyka, badania operacyjne, ekonometria, prognozowanie i symulacje oraz ocena zjawisk złożonych. Powiększa się i stabilizuje zarazem liczba pracowników. Obecny stan Katedry to 10 pracowników naukowo – dydaktycznych oraz 2 pracowników naukowo- technicznych. Skład Katedry tworzą 1 profesor zwyczajny, 2 doktorów habilitowanych oraz 7 pracowników ze stopniem doktora. W pracach Katedry uczestniczy doktorant, który jest w ostatnim stadium ubiegania się o stopień. Z wymienionego składu 9 osób uzyskało stopień doktora pod kierunkiem profesora Karola Kukuły. W trakcie realizacji są habilitacje kolejnych pracowników Katedry. W ostatnim dwudziestoleciu na koncie pracowników Katedry Statystyki Matematycznej odnotowano ponad 300 prac magisterskich i licencjackich wykonanych na studiach dziennych i zaocznych. W 1994 roku Katedra organizuje międzynarodową konferencję w Kamienicy. Było to XXIV Colloquium Metodologiczne z Agrobiometrii. W 2006 roku przypadała 50 rocznica istnienia Katedry. Z tej okazji zorganizowano międzynarodową konferencję nt. „Statystyka na usługach gospodarki żywnościowej”. Również i ta konferencja odbyła się w Kamienicy – Ośrodek w Gorcach. W 2012 roku w ramach obchodu 40 – lecia pracy naukowo – dydaktycznej prof. Kukuły, zorganizowano międzynarodową Konferencję będącą kontynuacją poprzedniej „Statystyka na usługach gospodarki żywnościowej II”. Konferencja odbyła się w Szczawnicy w Pieninach.

Okres lat dziewięćdziesiątych XX stulecia stanowi niespotykany w historii powojennej Polski okres nasilenia przemian społeczno – gospodarczych. Wydarzenia, jakie miały miejsce w tym okresie doprowadziły do transformacji ustrojowej w Polsce. W dzieło tych pozytywnych przemian wpisuje się zespół pracowników Zakładu Statystyki Matematycznej. W 1995 pracownicy Zakładu

uczestniczą w zakrojonym na szeroką skalę projekcie. Przedsięwzięcie to stanowi organizację kursu nt. „Kształcenie liderów wiejskich w zakresie ekonomii rynkowej w celu rozwijania działalności rolniczej w Polsce Południowej”. Szkolenia były przeznaczone dla pracowników doradztwa rolniczego oraz nauczycieli szkół rolniczych Polski Południowej. Dyrektorem oraz koordynatorem projektu był profesor Karol Kukuła. Szkoleniem objęto 120 osób. Zajęcia były prowadzone w siedzibach szkół rolniczych w Giebułtowiu, Radoczy i Nawojowej. Ta niezwykle potrzebna i pożyteczna akcja dla regionu Polski Południowej była finansowana z funduszy FAPA (Fundacja Programów Pomocy dla Rolnictwa) w ramach szerszego programu PHARE. Podsumowaniem trwającego cały 1995 rok kursu było wydanie podręcznika dla jego uczestników pt. „*Elementy ekonomii rynkowej w gospodarce rolno – żywnościowej*”. Książka ta jest pracą zbiorową wykładowców kursu i ukazała się pod redakcją profesorów: Karola Kukuły i Jana Siekierskiego.

Pracę naukową członków Katedry stanowi wielowątkowa działalność publikacyjna w formie artykułów i monografii. Z ważniejszych zagadnień będących przedmiotem zainteresowań pracowników Katedry Statystyki Matematycznej wymienić należy:

1. Badania nad strukturą obszarową gospodarstw indywidualnych w Polsce w ujęciu dynamiczno – przestrzennym.
2. Wielokryterialne oceny infrastruktury technicznej wsi w ujęciu regionalnym.
3. Analiza stanu służby zdrowia i opieki społecznej polskiej wsi – badania regionalne.
4. Badania preferencji konsumenckich przy użyciu pomiaru łącznego.
5. Studia regionalne w zakresie agroturystyki oraz jej bazy.
6. Analiza stopnia degradacji środowiska w świetle ponoszonych nakładów na jego ochronę.
7. Modelowanie procesów biologicznych z wykorzystaniem symulacji komputerowej.
8. Poszukiwanie optimum intensywności gospodarstw wiejskich.
9. Rodzinne gospodarstwa rolne w Polsce Południowej.
10. Ekonometryczne modele bezrobocia na obszarach wiejskich.
11. Statystyczna analiza sfery gospodarstw ekologicznych w Polsce.
12. Ocena stopnia umaszynowania polskiego rolnictwa – badania regionalne.
13. Regionalne studium stopnia rozwoju biogospodarki w Polsce.
14. Rozwój biogospodarki w UE – badania rankingowe.
15. Studia regionalne w zakresie struktury agrarnej – poziom województw i powiatów.
16. Trendy wykorzystywania odnawialnych źródeł energii w produkcji energii elektrycznej w Polsce.
17. Badania rankingowe krajów UE w zakresie produkcji energii odnawialnej.

18. Gospodarka odpadami w Polsce – badania przestrzenne.
19. Studia teoretyczne nad utworzeniem procedury wyboru metody porządkowania liniowego.
20. Studia teoretyczne nad procedurą budowy rankingu oraz podziału obiektów na grupy.

Badania nad strukturą agrarną w Polsce zapoczątkował jeszcze w okresie międzywojennym prof. Stefan Schmidt. Badania te są kontynuowane, o czym świadczą publikacje dr Jadwigi Bożek (w tym doktorat i habilitacja) a także prace profesora Karola Kukuły. Kilka lat temu w Katedrze pojęto realizację szeroko zakrojonych badań nad strukturą przestrzenną gospodarstw w Polsce w ramach projektu NN 310170333. Owocem tych prac jest monografia wydana w 2010 roku w oficynie wydawniczej PWN w Warszawie pt. „*Statystyczne studium struktury agrarnej w Polsce*”. Redaktorem naukowym oraz współautorem tej publikacji jest prof. Karol Kukuła. Pozostałymi autorami są: dr Danuta Bogocz, dr hab. Jadwiga Bożek i dr hab. Jacek Strojny. Warto podkreślić, iż zagadnienia związane ze zmianami oraz ukształtowaniem przestrzennym struktury obszarowej gospodarstw należą do problemów kluczowych związanych z rozwojem polskiego rolnictwa. Chodzi tu głównie o konkurencyjność naszego rolnictwa w UE. Stąd też widać silny związek realizowanych badań z praktyką.

W Katedrze zajmowano się również problematyką natury teoretycznej. Do zagadnień tych należą:

- Stworzenie podstaw statystycznej analizy strukturalnej (SAS), pozycja monograficzna Karola Kukuły: „*Statystyczne metody analizy struktur ekonomicznych*”, Wyd. Edukacyjne, Kraków 1996.
- Monograficzne opracowanie własności oraz możliwości aplikacyjnych jednej z metod normowania cech diagnostycznych. Pozycja książkowa Karola Kukuły: „*Metoda unitaryzacji zerowanej*”, PWN, Warszawa 2000.
- Zastosowania teorii zbiorów rozmytych w badaniach ekonomicznych – doktorat Danuty Bogocz.
- Opracowanie procedury wspomagającej proces wyboru metody normowania cech diagnostycznych – prace artykułowe prof. Karola Kukuły i dr Lidii Luty.
- Opracowanie procedury budowy rankingu obiektów na bazie zmiennej syntetycznej – prace artykułowe prof. Karola Kukuły.

Równoległe z prowadzeniem działalności naukowej pracownicy Katedry podejmują wysiłki nad stworzeniem jak najlepszych warunków realizacji dydaktyki niełatwych dla studentów przedmiotów wykładanych w Katedrze. Znajduje to swój wyraz w opracowaniu podręczników i skryptów. Pierwszy skrypt z cyklu pomocy dydaktycznych autorstwa J. Bożek i J. Krawontki „*Podstawy informatyki*” został zrealizowany przez wydawnictwo uczelniane w 1991 i 1992 roku. Następnym, będącym dziełem zespołu złożonego z czterech osób (E. Badach, D. Bogocz, J. Krawontka i K. Kukuła) był skrypt do matematyki „*Wybrane*

zagadnienia matematyki w zadaniach". Skrypt ten powstał pod red. K. Kukuły. Pozycja ta miała 3 wydania w latach: 1995, 1996 i 2014. Kolejną pozycją jest podręcznik ze statystyki o zasięgu ogólnopolskim wydany przez oficynę wydawniczą PWN „*Elementy statystyki w zadaniach*” autorstwa K. Kukuły. Pozycja ta miała dwa wydania w 1998 i 2004 roku. Wykładany na kierunkach Ekonomia i Zarządzanie przedmiot Ekonometria ma także podręcznik pod red. K. Kukuły „*Wprowadzenie do ekonometrii w przykładach i zadaniach*”, wydany przez Wydawnictwo Naukowe PWN – dwie edycje. Modyfikacja tej pracy będąca rozszerzeniem jej zawartości o zagadnienia teoretyczne ukazała się w 2009 roku pod skróconym tytułem „*Wprowadzenie do ekonometrii*”. Podobnie jak w poprzedniej pracy zespół autorski stanowili: dr Zbigniew Jędrzejczyk, prof. Karol Kukuła, prof. Jacek Osiewalski oraz dr Anna Walkosz. Publikacja ta licząca niepełne 500 stron została zrealizowana przez Wyd. Naukowe PWN pod red. prof. Karola Kukuły. Również badania operacyjne będące przedmiotem wykładu na specjalności Zarządzanie mają swój podręcznik wydawany przez Wydawnictwo Naukowe PWN w Warszawie od 1991 roku. Ostatnie wydanie tego podręcznika o zasięgu ogólnokrajowym to wydanie siódme i ukazało się w roku Jubileuszu Katedry tj. w 2016 roku. Długi bo trwający ćwierć wieku okres istnienia tej pozycji na rynku krajowym świadczy o dużym zapotrzebowaniu na tego rodzaju prace. „*Badania operacyjne w przykładach i zadaniach*” są owocem długoletniej współpracy redaktora naukowego tego podręcznika prof. Karola Kukuły z Uniwersytetu Rolniczego w Krakowie z dr Zbigniewem Jędrzejczykiem, dr Jerzym Skrzypkim oraz dr Anną Walkosz – wszyscy reprezentują Uniwersytet Ekonomiczny w Krakowie. Z przytoczonych informacji jasno wynika, że wszystkie przedmioty prowadzone w ramach Katedry Statystyki i Ekonometrii mają silne wsparcie w podręcznikach, których autorami bądź współautorami są pracownicy tejże Katedry.

Kierownik Katedry Statystyki i Ekonometrii oraz Jego współpracownicy podejmują pracę w innych ośrodkach akademickich w kraju. Obecny szef Katedry prof. Kukuła od 2002 roku do chwili obecnej pracuje na drugim etacie w Państwowej Wyższej Szkole Zawodowej w Tarnowie. Nieco wcześniej wykłada w Wyższej Szkole Biznesu i Przedsiębiorczości w Ostrowcu Świętokrzyskim, gdzie sprawuje funkcję prorektora. Następnie jest zaproszony do Wyższej Szkoły Humanistyczno – Ekonomicznej w Zamościu, gdzie prowadzi wykłady ze statystyki, ekonometrii i badań operacyjnych gromadząc jednocześnie grupy studentów na seminariach licencjackich i magisterskich. W latach 2001-2003 powierzono mu zaszczytną godność rektora tej uczelni.

W minionym sześćdziesięcioleciu Katedra Statystyki i Ekonometrii pełniła rolę głównego ośrodka dydaktycznego na Wydziale Rolniczo – Ekonomicznym z zakresu przedmiotów ścisłych takich jak: matematyka, informatyka, statystyka, ekonometria, ekonomia matematyczna, badania operacyjne, prognozowanie i symulacje oraz ocena zjawisk złożonych. Myślę, iż warto pamiętać o tym, że Wydział Rolniczo – Ekonomiczny ma za zadanie dostarczać gospodarce

ekonomistów, menagerów i inżynierów. Stąd koniecznym wydaje się zwrócenie szczególnej uwagi na kształcenie oraz efekty tego kształcenia w zakresie przedmiotów ścisłych. Rola Katedry obchodzącej Jubileusz sześćdziesięciolecia istnienia w dydaktyce tych przedmiotów jest nie do podważenia. Konstatację tę dedykują zarówno władzom Wydziału Rolniczo – Ekonomicznego jak i władzom rektorskim Uczelni.

Na zakończenie zamieszczam krótkie kalendarium kierownictwa obecnej Katedry Statystyki i Ekonometrii; działającej w ramach Wydziału Rolniczo – Ekonomicznego Uniwersytetu Rolniczego im. Hugona Kołłątaja w Krakowie.

1. Prof. zw. dr hab. Stefan Schmidt – (1956-1960)
2. Prof. dr hab. Jan Czarkowski – opiekun tymczasowy – (1960-1964)
3. doc. dr hab. Jan Pociąg – (1964 –1987)
4. Prof. zw. dr hab. Eugeniusz Otoliński – opiekun tymczasowy – (1987-1992)
5. Prof. zw. dr hab. Karol Kukuła (1992 – do chwili obecnej).

**60TH ANNIVERSARY OF THE EXISTENCE
OF THE DEPARTMENT OF STATISTICS AND ECONOMETRICS
IN THE STRUCTURE OF THE AGRICULTURAL UNIVERSITY
IN KRAKOW**

Abstract: Sixty years of the existence (1956 – 2016) of the Department of Mathematical Statistics makes a long period of time. The activity of this department begins with the very beginning of functioning of the Higher Agricultural School in Krakow that is from the year of 1953. This school is based on the foundations of the employees of the Jagiellonian University. This is also the mother university of the founder and creator of this Department, Prof. Stefan Schmidt. The subsequent Head of the Department is the Assistant Professor Jan Pociąg (1964 – 1987). Since 1992 up to now the Head of the Department has been Prof. Karol Kukuła. Within this period many original scientific works have been written – monographs, articles and textbooks spread out throughout the country. Since 2015 the name of the Department has been changed into the Department of Statistics and Econometrics.

Keywords: Department of Statistics and Econometrics, monographs, textbooks, articles

SYTUACJA KOBIET NA RYNKU PRACY W POLSCE NA TLE KRAJÓW UNII EUROPEJSKIEJ – ANALIZA STATYSTYCZNA

Iwona Bąk

Katedra Zastosowań Matematyki w Ekonomii
Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
e-mail: iwona.bak@zut.edu.pl

Streszczenie: Celem artykułu jest ocena sytuacji kobiet na rynku pracy w Polsce na tle krajów Unii Europejskiej. Analizę rozpoczęto od charakterystyki wybranych aspektów rynku pracy kobiet. Wykorzystując metodę unitaryzacji zerowanej sporządzono dwa rankingi. Pierwszy z nich dotyczył roku 2004, a więc momentu wejścia Polski do UE, drugi zaś ukazywał klasyfikację państw członkowskich dziesięć lat później. Następnie wykorzystując wartości miernika syntetycznego wyodrębniono grupy typologiczne krajów o podobnej sytuacji kobiet na rynku pracy. Z przeprowadzonych badań wynika, że nasz kraj w 2014 roku dość znacząco poprawił się pod względem sytuacji kobiet na rynku pracy. Wzrosły wskaźniki zatrudnienia, a zmniejszyły się wskaźniki dotyczące bezrobocia, zwłaszcza długookresowego oraz wśród młodych kobiet.

Słowa kluczowe: rynek pracy kobiet, metoda unitaryzacji zerowanej, Unia Europejska

WSTĘP

Problematyka nierówności płci na rynku pracy to jedna z bardziej interesujących dziedzin badań naukowych. Aktualności owym zagadnieniom nadaje fakt, iż polityka równouprawnienia w Unii Europejskiej jest jednym z priorytetowych instrumentów polityki społeczno-gospodarczej. Mimo zmian w świadomości społecznej, istnienia prawnych zapisów, programów oraz dyrektyw unijnych, kobiety w dalszym ciągu stanowią kategorię dyskryminowaną w różnych aspektach życia społecznego, zwłaszcza na rynku pracy. Dyskryminacja kobiet oznacza przypadki występowania różnicowania sytuacji zawodowych kobiet i mężczyzn na niekorzyść tych pierwszych, wynikające z zastosowania różnych

kryteriów oceny (nierówność miar) bądź (i) oferowania różnych możliwości rozwoju (nierówność szans) pracownikom o porównywalnym poziomie wykształcenia, wydajności pracy, doświadczeniu zawodowym, stażu pracy itp. [Kalinowska-Nawrotek 2004, s. 232]. Kobiety aktywne zawodowo spotykają się z dyskryminacją w wielu sytuacjach i na różnych etapach kariery, m.in.: na poziomie rekrutacji, dostępu do awansów, możliwości dokończania, wynagrodzenia za pracę, narażone są także na mobbing i molestowania seksualne. Muszą również borykać się z problemami łączenia obowiązków zawodowych i rodzinnych, a wracając na rynek pracy po przebytych urlopie macierzyńskim często obciążone są problemem dezaktualizacji ich kwalifikacji, wiedzy i umiejętności [Czubarą i inni 2012, s. 5].

Celem badania, którego wyniki zamieszczono w artykule, była ocena sytuacji kobiet na rynku pracy w Polsce na tle krajów Unii Europejskiej (UE). Analizę rozpoczęto od charakterystyki wybranych aspektów rynku pracy. Do określenia pozycji Polski wśród krajów unijnych wykorzystano wyniki klasyfikacji poszczególnych państw członkowskich oraz charakterystykę wyodrębnionych grup typologicznych krajów o podobnej sytuacji na rynku pracy. Liniowe porządkowanie krajów przeprowadzono za pomocą metody unitaryzacji zerowanej. Sporządzono dwa rankingi: pierwszy z nich dotyczył roku 2004, a więc momentu wejścia Polski do UE, drugi zaś ukazywał klasyfikację państw członkowskich dziesięć lat później, dzięki czemu możliwe było uchwycenie ewentualnych zmian dotyczących badanego zjawiska.

WYBRANE ASPEKTY RYNKU PRACY KOBIEC W POLSCE NA TLE UNII EUROPEJSKIEJ

W latach 2004-2014 wskaźnik zatrudnienia kobiet w UE był niższy niż wskaźnik zatrudnienia mężczyzn (Tabela 1). Sytuacja taka dotyczyła również naszego kraju. Zauważyć jednak można znaczne różnice w dynamice badanych wskaźników. W UE dysproporcja między wskaźnikiem zatrudnienia mężczyzn i kobiet zmniejszyła się z 14,9 p.p. w 2004 roku do 10,6 p.p. w roku 2014. W Polsce natomiast odnotowano wzrost tej różnicy w badanym okresie o 2 p.p. (z 11 p.p. do 13 p.p.). Zauważyć można, że w latach 2004-2007 w UE różnice między wskaźnikami były wyższe niż w Polsce, w roku 2008 nastąpiło zrównanie tych różnic, a począwszy od 2009 roku sytuacja uległa odwróceniu – różnice między obydwojma wskaźnikami w Polsce były wyższe niż w UE.

Tabela 1. Wskaźniki zatrudnienia w Polsce oraz w Unii Europejskiej ogółem i według płci w latach 2004-2014

Lata	Polska			Unia Europejska		
	ogółem	kobiety	mężczyźni	ogółem	kobiety	mężczyźni
2004	51,9	46,4	57,4	62,7	55,3	70,2
2005	53,0	47,0	59,0	63,4	56,0	70,7
2006	54,5	48,2	60,9	64,3	57,1	71,6
2007	57,0	50,6	63,6	65,3	58,1	72,4
2008	59,2	52,4	66,3	65,7	58,8	72,7
2009	59,3	52,8	66,1	64,5	58,3	70,6
2010	58,9	52,6	65,3	64,0	58,1	70,0
2011	59,3	52,7	66,0	64,1	58,4	70,0
2012	59,7	53,1	66,3	64,1	58,5	69,6
2013	60,0	53,4	66,6	64,1	58,8	69,4
2014	61,7	55,2	68,2	64,8	59,5	70,1

Źródło: opracowanie własne na podstawie danych Eurostatu

W 2014 r. we wszystkich państwach członkowskich UE wskaźniki zatrudnienia mężczyzn utrzymywały się na wyższym poziomie niż wskaźniki zatrudnienia kobiet, choć zaobserwowano też znaczące różnice między państwami. Różnica między wskaźnikiem zatrudnienia kobiet a wskaźnikiem zatrudnienia mężczyzn na Malcie wyniosła aż 25,6 p.p. i tam odnotowano też trzeci w kolejności od najniższego wskaźnik zatrudnienia kobiet (49,3%). Wysoką różnicę odnotowały ponadto Włochy (17,9 p.p.) i Grecja (16,9 p.p.) – kraje, które pod względem wielkości wskaźnika zatrudnienia kobiet zajmują odpowiednio przedostatnie i ostatnie miejsce wśród państw członkowskich. Najniższe różnice w zatrudnieniu kobiet i mężczyzn zaobserwowano w Finlandii (1,5 p.p.) i na Litwie (1,6 p.p.). Różnice między płciami pod względem wskaźnika zatrudnienia były też stosunkowo niewielkie w Szwecji i na Łotwie, gdzie wskaźnik zatrudnienia kobiet był o mniej niż 4,1 punkty procentowe niższy niż wskaźnik zatrudnienia mężczyzn. W Polsce różnica między wskaźnikami zatrudnienia mężczyzn i kobiet wyniosła 13 p.p. Wskaźnik zatrudnienia kobiet w Polsce (55,2%) jest nadal jednym z niższych w Unii Europejskiej. Niższy od Polski wskaźnik odnotowano w Grecji (41,1%), we Włoszech (46,8%), na Malcie (49,3%), w Hiszpanii (51,2%), Chorwacji (50,0%), Rumunii (53,3%) oraz na Słowacji (54,3%)¹.

W Polsce, podobnie do większości krajów UE, istotnym problemem jest poziom zatrudnienia wśród osób młodych (15-24 lata), dotyczy to szczególnie kobiet. Tylko nieliczne kraje mogą poszczycić się wysokimi wskaźnikami zatrudnienia w tej grupie wiekowej, należą do nich Holandia (60,7%) i Dania (54,9%). Wskaźnik zatrudnienia powyżej 40% odnotowano również w: Austrii (49,9%), Wielkiej Brytanii (47,8%), na Malcie (46,7%), w Niemczech (44,3%),


¹ Dane Eurostatu dla kobiet w wieku 15 - 64 lat.

Szwecji (44%) i Finlandii (43%). W 2014 r. pracowało tylko 10,9% młodych Greczynek oraz 12,8% kobiet we Włoszech, a także ponad 15% kobiet w Chorwacji, Bułgarii czy Luksemburgu. Polska ze wskaźnikiem 21,3% również odstaje *in minus* od średniej UE (29,03%)².

W 2004 roku stopa bezrobocia w Polsce kształtowała się na poziomie 19,1%, co było najgorszym wynikiem wśród wszystkich państw członkowskich (przeciętnie dla UE wskaźnik ten wynosił 9,3%). W kolejnych latach sytuacja Polski w tym względzie ulegała poprawie. W 2014 roku stopa bezrobocia wyniosła 9% i była niższa od średniej unijnej o 1,2 p.p. Spowodowało to przesunięcie naszego kraju z 28 (w 2004) na 15 pozycję. Bezrobocie wśród kobiet, zarówno w krajach UE, jak i w Polsce, jest wyższe niż wśród mężczyzn [Polska 2015...2015]. Przeciętna dla roku 2014 stopa bezrobocia dla krajów UE-28 wyniosła 10,1% dla mężczyzn oraz 10,3% dla kobiet. W Polsce dysproporcja między tymi wskaźnikami była większa i wynosiła 1,1 p.p. (8,5% dla mężczyzn oraz 9,6% dla kobiet).

Dla bliższego zobrazowania i pomiaru różnic pomiędzy sytuacją kobiet i mężczyzn w zakresie bezrobocia wyznaczono wskaźnik zróżnicowania (dyskryminacji) „R” [Kalinowska-Nawrotek 2004, s. 234]. Wskaźnik ten wyraża różnicę pomiędzy stopą bezrobocia kobiet a stopą bezrobocia mężczyzn i stanowi swego rodzaju miernik nierówności płci w odniesieniu do bezrobocia.

Rysunek 1. Kształtowanie się wskaźnika dyskryminacji „R” w krajach Unii Europejskiej w 2014 roku



Źródło: opracowanie własne na podstawie danych Eurostatu

Na Rysunku 1 przedstawiono wartości wskaźnika dyskryminacji „R” w Polsce na tle krajów Unii Europejskiej w 2014 roku. W dwunastu krajach unijnych wskaźnik był dodatni, co oznacza, że kobietom w tych krajach trudniej było znaleźć

² Wyraźna dysproporcja (ponad 9 pkt. proc.) pomiędzy danymi dla Polski i UE widoczna jest również w grupach wiekowych osób starszych (przedział wiekowy 55-64).

pracę niż mężczyznom. Największe dysproporcje wystąpiły w krajach południowej Europy, takich jak: Grecja, Włochy, Chorwacja, Hiszpania, wartości wskaźnika „R” kształtowały się tam od 1,8 do 6,5 p.p. Nie bez wpływu na taki stan rzeczy pozostaje dominujący w tych krajach tzw. tradycyjny model rodziny, w którym rola kobiety sprowadza się głównie do funkcji prokreacyjnej, wychowywania dzieci i zajmowania się ogniskiem domowym³. Wysokim wskaźnikiem dyskryminacji, wynoszącym 2,3 p.p., charakteryzowały się ponadto Czechy. W grupie krajów o niekorzystnej sytuacji na rynku pracy znalazła się również Polska. Natomiast ujemne wartości wskaźnika zaobserwowano w szesnastu krajach członkowskich, przy czym, jak wynika z rys. 1 najłatwiej było znaleźć pracę kobietom w Irlandii.

TAKSONOMICZNA ANALIZA RYNKU PRACY KOBIET W KRAJACH UNII EUROPEJSKIEJ

Do oceny sytuacji na rynku pracy kobiet w Polsce na tle krajów UE zebrano wstępnie dane statystyczne o 21 cechach charakteryzujących wybrane aspekty tego rynku. Wybór cech zdeterminowany był dostępnością danych. Większość informacji pochodziła z 2004 i 2014 roku, jedynie w kilku przypadkach, z uwagi na brak danych, zdecydowano się na rok wcześniejszy⁴. Do liniowego porządkowania krajów Unii Europejskiej wykorzystano metodę unitaryzacji zerowanej. Prawidłowa konstrukcja miernika syntetycznego wymaga wyboru cech diagnostycznych o wysokich walorach dyskryminacyjnych. Dlatego też w pierwszym etapie z badania wykluczono te cechy, które charakteryzowały się względnym zróżnicowaniem poniżej 10% [Panek 2009, s. 19-20]. W kolejnym kroku, w celu wyeliminowania cech o podobnym potencjale informacyjnym, zastosowano dwie metody: Hellwiga i odwróconej macierzy⁵. W związku z tym, że dla każdego roku ostateczne zestawy cech nieznacznie się różniły, dlatego podjęto decyzję o ustaleniu jednakowej listy złożonej z tych cech, które znalazły się w obu zestawach. W ten sposób do badania zakwalifikowano następujące cechy diagnostyczne:

- X_1 – udział kobiet pracodawców w ogólnej liczbie zatrudnionych (w %),
- X_2 – wskaźnik zatrudnienia kobiet w wieku 15+ (w %),
- X_3 – wskaźnik zatrudnienia kobiet w wieku 15-24 lata (w %),
- X_4 – udział kobiet na wysokich stanowiskach kierowniczych w ogólnej liczbie zatrudnionych na tych stanowiskach (w %),

³ W 2004 roku różnice pomiędzy stopą bezrobocia kobiet i mężczyzn były jeszcze wyższe i wynosiły odpowiednio: dla Grecji - 9,6 p.p., dla Hiszpanii - 6,5 p.p., dla Włoch - 4,2 p.p. i dla Chorwacji - 3,4 p.p.

⁴ Dane pochodziły z bazy danych Eurostatu (10.01.2016) oraz z publikacji: *Polska w Unii Europejskiej 2004–2014*.

⁵ Opis tych metod można znaleźć np. w pracach: [Nowak 1990], [Malina 2004], [Młodak 2006], [Panek 2009].

- X_5 – udział kobiet w wieku produkcyjnym z wykształceniem wyższym w ogólnej liczbie kobiet w wieku produkcyjnym (w %),
- X_6 – udział długotrwałego bezrobocia kobiet w ogólnej liczbie bezrobotnych kobiet (w %),
- X_7 – udział kobiet zatrudnionych w niepełnym wymiarze w ogólnej liczbie zatrudnionych w niepełnym wymiarze (w %),
- X_8 – udział bezrobotnych kobiet z wykształceniem podstawowym w ogólnej liczbie bezrobotnych kobiet (w %),
- X_9 – udział bezrobotnych kobiet z wykształceniem wyższym w ogólnej liczbie bezrobotnych kobiet (w %).

W powyższym zbiorze znalazły się zarówno stymulanty, których wysokie wartości są korzystne z punktu widzenia istoty analizowanego zjawiska (X_1, X_2, X_3, X_4, X_5) oraz destymulanty (pozostałe cechy), w przypadku których pożądane są wartości niskie. Ponieważ cechy diagnostyczne mają różne miana i różne zakresy zmienności, zatem nie można ich bezpośrednio porównywać i dodawać. Należy je doprowadzić do porównywalności dokonując odpowiednich transformacji pozbawiających cechy mian i ujednoczyć co do rzędu wielkości. W pracy zastosowano metodę unitaryzacji zerowanej [Kukuła 2000, s. 60 – 92]. W metodzie tej stosuje się następujące przekształcenia:

$$\text{dla stymulant} \quad z_{ij} = \frac{x_{ij} - \min_i x_{ij}}{\max_i x_{ij} - \min_i x_{ij}}, \quad \max_i x_{ij} \neq \min_i x_{ij}; \quad (1)$$

$$\text{dla destymulant} \quad z_{ij} = \frac{\max_i x_{ij} - x_{ij}}{\max_i x_{ij} - \min_i x_{ij}}, \quad \max_i x_{ij} \neq \min_i x_{ij}. \quad (2)$$

Taki sposób normalizacji powoduje, że wszystkie wartości cech znormalizowanych należą do przedziału $[0,1]$. Syntetyczną miarę rozwoju (z_i) buduje się jako średnią arytmetyczną unormowanych wartości cech diagnostycznych:

$$z_i = \frac{1}{k} \sum_{j=1}^k z_{ij}, \quad (3)$$

gdzie: k - liczba cech diagnostycznych.

Na podstawie wartości miernika syntetycznego można wyodrębnić cztery grupy typologiczne, obejmujące obiekty o wartościach miernika z następujących przedziałów: grupa 1: $z_i \geq \bar{z} + s_z$; grupa 2: $\bar{z} + s_z > z_i \geq \bar{z}$; grupa 3: $\bar{z} > z_i \geq \bar{z} - s_z$; grupa 4: $z_i < \bar{z} - s_z$.

W Tabeli 2 przedstawiono wyniki klasyfikacji i grupy typologiczne krajów UE uzyskane na podstawie wartości syntetycznego miernika rozwoju obliczonego na podstawie cech charakteryzujących wybrane aspekty rynku pracy kobiet.

Tabela 2. Uporządkowanie krajów Unii Europejskiej ze względu na wybrane aspekty rynku pracy kobiet w latach 2004 i 2014

Kraje	Wartość miernika (μ_i)	Pozycja w rankingu	Nr grupy	Kraje	Wartość miernika (μ_i)	Pozycja w rankingu	Nr grupy
2004				2014			
Wielka Brytania	0,556	1	I	Szwecja	0,556	1	I
Szwecja	0,554	2	I	Finlandia	0,544	2	I
Finlandia	0,545	3	I	Dania	0,536	3	I
Luksemburg	0,544	4	I	Austria	0,533	4	I
Dania	0,54	5	I	Luksemburg	0,529	5	I
Irlandia	0,537	6	I	Wielka Brytania	0,526	6	II
Austria	0,528	7	II	Polska	0,514	7	II
Cypr	0,525	8	II	Malta	0,513	8	II
Holandia	0,515	9	II	Holandia	0,509	9	II
Malta	0,513	10	II	Estonia	0,508	10	II
Hiszpania	0,508	11	II	Rumunia	0,507	11	II
Łotwa	0,495	12	II	Łotwa	0,506	12	II
Francja	0,495	13	II	Francja	0,506	13	II
Węgry	0,489	14	III	Niemcy	0,504	14	II
Portugalia	0,484	15	III	Czechy	0,5	15	III
Estonia	0,475	16	III	Litwa	0,498	16	III
Polska	0,474	17	III	Cypr	0,495	17	III
Belgia	0,474	18	III	Belgia	0,494	18	III
Słowenia	0,473	19	III	Węgry	0,493	19	III
Włochy	0,471	20	III	Irlandia	0,492	20	III
Litwa	0,466	21	III	Hiszpania	0,482	21	III
Niemcy	0,465	22	III	Słowenia	0,482	22	III
Czechy	0,462	23	III	Bułgaria	0,475	23	IV
Rumunia	0,458	24	IV	Chorwacja	0,474	24	IV
Chorwacja	0,454	25	IV	Portugalia	0,473	25	IV
Grecja	0,453	26	IV	Włochy	0,467	26	IV
Słowacja	0,447	27	IV	Słowacja	0,465	27	IV
Bułgaria	0,444	28	IV	Grecja	0,444	28	IV

Źródło: obliczenia własne

Z Tabeli 2 wynika, że pozycje zajmowane przez poszczególne kraje unijne w obu rankingach w większości przypadków były odmienne, tylko pięć państw

(Belgia, Francja, Holandia, Łotwa i Słowacja) nie zmieniło swojej pozycji w badanych latach. Dla niektórych krajów (Chorwacja, Finlandia, Luksemburg, Szwecja) różnice w rankingach nie przekraczały jednej pozycji. Największą rozbieżność zauważono dla Irlandii, która w roku 2004 znalazła się na 6 miejscu, a dziesięć lat później spadła na 20 pozycję. Sytuacja na rynku pracy kobiet pogorszyła się zdecydowanie również w Hiszpanii (spadek z 11 na 21 pozycję) oraz w Portugalii (spadek z 15 na 25 pozycję). Z kolei największą poprawę odnotowano w Rumunii, która z 24 pozycji w roku 2004 awansowała w roku 2014 na 11 pozycję. Pozytywną zmianę odnotowano również w Polsce, na przestrzeni 10 lat poprawiła się ona o dziesięć pozycji (z 17 miejsca w rankingu w 2004 roku przesunęła się na miejsce siódme w roku 2014). O umiarkowanej zgodności otrzymanych rankingów świadczy wartość współczynnika τ Kendalla wynosząca 0,52⁶.

Dokładna analiza poszczególnych cech diagnostycznych w wyodrębnionych grupach typologicznych wykazała, że o przynależności krajów do określonej grupy decydowała czasami nawet jedna cecha, której poziom wyraźnie różnicował kraje pomiędzy sobą. Z uwagi na to zdecydowano się na wyznaczenie mierników ω_j , które można interpretować jako wagi określające relatywne znaczenie poszczególnych cech diagnostycznych⁷. Mierniki te obliczono według wzoru [Nowak 1990, s. 34-35]:

$$\omega_j = \frac{V_j}{\sum_{j=1}^m V_j} \cdot 100\% \quad (4)$$


gdzie: V_j – klasyczny współczynnik zmienności obliczony dla j -tej cechy diagnostycznej.

W badaniu rynku pracy kobiet, zarówno w roku 2004, jak i 2014, największe znaczenie miały: udział kobiet zatrudnionych w niepełnym wymiarze w ogólnej liczbie zatrudnionych w niepełnym wymiarze, wskaźnik zatrudnienia kobiet w wieku 15+, udział długotrwałego bezrobocia kobiet w ogólnej liczbie bezrobotnych kobiet, udział bezrobotnych kobiet z wykształceniem wyższym w ogólnej liczbie bezrobotnych kobiet. Wymienione cztery cechy diagnostyczne odznaczały się największą zmiennością w zbiorze przyjętych do badania cech, ich udział przekraczał 55% ogólnej wartości sumy współczynników zmienności i dlatego w znaczącym stopniu wpływały one na klasyfikację obiektów (krajów UE). Na Rysunku 2-3 przedstawiono średni poziom wybranych cech dotyczących rynku pracy kobiet, które znacząco różnicowały grupy.

⁶ Współczynnik tau Kendalla przyjmuje wartości z przedziału $[-1, 1]$. Im jego wartość jest bliższa 1, tym większa jest zgodność uporządkowań [Stanisz 2006, s. 313-314], [Steczkowski, Zeliaś 1997, s. 195-199].


⁷ Im wyższa wartość miernika, tym większe znaczenie j -tej cechy diagnostycznej.

Rysunek 2. Średni wskaźnik zatrudnienia kobiet w wieku 15+ w grupach typologicznych w 2014 roku (w %)



Źródło: opracowanie własne

Rysunek 3. Średni udział długotrwałego bezrobocia kobiet w bezrobociu w grupach typologicznych w 2014 roku (w %)



Źródło: opracowanie własne

W 2014 roku w najlepszej pierwszej grupie typologicznej znalazły się państwa UE charakteryzujące się najniższymi przeciętnymi wskaźnikami dotyczącymi bezrobocia długotrwałego kobiet oraz najwyższymi wskaźnikami dotyczącymi zatrudnienia. Dobra sytuacja państw z drugiej grupy, w tym Polski, wynikała z wysokich wskaźników dotyczących zatrudnienia kobiet w wieku 15+ oraz najwyższym przeciętnym udziałem kobiet na wysokich stanowiskach kierowniczych w ogólnej liczbie zatrudnionych na tych stanowiskach. Słaba sytuacja kobiet na rynku pracy krajów UE należących do grupy trzeciej wynikała z tego, że większość cech diagnostycznych odznaczała się niekorzystnymi wartościami. Negatywny wpływ na rynek pracy kobiet, w państwach zaliczonych do ostatniej grupy, miały wysokie wartości cech dotyczących bezrobocia. Jedynie udział kobiet z wykształceniem wyższym w ogólnej liczbie kobiet bezrobotnych przyjmował korzystne niskie wartości.

PODSUMOWANIE

Na podstawie przeprowadzonych badań można stwierdzić, że w Unii Europejskiej znajdują się kraje o bardzo zróżnicowanej sytuacji kobiet na rynku pracy. We wszystkich państwach członkowskich wskaźniki zatrudnienia kobiet kształtowały się na niższym poziomie niż wskaźniki zatrudnienia mężczyzn. Przeciętna stopa bezrobocia kobiet w krajach UE była nieznacznie wyższa od przeciętnej dla mężczyzn. Ta niewielka różnica (0,2 p.p.) wynikała z tego, że sytuacja kobiet i mężczyzn w zakresie bezrobocia różniła się znacznie, o czym świadczy wyznaczony miernik nierówności płci „R”. Ujemne wartości wskaźnika zaobserwowano w szesnastu krajach członkowskich, co oznacza, że kobietom w tych krajach łatwiej było znaleźć pracę niż mężczyznom. W pozostałych krajach, w tym Polsce, sytuacja w tym względzie była dla kobiet niekorzystna.

Na podstawie otrzymanych rankingów krajów unijnych oraz charakterystyki wydzielonych grup typologicznych można dokonać oceny sytuacji kobiet na rynku

pracy w Polsce na tle krajów UE. Z przeprowadzonych badań wynika, że kraj nasz w tym względzie odnotował pozytywną zmianę, o czym świadczy poprawa jego pozycji w rankingu na przestrzeni 10 lat – z 17 miejsca w rankingu w 2004 roku przesunął się na miejsce siódme w roku 2014. Wzrosły wskaźniki zatrudnienia wśród kobiet, a zmniejszyły się wskaźniki dotyczące bezrobocia, zwłaszcza długookresowego oraz wśród kobiet młodych. Ponadto zwiększyły się udziały: kobiet na wysokich stanowiskach kierowniczych w ogólnej liczbie zatrudnionych na tych stanowiskach oraz kobiet w wieku produkcyjnym z wykształceniem wyższym w ogólnej liczbie kobiet w wieku produkcyjnym. Oczywiście otrzymane wyniki porządkowania mogą budzić pewne wątpliwości, gdyż trzeba pamiętać, że były to rankingi uzyskane jedynie na podstawie przyjętych do badania cech diagnostycznych. Przy innym zestawie tego rodzaju cech pozycje państw, w tym Polski, mogłyby ulec zmianie. Ponadto należy zaznaczyć, że sytuacja kobiet na rynku pracy w bardzo różnych krajach UE wymaga wieloaspektowych analiz, ponieważ zależy od wielu czynników, m.in. od uwarunkowań kulturowych, sytuacji ekonomicznej i gospodarczej, sprawności działania infrastruktury. Dużą trudnością w przeprowadzaniu tego typu analiz jest zebranie wiarygodnych i porównywalnych danych statystycznych, gdyż bazy danych urzędów statystycznych krajów Unii nie zawsze zapewniają pełne i aktualne informacje.

BIBLIOGRAFIA

- Czubara T., Kowalewski M., Thurow R. (2012) Sytuacja kobiet na rynku pracy w województwie zachodniopomorskim, Urząd Marszałkowski Województwa Zachodniopomorskiego, Szczecin.
- Kalinowska-Nawrotek B. (2004) Formy dyskryminacji kobiet na polskim rynku pracy, *Ruch Prawniczy, Ekonomiczny i Socjologiczny*, rok LVI, zeszyt 2, Wydział prawa i Administracji UAM w Poznaniu, Poznań.
- Kukuła K. (2000) *Metoda unitaryzacji zerowanej*, PWN, Warszawa.
- Malina A. (2004) *Wielowymiarowa analiza przestrzennego zróżnicowania struktury gospodarki Polski według województw*, Wydaw. AE w Krakowie, Kraków.
- Młodak A. (2006) *Analiza taksonomiczna w statystyce regionalnej*, Difin, Warszawa.
- Panek T. (2009) *Statystyczne metody wielowymiarowej analizy porównawczej*, SGH w Warszawie – Oficyna Wydawnicza, Warszawa.
- Nowak E. (1990) *Metody taksonomiczne w klasyfikacji obiektów społeczno-gospodarczych*, Państwowe Wydawnictwo Ekonomiczne, Warszawa.
- Polska w Unii Europejskiej 2004-2014 (2014) GUS, Warszawa.
- Polska 2015. Raport o stanie gospodarki (2015) Ministerstwo Gospodarki, Warszawa.
- Stanisz A. (2006) *Przystępny kurs statystyki z zastosowaniem STATISTICA PL na przykładach z medycyny, t. 1. Statystyki podstawowe*, Wydawnictwo StatSoft Polska, Kraków.
- Steczkowski J., Zeliaś A. (1997) *Metody statystyczne w badaniu zjawisk jakościowych*, Wydawnictwo Uczelniane Akademii Ekonomicznej w Krakowie, Kraków.

**THE SITUATION OF WOMEN ON THE LABOR MARKET IN POLAND
COMPARED TO THE EUROPEAN UNION COUNTRIES
– STATISTICAL ANALYSIS**

Abstract: The aim of this article is to assess the situation of women on the labor market in Poland compared to the European Union countries. In the first step were analysed selected characteristics of the labor market of women. Two ranking were prepared using method of zero unitarization. The first is focused on the year 2004 and the moment of entry of Poland into the EU, while the second one is showing the classification of the EU countries a decade later. In the next step, using the synthetic measure, were identified typological groups of countries with a similar situation of women on the labor market. The study showed significant improvement in our country in 2014, in terms of the situation of women in the labor market. Employment rates increased, indicators of unemployment were reduced, particularly long-term and among young women.

Keywords: the labor market of women, the method of zero unitarization, the European Union

OCENA TRUDNOŚCI FINANSOWYCH W ZAKRESIE NABYWANIA ŻYWNOSCI – ZASTOSOWANIE MODELU PROBITOWEGO ZE ZMIENNYMI EFEKTAMI

Hanna Dudek

Katedra Ekonometrii i Statystyki

Szkoła Główna Gospodarstwa Wiejskiego w Warszawie

e-mail: hanna_dudek@sggw.pl

Streszczenie: W pracy podjęto temat postrzegania przez gospodarstwa domowe występowania trudności finansowych w zakresie zakupu wystarczającej ilości żywności. W celu identyfikacji determinant tego zjawiska wykorzystano modele probitowe z efektami losowymi. W analizie statystycznej wykorzystano dane z badania „Diagnoza społeczna – warunki i jakość życia Polaków” z lat 2000-2015. Stwierdzono, że oprócz dochodów ekwiwalentnych i miejsca zamieszkania ważną rolę odgrywa typ biologiczny gospodarstwa domowego.

Słowa kluczowe: trudności finansowe, żywność, gospodarstwa domowe, model probitowy z efektami losowymi

WPROWADZENIE

Koncepcja ubóstwa ulega zmianom w czasie – od wąsko rozumianego skrajnego ubóstwa materialnego do podejścia uwzględniającego wiele aspektów deprivacji. Zmiany te znajdują odzwierciedlenie w metodyce opracowania wskaźników ubóstwa [Szukiełojć-Bieńkuńska 2008]. Niezależnie od różnych podejść w pojmowaniu ubóstwa wszystkie jego definicje, formułowane w pracach naukowych oraz dokumentach statystyki publicznej, odnoszą się do niezaspokojenia potrzeb na pożądanym poziomie. W szczególności, uznany ekspert w tej dziedzinie – prof. T. Panek – proponuje przyjęcie definicji, wg której przez ubóstwo rozumie się sytuację, w której jednostka (osoba, rodzina, gospodarstwo domowe) nie dysponuje wystarczającymi środkami finansowymi pozwalającymi na zaspokojenie podstawowych potrzeb [Panek 2014]. Ponieważ potrzeba zapewnienia sobie wyżywienia stanowi jedną z podstawowych potrzeb, to należy

badać stan jej zaspokojenia. W opracowaniu tym podjęto się analizy opinii gospodarstw domowych na temat ich możliwości finansowych zakupu wystarczającej ilości żywności. W analizie statystycznej wykorzystano dane z badania „Diagnoza społeczna – warunki i jakość życia Polaków”.

Cel pracy stanowi identyfikacja cech gospodarstw domowych sygnalizujących trudności finansowe w zakresie nabywania wystarczającej ilości żywności. Do realizacji tego celu wykorzystano modele probitowe dla danych panelowych. W literaturze przedmiotu brakuje tego typu analiz mikroekonometrycznych, dlatego też niniejsza praca stara się wypełnić lukę w tym względzie.

BADANIE „DIAGNOZA SPOŁECZNA” JAKO ŹRÓDŁO DANYCH O TRUDNOŚCIACH FINANSOWYCH W ZASPOKOJENIU POTRZEB NA ARTYKUŁY ŻYWNOŚCIOWE

Analizę wykonano na podstawie informacji z badań „Diagnoza społeczna – warunki i jakość życia Polaków” przeprowadzonych w latach 2000-2015. Wykorzystano dane z kwestionariuszy dla gospodarstw domowych. W ramach badań „Diagnozy społecznej” w 2000 r. przebadano 3005 gospodarstw domowych, w 2003 r. – 3961, w 2005 r. – 3851, w 2007 r. – 5532, w 2009 r. – 12380, w 2011 r. – 12381, w 2013 r. – 12352 oraz w 2015 r. – 11740 gospodarstw domowych. Szczegółowe informacje na temat schematu doboru próby, procedury i przebiegu badania można znaleźć w raporcie [Czapiński, Panek 2000-2015].

W kwestionariuszu badania uwzględniono pytanie: *Czy Pana(i) gospodarstwo domowe stać na zakupy wystarczających ilości następujących artykułów żywnościowych? Należy udzielić odpowiedzi niezależnie dla każdego z poniższych artykułów:*

- 1) *warzywa i przetwory warzywne,*
- 2) *owoce i przetwory owocowe,*
- 3) *mięso (w tym drób),*
- 4) *przetwory mięsne i drobiowe,*
- 5) *ryby i przetwory rybne,*
- 6) *masło i inne tłuszcze jadalne,*
- 7) *mleko,*
- 8) *przetwory mleczne,*
- 9) *cukier,*
- 10) *wyroby cukiernicze (słodycze, czekolada itd.).*

Respondenci mieli do wyboru dwie odpowiedzi: tak lub nie [Rada Monitoringu Społecznego 2015]. W niniejszej pracy analizie poddano dane na temat trudności finansowych w zakresie nabywania wystarczającej ilości co najmniej jednego z dziesięciu wyszczególnionych artykułów żywnościowych. W modelowaniu

ekonometrycznym dane takie odpowiadają zmiennej binarnej przyjmującej wartość 1 w sytuacji, gdy takie trudności wystąpiły oraz wartość 0 w sytuacji, gdy gospodarstwo domowe nie sygnalizowało trudności finansowych w nabywaniu któregośkolwiek z artykułów żywnościowych [Dudek i in. 2011]. W celu objaśnienia prawdopodobieństwa wystąpienia analizowanych trudności rozpatrzono różne cechy gospodarstw domowych. Uwzględniono wiele czynników, które w literaturze przedmiotu uznaje się za determinanty ubóstwa ekonomicznego i nierównomierności dochodowych [Phipps 1991, Panek 2006, Rusnak 2012, Sączewska-Piotrowska 2015].

Z uwagi na fakt, że w 2007 r. ponad połowa gospodarstw domowych nie udzieliła odpowiedzi na rozpatrywane pytanie, informacje dotyczące tego roku pominięto w przeprowadzonej w pracy analizie ekonometrycznej. Łącznie dysponowano zatem danymi w postaci niezbilansowanego panelu z 7 lat.

ZASTOSOWANE METODY

W pracy zastosowano model probitowy z efektami losowymi (ang. random effects probit model), który może być zapisany w następujący sposób [Greene 2012]:

$$y_{it}^* = \mathbf{x}_{it}\boldsymbol{\beta} + u_i + \varepsilon_{it}, \quad i=1, \dots, n, \quad t=1, \dots, T_i, \quad (1)$$

$$y_{it} = \begin{cases} 1 & \text{gdy } y_{it}^* \geq 0 \\ 0 & \text{gdy } y_{it}^* < 0 \end{cases}$$

gdzie: \mathbf{x}_{it} oznacza wektor wierszowy zmiennych objaśniających odnoszących się do obserwowanych charakterystyk gospodarstw domowych,

n – liczba gospodarstw domowych,

T_i – liczba analizowanych lat dla i -tego gospodarstwa domowego, $i=1, \dots, n$,

$\boldsymbol{\beta}$ – wektor kolumnowy parametrów strukturalnych modelu,

u_i – tzw. efekt indywidualny opisujący nieobserwowalne charakterystyki i -tego gospodarstwa domowego,

ε_{it} – błąd losowy o standardowym rozkładzie normalnym.

O składnikach u_i oraz ε_{it} zakłada się, że są zmiennymi losowymi spełniającymi warunki:

- $u_i \sim N(0, \sigma_u)$; $\text{cov}(u_i, u_j) = \sigma_u^2$, jeśli $i=j$ oraz 0 w przeciwnym przypadku,
- $\varepsilon_{it} \sim N(0, 1)$; $\text{cov}(\varepsilon_{it}, \varepsilon_{js}) = 1$ jeśli $i=j, t=s$ oraz 0 w przeciwnym przypadku,
- $\text{cov}(u_i, \varepsilon_{it}) = 0$,
- u_i oraz ε_{it} są nieskorelowane z obserwowanymi zmiennymi objaśniającymi.

W konsekwencji przyjętych założeń zmienna losowa w_{it} , będąca sumą obu składników, $w_{it} = u_i + \varepsilon_{it}$, ma rozkład normalny, przy czym: $E(w_{it}) = 0$ oraz $\text{Var}(w_{it}) = 1 + \sigma_u^2$. Prawdopodobieństwo wystąpienia trudności w zakresie zakupu wystarczającej ilości żywności dla i -tego gospodarstwa domowego w roku t

o wartościach cech określonych przez wektor \mathbf{x}_{it} można zatem wyznaczyć ze wzoru [Greene 2012]:

$$P(y_{it} = 1 | \mathbf{x}_{it}) = P(u_i + \varepsilon_{it} > -\mathbf{x}_{it}\boldsymbol{\beta}) = \Phi\left(\frac{\mathbf{x}_{it}\boldsymbol{\beta}}{\sqrt{1 + \sigma_u^2}}\right), \quad (2)$$

gdzie Φ oznacza dystrybuantę standardowego rozkładu normalnego. Współczynnik autokorelacji dla składnika w_{it} wyraża się wzorem:

$$\rho = \text{corr}(w_{it}, w_{is}) = \frac{\sigma_u^2}{1 + \sigma_u^2} \quad (3)$$

Testowanie występowania efektów indywidualnych u_i w modelu (1) polega na weryfikacji hipotezy zerowej $\rho=0$, wobec hipotezy alternatywnej $\rho \neq 0$. W tym celu może być wykorzystany test ilorazu wiarygodności LR¹ (ang. Likelihood Ratio) [Greene 2015]. Brak podstaw do odrzucenia hipotezy zerowej oznacza zredukowanie modelu probitowego z efektami losowymi do zwykłego modelu probitowego nie uwzględniającego panelowej struktury danych empirycznych. Należy w tym miejscu wspomnieć, że standardowo w ekonometrii do wyjaśniania binarnej zmiennej objaśnianej oprócz modeli probitowych wykorzystuje się modele logitowe. Zastosowanie modeli logitowych z efektami losowymi napotyka jednak na pewne ograniczenia – założenie o rozkładzie logistycznym składnika ε_{it} nie implikuje bowiem tego typu rozkładu dla zmiennej losowej $w_{it} = u_i + \varepsilon_{it}$. Ponadto, w analizie danych panelowych oprócz modeli z losowymi efektami można rozpatrywać modele ze stałymi efektami, gdzie dopuszcza się skorelowanie nieobserwowalnych efektów indywidualnych z obserwowanymi zmiennymi objaśniającymi. Jednakże te modele rzadko znajdują zastosowanie w analizie mikrodanych, gdyż nie umożliwiają oszacowania wpływu stałych w czasie obserwowalnych zmiennych objaśniających (np. płci lub rasy) [Verbeek 2008]. Na domiar tego, w procesie estymacji modeli ze stałymi efektami pomijane są te obserwacje, dla których zmienna objaśniana nie zmienia się w czasie². Z wymienionych powodów modele probitowe ze zmiennymi efektami są najczęściej wykorzystywanymi modelami w mikroekonometrycznej analizie danych panelowych.

¹ W teście LR porównywane są logarytmy wiarygodności dla modelu probitowego z efektami losowymi oraz zwykłego modelu probitowego, tzn. takiego, w którym nie występują efekty indywidualne reprezentowane przez składnik u_i . Podwojona różnica tych logarytmów wiarygodności ma asymptotyczny rozkład χ^2 z 1 stopniem swobody.

² W szczególności, w przeprowadzonej w pracy analizie, w procesie estymacji zostałyby pominięta znaczna część próby odnosząca się do gospodarstw domowych, które nie wykazywały w całym analizowanym okresie żadnych trudności w zakresie nabywania wystarczającej ilości żywności.

WYNIKI

Na podstawie wstępnej analizy danych stwierdzono, że w latach 2000-2015 znacząco zmniejszył się odsetek gospodarstw domowych, których nie było stać ze względów finansowych na zakup wystarczającej ilości żywności. W 2000 r. gospodarstwa, które wskazały, że nie mogły pozwolić sobie na nabycie artykułów z co najmniej jednej z dziesięciu wyszczególnionych grup, stanowiły 54% ogółu badanych, w 2015 r. zaś – jedynie 18%.

Gospodarstwa domowe oceniały, że najczęściej nie było ich stać na zaspokojenie potrzeb żywnościowych w zakresie ryb i przetworów rybnych (15% gospodarstw w 2015 r. oraz 37% w 2000 r.) i wyrobów cukierniczych (11% gospodarstw w 2015 r. oraz 46% w 2000 r.), najrzadziej zaś – w zakresie mleka (3% gospodarstw w 2015 r. oraz 5% w 2000 r.).

W celu identyfikacji gospodarstw domowych, które wykazywały trudności finansowe w zakupie wybranych artykułów żywnościowych, w modelowaniu ekonometrycznym uwzględniono informacje dotyczące ich miejsca zamieszkania, typu biologicznego gospodarstw domowych oraz miesięcznych dochodów³. Ze względu na zmiany w zakresie różnej klasyfikacji dotyczącej przynależności do grupy społeczno-ekonomicznej, cecha ta nie została rozpatrzona w modelowaniu ekonometrycznym. Poza dochodami, pozostałe cechy uwzględnione w charakterze zmiennych objaśniających mają charakter jakościowy. Do ich kwantyfikacji zastosowano zmienne zero-jedynkowe przyjmujące wartość 1, jeśli dany wariant cechy występuje oraz wartość 0, jeśli dany wariant cechy nie występuje. W celu uniknięcia współliniowości w modelu pominięto po jednej zmiennej zero-jedynkowej dla każdej ze zmiennych jakościowych. Wyniki estymacji parametrów modelu probitowego ze zmiennymi efektami przedstawiono w Tabeli 1.

Tabela 1. Wyniki oszacowań modelu probitowego ze zmiennymi efektami

Zmienna	Oszacowanie parametru	Błąd standardowy
Typ biologiczny gospodarstwa domowego:		
małżeństwa z 1 dzieckiem	-0,13	0,03***
małżeństwa z 2 dzieci	-0,26	0,03***
małżeństwa z 3 i więcej dzieci	-0,16	0,04***
rodziny niepełne	0,24	0,03***
gospodarstwa wielorodzinne	-0,13	0,04***
gospodarstwa jednoosobowe	0,41	0,03***
gospodarstwa nierodzinne wieloosobowe	0,04	0,07
małżeństwa bez dzieci	Ref.	Ref.

³ Dochody ekwiwalentne oznaczają dochody gospodarstwa domowego w przeliczeniu na 1 jednostkę ekwiwalentną. Takie przeliczenie uwzględnia różnice w kosztach utrzymania wynikające ze różnego składu demograficznego gospodarstw domowych. W badaniu „Diagnoza Społeczna” dochody ekwiwalentne obliczono przy użyciu metody Szulca [2003]. W celu uzyskania porównywalności danych z lat 2000-2015 dochody urealniono do poziomu z 2015 r.

Zmienna	Oszacowanie parametru	Błąd standardowy
Województwo:		
dolnośląskie	-0,04	0,05
kujawsko-pomorskie	-0,07	0,06
lubelskie	0,06	0,05
lubuskie	0,11	0,06*
łódzkie	0,08	0,05
małopolskie	0,06	0,05
mazowieckie	Ref.	Ref.
opolskie	-0,04	0,05***
podkarpackie	0,14	0,06***
podlaskie	-0,20	0,06***
pomorskie	0,08	0,06
śląskie	-0,17	0,05***
świętokrzyskie	0,10	0,06*
warmińsko-mazurskie	0,21	0,06***
wielkopolskie	-0,23	0,05***
zachodnio-pomorskie	0,03	0,06
Klasa miejscowości		
miasto z co najmniej 500 tys. mieszkańców	0,03	0,04
miasto z 200-500 tys. mieszkańców	-0,07	0,04*
miasto z 100-200 tys. mieszkańców	-0,21	0,05***
miasto z 20-100 tys. mieszkańców	-0,02	0,03
miasto z co najwyżej 20 tys. mieszkańców	-0,01	0,03
wieś	Ref.	Ref.
Logarytm naturalny dochodów ekwiwalentnych	-1,40	0,02***
Rok:		
2000	Ref.	Ref.
2003	-0,48	0,02***
2005	-0,56	0,04***
2009	-0,74	0,04***
2011	-0,85	0,04***
2013	-0,87	0,04***
2015	-1,01	0,04***
Stała	0,21	0,06***
σ_u	0,96	0,02***
ρ	0,48	0,01***

Źródło: obliczenia własne wykonane w programie Stata,

* oznacza istotność na poziomie 0,1, ** – na poziomie 0,05, *** – na poziomie 0,01

Rezultaty dotyczące oszacowań odchylenia standardowego efektów indywidualnych σ_u oraz współczynnika autokorelacji ρ wskazują na istotność wystąpienia składnika u_i w modelu (1). Potwierdza to także wynik testu logarytmu wiarygodności: wartość statystyki testowej wynosi LR=3082, co oznacza odrzucenie hipotezy zerowej $\rho=0$. Zastosowanie modelu probitowego z efektami losowymi okazało się być zatem bardziej zasadne niż zwykłego modelu probitowego nie uwzględniającego panelowej struktury danych.

Można zaobserwować, że w Tabeli 1 niektóre z parametrów przy zmiennych zero-jedynkowych reprezentujących różne warianty zmiennych jakościowych nie są istotnie różne od zera. Dlatego też, dodatkowo przeprowadzono testy ilorazu wiarygodności LR weryfikujące wpływ typu biologicznego gospodarstw domowych, zamieszkiwanego województwa oraz klasy miejscowości na subiektywną ocenę możliwości finansowych zakupu wystarczającej ilości żywności. Rezultaty tych testów wskazują na istotność każdej z rozpatrywanych jakościowych zmiennych objaśniających (por. Tabela 2).


Tabela 2. Wyniki testów LR dla wybranych jakościowych zmiennych objaśniających

Jakościowa zmienna objaśniająca	Wartość statystyki LR	Liczba stopni swobody
Typ biologiczny gospodarstwa domowego	519,17***	7
Województwo	137,18***	15
Klasa miejscowości	25,5 ***	5

Źródło: obliczenia własne wykonane w programie Stata. Oznaczenia – jak w Tabeli 1

Dokonując interpretacji wyników przedstawionych w Tabeli 1, przy założeniu *ceteris paribus*, można stwierdzić, że w odniesieniu do gospodarstw domowych małżeństw bez dzieci gospodarstwa małżeństw z dziećmi oraz gospodarstwa wielorodzinne rzadziej sygnalizowały trudności finansowe w zakresie zakupu wystarczającej ilości żywności, natomiast gospodarstwa jednoosobowe oraz gospodarstwa rodzin niepełnych – częściej. Nie odnotowano statystycznie istotnej różnicy w tym względzie między gospodarstwami domowymi małżeństw bez dzieci a wieloosobowymi gospodarstwami nierodzinnymi. W porównaniu do gospodarstw domowych z województwa mazowieckiego, prawdopodobieństwo negatywnego postrzegania sytuacji finansowej dotyczącej zakupu wystarczającej ilości żywności było istotnie mniejsze w gospodarstwach województw opolskiego, podlaskiego, śląskiego i wielkopolskiego, natomiast istotnie większe prawdopodobieństwo tego zdarzenia dotyczyło gospodarstw z województw podkarpackiego i warmińsko-mazurskiego. W odniesieniu do pozostałych województw nie stwierdzono statystycznie istotnych różnic w tym zakresie. Zaobserwowano, że przy założeniu *ceteris paribus*, z roku na rok zmniejszało się prawdopodobieństwo negatywnej oceny możliwości zakupu wystarczającej ilości żywności. Zgodnie z oczekiwaniami, wzrost dochodów ekwiwalentnych powodował zmniejszenie prawdopodobieństwa subiektywnej percepcji trudności finansowych nabywania żywności. Ilustrację graficzną tych zależności w wybranych grupach gospodarstw domowych przedstawiono na Rysunku 1. Na rysunku tym zaprezentowano dane dotyczące dwóch typów biologicznych gospodarstw domowych zamieszkujących Warszawę.

Rysunek 1. Prawdopodobieństwo wystąpienia subiektywnych trudności finansowych w zakresie zakupu żywności wśród wybranych typów gospodarstw domowych



Źródło: obliczenia własne

Na Rysunku 1 uwzględniono dwa wybrane typy biologiczne gospodarstw domowych: gospodarstwa rodzin niepełnych oraz gospodarstwa małżeństw z dwojgiem dzieci. Można zaobserwować, że np. w sytuacji posiadania dochodów ekwiwalentnych równych 2000 zł⁴, prawdopodobieństwo oszacowane na podstawie wyników estymacji modelu probitowego ze zmiennymi efektami wyniosło:

- dla gospodarstw domowych rodzin niepełnych – 0,34 w 2000 r. i 0,13 w 2015 r.,
- dla gospodarstw domowych małżeństwem z dwojgiem dzieci – 0,22 w 2000 r. i 0,07 w 2015 r.

Przykład ten ilustruje różną percepcję trudności finansowych w zakresie nabywania wystarczających ilości żywności w odmiennych typach biologicznych gospodarstw domowych oraz jej zmianę w 2015 r. w stosunku do 2000 r. Dodatkowo w Tabeli 3 przedstawiono oszacowania prawdopodobieństw wystąpienia trudności finansowych w zakupie żywności w różnych grupach gospodarstw domowych dla dochodów ekwiwalentnych ustalonych na poziomie mediany (1248 zł). Obliczenia zostały wykonane na podstawie wzoru (2), uwzględniając „średni rok” – 2009⁵.

⁴ Dochody urealniono z uwzględnieniem inflacji, tym samym dochody wynoszące 2000 zł w cenach z 2015 r. odpowiadają dochodom równym 1410 zł w cenach z 2000 r.

⁵ Kwocie 1248 zł w 2015 r. odpowiada 1125 zł w 2009 r. W obliczeniach zamieszczonych w Tabeli 3 wykorzystano podejście zaprezentowane w pracy [Gibbons i in. 1994].

Tabela 3. Wyniki oszacowań prawdopodobieństw dla wybranych grup gospodarstw domowych o różnym typie biologicznym w 2009 r.

Typ biologiczny gospodarstwa domowego	Woj. wielkopolskie		Woj. warmińsko-mazurskie	
	Miasto 100-200 tys.	Wieś	Miasto 100-200 tys.	Wieś
Małżeństwa bez dzieci	0,17	0,21	0,26	0,31
Małżeństwa z 1 dzieckiem	0,14	0,18	0,23	0,28
Małżeństwa z 2 dziećmi	0,12	0,16	0,20	0,25
Małżeństwa z 3 i więcej dziećmi	0,14	0,18	0,22	0,27
Rodziny niepełne	0,21	0,26	0,31	0,37
Gospodarstwa wielorodzinne	0,14	0,18	0,23	0,28
Gospodarstwa jednoosobowe	0,25	0,30	0,36	0,42
Gospodarstwa nierodzinne wieloosobowe	0,17	0,22	0,27	0,32

Źródło: obliczenia własne

Wyniki zaprezentowane w Tabeli 3 dotyczą „najlepszego” i „najgorszego” województwa ustalonego na podstawie rezultatów estymacji z Tabeli 1. W kwestii wielkości miejscowości zamieszkania, nie można jednoznacznie orzec, że im większa miejscowość, tym mniejsze prawdopodobieństwo wystąpienia trudności finansowych⁶. Na podstawie rezultatów przedstawionych w Tabeli 1 można natomiast stwierdzić, że najbardziej różnią się w tym względzie gospodarstwa domowe z miast o wielkości 100-200 tys. mieszkańców oraz gospodarstwa domowe ze wsi. Dlatego też rozpatrzono te dwie grupy gospodarstw. Z informacji zawartych w Tabeli 3 wynika, że najmniejsze prawdopodobieństwo odnosi się do gospodarstw domowych z dwojgiem dzieci, największe zaś – do gospodarstw jednoosobowych i w następnej kolejności – do gospodarstw rodzin niepełnych.

Uzyskane w tej pracy wyniki porównano z rezultatami prezentowanymi w raportach „Diagnozy Społecznej” sporządzonych dla poszczególnych lat, w których przeprowadzono badanie [Czapiński, Panek 2000-2015]. W raportach tych stwierdzono, że wśród typów biologicznych gospodarstw najczęściej wskazywały na brak środków finansowych na zakup wybranych grup artykułów żywnościowych gospodarstwa domowe rodzin niepełnych oraz gospodarstwa jednoosobowych, co znalazło potwierdzenie w prezentowanych w tej pracy wynikach analizy ekonometrycznej. Biorąc pod uwagę województwo zamieszkania, podobnie jak w tej pracy, w większości raportów „Diagnozy Społecznej” z okresu 2000-2015, wymieniono głównie gospodarstwa z woj. warmińsko-mazurskiego, podkarpackiego oraz także w niektórych latach – z woj. lubelskiego, łódzkiego, świętokrzyskiego i lubelskiego. W kwestii wielkości miejscowości zamieszkania nie odnotowano pełnej zgodności. Autorzy raportów „Diagnozy Społecznej” informują, że gospodarstwa domowe najczęściej zmuszane

⁶ Wnioski takie są formułowane zwykle w odniesieniu do prawdopodobieństwa wystąpienia ubóstwa monetarnego [Rusnak 2012].

do rezygnacji ze względów finansowych z zakupu wybranych grup artykułów żywnościowych zamieszkiwały przede wszystkim wsie oraz małe miasta o liczbie 20-100 tys., natomiast wyniki analizy ekonometrycznej wskazują, że w odniesieniu do analizowanego zjawiska, przy założeniu *ceteris paribus*, sytuacja mieszkańców wsi nie była gorsza niż mieszkańców miast z co najmniej 500 tys. mieszkańców⁷.

PODSUMOWANIE

Potrzeba zapewnienia wyżywienia należy do podstawowych potrzeb związanych z zabezpieczeniem egzystencji, dlatego też konieczne jest badanie stanu jej zaspokojenia oraz jego determinant. W pracy podjęto się analizy zjawiska występowania kłopotów finansowych z zaspokojeniem potrzeb w zakresie zakupu artykułów żywnościowych. W tym celu wykorzystano dane z badania „Diagnoza Społeczna” przeprowadzonego wielokrotnie w latach 2000-2015. Dzięki temu badaniu uzyskano informacje na temat opinii gospodarstw domowych dotyczących ich możliwości finansowych zakupu wystarczającej ilości żywności. W analizie ekonometrycznej zastosowano model zmiennych dwumianowych dla danych panelowych. Metody analizy danych panelowych pozwalają na uwzględnienie nieobserwowalnych efektów indywidualnych gospodarstw domowych. W celu identyfikacji determinant wystąpienia trudności finansowych w zakresie zakupu wystarczającej ilości żywności zastosowano modele probitowe ze zmiennymi efektami. Wyniki estymacji modelu wskazały, że oprócz dochodów ekwiwalentnych ważną rolę odgrywa typ biologiczny gospodarstw domowych oraz ich miejsce zamieszkania.

BIBLIOGRAFIA

- Czapiński J., Panek T. (red.) (2000-2015) Diagnoza społeczna 2000-2015. www.diagnoza.com, dostęp w dniu 1.03.2015.
- Dudek H., Krawiec M., Landmesser J. (2011) Podstawy analizy statystycznej w badaniach rynku, Wydawnictwo SGGW.
- Gibbons R. D, Hedeker D., Charles S. C., Frisch P. (1994) Random-effects probit model for predicting medical malpractice claims, *Journal of the American Statistical Association*, Vol. 89, s. 760–767.
- Greene W.H. (2012) *Econometric analysis*, Pearson Education, Harlow.
- Greene W.H. (2015) *Panel data models for discrete choice*, [w:] *The Oxford handbook for panel data* red. B. Baltagi, Oxford University Press, Oxford.

⁷ Okazało się, że kluczową rolę w tym względzie odgrywały dochody ekwiwalentne gospodarstw domowych – pominięcie ich w modelu prowadziło do takich wniosków jakie wysnuli autorzy raportu.

- Panek T. (2014) Ubóstwo i wykluczenie społeczne, [w:] Statystyka Społeczna red. T. Panek, PWE, Warszawa.
- Panek T. (2006) Multidimensional fuzzy relative poverty dynamic measures in Poland, w: Fuzzy set approach to multidimensional poverty measurement, red. A. Lemmi, G. Betti, Springer Science Business+Media, LLC, New York, s. 233-256.
- Phipps S. (1991) Regional differences in the incidence of poverty in Canada, Canadian Journal of Regional Science, Vol. 14 (1), s. 47-71.
- Rada Monitoringu Społecznego (2015) Diagnoza społeczna 2000–2015: zintegrowana baza danych, <http://www.diagnoza.com>, dostęp w dniu 1.03.2015.
- Rusnak Z. (2012) Logistic regression model in poverty analyses, Econometrics, Vol. 35 (1), s. 9-23.
- Sączewska-Piotrowska A. (2015) Nierówności dochodowe a typ gospodarstwa domowego w świetle badań panelowych, Studia Ekonomiczne, Nr 232, s. 204-214.
- Szukielójć-Bieńkuńska A. (2008) Pomiar ubóstwa i wykluczenia społecznego w urzędowej statystyce polskiej, [w:] Pomiar ubóstwa, zmiany koncepcji i ich znaczenie red. I. Topińska, Opracowania PBZ, Instytut Pracy i Spraw Socjalnych, Warszawa.
- Szulc A. (2003) It is possible to estimate reliable equivalence scales, Statistics in Transition, Vol. 6, s. 589-611.
- Verbeek M. (2008) A guide to modern econometrics, Wiley & Sons, Ltd, Chichester.

ASSESSMENT OF FINANCIAL DIFFICULTIES IN FOOD PURCHASE – APPLICATION OF RANDOM EFFECTS PROBIT MODEL

Abstract: In the article the problem of the financial difficulties of households to purchase enough food was undertaken. In order to identify the determinants of this phenomenon random effects probit model was employed. Data came from the research “Social Diagnosis – the conditions and quality of life Poles” conducted in the years 2000-2015. It was found that apart from of equivalent incomes and places of residence important impact had biological types of households.

Keywords: financial difficulties, food, households, random effects probit model

METODA PRZEPIYWÓW NA RYNKU PRACY (IOA) I WIELOMIANOWA ANALIZA LOGITOWA W BADANIACH AKTYWNOŚCI EKONOMICZNEJ LUDNOŚCI

Włodzimierz Kołodziejczak, Feliks Wysocki

Katedra Finansów i Rachunkowości

Uniwersytet Przyrodniczy w Poznaniu

e-mail: wkol@up.poznan.pl, wysocki@up.poznan.pl

Streszczenie: Metoda przepływów na rynku pracy w połączeniu z szacowaniem poziomu bezrobocia równowagi oraz wielomianowa analiza logitowa mogą posłużyć do rozwinięcia i uzupełnienia wnioskowania prowadzonego na podstawie klasycznych charakterystyk aktywności ekonomicznej ludności. Ich zastosowanie pozwala na dekompozycję zasobów pracy ze względu na wybrane cechy demograficzne i społeczno-ekonomiczne w odniesieniu do możliwości zmiany stanu aktywności ekonomicznej ludności oraz na określenie udziału składnika strukturalnego i cyklicznego w bezrobociu. Celem artykułu jest prezentacja możliwości wykorzystania metody przepływów na rynku pracy (IOA) i wielomianowej analizy logitowej do badania aktywności ekonomicznej ludności.

Słowa kluczowe: metoda przepływów na rynku pracy, wielomianowa analiza logitowa, aktywność ekonomiczna ludności, bezrobocie równowagi, bezrobocie strukturalne, rynek pracy, przepływy na rynku pracy

WPROWADZENIE

Badania aktywności ekonomicznej ludności mogą być prowadzone w ujęciu statycznym lub z zastosowaniem metod ilościowych opartych na obserwacji dynamicznych przepływów między zatrudnieniem, bezrobociem i biernością zawodową. Możliwe jest także ujęcie zagadnień aktywności ekonomicznej ludności w szerszym kontekście, np. całej gospodarki (np. w ramach modelu optymalnego tempa transformacji, zob. Tyrowicz 2011). Każde z podejść badawczych i każda z metod możliwych do zastosowania dostarcza pewnych możliwości, ale jednocześnie jest obciążona ograniczeniami, dotyczącymi dostępności i wartości

informacyjnej danych oraz wnioskowania na podstawie wyników obliczeń. Różne podejścia i metody stosowane jednocześnie wzajemnie się uzupełniają, a ich równoległe stosowanie pozwala na bardziej precyzyjne i trafne wnioskowanie oraz na (przynajmniej częściową) weryfikację uzyskiwanych wyników.

Celem artykułu jest prezentacja możliwości wykorzystania dwóch spośród metod opartych na analizie przepływów ludności między stanami aktywności ekonomicznej: metody przepływów na rynku pracy (Inflow-Outflow Analysis - IOA) i wielomianowej analizy logitowej¹.

METODA PRZEPLÝWÓW NA RYNKU PRACY (IOA) I WIELOMIANOWA ANALIZA LOGITOWA – ZAGADNIENIA METODYCZNE

Metoda przepływów na rynku pracy Inflow-Outflow Analysis (IOA) i wielomianowa analiza logitowa skupiają się na analizie przepływów między stanami aktywności ekonomicznej ludności: zatrudnieniem, bezrobociem i biernością zawodową. Do ich zastosowania konieczne są dane jednostkowe, które umożliwiają śledzenie zmian stanów poszczególnych badanych osób w czasie.

Metoda przepływów na rynku pracy Inflow-Outflow Analysis (IOA) opiera się na założeniu, że zbadanie zmian pozycji jednostek na rynku pracy w przeszłości pozwala przewidywać różnicowanie się ich pozycji na tym rynku w przyszłości, czyli możliwości pozostania w określonym stanie lub jego zmiany (Unemployment 1995). W konsekwencji, poznanie struktury przepływów pomiędzy poszczególnymi stanami aktywności ekonomicznej umożliwia wnioskowanie o możliwościach podjęcia (utrzymania) zatrudnienia, zagrożeniu bezrobociem lub skłonności do dezaktywizacji zawodowej w grupach ludności wyodrębnionych ze względu na wybrane cechy [Socha i Sztanderska 2002]. Ponieważ napływy (I_u) i odpływy (O_u) z bezrobocia w stanie ustabilizowanym są równe, stopę bezrobocia można wyrazić w formie iloczynu stopy napływów do bezrobocia w sile roboczej i długości pozostawania w bezrobociu [Unemployment 1995, Socha i Sztanderska 2002]. Dzięki temu, możliwe jest zdefiniowanie oraz obliczenie:

– stopy napływów do bezrobocia w sile roboczej jako:

$$i_u = \frac{I_u}{U + E}$$

gdzie:

¹ Ze względu na ograniczenia wydawnicze, dotyczące dopuszczalnej objętości artykułu, autorzy skoncentrowali uwagę na kwestiach metodycznych i porównaniu możliwości wnioskowania. Przykłady wykorzystania dla danych empirycznych można znaleźć w monografii „Determinanty aktywności ekonomicznej ludności wiejskiej w Polsce” [Kołodziejczak i Wysocki, 2015].

- i_u – stopa napływów do bezrobocia w sile roboczej,
 I_u – napływy do bezrobocia,
 U – liczba bezrobotnych,
 E – liczba pracujących;
 – stopy odpływów z bezrobocia jako:

$$o_u = \frac{O_u}{U}$$

gdzie:

- o_u – stopa odpływów z bezrobocia,
 O_u – odpływy z bezrobocia,
 U – liczba bezrobotnych;
 – przeciętnej długości trwania bezrobocia:

$$D_u^U = \frac{1}{o_u}$$

gdzie:

- D_u^U – przeciętne trwanie bezrobocia w badanej populacji,
 o_u – stopa odpływów z bezrobocia.

Analiza wartości tych wskaźników oraz ich zmian w czasie pozwala między innymi na określenie płynności siły roboczej. Im wyższe są wartości stóp przepływów, tym większa płynność (mobilność) ludności aktywnej ekonomicznie. Niskie stopy przepływów wskazują na istotne znaczenie czynników o charakterze strukturalnym dla kształtowania się sytuacji na rynku pracy. Zwiększanie się wartości stóp przepływów, zwykle wskazuje na zmniejszanie znaczenia czynników strukturalnych (jednak nie świadczy o tym wprost, bowiem czynniki strukturalne mogą także powodować w niektórych przypadkach zwiększenie wartości stóp przepływów). Podobnie, wzrastająca długość okresu trwania bezrobocia może świadczyć o istotnym wpływie czynników strukturalnych, a krótsze okresy trwania bezrobocia pozwalają przypuszczać, że znaczenie czynników strukturalnych było mniejsze [Socha i Sztanderska 2002].

Na podstawie obliczonych stóp przepływów można dokonać dekompozycji determinant bezrobocia, na składnik cykliczny i strukturalny. Bezrobocie strukturalne w szerszym znaczeniu utożsamiane jest z bezrobociem równowagi, czyli z takim poziomem bezrobocia, który nie wynika z wahań cyklicznych koniunktury gospodarczej i do którego dąży gospodarka w długim okresie. W jego skład wchodzi bezrobocie strukturalne w węższym znaczeniu, kształtowane przez niedopasowania jakościowe popytu i podaży pracy, bezrobocie frykcyjne (występujące na skutek krótkookresowych zmian stanu aktywności ekonomicznej

spowodowanych zmianami miejsca zatrudnienia) i instytucjonalne (kształtowane głównie przez oddziaływanie regulacji prawnych [zob. Kwiatkowski 2002, Socha i Sztanderska 2002, Kołodziejczak i Wysocki 2015]). Jeden ze sposobów szacowania wielkości składnika cyklicznego i strukturalnego tego zjawiska został zaproponowany przez The Center for Economics Policy Research (CEPR) [Unemployment 1995] i polega na wyznaczeniu stopy bezrobocia w równowadze według wzoru:

$$u^* = \frac{s + z}{s + h + n}$$

gdzie:

u^* – stopa bezrobocia w równowadze,

$s = (EU + EI) / E$ – stopa odpływu z zatrudnienia (łącznie do bezrobocia i bierności zawodowej),

$h = UE / U$ – stopa odpływu z bezrobocia do zatrudnienia,

$z = (IU - UI - EI) / (E + U)$ – demograficzny składnik bezrobocia,

n – procentowe zmiany zasobów siły roboczej w przyjętym okresie trwania próby,

przy czym:

E – liczba pracujących na początku badanego okresu,

U – liczba bezrobotnych na początku badanego okresu,

EU – wielkość przepływu z zatrudnienia do bezrobocia w badanym okresie (liczba osób, które zmieniły stan z zatrudnionego na bezrobotnego),

EI – wielkość przepływu z grupy zatrudnionych do grupy biernych zawodowo,

IU – wielkość przepływu z grupy biernych zawodowo do grupy bezrobotnych,

UI – wielkość przepływu z grupy bezrobotnych do grupy biernych zawodowo,

UE – wielkość przepływu z grupy bezrobotnych do grupy zatrudnionych.

W znacznym uproszczeniu można założyć, że jeżeli $u^* > u$, to bezrobocie rzeczywiste (u) prawdopodobnie będzie wzrastać, ponieważ nie osiągnęło jeszcze poziomu wynikającego z oddziaływania czynników strukturalnych na rynku pracy (niedopasowania popytu i podaży pracy); jeżeli $u^* < u$, to bezrobocie rzeczywiste jest wyższe niż wynikające z czynników strukturalnych, a różnica może być w przybliżeniu utożsamiana z bezrobociem spowodowanym zbyt wolnym wzrostem gospodarczym (a więc prawdopodobnie możliwe jest zbliżenie wartości u do poziomu u^* poprzez pobudzenie koniunktury na rynku dóbr i usług) [Kołodziejczak 2015].

Zmienna objaśniana w modelach logitowych ma charakter dyskretny. Zatem, jeżeli występują trzy przepływy, np. z bezrobocia, to zmienna objaśniana y przyjmuje trzy wartości: $y=0$, gdy osoba bezrobotna pozostaje bezrobotną, $y=1$, gdy przechodzi do zatrudnienia i $y=2$, gdy ulega dezaktywizacji ($y=j$, $j=0, 1, 2$). Wówczas przyjmując, że wektor zmiennych objaśniających jest X , można dokonać estymacji zbioru parametrów strukturalnych $\beta(j)$, $j=0, 1, 2$ odpowiadających każdemu przepływowi [Rizov 2005, Gruszczyński 2010]:

$$\Pr(y = j) = \frac{e^{X\beta(j)}}{e^{X\beta(0)} + e^{X\beta(1)} + e^{X\beta(2)}}, \quad j = 0, 1, 2.$$

Aby model był identyfikowalny należy przyjąć, że $\beta(0)$ jest zbiorem (wektorem) parametrów równych zero [Gruszczyński 2010]. Wtedy pozostałe zbiory parametrów $\beta(1)$ i $\beta(2)$ mierzą wpływ zmiennych objaśniających na prawdopodobieństwo wystąpienia odpływu z danego stanu (zatrudnienia, bezrobocia, bierności ekonomicznej) do pozostałych stanów. Przy założeniu $\beta(0)=0$ mamy:

$$\Pr(y = 0) = \frac{1}{1 + e^{X\beta(1)} + e^{X\beta(2)'}}$$

$$\Pr(y = 1) = \frac{e^{X\beta(1)}}{1 + e^{X\beta(1)} + e^{X\beta(2)'}}$$

$$\Pr(y = 2) = \frac{e^{X\beta(2)}}{1 + e^{X\beta(1)} + e^{X\beta(2)'}}$$

W budowanych modelach zmienne objaśniające mogą być mierzone na skali metrycznej (np. staż pracy) i niemetrycznej (np. płeć i wykształcenie, które są zmiennymi kategoryzacyjnymi)². Ocena wpływu zmiennych objaśniających (cech osób aktywnych ekonomicznie) na kształtowanie się przepływów na rynku pracy oparta jest na postaci logitowej modelu określonej wzorem:

$$\ln\left(\frac{\Pr(y = \textit{kategoria } j)}{\Pr(y = \textit{kategoria bazowa})}\right) = X\beta(j)$$

² Zbiór zmiennych objaśniających (X) występujących w zbudowanych tutaj modelach przepływów siły roboczej tworzą tylko zmienne mierzone na skali nominalnej (zmienne kategoryzacyjne), które opisują cechy indywidualne osób aktywnych ekonomicznie, takie jak: płeć, stan cywilny, przedziały wieku, wykształcenie, klasa miejscowości zamieszkania, sekcja PKD, główne źródło utrzymania.

Dzieląc przez siebie prawdopodobieństwo wyboru j -tej kategorii zmiennej objaśnianej (pod wpływem zmiennych objaśniających) przez prawdopodobieństwo wyboru kategorii referencyjnej, można te ilorazy zapisać jako:

$$\left(\frac{\Pr(y = j|X)}{\Pr(y = 0|X)} \right) = \exp(X\beta(j)), \quad j = 1, 2.$$

W praktyce wyznacza się względne ilorazy szans (ryzyka) (ang. *relative-risk ratios* – *RRR*, lub *odds ratios* – *OR*) [Bodea i in. 2009, Hamilton 2013] dla każdego stanu j ($j=1, 2$) zmiennej y (w porównaniu ze stanem bazowym $j=0$) i zmiennej objaśniającej x_k w związku z „jednostkową zmianą” jej wartości ($x_k+\delta$, dla $\delta=1$), przy założeniu, że wartości pozostałych zmiennych objaśniających nie ulegają zmianie. W przypadku zmiennych objaśniających kategoryzacyjnych wzrost o „jedną jednostkę” oznacza porównanie wybranej kategorii (zakodowanej jako 1) w stosunku do kategorii bazowej (0). W ten sposób, porównanie ilorazów prawdopodobieństw dla $\delta=1$ do ilorazów dla $\delta=0$ prowadzi do równania [Hamilton 2013]:

$$RRR_{jk} \times \frac{\Pr(y = j|x_k)}{\Pr(y = 0|x_k)} = \frac{\Pr(y = j|x_k + 1)}{\Pr(y = 0|x_k + 1)},$$

gdzie: RRR_{jk} jest mnożnikiem zwanym względnym ilorazem szans (ryzyka) obliczonym dla j -tego stanu zmiennej y i wybranej kategorii (1) k -tej ($k=1, \dots, K$) zmiennej objaśniającej.

Przekształcając powyższą zależność otrzymujemy [Bodea i in. 2009]:

$$RRR = \frac{e^{\beta_0 + \beta_1 x_1 + \dots + \beta_k(x_k+1) + \dots + \beta_K x_K}}{e^{\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \dots + \beta_K x_K}} = e^{\beta_k}$$

Wynika stąd, że ilorazy szans wyznacza się w prosty sposób, obliczając dla poszczególnych kategorii wartości e^β . Liao [1994] i Gruszczyński [2010] wskazują, że jeżeli na przykład x_k jest zmienną zerojedynkową, e^{β_k} mówi ile razy wzrasta iloraz szans wartości $y=j$ dla kategorii „1” zmiennej x_k w porównaniu z tym samym ilorazem dla kategorii „0” zmiennej x_k . Iloraz szans dla kategorii referencyjnej przyjmuje więc wartość 1. Natomiast pozostałe ilorazy szans wskazują na wyższe ($RRR>1$) lub niższe ($RRR<1$) szanse (ryzyko) wystąpienia przepływu z danego do innego stanu rynku pracy w grupie osób wyróżnionych ze względu na określoną kategorię (1) w stosunku do osób tworzących kategorię referencyjną (0). Tym samym oszacowane parametry strukturalne wielomianowych modeli logitowych umożliwiły wyznaczenie ilorazów szans (ryzyka) zmiany stanu aktywności ekonomicznej badanych osób na rynku pracy oraz obliczenie prawdopodobieństw ich przejścia z poszczególnych stanów do pozostałych lub pozostania w stanie

wyjściowym w zależności od ich cech demograficznych i społeczno-ekonomicznych.

Metoda przepływów na rynku pracy umożliwia zbadanie stóp przepływów pomiędzy stanami aktywności ekonomicznej ludności, oszacowanie skończonych okresów trwania bezrobocia, prawdopodobieństw zmiany stanów w poszczególnych grupach, a stosowany w połączeniu z nią jeden ze sposobów szacowania bezrobocia równowagi umożliwia dekompozycję przyczyn zmian stanów aktywności ekonomicznej na składnik cykliczny i strukturalny. Wielomianowe modele logitowe są natomiast przydatne przede wszystkim do określania szans (ryzyka) zmiany stanu aktywności ekonomicznej ludności (Tabela 1).

Tabela 1. Możliwości zastosowania metody przepływów na rynku pracy (IOA) i wielomianowej analizy logitowej według planowanych efektów badania

Efekt badania	IOA i metoda szacowania bezrobocia równowagi, np. wg CEPR	Wielomianowe modele logitowe
Określenie ilorazów szans zmiany stanu aktywności ekonomicznej ludności względem grup referencyjnych	–	+
Określenie prawdopodobieństw zmiany stanu aktywności ekonomicznej ludności	+	+
Określenie stóp przepływów brutto pomiędzy stanami aktywności ekonomicznej ludności	+	–
Określenie przeciętnej długości trwania bezrobocia	+	–
Dekompozycja zjawiska bezrobocia na składnik cykliczny i strukturalny	+	–

Źródło: opracowanie własne na podstawie: Unemployment [1995], Socha i Sztanderska [2002], Zatrudnienie w Polsce [2005], Kołodziejczak i Wysocki [2015]

PODSUMOWANIE

Podsumowując rozważania przedstawione w artykule, można stwierdzić, że:

1. Metody „dynamiczne” do których zalicza się zaprezentowaną w artykule metodę przepływów na rynku pracy (IOA) i wielomianową analizę logitową są cennym uzupełnieniem klasycznej analizy wskaźników rynku pracy. Ich zastosowanie pozwala na rozwinięcie wnioskowania, zwłaszcza w zakresie dotyczącym przyczyn zmian stanu aktywności ekonomicznej ludności w zależności od jej charakterystyki demograficzno-społecznej. W przypadku równoczesnego

zastosowania tradycyjnej analizy wskaźników rynku pracy z metodami „dynamicznymi” możliwa jest również weryfikacja wyników uzyskanych za pomocą każdego z zastosowanych podejść badawczych.

2. Metoda przepływów na rynku pracy (IOA) w połączeniu z szacowaniem poziomu bezrobocia równowagi pozwala na wnioskowanie o cyklicznych i strukturalnych uwarunkowaniach zmiany stanu aktywności ekonomicznej ludności. Badanie wielkości stóp przepływów pozwala na zrozumienie poszczególnych składników zmian w dynamicznym układzie trzech stanów aktywności ekonomicznej, natomiast określenie poziomu bezrobocia równowagi umożliwia ustalenie (w przybliżeniu) wielkości składnika cyklicznego i strukturalnego badanych zjawisk.
3. Wielomianowa analiza logitowa jest pomocna dla określenia związków pomiędzy charakterystykami ludności a prawdopodobieństwem zmiany stanu aktywności ekonomicznej oraz do porównania szans/ryzyka przejścia między tymi stanami w odniesieniu do wybranych grup ludności.

BIBLIOGRAFIA

- Bodea T.D., Garrow L.A., Meyer M.D., Ross C.L. (2009) Socio-demographic and built environment influences on the odds of being overweight or obese: The Atlanta experience, *Transportation Research Part A* 43, 430-444.
- Gruszczyński M. (red. nauk.) (2010) *Mikroekonometria. Modele i metody analizy danych indywidualnych*, Wolters Kluwer Polska.
- Hamilton L. C. (2013) *Statistics with STATA version 12*, Brooks/Cole, Cengage Learning International Edition, Belmont.
- Kołodziejczak W., Wysocki F. (2015) *Determinanty aktywności ekonomicznej ludności wiejskiej w Polsce*, Monografia, Wyd. UP w Poznaniu, Poznań 2015.
- Kwiatkowski E. (2002) Strukturalne determinanty naturalnej stopy bezrobocia, *Bank i Kredyt* 11-12.
- Liao T.F. (1994) *Interpreting probability models. Logit, probit and other generalized linear models*, Sage University Paper 101. Ser.: *Quantitative Applications in the Social Sciences*. Thousand Oaks, California.
- McFadden D.L. (1981) *Econometric models of probabilistic choice*. W: *Structural analysis of discrete data with econometric applications*, Red. C.F. Manski, D. McFadden. The MIT Press, Cambridge, 198-272.
- Rizov M. (2005) Pull and push: individual farming in Hungary, *Food Policy* 30, 43-62.
- Socha M., Sztanderska U. (2002) *Strukturalne podstawy bezrobocia w Polsce*, PWN, Warszawa.
- Tyrowicz J. (2011) *Histereza bezrobocia w Polsce*, Wydawnictwo Uniwersytetu Warszawskiego, Warszawa.
- Unemployment: Choices for Europe* (1995) Centre for Economic Policy Research, London.
- Zatrudnienie w Polsce 2005* (2005) Ministerstwo Gospodarki i Pracy, Departament Analiz i Prognoz Ekonomicznych, Warszawa.

**INFLOW-OUTFLOW ANALYSIS (IOA) AND MULTINOMIAL
LOGISTIC REGRESSION IN THE RESEARCH OF ECONOMIC
ACTIVITY OF POPULATION**

Abstract: Inflow-Outflow Analysis (IOA) combined with estimation of equilibrium unemployment and multinomial logistic regression can be used to develop and complete inference conducted on the basis of the classic characteristics of economic activity of population. Application of these methods let us decompose the labour resources according to the selected socio-economic traits in terms of possible changes in the state of economic activity of population, as well as assess the shares of structural and cyclical component of unemployment. The aim of the paper is to present the possibilities of using the Inflow-Outflow Analysis (IOA) and multinomial logistic regression in the research of economic activity of population.

Keywords: Inflow-Outflow Analysis, multinomial logistic regression, economic activity of population, equilibrium unemployment, structural unemployment, labour market, flows on the labour market

ANALIZA ZGODNOŚCI WNIOSKÓW WYNIKAJĄCYCH Z ZASTOSOWANIA WYBRANYCH FUNKCJI DYSKRYMINACYJNYCH

Sławomir Lisek

Katedra Statystyki i Ekonometrii
Uniwersytet Rolniczy w Krakowie
e-mail: slisek@ar.krakow.pl

Streszczenie: Prognozowanie zagrożenia upadłością jest istotną czynnością w procesie zarządzania, a także kontroli jednostkami gospodarczymi. Jednym z narzędzi prognozowania upadłości są funkcje dyskryminacyjne. By mogły być one użytecznym narzędziem, powinny prowadzić do podobnego ustalenia rankingów przedsiębiorstw pod względem kondycji finansowej, a przynajmniej wskazywać na podobne wnioski w zakresie zagrożenia upadłością. Przeprowadzone badanie wykazało, iż rankingi sporządzone na podstawie różnych funkcji wykazują małe podobieństwo. Natomiast podobne wnioski co do zagrożenia upadłością wyciąga się na podstawie funkcji Altmana, Hołdy i HCP, nieco bardziej różnią się funkcje Koha i Killougha oraz Gajdki i Stosa, najbardziej zaś odstaje funkcja Beermana.

Słowa kluczowe: funkcje dyskryminacyjne, kondycja finansowa przedsiębiorstwa, upadłość, ranking przedsiębiorstw

FUNKCJE DYSKRYMINACYJNE W PROCESIE PRZEWIDYWANIA RYZYKA UPADŁOŚCI

Przesłanki tworzenia funkcji dyskryminacyjnych

Główną przesłanką tworzenia modeli prognozowania bankructwa była upadłość wielkich korporacji amerykańskich pod koniec XX wieku. [Jerzemska 2004; s. 336-337]. Jednym z najważniejszych narzędzi służących do prognozowania upadłości są modele dyskryminacyjne. Szacuje się, iż analiza dyskryminacyjna stosowana jest w 30% przypadków prognozowania upadłości, gdy zajmująca kolejne miejsce analiza logitowa już tylko w 21% przypadków. Sieci neuronowe stosowane są w 9% przypadków, drzewa decyzyjne 5,6%

przypadków, pozostałe w nie więcej niż 5% przypadków [Hołda, Pocięcha 2009; s. 139]. Analiza dyskryminacyjna może być jednowymiarowa lub wielowymiarowa. Analiza jednowymiarowa polega na analizowaniu jednej cechy i wyciąganiu na jej podstawie wniosków. Wielowymiarowa analiza dyskryminacyjna to sprowadzenie wielu cech za pomocą funkcji dyskryminacyjnej do jednej wielkości zagregowanej, na podstawie której dokonuje się oceny w zakresie zagrożenia upadłością [tamże, s. 147]. By można funkcje dyskryminacyjne uznać za bezpieczne narzędzie prognozowania upadłości, rankingi spółek sporządzane na ich podstawie powinny być zbieżne. Przynajmniej zaś powinny wykazywać podobne prognozy w zakresie zagrożenia upadłością. Zasadnym wydaje się więc być zbadanie tych kwestii na podstawie rzeczywistych sprawozdań losowo wybranych firm.

Funkcje dyskryminacyjne omawiane w niniejszym artykule

W tej pracy porównano wnioski wyciągane z wykorzystaniem 6 funkcji dyskryminacyjnych, w tym 3 zagranicznych ekonomistów i 3 polskich naukowców. Funkcjami tymi są: model Altmana [Altman, Branch 2015, s. 7], obliczany zgodnie z regułą:

$$Z_A = 3,25 + 6,56X_1 + 3,26 * X_2 + 6,72 * X_3 + 1,05 * X_4, \quad (1)$$

gdzie:

- Z_A – oznacza funkcję dyskryminacyjną Altmana,
- X_1 – (aktywa bieżące – zobowiązania bieżące)/aktywa ogółem,
- X_2 – zyski zatrzymane/aktywa ogółem,
- X_3 – EBIT/aktywa ogółem,
- X_4 – księgową wartość kapitału własnego/zobowiązania ogółem.

Wartością rozgraniczającą spółki zagrożone upadłością od niezagrażonych w tym modelu jest 0. [tamże, s. 7]

Kolejną analizowaną funkcją jest model Beermana [Jerzemowska 2004, s. 342-343], wyrażony wzorem:

$$Z_B = 0,21705X_1 + 0,06276X_2 + 0,01218X_3 + 0,07741X_4 + 0,10477X_5 + 0,8127X_6 + 0,16454X_7 + 0,06135X_8 + 0,26832X_9 + 0,12368X_{10}, \quad (2)$$

gdzie:

- Z_B – funkcja dyskryminacyjna Beermana,
- X_1 – amortyzacja / (aktywa trwałe + przyrost aktywów trwałych),
- X_2 – nadwyżka finansowa / kapitały obce
- X_3 – przyrost aktywów trwałych / amortyzacja
- X_4 – kapitały obce/kapitały całkowite,
- X_5 – (wynik netto + podatek dochodowy + wynik zdarzeń nadzwyczajnych)/przychody ze sprzedaży,

- X_6 – (wynik netto + podatek dochodowy + wynik zdarzeń nadzwyczajnych)/
 kapitały ogółem,
 X_7 – zobowiązania bankowe / kapitały obce
 X_8 – przychody ze sprzedaży / kapitały ogółem,
 X_9 – zapasy / przychody ze sprzedaży
 X_{10} – (wynik netto + podatek dochodowy + wynik zdarzeń nadzwyczajnych)/
 kapitały obce,

Wartością krytyczną w przypadku tego modelu jest 0,30081. [tamże, s. 343]

Następnym omawianym zagranicznym modelem jest funkcja którą opracowali H. Koh i L. Killough. Model ten wyraża się wzorem [Hołda Pocięcha 2009, s. 157]:

$$Z_{KK} = -1,2601 + 0,8701X_1 + 2,1981X_2 + 0,1184X_3 + 0,8960X_4, \quad (3)$$

gdzie:

- Z_{KK} – oznacza funkcję dyskryminacyjną Koh i Killough,
 X_1 – aktywa obrotowe/zobowiązania krótkoterminowe,
 X_2 – zyski zatrzymane/aktywa ogółem,
 X_3 – zysk przypadający na akcję,
 X_4 – dywidenda przypadająca na akcję.

Dla tej funkcji wartością graniczną jest 0. [tamże, s. 157]

Oprócz wymienionych wyżej modeli zagranicznych, badaniu poddano też 3 modele polskich autorów. Pierwszym z nich jest model Gajdki i Stosa. Wyraża się on wzorem [tamże, s. 173]:

$$Z_{GS} = 0,7732059 - 0,0856425X_1 + 0,0007747X_2 + 0,9220985X_3 + 0,6535995X_4 + 0,594687X_5 \quad (4)$$

gdzie:

- Z_{GS} – oznacza funkcję dyskryminacyjną Gajdki i Stosa,
 X_1 – przychody ze sprzedaży/aktywa ogółem,
 X_2 – zobowiązania krótkoterminowe/koszt wytworzenia produkcji sprzedanej
 *360,
 X_3 – zysk netto/aktywa ogółem,
 X_4 – zysk brutto / przychody ze sprzedaży netto,
 X_5 – zobowiązania ogółem/aktywa ogółem

Punkt krytyczny w tym wypadku wynosi 0,45 [tamże, s. 173].

Kolejnym badanym modelem jest funkcja Hołdy, obliczana wg wzoru [tamże, s. 174]:

$$Z_H = 0,0605X_1 - 0,0196X_2 + 0,157X_3 + 0,00969X_4 + 0,000672X_5, \quad (5)$$

gdzie:

- Z_H – oznacza funkcję dyskryminacyjną Hołdy,
- X_1 – majątek obrotowy/zobowiązania krótkoterminowe,
- X_2 – zobowiązania ogółem/suma bilansowa,
- X_3 – przychód z ogółu działalności/średnioroczny majątek ogółem,
- X_4 – zysk netto/średnioroczny majątek ogółem,
- X_5 – przeciętne zobowiązania krótkoterminowe/koszty sprzedanych produktów, towarów i materiałów.

Punkt krytyczny w tym wypadku wynosi 0 [tamże, s. 174].

Ostatnią z omawianych funkcji jest model Hamrola, Czajki i Piechockiego. Oblicza się go zgodnie ze wzorem [tamże, s. 176]:

$$Z_{HCP} = -2,368 + 3,562X_1 + 1,588X_2 + 4,288X_3 + 6,719X_4, \quad (6)$$

gdzie:

- Z_{HCP} – oznacza funkcję dyskryminacyjną Hamrola, Czajki, Piechockiego,
- X_1 – wynik finansowy netto/majątek całkowity,
- X_2 – (majątek obrotowy – zapasy)/zobowiązania krótkoterminowe,
- X_3 – kapitał stały/majątek całkowity,
- X_4 – wynik finansowy ze sprzedaży / przychody netto ze sprzedaży.

Dla tej funkcji wartością graniczną jest 0 [tamże, s. 176].

Przyjęte do analizy w niniejszej pracy funkcje dyskryminacyjne wyraźnie różnią się między sobą swoją konstrukcją. Niektóre z nich są skonstruowane na bazie niewielkiej liczby zmiennych diagnostycznych (np. Altman), a model Beermana zbudowano z wykorzystaniem dużej liczby zmiennych diagnostycznych. Zasadnym jest zbadanie zbieżności wniosków wynikających z oceniania przedsiębiorstw za pomocą różnych modeli.

Materiał badawczy i wartości funkcji dla badanych spółek

Podstawą do przeprowadzenia badań nad zgodnością wniosków wynikających z zastosowania różnych modeli są jednostkowe sprawozdania finansowe losowo wybranych firm z województwa małopolskiego i śląskiego. Wykorzystano sprawozdania jednostkowe, ponieważ upadłość jednostki dominującej nie powoduje upadłości jednostek zależnych, ani też stowarzyszonych. W takiej sytuacji syndyk powinien po prostu sprzedać akcje lub udziały spółek zależnych lub stowarzyszonych. Bazując na tych sprawozdaniach obliczono wartość funkcji dyskryminacyjnych dla poszczególnych przedsiębiorstw, zgodnie ze wzorami od 1) do 6). Wynoszą one:

Tabela 1. Wartość poszczególnych funkcji dyskryminacyjnych dla wybranych przedsiębiorstw

Spółka	Z_A	Z_B	Z_{KK}	Z_H	Z_{GS}	Z_{HCP}
Wawel S.A.	11,3583	0,3713	21,4401	0,3639	0,9038	7,1597
Wojas S.A.	6,4693	0,3423	0,5819	0,3065	0,5948	3,6159
Stalprodukt	10,8807	0,2349	3,0117	0,2046	0,7069	2,7201
MO Bruk S.A.	3,7695	0,1502	-0,8815	0,0499	0,3966	1,9261
Comarch	8,9728	0,2029	3,4437	0,3106	0,6737	7,0892
Quantum	16,4198	-0,0672	-0,2318	0,2339	0,4747	4,0257
Newag	5,6895	0,4019	0,8850	0,2059	0,6153	3,1456
ES System	10,3216	0,1487	1,1192	0,3104	0,6807	6,6228
AZOTY S.A.	12,5336	0,2712	5,1469	0,4297	0,8511	11,7261
Instal Kraków S.A.	8,0981	0,2218	1,4933	0,3085	0,5336	2,0845
Famur S.A.	4,1648	0,2877	0,3187	0,1171	1,1140	1,4180
RAFAKO S.A.	4,1367	0,2136	1,6633	0,2224	0,4699	0,8038
RAFAMET S.A.	7,3774	0,1685	1,4055	0,1966	0,7037	6,2111
TAURON S.A.	6,8605	0,2451	1,0788	0,1279	0,7584	3,9890
Farmacol S.A.	6,1021	0,2869	0,8162	0,4712	0,2884	0,6244
Stalprofil S.A.	10,2831	0,2940	2,6279	0,3429	0,6104	3,5190
Elzab S.A.	5,7187	0,3624	0,0501	0,2161	0,9036	2,6375
Ferrum S.A.	1,6355	0,2051	-1,1783	0,2366	0,4478	-0,2206
PGO S.A.	2,6777	1,9491	-0,9995	0,0236	16,4594	0,1144
ZM Henryk Kania S.A.	7,3576	0,3540	0,9948	0,3794	0,4012	2,9645

Źródło: opracowanie własne

Analizując Tabelę 1 należy zauważyć, iż wszystkie jednostki są w bezpiecznej sytuacji finansowej, gdyby oceniać ich zagrożenie miernikiem Altmana. W każdym przypadku wynik zdecydowanie przekracza 0, co świadczy o tym, że sytuacja jednostek jest stabilna. To samo można powiedzieć o rezultacie pomiaru metodą Hołdy. Zupełnie odmienny wniosek należy wyciągnąć z pomiaru za pomocą funkcji Beermana. Tutaj większość przedsiębiorstw nie przekracza krytycznej wielkości 0,30081, dlatego należy uznać iż są one zagrożone upadłością. W przypadku pozostałych modeli, większość spółek jest bezpieczna, ale znajduje się też niewielka ilość zagrożonych upadłością.

WERYFIKACJA SPÓJNOŚCI WYNIKÓW UZYSKANYCH Z WYKORZYSTANIEM UŻYTYCH MIAR

Korelacja bezwzględnych rezultatów uzyskanych z wykorzystaniem poszczególnych miar

W celu zbadania zbieżności wyników uzyskanych przy zastosowaniu różnych funkcji, poniżej w Tabeli 2 zamieszczono współczynniki korelacji liniowej Pearsona, pomiędzy rezultatami uzyskanymi z obliczeń z wykorzystaniem poszczególnych funkcji dyskryminacyjnych:

Tabela 2. Macierz współczynników korelacji liniowej dla rezultatów wynikających z zastosowania poszczególnych funkcji

	Z_A	Z_B	Z_{KK}	Z_H	Z_{GS}	Z_{HCP}
Z_A	1,00	-0,39	0,41	0,47	-0,31	0,67
Z_B	-0,39	1,00	-0,07	-0,38	0,97	-0,28
Z_{KK}	0,41	-0,07	1,00	0,38	-0,13	0,50
Z_H	0,47	-0,38	0,38	1,00	-0,47	0,44
Z_{GS}	-0,31	0,97	-0,13	-0,47	1,00	-0,26
Z_{HCP}	0,67	-0,28	0,50	0,44	-0,26	1,00

Źródło: opracowanie własne

Omawiając dane z Tabeli 2 należy powiedzieć, iż wyniki uzyskane w rezultacie stosowania poszczególnych miar są generalnie słabo skorelowane pomiędzy sobą. Jedynie rezultaty wynikające z zastosowania modelu Gajdki i Stosa są prawie całkowicie skorelowane z rezultatami funkcji Beermana. Również silna korelacja występuje pomiędzy funkcjami Altmana oraz Hamroła, Czajki i Piechockiego. Dlatego też można przyjąć iż rezultaty bezwzględne modelu Altmana i HCP są zbieżne, a także rezultaty modelu Beermana oraz modelu Gajdki i Stosa. Natomiast występuje rozbieżność pomiędzy rezultatami wynikającymi z wykorzystania pozostałych funkcji. Tabela 2 wyraźnie pokazuje więc, iż funkcje te nie powinny być stosowane zamiennie, jako syntetyczna miara kondycji firmy.

Wnioski na temat zagrożenia upadłością na podstawie poszczególnych funkcji i ich jednorodność

Poniżej w Tabeli 3 zamieszczono podział na jednostki bezpieczne, zgodnie z pomiarem wg reguł danej funkcji i jednostki zagrożone upadłością. Jednostki bezpieczne oznaczone są cyfrą 1, natomiast zagrożone cyfrą 0.

Tabela 3. Jednostki bezpieczne i zagrożone zgodnie z regułą poszczególnych funkcji

Spółka	Z _A	Z _B	Z _{KK}	Z _H	Z _{GS}	Z _{HCP}
Wawel S.A.	1	1	1	1	1	1
Wojas S.A.	1	1	1	1	1	1
Stalprodukt	1	0	1	1	1	1
MO Bruk S.A.	1	0	0	1	0	1
Comarch	1	0	1	1	1	1
Quantum	1	0	0	1	1	1
Newag	1	1	1	1	1	1
ES System	1	0	1	1	1	1
AZOTY S.A.	1	0	1	1	1	1
Instal Kraków S.A.	1	0	1	1	1	1
Famur S.A.	1	0	1	1	1	1
RAFAKO S.A.	1	0	1	1	1	1
RAFAMET S.A.	1	0	1	1	1	1
TAURON S.A.	1	0	1	1	1	1
Farmacol S.A.	1	0	1	1	0	1
Stalprofil S.A.	1	0	1	1	1	1
Elzab S.A.	1	1	1	1	1	1
Ferrum S.A.	1	0	0	1	0	0
PGO S.A.	1	1	0	1	1	1
ZM Henryk Kania S.A.	1	1	1	1	0	1

Źródło: opracowanie własne

Dane z Tabeli 3 informują, iż wnioski wynikające z funkcji Altmana i funkcji Hołdy są w pełni tożsame. W obu przypadkach wszystkie firmy są jednostkami bezpiecznymi. Najbardziej różne od pozostałych wnioski wysnuwa się na podstawie funkcji Beermana, według której tylko 6 na 20 analizowanych firm jest bezpieczne. W przypadku funkcji Koha i Killougha, a także Gajdki i Stosa w 4 przypadkach spółki są zagrożone w pozostałych bezpieczne. Są to jednakże inne spółki. Model HCP wykazuje 1 spółkę zagrożoną, pozostałe zaś są bezpieczne, w czym jest zbliżony w zakresie wyciąganych wniosków do modeli Hołdy i Altmana. Wnioski pomiędzy funkcjami Altmana i Hołdy, a funkcjami Koha i Killougha, a także Gajdki i Stosa, różnią się w 4 przypadkach, czyli w 25% analizowanych przypadków.

Wnioski w zakresie zagrożenia upadłością wyciągane na podstawie analizowanych funkcji (Tabela 3) są bardziej jednorodne, niż wartości bezwzględne wyników tych funkcji (Tabela 1). Funkcje Altmana, Hołdy i HCP są

w zasadzie bardzo podobne pod względem wniosków na temat zagrożenia upadłością, nieco bardziej różnią się funkcje Gajdki i Stosa, najbardziej zaś różni się funkcja Beermana.

Ranking przedsiębiorstw na podstawie analizowanych funkcji

Podstawowym zadaniem funkcji dyskryminacyjnych nie jest ocena kondycji firm, a prognoza zagrożenia upadłością. Jednak są one syntetycznym miernikiem sytuacji przedsiębiorstwa, więc umożliwiają utworzenie rankingu przedsiębiorstw pod względem sytuacji finansowej. Ranking spółek wg poszczególnych modeli przedstawiono w Tabeli 4.

Tabela 4. Ranking przedsiębiorstw na podstawie poszczególnych funkcji

lokata	Firma	Z _A	lokata	Firma	Z _B	lokata	Firma	Z _{KK}
1	Quantum	16,42	1	PGO S.A.	1,95	1	Wawel S.A.	21,44
2	AZOTY S.A.	12,53	2	Newag	0,40	2	AZOTY S.A.	5,15
3	Wawel S.A.	11,36	3	Wawel S.A.	0,37	3	Comarch	3,44
4	Stalprodukt	10,88	4	Elzab S.A.	0,36	4	Stalprodukt	3,01
5	ES System	10,32	5	ZM Henryk Kania S.A.	0,35	5	Stalprofil S.A.	2,63
6	Stalprofil S.A.	10,28	6	Wojas S.A.	0,34	6	RAFAKO S.A.	1,66
7	Comarch	8,97	7	Stalprofil S.A.	0,29	7	Instal Kraków S.A.	1,49
8	Instal Kraków S.A.	8,10	8	Famur S.A.	0,29	8	RAFAMET S.A.	1,41
9	RAFAMET S.A.	7,38	9	Farmacol S.A.	0,29	9	ES System	1,12
10	ZM Henryk Kania S.A.	7,36	10	AZOTY S.A.	0,27	10	TAURON S.A.	1,08
11	TAURON S.A.	6,86	11	TAURON S.A.	0,25	11	ZM Henryk Kania S.A.	0,99
12	Wojas S.A.	6,47	12	Stalprodukt	0,23	12	Newag	0,89
13	Farmacol S.A.	6,10	13	Instal Kraków S.A.	0,22	13	Farmacol S.A.	0,82
14	Elzab S.A.	5,72	14	RAFAKO S.A.	0,21	14	Wojas S.A.	0,58
15	Newag	5,69	15	Ferrum S.A.	0,21	15	Famur S.A.	0,32
16	Famur S.A.	4,16	16	Comarch	0,20	16	Elzab S.A.	0,05
17	RAFAKO S.A.	4,14	17	RAFAMET S.A.	0,17	17	Quantum	-0,23
18	MO Bruk S.A.	3,77	18	MO Bruk S.A.	0,15	18	MO Bruk S.A.	-0,88
19	PGO S.A.	2,68	19	ES System	0,15	19	PGO S.A.	-1,00
20	Ferrum S.A.	1,64	20	Quantum	-0,07	20	Ferrum S.A.	-1,18

lokata	Firma	Z _H	lokata	Firma	Z _{Gs}	lokata	Firma	Z _{HCP}
1	Farmacol S.A.	0,47	1	PGO S.A.	16,46	1	AZOTY S.A.	11,73
2	AZOTY S.A.	0,43	2	Famur S.A.	1,11	2	Wawel S.A.	7,16
3	ZM Henryk Kania S.A.	0,38	3	Wawel S.A.	0,90	3	Comarch	7,09
4	Wawel S.A.	0,36	4	Elzab S.A.	0,90	4	ES System	6,62
5	Stalprofil S.A.	0,34	5	AZOTY S.A.	0,85	5	RAFAMET S.A.	6,21
6	Comarch	0,31	6	TAURON S.A.	0,76	6	Quantum	4,03
7	ES System	0,31	7	Stalprodukt	0,71	7	TAURON S.A.	3,99
8	Instal Kraków S.A.	0,31	8	RAFAMET S.A.	0,70	8	Wojas S.A.	3,62
9	Wojas S.A.	0,31	9	ES System	0,68	9	Stalprofil S.A.	3,52
10	Ferrum S.A.	0,24	10	Comarch	0,67	10	Newag	3,15
11	Quantum	0,23	11	Newag	0,62	11	ZM Henryk Kania S.A.	2,96
12	RAFAKO S.A.	0,22	12	Stalprofil S.A.	0,61	12	Stalprodukt	2,72
13	Elzab S.A.	0,22	13	Wojas S.A.	0,59	13	Elzab S.A.	2,64
14	Newag	0,21	14	Instal Kraków S.A.	0,53	14	Instal Kraków S.A.	2,08
15	Stalprodukt	0,20	15	Quantum	0,47	15	MO Bruk S.A.	1,93
16	RAFAMET S.A.	0,20	16	RAFAKO S.A.	0,47	16	Famur S.A.	1,42
17	TAURON S.A.	0,13	17	Ferrum S.A.	0,45	17	RAFAKO S.A.	0,80
18	Famur S.A.	0,12	18	ZM Henryk Kania S.A.	0,40	18	Farmacol S.A.	0,62
19	MO Bruk S.A.	0,05	19	MO Bruk S.A.	0,40	19	PGO S.A.	0,11
20	PGO S.A.	0,02	20	Farmacol S.A.	0,29	20	Ferrum S.A.	-0,22

Źródło: opracowanie własne

Analizując Tabelę 4 można stwierdzić, że rankingi sporządzone na podstawie poszczególnych miar znacznie różnią się między sobą. Modelowym przykładem jest spółka PGO S.A., która lideruje w rankingach sporządzonych na podstawie funkcji Beermana oraz funkcji Gajdki i Stosa, natomiast zajmuje ostatnie miejsce w rankingu wg funkcji Hołdy, przedostatnie zaś w rankingach wg modeli HCP, Altmana, Koha i Killougha. Podobne wnioski można wysnuć w stosunku do innych firm.

Podobieństwo rankingów zbadano miarą podobieństwa rankingów p , obliczaną zgodnie z formułą [Kukuła 1989; s. 256]:

$$p = 1 - \frac{2 \sum_{j=1}^r |d_j|}{r^2 - z},$$

gdzie:

r – ilość obiektów,

d_j – różnica lokat j – tego obiektu w obu rankingach

$z = 0$ jeśli r jest parzyste, 1 jeśli r jest nieparzyste.

Macierz podobieństwa p , kształtuje się następująco:

Tabela 5. Macierz podobieństwa p , dla rankingów wg poszczególnych funkcji

	Z_A	Z_B	Z_{KK}	Z_H	Z_{GS}	Z_{HCP}
Z_A	1	0,28	0,75	0,58	0,44	0,72
Z_B	0,28	1	0,30	0,35	0,49	0,29
Z_{KK}	0,75	0,30	1	0,53	0,46	0,63
Z_H	0,58	0,35	0,53	1	0,23	0,52
Z_{GS}	0,44	0,49	0,46	0,23	1	0,49
Z_{HCP}	0,72	0,29	0,63	0,52	0,49	1

Źródło: opracowanie własne

Na podstawie Tabeli 5 można wywnioskować, że najbardziej zbliżone są do siebie rankingi zbudowane na podstawie funkcji Altmana, Koha i Killougha oraz HCP. Natomiast podobieństwo pozostałych rankingów jest niewielkie.

Generalnie Tabela 5 potwierdza jednak wnioski z Tabeli 4 o tym, iż rankingi nie są do siebie podobne. Fakt ten powoduje, iż nie można tych funkcji przyjąć za podstawę obiektywnych rankingów.

KONKLUZJE

Przeprowadzone badanie wykazało, iż rezultaty obliczeń wg poszczególnych funkcji dyskryminacyjnych, dla tych samych spółek i w tym samym okresie, różnią się między sobą istotnie.

Również rankingi sporządzone na podstawie różnych funkcji wykazują małe podobieństwo. Dlatego też funkcji tych nie można wykorzystywać do budowania rankingów firm w zależności od kondycji finansowej.

Natomiast występuje podobieństwo wniosków co do zagrożenia upadłością pomiędzy funkcjami Altmana, Hołdy i HCP. Nieco bardziej różnią się wnioski z wykorzystaniem funkcji Koha i Killougha oraz Gajdki i Stosa. Najbardziej różniącą się jest funkcja Beermana.

BIBLIOGRAFIA

- Altman E. I., Branch B. (2015) The Banruptcy System's Chapter 22 Recidivism Problem: How Serious is It?, *The Financial Review* 50 s. 1-26.
- Hołda A., Pocięcha J. (2009) Probabilistyczne metody badania sprawozdań finansowych. Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie.
- Jerzemowska M. (2004) Analiza Ekonomiczna w przedsiębiorstwie, Polskie Wydawnictwo Ekonomiczne.
- Kukuła K. (1989) Statystyczna analiza strukturalna i jej zastosowanie w sferze usług produkcyjnych dla rolnictwa, *Zeszyty Naukowe Akademii Ekonomicznej w Krakowie*, seria specjalna Monografie nr 89, Kraków, s. 256.

ANALYSYS OF THE COHERENCE CONCLUSIONS ACHIVED USING SIX SELECTED DISCRIMANATIONS FUNCTIONS

Abstract: Prediction of the firm's collapse is one of the important problems in management process. Important forecasting methods are discrimination's functions. They should lead to fix similar firms' ranking or at least to draw similar conclusions in collapse danger subject. Perfrmed investigations informs that Altman model, Hołda model and HCP model lead to draw similar conclusions. To more different conclusions lead Koh and Killough model and Gajdka and Stos model. Most different is Beerman model. Rankings are not similar.

Keywords: synthetic measure, financial condition of the enterprise, *collapse*, discrimination functions, ranking of the enterprises

REGIONALNE ZRÓŻNICOWANIE STRUKTURY OBSZAROWEJ UŻYTKÓW ROLNYCH W POLSCE

Lidia Luty

Katedra Statystyki i Ekonometrii
Uniwersytet Rolniczy w Krakowie
e-mail: rrdutka@cyf-kr.edu.pl

Streszczenie: Celem opracowania było przedstawienie regionalnego zróżnicowania struktury obszarowej użytków rolnych (UR) gospodarstw ekologicznych w porównaniu do struktury we wszystkich gospodarstwach rolnych posiadających UR w Polsce. Bazowano zarówno na liczbie jak i powierzchni gospodarstw w grupach obszarowych UR. Do podziału województw na podzbiory podobne pod względem rozpatrywanych struktur wykorzystano metodę eliminacji wektorów. Ponadto, zbadano dynamikę badanych struktur w Polsce po akcesji do Unii Europejskiej (UE). Analiza pokazała, że rolnictwo, w tym w szczególności oparte na ekologicznych metodach wytwarzania jest regionalnie zróżnicowane. Zmiany analizowanych struktur w Polsce zmierzają do koncentracji ziemi i zmniejszania liczby gospodarstw o małej powierzchni UR w gospodarstwach rolnych, w tym znacząco w gospodarstwach ekologicznych.

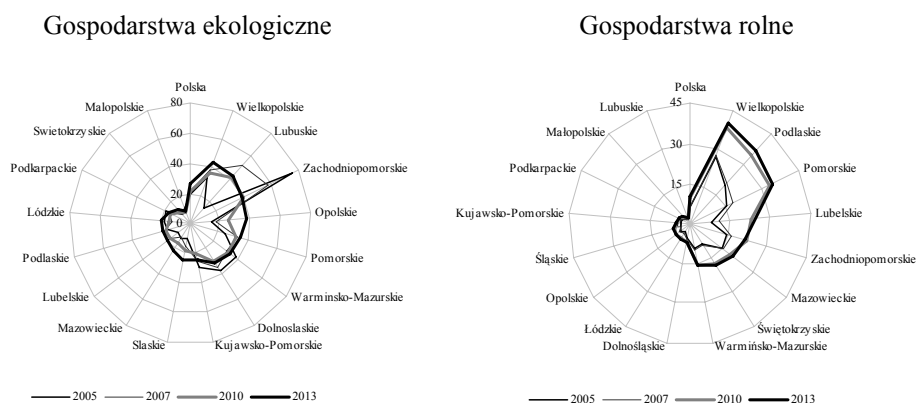
Słowa kluczowe: taksonomia struktur, dynamika struktur, rolnictwo ekologiczne, zróżnicowanie regionalne

WSTĘP

W 2005 roku średnia powierzchnia UR gospodarstw rolnych w Polsce wynosiła 6 ha (Rysunek 1), natomiast w UE była trzykrotnie wyższa. Z kolei średnia powierzchnia użytków rolnych w gospodarstwach ekologicznych szacowana była na 19 ha, a w Unii na 30 ha. Gospodarstwa ekologiczne Polski stanowiły zaledwie 2,6% wszystkich gospodarstw ekologicznych w UE, a ich użytki rolne zajmowały tylko 1,6% tej powierzchni. W rok po akcesji Polski do UE średnia powierzchnia UR w gospodarstwach rolnych przekraczała 15 ha tylko w trzech województwach: wielkopolskie, podlaskie i pomorskie, a w roku 2007

granicę tę przekroczyły jeszcze dwa województwa: zachodniopomorskie i mazowieckie. Widoczne wzrosty powierzchni UR w gospodarstwach odnotowano w 2010 roku. W roku 2013 prawie we wszystkich województwach średnia ta wzrosła (spadła jedynie w zachodniopomorskim o 1 ha), ale wzrosty nie przekraczały 2,4 ha.


Rysunek 1. Średnie powierzchnie UR w gospodarstwach ekologicznych i rolnych [ha] w wybranych latach



Źródło: opracowanie własne na podstawie danych Eurostat

Zmiany średniej powierzchni UR w gospodarstwach ekologicznych w województwach Polski w badanych latach nie miały tak stałego kierunku jak zmiany średniej wszystkich gospodarstw rolnych. W 2013 roku tylko w trzech województwach średnia powierzchnia gospodarstwa ekologicznego nie przekraczała 19 ha.

Rysunek 2. Udział użytkowników rolnych w gospodarstwach ekologicznych w UR gospodarstw rolnych ogółem w wybranych latach.



Źródło: opracowanie własne na podstawie danych Eurostat

Na przestrzeni badanych lat nastąpił wzrost co najmniej dwukrotny udziału użytków rolnych gospodarstw ekologicznych w UR ogółem w każdym województwie, przy czym zauważalny był w roku 2010, a znaczny w zachodniopomorskim, lubuskim, warmińsko-mazowieckim (Rysunek 2). W kolejnych latach, w tych województwach wskaźnik ten przekroczył poziom 9%.

Województwa Polski nie są obszarami o jednolitym rolnictwie.¹ Zróżnicowanie regionalne w rolnictwie polskim utrzymuje się od wieku XIX, kiedy Polska była pod zaborami, a na jej ziemiach wykształciły się trzy różne systemy gospodarcze [Kukuła 2010]. Wynika to z różnorodności warunków przyrodniczych, organizacyjno-ekonomicznych oraz środowiskowych [Kopiński 2016]. Struktura agrarna jest jednym z elementów, który decyduje o możliwościach produkcyjnych rolnictwa [Kukuła 2010]. Rosnąca konkurencja na rynku rolnym wymusza zwiększanie powierzchni gospodarstw rolnych (Rysunek 3). Zmiany struktury obszarowej gospodarstw są więc jednym ze wskaźników dostosowywania się rolnictwa polskiego do nowej rzeczywistości ekonomicznej i dlatego są uważnie śledzone. Niewątpliwie przyczyniają się do nich, jak pisze Pięta [2007] następujące grupy działań wobec wsi i rolnictwa: podtrzymywanie cen i stabilizacja rynków, dotacje do środków produkcji rolniczej oraz dopłaty do oprocentowania kredytów skupowych, instrumenty polityki strukturalnej na wsi i w rolnictwie.

Celem niniejszego opracowania jest przedstawienie i porównanie regionalnego zróżnicowania struktury użytków rolnych gospodarstw ekologicznych i gospodarstw rolnych. Badanie prowadzono bazując zarówno na liczbie gospodarstw jak i powierzchni ich UR w poszczególnych grupach obszarowych UR. Ponadto, określono stopień zmian badanych struktur w Polsce w latach 2005-2013.

MATERIAŁ I METODA ANALIZY

Analizę obejmującą głównie rok 2013 prowadzono w oparciu o dane dostępne z baz Eurostat. Rozważane szeregi czasowe opisują liczbę lub powierzchnię UR [ha] w grupach obszarowych użytków rolnych określonych następująco: do 5; od 5 do 9,9; od 10 do 19,9; od 20 do 49,9; od 50 do 99,9; 100 i więcej [ha] odpowiednio w gospodarstwach ekologicznych i w gospodarstwach rolnych ogółem posiadających UR.

Strukturę wg przyjętych grup obszarowych UR w województwach Polski można przedstawić w postaci macierzy $[a_{ij}]$:

¹ Podkreślali to w ostatnich latach w swych pracach m. in.: Kopiński, Matyka 2016; Rudnicki i in. 2015; Matyka i in. 2013; Stany 2013; Poczta, Bartkowiak 2012; Kopiński, Kasprowicz 2010

$$[a_{ij}]_{\substack{i=1,2,\dots,n \\ j=1,2,\dots,m}} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{12} & a_{22} & \dots & a_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{bmatrix} \quad (1)$$

gdzie a_{ij} opisuje udział liczby (powierzchni) gospodarstw z j grupy obszarowej w liczbie (powierzchni) wszystkich gospodarstw w i województwie, przy czym spełnione są następujące warunki: $0 \leq a_{ij} \leq 1$ oraz $\sum_{j=1}^m a_{ij} = 1$, dla $i = 1, 2, \dots, n$.

Dla każdej pary województw wyznaczono miarę zróżnicowania według wzoru [Kukuła, 1989]: $d_{ik} = \frac{1}{2} \sum_{j=1}^m |\alpha_{ij} - \alpha_{kj}|$. Elementy d_{ik} tworzą symetryczną macierz $[d_{ik}]_{i,k=1,2,\dots,n}$. Podstawą podziału województw na grupy podobne ze względu na rozpatrywaną strukturę było przekształcenie macierzy $[d_{ik}]_{i,k=1,2,\dots,n}$ w binarną macierz podobieństw $[p_{ik}]_{i,k=1,2,\dots,n}$, której elementy p_{ik} są zdefiniowane następująco: $p_{ik} = \begin{cases} 0, & \text{gdy } d_{ik} < d^* \\ 1, & \text{gdy } d_{ik} \geq d^* \end{cases}$, gdzie wartości progową d^* przyjęto na

poziomie: $d^* = \frac{2 \sum_{i=1}^n \sum_{k>i}^n d_{ik}}{n(n-1)}$. Macierz $[p_{ik}]_{i,k=1,2,\dots,n}$ stanowi punkt wyjścia do

grupowania województw zgodnie z procedurą eliminacji wektorów [Chomątowski, Sokołowski, 1978].

Dla każdej grupy województw podobnych pod względem badanej struktury wyznaczono środek ciężkości.

Ponadto, miernik $v_{t/t+\tau} = \frac{1}{2} \sum_{j=1}^m |\alpha_{(t+\tau)j} - \alpha_{tj}|$, gdzie α_{tj} , $\alpha_{(t+\tau)j}$ oznacza

odpowiednio udział j składowej struktury w roku t i $t + \tau$ ($\tau \in N$) dla obiektu, wykorzystano do określenia stopnia zmian badanych struktur w całej Polsce.

WYNIKI BADAŃ


W roku 2013 średnie zróżnicowania struktury obszarowej UR województw Polski oszacowane na poziomie d^* wynosiły odpowiednio dla powierzchni i liczby gospodarstw ekologicznych: 0,233; 0,259, a dla gospodarstw rolnych: 0,333 i 0,221. Przyjmując je jako progową wartość zróżnicowania wyodrębniono

grupy województw podobnych (Rysunek 3). Środki ciężkości dla grup województw podano w Tabeli 1.


W Polsce wyróżniliśmy cztery grupy województw o podobnej strukturze obszarowej UR powierzchni gospodarstw ekologicznych, wśród których najliczniejszą grupę województw, północno-zachodniej części kraju charakteryzuje wysoki odsetek udziału UR w grupie obszarowej 100 ha i więcej. W województwach: podlaskim, mazowieckim, łódzkim i lubelskim prawie połowa powierzchni użytków rolnych jest w grupach obszarowych od 50 ha, a prawie 75% w grupach od 20 ha. Kolejne dwa województwa: małopolskie i podkarpackie przeciętny odsetek powierzchni w grupie obszarowej o największej powierzchni mają także najwyższy (na poziomie 32,4%), ale w stosunku do województw z grup I lub II struktura ta jest bardziej rozdrobniona. Grupę jednoelementową tworzy województwo świętokrzyskie, w którym połowa powierzchni UR jest w grupie obszarowej od 10 do 59,9 ha.

Rysunek 3. Grupy województw podobnych pod względem struktury powierzchni (liczby) odpowiednio gospodarstw ekologicznych i gospodarstw rolnych w Polsce, w 2013 [legenda w Tabeli 1]


Powierzchni gospodarstw ekologicznych




Liczby gospodarstw ekologicznych



Powierzchni gospodarstw rolnych



Liczby gospodarstw rolnych



Źródło: opracowanie własne na podstawie danych Eurostat

Grupę pierwszą województw podobnych pod względem liczby gospodarstw ekologicznych w grupach obszarowych UR stanowią województwa, w których dominują gospodarstwa o dużej powierzchni użytków rolnych. Granica podziału tej grupy z pozostałymi grupami jest prawie taka sama jak granica podziału dla struktury powierzchni tych gospodarstw. Jedynie województwo śląskie nie zaklasyfikowało się do grupy I, które posiada niewielką liczbę gospodarstw ekologicznych, z czego najwięcej w grupie obszarowej od 5 do 9,99 ha. W województwie podlaskim i mazowieckim ponad 1/3 gospodarstw ekologicznych ma powierzchnię od 10 do 19,99 ha, a kolejne 29,6% powierzchni UR od 20 do 49,9 ha. Z kolei w grupie trzeciej województw, gospodarstwa ekologiczne charakteryzuje mniejsza powierzchnia użytków rolnych. Województwo małopolskie wyróżnia struktura liczby gospodarstw ekologicznych w badanych grupach obszarowych, aż 67,1% tych gospodarstw ma powierzchnię poniżej 10 ha, z czego 25,5% do 5 ha.

Tabela 1. Środki ciężkości grup województw podobnych

Grupa	Grupy obszarowe UR [ha]						
	do 5	od 5 do 9,9	od 10 do 19,9	od 20 do 49,9	od 50 do 99,9	100 i więcej	
Powierzchni gospodarstw ekologicznych							
I	0,005	0,023	0,066	0,157	0,214	0,535	
II	0,012	0,061	0,183	0,259	0,138	0,348	
III	0,056	0,172	0,167	0,157	0,125	0,324	
IV	0,046	0,165	0,313	0,230	0,123	0,123	
Liczby gospodarstw ekologicznych							
I	0,046	0,115	0,219	0,289	0,158	0,173	
II	0,053	0,173	0,356	0,296	0,062	0,059	
III	0,153	0,271	0,275	0,162	0,063	0,077	
IV	0,255	0,416	0,199	0,081	0,025	0,025	
Powierzchni gospodarstw rolnych							
I	0,032	0,041	0,086	0,148	0,155	0,538	
II	0,056	0,085	0,158	0,217	0,133	0,352	
III	0,123	0,207	0,286	0,257	0,066	0,059	
IV	0,335	0,220	0,163	0,128	0,058	0,096	
Liczby gospodarstw rolnych							
I	0,132	0,187	0,221	0,368	0,075	0,017	
II	0,201	0,275	0,227	0,235	0,042	0,020	
III	0,362	0,404	0,157	0,067	0,008	0,002	

Źródło: opracowanie własne na podstawie danych Eurostat

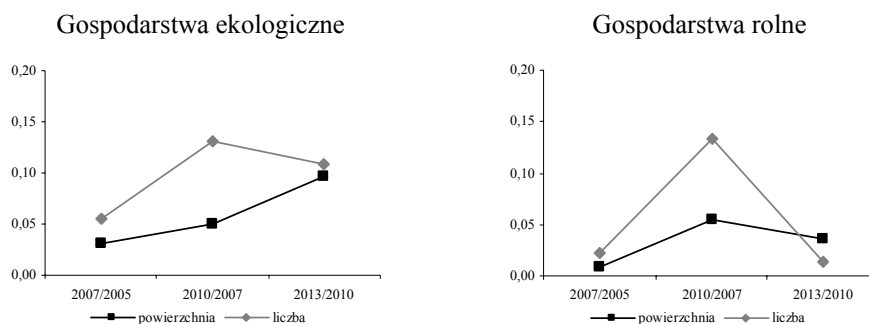
Tylko w województwie zachodniopomorskim, tworzącym grupę jednoelementową w gospodarstwach rolnych 53,8% powierzchni UR jest w gospodarstwach o powierzchni co najmniej 100 ha. Kolejna grupa województw lubuskie, polskie, dolnośląskie, warmińsko-mazurskie, pomorskie, wielkopolskie,

kujawsko-pomorskie wyróżnia się przeciętnym udziałem UR w grupie gospodarstw bardzo dużych na poziomie 35,5%. W grupie trzeciej znalazły się województwa, w których dominują gospodarstwa o powierzchni UR od 20 do 49,9 ha (podlaskie) lub 10 do 19,9 ha (mazowieckie i łódzkie). Ostatnią wyróżnioną grupę tworzą cztery województwa południowo-wschodniej Polski, w których znaczna część UR jest w grupie obszarowej do 5 ha, w szczególności w województwie małopolskim (49,8%) i podkarpackim (43,1%).

Podział gospodarstw rolnych według struktury ich liczby w grupach obszarowych UR pozwolił wyróżnić trzy grupy województw podobnych. I tak, w pierwszej grupie znalazły się województwa: podlaskie, warmińsko-mazurskie i kujawsko-pomorskie, w których dominująca liczba gospodarstw ma powierzchnię UR od 20 do 49,9 ha. Drugą grupę tworzy aż dziewięć województw, w których rozkład liczby gospodarstw w rozpatrywanych grupach obszarowych do 49,9 ha jest porównywalny. W grupie, gdzie ponad 65% gospodarstw rolnych ma powierzchnię nie większą niż 9,9 ha znalazły się województwa: świętokrzyskie, śląskie, małopolskie i podkarpackie.

Wartości miary $v_{t/t+\tau}$ wskazują, że w Polsce w latach 2005-2013 brak stabilizacji badanych struktur (Rysunek 4). Zmiany struktury zarówno liczby gospodarstw rolnych ogółem jak i liczby gospodarstw ekologicznych wg grup obszarowych UR były znaczące w roku 2010 w porównaniu do 2007 roku i na prawie identycznym poziomie, przy czym w kolejnych latach (do 2013 roku) ta pierwsza prawie nie zmieniała się, a ta druga dalej zmieniała się. Mniejszym zmianom ulegała struktura powierzchni gospodarstw ekologicznych niż ich liczby, z tendencją do zwiększania się zmian w kolejnych badanych latach. Struktura powierzchni gospodarstw rolnych w roku 2007 w stosunku do 2005 roku praktycznie nie zmieniła się. Natomiast w kolejnych latach zmiany były zauważalne.

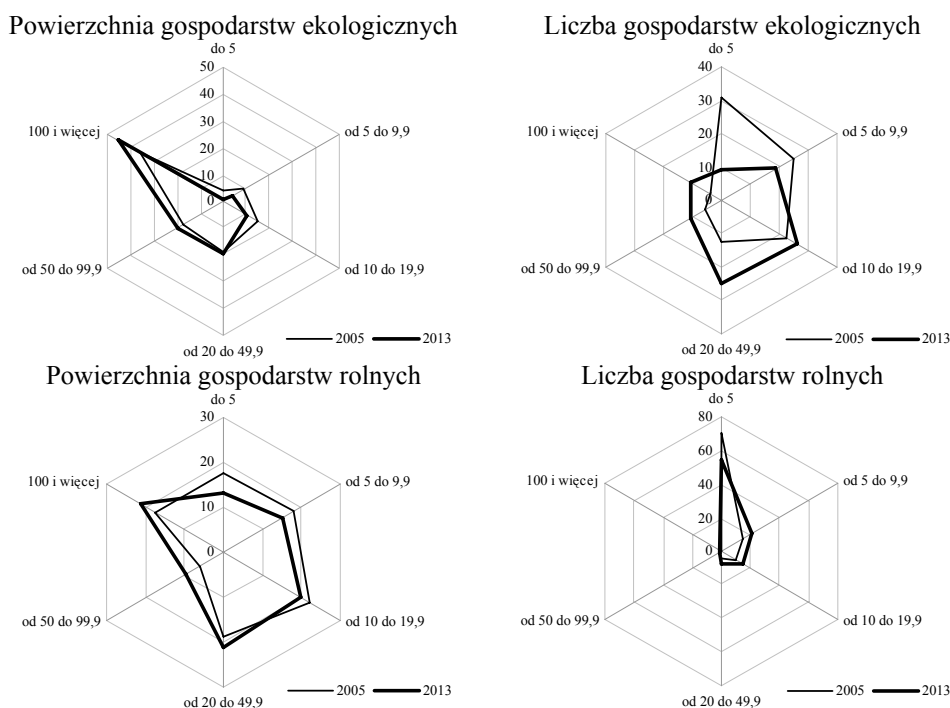
Rysunek 4. Przebieg zmian wartości miernika dynamiki struktury obszarowej liczby (powierzchni) gospodarstw ekologicznych i rolnych w Polsce ($v_{t/t+\tau}$)



Źródło: opracowanie własne na podstawie danych Eurostat

Wszystkie te zmiany w latach 2005-2013 wpływały na zwiększenie udziału UR w grupie obszarowej UR o powierzchni 20 ha i więcej, zarówno w gospodarstwach rolnych jak i ekologicznych oraz zmniejszeniu liczb tych gospodarstw w grupie obszarowej do 5 ha lub do 9,9 ha (Rysunek 5).

Rysunek 5. Odsetki wybranych charakterystyk gospodarstw w grupach obszarowych UR w Polsce w 2005 i 2013 roku



Źródło: opracowanie własne na podstawie danych Eurostat

WNIOSKI

Obraz struktury obszarowej gospodarstw rolnych, w tym także gospodarstw ekologicznych dokonany na bazie zarówno ich liczby jak i powierzchni w poszczególnych grupach obszarowych UR umożliwia wyciągnięcie następujących wniosków:

1. Rolnictwo oparte na ekologicznych metodach wytwarzania tak jak i rolnictwo ogółem jest regionalnie zróżnicowane.
2. Potencjał rolnictwa, w tym także rolnictwa ekologicznego jest mniejszy w województwach południowo-wschodniej Polski.

3. Zmiany w analizowanych strukturach w Polsce, zarówno dla gospodarstw rolnych ogółem jak i dla gospodarstw ekologicznych zmierzają do koncentracji ziemi i zmniejszania liczby gospodarstw o małej powierzchni.
4. Największym zmianom w latach 2005-2013 ulegała struktura liczby gospodarstw ekologicznych w grupach obszarowych UR. W badanym okresie zmniejszył się udział liczby gospodarstw z grup obszarowych o powierzchni poniżej 9,9 ha.

BIBLIOGRAFIA

- Chomałowski S., Sokołowski A. (1978) Taksonomia struktur, *Przegląd Statystyczny* 2, 217-226.
- Kopiński J., Krasowicz S. (2010) Regionalne zróżnicowanie warunków produkcji rolniczej w Polsce, *Studia i Raporty IUNG-BIP* 22, 9-29.
- Kopiński J., Matyka M. (2016) Ocena regionalnego zróżnicowania współzależności czynników przyrodniczych i organizacyjno-produkcyjnych w polskim rolnictwie, *Zagadnienia Ekonomiki Rolnej* 1 (346), 57-79.
- Kukuła K., red. (2010) *Statystyczne studium struktury agrarnej w Polsce*, Wydawnictwo Naukowe PWN, Warszawa.
- Kukuła K. (1989) *Statystyczna analiza strukturalna i jej zastosowanie w sferze usług produkcyjnych dla rolnictwa*, Zeszyty Naukowe AE w Krakowie, Seria specjalna: Monografie, 89, Kraków.
- Matyka, M., Krasowicz, S., Kopiński, J., Kuś, J. (2013) Regionalne zróżnicowanie zmian produkcji rolniczej w Polsce, *Studia i Raporty IUNG-PIB* 32(6), 143-165.
- Pięta P. (2007) Renty strukturalne jako instrument zmiany struktury agrarnej w Polsce, *Acta Scientiarum Polonorum, Oeconomia* 6 (4) 2007, 39-47.
- Poczta W., Bartkowiak N. (2012) Regionalne zróżnicowanie rolnictwa polskiego, *Journal of Agribusiness and Rural Development* 1(23), 95-109.
- Rudnicki R., Wiśniewski Ł., Kluba M. (2015) Poziom i struktura rolnictwa polskiego w świetle wyników Powszechnego Spisu Rolnego 2010, *Roczniki Naukowe Seria 17* (3), 335-343.
- Stany M. (2013) *Przestrzenne zróżnicowanie rozwoju obszarów wiejskich w Polsce*, IRWiR-PAN, Warszawa.
- <http://ec.europa.eu/eurostat>

REGIONAL DIVERSIFICATION OF THE STRUCTURE AREA OF UTILIZED AGRICULTURAL AREA IN POLAND

Abstract: The purpose of this paper was to present the regional diversification of the structure area of utilized agricultural area (UAA) of organic farms compared to the diversification of the structure area of agricultural holdings with UAA in total in Poland. It was based both on the number and area of farms in the area groups of UAA. The vectors' elimination method was used for the division of voivodeships into subsets similar in terms of analysed structures. In addition, it was investigated the dynamics of these structures in Poland after accession to the European Union. The analysis showed that agriculture, in particular based on organic methods of production is regionally diversified. Changes of the structures in Poland tend to land concentration and reduce the number of farms with a small area of UAA, significantly including organic farms .

Keywords: taxonomy of structures, dynamics of structures, organic farming, regional diversification

ZRÓŻNICOWANIE OBSZARÓW WIEJSKICH W POLSCE – UJĘCIE REGIONALNE

Kesra Nermend

Katedra Metod Komputerowych w Ekonomii Eksperymentalnej
Uniwersytet Szczeciński
e-mail: kesra@wneiz.pl

Danuta Milaszewicz

Katedra Makroekonomii
Uniwersytet Szczeciński
dmilasz@wneiz.pl

Streszczenie: W artykule przedstawiono zastosowanie arytmetyki przyrostów w konstrukcji wektorowej miary syntetycznej do badania jednorodności czasowej zróżnicowania rozwoju obszarów wiejskich w ujęciu regionalnym w Polsce. W konstrukcji miernika zastosowano parę uporządkowaną: przyrost wartości średniej oraz przyrost odchylenia standardowego. Dzięki temu uzyskano dla każdej wartości miary dodatkową informację mówiącą o jednorodności rozwoju obszarów wiejskich polskich regionów NUTS2.

Słowa kluczowe: wektorowa miara syntetyczna, taksonomia, arytmetyka przyrostów, badania regionalne, jednorodność regionów

WPROWADZENIE

Problematyka jednorodności czasowej i zróżnicowanie rozwoju regionów stała się ważnym zagadnieniem, zwłaszcza od czasu funkcjonowania Polski jako pełnoprawnego członka Unii Europejskiej. Wejście Polski w struktury europejskie wiąże się z ogromnymi korzyściami dla całej gospodarki i poszczególnych regionów. Jednocześnie należy pamiętać, że uzyskanie korzyści politycznych, gospodarczych, finansowych czy społeczno-kulturalnych wymagało od Polski ogromnej pracy polegającej na dostosowaniu się do standardów, jakie panują w strukturach krajów unijnych. Pozwoliło to na korzystanie ze współfinansowania środkami UE rozwoju polskich regionów.

W każdym województwie Polski obszary wiejski stanowią znaczną jego część. Jednym z ważniejszych narzędzi polityki rozwojowej UE okazuje się zatem Wspólna Polityka Rolna (WPR). Dzięki bezpośrednim dopłatom do produkcji rolnej i środkom zarządzania rynkami rolnymi (tzw. pierwszy filar WPR) oraz finansowaniu w ramach polityki rozwoju obszarów wiejskich (tzw. drugi filar WPR) programów ich restrukturyzacji i modernizacji nastąpiło przyspieszenie rozwoju i korzystne strukturalne przeobrażenia polskiej wsi.

Zmiany te, chociaż pozytywne, nie miały jednak jednolitego charakteru oraz tempa w przekroju geograficznym. Obok panujących w regionach zróżnicowanych warunków wyjściowych procesów rozwojowych, przyczyniały się one do zróżnicowania aktualnego poziomu rozwoju obszarów wiejskich, które w dalszym ciągu pod bardzo wieloma względami są słabiej rozwinięte od obszarów miejskich oraz dostrzegalne jest duże zróżnicowanie ich rozwoju w ujęciu regionalnym.

W artykule autorzy podejmują próbę zbadania zróżnicowania rozwoju obszarów wiejskich w polskich województwach oraz dynamiki zachodzących w nich przemian, po upływie sześciu lat od wstąpienia Polski w struktury Unii Europejskich, czyli w okresie 2010-2014.

Badanie rozwoju obszarów wiejskich w Polsce prowadzone były dotychczas wielokrotnie przez różnych autorów i dotyczyły różnych jego kontekstów: teoretycznych podstaw [Mazurek 2010], wielowymiarowości [Agrotec-PAN IGiPZ 2012] zrównoważenia [Staniak 2009; Żmija 2014], kapitału ludzkiego [Bagieńska 2010], wielofunkcyjności [Salamon 2005; Sikora 2012], efektów wsparcia UE [Zawalińska 2009], poziomu życia [Müller-Frączek i Muszyńska 2015], rolnictwa [Binderman 2008; Binderman 2013; Krasowicz 2009] jego produktywności [Rusielik 2015] oraz zachodzących w nim przemian strukturalnych [Dzun 2011]. W roku 2012 Fundacja Europejski Fundusz Rozwoju Wsi Polskiej, w ramach Forum Inicjatyw Rozwojowych zapoczątkowała badania monitorujące rozwój społeczno-gospodarczy obszarów wiejski, których efekty opublikowano w 2014 roku. Celem tego monitoringu, który ma być powtarzany w cyklu 2-letnim, jest systematyczna obserwacja zmian zachodzących na obszarach wiejskich na poziomie gmin, wskazanie barier utrudniających ten rozwój oraz zdefiniowanie przyszłych kierunków rozwoju tych obszarów. Dzięki temu monitoringowi możliwe jest ukazanie przestrzennego zróżnicowania obszarów wiejskich na terenie Polski. W opracowaniu z 2014 roku podano także typologię tych obszarów, z której wynika, że największa część obszarów wiejskich pełni funkcje rolnicze [Forum Inicjatyw Rozwojowych 2014]. Są to obszary o wybitnie rolniczym charakterze lub obszary, na których rolnictwo należy do funkcji wiodących.

Pamiętając o wielofunkcyjności współczesnych obszarów wiejskich wydaje się zatem, że można przyjąć założenie, iż zmienne ukazujące rozwój rolnictwa, określają także w znacznym stopniu polskie obszary wiejskie. Wykorzystując zatem 14 wybranych zmiennych charakteryzujących obszary wiejskie i rolnictwo, w artykule skupiono się na klasyfikacji tych obszarów w ujęciu regionalnym [NUTS2]. Wskaźniki opisujące obszary wiejskie w ujęciu regionalnym mogą

charakteryzować się wahaniami w czasie, co jest wynikiem zachodzących zmian wynikających z ich funkcjonowania i rozwoju. Obok zdiagnozowania zróżnicowania przestrzennego rozwoju obszarów wiejskich w regionach, ukazano zatem także metodykę badania jednorodności czasowej tego procesu. Badanie jednorodności czasowej pozwala na zaobserwowanie jak te zmiany oraz ich równomierność zachodzenia w czasie przyczyniły się do postępów rozwojowych badanych obszarów.

Zmiany w czasie poziomu rozwoju społeczno-gospodarczego obszarów wiejskich w ujęciu regionalnym z punktu widzenia jednorodności mogą mieć duży wpływ na ich miejsca w rankingu. Stąd badania dynamiki zmian oraz ich klasyfikacja pod kątem jednorodności czasowej staje się ważnym zagadnieniem, którego zakres wykorzystania może być bardzo duży w procesie zarządzania danym regionem i jego rozwojem. Dla uwypuklenia problemu jednorodności czasowej przeprowadzono badanie porównawcze w dwóch obszarach:

- klasyfikacji oraz badania dynamiki rozwoju obszarów wiejskich w województwach polskich z wykorzystaniem metody wektorowej do budowy miar agregatowych VMCM (Vector Measure Construction Method),
- klasyfikacji obszarów wiejskich w polskich regionach NUTS2 z uwzględnieniem jednorodności czasowej ich rozwoju, z wykorzystaniem metody VMCM-ARI (Vector Measure Construction Method and ARithmetic of Increments).

Klasyfikacja regionów jest możliwa do ustalenia po wcześniejszym określeniu poziomu rozwoju społeczno-gospodarczego analizowanych obiektów. W tym zakresie wykorzystuje się m.in. metody porządkowania liniowego. Jedną z najbardziej popularnych dziś metod porządkowania liniowego zaproponował Z. Hellwig [1968]. Pozwala ona na obliczenie syntetycznego wskaźnika, określanego mianem syntetycznej miary Hellwiga, która znalazła szereg zastosowań. Do badania zróżnicowania rozwoju obszarów wiejskich w polskich województwach w artykule wykorzystano natomiast metody, które umożliwiają nie tylko uporządkowanie regionów pod względem poziomu rozwoju obszarów wiejskich, ale także badanie dynamiki zachodzących zmian i ich niejednorodności czasowej. Inne podejście do badania dynamiki rozwoju na przykładzie rolnictwa wykorzystano w opracowaniu [Binderman 2013].

BADANIE DYNAMIKI ROZWOJU OBSZARÓW WIEJSKICH W POLSKICH WOJEWÓDZTWACH

Do badania dynamiki rozwoju obszarów wiejskich wykorzystana została metoda VMCM [Kolenda 2006; Nermend 2006a, 2006b; 2008a, 2008b]. Jej zaletą jest duża elastyczność aplikacji w ekonomii, co szczególnie daje się zauważyć w odmianie tej metody wykorzystującej wyłącznie iloczyn skalarny [Nermend 2008c; Nermend 2007]. W takim ujęciu do wyznaczenia wektorowej miary

agregatywnej można wykorzystać dowolny iloczyn skalarny. Procedura badawcza przy budowie miary dynamiki rozwoju obszarów wiejskich wykorzystana w artykule składała się z pięciu etapów: wyboru, eliminacji i normowania zmiennych, wyznaczenia wzorca i antywzorca oraz budowy wektorowej miary agregatywnej.

Do badań wybrano 14 zmiennych z horyzontu czasowego 2010-2014. Dane pochodzą z publikacji z lat 2011-2015 pt. *Rolnictwo i gospodarka żywnościowa w Polsce, Roczników statystycznych rolnictwa oraz Roczników statystycznych województw*. Analizowane zmienne charakteryzują różne obszary rozwoju rolnictwa i obszarów wiejskich w regionach. Pierwsze trzy zmienne to wskaźniki ogólnie charakteryzujące gospodarstwa rolne w regionach:

X_1 – ilość gospodarstw rolnych na 1000 mieszkańców; X_2 – przeciętna powierzchnia gospodarstwa rolnego (w ha użytków rolnych); X_3 – przeciętny miesięczny dochód rozporządzalny na 1 osobę w gospodarstwach domowych uzyskiwany z gospodarstwa indywidualnego w rolnictwie.

Następne pięć zmiennych to grupa wskaźników charakteryzujących infrastrukturalno-techniczne warunki gospodarowania i życia na obszarach wiejskich:

X_4 – wskaźnik zwodociągowania obszarów wiejskich (w %); X_5 – wskaźnik skanalizowania obszarów wiejskich (w %); X_6 – nakłady inwestycyjne na 1 ha użytków rolnych (w zł); X_7 – powierzchnia zmeliorowanych użytków rolnych (w % ogólnej powierzchni użytków rolnych); X_8 – powierzchnia użytków rolnych przypadająca na 1 ciągnik (w ha).

Ostatnie sześć zmiennych posłużyły do określenia zasobów ludzkich na obszarach wiejskich i można je uznać za grupę wskaźników o charakterze ekonomiczno-społecznym:

X_9 – przeciętna długość życia mężczyzn (w latach); X_{10} – przeciętna długość życia kobiet (w latach); X_{11} – pracujący na 100 ha użytków rolnych (ilość osób); X_{12} – stopa bezrobocia na wsi (w %); X_{13} – ludność w wieku nieprodukcyjnym na 100 osób w wieku produkcyjnym; X_{14} – saldo migracji wewnętrznej na wsi (ilość osób).

W rozpatrywanym okresie nie dla wszystkich wskaźników dostępne były corocznie publikowane dane. Brakujące dane uzupełniono z wykorzystaniem regresji liniowej na podstawie kształtowania się ich wielkości w kolejnych latach. Uzupełniono w ten sposób brakujące wartości danych dla zmiennej X_8 w latach 2011 i 2012 oraz zmiennej X_1 w roku 2010.

Z 14 wskaźników, 13 miało współczynnik istotności cech we wszystkich latach na poziomie większym niż 0,1 ($X_1 - X_{13}$). Wskaźnik X_{14} miał w latach 2010 i 2011 współczynnik istotności cech na poziomie niższym niż 0,1. Wartość 0,1 przyjęto jako próg odrzucenia wskaźnika. Przy czym przyjęto, że wskaźniki zostają odrzucone, jeżeli we wszystkich latach wartość współczynnika istotności będzie mniejsza niż 0,1. Dlatego ostatecznie nie odrzucono żadnego wskaźnika.

Wskaźniki X_1 – X_7 , X_9 , X_{10} , X_{14} mają charakter stymulanty, a pozostałe (X_8 , X_{11} – X_{13}) charakter destymulanty. Jako rok odniesienia przyjęto 2010 rok. W związku z tym podczas standaryzacji wartości średniej i odchylenia standardowego wyliczono dla 2010 roku i użyto ich do standaryzacji wszystkich lat. Wzorzec i antywzorzec były wyznaczone z roku odniesienia z wykorzystaniem I i III kwartyła.

W Tabeli 1 przedstawiono wartości miary i wyniki klasyfikacji województw. Z tabeli wynika, że w analizowanym okresie w polskim rolnictwie nastąpił znaczny rozwój – wartość miary wzrosła z 0,573 w 2010 roku do 0,911 w 2014 roku. W badanym okresie nastąpił dynamiczny rozwój obszarów wiejskich w ujęciu regionalnym. Wzrost poziomu rozwoju zanotowano we wszystkich województwach, a 15 z nich osiągnęło w 2014 roku rozwój na poziomie wyższym niż przeciętny dla Polski w 2010 roku. Jedynie dla województwa lubelskiego wartość miary rozwoju obszarów wiejskich uzyskana w 2014 roku była mniejsza niż dla całej Polski w 2010 roku.

Tabela 1. Wartości miary wektorowej i przynależność województw do klas w latach 2010 – 2014

Województwo	2010		2011		2012		2013		2014	
	Miara	Klasa	Miara	Klasa	Miara	Klasa	Miara	Klasa	Miara	Klasa
Wielkopolskie	1,064	1	1,090	1	1,271	1	1,322	1	1,495	1
Opolskie	0,800	1	0,864	1	1,058	1	0,979	1	1,274	1
Pomorskie	0,774	1	0,808	2	0,956	1	1,022	1	1,148	1
Śląskie	0,670	2	0,762	2	0,846	2	0,859	2	0,975	2
Małopolskie	0,644	2	0,670	2	0,575	3	0,693	3	0,733	3
Mazowieckie	0,623	2	0,712	2	0,689	2	0,866	2	0,932	2
Kujawsko-pomorskie	0,577	2	0,533	3	0,752	2	0,681	3	0,818	3
P O L S K A	0,573	2	0,604	2	0,700	2	0,771	2	0,911	2
Dolnośląskie	0,518	3	0,593	2	0,663	3	0,709	3	0,835	3
Łódzkie	0,470	3	0,596	2	0,555	3	0,751	2	0,815	3
Lubuskie	0,468	3	0,197	4	0,554	3	0,446	4	0,786	3
Warmińsko-mazurskie	0,442	3	0,245	4	0,485	3	0,467	3	0,811	3
Podkarpackie	0,430	3	0,489	3	0,441	3	0,509	3	0,618	4
Podlaskie	0,396	3	0,610	2	0,690	2	0,776	2	0,842	3
Zachodnio-pomorskie	0,252	4	0,089	4	0,538	3	0,544	3	0,913	2
Lubelskie	0,188	4	0,181	4	0,300	4	0,369	4	0,468	4
Świętokrzyski	0,163	4	0,326	3	0,453	3	0,416	4	0,644	3

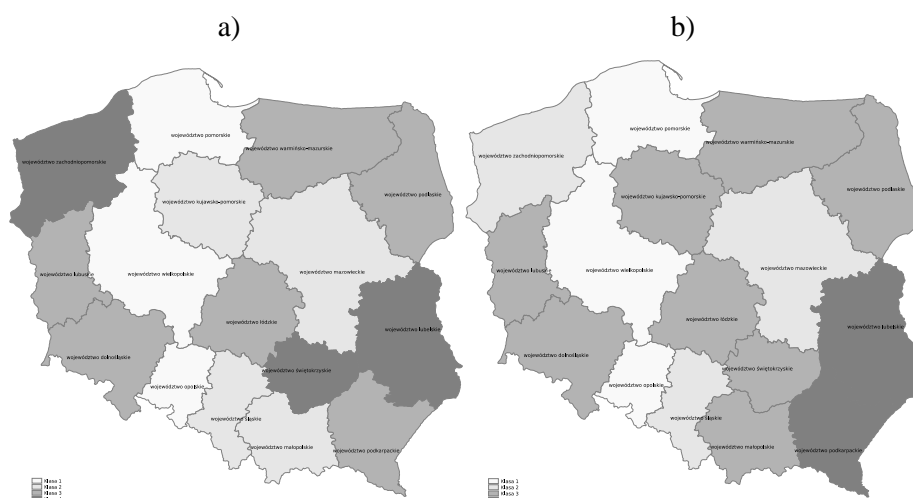
Źródło: opracowanie własne na podstawie wyników analizy

Z danych zawartych w Tabeli 1 wynika, iż rozwój obszarów wiejskich w polskich województwach w latach 2010 – 2014 miał charakter wzrostowy, ale niejednorodny. W roku 2013 w części województw odnotowano jednak

zahamowanie rozwoju, a nawet jego spadek (opolskie, kujawsko-pomorskie, lubuskie, warmińsko-mazurskie, świętokrzyskie), a w innych tylko bardzo niewielki wzrost (śląskie, małopolskie, podlaskie, zachodniopomorskie). W roku 2014 we wszystkich województwach odnotowano natomiast wyższy poziom rozwoju.

Rysunek 1. Wizualizacja uzyskanych wyników oceny poziomu rozwoju w roku:

a) 2010, b) 2014



Źródło: opracowanie własne na podstawie wyników przeprowadzonej analizy

Z Rysunku 1 wynika, iż w 2010 roku rozwój obszarów wiejskich w centralnej Polsce był wyższy niż na ścianie zachodniej i wschodniej kraju. W roku 2014, na tle innych województw, szczególnie poprawiała się sytuacja w województwie zachodniopomorskim, dla którego wektorowa miara agregatowa najbardziej zwiększyła swoją wartość (z 0,252 do 0,913).

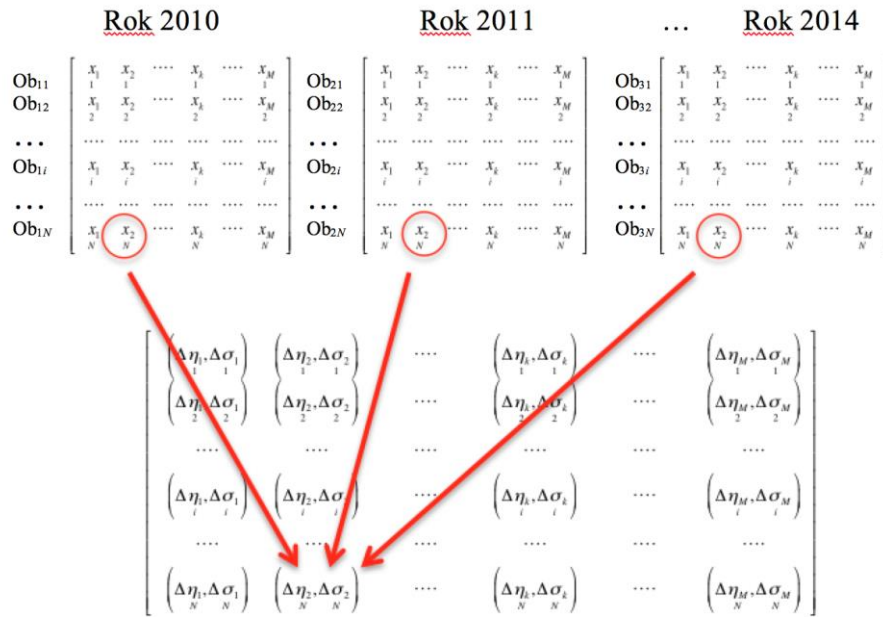
BADANIE JEDNORODNOŚCI CZASOWEJ ROZWOJU OBSZARÓW WIEJSKICH W POLSKICH WOJEWÓDZTWACH

Do badania jednorodności czasowej rozwoju obszarów wiejskich w polskich regionach NUTS2 wykorzystano metoda VMCM-ARI zaproponowaną przez M. Borawskiego [Borawski 2012]. W zależności od przyjętego sposobu obliczenia, uzyskuje się informację o jednorodności zbioru obiektów składających się na analizowany obiekt, np. jednorodności gmin wiejskich w ramach województwa czy, tak jak w tym opracowaniu, wielkości zmian wartości miary rozwoju na przestrzeni lat, co przedstawiono na Rysunku 2.

Obliczenia są wykonywane w przestrzeni wektorowej, w której wymogiem jest, aby dla każdego elementu istniał element przeciwny. Jeżeli przyjmie się pary

uporządkowane: wartość średnia, odchylenie standardowe i wartość średnia, wariancja, jako elementy opisujące wektor, to konsekwencją tego faktu jest konieczność przyjmowania przez nie wartości ujemnych. W związku z tym operacje arytmetyczne nie mogą być wykonywane na odchyleniach arytmetycznych i wariancjach, ale muszą być wykonywane na ich różnicach, zwanych dalej przyrostami, które mogą przyjmować wartości ujemne.

Rysunek 2. Macierz dwójek uporządkowanych przy badaniu jednorodności czasowej



Źródło: opracowanie własne

Wartość średnia, odchylenie standardowe i wariancja są zamieniane na ich przyrosty. Wykonuje się to poprzez wyznaczenie różnicy pomiędzy uzyskaną wartością średnią, odchyleniem standardowym i wariancją a ich punktami odniesienia. Powstają w ten sposób dwójki uporządkowane:

$$\begin{pmatrix} \Delta \eta_j \\ \Delta \sigma_j \end{pmatrix} = \begin{pmatrix} \eta_j - \eta_o \\ \sigma_j - \sigma_o \end{pmatrix}, \quad (1)$$

gdzie η_o , i σ_o są punktami odniesienia, odpowiednio dla przyrostu wartości średniej i przyrostu odchylenia standardowego, oraz:

$$\begin{pmatrix} \Delta \eta_j \\ \Delta \sigma_j^2 \end{pmatrix} = \begin{pmatrix} \eta_j - \eta_o \\ \sigma_j^2 - \sigma_o^2 \end{pmatrix}. \quad (2)$$

Punkty odniesienia mogą być obrane dowolnie, powinny jednak być identyczne dla wszystkich przyrostów wartości średnich i podobnie, identyczne dla wszystkich przyrostów odchyłeń standardowych i przyrostów wariancji. Najwygodniej przyjąć je jako równe zero. Można wówczas w łatwy sposób dodając zero, zamienić przyrosty na wartości średnie, odchylenia standardowe i wariancje. Szerzej operacje na dwójkach uporządkowanych i metoda VMCM-ARI są opisane w [Borawski 2012; Nermend i Tarczyńska-Łuniewska 2013].

W przeprowadzonym badaniu, dla każdego roku analizy, wyznaczono wartości średnie i odchylenia standardowe dla danych charakteryzujących obszary wiejskie. Aby otrzymać przyrosty odjęto od nich zero. Wartości średnie i przyrosty wartości średnich reprezentują średni poziom wartości wskaźników dla województw w badanych latach. Natomiast odchylenia standardowe oraz ich przyrosty określają zmienność czasową badanych obiektów, czyli zmienność rozwoju obszarów wiejskich województw w badanych latach. Dzięki takiemu podejściu można wnioskować jak duże były zmiany poszczególnych wskaźników charakteryzujących rozwój obszarów wiejskich w badanych latach. Wyznaczone przyrosty odchyłeń standardowych określają bezpośrednio wahania wskaźników, a nie miary agregatowej. Podejście to pozwala na badania tych zmian, które nastąpiły w tych obszarach, na podstawie wybranych do badań wskaźników. Uzyskana miara agregatowa pozwala odpowiedzieć na pytanie czy badane zjawisko było stabilne (jednorodne) w czasie.

Wskaźniki opisujące obiekty mogą charakteryzować się wahaniami w czasie, co jest wynikiem zmian w nich zachodzących w przestrzeni czasowej, wynikających z procesu ich funkcjonowania i rozwoju. Konieczne może być zatem badanie jednorodności czasowej pozwalające na obserwowanie jak te zmiany następowały, a ich równomierność zachodzenia w czasie umożliwi określenie stopnia zmian rozwoju obiektu. Zmiany w poziomie rozwoju obiektów w czasie mogą mieć duży wpływ na ich miejsca w rankingu, które będzie zależęć od okresu przeprowadzenia badania. W pewnych okresach dany obiekt może mieć wysokie miejsce w rankingu, a w innych niskie. Szczegółowy opis metody jest analizy jednorodności czasowej obiektów jest opisany w publikacji [Nermend i Tarczyńska-Łuniewska 2013].

Badania jednorodności czasowej rozwoju obszarów wiejskich przeprowadzono na tym samym zestawie 14 wskaźników. Uzyskane wyniki przedstawiono w Tabeli 2. Największą zmiennością wykazały się dwa województwa: zachodniopomorskie i lubuskie. Zmiany w tych województwach w latach 2010-2014 były największe. Najmniejsza zmienność wystąpiła w województwach wielkopolskim, mazowieckim, łódzkim i lubelskim. Jest to niekorzystna sytuacja szczególnie dla województwa lubelskiego, gdyż zajmuje ono ostatnie miejsce w rankingu pod względem rozwoju obszarów wiejskim, a dynamika zmian jego rozwoju w analizowanym okresie była niewielka. Biorąc pod uwagę wyniki poprzedniego badania (wektorowej miary syntetycznej rozwoju), z których wynika, że nastąpiło polepszenie wskaźników dla wszystkich


województw, jednak niewielkie dla województwa lubelskiego, można stwierdzić, że także w tym względzie województwo to negatywie odstaje od pozostałych.

Tabela 2. Wartości miar w metodzie VMCM-ARI oraz przynależność województw do klas w latach 2010 – 2014

Województwo	Miara: średnia	Miara: odchylenie	Klasa: średnia	Klasa: odchylenie
Wielkopolskie	1,008	0,074	1	4
Opolskie	0,841	0,097	1	2
Pomorskie	0,726	0,092	2	2
Śląskie	0,678	0,096	2	2
Małopolskie	0,601	0,096	2	2
Mazowieckie	0,576	0,071	2	4
P O L S K A	0,552	0,066	2	4
Podlaskie	0,519	0,084	3	3
Kujawsko-pomorskie	0,512	0,089	3	3
Dolnośląskie	0,498	0,083	3	3
Łódzkie	0,470	0,066	3	4
Podkarpackie	0,419	0,089	3	3
Warmińsko-mazurskie	0,336	0,097	3	2
Lubuskie	0,325	0,107	3	1
Świętokrzyskie	0,306	0,084	4	3
Zachodniopomorskie	0,273	0,119	4	1
Lubelskie	0,209	0,068	4	4

Źródło: opracowanie własne na podstawie wyników analizy

Rysunek 3. Wizualizacja otrzymanych wyników analizy dla przyrządów: a) wartości średniej, b) odchylenia standardowego



Źródło: opracowanie własne na podstawie wyników analizy

Na Rysunku 3a przedstawiono klasyfikację obszarów wiejskich według województw ze względu na ich średni poziom rozwoju, a na Rysunku 3b klasyfikację ze względu na jednorodność ich rozwoju w czasie.

Z przedstawionego rankingu wynika, iż w latach 2010-2014 rozwój obszarów wiejskich w centralnej Polsce był najbardziej stabilny. Najwyższe miejsca w rankingu zajęły województwa wielkopolskie i śląskie. Z tych dwóch województw większą niejednorodnością charakteryzuje się województwo śląskie (klasa 2). Za interesujący wynik przeprowadzonych badań można uznać fakt, że dwa województwa leżące w pasie granicznym na ścianie zachodniej (województwo zachodniopomorskie i lubuskie) z punktu widzenia poziomu rozwoju sklasyfikowane jako średnio i słabo rozwinięte na tle innych (Rysunek 3a), charakteryzowała najwyższa niejednorodność czasowa rozwoju (Rysunek 3b).

WNIOSKI

W artykule przedstawiono metodykę badania poziomu, dynamiki zmian i jednorodności czasowej rozwoju obszarów wiejskich w Polsce w ujęciu regionalnym. Po weryfikacji metody VMCM, podczas klasyfikacji województw według miary agregatowej, obliczonej na podstawie wybranych wskaźników charakteryzujących obszary wiejskie, wykazano, że w badanym okresie nastąpił znaczący postęp ich rozwoju.

Biorąc pod uwagę, że rozwój jest długookresowym procesem zachodzącym w czasie, przy badaniu poziomu rozwoju uzasadnione także wydaje się zwrócenie uwagi na tempo zmian rozwojowych oraz na ich ciągłość. Od tych dwóch elementów charakteryzujących procesy przemian rozwojowych uzależniona jest przecież końcowa ocena badanych obiektów i tworzony ich ranking. Możliwość oceny jednorodności czasowej rozwoju daje wykorzystana w artykule metoda VMCM-ARI. Uzyskane, dzięki jej zastosowaniu, wyniki analizy jednorodności czasowej rozwoju obszarów wiejskich w polskich regionach dały możliwość wskazania województw, w których rozwój obszarów wiejskich następował w badanym okresie z większą (lub mniejszą) dynamiką niż w pozostałych. Wydaje się to być istotna informacja nie tylko z punktu widzenia możliwości pogłębienia analizy porównawczej, ale także z punktu widzenia polityki rozwoju regionalnego prowadzonej na szczeblu państwa oraz strategii rozwojowych i zarządzania rozwojem na poziomie jednostek samorządu terytorialnego.

Metody VMCM oraz VMCM-ARI zastosowane w artykule do oceny poziomu, dynamiki i jednorodności czasowej rozwoju polskich obszarów wiejskim z powodzeniem mogą być wykorzystane w analizie innych zjawisk i obiektów ekonomicznych. Ich potencjalna użyteczność wydaje się być bardzo duża.

BIBLIOGRAFIA

- Agrotec-PAN IGiPZ (2012) Szanse i zagrożenia oraz potencjalne kierunki rozwoju obszarów wiejskich w Polsce w ujęciu regionalnym. Raport podsumowujący. Agrotec Polska Sp. z o.o. & Instytut Geografii i Przestrzennego Zagospodarowania PAN, Warszawa.
- Bagieńska A. (2010) Kapitał ludzki jako czynnik rozwoju obszarów wiejskich, w: B. Kryk (red.) Zrównoważony rozwój obszarów wiejskich wybrane aspekty społeczne, Szczecin, Economicus, str. 11-36.
- Binderman A. (2008) Zastosowanie liniowej i nieliniowej funkcji użyteczności do badania poziomu rolnictwa w Polsce, MIBE IX, str. 29-38.
- Binderman A. (2011) Wielokryterialne metody analizy różnicowania polskiego rolnictwa w 2009 roku, MIBE XII, 2, str. 58-68.
- Binderman A. (2013) Dynamika regionalnego różnicowania rolnictwa w Polsce w latach 1998-2010, Metody Ilościowe w Badaniach Ekonomicznych, t. XIV/3, str. 17-26.
- Borawski M. (2012) Vector space of increments, Control and Cybernetics, No. 1.
- Dzun W. (2011) Przemiany strukturalne w rolnictwie polskim, w: M. Drygas (red.), Rozwój obszarów wiejskich w Polsce. Diagnozy, strategie, koncepcje polityki, Instytut Rozwoju Wsi i Rolnictwa Polskiej Akademii Nauk Warszawa, str. 125-154.
- Forum Inicjatyw Rozwojowych (2014) Monitoring rozwoju obszarów wiejskich w Polsce. Etap I. Synteza.
http://www.efrwp.pl/dir_upload/photo/4686b84733f0c98e118138122248.pdf
- Hellwig Z. (1968) Zastosowanie metody taksonomicznej do typologicznego podziału krajów ze względu na poziom ich rozwoju oraz zasoby i strukturę wykwalifikowanych kadr, Przegląd Statystyczny, nr 4.
- Kolenda M. (2006) Taksonomia numeryczna. Klasyfikacja, porządkowanie i analiza obiektów wielocechowych. Wrocław, Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu.
- Krasowicz S. (2009) Regionalne różnicowanie zmian w rolnictwie polskim, Studia i Raporty IUNG-PIB, z. 15, str. 9-37.
- Kukuła K. (2000) Metoda unitaryzacji zerowanej. Warszawa, PWN.
- Mazurek J. (2010) Rozwój obszarów wiejskich w Polsce – przegląd koncepcji teoretycznych, Zeszyty Naukowe Instytutu Ekonomii i Zarządzania, nr 14, str. 61-81.
- Müller-Frączek I., Muszyńska J. (2015) Zastosowanie porządkowania hierarchicznego do oceny regionalnego różnicowania poziomu życia na wsi, Metody Ilościowe W Badaniach Ekonomicznych, t. XVI/4, str. 54-63.
- Nermend K., Borawski M. (2006) Using average-variance number system in calculation of a synthetic development measure, Polish Journal of Environmental Studies, Vol. 15, No. 4C, p. 127-130.
- Nermend K. (2006a) A synthetic measure of sea environment pollution, Polish Journal of Environmental Studies, Vol. 15 no 4b 2006, str. 127-129.
- Nermend K. (2006b) Using average-variance representation in economic analyses, Polish Journal of Environmental Studies, Vol. 15, No. 4C, 2006, p. 123-126.
- Nermend K. (2007) Taxonomic Vector Measure of Region Development (TWMRR). Polish Journal of Environmental Studies, no. 4A.

- Nermend K. (2008a) Employing similarity measures to examine the development of technical infrastructure in Polish counties. *Folia Oeconomica Stetinensia*, Vol. 15, No. 7, 2008, p. 87-97.
- Nermend K. (2008b) Zastosowanie rzutu wektora do budowy miernika syntetycznego. *Przegląd Statystyczny*, no. 3.
- Nermend K. (2008c) Rachunek wektorowy w analizie rozwoju regionalnego. Szczecin, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego
- Nermend K. (2009) *Vector Calculus in Regional Development Analysis*, Series: Contributions to Economics, Springer.
- Nermend K., Tarczyńska-Łuniewska M. (2013) Badanie jednorodności przestrzennej i czasowej rozwoju obiektów społeczno-gospodarczych, *Przegląd Statystyczny*, R. LX, z. 1, str. 85-100.
- Rusielik R. (2015) Produktywność rolnictwa w Polsce - analiza z wykorzystaniem zagregowanych indeksów produktywności Färe-Primonta, *Metody Ilościowe w Badaniach Ekonomicznych*, t. XVI/4, str. 95-106.
- Salomon J. (2005) Badanie wielofunkcyjnego rozwoju obszarów wiejskich województwa świętokrzyskiego, *Infrastruktura i Ekologia obszarów Wiejskich*, nr 4, str. 145-155.
- Sikora J. (2012) Wielofunkcyjność obszarów wiejskich w Polsce, *Journal of Agribusiness and Rural Development*, nr 2(24), str. 215-226.
- Staniak M. (2009) Zrównoważony rozwój obszarów wiejskich w aspekcie środowiskowym, *Woda – Środowisko – Obszary Wiejskie*, t. 9, nr 3(27), str. 187-194.
- Zawalińska K. (2009) Instrumenty i efekty wsparcia Unii Europejskiej dla regionalnego rozwoju obszarów wiejskich w Polsce, Instytut Rozwoju Wsi i Rolnictwa Polskiej Akademii Nauk Warszawa.
- Żmija D. (2014) Zrównoważony rozwój rolnictwa i obszarów wiejskich w Polsce, *Studia Ekonomiczne*, nr 166, str. 149-158.

DIVERSIFIED DEVELOPMENT OF RURAL AREAS IN POLAND – REGIONAL APPROACH

Abstract: The article shows the use of arithmetic of increments for constructing a synthetic vector measure in order to examine time homogeneity of the diversification of Polish rural areas development in the regional approach. The measure is composed of an ordered pair: a mean value increment and a standard deviation increment. As a consequence, for each measure value additional information is obtained about homogenous development of Polish rural NUTS2 areas.

Keywords: vectoral synthetic measure, taxonomy, arithmetic of increments, regional analysis, regional homogeneity

ZASTOSOWANIE MODELI TRENDU DO PROJEKCJI OPŁACALNOŚCI PRODUKCJI MLEKA W PERSPEKTYWIE ŚREDNIOTERMINOWEJ

Aldona Skarżyńska, Konrad Jabłoński

Instytut Ekonomiki Rolnictwa i Gospodarki Żywnościowej – PIB w Warszawie

e-mail: konrad.jablonski@ierigz.waw.pl

Streszczenie: Celem badań jest określenie w perspektywie 2020 r. kierunku zmiany opłacalności produkcji mleka w Polsce w ujęciu regionalnym. Do sporządzenia projekcji wykorzystano klasyczne modele tendencji rozwojowej. Ze względu na zmienność ceny mleka w czasie (+/-8,7%) zbudowano warianty projekcji. Ocenia się, że w 2020 r. dynamika wzrostu przychodów będzie silniejsza niż kosztów w efekcie opłacalność mleka będzie wyższa (od 11,2 do 17,2 p.p.) niż w 2015 r. ale niższa w porównaniu do 2014 r. (od 1,6 do 6,8 p.p.). Tylko w korzystnym wariantcie projekcji (wzrost ceny mleka o 8,7%) opłacalność będzie wyższa niż w 2014 r.

Słowa kluczowe: projekcja, modele trendu, opłacalność produkcji mleka

WSTĘP

Wyniki prognoz czy projekcji są coraz częściej wykorzystywane w procesie zarządzania gospodarstwem rolnym. Do przetrwania na rynku potrzebne są informacje, które w mniejszym lub większym stopniu przedstawiałyby przyszłe warunki. Jednak w rolnictwie przewidywanie zmian wyników produkcyjnych czy sytuacji ekonomicznej jest bardzo trudne, wynika to z biologiczno-technicznego charakteru produkcji, której prowadzenie wiąże się z dużym ryzykiem. Ryzyko w produkcji rolniczej ma szczególny charakter z uwagi na dużą liczbę zagrożeń i większą niż w produkcji przemysłowej nieprzewidywalność zmienności pewnych zjawisk.

Projekcje pokazują, jakie trendy mogą kształtować prognozowane zjawisko w najbliższych latach. Ich zadaniem jest inspirowanie osób korzystających z wyników do podjęcia działań zmierzających do utrwalenia kierunku rozwoju uznanego za korzystny lub do przeciwdziałania kierunkowi rozwoju, który uznaje się za niepożądany [Zeliaś 2004]. Według Stańko [1999] prognozowanie to

działalność poznawcza, zmierzająca do wskazania najbardziej prawdopodobnych kierunków rozwoju przyszłych faktów, zjawisk czy zdarzeń na podstawie przesłanek ustalonych w toku badań naukowych. Według innej definicji „prognozowanie to racjonalne, naukowe przewidywanie przyszłych zdarzeń” [Zeliaś 1997, Cieślak 2004]. O naukowych przewidywaniach przyszłości mówimy wtedy, gdy w procesie wnioskowania korzystamy z reguł nauki, którą od wiedzy potocznej różni między innymi ścisły język i określona metoda badawcza.

Projekcje spełniają ważną rolę informacyjną i ostrzegawczą. Jednak ich dokładność zależy od warunków, w jakich przebiega proces prognozowania. W przypadku produktów rolniczych przewidywanie zmian wyników ekonomicznych jest trudne, może być jednak pomocne przy podejmowaniu wielu decyzji zarządczych w gospodarstwach. Natomiast w skali kraju daje podstawy do podjęcia odpowiednich decyzji w zakresie polityki rolnej czy też regulacji poszczególnych rynków.

Po zniesieniu z dniem 1 kwietnia 2015 roku kwot mlecznych szczególnie niekorzystna sytuacja występuje na rynku mleka. W Polsce chów bydła mlecznego oraz produkcja mleka pełni ważną rolę w generowaniu dochodów zarówno gospodarstw utrzymujących krowy mleczne, jak też całego rolnictwa. Świadczy o tym udział mleka w globalnej produkcji rolniczej, który w 2014 roku wynosił 16,4%, a w produkcji towarowej 18,8%, co stanowiło 33,6% globalnej produkcji zwierzęcej, a 31,6% towarowej produkcji zwierzęcej [GUS 2015].

Wśród największych producentów mleka w Unii Europejskiej, Polska zajmuje czwarte miejsce po Niemczech, Francji i Wielkiej Brytanii. Zniesienie limitów produkcji mleka i wzrost jego podaży, przyczyniły się do spadku cen mleka. Według GUS w 2014 roku średnia cena skupu mleka wynosiła 1,37 zł/litr, podczas gdy w 2015 roku – 1,13 zł/litr, obniżyła się więc o 17,5% [GUS 2016].

Celem badań było określenie w perspektywie 2020 roku kierunku i dynamiki zmiany opłacalności produkcji mleka w Polsce w ujęciu regionalnym, biorąc pod uwagę prognozowane tempo zmiany cen środków do produkcji rolnej oraz mleczności krów i ceny mleka. Ocenie poddano także wielkość odchylenia wyników ekonomicznych z produkcji mleka od poziomu przewidywanego na 2020 rok, czyli wynikającego z trendu, ze względu na zmienność ceny mleka w latach 1998-2015 określoną na podstawie danych statystyki publicznej, czyli przy przewidywanych korzystnych i niekorzystnych uwarunkowaniach cenowych.

DANE ŹRÓDŁOWE I METODYKA BADAŃ

W badaniach wykorzystano dane o działalności krowy mlecznej, zebrane i przetworzone w systemie AGROKOSZTY, natomiast dane o gospodarstwach, w których te badania przeprowadzono pochodziły z bazy Polskiego FADN. Próbkę badawczą stanowiło 169 gospodarstw indywidualnych położonych na terenie całego kraju, które w 2014 roku utrzymywały krowy mleczne. Gospodarstwa te wybrano w sposób celowy z próby reprezentacyjnej dla pola obserwacji Polskiego FADN. Dla realizacji celu badań dane empiryczne charakteryzujące krowy mleczne w 2014 roku

przeszacowano na rok 2015, zgodnie ze zmianą mleczności krów oraz zmianą cen poszczególnych składników wartości produkcji oraz kosztów bezpośrednich i pośrednich. Wskaźniki zmian zastosowane w przeszacowaniach obliczono korzystając głównie z danych statystyki publicznej.

Wyniki produkcji mleka w układzie tabelarycznym i graficznie zaprezentowano jako średnie dla grup gospodarstw, kryterium podziału było położenie w 4 regionach rolniczych¹. Wykorzystano analizę poziomą, porównując parametry charakteryzujące produkcję mleka w latach badań (tj. 2014 i 2015 oraz według projekcji w 2020 r.) oraz w wariantach projekcji na 2020 rok wynikających ze zmienności w latach ceny mleka.

Badaniami objęto przychody (wartość produkcji potencjalnie towarowej przypadająca na 1 krowę mleczną), koszty oraz efekty ekonomiczne. Miernikiem oceny uzyskanych efektów była nadwyżka bezpośrednia i dochód z działalności bez dopłat. Sposób obliczenia tych kategorii zaprezentowano poniżej:
nadwyżka bezpośrednia = wartość produkcji – koszty bezpośrednie,
dochód z działalności bez dopłat = wartość produkcji – koszty ogółem (bezpośrednie + pośrednie).

Do oceny ekonomicznej efektywności produkcji mleka zastosowano wskaźnik opłacalności produkcji, tzn. wyrażony w procentach stosunek wartości produkcji ogółem do kosztów ogółem.

W prezentowanych rachunkach wartość produkcji podana została na 1 krowę mleczną. Według przyjętej metodyki obejmuje ona mleko (produkt główny), wartość krowy wybrakowanej zgodnie z programem wynikającym z okresu produkcyjnego użytkowania zwierząt (produkt uboczny) oraz przyrost żywca, czyli cielęta po odsadzeniu od krowy. Koszty analizowano w podziale na bezpośrednie i pośrednie, tzn. w zależności od miejsca ich powstawania. Koszty bezpośrednie to składniki kosztów, które bez wątpliwości można przypisać do danej działalności, ich wielkość ma proporcjonalny związek ze skalą produkcji oraz mają bezpośredni wpływ na rozmiar (wielkość i wartość) produkcji. Natomiast koszty pośrednie są to koszty wspólne dla całego gospodarstwa; dzielą się na rzeczywiste i szacunkowe [Skarżyńska, Jabłoński 2015]. Koszty pośrednie gospodarstwa zostały rozdzielone na działalności według udziału wartości produkcji każdej z nich w wartości produkcji gospodarstwa ogółem.

Wyniki produkcji mleka w 2015 roku przyjęto jako punkt wyjścia do sporządzenia projekcji na 2020 rok, czyli określenia jakich zmian po stronie przychodów jak i kosztów, można spodziewać się w perspektywie kilku najbliższych lat. O wyborze roku 2015 jako punktu wyjścia do dalszych obliczeń zdecydowała

¹ Regiony rolnicze obejmują województwa: 1) Pomorze i Mazury – lubuskie, pomorskie, zachodniopomorskie, warmińsko-mazurskie; 2) Wielkopolska i Śląsk – wielkopolskie, opolskie kujawsko-pomorskie, dolnośląskie; 3) Mazowsze i Podlasie – podlaskie, mazowieckie, łódzkie, lubelskie; 4) Małopolska i Pogórze – świętokrzyskie, śląskie, małopolskie, podkarpackie.

sytuacja cenowa mleka (tzn. znaczący spadek cen głównie ze względu na zniesienie limitów produkcji mleka) oraz zastosowana metoda projekcji.

Budowę projekcji oparto na ekstrapolacji w przyszłość wybranych szeregów czasowych [Skarżyńska 2014]. W tym celu dla każdej ze zmiennych opisujących przychody i koszty produkcji mleka przyporządkowano odpowiadające im szeregi czasowe z danymi statystyki publicznej. W większości przypadków dane pochodziły z lat 1995-2015². Do obliczeń wykorzystano klasyczne modele tendencji rozwojowej. Wyodrębnienia tendencji rozwojowej dokonano metodą analityczną, czyli poprzez znalezienie takiej funkcji trendu $f(t)$ (t oznacza czas), która najdokładniej opisuje zmiany zjawiska w czasie [Wasilewska 2011]. Takie podejście zakładało, że poziom analizowanego zjawiska jest funkcją czasu, a efekt różnych czynników wpływających na jego przebieg został uwzględniony w zmianach zaobserwowanych w czasie.

Wyboru postaci analitycznej funkcji trendu dokonano metodą heurystyczną. Polega ona na znalezieniu kilku postaci tej funkcji, a następnie wyboru jednej z nich według zastosowanego kryterium [Stańko 1999]. Analizie poddano siedem funkcji: liniową, wielomianu drugiego stopnia (kwadratową), wykładniczą, potęgową, logarytmiczną, hiperboliczną i liniowo-hyperboliczną. Na ich podstawie dla każdego z szeregów czasowych stworzono modele trendu następującej postaci:

$$Y_t = \beta_0 + \beta_1 t + \varepsilon_t - \text{model trendu liniowego}, \quad (1)$$

$$Y_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \varepsilon_t - \text{model trendu kwadratowego} \\ \text{(wielomianu drugiego stopnia)}, \quad (2)$$

$$Y_t = \beta_0 e^{\beta_1 t} \cdot \varepsilon_t - \text{model trendu wykładniczego}, \quad (3)$$

$$Y_t = \beta_0 (t + 2)^{\beta_1} \cdot \varepsilon_t - \text{model trendu potęgowego}, \quad (4)$$

$$Y_t = \beta_0 + \beta_1 \ln(t + 2) + \varepsilon_t - \text{model trendu logarytmicznego}, \quad (5)$$

$$Y_t = \beta_0 + \beta_1 \frac{1}{t+2} + \varepsilon_t - \text{model trendu hiperbolicznego}, \quad (6)$$

$$Y_t = \beta_0 + \beta_1 t + \beta_2 \frac{1}{t+2} + \varepsilon_t - \text{model trendu liniowo-hyperbolicznego}, \quad (7)$$

gdzie:

Y_t – wartość zmiennej objaśnianej w czasie t ,

t – zmienna objaśniająca (czas), przyjmuje wartości całkowite od 1 do n ,

β_0 – wyraz wolny,

β_1, β_2 – współczynniki kierunkowe funkcji,

ε_t – składnik losowy.

Parametry wszystkich modeli estymowano klasyczną metodą najmniejszych kwadratów. Niezależnie dla każdego z analizowanych szeregów czasowych, wybrano jedną z funkcji trendu³. Przy wyborze kierowano się głównie wysokością

² Z powodu braku danych korzystano niekiedy z krótszych szeregów.

³ Ze względu na wymogi dotyczące objętości artykułu nie zamieszczono parametrów strukturalnych i struktury stochastycznej dla wszystkich stworzonych modeli. Dla przykładu podano wyniki estymacji modeli (ostatecznie wybranych do analizy), dla dwóch szeregów czasowych: 1) cena cieląt (wg GUS) – model trendu liniowego

współczynnika determinacji R^2 oraz wiedzą na temat kształtowania się badanego zjawiska w czasie. Modele, w których parametry były statystycznie nieistotne odrzucono⁴.

Wykorzystując wybrane modele obliczono wartości teoretyczne szeregów wraz z projekcją na 2020 rok. Następnie na podstawie tych wartości obliczono wskaźniki zmian z roku na rok (rok poprzedni = 1). Wskaźniki te wykorzystano do przeliczenia wartości z 2015 roku, opisujących składniki struktury wartości produkcji i kosztów, na rok 2020. W ten sposób uzyskano projekcję wyników ekonomicznych produkcji mleka w przeciętnych warunkach produkcyjno-cenowych, tzn. wynikających z trendu.

Z badań wynika, że spośród czynników warunkujących opłacalność produkcji mleka stosunkowo niewielkim zmianom podlega mleczność krów i koszty produkcji mleka. Znacznie większa zmienność charakteryzuje natomiast cenę sprzedaży mleka. Zmienność ceny mleka określono na podstawie danych GUS z lat 1998-2015 (dla każdego regionu osobno), wykorzystując stworzone wcześniej modele trendu. Odpowiednich obliczeń dokonano korzystając z następującego wzoru:

$$V = \frac{\sqrt{n-1} \sum (Y - \hat{Y})^2}{\bar{Y}} \quad (8)$$

gdzie:

- V – zmienność badanej zmiennej,
- Y – wartości empiryczne zmiennej,
- \hat{Y} – wartości teoretyczne zmiennej wynikające z modelu,
- \bar{Y} – średnia arytmetyczna wartości zmiennej,
- n – liczba obserwacji.

Biorąc pod uwagę zmienność ceny mleka, sporządzono dwa warianty projekcji wyników ekonomicznych produkcji mleka w 2020 roku, tzn. przy korzystnych warunkach cenowych (wariant A) i przy niekorzystnych warunkach cenowych mleka (wariant B).

WYNIKI EKONOMICZNE PRODUKCJI MLEKA W LATACH 2014–2015 ORAZ PROJEKCJA NA 2020 ROK

W 2015 roku, w porównaniu do roku 2014, ze względu na spadek ceny mleka odnotowano pogorszenie wyników ekonomicznych jego produkcji. W próbie badawczej gospodarstw położonych w regionie Pomorze i Mazury dochód z działalności bez dopłat liczony na 1 krowę obniżył się o 35,5%, a wskaźnik opłacalności produkcji mleka o 18,0 p.p. W gospodarstwach z Wielkopolski i Śląska

następującej postaci: $Y_t = 2,789 + 0,369t$, $R^2 = 0,936$; 2) cena energii elektrycznej (wg GUS) – model trendu potęgowego następującej postaci: $Y_t = 0,048(t + 2)^{0,844}$, $R^2 = 0,986$.

⁴ Istotność parametrów badano testem t-student, na poziomie istotności 0,05.

dochód był niższy o 41,6%, a wskaźnik opłacalności o 17,3 p.p. Natomiast na Mazowszu i Podlasiu spadek wynosił odpowiednio: 33,8% i 20,3 p.p., a w próbie gospodarstw z regionu Małopolska i Pogórze – 47,8% i 16,4 p.p. (Tabele: 2–5).

W roku 2015 – przyjętym za bazowy dla modelu projekcji – średnio w próbie gospodarstw w każdym z regionów rolniczych, produkcja mleka pozwoliła na uzyskanie dochodu. W najkorzystniejszej sytuacji byli producenci mleka na Mazowszu i Podlasiu, dochód z działalności bez dopłat przypadający na 1 krowę wynosił 2337 zł. Dochód ten przewyższał poziom uzyskany w regionie Wielkopolska i Śląsk – o 18,4%, Pomorze i Mazury – o 29,7%, a Małopolska i Pogórze – aż o 84,9%. Produkcję mleka na Mazowszu Podlasiu charakteryzowała również najwyższa efektywność ekonomiczna. Do oceny zastosowano wskaźnik opłacalności, który wyraża nadwyżkę wartości produkcji ogółem nad kosztami ogółem. Opłacalność produkcji mleka w regionie Mazowsze i Podlasie ukształtowała się na poziomie 141,5%, podczas gdy na Pomorzu i Mazurach wskaźnik opłacalności wynosił 134,5%, w regionie Wielkopolska i Śląsk – 125,3%, a Małopolska i Pogórze – 118,7%.

W próbie gospodarstw z regionu Mazowsze Podlasie – w porównaniu do pozostałych regionów – producenci zapewnili sobie wyraźną przewagę w zakresie produkcji mleka. Świadczy o tym między innymi najniższy koszt (ogółem) produkcji 1 litra mleka (0,92 zł) i wytworzenia 1 zł dochodu z działalności bez dopłat (2,41 zł) oraz najwyższy dochód bez dopłat przypadający na 1 litr mleka (0,38 zł) – Tabele: 2–5.

Jakich zmian można oczekiwać w perspektywie 2020 roku. Zastosowana metoda projekcji pozwoliła określić spodziewany kierunek zmiany zarówno po stronie przychodów jak i kosztów produkcji – Tabela 1.

Tabela 1. Roczne przyrosty do 2020 roku wartości produkcji i kosztów w przeliczeniu na 1 krowę mleczną, w regionach rolniczych

Wyszczególnienie	REGIONY ROLNICZE			
	Pomorze i Mazury	Wielkopolska i Śląsk	Mazowsze i Podlasie	Małopolska i Pogórze
Wartość produkcji ogółem, %	4,2-4,6	5,1-5,4	5,2-5,8	5,1-5,6
w tym: wydajność mleczna krów	1,4-1,5	2,4-2,4	2,5-2,8	2,3-2,4
cena mleka	2,9-3,2	2,7-3,1	2,8-3,1	2,9-3,3
Koszty ogółem, %	2,6-2,9	2,8-3,1	2,9-3,2	2,8-3,1

Źródło: opracowanie na podstawie badań własnych

W warunkach, które określił model projekcji ocenia się, że w perspektywie 2020 roku w próbie gospodarstw w regionie Pomorze i Mazury dynamika wzrostu przychodów liczonych na krowę (24,1%) będzie silniejsza niż kosztów jej utrzymania (14,7%) o 9,4 p.p. W efekcie wskaźnik opłacalności produkcji mleka wzrośnie do poziomu 145,7%, podczas gdy w 2015 roku wynosił 134,5%. W 2015 roku produkcja mleka była dochodowa i według projekcji w perspektywie kilku najbliższych lat również taką pozostanie. W 2020 roku dochód z działalności bez dopłat liczony na krowę mleczną może przewyższyć poziom z roku bazowego

(2015) o 51,7% (wyniesie 2734 zł wobec 1802 zł). Ocenia się, że koszt produkcji 1 litra mleka wzrośnie o 6,7%, jednak dzięki wyższej mleczności krów (o 7,4%) i cenie mleka (o 16,4%) dochód z działalności bez dopłat liczony na 1 litr mleka będzie wyższy o 41,2%. Koszty ogółem wytworzenia 1 zł tego dochodu będą stanowiły 75,6% poziomu z 2015 roku – Tabela 2.

Tabela 2. Wyniki produkcji mleka w wybranych gospodarstwach w regionie Pomorze i Mazury w 2015 roku oraz projekcja na 2020 rok (w cenach bieżących)

Wyszczególnienie	Poziom w roku		Projekcja na 2020 rok			Wskaźnik zmian: 2020/2015 (2015=100)		
	2014	2015	według trendu	warianty ^a		według trendu	warianty ^a	
				[A]	[B]		[A]	[B]
Liczba badanych gospodarstw	41							
Średnioroczny stan krów mlecznych [szt.]	31,2							
Wydajność mleczna krów [litr]	5448	5607	6023	6023	6023	107,4	107,4	107,4
Cena sprzedaży mleka [zł/litr]	1,34	1,10	1,28	1,40	1,16	116,4	127,3	105,5
	Na 1 krowę mleczną, zł							
Wartość produkcji (WP)	8120	7023	8719	9429	8009	124,1	134,3	114,0
Koszty bezpośrednie	2556	2530	2993	2993	2993	118,3	118,3	118,3
Nadwyżka bezpośrednia	5564	4493	5726	6437	5016	127,4	143,3	111,6
Koszty pośrednie	2770	2691	2993	2993	2993	111,2	111,2	111,2
Dochód z działalności bez dopłat	2794	1802	2734	3444	2023	151,7	191,1	112,3
Koszty ogółem (KO)	5326	5221	5986	5986	5986	114,7	114,7	114,7
Wskaźnik opłacalności (WP/KO) [proc.]	152,5	134,5	145,7	157,5	133,8	108,3	117,1	99,5
Koszty ogółem na 1 litr mleka [zł]	0,98	0,93	0,99	0,99	0,99	106,7	106,7	106,7
Dochód bez dopłat na 1 litr mleka [zł]	0,51	0,32	0,45	0,57	0,34	141,2	177,9	104,5
KO na 1 zł dochodu bez dopłat [zł]	1,91	2,90	2,19	1,74	2,96	75,6	60,0	102,1

^a Warianty: A – korzystny, B – niekorzystny

Źródło: opracowanie na podstawie badań własnych

W 2020 roku w badanych gospodarstwach z regionu Wielkopolska i Śląsk można spodziewać się silniejszej o 13,2 p.p. dynamiki wzrostu przychodów niż kosztów utrzymania krów. Ekonomiczna efektywność produkcji mleka będzie wyższa o 14,4 p.p., a dochód bez dopłat przypadający na krowę przekroczy poziom z roku bazowego (2015) o 81,6%, wynosie 3584 zł (w 2015 r. wynosił 1974 zł). Ocenia się, że wyniki będą korzystne pomimo relatywnie wysokich kosztów utrzymania krów (9029 zł/sztukę). Ze względu na wysoką mleczność krów, koszt

produkcji 1 litra mleka w 2020 roku wzrośnie tylko o 2,6%. Biorąc jednak pod uwagę spodziewany, znaczny wzrost ceny mleka (o 15,7%) i mleczności krów (o 12,8%), dochód liczony na 1 litr przewyższy poziom z 2015 roku o 60,9%. Koszty wytworzenia 1 zł tego dochodu obniżą się, w badanych gospodarstwach mogą stanowić 63,8% poziomu z 2015 roku (2,52 zł wobec 3,95 zł) – Tabela 3.

Tabela 3. Wyniki produkcji mleka w wybranych gospodarstwach w regionie Wielkopolska i Śląsk w 2015 roku oraz projekcja na 2020 rok (w cenach bieżących)

Wyszczególnienie	Poziom w roku		Projekcja na 2020 rok			Wskaźnik zmian: 2020/2015 (2015=100)		
	2014	2015	według trendu	warianty ^a		według trendu	warianty ^a	
				[A]	[B]		[A]	[B]
Liczba badanych gospodarstw	32							
Średnioroczny stan krów mlecznych [szt.]	29,6							
Wydajność mleczna krów [litr]	7008	7213	8139	8139	8139	112,8	112,8	112,8
Cena sprzedaży mleka [zł/litr]	1,47	1,21	1,40	1,51	1,28	115,7	124,8	105,8
	Na 1 krowę mleczną, zł							
Wartość produkcji (WP)	11322	9774	12613	13549	11678	129,0	138,6	119,5
Koszty bezpośrednie	4437	4366	5147	5147	5147	117,9	117,9	117,9
Nadwyżka bezpośrednia	6884	5408	7467	8402	6531	138,1	155,4	120,8
Koszty pośrednie	3505	3434	3882	3882	3882	113,0	113,0	113,0
Dochód z działalności bez dopłat	3380	1974	3584	4520	2649	181,6	229,0	134,2
Koszty ogółem (KO)	7942	7800	9029	9029	9029	115,8	115,8	115,8
Wskaźnik opłacalności (WP/KO) [proc.]	142,6	125,3	139,7	150,1	129,3	111,5	119,8	103,2
Koszty ogółem na 1 litr mleka [zł]	1,13	1,08	1,11	1,11	1,11	102,6	102,6	102,6
Dochód bez dopłat na 1 litr mleka [zł]	0,48	0,27	0,44	0,56	0,33	160,9	202,9	118,9
KO na 1 zł dochodu bez dopłat [zł]	2,35	3,95	2,52	2,00	3,41	63,8	50,6	86,3

^a jak w Tabeli 2.

Źródło: opracowanie na podstawie badań własnych

W próbie gospodarstw z regionu Mazowsze i Podlasie, przy tempie zmian mleczności krów (2,5-2,8%) i ceny mleka (2,8-3,1%) przewidywanym na 2020 rok, wzrost przychodów liczony na 1 krowę będzie najsilniejszy. W porównaniu do 2015 roku można oczekiwać przychodów wyższych o 30,5%, podczas gdy koszty mogą wzrosnąć o 16,4%. Oznacza to, że dynamika wzrostu wartości produkcji będzie o 14,1 p.p. silniejsza niż wzrostu kosztów. W tej sytuacji wskaźnik opłacalności osiągnie poziom 158,7% i będzie wyższy niż w roku bazowym dla

projekcji o 17,2 p.p. Dochód z działalności bez dopłat liczony na 1 krowę wzrośnie o 64,6% (wyniesie 3847 zł), a na 1 litr mleka o 44,4% (wyniesie 0,55 zł). Koszty ogółem wytworzenia 1 litra mleka wzrosną o 2,1%, jednak ze względu na przewidywany wzrost dochodu, koszt wytworzenia jego jednostki obniży się o 29,3% (będzie stanowił 70,7% poziomu z 2015 r.) – Tabela 4.

Tabela 4. Wyniki produkcji mleka w wybranych gospodarstwach w regionie Mazowsze i Podlasie w 2015 roku oraz projekcja na 2020 rok (w cenach bieżących)

Wyszczególnienie	Poziom w roku		Projekcja na 2020 rok			Wskaźnik zmian: 2020/2015 (2015=100)		
	2014	2015	według trendu	warianty ^a		według trendu	warianty ^a	
				[A]	[B]		[A]	[B]
Liczba badanych gospodarstw	54							
Średnioroczny stan krów mlecznych [szt.]	24,5							
Wydajność mleczna krów [litr]	5964	6138	6997	6997	6997	114,0	114,0	114,0
Cena sprzedaży mleka [zł/litr]	1,42	1,17	1,35	1,48	1,23	115,4	126,5	105,1
	Na 1 krowę mleczną, zł							
Wartość produkcji (WP)	9249	7973	10405	11273	9536	130,5	141,4	119,6
Koszty bezpośrednie	3154	3148	3746	3746	3746	119,0	119,0	119,0
Nadwyżka bezpośrednia	6095	4825	6658	7527	5790	138,0	156,0	120,0
Koszty pośrednie	2564	2488	2811	2811	2811	113,0	113,0	113,0
Dochód z działalności bez dopłat	3532	2337	3847	4716	2979	164,6	201,8	127,5
Koszty ogółem (KO)	5718	5636	6558	6558	6558	116,4	116,4	116,4
Wskaźnik opłacalności (WP/KO) [proc.]	161,8	141,5	158,7	171,9	145,4	112,2	121,5	102,8
Koszty ogółem na 1 litr mleka [zł]	0,96	0,92	0,94	0,94	0,94	102,1	102,1	102,1
Dochód bez dopłat na 1 litr mleka [zł]	0,59	0,38	0,55	0,67	0,43	144,4	177,0	111,8
KO na 1 zł dochodu bez dopłat [zł]	1,62	2,41	1,70	1,39	2,20	70,7	57,7	91,3

^a jak w Tabeli 2.

Źródło: opracowanie na podstawie badań własnych

W gospodarstwach z regionu Małopolska i Pogórze, w docelowym roku projekcji (2020) skumulowany wzrost przychodów liczonych na 1 krowę może wynieść 29,8%, podczas gdy kosztów jej utrzymania 15,4%. Silniejszy wzrost przychodów niż kosztów będzie stymulował poprawę wyników. Dlatego wyższa będzie efektywność ekonomiczna produkcji mleka (o 14,8 p.p.), a także nadwyżka ekonomiczna pozostająca do dyspozycji rolników. Dochód z działalności bez dopłat przypadający na 1 krowę wzrośnie aż o 107,1% (wyniesie 2618 zł wobec

1264 zł w 2015 r.), a na 1 litr mleka – o 84,5% (wyniesie 0,39 zł wobec 0,21 zł w 2015 r.). Należy jednak dodać, że pomimo silnej dynamiki wzrostu, dochód bez dopłat ujęty nominalnie liczony na 1 krowę, jak i na 1 litr mleka nadal pozostanie niższy niż w pozostałych regionach. Niższa będzie również ekonomiczna efektywność produkcji mleka – Tabela 5.

Tabela 5. Wyniki produkcji mleka w wybranych gospodarstwach w regionie Małopolska i Pogórze w 2015 roku oraz projekcja na 2020 rok (w cenach bieżących)

Wyszczególnienie	Poziom w roku		Projekcja na 2020 rok			Wskaźnik zmian: 2020/2015 (2015=100)		
	2014	2015	według trendu	warianty ^a		według trendu	warianty ^a	
				[A]	[B]		[A]	[B]
Liczba badanych gospodarstw	42							
Średnioroczny stan krów mlecznych [szt.]	23,3							
Wydajność mleczna krów [litr]	5866	6038	6780	6780	6780	112,3	112,3	112,3
Cena sprzedaży mleka [zł/litr]	1,44	1,19	1,39	1,51	1,27	116,8	126,9	106,7
	Na 1 krowę mleczną, zł							
Wartość produkcji (WP)	9314	8039	10437	11223	9650	129,8	139,6	120,0
Koszty bezpośrednie	3553	3518	4173	4173	4173	118,6	118,6	118,6
Nadwyżka bezpośrednia	5761	4521	6264	7050	5477	138,6	155,9	121,1
Koszty pośrednie	3341	3257	3646	3646	3646	111,9	111,9	111,9
Dochód z działalności bez dopłat	2420	1264	2618	3404	1831	207,1	269,3	144,9
Koszty ogółem (KO)	6894	6775	7819	7819	7819	115,4	115,4	115,4
Wskaźnik opłacalności (WP/KO) [proc.]	135,1	118,7	133,5	143,5	123,4	112,5	121,0	104,0
Koszty ogółem na 1 litr mleka [zł]	1,18	1,12	1,15	1,15	1,15	102,8	102,8	102,8
Dochód bez dopłat na 1 litr mleka [zł]	0,41	0,21	0,39	0,50	0,27	184,5	239,8	129,0
KO na 1 zł dochodu bez dopłat [zł]	2,85	5,36	2,99	2,30	4,27	55,7	42,9	79,7

^a jak w Tabeli 2.

Źródło: opracowanie na podstawie badań własnych

WARIANTY PROJEKCJI NA 2020 ROK

Przez prognozowanie przyszłych zdarzeń dąży się do minimalizowania ryzyka, które towarzyszy podejmowanym decyzjom. Wśród prognozowanych kategorii (zmiennych) ważną pozycję zajmuje cena. Procesy integracji i globalizacji sprawiają, że kształtowanie się cen produktów rolnych wynika nie tylko z relacji popytowo-podażowych w kraju ale także z sytuacji na rynkach światowych i powiązania z cenami światowymi, oddziaływania instrumentów Wspólnej Polityki Rolnej, czy jest wynikiem jeszcze innych uwarunkowań.

Istota prognozowania na podstawie szeregów czasowych opiera się na założeniu, że w zjawisku prognozowanym znajdują odzwierciedlenie wszystkie czynniki, które na to zjawisko wpływają. Przytoczona zasada szczególnie dotyczy cen [Hamulczuk, Stańko 2011].

Funkcjonowanie rynku mleka do 30 marca 2015 roku było oparte o kwoty mleczne, podlegało więc regulacji instrumentów unijnej polityki rolnej. Zniesienie limitów produkcji mleka i w związku z tym wzrost jego podaży, przyczyniły się do znacznego spadku cen mleka. Na aktualną sytuację na rynku mleka w Polsce i niekorzystny wpływ na poziom cen, oprócz zwiększonej podaży wywiera także rosyjskie embargo na import żywności z UE i innych krajów oraz spadek cen mleka i przetworów mlecznych na rynku światowym [Seremak-Bulge 2015].

Przesłanki te sugerują, że od poziomu ceny przewidywanej na 2020 rok, a wynikającej z tendencji długookresowej mogą występować odchylenia. Oznacza to, że dynamika zmiany ceny w przyszłości nie musi odzwierciedlać trendu obserwowanego w ostatnich latach. Wariantowe ujęcie wyników projekcji w perspektywie 2020 roku pokazuje wpływ na poziom dochodu, zmian ceny mleka wynikającej ze zmienności w czasie (model projekcji nie pokazuje zależności, np. jak zmiana podaży mleka może wpłynąć na poziom cen w roku następnym). Należy jednak zauważyć, że na zakres prezentowanych zmian, wpływ mają także dane, które były punktem wyjścia do przeprowadzonych badań. Oznacza to, że prezentowane zmiany dochodu i opłacalności wyrażonej w postaci relacji odnoszą się wyłącznie do próby badawczej gospodarstw. Mimo to uzyskane wyniki dają obraz sytuacji i jej skutków. Zamierzeniem autorów było zwrócenie uwagi na ryzyko ekonomiczne mające podłoże w zmienności ceny skupu mleka.

Obliczenia wykonane na podstawie danych GUS wykazały, że w okresie 18 lat (1998-2015) zmienność ceny mleka w dwóch regionach, tj. Pomorze i Mazury oraz Mazowsze i Podlasie wynosiła 9,2%, natomiast w kolejnych dwóch była podobna, w regionie Wielkopolska i Śląsk wynosiła 8,2%, a Małopolska i Pogórze 8,4%. Wpływ tej zmienności na odchylenia ceny od poziomu wynikającego z kilkunastoletniej funkcji trendu w każdym z regionów był w zasadzie taki sam (+/- 0,12 zł).


Biorąc pod uwagę zmienność ceny mleka obserwowaną w latach 1998-2015 określono odchylenia dochodu od poziomu przewidywanego na 2020 rok. Z badań wynika (Tabele: 2-5), że dochód bez dopłat liczony na 1 krowę mleczną

i prognozowany na 2020 rok, może podlegać znacznym wahaniom (przy niezmiennym poziomie pozostałych czynników), w regionie:

1. Pomorze i Mazury +/- 26% (tj. o 710 zł),
2. Wielkopolska i Śląsk +/- 26% (tj. o 935 zł),
3. Mazowsze i Podlasie +/- 23% (tj. o 868 zł),
4. Małopolska i Pogórze +/- 30% (tj. o 786 zł).

Wahaniom podlegać będzie również opłacalność produkcji mleka ujęta jako relacja wartości produkcji do kosztów poniesionych na jej wytworzenie. W gospodarstwach położonych na Pomorzu i Mazurach, ze względu na wzrost lub spadek ceny mleka o 0,12 zł, wskaźnik opłacalności – w odniesieniu do jego wielkości wynikającej z trendu – obniży się lub wzrośnie o 12 p.p. Będzie wynosił 133,8 lub 157,5%, podczas gdy w rachunku wyjściowym (tzn. przy cenie mleka wynikającej z trendu) osiągnął poziom 145,7%. W regionie Wielkopolska i Śląsk oraz Małopolska i Pogórze wahania wskaźnika opłacalności będą wynosić +/- 10 p.p., a na Mazowszu i Podlasiu +/-13 p.p. Przewiduje się, że w 2020 roku opłacalność produkcji mleka będzie kształtować się na poziomie wyższym niż w roku 2014 tylko w korzystnym wariancie projekcji – wykres 1.

Wykres 1. Wskaźnik opłacalności produkcji mleka w latach 2014-2015 oraz projekcja na 2020 rok, ujęcie regionalne



Źródło: opracowanie na podstawie badań własnych

PODSUMOWANIE

Prowadzenie gospodarstwa rolnego związane jest z podejmowaniem różnych decyzji. Decyzje te dotyczą przyszłości, dlatego ich podejmowanie opiera się na przewidywaniu przyszłych warunków funkcjonowania gospodarstwa.

Metody szeregów czasowych zastosowane do przewidywania przyszłych zdarzeń pozwalają na uzyskanie wielu informacji o prawidłowościach, jakie występują w analizowanych danych. Dzięki temu wiedza analityków może być poszerzona, np. o występujące trendy, wahania, itp. Dysponując pewnymi informacjami można zbudować model projekcji, który będzie łączył fakty niepodważalne (twarde) z intuicją i wiedzą pozastatystyczną i który będzie przystosowany do badań określonego zjawiska. Założeniom tym odpowiada model projekcji zbudowany w celu oceny opłacalności produkcji mleka w perspektywie 2020 roku.

Według projekcji sporządzonej w warunkach wynikających z tendencji długookresowej, do 2020 roku przewiduje się poprawę mleczności krów oraz wzrost ceny mleka. Jednak dynamika tych zmian będzie różna w zależności od położenia regionalnego gospodarstw. Biorąc pod uwagę skumulowany wpływ obu zmiennych, ocenia się że w 2020 roku – w porównaniu do roku 2015 – najsilniejszy wzrost przychodów liczonych na 1 krowę odnotują rolnicy w regionie Mazowsze i Podlasie (30,5%), a najniższy na Pomorzu i Mazurach (24,1%). Koszty utrzymania krów w ujęciu regionalnym wzrosną w granicach 14,7-16,4%. W rezultacie efektywność ekonomiczna produkcji mleka będzie kształtować się na poziomie wyższym (od 11,2 do 17,2 p.p.) niż w roku bazowym dla projekcji. Pod tym względem przewaga producentów mleka z Mazowsza i Podlasia jest również wyraźna.

Warianty projekcji, których wyniki różnicuje zmienność ceny mleka wynikająca ze zmienności w czasie (1998-2015), pokazują odchylenia wyników ekonomicznych produkcji mleka, od poziomu na 2020 rok przewidywanego przy cenie wynikającej z trendu. Z badań wynika, że w regionach rolniczych dochód z działalności bez dopłat w przeliczeniu na 1 krowę może podlegać wahanom od +/-23 do +/-30%. Natomiast opłacalność produkcji mleka ujęta jako relacja wartości produkcji do kosztów poniesionych na jej wytworzenie może wahać się w zakresie +/- 10-13 p.p. Pomimo tych wahań ocenia się, że produkcja mleka nadal będzie opłacalna. Należy jednak zaznaczyć, że punktem wyjścia do badań były wyniki uzyskane w gospodarstwach towarowych, w związku z tym wyniki projekcji również takich dotyczą.

BIBLIOGRAFIA

- Cieślak M. (2004) Prognozowanie gospodarcze. Metody i zastosowania, PWN, Warszawa.
GUS (2015) Rocznik Statystyczny Rolnictwa 2014, Zakład Wydawnictw Statystycznych, Warszawa.

- GUS (2016) Biuletyn statystyczny, nr 2/2016, Zakład Wydawnictw Statystycznych, Warszawa.
- Hamulczuk M., Stańko S. (2011) Istota prognozowania na podstawie szeregów czasowych, W: M. Hamulczuk (red. nauk.), Prognozowanie cen surowców rolnych z wykorzystaniem modeli szeregów czasowych, Program Wieloletni 2011-2014, nr 10, IERiGŻ- PIB, Warszawa.
- Seremak-Bulge J. (red. nauk.) (2015) Rynek Mleka. Stan i perspektywy, nr 49, IERiGŻ- PIB, Warszawa.
- Skarżyńska A. (red.) (2014) Nadwyżka bezpośrednia z wybranych produktów rolniczych w 2013 roku oraz projekcja dochodów na 2020 rok, IERiGŻ- PIB, Warszawa.
- Skarżyńska A., Jabłoński K. (2015) Wyniki ekonomiczne wybranych produktów rolniczych w 2014 roku, IERiGŻ- PIB, Warszawa.
- Stańko S. (1999) Prognozowanie w rolnictwie, wyd. 2, SGGW, Warszawa.
- Wasilewska E. (2011) Statystyka opisowa od podstaw, SGGW, Warszawa.
- Zeliaś A. (1997) Teoria prognozy, wyd. 3, PWE, Warszawa.
- Zeliaś A. (2004) Przyczynek do dyskusji o trudnych problemach prognozowania ekonomicznego, Zeszyty Naukowe Uniwersytetu Szczecińskiego, nr 394, Prace Katedry Ekonometrii i Statystyki, nr 15. Szczecin.

USE OF TREND MODELS FOR PROJECTION OF PROFITABILITY OF MILK PRODUCTION IN THE MID-TERM PERSPECTIVE

Abstract: The aim of the study is to determine the change in the profitability of milk production in Poland until 2020 year in regional breakdown. To prepare the projections classical models of development trend have been used. Due to the volatility of milk prices over time (+/-8.7%) different variants of the projection were developed. The results show that in 2020 compared to 2015 the growth of revenues will be stronger than the growth of costs and as a result the profitability of milk production will be higher (from 11.2 to 17.2 percentage points). However, estimation also shows that profitability of milk production in 2020 will be lower than in 2014 (from 1.6 to 6.8 pp). Only in the favorable projection variant (increase of milk price by 8.7%), profitability will be higher than in 2014.

Keywords: projection, trend models, profitability of milk production

ROLNICTWO W REGIONACH. WIELOWYMIAROWE SPOJRZENIE W UJĘCIU DYNAMICZNYM

Agnieszka Sompolska-Rzechuła

Katedra Zastosowań Matematyki w Ekonomii
Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
e-mail: asompolska@zut.edu.pl

Streszczenie: W pracy wykorzystano wybrane metody wielowymiarowej analizy porównawczej do oceny i porównania poziomu rolnictwa w regionach Polski w ujęciu dynamicznym. Okres badawczy obejmował lata 2011-2014. Zbiór cech diagnostycznych dotyczył wielu aspektów rolnictwa: powierzchni zasiewów, pogłowia zwierząt, skupu produktów rolniczych oraz plonów. Uzyskane wyniki wskazują, iż rolnictwo w województwach Polski jest bardzo zróżnicowane a zmiany w rolnictwie zachodzą wolniej niż w pozostałych działach gospodarki narodowej co jest wynikiem jego specyficznego charakteru.

Słowa kluczowe: rolnictwo, regiony, zróżnicowanie

WPROWADZENIE

Współczesne rolnictwo odgrywa znaczącą rolę w gospodarce narodowej. Ma wiele wymiarów i płaszczyzn, na których można je rozpatrywać. Ważne i wciąż aktualne wydają się trzy z nich: płaszczyzna bezpieczeństwa żywnościowego, płaszczyzna wzrostu gospodarczego i rozwoju społecznego oraz płaszczyzna zrównoważenia i trwałości systemów społeczno-gospodarczych i przyrodniczych [Adamowicz 2009]. Rolnictwo, podobnie jak inne sektory gospodarki, uczestniczy w procesach globalizacji, którymi jest objęte, i podlega istotnym zmianom. Jest sektorem bardzo wrażliwym i wymaga specjalnego traktowania, szczególnej ochrony i wsparcia. Wynika to z tego, że w rolnictwie nie następuje szybki zwrot kapitału, jak w innych działach gospodarki, cały cykl produkcyjny jest dłuższy, a produkcja rolnicza często zależy od czynników niezależnych od człowieka, np. od warunków pogodowych. Rolnictwo dominuje w znacznej części obszaru Unii Europejskiej, odgrywa ważną rolę w kształtowaniu dobrej kondycji gospodarki

żywnościowej rolnej i wpływa na kształtowanie krajobrazu obszarów wiejskich. [Weiss, Bitkowska 2014].

Rolnictwo polskie wykazuje duże zróżnicowanie przestrzenne w ujęciu regionalnym. Zróżnicowanie to jest wypadkową wielu czynników: przyrodniczych, demograficznych i ekonomicznych [Poczta, Bartkowiak 2012].

Problematyka przestrzennego zróżnicowania rolnictwa w Polsce jest bardzo często podejmowana w publikacjach naukowych. Ze względu na złożoność zjawiska wykorzystywane są metody wielowymiarowej analizy porównawczej. Wynikiem przeprowadzanych badań są klasyfikacje różnych obiektów np. województw, powiatów czy gmin oraz analizy porównawcze. Przykładami prac, w których zastosowano metody taksonomiczne w analizie przestrzennego zróżnicowania rolnictwa w Polsce są: [Poczta, Bartkowiak 2012], [Kamińska, Nowak 2014], [Beba, Poczta 2015], [Bożek, Bożek 2011], [Bindermann 2012].

Celem pracy jest przestrzenno-czasowa ocena rolnictwa w Polsce. W badaniu wykorzystano informacje zawarte w publikacjach Ministerstwa Rolnictwa i Rozwoju Wsi pt. „*Rolnictwo i Gospodarka Żywnościowa w Polsce*”, dotyczące województw Polski. Badanie dotyczy okresu 2011-2014. W ocenie przestrzennego zróżnicowania rolnictwa i typologii regionów wykorzystano liniowe porządkowania obiektów i klasyfikację utworzoną na podstawie liniowego porządkowania regionów Polski.

METODA BADAWCZA

Przeprowadzenie badania taksonomicznego obiektów wymaga ustalenia zbioru cech diagnostycznych. Istnieją dwa podstawowe podejścia do wyboru cech: pozastatystyczne (merytoryczne) i statystyczne. Analiza merytoryczna jest oceną jakościową przeprowadzaną z wykorzystaniem merytorycznej znajomości badanego zjawiska odwołującej się do intuicji badawczej popartej znajomością teorii ekonomicznej i procesów ekonomicznych w badanej dziedzinie. Zastosowanie analizy statystycznej ma na celu ograniczenie zbioru potencjalnych cech do zbioru, który charakteryzowałby badane obiekty w sposób możliwie pełny, a przy tym tworzyłby zbiór mniej liczny. Można wyróżnić trzy podejścia do wyboru cech na potrzeby klasyfikacji zbioru obiektów [Wysocki 2010]:

- Ustalenie systemu wag zróżnicowanych dla rozpatrywanych cech.
- Selekcja cech - wyeliminowanie z pierwotnego zespołu cech, które nie mają lub mają słabe zdolności dyskryminacji zbioru obiektów. Problem selekcji cech jest szczególnym przypadkiem ważenia cech, ponieważ cechom wyeliminowanym przypisuje się wagę 0, a wybranym wagę 1.
- Zastąpienie wyjściowych cech nowymi „sztucznymi” cechami, na przykład poprzez zastosowanie analizy czynnikowej lub analizy składowych głównych.

W pracy zastosowano trzecie podejście wykorzystując do selekcji cech metodę głównych składowych (PCA).

Teoretyczne podstawy analizy głównych składowych stworzył K. Pearson [1901], który zastosował ją po raz pierwszy dla zmiennych nielosowych, natomiast H. Hotelling [1933] uogólnił metodę na zmienne losowe¹. W analizie głównych składowych przyjmuje się, że występuje p zmiennych X_j ($j = 1, \dots, p$), a obserwacje przeprowadzone na n obiektach ($i = 1, \dots, n$) zebrane są w formie macierzy danych \mathbf{X} . Idea analizy głównych składowych polega na ortogonalnej transformacji układu badanych zmiennych X_j w zbiór nowych nieobserwowalnych zmiennych Y_l , które są liniowymi kombinacjami tych obserwowalnych zmiennych, co można zapisać w postaci uogólnionego układu [Balicki 2009]:

$$Y_l = w_{1l}X_1 + w_{2l}X_2 + \dots + w_{pl}X_p = \sum_{j=1}^p w_{jl}X_j \quad \text{dla } l = 1, \dots, m = p, \quad (1)$$

gdzie w_{jl} są ładunkami składowych.

Nowe, przetworzone zmienne Y_l nazywają się głównymi składowymi zmiennymi X_j . Zmienne składowe są kombinacjami cech wyjściowych i zawierają pewną część informacji wnoszonej przez poszczególne cechy wyjściowe. Są unormowane i nieskorelowane.

Metoda głównych składowych polega zatem na ortogonalnym przekształceniu p -wymiarowego układu zmiennych opisujących obserwacje wielowymiarowe na nowy układ zmiennych nieskorelowanych. Przekształcenia tego dokonuje się tak, że wariancje kolejnych składowych są coraz mniejsze, przy czym całkowita wariancja wszystkich zmiennych wyjściowych jest równa sumie wariancji wszystkich głównych składowych.

Podstawowy cel analizy głównych składowych polega na identyfikacji struktury zależności, poprzez utworzenie zupełnie nowego zbioru istotnych zmiennych, który częściowo bądź całkowicie mógłby zastąpić pierwotny zbiór zmiennych. Cel ten określa się jako redukcję wymiarowości złożonego zjawiska.

Istnieje kilka sposobów określania liczby składowych [Balicki 2009]:

1. Liczba głównych składowych powinna być taka, aby wyjaśniały one względnie dużą część całkowitej zmienności, określoną na 70-90%.
2. Liczbę głównych składowych należy ograniczyć do tych, które wyodrębniają przynajmniej tyle zmienności całkowitej, ile jedna standaryzowana zmienna oryginalna, czyli jeden (kryterium Kaisera).
3. Kryterium wykorzystujące metodę graficzną. Na wykresie liniowym można przedstawić wartości własne i odnaleźć punkt, od którego na prawo, następuje łagodny spadek wartości własnych. Jest to punkt, w którym „duże” wartości własne kończą się i zaczynają się „małe” wartości własne (kryterium według wykresu osypiska).

¹ Informacje o metodzie głównych składowych, jej genezie i rozwoju, można znaleźć w pracy [Balicki 2009].

Ostateczny zbiór cech diagnostycznych jest podstawą do zastosowania wybranej metody taksonomicznej, np. liniowego porządkowania obiektów. Na wstępie należy ustalić charakter cech, czyli wyróżnić: stymulanty, destymulanty² i nominanty. Stymulanty to takie cechy diagnostyczne, których wzrost kojarzyć należy ze wzrostem oceny zjawiska złożonego. Destymulanty zaś to cechy diagnostyczne, których wzrost powoduje spadek oceny zjawiska złożonego. Rzadziej w badaniach empirycznych pojawiają się nominanty. Za nominanty uważa się cechy, których rosnące do wartości nominalnej wartości bezwzględne powodują wzrost względnych wartości cechy, dalszy wzrost wartości pierwotnych związany jest ze zmniejszaniem się wartości unormowanych [Borys 1978].

Kolejnym etapem budowy cechy syntetycznej jest normalizacja cech. Normowanie cech powinno spełniać następujące warunki [Kukuła 2014]: przekształcone cechy powinny być pozbawione mian i sprowadzone do stałego przedziału wartości, najlepiej do przedziału [0, 1], możliwe są przekształcenia oryginalnych cech diagnostycznych przyjmujących wartości zarówno dodatnie, zero, jak i wartości ujemne, możliwe jest dodawanie cech diagnostycznych unormowanych w każdym z obiektów.

Spośród wielu metod normowania warunki te spełnia metoda unitaryzacji zerowanej (MUZ)³, charakteryzująca się stałym punktem odniesienia, którym jest rozstęp zmiennej normowanej. Normowanie cechy (stymulanty) dokonuje się w sposób następujący [Kukuła 2000]:

$$z_{ij} = \frac{x_{ij} - \min_i x_{ij}}{\max_i x_{ij} - \min_i x_{ij}}, \quad (2)$$

przy czym $z_{ij} \in [0, 1]$.

Aby przejść z wielu unormowanych cech do jednej oceny charakteryzującej obiekt należy zsumować wszystkie cechy unormowane dla każdego obiektu:

$$q_i = \sum_{j=1}^k z_{ij} \quad i = 1, 2, \dots, n. \quad (3)$$

Po podzieleniu wartości q_i przez liczbę cech diagnostycznych uzyskuje się uśrednioną ocenę cech unormowanych w i -tym obiekcie, która stanowi zmienną syntetyczną:

$$\mu_i = \frac{q_i}{k} \quad i = 1, 2, \dots, n. \quad (4)$$

Na podstawie uporządkowanych wartości miernika μ_i można podzielić zbiór obiektów na dowolną liczbę grup. W pracy dokonano podziału województw na trzy grupy według wzoru:

$$l = \frac{\max_i q_i - \min_i q_i}{3}. \quad (5)$$

Parametr l wykorzystuje się do podziału całego zbioru obiektów na grupy według poziomu zjawiska złożonego:

² Pojęcie stymulanty i destymulanty zostało wprowadzone przez Hellwiga [Hellwig 1968].

³ Więcej informacji można znaleźć w pracy [Kukuła 2000].

- I – najlepszy poziom: $\mu_i \in (\max_i \mu_i - l; \max_i \mu_i]$,
II – średni poziom: $\mu_i \in (\max_i \mu_i - 2l; \max_i \mu_i - l]$,
III – niski poziom: $\mu_i \in [\max_i \mu_i - 3l; \max_i \mu_i - 2l]$.

WYNIKI

Do realizacji celu, określonego jako ocena zróżnicowania rolnictwa w regionach Polski w ujęciu dynamicznym wykorzystano dane z publikacji Ministerstwa Rolnictwa i Rozwoju Wsi pt. „*Rolnictwo i Gospodarka Żywnościowa w Polsce*”. Badanie miało charakter dynamiczny i obejmowało okres 2011-2014. Analizując badane zjawisko utworzono wstępny zbiór cech diagnostycznych, który obejmował następujące wskaźniki:

- X_1 – średnie gospodarstwo (ha),
- X_2 – udział w krajowej powierzchni uprawy zasiewów (%),
- X_3 – udział w krajowej powierzchni uprawy zbóż (%),
- X_4 – udział w krajowej powierzchni uprawy ziemniaków (%),
- X_5 – udział w krajowej powierzchni uprawy buraków cukrowych (%),
- X_6 – udział w krajowej powierzchni uprawy rzepaku (%),
- X_7 – plony zbóż (dt/ha),
- X_8 – plony ziemniaków (dt/ha),
- X_9 – udział trwałych użytków zielonych w użytkach rolnych (%),
- X_{10} – pogłowie bydła (szt./ 100 ha UR),
- X_{11} – pogłowie krów (szt./ 100 ha UR),
- X_{12} – pogłowie trzody chlewnej (szt./ 100 ha UR),
- X_{13} – skup zbóż (kg/ha),
- X_{14} – skup ziemniaków (dt/ha),
- X_{15} – skup trzody chlewnej (kg/ha),
- X_{16} – skup bydła (kg/ha),
- X_{17} – skup drobiu (kg/ha),
- X_{18} – skup mleka (l/ha).

Wskaźniki poddano analizie statystycznej, obliczając wartości podstawowych parametrów opisowych. Wszystkie wskaźniki, w każdym roku, charakteryzowały się silną zmiennością, wyrażoną za pomocą współczynnika zmienności, który wyniósł dla każdej cechy powyżej 10%. W kolejnym kroku sprawdzono siłę korelacji pomiędzy cechami i metodą PCA wyeliminowano te cechy, które są silnie ze sobą powiązane, oddzielnie dla każdego analizowanego roku.

W celu eliminacji cech określono wektory wartości własnych oraz wartości mówiące o tym, jaki procent wariancji zmiennych, przyjętych w badaniu, wyjaśniają poszczególne główne składowe. O liczbie głównych składowych zdecydowało kryterium, mówiące, że należy wziąć pod uwagę tylko te składowe,

które mają wartość własną wynoszącą co najmniej 1,0 (kryterium Kaisera). Liczbę głównych składowych oraz procent zmienności wyjaśnianej przez te składowe w poszczególnych latach przedstawiono w Tabeli 1.

Tabela 1. Liczba składowych i procent zmienności

Rok	Liczba składowych	Procent zmienności
2011	5	85,29
2012	4	85,25
2013	5	90,32
2014	5	90,54

Źródło: opracowanie własne

Interpretując składowe, uwzględniono w badaniu te cechy, które mają względnie wysoką (dodatnią lub ujemną) wagę, wyrażoną wartością współczynnika korelacji ze składową na poziomie co najmniej 0,7. Następnie porównano zbiory cech otrzymane w każdym roku analizowanego okresu i otrzymano następujące cechy, tworzące ostateczny zbiór cech diagnostycznych:

- X_3 – udział w krajowej powierzchni uprawy zbóż (%),
- X_6 – udział w krajowej powierzchni uprawy rzepaku (%),
- X_7 – plony zbóż (dt/ha),
- X_{10} – pogłowie bydła (szt./ 100 ha UR),
- X_{12} – pogłowie trzody chlewnej (szt./ 100 ha UR),
- X_{13} – skup zbóż (kg/ha),
- X_{16} – skup bydła (kg/ha),
- X_{18} – skup mleka(l/ha),

który posłużył do utworzenia liniowego porządkowania i typologii województw pod względem poziomu rolnictwa.

Wśród wyodrębnionych cech zauważa się wskaźniki, które dotyczą pewnych aspektów związanych z działalnością w sektorze rolniczym. Dwie pierwsze cechy obejmują udziały województw w krajowej powierzchni zasiewów, kolejna cecha dotyczy plonów, następne odnoszą się do pogłowia zwierząt według województw na 100 ha UR a ostatnia grupa cech ma związek ze skupem podstawowych produktów rolniczych z 1 ha UR.

Na podstawie otrzymanego zbioru cech, w każdym roku utworzono liniowe porządkowanie regionów (Tabela 2).

Tabela 2. Wyniki liniowego porządkowania województw

Województwo	Pozycja w rankingu w roku			
	2011	2012	2013	2014
dolnośląskie	6	5	6	6
kujawsko-pomorskie	2	2	2	2
lubelskie	11	11	11	11
lubuskie	15	13	13	13
łódzkie	7	7	7	7
małopolskie	13	14	15	15
mazowieckie	4	4	5	5
opolskie	3	3	3	3
podkarpackie	16	16	16	16
podlaskie	5	6	4	4
pomorskie	9	8	8	8
śląskie	12	12	12	12
świętokrzyskie	14	15	14	14
warmińsko-mazurskie	8	9	9	9
wielkopolskie	1	1	1	1
zachodniopomorskie	10	10	10	10

Źródło: opracowanie własne

Analizując pozycje województw w porządkowaniach otrzymanych w czterech kolejnych latach okresu 2011-2014 zauważa się, iż w przypadku ośmiu województw nastąpiły bardzo nieznaczne zmiany w pozycjach zajmowanych w rankingach. Zmiany te dotyczą jednego lub dwóch miejsc. Taka sytuacja odnosi się np. do województw: lubuskiego i podlaskiego. W przypadku pozostałych regionów nie stwierdzono zmian pozycji zajmowanej w rankingach w ciągu czterech analizowanych lat (np. kujawsko-pomorskie, wielkopolskie, zachodniopomorskie).

Dużą zgodność między pozycjami województw w rankingach w okresie 2011-2014 potwierdzają wartości współczynników korelacji τ Kendalla, które przyjmują wartości powyżej 0,9.

Województwo wielkopolskie zajmuje pierwszą lokatę we wszystkich czterech latach, a ostatnią pozycję – region podkarpacki. Pierwsza pozycja województwa wielkopolskiego związana jest z najwyższymi wartościami takich wskaźników, jak: udział w krajowej powierzchni uprawy zbóż (%), pogłowie trzody chlewnej (szt./ 100 ha UR), skup bydła (kg/ha) – w okresie 2012-2014 i udział w krajowej powierzchni uprawy zbóż (%), pogłowie trzody chlewnej (szt./ 100 ha UR) – w roku 2014. Wartości pozostałych cech pozostają także na bardzo wysokim poziomie. Natomiast województwo podkarpackie zajęło ostatnią pozycję we wszystkich rankingach ponieważ wartości wszystkich cech przyjętych w badaniu w każdym roku są na bardzo niskim poziomie.

Na podstawie wartości cechy syntetycznej dokonano klasyfikacji województw pod względem stanu rolnictwa. W całym badanym okresie tylko w przypadku województwa kujawsko-pomorskiego zaobserwowano zmianę przynależności do grupy rozwojowej. W latach 2011-2012 znajdowało się ono w grupie drugiej a w dwóch następnych latach – w grupie pierwszej. Przemieszczenie do grupy pierwszej wynikało ze zwiększenia z roku na rok wartości niektórych cech, takich, jak: X_6 , X_7 , X_{10} , X_{12} , X_{16} , X_{18} . Największe średnie wzrosty w całym badanym okresie zaobserwowano w przypadku udziału w krajowej powierzchni uprawy rzepaku – o 21,5% i skupu bydła – o 20,9%.

Ze względu na bardzo zbliżone wyniki klasyfikacji w każdym roku, podano podział województw uzyskany dla roku 2014 (tablica 3).

Tabela 3. Wyniki klasyfikacji województw w roku 2014

Grupa	Liczba województw	Województwo	Charakterystyka grupy pod względem średnich wartości cech
I	2	wielkopolskie, kujawsko-pomorskie	najwyższe wartości cech: X_3 , X_6 , X_7 , X_{10} , X_{12} , X_{16} , X_{18}
II	8	opolskie, podlaskie, mazowieckie, dolnośląskie, łódzkie, pomorskie, warmińsko- mazurskie, zachodniopomorskie	najwyższa wartość cechy X_{13} , wysokie wartości pozostałych cech
III	6	lubelskie, śląskie, lubuskie, świętokrzyskie, małopolskie, podkarpackie	najniższe wartości wszystkich cech

Źródło: opracowanie własne

Województwa należące do klasy pierwszej stanowią klasę o najlepszym stanie rolnictwa z uwzględnieniem przyjętych cech diagnostycznych. Klasa druga zawierająca osiem obiektów to klasa o średnim poziomie rolnictwa, a skupienie trzecie zawiera sześć obiektów, które stanowią najślabszą grupę województw pod względem poziomu rolnictwa na tle przyjętych wskaźników. Przestrzenną delimitację województw przedstawiono na Rysunku 1.

Rysunek 1. Przestrzenna delimitacja województw pod względem poziomu rolnictwa w roku 2014



Źródło: opracowanie własne na podstawie Tabeli 3

Klasę pierwszą, pod względem położenia geograficznego, stanowią dwa sąsiadujące ze sobą województwa: wielkopolskie i kujawsko-pomorskie. Klasa trzecia to przede wszystkim obiekty leżące w południowo-wschodniej części Polski oraz jedno województwo z zachodniej części kraju – lubuskie. Pozostałe województwa, położone w północnej, środkowej i południowo-zachodniej części kraju składają się na trzecia klasę województw.

PODSUMOWANIE

W pracy zastosowano wybrane metody wielowymiarowej analizy porównawczej do oceny zróżnicowania rolnictwa w regionach Polski w ujęciu dynamicznym. Badanie obejmowało okres 2011-2014. Do selekcji cech wykorzystano metodę głównych składowych (PCA). Typologię województw przeprowadzono za pomocą klasyfikacji opartej na liniowym porządkowaniu obiektów.

Przeprowadzone badanie pozwoliło na sformułowanie następujących wniosków:

1. Województwa są silnie zróżnicowane pod względem poziomu rolnictwa biorąc pod uwagę przyjęte cechy diagnostyczne.
2. Rankingi województw otrzymane w latach 2011-2014 różnią się nieznacznie pod względem pozycji zajmowanych przez poszczególne województwa.
3. Kilka regionów zmieniło swoje pozycje w porządkowanych. Różnica dotyczyła jednego lub dwóch miejsc. Pozostałe województwa utrzymywały niezmienną lokatę w każdym analizowanym roku.
4. Miejsce pierwsze w każdym rankingu zajmowało województwo wielkopolskie, a ostatnie – podkarpackie.

5. Klasyfikacja województw utworzona na podstawie wartości zmiennej syntetycznej pozwoliła na wyłonienie trzech grup typologicznych województw. W badanym okresie 2011-2014 nie zauważono znaczących zmian w otrzymanych klasyfikacjach. Jedynie województwo kujawsko-pomorskie zmieniło swoją przynależność. W latach 2011-2012 zostało przypisane do klasy drugiej a w latach następnych zmieniło przynależność do klasy pierwszej.
6. Wśród trzech grup typologicznych klasa pierwsza charakteryzuje się najwyższymi wartościami wskaźników przyjętych w badaniu i posiada najwyższy poziom rozwoju rolnictwa. Klasa druga to obiekty o średnim poziomie rozwoju analizowanego zjawiska. Natomiast skupienie trzecie odznacza się najniższym poziomem rozwoju rolnictwa.

BIBLIOGRAFIA

- Adamowicz M. (2009) Współczesna rola rolnictwa a modele interwencjonizmu rolnego, *Wieś i Rolnictwo*, nr 2 (143), s. 32-54.
- Balicki A. (2009) Statystyczna Analiza wielowymiarowa i jej zastosowania społeczno-ekonomiczne, Wydawnictwo Uniwersytetu Gdańskiego, Gdańsk.
- Beba P., Poczta, W. (2015) Miejsce rolnictwa w gospodarce polskich regionów. *Journal of Agribusiness and Rural Development*, 1(35), s. 17-26.
- Bindermann A. (2012) Rozwój polskiego rolnictwa w kontekście regionalnego zróżnicowania w latach 1998-2010, *Metody Ilościowe w Badaniach Ekonomicznych*, t. XIII/3, s. 52-64.
- Bożek J., Bożek B. (2011) Typologia struktury agrarnej województw w ujęciu dynamicznym z zastosowaniem klasyfikacji rozmytej, *Metody Ilościowe w Badaniach Ekonomicznych*, t. XII/2, s. 91-100.
- Kamińska A., Nowak A. (2014) Zastosowanie analizy skupień do badania zróżnicowania regionalnego potencjału produkcyjnego rolnictwa w Polsce, *Stowarzyszenie Ekonomistów Rolnictwa i Agrobiznesu, Roczniki Naukowe*, t. XVI, z. 3, s. 126-130.
- Poczta W., Bartkowiak N. (2012) Regionalne zróżnicowanie rolnictwa w Polsce, *Journal of Agribusiness and Rural Development*, 1(23) 2012, s. 95-109.
- Rolnictwo i Gospodarka Żywnościowa w Polsce (2012-2015), Praca zbiorowa pod redakcją Instytutu Ekonomiki Rolnictwa i Gospodarki Żywnościowej, Ministerstwo Rolnictwa i Rozwoju Wsi, Warszawa 2012-2015.
- Weiss E., Bitkowska A. (2014) Rolnictwo w Polsce w świetle zmian polityki Unii Europejskiej. *Journal of Agribusiness and Rural Development*, 2(32), s. 203-212.
- Wysocki F. (2010) Metody taksonomiczne w rozpoznawaniu typów ekonomicznych rolnictwa i obszarów wiejskich, Wydawnictwo Uniwersytetu Przyrodniczego w Poznaniu, Poznań.

**AGRICULTURE IN REGIONS. MULTIVARIATE ANALYSIS
THROUGH DYNAMIC APPROACH**

Abstract: In this study selected multivariate comparative analysis were applied to assess and compare level of Polish regional agriculture in dynamic approach. Study period covered the years 2011-2014. Set of diagnostic features concerned numerous agriculture aspects: sowing area, number of animals, purchase of agricultural products and harvests. Obtained results indicate that agriculture sector in Polish voivodships is highly diverse and changes in are slower comparing to other sectors of the national economy, what result from its specific character.

Keywords: agriculture, regions, diversity

ZASTOSOWANIE METOD PORZĄDKOWANIA LINIOWEGO DO OCENY POZIOMU ROZWOJU SPOŁECZNO-GOSPODARCZEGO POWIATÓW WOJEWÓDZTWA LUBUSKIEGO

Przemysław Szczuciński

Wydział Ekonomiczny, Państwowa Wyższa Szkoła Zawodowa
im. Jakuba z Paradyża w Gorzowie Wielkopolskim
e-mail: pszczucinski@pwsz.pl

Streszczenie: Rozwój społeczno-gospodarczy jest zróżnicowany w wymiarze przestrzennym. Podstawowymi jednostkami są w tym wymiarze województwa. W artykule ocenie poddano poziom rozwoju społeczno-gospodarczego województwa lubuskiego na szczeblu powiatów. Zastosowano w tym celu metody porządkowania liniowego. Wykorzystano mierniki oparte zarówno o jeden, jak i dwa wzorce. Określono powiaty o wyższym i niższym poziomie rozwoju. Wyniki wskazują, że bardziej właściwe jest stosowanie mierników opartych o dwa wzorce. Rozbieżność wyników jest mniejsza, a otrzymane rankingi bardziej zbieżne do siebie.

Słowa kluczowe: rozwój społeczno-gospodarczy, analiza taksonomiczna, metody porządkowania liniowego, zróżnicowanie powiatów, województwo lubuskie

WPROWADZENIE

Region to najogólniej zespół obszarów graniczących ze sobą wyróżnionych pod względem podobnych kryteriów w stosunku do obszarów przyległych. W różnych definicjach podkreśla się przy tym różne cechy regionu. Biorąc pod uwagę kryterium administracyjne pod pojęciem regionu rozumie się ściśle wyznaczony obszar terytorialny, obejmujący kompleks gospodarczy o określonym profilu lub specjalizacji z wyodrębnionym centrum administracyjno-gospodarczym, pełniącym funkcje ośrodka decydującego o jego funkcjonowaniu i rozwoju [Korenik, 2003, s. 52]. W tym rozumieniu podstawową jednostką podziału regionalnego kraju stanowi województwo. W układzie przestrzennym

wyróżnić można również jednostki wyższego i niższego rzędu. Te pierwsze składają się z kilku regionów i są to makroregiony. Na ich poziomie nie ma jednostek administracji publicznej, lecz pełnią one ważną funkcję planistyczno-pomocniczą. Podobną funkcję stanowią podregiony. Na niższym, lokalnym poziomie wyróżnia się powiaty i gminy [por. Jankowski, 2013, s. 231].

Rozwój społeczno-gospodarczy regionu jest kategorią wielowymiarową. Proces ten obejmuje zarówno zmiany ilościowe (wzrost PKB) jak i strukturalno-jakościowe w gospodarce. Przekłada się on również na zmiany w sposobie, jakości i poziomie życia mieszkańców. Istotna jest także dostępność do urządzeń i instytucji świadczących usługi na rzecz zaspokojenia potrzeb społecznych. Rozwój regionu jest też procesem wzajemnej wymiany pomiędzy człowiekiem a otaczającym go środowiskiem przyrodniczym [Adamiak i in. 2001, s. 28 i n.]. Proces ten ma także swój wymiar przestrzenny. W literaturze wskazuje się na znaczące zróżnicowanie w przekroju regionalnym takich zjawisk, jak: zagęszczenia ludności, kapitału, inwestycji, migracji, zatrudnienia czy dochodów. Problematykę tę poruszają między innymi: Korenik [2003], Zaucha i in. [2015], Korol i in. [2016]. Niejednorodny w przestrzeni jest również poziom rozwoju mniejszych jednostek, tj. powiatów, gmin i miast. W tym ujęciu można mówić o zróżnicowaniu rozwoju wewnątrz regionów. Do podstawowych metod ilościowych znajdujących zastosowanie w tym względzie należą metody taksonomiczne [zob. Pocięcha, 2008].

W Strategii Rozwoju Województwa Lubuskiego 2020 [Zielona Góra, 2012] określono, że celem głównym jest wykorzystanie potencjałów województwa lubuskiego do wzrostu jakości życia, dynamizowania konkurencyjnej gospodarki, zwiększania spójności regionu oraz efektywnego zarządzania jego rozwojem. Badanie ma na celu określenie zróżnicowania przestrzennego rozwoju społeczno-gospodarczego województwa na poziomie powiatów przy zastosowaniu metod porządkowania liniowego.

METODA BADAWCZA

Rozwój społeczno-gospodarczy regionu jest procesem wieloaspektowym i złożonym. Oceny takich złożonych zjawisk dokonuje się przez zastosowanie wskaźników cząstkowych lub wskaźnika syntetycznego. Oba te sposoby traktować należy jako uzupełniające wobec siebie. Analiza cząstkowa pozwala na określenie szczegółowo różnych aspektów zjawisk. Analiza syntetyczna umożliwia natomiast całościowe spojrzenie na badane zagadnienie. W analizie syntetycznej zastosowanie znajdują metody porządkowania liniowego.

Wśród różnych stosowanych miar wymienić należy między innymi mierniki: Helwiga [1968], Cieślak [1974], Walesiaka [2006]. Interesującą propozycję przedstawiono również w pracy Bindermana Z., Borkowskiego, Prokopenya i Szczęsnego [2015, s. 23-39]. Autorzy wskazują, że jeżeli przyjrzeć się

proponowanym w literaturze wskaźnikom to okazuje się, że w wielu przypadkach przedstawić je można jako funkcje odległości od jednego lub dwóch wzorców.

Podstawę zaproponowanej metody stanowi wejściowa macierz danych. Dla n obiektów i m zmiennych diagnostycznych określona jest ona jako:

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix}. \quad (1)$$

Dane statystyczne następnie należy poddać normalizacji oraz wyznaczyć odległość pomiędzy odpowiednimi obiektami oznaczoną jako d . Przyjmując, że obiekt \mathbf{x}_{\min} oznacza obiekt najlepszy (wzorcowy) i \mathbf{x}_{\max} najgorszy (antywzorcowy) mierniki rozwoju wyraża się jako:

$$w_1(\mathbf{x}) = \frac{d(\mathbf{x}_{\min}, \mathbf{x})}{d(\mathbf{x}_{\min}, \mathbf{x}_{\max})}, \quad (2)$$

$$w_2(\mathbf{x}) = 1 - \frac{d(\mathbf{x}_{\max}, \mathbf{x})}{d(\mathbf{x}_{\min}, \mathbf{x}_{\max})}. \quad (3)$$

Odległość d wyraża wzór:

$$d(\mathbf{x}_*, \mathbf{x}) = \left[\sum_{i=1}^n |x_i^* - x_i|^p \right]^{1/p}, \quad (4)$$

gdzie: \mathbf{x}_* to odpowiednio \mathbf{x}_{\min} i \mathbf{x}_{\max} , dla $p=1$ jest to odległość miejska, dla $p=2$ odległość euklidesowa [np. Kolenda 2006, s. 53].

Powyżej przedstawione mierniki wykorzystują jeden wzorec. Miernik $w_1(\mathbf{x})$ bazuje na odległości od antywzorca, miernik $w_2(\mathbf{x})$ od wzorca¹. Wskazuje się także, że pojedynczy miernik syntetyczny może być daleki od optymalnego oraz sugeruje użycie mierników opartych o dwa wzorce [zob. Binderman A., 2006; 2011].

W tym względzie zastosować można następujące rozwiązania:

$$w_3(\mathbf{x}) = \frac{2}{\frac{1}{w_1(\mathbf{x})} + \frac{1}{w_2(\mathbf{x})}}, \quad (5)$$

$$w_4(\mathbf{x}) = \sqrt{w_1(\mathbf{x}) \cdot w_2(\mathbf{x})}, \quad (6)$$

¹ Wzorec rozwoju to obiekt, który posiada najwyższe wartości zmiennych stymulant i najniższe destymulant. Antywzorec posiada najniższe wartości stymulant i najwyższe destymulant.

$$w_5(\mathbf{x}) = \frac{w_1(\mathbf{x}) + w_2(\mathbf{x})}{2}, \quad (7)$$

$$w_6(\mathbf{x}) = \sqrt{\frac{w_1(\mathbf{x})^2 + w_2(\mathbf{x})^2}{2}}, \quad (8)$$

$$w_7(\mathbf{x}) = \frac{d(\mathbf{x}_{\min}, \mathbf{x})}{d(\mathbf{x}_{\min}, \mathbf{x}) + d(\mathbf{x}_{\max}, \mathbf{x})} = \frac{w_1(\mathbf{x})}{1 + w_1(\mathbf{x}) - w_2(\mathbf{x})}. \quad (9)$$

Mierniki $w_3(\mathbf{x})$, $w_4(\mathbf{x})$, $w_5(\mathbf{x})$ oraz $w_6(\mathbf{x})$ stanowią odpowiednio formuły średnich: harmoniczej, geometrycznej, arytmetycznej i kwadratowej. Miernik $w_7(\mathbf{x})$ związany jest z metodą TOPSIS [Hwang, Yoon 1981; za: Binderman Z. i in., 2015, s. 30]. Według tej metody za najlepszy obiekt uważa się ten, który ma najmniejszą odległość od wzorca i jednocześnie największą od antywzorca. Kryterium to wykorzystują również mierniki $w_3(\mathbf{x}) - w_6(\mathbf{x})$. Natomiast miernik $w_2(\mathbf{x})$ przy standaryzacji cech wyraża formułę Hellwiga, która wykorzystuje obiekt najlepszy \mathbf{x}_{\max} .

Przedstawione mierniki są unormowane i spełniają właściwości:

$$0 \leq w_k(\mathbf{x}) \leq 1 \text{ dla } \mathbf{x} \in \langle \mathbf{x}_{\min}, \mathbf{x}_{\max} \rangle, \text{ dla } k = 1, 2, \dots, 7,$$

$$w_k(\mathbf{x}_{\min}) = 0, \quad w_k(\mathbf{x}_{\max}) = 1.$$

Dodać można, że:

$$w_3(\mathbf{x}) \leq w_4(\mathbf{x}) \leq w_5(\mathbf{x}) \leq w_6(\mathbf{x}).$$

Relacja ta wynika z nierówności opisującej średnie użyte do konstrukcji mierników $w_3(\mathbf{x}) - w_6(\mathbf{x})$ [Mitronović, 1972, s. 19].

WOJEWÓDZTWO LUBUSKIE I JEGO POWIATY

Województwo lubuskie położone jest w zachodniej części Polski. Graniczy z Niemcami oraz z trzema innymi województwami: zachodniopomorskim, wielkopolskim i dolnośląskim. Jest to jedno z mniejszych województw w kraju. Powierzchnia województwa wynosi 13 988 km², liczba ludności 1 020 tys. osób [zob. Województwo lubuskie..., 2015]. Cechą charakterystyczną jest duże zalesienie w regionie. Lasy stanowią 50,8% jego powierzchni i jest to najwyższy odsetek w Polsce. Województwo lubuskie posiada dwie stolice. Gorzów Wielkopolski jest siedzibą wojewody, Zielona Góra jest siedzibą władz samorządowych. Obie stolice województwa liczą około 120 tys. mieszkańców. Razem sieć osadnicza składa się z 42 miast i 1297 wsi. Odsetek ludności w miastach wynosi 63,1%, na wsi 36,9%.

Według danych za 2014 r. liczba podmiotów gospodarczych zarejestrowanych w REGON wynosi 110,1 tys. Wartość brutto środków trwałych

w gospodarce sięga 87,7 mld zł. Nakłady inwestycyjne kształtują się na poziomie 4,8 mln zł. Produkt krajowy brutto wytworzony w regionie wynosi 38 mld 366 mln zł. Stanowi to 2,2% udziału w gospodarce kraju. W regionie zatrudnionych jest 330,5 tys. pracujących. Udział pracujących w rolnictwie wynosi 11,3%, w przemyśle 31,9%, w usługach 56,8%. Największy udział w produkcji sprzedanej przemysłu mają takie działy, jak: produkcja pojazdów samochodowych, przyczep i naczep 15,7%, wyrobów z drewna, korka i wikliny 11,3%, artykułów spożywczych 8,9%, papieru i wyrobów z papieru 8,3%, wyrobów z metali 6,9%. Stopa bezrobocia w regionie wynosi 12,5%. W ostatnim badanym roku odnotować należy jej znaczący spadek o 3,2 p.p.

Pewną odrębność i specyfikę posiada także każdy z obszarów wchodzących w skład województwa. W artykule wzięto pod uwagę powiaty regionu. Wstępnie do oceny rozwoju powiatów wytypowano 50 cech diagnostycznych. Kierując się kryteriami statystycznymi wyeliminowano cechy, które charakteryzowały się poziomem zmienności niższym niż 10% oraz dla których bezwzględne wartości współczynników korelacji były wyższe niż 0,85. Wyboru finalnego cech dokonano kierując się kryterium ich zgodności merytorycznej z pojęciem rozwoju społeczno-gospodarczego. W ten sposób wybrano ostatecznie 18 cech diagnostycznych. Charakteryzują one następujące aspekty rozwoju społeczno-gospodarczego: stan ilościowy podmiotów gospodarczych, sytuację na rynku pracy, produkcję, środki trwałe i inwestycje, sytuację demograficzną, edukację, ochronę zdrowia, bezpieczeństwo publiczne, budownictwo mieszkaniowe, turystykę, ochronę środowiska, finanse jednostek samorządów terytorialnych [por. Zeliaś, 2000; Malina, 2004; Strahl (red.), 2006]. Dane statystyczne według powiatów za 2014 rok przedstawiono w Tabeli 1.

Tabela 1. Cechy diagnostyczne poziomu rozwoju społeczno-gospodarczego powiatów województwa lubuskiego za 2014 rok

Zmienna	\bar{x}	$s(x)$	V_s	Min. i max.	
X_1	Liczba podmiotów gospodarczych zarejestrowanych w rejestrze REGON na tys. mieszkańców	103,2	20,1	19,5	82,1 – nowosolski 150,6 – m. Zielona Góra
X_2	Udział nowych podmiotów sektora kreatywnego w liczbie nowych podmiotów ogółem%*	3,88	1,07	27,6	2,5 – krośnieński 6,6 – m. Zielona Góra
X_3	Pracujący w sektorze usług w % ogółu pracujących	47,7	11,6	24,3	30,0 – gorzowski 76,3 – m. Zielona Góra
X_4	Stopa bezrobocia rejestrowanego w % stan w grudniu	13,8	5,24	38,0	5,9 – m. Gorzów Wlkp. 22,2 – żagański
X_5	Liczba ofert pracy na 100 bezrobotnych za grudzień	4,02	1,89	46,9	1,9 -strzelecko-drezdenecki 8,7 – m. Gorzów Wlkp.
X_6	Produkcja sprzedana przemysłu na mieszkańca w tys. zł**	25,1	15,4	61,6	9,4 – sulęciński 60,0 – m. Gorzów Wlkp.

Zmienna		\bar{x}	s(x)	V_s	Min. i max.
X ₇	Wartość brutto środków trwałych w przedsiębiorstwach na mieszkańca w tys. zł **	31,2	22,9	73,6	12,7 – krośnieński 104,0 – m. Zielona Góra
X ₈	Nakłady inwestycyjne w przedsiębiorstwach na mieszkańca w tys. zł **	2,48	0,86	34,6	1,4 – żagański 4,1 – Gorzów Wlkp.
X ₉	Saldo migracji międzypowiatowych i zagranicznych na pobyt stały na tys. mieszkańców***	-1,77	2,72	X	-5,2 – krośnieński 4,4 – m. Zielona Góra
X ₁₀	Przyrost naturalny na tys. mieszkańców***	0,22	1,00	X	-2,0 – żagański 1,7 – zielonogórski
X ₁₁	Studenci szkół wyższych na tys. mieszkańców	11,5	27,7	241,9	0,0 – 7 powiatów 107,8 – m. Zielona Góra
X ₁₂	Lekarze i lekarze dentyści na 10 tys. mieszkańców	44,2	22,2	50,2	23,0 – żagański 102,0 – m. Zielona Góra
X ₁₃	Przestępstwa stwierdzone w zakończonych postępowaniach przygotowawczych na tys. mieszkańców	27,8	7,14	25,7	17,7 – wschowski 40,9 – nowosolski
X ₁₄	Mieszkania oddane do użytkowania na tys. mieszkańców	3,04	1,47	48,2	1,2 – żagański 7,1 – m. Zielona Góra
X ₁₅	Udzielone noclegi na 100 mieszkańców w turystycznych obiektach noclegowych	145,9	107,7	73,8	37,7 – żarski 394,3 – świebodziński
X ₁₆	Nakłady inwestycyjne na ochronę środowiska i gospodarkę wodną w tys. zł na mieszkańca	8,84	14,6	165,4	1,5 – międzyrzecki 57,0 – wschowski
X ₁₇	Dochody własne powiatów i gmin na mieszkańca w tys. zł	2,09	0,24	11,7	1,6 – wschowski 2,5 – m. Zielona Góra
X ₁₈	Środki z Unii Europejskiej na finansowanie projektów unijnych na mieszkańca w zł	51,7	33,5	64,8	5,7 – m. Gorzów Wlkp. 129,1 – sulęciński

* Do sektora kreatywnego zalicza się następujące działy PKD: działalność związaną z produkcją filmów, nagrań i programów telewizyjnych, nadawanie programów ogólnodostępnych i abonamentowych, działalność w zakresie architektury i inżynierii, reklamę, badania rynku i opinii publicznej, działalność twórczą związaną z kulturą i rozrywką, pozostała działalność profesjonalną, naukową i techniczną.

** Dane dotyczą przedsiębiorstw o liczbie pracujących powyżej 9 osób.

*** Współczynnika zmienności nie wyznaczano, gdyż jest to niecelowe.

Źródło: opracowanie własne na podstawie Województwo lubuskie... [2015], Banku Danych Lokalnych GUS [dostęp: 05.04.2016]

Poziom zróżnicowania wybranych do badania cech diagnostycznych jest znaczący. Współczynniki zmienności kształtują się od 11,7% dla zmiennej dochody własne powiatów i gmin nawet do 241,9% dla liczby studentów szkół wyższych. Pierwszą ze zmiennych charakteryzujących rozwój powiatów jest liczba

podmiotów gospodarczych zarejestrowanych w REGON. W przeliczeniu na tys. mieszkańców wynosi ona od 82,1 w powiecie nowosolskim do 150,6 w powiecie miejskim Zielona Góra. Relatywnie najwięcej jest też w tym mieście tworzonych podmiotów sektora kreatywnego. Wśród wszystkich nowoutworzonych podmiotów stanowią one 6,6%. Także najwyższy jest odsetek pracujących w sektorze usług, tj. 76,3%. Najniższy występuje w powiecie gorzowskim 30,0%.

Istotne zróżnicowanie wykazuje także stopa bezrobocia w regionie. Kształtuje się od 5,9% w Gorzowie Wlkp. do 22,2% w powiecie żagańskim. Charakterystyczny dla Gorzowa Wlkp. jest także najwyższy poziom produkcji sprzedanej przemysłu i nakładów inwestycyjnych w przedsiębiorstwach. Wartość produkcji sprzedanej przemysłu sięga 60,0 tys. zł. na mieszkańca. Natomiast w Zielonej Górze najwyższe są następujące wskaźniki: dochody własne powiatu na mieszkańca, wartość brutto środków trwałych w przedsiębiorstwach, liczba mieszkań oddanych do użytku, liczby lekarzy i lekarzy dentystów oraz liczba studentów. Najkorzystniejsze jest też saldo migracji międzypowiatowych i zagranicznych na pobyt stały. Wynosi ono 4,4 na tys. mieszkańców. Największy odpływ ludności obserwuje się w powiecie krośnieńskim. Saldo w powiecie tym wynosi -5,2 na tys. mieszkańców.

Wśród innych cech najwyższy przyrost naturalny występuje w powiecie zielonogórskim. Poziom wynosi 1,7 na tys. mieszkańców. Z kolei relatywnie najwięcej turystów odwiedza powiat świebodziński. W powiecie tym w 2014 roku udzielono 394,3 noclegów w przeliczeniu na tys. mieszkańców. Największy napływ środków z Unii Europejskiej odnotować należy w powiecie sułecińskim. Poziom wydatków na finansowanie projektów unijnych wyniósł 129,1 zł na mieszkańca. Najmniejszy był w Gorzowie Wlkp. 5,7 zł na mieszkańca.

PORZĄDKOWANIE LINIOWE POWIATÓW WEDŁUG POZIOMU ROZWOJU

Rozwój społeczno-gospodarczy jest wypadkową wielu cech. Dane statystyczne wskazują, że ich rozkład jest niejednorodny i różne jest nasilenie poszczególnych aspektów rozwoju według powiatów. W celu dokonania syntetycznej oceny zjawiska wykorzystano metody porządkowania liniowego. Zastosowano zarówno mierniki opierające się na jednym, jak i na dwóch wzorcach. Jako metodę normalizacji wybrano jedną z częściej stosowanych metod – standaryzację cech [zob. Kukuła, 2000; Młodak, 2006; Pawełek, 2008]. Spośród wybranych cech X_4 i X_{13} , tj. stopa bezrobocia rejestrowanego i przestępstwa stwierdzone w zakończonych postępowaniach przygotowawczych stanowią destymulanty rozwoju. Pozostałe cechy to stymulanty rozwoju. Przyjęto, że każda z cech jest jednakowo ważna. W związku z tym każdej z nich przypisano taką

samą (jednostkową) wagę. Wyniki obliczeń dla poszczególnych mierników przedstawiono w Tabeli 2.

Tabela 2. Poziom rozwoju społeczno-gospodarczego powiatów województwa lubuskiego za 2014 rok

Lp.	Powiat	Miernik w ₁	Miernik w ₂	Miernik w ₃	Miernik w ₄	Miernik w ₅	Miernik w ₆	Miernik w ₇
1.	gorzowski	0,536 (3)	0,340 (4)	0,416 (4)	0,427 (4)	0,438 (4)	0,449 (4)	0,448 (4)
2.	międzyrzecki	0,391 (9)	0,251 (8)	0,306 (9)	0,314 (9)	0,321 (9)	0,329 (9)	0,343 (9)
3.	słubicki	0,452 (7)	0,296 (5)	0,358 (5)	0,366 (5)	0,374 (5)	0,382 (5)	0,391 (5)
4.	strzelecko- -drezdenecki	0,334 (12)	0,209 (12)	0,257 (12)	0,263 (13)	0,271 (13)	0,278 (12)	0,297 (12)
5.	sulęciński	0,458 (5)	0,272 (6)	0,341 (6)	0,353 (6)	0,365 (6)	0,377 (6)	0,386 (6)
6.	m. Gorzów Wlkp.	0,621 (2)	0,448 (2)	0,521 (2)	0,528 (2)	0,535 (2)	0,542 (2)	0,530 (2)
7.	krośnieński	0,350 (11)	0,201 (13)	0,255 (13)	0,264 (12)	0,275 (11)	0,285 (11)	0,304 (11)
8.	nowosolski	0,328 (13)	0,214 (11)	0,259 (11)	0,265 (11)	0,272 (12)	0,277 (13)	0,295 (13)
9.	świebodziński	0,513 (4)	0,385 (3)	0,440 (3)	0,444 (3)	0,449 (3)	0,454 (3)	0,455 (3)
10.	wschowski	0,457 (6)	0,243 (10)	0,317 (8)	0,333 (7)	0,350 (7)	0,366 (7)	0,377 (7)
11.	zielonogórski	0,416 (8)	0,262 (7)	0,322 (7)	0,331 (8)	0,339 (8)	0,348 (8)	0,361 (8)
12.	żagański	0,264 (14)	0,141 (14)	0,184 (14)	0,193 (14)	0,202 (14)	0,211 (14)	0,235 (14)
13.	żarski	0,361 (10)	0,248 (9)	0,294 (10)	0,300 (10)	0,305 (10)	0,310 (10)	0,325 (10)
14.	m. Zielona Góra	0,791 (1)	0,481 (1)	0,598 (1)	0,617 (1)	0,636 (1)	0,655 (1)	0,604 (1)


*W nawiasach podano pozycję powiatów w rankingu według danego miernika.

Źródło: obliczenia własne

Generalnie wyższa wartość danego miernika wskazuje na wyższy poziom rozwoju społeczno-gospodarczego powiatów. Zauważyć jednak należy, że otrzymane wyniki różnią się między sobą. Największe różnice wykazują wartości dla miar $w_1(\mathbf{x})$ i $w_2(\mathbf{x})$. Na przykład w przypadku m. Zielona Góra różnica otrzymanych wyników wynosi 0,311. Istotne są również różnice w otrzymanych rankingach. Szczególnie widoczna jest w przypadku powiatu wschowskiego. Według pierwszego miernika powiat ten zajmuje w rankingu 6 a według drugiego 10 pozycję.

Wyraźnie mniejsze różnice wyników występują dla miar opartych o dwa wzorce. Największa różnica ma miejsce między miarami $w_3(x)$ oraz $w_7(x)$ dla powiatu wschowskiego i wynosi 0,060. Ogólnie różnice w rankingu wynoszą maksymalnie 2 pozycje, a w wielu przypadkach pozycje te są identyczne. Wskazuje to, że bardziej właściwe jest stosowanie miar opartych o dwa wzorce. Mniejsza jest rozbieżność wyników dla tej grupy miar. Ilustrację wyników stanowi Rysunek 1.

Rysunek 1. Wartości mierników $w_3 - w_7$ według powiatów województwa lubuskiego




Źródło: opracowanie własne

Spośród metod opartych o dwa wzorce do oceny poziomu rozwoju powiatów wybrano miernik w_7 związany ze znaną w literaturze metodą TOPSIS. Rozkład wartości miernika według powiatów przedstawiono na Rysunku 2.

W skali województwa najwyższy poziom rozwoju społeczno-gospodarczego wykazują jego dwie stolice Zielona Góra i Gorzów Wlkp. Wartości miernika rozwoju sięgają odpowiednio 0,604 i 0,530. Średnim poziomem na tle pozostałych jednostek charakteryzują się powiaty: zielonogórski, gorzowski, ślubicki, sulęciński, świebodziński i wschowski. Z wyłączeniem powiatu wschowskiego tworzą one swego rodzaju pas przez centralną część województwa. Mierniki rozwoju dla tej grupy powiatów kształtują się w przedziale 0,35 - 0,50. Słabiej rozwinięte są powiaty położone na krańcach województwa. Zaliczyć do nich należy z części północno-wschodniej regionu powiaty: strzelecko-drezdenecki i międzyrzeczki oraz z części południowej: krośnieński, żarski, żagański i nowosolski. Wartości miernika rozwoju wynoszą poniżej 0,35.

Rysunek 2. Rozkład przestrzenny miernika w7 według powiatów województw lubuskiego



Źródło: opracowanie własne

Otrzymane wyniki świadczą o występowaniu zróżnicowania poziomu rozwoju społeczno-gospodarczego powiatów. Wydaje się, że nie bez znaczenia jest w tym względzie oddziaływanie obu stolic województwa na sytuację w innych powiatach. Dotyczy to zwłaszcza powiatów najbliższych położonych gorzowskiego i zielonogórskiego. W przypadku powiatu ślubickiego istotne może być usytuowanie od strony niemieckiej miasta Frankfurt nad Odrą oraz wpływ handlu przygranicznego na rozwój powiatu. Natomiast w przypadku powiatów: strzelecko-drezdeneckiego, międzyrzeczki, krośnińskiego, żagańskiego i nowosolskiego uwidaczniającym się zjawiskiem jest wysoka stopa bezrobocia. Wymienione czynniki rozwoju i ich oddziaływanie wymagają jednak dalszych bardziej szczegółowych badań.

PODSUMOWANIE

Województwo lubuskie ze względu na położenie, wielkość, zasoby naturalne i profil produkcyjny charakteryzuje swoista specyfika na tle innych województw. Pewną odmienność posiada także każdy z obszarów je tworzących, tj. powiatów. Ocenę ich rozwoju społeczno-gospodarczego przeprowadzono w oparciu o 18 cech diagnostycznych. Zróżnicowana jest sytuacja powiatów między innymi ze względu

na takie cechy, jak: liczba podmiotów gospodarczych, stopa bezrobocia, saldo migracji, liczba mieszkań oddanych do użytku, udzielone noclegi w obiektach turystycznych, dochody budżetów. W związku z tym na potrzeby dokonania oceny syntetycznej poziomu rozwoju powiatów wykorzystano metody porządkowania liniowego. Rezultaty badania wskazują, że spośród wymienionych metod bardziej właściwe jest stosowanie mierników opartych o dwa wzorce. Ich zastosowanie daje mniejsze różnice w wynikach niż metod opartych tylko na jednym wzorcu. Również otrzymane za ich pomocą rankingi są bardziej zbliżone do siebie.

BIBLIOGRAFIA

- Adamiak J., Kosiedowski W., Potoczek A., Słowińska B. (2001) Zarządzanie rozwojem regionalnym i lokalnym. Problemy teorii i praktyki, Wydawnictwo TNOiK Dom Organizatora, Toruń.
- Bank Danych Lokalnych GUS (dostęp 05.04.2016) <http://www.stat.gov.pl>.
- Binderman A. (2006) Klasyfikacja obiektów oparta na dwóch wzorcach, *Ekonomika i Organizacja Gospodarki Żywnościowej*, Zeszyty Naukowe SGGW nr 60, Warszawa, str. 25 – 34.
- Binderman A. (2011) Wielokryterialne metody analizy zróżnicowania polskiego rolnictwa w 2009 roku, *Metody Ilościowe w Badaniach Ekonomicznych*, Tom 12, Zeszyt 2, SGGW, Warszawa, str. 58 – 68.
- Binderman Z., Borkowski B., Prokopenya A., Szczęsny W. (2015) Application of Dissimilarity Measures to Objects Ordering and Concentration Measurement, [w]: Prokopenya A., Jakubiak M. (eds.) *Computer Algebra Systems in Teaching and Research*, Uniwersytet Przyrodniczo-Humanistyczny w Siedlcach, Siedlce, str. 23–39.
- Cieślak M. (1974) Taksonomiczna procedura programowania rozwoju gospodarczego i określania zapotrzebowania na kadry kwalifikowane, *Przegląd Statystyczny*, Zeszyt 1, str. 29 – 39.
- Helwig Z. (1968) Zastosowanie metody taksonomicznej do typologicznego podziału krajów ze względu na poziom ich rozwoju i strukturę wykwalifikowanych kadr, *Przegląd Statystyczny*, Zeszyt 4, str. 307 – 327.
- Hwang C. L., Yoon K. (1981) *Multiple Attribute Decision Making: Methods and Applications*, Springer-Verlag, New York.
- Jankowski P. (2013) *Województwo jako region europejski*, Wydawnictwo Adam Marszałek, Toruń 2013.
- Kolenda M. (2006) Taksonomia numeryczna. Klasyfikacja, porządkowanie i analiza obiektów wielocechowych, Wydawnictwo AE we Wrocławiu, Wrocław.
- Korenik S. (2003) Dysproporcje w rozwoju regionów Polski – wybrane aspekty, Wydawnictwo AE we Wrocławiu, Wrocław.
- Korol J., Kusideł E., Szczuciński P. (2016) *Przedsiębiorczość, produktywność i konkurencyjność regionów Polski*, Wydawnictwo Adam Marszałek, Toruń.
- Kukuła K. (2000) *Metoda unitaryzacji zerowanej*, Wydawnictwo Naukowe PWN, Warszawa.
- Malina A. (2004) *Wielowymiarowa analiza przestrzennego zróżnicowania struktury gospodarki Polski według województw*, Wydawnictwo AE w Krakowie, Kraków.

- Mitronović D. S. (1972) Elementarne nierówności, PWN, Warszawa.
- Młodak A. (2006) Analiza taksonomiczna w statystyce regionalnej, Wydawnictwo Difin, Warszawa.
- Pawelek B. (2008) Metody normalizacji zmiennych w badaniach porównawczych złożonych zjawisk ekonomicznych, Wydawnictwo UE w Krakowie, Kraków.
- Pociecha J. (2008) Rozwój metod taksonomicznych i ich zastosowań w badaniach społeczno-ekonomicznych, Konferencja naukowa z okazji 90-lecia GUS, Statystyka społeczna – dokonania – szanse – perspektywy, Kraków.
- Strahl D. red. (2006) Metody oceny rozwoju regionalnego, Wydawnictwo AE we Wrocławiu, Wrocław.
- Strategia Rozwoju Województwa Lubuskiego 2020 (2012) Załącznik do Uchwały Sejmiku Województwa Lubuskiego z dnia 19 listopada 2012 r., Zielona Góra.
- Walesiak M. (2006) Uogólniona miara odległości w statystycznej analizie wielowymiarowej, Wydawnictwo AE we Wrocławiu, Wrocław.
- Województwo lubuskie. Podregiony, powiaty, gminy 2015 (2015) Urząd Statystyczny w Zielonej Górze, Zielona Góra.
- Zaucha J., Brodzicki T., Ciołek D., Komornicki T., Mogiła Z., Szlachta J., Zaleski J. (2015) Terytorialny wymiar wzrostu i rozwoju, Wydawnictwo Difin, Warszawa.
- Zeliaś A. red. (2000) Taksonomiczna analiza przestrzennego zróżnicowania poziomu życia w Polsce w ujęciu dynamicznym, Wydawnictwo AE w Krakowie, Kraków.

APPLYING OBJECTS ORDERING FOR ASSESSMENT OF SOCIO-ECONOMIC DEVELOPMENT LEVEL OF LUBUSKIE VOIVODESHIP POWIATS

Abstract: Socio-economic development is varied in spatial aspect. Voivodeships are in this aspect the basic administrative units. The article presents assessment of socio-economic development level of Lubuskie Voivodeship at the powiat level. For this purpose, objects ordering method was applied. Indicators based on one or two models were used. This allows for determining powiats of higher and lower level of development. The results indicate that it is more appropriate to use indicators based on two models. Differences in results are lower and received rankings are more convergent.

Keywords: socio-economic development, taxonomic analysis, methods of objects ordering, diversity of powiats, Lubuskie Voivodeship

PROGNOZOWANIE NA PODSTAWIE SZEREGÓW CZASOWYCH O WYSOKIEJ CZĘSTOTLIWOŚCI OCZYSZCZONYCH Z SEZONOWOŚCI DLA LUK NIESYSTEMATYCZNYCH

Maria Szmuksta-Zawadzka

Studium Matematyki

Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
e-mail: maria.szmuksta-zawadzka@zut.edu.pl

Jan Zawadzki

Katedra Zastosowań Matematyki w Ekonomii
Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
e-mail: jan.zawadzki@zut.edu.pl

Streszczenie: W pracy przedstawione zostaną wyniki zastosowania wybranych modeli wyrównywania wykładniczego w prognozowaniu zmiennej o bardzo wysokiej częstotliwości, obserwowanej w okresach godzinnych, dla luk niesystematycznych, oczyszczonej z dwóch lub trzech rodzajów sezonowości. Rozpatrywany był wariant, w którym luki występują w każdym z rodzajów wahań składowych.

Słowa kluczowe: prognozowanie, dane o wysokiej częstotliwości, złożona sezonowość, wyrównywanie wykładnicze

WPROWADZENIE

W pracy [Szmuksta-Zawadzka, Zawadzki, 2015] wykazano, że modele wyrównywania wykładniczego mogą być z powodzeniem wykorzystane w prognozowaniu zmiennej ekonomicznej ze złożonymi wahaniami sezonowanymi dla kompletnych szeregów czasowych oczyszczonych z dwóch lub trzech rodzajów sezonowości. W niniejszej pracy podjęta zostanie próba rozszerzenia rozważań na szeregi z lukami niesystematycznymi występującymi w każdym z rodzajów wahań składowych.

Prognozy dla modeli Browna i Holta buduje na podstawie szeregów z których wyeliminowano sezonowość roczną, tygodniową i godziną. Natomiast

w przypadku modeli Holta-Wintersa eliminowane są tylko wahania o cyklu rocznym i tygodniowym, ponieważ wahania o cyklu dobowym opisywane są za pomocą dodatkowego równania. W przypadku wszystkich modeli prognozy wyjściowe wyznaczane są na podstawie predyktorów dla danych oczyszczonych. Prognozy ostateczne natomiast są sumami prognoz wyjściowych i składników sezonowości (modele addytywne) lub iloczynami prognoz wyjściowych i wskaźników sezonowości (modele multiplikatywne). Modele wymienione wyżej są przystosowanymi dla danych oczyszczonych o wysokiej częstotliwości modelami znanymi w literaturze dla wahań o niezłożonej sezonowości lub dla zmiennych, w których wahania te nie występują (por. [Pawłowski 1973]; [Zeliaś, Pawełek, Wanat 2003]; [Dittman 2006]).

Zapisy analityczne modeli w postaci addytywnej i multiplikatywnej podane zostały w pracy [Szmuksta-Zawadzka, Zawadzki 2015]. Poniżej przedstawione zostaną modele w postaci multiplikatywnej. W poniższych zapisach litera „m” oznacza model multiplikatywny.

Zapis ogólny modelu multiplikatywnego ze złożoną sezonowością jest następujący :

$$Y_{t(m)} = P^{(m)}(t) \cdot M^{(m)}(t) \cdot D^{(m)}(t) \cdot G^{(m)}(t) \cdot V_{t(m)} \quad (1)$$

gdzie:

$P^{(m)}(t)$ – trend,

$M^{(m)}(t)$ – wskaźniki sezonowości o cyklu 12 miesięcznym,

$D^{(m)}(t)$ – wskaźniki sezonowości o cyklu 7 dniowym,

$G^{(m)}(t)$ – wskaźniki sezonowości o cyklu 24 godzinnym.

Oznaczając przez $Y_{t(m)}^{***}$ zmienną prognozowaną, z której wyeliminowano wskaźniki sezonowości o cyklu rocznym, tygodniowym i dobowym można podać zapisy analityczne modeli Browna i Holta.

Równanie prostego modelu Browna (m_B) wyraża się wzorem:

$$m_t^{***} = \alpha Y_{t(m)}^{***} + (1 - \alpha) m_{t-1}^{***}, \quad (2)$$

gdzie: m_t^{***} - operator rzędu pierwszego,

α - stała wygładzania ($0 \leq \alpha \leq 1$).

Predyktor oparty na tym modelu przyjmuje postać:

$$\Pi_{a_B}^{***} = m_{t_0}^{***}, \quad (3)$$

gdzie t_0 jest okresem wyjściowym budowy prognoz.

Prognozę końcową otrzymuje się na podstawie predyktora:

$$\Pi_{m_B} = \Pi_{m_B}^{***} \cdot M^{(m)}(t) \cdot D^{(m)}(t) \cdot G^{(m)}(t) \quad (4)$$

Równania liniowego modelu Holta (m_H) są następujące:

$$m_t^{***} = \alpha Y_{t(m)}^{***} + (1 - \alpha)(m_{t-1}^{***} + \delta_{1t-1}^{***}), \quad (5)$$

$$\delta_{1t}^{***} = \beta(m_t^{***} - m_{t-1}^{***}) + (1 - \beta)\delta_{1t-1}^{***}, \quad (6)$$

gdzie: m_t^{***} - operator rzędu pierwszego,

δ_{1t}^{***} - parametr kierunkowy trendu,

α - stała wygładzania ($0 \leq \alpha \leq 1$),

β - stała wygładzania ($0 \leq \beta \leq 1$).

Predyktory: wyjściowy dla horyzontu prognozy $h=1,2,\dots$ oraz końcowy przyjmują postać:

$$\Pi_{m_H}^{***} = m_{t_0}^{***} + \delta_{1t_0}^{***} h, \quad (8)$$

$$\Pi_{m_H} = \Pi_{m_H}^{***} \cdot M^{(m)}(t) \cdot D^{(m)}(t) \cdot G^{(m)}(t) \quad (9)$$

Jak wspomniano wyżej w przypadku modelu Holta-Wintersa eliminuje się dwa rodzaje wahań: o cyklu rocznym i tygodniowym. Zmienną z której wyeliminowano składniki sezonowości o cyklach wskazanych wyżej oznaczymy przez $Y_{t(m)}^{**}$.

Równania multiplikatywnego modelu Holta-Wintersa, opisujące wahania o cyklu dobowym o długości m są następujące:

$$m_t^{**} = \frac{\alpha Y_t^{**}}{C_{t-m}^{**}} + (1 - \alpha)(m_{t-1}^{**} + \delta_{1t-1}^{**}), \quad (10)$$

$$\delta_{1t}^{**} = \beta(m_t^{**} - m_{t-1}^{**}) + (1 - \beta)\delta_{1t-1}^{**}, \quad (11)$$

$$C_t^{**} = \frac{\delta Y_{t(m)}^{**}}{m_t^{**}} + (1 - \delta)C_{t-m}^{**}, \quad (12)$$

gdzie: m_t^{**} - operator rzędu pierwszego,

δ_{1t}^{**} - parametr kierunkowy trendu,

C_t^{**} - ocena wskaźnika sezonowości,

α - stała wygładzania ($0 \leq \alpha \leq 1$),

β - stała wygładzania ($0 \leq \beta \leq 1$).

δ - stała wygładzania ($0 \leq \delta \leq 1$).

Predyktor wyjściowy dla horyzontu prognozy $h=1,2,\dots$ przyjmuje postać:

$$\bar{\Pi}_{m_HW}^{**} = m_{t_0}^* + \delta_{1t_0}^* h + C_{t_0, 1+h}^* \quad (13)$$

Prognozę końcową wyznacza się ze wzoru:

$$\Pi_{m_HW} = \bar{\Pi}_{m_HW}^{**} \cdot M^{(m)}(t) \cdot D^{(m)}(t) \quad (14)$$

Jednym z ważnych zagadnień wymagających rozstrzygnięcia jest wybór modelu adaptacyjnego dla celów prognozowania o „optymalnych” wartościach stałych wygładzania (wyrównywania). W przypadku pełnych danych wyboru tego można dokonać posługując się jednym z dwóch kryteriów (mierników) polegających na minimalizacji:

- przeciętnych błędów względnych wartości wyrównanych obliczanych dla dostępnych danych w przedziale czasowym „próby” (K_{WW}),
- przeciętnych względnych ocen błędów prognoz ekstrapolacyjnych obliczonych dla okresu empirycznej weryfikacji prognoz (K_{EX}).

W przypadku szeregów z lukami w grę wchodzi także trzecie kryterium, minimalizujące przeciętne względne oceny błędów prognoz interpolacyjnych obliczonych dla podokresów, w których występowały luki (K_{IN}).


Z uwagi na to, że modele tego samego rodzaju charakteryzujące się minimalnymi ocenami mierników dla poszczególnych kryteriów dość często mogą różnić się stałymi wygładzania. Konsekwencją tego faktu będzie występowanie dość znacznych różnic błędów prognoz, zwłaszcza ekstrapolacyjnych. W związku z tym, dla każdego z mierników należy obliczyć dwa pozostałe rodzaje mierników, odnoszące bądź do wartości wyrównanych bądź i (lub) przynajmniej jeden rodzaju prognoz. Będą one oznaczone dodatkowymi indeksami. Na przykład dla kryterium K_{WW} będzie to K_{WW_IN} i K_{WW_EX} .

SYNTETYCZNA CHARAKTERYSTYKA ZMIENNEJ PROGNOZOWANEJ

Modelowaniu i prognozowaniu dla luk niesystematycznych z wykorzystaniem modeli Browna, Holta i Holta-Wintersa w postaci addytywnej i multiplikatywnej poddane zostało zapotrzebowanie na moc energetyczną w aglomeracji A. Podstawą budowy prognoz wyjściowych były godzinne szeregi czasowe z których wyeliminowano dwa lub trzy rodzaje wahań sezonowych.

Kształtowanie się zmiennej prognozowanej bez luk w okresie trzech lat zostało przedstawione na rys. 1. Pierwsze dwa lata posłużą do budowy modeli i prognoz inter- i ekstrapolacyjnych a rok trzeci będzie okresem empirycznej ich weryfikacji.


Rysunek 1. Kształtowanie się zapotrzebowania na moc energetyczną (w MWh)



Źródło: Bank Danych Katedry Zastosowań Matematyki w Ekonomii ZUT w Szczecinie

Poniżej zostaną przedstawione w sposób graficzny kształtowanie się ocen wskaźników i składników sezonowości o cyklu rocznym, tygodniowym i dobowym (rys. 2-4).


Rysunek 2. Oceny składników i wskaźników sezonowości o cyklu rocznym



Źródło: Szmuksta-Zawadzka, Zawadzki, 2015, s.152

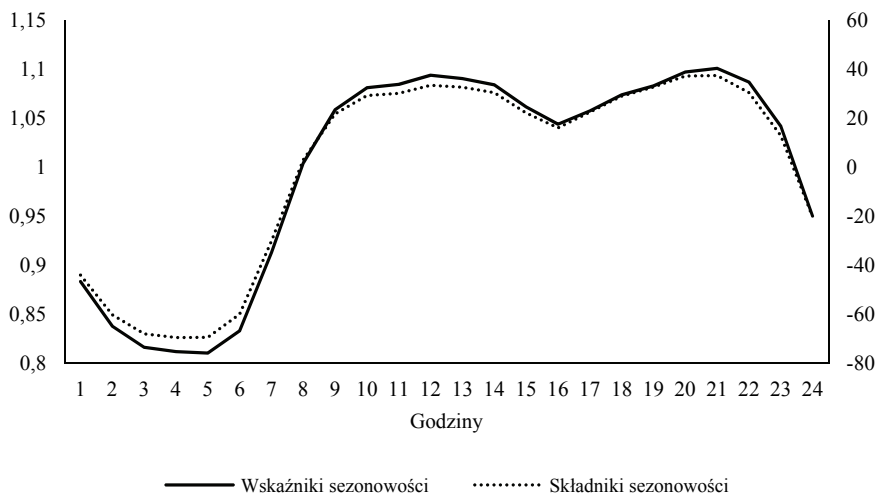
Rozstęp wskaźników sezonowości wynosił ok. 15 p.p. i był zdecydowanie niższy niż dla cyklu rocznego. Różnica skrajnych ocen składników sezonowości wynosiła ok. 55 MWh.

Rysunek 3. Oceny składników i wskaźników sezonowości o cyklu tygodniowym



Źródło: Szmuksta-Zawadzka, Zawadzki, 2015, s.153

Rysunek 4. Oceny składników i wskaźników sezonowości o cyklu 24 godzinnym



Źródło: Szmuksta-Zawadzka, Zawadzki, 2015, s.153

WYNIKI MODELOWANIA I PROGNOZOWANIA

W modelowaniu i prognozowaniu z wykorzystaniem modeli: Browna, Holta i Holta-Wintersa zapotrzebowania na moc energetyczną w aglomeracji A wykorzystane zostały godzinne szeregi czasowe. Dla modeli Browna i Holta w postaci addytywnej i multiplikatywnej z szeregów oryginalnych zostały wyeliminowane wahania o cyklu: 12-miesięcznym, 7-dniowym i 24-godzinnym. Natomiast w przypadku modeli Holta-Wintersa, w tych samych postaciach wyeliminowano dwa pierwsze rodzaje wahań sezonowych, ponieważ wahania o cyklu dobowym będą podlegać modelowaniu i prognozowaniu adaptacyjnemu. Rozpatrywany był jeden wariant luk niesystematycznych. Przyjęto założenie, że luki występują w każdym z rodzajów wahań. Obejmowały dwa miesiące (sierpień i październik), dwa dni tygodnia (wtorek i czwartek) oraz osiem godzin (2, 6, 8, 10, 14, 16, 18 i 22), w okresie od 1 lipca roku pierwszego do 30 czerwca roku drugiego.

Liczba brakujących danych wynosiła 5272, co stanowiło 30,09% długości pełnego szeregu liczącego 17520 obserwacji. Luki w danych otrzymano przez wymazanie wskazanej wyżej liczby obserwacji z pełnego szeregu.

Do budowy prognoz na podstawie modeli Holta-Wintersa w postaci addytywnej i multiplikatywnej wykorzystane zostały szeregi czasowe oczyszczone z wahań o cyklu rocznym i tygodniowym (Y_t^{**}). Natomiast prognozy na podstawie prostych modeli Browna i modeli Holta były budowane dla zmiennej, z której zostały wyeliminowane także wahania o cyklu 24-godzinnym (Y_t^{***}).

W Tabeli 1 i 2 zostały zestawione błędy prognoz inter- i ekstrapolacyjnych otrzymanych na podstawie predyktorów opartych na modach Browna, Holta i Holta-Wintersa w postaci addytywnej i multiplikatywnej o stałych wygładzania charakteryzujących się minimalnymi ocenami poszczególnych kryteriów. Kolumna druga każdej tabeli zawiera skrótowe nazwy modeli poprzedzone odpowiednio: symbolem „a” dla modeli addytywnych oraz „m” dla modeli multiplikatywnych. W celach porównawczych w wierszach poniżej podane zostały wielkości odpowiednich błędów otrzymanych na podstawie takich samych modeli dla pełnych danych (bez luk). Zostały one oznaczone występującymi po nazwach modeli dolnymi indeksami „p”.

Natomiast w dwóch ostatnich wierszach, dla postaci addytywnej i multiplikatywnej, podane zostały mierniki dokładności wartości teoretycznych (K_{WW}), prognoz ekstrapolacyjnych (K_{EX}), a dla danych z lukami także prognoz interpolacyjnych (K_{IN}), otrzymane na podstawie klasycznych modeli szeregu czasowego odpowiednio: z liniowym trendem i periodycznymi składnikami sezonowymi (a_{Kl} , a_{Kl_p}) oraz z trendem wykładniczym o stałej stopie wzrostu i relatywnie stałych waniach sezonowych (m_{Kl} , m_{Kl_p}).

Z analizy ocen błędów wartości wyrównanych (K_{WW}) wynika, że najniższą jego oceną wynoszącą 4,182% charakteryzuje się predyktor oparty na

multiplikatywnym modelu Browna (m_B) o stałej wygładzania $\alpha=0,96$. Jest ona tylko o 0,118 p.p. wyższa od oceny błędu dla modelu m_{B_p} dla pełnych danych i stałej wygładzania $\alpha=0,97$. Najwyższą oceną miernika K_{WW} wynoszącą 5,569% charakteryzował się model a_H .

Dla modelu m_B otrzymano także najniższą ocenę błędu prognoz interpolacyjnych dla tego kryterium ($K_{WW_IN} = 6,415\%$) a najwyższą (9,121%) dla modelu a_{HW} spośród pozostałych modeli.

Najniższą ocenę błędu prognoz ekstrapolacyjnych dla tego kryterium otrzymano także dla modelu m_B ($K_{WW_EX} = 7,617\%$). Natomiast oceny przekraczające 87%, otrzymano dla: addytywnego modelu Holta (a_B) oraz obu postaci modelu Holta-Wintersa (a_{HW} , m_{HW}).

Podobnie wygląda sytuacja dla pełnych danych – bardzo wysokie błędy prognoz ekstrapolacyjnych (K_{WW_EX}), oprócz trzech wyżej wymienionych modeli, otrzymano także dla multiplikatywnego modelu Browna (m_{B_p}).

Minimalną ocenę błędu prognoz interpolacyjnych (K_{IN}) wynoszącą 6,361%, otrzymano także na podstawie predyktora opartego na multiplikatywnym modelu Browna (m_B), ale dla $\alpha=0,60$. Dla modelu addytywnego a_B i $\alpha=0,58$ była ona o 0,72 p.p. wyższa. Najniższą wynoszącą 8,117% charakteryzował się model m_{HW} . Oceny K_{IN_WW} wahały się od 4,443% dla modelu m_B do 6,835%.

Dla modelu m_{HW} minimalną ocenę miernika K_{IN_EX} wynoszącą 7,368% otrzymano dla predyktora m_B . Oceny błędów K_{IN_EX} dla addytywnej postaci modelu Holta i obu postaci modelu Holta-Wintersa przyjmują, podobnie jak w przypadku kryterium K_{WW} wysokie wartości. Zawarte są one w przedziale od 28,656% dla modelu a_{HW} do 81,322% dla modelu a_H .

Najniższą ocenę błędu prognoz ekstrapolacyjnych (K_{EX}) wynoszącą 7,254% otrzymano dla modelu Browna w postaci multiplikatywnej (m_{HW}) o stałej wygładzania: $\alpha=0,66$. Dalszymi w kolejności z błędami wynoszącymi 7,531% i 7,536% były modele Browna o postaci addytywnej (a_B) i Holta (a_H) o stałej wygładzania $\alpha=0,75$. Dla dwóch pozostałych modeli (a_{HW} oraz m_H) przekroczyły one 8%.

Z porównania ocen błędów dla kryterium (K_{EX}) dla danych z lukami i pełnych danych wynika, że z wyjątkiem modeli Holta w postaci addytywnej otrzymano identyczne oceny stałych wygładzania oraz identyczne oceny błędów prognoz ekstrapolacyjnych. Oznacza to, że występowanie luk w danych nie miało wpływu na wartości i dokładność prognoz. W przypadku miernika K_{EX_WW} jego oceny zawarte są w przedziale od 4,366% dla modelu a_B do 5,830% dla modelu m_{HW} . Minimalną ocenę wartości miernika K_{EX_IN} otrzymano dla modelu m_H (5,516%) a maksymalną dla modelu a_H (14,043%).

Tabela 1. Oceny błędów wartości wyrównanych, prognoz interpolacyjnych i prognoz ekstrapolacyjnych dla najlepszych addytywnych modeli adaptacyjnych (w %)

Model	Oznaczenie	Wartości wyrównane (WW)						Prognozy interpolacyjne (IN)						Prognozy ekstrapolacyjne (EX)					
		Stale wygładzania			MAPE (%)			Stale wygładzania			MAPE (%)			Stale wygładzania			MAPE (%)		
		α	β	γ	K_{WW}	$K_{WW IN}$	$K_{WW EX}$	K_{IN}	$K_{IN WW}$	$K_{IN EX}$	α	β	γ	K_{EX}	$K_{EX WW}$	$K_{EX IN}$			
Brown	a.B	0,97	-	-	4,216	6,584	7,808	6,433	4,547	7,665	0,75	-	-	7,531	4,366	6,474			
	a.B _a	0,97	-	-	4,007	-	7,808	-	-	-	0,75	-	-	7,531	4,132	-			
Holka	a.H	0,20	0,01	-	5,569	6,665	91,759	6,572	5,850	81,322	0,18	0,04	-	7,536	5,829	14,043			
	a.H _a	0,15	0,01	-	5,545	-	84,750	-	-	-	0,11	0,09	-	8,694	5,993	-			
Holka, Wintersa	a.HW	0,15	0,01	0,14	4,882	8,191	87,051	7,618	6,631	28,656	0,08	0,01	0,07	8,047	5,830	8,225			
	a.HW _a	0,15	0,01	0,14	4,453	-	83,436	-	-	-	0,08	0,01	0,07	8,047	4,820	-			
Klas. szer. czas.	a.Kl	-	-	-	6,907	-	-	6,724	-	-	-	-	-	8,552	-	-			
	a.Kl _p	-	-	-	6,666	-	-	-	-	-	-	-	-	8,192	-	-			

Źródło: opracowanie własne

Tabela 2. Oceny błędów wartości wyrównanych, prognoz interpolacyjnych i prognoz ekstrapolacyjnych dla najlepszych multiplikatywnych modeli adaptacyjnych (w %)

Model	Oznaczenie	Wartości wyrównane (WW)						Prognozy interpolacyjne (IN)						Prognozy ekstrapolacyjne (EX)					
		Stale wygładzania			MAPE (%)			Stale wygładzania			MAPE (%)			Stale wygładzania			MAPE (%)		
		α	β	γ	K_{WW}	$K_{WW IN}$	$K_{WW EX}$	α	β	γ	K_{IN}	$K_{IN WW}$	$K_{IN EX}$	α	β	γ	K_{EX}	$K_{EX WW}$	$K_{EX IN}$
Brownna	m _B	0,96	-	-	4,182	6,415	7,617	0,00	-	-	6,361	4,443	7,268	0,66	-	-	7,254	4,371	6,474
	m _{Ba}	0,20	0,01	-	5,306	6,390	8,850	-	-	-	-	-	-	0,66	-	-	7,254	4,465	-
Holta	m _H	0,20	0,01	-	5,302	5,429	8,850	0,20	0,01	-	5,429	5,302	8,850	0,15	0,01	-	8,071	5,477	6,415
	m _{Ha}	0,15	0,02	-	5,303	-	87,289	-	-	-	-	-	-	0,15	0,01	-	8,071	5,454	-
Holta-Wintersa	m _{HW}	0,15	0,01	0,14	4,722	9,121	97,868	0,06	0,04	0,01	8,117	6,835	63,24	0,08	0,01	0,04	7,536	5,341	9,616
	m _{HWa}	0,15	0,14	0,01	4,288	-	94,870	-	-	-	-	-	-	0,11	0,01	0,01	7,068	5,927	-
Klas. szer. czas.	m _{Kl}	-	-	-	6,631	-	-	-	-	-	6,660	-	-	-	-	-	8,050	-	-
	m _{Kla}	-	-	-	6,372	-	-	-	-	-	-	-	-	-	-	-	7,857	-	-

Źródło: opracowanie własne

Należy zwrócić uwagę, że oceny błędów: wartości wyrównanych (K_{EX_WW}) prognoz interpolacyjnych (K_{EX_IN}), dla modelu charakteryzującego się minimalną oceną miernika K_{EX} , przyjęły wartości tylko niewiele wyższe od minimalnych ocen błędów K_{WW} oraz K_{IN} . Oznacza to, że kryterium wyboru modelu dla celów prognozowania ekstrapolacyjnego z całą pewnością nie mogą być predyktory oparte na modelach Holta oraz Holta-Wintersa. Ewentualnie mogą być brane pod uwagę, niezależnie od postaci, jedynie modele Browna.

W tabelach tych podane zostały, zarówno dla luk jak i dla pełnych danych, oceny błędów wartości wyrównanych, prognoz interpolacyjnych (dla luk) i ekstrapolacyjnych otrzymanych na podstawie modeli klasycznych w postaci addytywnej (a_{KL} , a_{KLp}) i multiplikatywnej (m_{KL} , m_{KLp}). Średnie względne błędy wartości teoretycznych (wyrównanych) dla modelu addytywnego i multiplikatywnego wynoszą odpowiednio: 6,907% oraz 6,663% i są one o ok. 2,3. oraz 2,6 p.p. wyższe od otrzymanych dla najlepszego modelu adaptacyjnego (m_B). W przypadku prognoz interpolacyjnych względne ich błędy przyjęły wartości: 6,660% (m_{KL}) oraz 6,545% (m_{KL}) i są one wyższe od minimalnego średniego błędu prognoz otrzymanego na podstawie modeli Browna o ok. 0,2 – 0,3 p.p.

W przypadku prognoz ekstrapolacyjnych otrzymanych na podstawie modelu w postaci multiplikatywnej błąd ten jest o 0,796 p.p. (10,97%) wyższy od błędu minimalnego otrzymanego na podstawie modelu m_{HW} .

W tabeli 3 zamieszczone zostały oceny błędów średnich prognoz interpolacyjnych i ekstrapolacyjnych dla danych z lukami otrzymanych na podstawie najlepszych predyktorów adaptacyjnych (m_B oraz m_{HW}), w dezagregacji na godziny, dni tygodnia i miesiące.

Tabela 3. Przeciętne względne błędy prognoz zdezagregowanych

	Liczba luk	Prognozy interpolacyjne		Prognozy ekstrapolacyjne			
		Modele z lukami		Modele bez luk			
		m_B _0.60	m_{KL}	m_B _0.66	m_{KL}	m_{HWp} _0.11_0.01_0.01	m_{KLp}
Ogółem	5272	6,361	6,660	7,254	8,050	7,068	7,696
G1	147	6,601	6,142	6,746	8,119	5,979	7,355
G2	365	5,152	6,483	7,150	7,666	6,190	7,701
G3	147	5,946	5,390	7,446	8,793	6,500	7,982
G4	147	6,052	5,490	8,038	9,433	6,548	8,706
G5	147	6,110	5,942	7,978	9,090	6,964	8,580
G6	365	6,438	7,477	8,744	8,794	8,394	8,964
G7	147	8,573	9,135	9,655	9,802	9,181	9,739
G8	365	7,061	8,295	10,166	10,491	9,431	10,439
G9	147	7,566	8,727	8,528	8,911	7,693	8,999
G10	365	4,477	6,104	6,580	7,476	6,421	7,129

	Liczba luk	Prognozy interpolacyjne		Prognozy ekstrapolacyjne			
		Modele z lukami				Modele bez luk	
		m_B_0.60	m_KL	m_B_0.66	m_KL	m_HWp_0.11_0.01_0.01	m_KLp
G11	147	6,224	6,075	5,710	6,896	5,416	6,525
G12	147	6,179	5,939	5,960	7,319	5,707	6,805
G13	147	6,484	5,857	5,549	6,749	5,734	6,274
G14	365	4,379	5,323	5,280	6,263	5,655	5,768
G15	147	6,672	5,595	5,271	6,111	5,815	5,718
G16	365	5,375	6,067	5,854	6,544	6,162	6,525
G17	147	9,352	7,162	7,841	8,872	8,837	8,516
G18	365	6,898	7,547	9,136	9,484	9,638	9,176
G19	147	9,367	9,629	9,403	9,540	9,459	9,317
G20	147	8,037	7,898	9,208	9,559	9,398	9,143
G21	147	6,738	7,209	7,772	8,070	8,083	7,689
G22	365	6,187	5,374	5,723	6,545	6,090	6,133
G23	147	6,881	5,911	5,194	6,261	5,435	5,767
G24	147	7,200	5,978	5,155	6,405	4,907	5,762
PN	560	6,752	7,819	7,524	8,267	7,267	7,871
WT	1248	6,709	6,593	6,473	7,274	6,372	6,866
ŚR	560	5,309	6,425	6,988	7,708	6,786	7,394
CZ	1248	6,862	6,509	7,282	7,870	6,969	7,598
PT	544	5,150	5,889	7,168	8,060	6,790	7,657
SO	552	5,763	6,207	6,803	7,849	6,741	7,446
ND	560	6,894	7,417	8,553	9,335	8,566	9,058
ST	392	4,522	5,325	6,142	5,946	6,080	5,840
LU	352	4,543	4,281	5,301	9,101	5,250	8,488
MAR	392	3,653	4,878	11,086	10,040	10,968	9,698
KW	368	4,471	6,046	6,016	7,680	6,168	7,361
MAJ	408	5,664	6,763	8,622	9,573	8,291	8,708
CZE	368	7,410	6,948	7,064	10,649	6,654	9,351
LIP	376	5,682	6,121	9,393	7,667	7,782	7,858
SIĘ	744	8,282	8,163	7,101	6,584	6,306	6,696
WRZ	368	5,982	7,052	5,616	7,745	5,673	7,206
PAŹ	744	8,701	7,116	6,113	5,891	6,050	5,928
LIS	384	6,723	7,452	6,337	7,411	6,453	7,202
GRU	376	6,625	7,815	7,936	8,452	8,860	8,106

Źródło: opracowanie własne

W celach porównawczych podane zostały, w takim samym układzie, błędy obu rodzajów prognoz otrzymanych na podstawie modelu klasycznego w postaci multiplikatywnej (m_{KL}). Kolumna druga zawiera liczby prognoz interpolacyjnych, obejmujących godziny, dni i miesiące, w których wystąpiły luki.

Z porównania ocen błędów prognoz interpolacyjnych dla godzin wynika, że dla predyktora adaptacyjnego (m_B) są one w 14 przypadkach na 24 niższe od uzyskanych dla predyktora klasycznego (m_{KL}). Różnice te zawarte są w przedziale od 0,262 p.p. (godz. 19) do 1,626 p.p. (godz. 10). Niższe oceny błędów prognoz interpolacyjnych na podstawie predyktora klasycznego otrzymano dla 10 okresów godzinowych. Mieszczą się one w przedziale od 0,169 p.p. (godz. 5) do 2,189 p.p. (godz. 17). Jedynie dla godz. 22 lepszym o 0,702 p.p. okazał się predyktor klasyczny. Dla pięciu spośród siedmiu dni tygodnia bardziej efektywny okazał się predyktor oparty na modelu wyrównywania wykładniczego. Różnice ocen kształtowały się w przedziale od 0,444 p.p. dla czwartku do 1,116 p.p. dla środy. Natomiast niższe oceny błędów prognoz, wynoszące odpowiednio 0,117 p.p. i 0,352 p.p. otrzymano dla wtorku i czwartku, a więc dni w których występowały luki. Wyższe dokładności prognoz adaptacyjnych otrzymano dla 8 spośród 12 miesięcy. Zawarte były w przedziale od 0,439 p.p. dla lipca do 1,574 p.p. dla kwietnia.


Predyktor klasyczny okazał się bardziej efektywny w czterech miesiącach (lutym, czerwcu, sierpniu i październiku). Różnice w ocenach wahały się od 0,120 p.p. dla sierpnia do 1,585 p.p. dla października, a więc miesięcy, w których występowały luki.

Jak wspomniano wcześniej przeciętny błąd względny prognoz ekstrapolacyjnych otrzymanych na podstawie predyktora adaptacyjnego (m_{HW}) wynosił 7,254% i był niższy o 0,796 p.p. od błędu prognoz dla predyktora klasycznego (m_{KL}). Dla prognoz zdezagregowanych dla wszystkich 24 godzin otrzymano niższe błędy dla predyktora adaptacyjnego. Kształtowały się one w przedziale od 0,049 p.p. dla godz. 6 do 1,321 p.p. dla godz. 14. W przypadku 7 dni tygodnia także predyktor adaptacyjny okazał się bardziej efektywny. Różnice ocen błędów kształtowały się w przedziale od 0,588 p.p. dla czwartku do 1,046 p.p. dla soboty. Dla 8 spośród 12 miesięcy niższe oceny błędów otrzymano dla predyktora m_{HW} . Różnice ocen błędów zawarte były w przedziale 0,951. – 3,586 p.p. i dotyczyły odpowiednio: maja i lutego. Niższe oceny błędów dla predyktora klasycznego otrzymano dla: stycznia (o 0,046 p.p.), marca (o 1,046 p.p.) lipca (o 1,725 p.p.) oraz października (o 0,223 p.p.).

Obecnie przedstawione zostaną w postaci graficznej aproksymanty teoretyczne empirycznych rozkładów błędów prognoz interpolacyjnych otrzymane na podstawie najlepszego predyktora adaptacyjnego ($m_{B_0.60}$) oraz predyktora klasycznego (m_{KL}). Najlepiej rozkłady empiryczne błędów prognoz interpolacyjnych były aproksymowane za pomocą rozkładów wykładniczych.

Z Rysunku nr 5 wynika, że błędy prognoz adaptacyjnych ($m_{B_0.60}$) przyjmują nieco częściej niższe wartości od błędów otrzymanych na podstawie modelu klasycznego (m_{KL}).

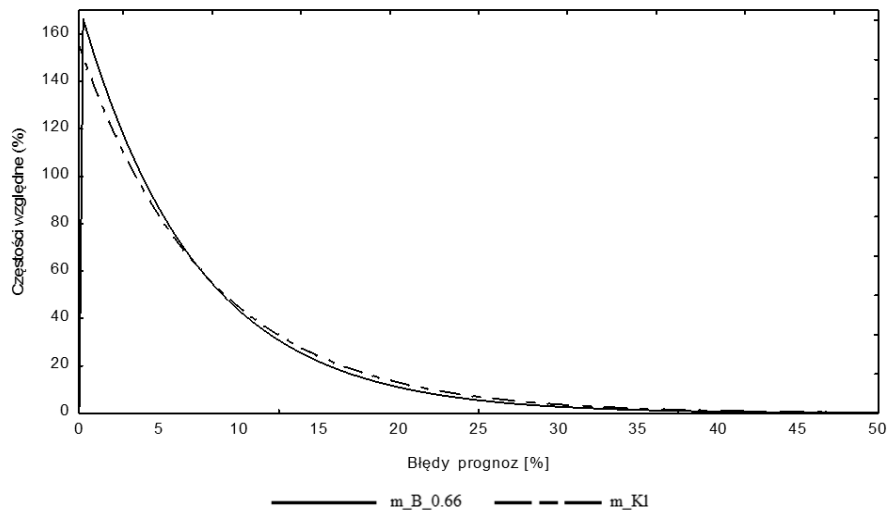
Rysunek 5. Rozkłady błędów prognoz interpolacyjnych otrzymanych na podstawie modeli $m_{B_0.60}$ oraz m_{KL}



Źródło: opracowanie własne

Kształtowanie się wykładniczych aproksymant rozkładów empirycznych błędów prognoz ekstrapolacyjnych otrzymanych na podstawie najlepszych predyktorów: adaptacyjnego ($m_{B_0.66}$) oraz predyktora klasycznego (m_{KL}) dla luk niesystematycznych zostało przedstawione graficznie na Rysunku 6.

Rysunek 6. Aproksymanty teoretyczne rozkładów błędów prognoz ekstrapolacyjnych otrzymanych na podstawie modeli $m_B_{0.66}$ oraz m_{KL}



Źródło: opracowanie własne

Z porównania rozkładów błędów prognoz inter- i ekstrapolacyjnych wynika, że dokładność prognoz ekstrapolacyjnych jest wyraźnie wyższa od dokładności prognoz otrzymanych na podstawie modelu klasycznego

PODSUMOWANIE

Przeprowadzone w pracy rozważania można podsumować następująco :

1. Podstawą wyboru modelu dla celów prognozowania *ex ante* nie mogą być modele o stałych wygładzania, którym odpowiadają minimalne oceny błędów wartości wyrównanych (K_{WW}) i prognoz interpolacyjnych (K_{IN}). Wynika to z faktu, że błędy prognoz ekstrapolacyjnych przyjmują dla nich zazwyczaj bardzo wysokie oceny, zwłaszcza dla modeli Holta i Holta-Wintersa.
2. Kryterium wyboru powinny być minimalne oceny błędów prognoz ekstrapolacyjnych (K_{EX}). Minimalnym ich ocenom odpowiadają tylko nieznacznie wyższe od minimalnych oceny błędów wartości wyrównanych (K_{WW}) i prognoz interpolacyjnych (K_{IN}).
3. Dokładność prognoz ekstrapolacyjnych dla najlepszego modelu adaptacyjnego dla danych z lukami była zbliżone dla tego rodzaju modelu i pełnych danych – różnica w dokładności wynosiła 2,6%.
4. Prognozy interpolacyjne dla modeli adaptacyjnych dla luk niesystematycznych dla luk niesystematycznych charakteryzowały się oceną przeciętnym błędem prognoz niższym o ok. 3,8 % niż dla klasycznego modelu szeregu czasowego. W przypadku prognoz ekstrapolacyjnych różnica ta wyniosła 10,97 %.

5. Potwierdzona została więc przydatność modeli wyrównywania wykładniczego w prognozowaniu zmiennej oczyszczonej ze złożonych wahań sezonowych, nawet w przypadku, gdy udział luk przekracza 30%.

BIBLIOGRAFIA

- Dittmann P. (2006) Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie, Wolters Kluwer Polska, Kraków.
- Pawłowski Z. (1973) Prognozowanie ekonometryczne, PWN, Warszawa.
- Szmuksta-Zawadzka M., Zawadzki J. (2015) Wykorzystanie danych oczyszczonych o wysokiej częstotliwości w prognozowaniu zmiennych ze złożoną sezonowością, Metody Ilościowe w Badaniach Ekonomicznych, SGGW, t. XVI nr.4. Warszawa.
- Zeliaś A., Pawełek B., Wanat S. (2003) Prognozowanie ekonomiczne. Teoria, przykłady, zadania, PWN, Warszawa.

FORECASTING BASED ON HIGH FREQUENCY TIME SERIES WITH UNSYSTEMATIC GAPS

Abstract: In the paper will be presented the results of the application of selected models of exponential smoothing in forecasting of very high frequency variable, observed hourly, with unsystematic gaps, from which two or three types of seasonality fluctuation were eliminated. In the research was used a combination, in which gaps were present in each type of the fluctuation component.

Keywords: forecasting, high frequency time series, complex seasonality, exponential smoothing