

Uniwersytet
Ekonomiczny
w Krakowie

Zeszyty Naukowe

Cracow Review
of Economics
and Management

Nr 5(941)

Kraków 2015

Rada Naukowa

Andrzej Antoszewski (Polska), *Slavko Arsovski* (Serbia), *Josef Arlt* (Czechy),
Daniel Baier (Niemcy), *Hans-Hermann Bock* (Niemcy), *Ryszard Borowiecki* (Polska),
Giovanni Lagioia (Włochy), *Tadeusz Markowski* (Polska), *Martin Mizla* (Słowacja),
David Ost (USA), *Józef Pociecha* (Polska)

Komitet Redakcyjny

Janusz Czekaj, *Jerzy Kornaś*, *Ryszard Kowalski* (sekretarz), *Barbara Pawełek*,
Aleksy Poczowski (redaktor naczelny), *Krystyna Przybylska*, *Tadeusz Sikora*,
Grzegorz Strupczewski (sekretarz), *Wanda Sulkowska*, *Krzysztof Woźniak* (sekretarz)

Redaktor statystyczny

Paweł Ulman

Redaktorzy Wydawnictwa

Hanna Wojciechowska, *Małgorzata Wróbel-Marks*,
Seth Stevens (artykuły i streszczenia w j. angielskim)

Projekt okładki i układ graficzny tekstu

Marcin Sokołowski

Streszczenia artykułów są dostępne w międzynarodowej bazie danych
The Central European Journal of Social Sciences and Humanities
<http://cejsh.icm.edu.pl> oraz w Central and Eastern European Online Library
www.ceeol.com, a także w adnotowanej bibliografii zagadnień ekonomicznych
i pokrewnych BazEkon http://kangur.uek.krakow.pl/bazy_ae/bazekon/nowy/index.php

© Copyright by Uniwersytet Ekonomiczny w Krakowie, Kraków 2015

ISSN 1898-6447

Wersja pierwotna: publikacja drukowana
Publikacja jest dostępna w bazie CEEOL (www.ceeol.com)
oraz w czytelniku on-line [ibuk.pl](http://www.ibuk.pl) (www.ibuk.pl)

Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie
31-510 Kraków, ul. Rakowicka 27, tel. 12 293 57 42, e-mail: wydaw@uek.krakow.pl
www.zeszyty-naukowe.uek.krakow.pl

Zakład Poligraficzny Uniwersytetu Ekonomicznego w Krakowie
31-510 Kraków, ul. Rakowicka 27

Objętość 8,1 ark. wyd.
Zam. 73/2015

Spis treści

Jacek Batóg

Identyfikacja i znaczenie obserwacji nietypowych w modelach konwergencji dochodowej 5

Viktor Shevchuk

Flexible Exchange Rates as Shock Absorbers in Central and Eastern Europe 17

Iwona Foryś, Barbara Batóg

Modelowanie aktywności nabywców mieszkań na rynku województwa zachodniopomorskiego 37

Justyna Brzezińska

The Problem of Zero Cells in the Analysis of Contingency Tables 49

Katarzyna Frodyma

Rynek energii ze źródeł odnawialnych w Unii Europejskiej – analiza statystyczna 63

Jan Acedański

Overlapping Generation Models with Heterogeneous Agents and Aggregate Uncertainty in Macroeconomic Modelling 79

Magdalena Okupniak

Zastosowanie analizy blokowej w badaniu struktury polskich przedsiębiorstw 97

Łukasz Klimczak

Model grawitacyjny jako narzędzie analizy handlu zagranicznego 107

Monika Hadaś-Dyduch

Produkty strukturyzowane – analiza stóp zwrotu osiągniętych w latach 2000–2013 131

Jacek Batóg

Instytut Ekonometrii i Statystyki
Uniwersytet Szczeciński

Identyfikacja i znaczenie obserwacji nietypowych w modelach konwergencji dochodowej

Streszczenie


Badanie zjawiska konwergencji dochodowej znajduje szerokie odzwierciedlenie w dotychczasowym dorobku nauki i praktyce gospodarczej. Otrzymywane rezultaty charakteryzują się jednak stosunkowo dużym zróżnicowaniem. Wielu autorów wskazuje na silne uzależnienie uzyskiwanych wyników od zakresu czasowego i przekrojowego prowadzonych analiz oraz stosowanych metod badawczych. Mało uwagi poświęca się jednak roli obserwacji nietypowych, które mogą być wynikiem błędnego pomiaru, wystąpienia zdarzenia losowego, niestandardowych warunków lub działań o charakterze celowym. Weryfikacji poddana została hipoteza o istotnym wpływie tych obserwacji na uzyskiwane wyniki procesu estymacji. Głównym celem pracy było ustalenie, czy występowanie obserwacji uznanych za nietypowe istotnie zmienia jakość modeli oraz szybkość procesu konwergencji dochodowej.

Słowa kluczowe: obserwacje nietypowe, konwergencja dochodowa, modele ekonometryczne, Unia Europejska.

1. Wprowadzenie

Oceniając efekty rozwoju społeczno-gospodarczego danego kraju, dokonuje się często porównań z innymi obiektami. Jednym z prostszych sposobów stosowanych w praktyce jest odniesienie wartości określonego miernika do wartości przeciętnej charakteryzującej pewien obiekt wzorcowy. Typowym przykładem

takiego miernika jest zaprezentowany na rys. 1 udział PKB *per capita* Polski w wartości średniej dla 28 krajów Unii Europejskiej. Obserwacja kształtowania się tej proporcji w latach 1993–2013 prowadzi do co najmniej dwóch wniosków. Po pierwsze, widoczne jest zjawisko zbieżności produktu krajowego brutto przypadającego na 1 mieszkańca Polski do średniej unijnej. W okresie ostatnich 20 lat odnotowany został wzrost analizowanego udziału z 44,0% do 68,5%.



Rys. 1. Udział PKB *per capita* Polski w wartości średniej dla UE-28 w latach 1993–2013 (w %)

Źródło: obliczenia własne na podstawie [The Conference Board... 2014].

Drugie spostrzeżenie odnosi się do charakteru wpływu światowych kryzysów gospodarczych na szybkość zbliżania się poziomu życia w Polsce do poziomu obserwowanego w Unii Europejskiej. Pierwszy kryzys, który miał miejsce w latach 2001–2003, spowodował nie tylko spowolnienie tej tendencji – widoczne było nawet zjawisko jej odwrócenia w latach 2001–2002. Drugi kryzys wiązał się ze znaczącym wzrostem zbieżności PKB *per capita* Polski z poziomem europejskim, obserwowanym zwłaszcza w latach 2008–2009, czyli w okresie największego spowolnienia i recesji światowej gospodarki. Odmienny sposób kształtowania się badanej proporcji podczas drugiego kryzysu wynikał z wysokiej odporności polskiej gospodarki na ogólnoświatowy szok ekonomiczny wywołany na rynku nieruchomości w Stanach Zjednoczonych.

Zjawisko polegające na wyrównywaniu się poziomów PKB przypadających na 1 mieszkańca, spowodowane tym, że kraje charakteryzujące się niższymi poziomami kapitału na 1 zatrudnionego wykazują tendencję do szybszego wzrostu PKB *per capita*, natomiast kraje o wysokim poziomie rozwoju, posiadające wysokie wartości kapitału na 1 zatrudnionego, odznaczają się niższym tempem

wzrostu gospodarczego ze względu na malejącą krańcową produktywność kapitału, określane jest mianem konwergencji dochodowej.

Poznanie przyczyn i mechanizmu kształtowania się tego zjawiska wymaga bardziej precyzyjnych narzędzi (miar) niż analizowana powyżej proporcja¹. Wśród tych narzędzi znaczącą rolę odgrywają modele konwergencji dochodowej typu β o postaci [Batóg i Batóg 2007, s. 132–133]:

$$\frac{1}{T} \ln(Y_{iT}) / (Y_{i0}) = y_i = \alpha_0 + \alpha_1 Y_{i0} + u_i, \quad (1)$$

gdzie:

$\frac{1}{T} \ln(Y_{iT}) / (Y_{i0})$ – średnioroczna stopa wzrostu realnego PKB *per capita* kraju *i*

po zlogarytmowaniu,

Y_{i0} – początkowy poziom realnego PKB *per capita* kraju *i* po zlogarytmowaniu,

Y_{iT} – poziom realnego PKB *per capita* kraju *i* w ostatnim okresie po zlogarytmowaniu.

2. Hipoteza badawcza i cel pracy

Jakkolwiek badanie zjawiska konwergencji dochodowej znajduje szerokie odzwierciedlenie w dotychczasowym dorobku nauki i praktyce gospodarczej, uzyskiwane rezultaty charakteryzują się stosunkowo dużym zróżnicowaniem. Jest ono skutkiem m.in. odmiennych definicji konwergencji dochodowej i w efekcie konstrukcji powiązanych z nimi metod badawczych, silnego uzależnienia uzyskiwanych wyników od zakresu czasowego lub przekrojowego prowadzonych analiz decydującego o jednorodności wykorzystywanych danych, zachodzących zmian strukturalnych i wpływu pojawiających się kryzysów gospodarczych. Szersze rozważania na ten temat zaprezentowano w pracy [Batóg 2010, s. 159–160]. Stosunkowo mało uwagi poświęca się jednak znaczeniu obserwacji nietypowych, a zwłaszcza ich roli w procesie estymacji parametrów strukturalnych modeli konwergencji realnej.

Obserwacja nietypowa określana jest często jako „obserwacja znacząco różniąca się od pozostałych” [Barnett i Lewis 1994; Maddala 2006, s. 125]. Wskazuje się też, że różnica między obserwacją nietypową a pozostałymi obserwacjami jest wynikiem odmiennego procesu generowania tej pierwszej [Hawkins

¹ „Jeżeli chcemy zrozumieć, czym powodowane są znaczące różnice w jakości życia między krajami, to musimy wyjaśnić mechanizm zróżnicowania długookresowych stóp wzrostu, którymi się one charakteryzują” [Barro i Sala-i-Martin 2004, s. 6].

1980]. Precyzyjna definicja obserwacji nietypowej jest jednak uzależniona od struktury analizowanych danych oraz stosowanej metody identyfikacji [Ben-Gal 2005].

Obserwacja nietypowa może być wynikiem błędnego pomiaru, błędnego określenia badanej populacji, niejednorodności zbiorowości statystycznej, z której pobrano próbę, występowania obserwacji ekstremalnych lub zdarzeń losowych, nieprawidłowych założeń dotyczących rozkładów generowanych danych oraz działań o charakterze celowym (zob. m.in. [Walfish 2006]).

Obserwacje nietypowe często zmieniają zależność między badanymi zmiennymi w wyniku pojawiania się błędów specyfikacji modelu. Z drugiej strony dostarczają one informacji o danym procesie oraz o jego zakłóceniach. Pozwala to na liczne zastosowania praktyczne analizy obserwacji nietypowych ukierunkowane np. na wykrywanie oszustw, badanie nietypowych zachowań wyborców, wspomaganie leczenia klinicznego, wykrywanie włamań do sieci, prognozowanie anomalii pogodowych lub analizę gospodarności [Ruts i Rousseeuw 1996, Fawcett i Provost 1997, Penny i Jolliffe 2001, Acuna i Rodriguez 2004, Hozer 1993].

W przeprowadzonym badaniu weryfikacji poddana zostanie hipoteza o istotnym wpływie obserwacji nietypowych na uzyskiwane wyniki procesu estymacji parametrów strukturalnych modelu konwergencji absolutnej typu β . Głównym celem pracy jest natomiast identyfikacja obserwacji nietypowych za pomocą zróżnicowanych metod, a także ustalenie, czy ich występowanie istotnie zmienia jakość budowanych modeli oraz ocenianą szybkość procesu konwergencji dochodowej.

3. Rodzaje i metody identyfikacji obserwacji nietypowych

Prawidłowa interpretacja wpływu obserwacji nietypowych na wyniki prowadzonych analiz wymaga precyzyjnego rozróżnienia, z jakim rodzajem obserwacji nietypowej mamy do czynienia, oraz zastosowania odpowiedniej metody jej identyfikacji. Wśród klasyfikacji obserwacji nietypowych dominuje podejście, zgodnie z którym wyróżnia się cztery rodzaje tych obserwacji. Należą do nich: *univariate outlier*, czyli obserwacja o wartościach jednej ze zmiennych znacznie odbiegających od reszty obserwacji, która niekoniecznie powoduje jednak negatywne zjawiska podczas estymacji, *regression (vertical) outlier*, czyli obserwacja o znacznie odbiegającej od reszty obserwacji wartości zmiennej zależnej dla danej wartości zmiennej niezależnej, która zwiększa błędy szacunku parametrów, nie zawsze jednak powoduje zmianę nachylenia, może natomiast mieć wpływ na wyraz wolny i obniżyć stopień dopasowania modelu, *leverage*, czyli obserwacja

charakteryzująca się wartościami zmiennej niezależnej znacznie odbiegającymi od jej średniej, której występowanie zmniejsza błędy szacunku parametrów i zwiększa stopień dopasowania modelu, oraz *influence*, czyli obserwacja powodująca istotną zmianę wartości ocen parametrów strukturalnych po jej usunięciu, która jednocześnie nie musi generować dużych reszt regresji.


Do najczęściej stosowanych metod identyfikacji obserwacji nietypowych zaliczane są metody wykorzystujące reszty regresji standaryzowane lub studentyzowane albo wartości h_i (*hat values*) będące miarą dźwigni (zob. m.in. [Williams i in. 2002, Ben-Gal 2005]), metoda DFBETAs (*difference of betas*), pozwalająca ocenić różnicę między wartościami ocen uzyskiwanymi dla regresji przy pełnej liczbie obserwacji oraz dla regresji z usuniętą wartością nietypową, jak również metoda wykorzystująca odległość Cooka, która umożliwia ocenę wpływu danej obserwacji nietypowej na wszystkie oceny parametrów strukturalnych jednocześnie.

4. Uzyskane wyniki

W badaniu występowania obserwacji nietypowych oraz w ocenie ich znaczenia dla rezultatów analizy zjawiska konwergencji dochodowej w krajach Unii Europejskiej wykorzystane zostały dane pochodzące z *The Conference Board Total Economy Database* [2014]. Zaprezentowane w tej bazie danych szeregi czasowe PKB *per capita* podawane są w USD według poziomu cen z 2007 r., które są dodatkowo modyfikowane za pomocą EKS PPP z 2005 r.


Na rys. 2 przedstawiono kształtowanie się produktów krajowych brutto na 1 mieszkańca 28 krajów Unii Europejskiej w latach 1993–2014. Wyróżniono trzy obiekty charakteryzujące się odmiennym poziomem analizowanej zmiennej. Pierwszym z nich jest Luksemburg odznaczający się znacznie wyższymi wartościami PKB *per capita* w porównaniu z innymi krajami. Dwa pozostałe to Bułgaria i Rumunia o nieco niższych w porównaniu z innymi krajami UE-28 wartościach tej zmiennej w całym badanym okresie. W grupie badanych krajów występuje jeszcze jeden obiekt – Irlandia – który również może być uznany za nietypowy w zakresie kształtowania się dynamiki PKB *per capita*, ponieważ w jego przypadku obserwowany był bardzo silny wzrost tej zmiennej (awans z 13 pozycji w 1993 r. na 2 w 2008 r.). Odmienność wymienionych krajów od pozostałych krajów UE-28 jest bardziej zauważalna na rys. 3, który prezentuje zależność początkowych poziomów i średnich stóp wzrostu realnego PKB *per capita*.

Zauważyć można również znaczący wpływ kryzysu gospodarczego na zjawisko konwergencji dochodowej obserwowane w Unii Europejskiej od 1993 r. W 2009 r. odnotowany został wzrost zróżnicowania analizowanej zmiennej, co z pewnością wpłynęło na spadek szybkości zbieżności dochodowej.



Rys. 2. PKB *per capita* w krajach Unii Europejskiej (logarytmy, USD, poziom cen z 2007 r., aktualizacja EKS PPP z 2005 r.)

Źródło: opracowanie własne na podstawie [The Conference Board... 2014].



Rys. 3. Wykres korelacyjny początkowych poziomów i średnich stóp wzrostu realnego PKB *per capita* w krajach Unii Europejskiej

Źródło: opracowanie własne na podstawie [The Conference Board... 2014].

Zależność ta została również scharakteryzowana poprzez oszacowanie parametrów strukturalnych modelu (1):

$$\hat{y}_i = 0,2224 - 0,0193 Y_{i0}, \quad R^2 = 0,61.$$

(0,029) (0,003)


W nawiasach podano średnie błędy szacunku, które pozwalają stwierdzić statystyczną istotność parametrów strukturalnych. Uwagę zwraca jednak niezbyt wysokie dopasowanie modelu do danych rzeczywistych. Wykorzystując wzory (2) i (3), można obliczyć odpowiednio szybkość konwergencji dochodowej β oraz połowę okresu konwergencji $T_{\frac{1}{2}}$ w przypadku uwzględnienia wszystkich obiektów.

$$\beta = -\frac{1}{T} \cdot \ln(1 + \alpha_1 \cdot T), \quad (2)$$

$$T_{\frac{1}{2}} = \frac{\ln 2}{\beta}. \quad (3)$$

Uzyskane wyniki wskazują na zbieżność poziomów PKB *per capita* w krajach Unii Europejskiej w tempie 2,28% rocznie oraz połowę okresu konwergencji równą 30,38 lat.

Nietypowość dwóch obserwacji została potwierdzona za pomocą wartości *hat values* h_i (zob. rys. 4) tylko dla dwóch krajów: Luksemburga i Rumunii. Podobne rezultaty uzyskano na podstawie reszt standaryzowanych i studentyzowanych.




Rys. 4. Wartości *hat values* h_i dla krajów Unii Europejskiej

Źródło: opracowanie własne na podstawie [The Conference Board... 2014].

Za pomocą metody wykorzystującej odległości Cooka jako nietypowe wskazano dodatkowo Estonię i Łotwę (zob. rys. 5), przy czym identyczny wynik

uzyskano, stosując metodę DFBETAs. Jak widać, zastosowanie żadnej z miar i metod nie potwierdziło nietypowości Bułgarii i Irlandii.

W dalszej części badania oszacowane zostały parametry strukturalne modeli, w których dokonywano kolejnej eliminacji obiektów uznanych wstępnie za nietypowe na podstawie obserwacji dynamiki PKB *per capita* (zob. tabela 1).



Rys. 5. Obserwacje nietypowe wskazane za pomocą odległości Cooka

Źródło: opracowanie własne na podstawie [The Conference Board... 2014].

Tabela 1. Wyniki estymacji parametrów strukturalnych modeli oraz szybkość konwergencji dochodowej absolutnej typu β w krajach Unii Europejskiej w latach 1993–2013

Liczba krajów	R_{sk}^2	$\hat{\alpha}_1$	$t(\hat{\alpha}_1)$	$\hat{\beta}$	$T_{\frac{1}{2}}$
Wszystkie kraje Unii Europejskiej					
$n = 28$	0,60	-0,0193	-6,42	2,28%	30,38
Kraje Unii Europejskiej bez Luksemburga					
$n = 27$	0,67	-0,0220	-7,29	2,67%	25,94
Kraje Unii Europejskiej bez Luksemburga i Irlandii					
$n = 26$	0,73	-0,0225	-8,20	2,75%	25,22
Kraje Unii Europejskiej bez Luksemburga, Irlandii i Rumunii					
$n = 25$	0,76	-0,0244	-8,87	3,04%	22,77
Kraje Unii Europejskiej bez Luksemburga, Irlandii, Rumunii i Bułgarii					
$n = 24$	0,79	-0,0263	-9,37	3,35%	20,68

Źródło: obliczenia własne na podstawie [The Conference Board... 2014].

Uzyskane rezultaty pozwalają stwierdzić, że pominięcie Luksemburga, Irlandii, Bułgarii i Rumunii powoduje znaczącą zmianę wyników estymacji, a w konsekwencji również szybkości konwergencji – połowa okresu konwergencji zmniejsza się z ponad 30 lat do niecałych 21 lat. Jednocześnie potwierdzają się wyniki identyfikacji obserwacji nietypowych, zgodnie z którymi Irlandia nie została uznana za obserwację tego typu. Warto jednak zauważyć, że Bułgaria, która również nie była wskazana jako obserwacja nietypowa, charakteryzuje się silnym wpływem na obserwowaną szybkość konwergencji. W przypadku usunięcia dwóch obiektów, które zostały zidentyfikowane jako nietypowe przy wykorzystaniu odległości Cooka, czyli Estonii i Łotwy, obserwowany był natomiast spadek szybkości konwergencji (ocena parametru α_1 w obu przypadkach kształtowała się na poziomie $-0,0178$) oraz pogorszenie stopnia dopasowania modelu do rzeczywistych danych.

5. Podsumowanie

W okresie ostatnich dwudziestu lat można zaobserwować zjawisko zbieżności dochodowej krajów Unii Europejskiej. Proces ten został jednak spowolniony przez ogólnoświatowy kryzys gospodarczy zapoczątkowany w gospodarce amerykańskiej w 2007 r. Wpływ poszczególnych krajów na szybkość konwergencji dochodowej jest zróżnicowany², a kluczową rolę w tym zakresie odgrywają obiekty uznane za nietypowe. Należy jednak zauważyć, że obserwacje uznane za nietypowe na podstawie kształtowania się dynamiki PKB *per capita* nie pokrywają się w pełni z obserwacjami wskazanymi jako nietypowe za pomocą zróżnicowanych miar i metod ich identyfikacji. Warto też podkreślić, że poszczególne podejścia stosowane w identyfikacji obserwacji nietypowych generują zróżnicowane zbiory tych obserwacji. W dużym stopniu jest to zapewne rezultatem odmiennej konstrukcji stosowanych miar.

Modele z usuniętymi obserwacjami nietypowymi charakteryzują się wyższą jakością, przy czym jest to na ogół widoczne w przypadku obserwacji uznanych za nietypowe z tytułu kształtowania się dynamiki PKB *per capita*. Redukcja zbioru obserwacji o obserwacje nietypowe pozwala na precyzyjniejsze wyodrębnienie analizowanej prawidłowości dzięki eliminacji wpływu wartości różniących się istotnie od pozostałych. Nie można jednak usuwać ich w sposób automatyczny, ponieważ powoduje to zmianę obserwowanej relacji między zmiennymi. Decydujące znaczenie powinna mieć w tym przypadku analiza merytoryczna

² Dokonanie pomiaru wkładu poszczególnych krajów w proces wyrównywania się dochodów w grupie obserwowanych obiektów nie jest możliwe za pomocą modelu (1). Można w tym celu wykorzystać koncepcję pionowej konwergencji krańcowej opisaną w pracy [Batóg 2013].

oparta np. na obserwacji dynamicznych właściwości badanych zjawisk lub znaczenia poszczególnych obiektów dla formułowanych wniosków.

Literatura

- Acuna E., Rodriguez C.A. [2004], *A Meta Analysis Study of Outlier Detection Methods in Classification*, Proceedings IPSI 2004, Venice, <http://academic.uprm.edu/eacuna/paperout.pdf> (dostęp: 26.04.2014).
- Barnett V., Lewis T. [1994], *Outliers in Statistical Data*, John Wiley, Chichester.
- Barro R.J., Sala-i-Martin X. [2004], *Economic Growth*, 2nd ed., MIT Press, Cambridge, Massachusetts.
- Batóg J. [2010], *Konwergencja dochodowa w krajach Unii Europejskiej. Analiza ekonometryczna*, Rozprawy i Studia, t. DCCCLIV (780), Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin.
- Batóg J. [2013], *Analiza krańcowej pionowej konwergencji dochodowej typu β w krajach Unii Europejskiej w latach 1993–2010*, Studia i Prace Wydziału Nauk Ekonomicznych i Zarządzania, nr 31, *Metody ilościowe w ekonomii*, t. 1, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin.
- Batóg J., Batóg B. [2006], *Income Convergence in the European Countries: Empirical Analysis*, „Folia Oeconomica Stetinensia”, nr 5(13).
- Ben-Gal I. [2005], *Outlier Detection [w:] Data Mining and Knowledge Discovery Handbook: A Complete Guide for Practitioners and Researchers*, red. O. Maimon, L. Rokach, Kluwer Academic Publishers, Boston.
- The Conference Board Total Economy Database* [2014], January, <http://www.conference-board.org/data/economydatabase/> (dostęp: 22.04.2014).
- Fawcett T., Provost F. [1997], *Adaptive Fraud Detection*, „Data Mining and Knowledge Discovery”, vol. 1, nr 3.
- Hawkins D. [1980], *Identification of Outliers*, Chapman and Hall, London.
- Hozer J. [1993], *Mikroekonometria*, PWE, Warszawa.
- Maddala G.S. [2006], *Econometrics*, Wydawnictwo Naukowe PWN, Warszawa.
- Penny K.I., Jolliffe I.T. [2001], *A Comparison of Multivariate Outlier Detection Methods for Clinical Laboratory Safety Data*, „The Statistician”, vol. 50, nr 3, <http://dx.doi.org/10.1111/1467-9884.00279>.
- Ruts I., Rousseeuw P.J. [1996], *Computing Depth Contours of Bivariate Point Clouds*, „Computational Statistics and Data Analysis”, vol. 23, nr 1, [http://dx.doi.org/10.1016/s0167-9473\(96\)00027-8](http://dx.doi.org/10.1016/s0167-9473(96)00027-8).
- Walfish S. [2006], *A Review of Statistical Outlier Methods*, „Pharmaceutical Technology”, November 2.
- Williams G.J., Baxter R.A., He H.X., Hawkins S., Gu L. [2002], *A Comparative Study of RNN for Outlier Detection in Data Mining*, Proceedings of the 2nd IEEE International Conference on Data Mining (ICDM'02), Maebashi City, Japan.

Identification and Significance of Outliers in Models of Income Convergence

(Abstract)

The research of income convergence found remunerative findings in the existing literature and economic practice. The results obtained, however, show comparatively large differentiation. Many authors underline the strong dependence of the results obtained from the time and spatial character of the sample as well as the type of methods applied. Little attention is placed on the role of non-typical observations (outliers) which can occur as a result of incorrect measurement, random error, non-standard circumstances or intentional impact. The hypothesis verified was that outliers exert an essential influence on estimation results. The main objective of the analyses provided was to determine if the occurrence of such observations significantly changes the quality of the models built and the speed of the process of income convergence.

Keywords: outliers, income convergence, econometric models, European Union.

Viktor Shevchuk

Department of Economy, Sociology and Philosophy
Cracow University of Technology

Flexible Exchange Rates as Shock Absorbers in Central and Eastern Europe

Abstract

Considering the merits of the flexible exchange rate and its ability to absorb asymmetric macroeconomic shocks, results on the basis of a two-variable SVAR model suggest that this ability was lacking in both Hungary and Romania, as regardless of the data used more than 80% of variability in the nominal (real) exchange rate over a four-quarter horizon can be explained by neutral structural shock. Variability in output is determined mainly by non-neutral (permanent) structural shocks. As for Poland and, to a lesser extent, the Czech Republic, the evidence supporting the stabilising properties are somewhat stronger, with up to 30% to 40% of changes in the nominal (real) exchange rate being explained by the permanent (output) shock. However, the results are sensitive to the data used.

Keywords: exchange rate regime, SVAR, the Blanchard-Quah decomposition, transformation economies.

1. Introduction

Stabilisation policies in the wake of the 2008–2009 financial crisis do not provide clear preferences for a particular exchange rate regime – fixed or floating. Although Poland, and its experience in sustaining a “green island”, is credited with a free-floating exchange rate policy, that is not a sufficient argument in favour of greater exchange rate flexibility. While other largest Central and East

European (CEE) countries, including Czech Republic, Hungary, and Romania, have been practicing variants of a floating exchange rate regime, Slovakia adopted the euro in 2009 and the Baltic States have been quite successful in making macroeconomic adjustments under a fixed exchange rate regime.

Under high capital mobility, with limited scope for independent interest rate policy, the choice of the exchange rate regime largely centers around the costs (or benefits) of giving up the flexible exchange rate as a stabilisation tool (i.e., a shock absorber). As mentioned by B. Stażka-Gawrysiak (2009, p. 54), the consensus now is such that the flexible exchange rate can act as a shock-absorbing instrument if its fluctuations are mainly driven by real, especially demand, shocks and as a destabilising one if they are largely driven by nominal disturbances. For the nominal (real) exchange rate to be an efficient shock absorber, it is necessary to respond in similar proportions to the same real (supply and demand) asymmetric shocks that significantly affect output (Masten 2002, p. 2). However, it is quite complicated to resolve whether exchange rate flexibility is a significant stabilising mechanism, as observed exchange rate movements could be purely extraneous and reflect not movements in fundamentals but other factors, such as financial market sentiment (*The Exchange Rate* 2003, p. 3). For a small open economy, M. Artis and M. Ehrmann (2006, pp. 874–893) argued that the exchange rate can act as a shock-absorber only if an economy is affected by an asymmetric shock with respect to its trading partner. If the exchange rate's own shocks are large enough, it is of further interest whether they are stabilising (or destabilising) for the economy. Moreover, the exchange rate – output relationship can evolve over time. For example, the exchange rate appreciation seemed to be contractionary from 1996 to 2000 in Poland, whereas for periods between 2000 and 2008 it had a positive significant effect (Arratibel & Michaelis 2014).

The purpose of this paper is to investigate potential features of nominal (real) exchange rates as shock absorbers in the Czech Republic, Hungary, Poland and Romania. Following the pioneering approach by M. Canzoneri, J. Valles and J. Vinals (1996), shock-absorbing properties are studied within the simplest structural vector autoregression (SVAR) two-variable framework, which could be easily extended to the three-variable framework of demand (IS), supply (AS) and nominal (LM) shocks.

Despite strong theoretical arguments in favour of exchange rate flexibility as a stabilising tool, evidence is not lacking that flexible exchange rate regimes do a worse job of insulating open economies from external shocks (Aysun 2008, pp. 302–328). This study is aimed at comparative analysis of exchange rate shocks for four transformation economies with a floating exchange rate regime within the familiar framework of the Blanchard-Quah decomposition. The long-run zero restrictions are often criticised from a theoretical and empirical point of view

on the basis of small sample biases and measurement errors, the possibility for permanent real effects of nominal shocks in overlapping generations and hysteresis models etc. (Farrant & Peersman 2006, pp. 939–961), but this approach is still popular because of its simplicity and transparency. Alternative approaches including, for example, SVAR models with short-run restrictions, suffer from the well-known problem of interpreting the multitude of identified models (Gehrke & Yao 2013).

The paper is structured as follows. Section 2 outlines the necessary analytical considerations, with a focus upon identification of structural shocks and empirical results. In Section 3, data and statistical methodology are presented. Estimation results are discussed at length in Section 4, while Section 5 checks robustness. The final section's concluding remarks round out the paper.

2. Analytical Framework

The main advantage of the shock-absorbing properties of exchange rate flexibility is its potential ability to generate rapid adjustment in international relative prices even when domestic prices adjust slowly (Borghijis & Kuijs 2005, p. 3). In the absence of a relative price-driven “expenditure-switching” mechanism, such real shocks as changes in the budget balance, foreign demand or terms of trade can cause significant output losses or overheating. However, exchange rate adjustment in response to monetary and financial (or nominal) shocks could be counterproductive, leading to a stronger disequilibrium in the economy. A fixed exchange rate system looks preferable in the case of nominal shocks, but it is inefficient in neutralising real shocks. As defined by M. Canzoneri, J. Valles and J. Vinals (1996), shocks are classified as “neutral” if they have no long-run effect on relative output, and as “non-neutral” if they do have. However, M. Artis and M. Ehrmann (2006, pp. 874–893) argue that measuring all variables relative to a neighbour not only reduces the analysis to an asymmetric shock with respect to its trading partner, but would overestimate the role of exchange rate as a shock absorber as well.

If the exchange rate generates shocks of its own, it is important to establish whether these disturbances are stabilising for the economy (Artis & Ehrmann 2006, pp. 874–893). For example, the effect of the exchange rate depreciation on output depends on whether the expenditure-switching channel or the interest rate channel dominates (Arratibel & Michaelis 2014). Assuming depreciation of the nominal (real) exchange rate, expansion of exports is expected, with a positive effect on output, while an increase in the interest rate is likely to “crowd out” domestic consumption and investment, thus triggering a contractionary pressure

on the economy. The balance sheet and wealth effects additionally complicate the picture of the relationship between the exchange rate and output in the short run¹.

Following M. Canzoneri, J. Valles and J. Vinals (1996), the vector of endogenous variables $\Delta x_t = [\Delta e_t, \Delta y_t]$ has a structural interpretation

$$\Delta x_t = C(L)\varepsilon_t, \quad (1)$$

where:

e_t – the nominal exchange rate,

y_t – the output (GDP or industrial production),

L – the lag operator,

$\varepsilon_t = [\varepsilon_{Nt}, \Delta\varepsilon_{Pt}]$ – a vector of serially uncorrelated structural shocks, with ε_{Nt} and ε_{Pt} being the neutral shock and non-neutral (or permanent) shocks, respectively.

The vector ε_t is to be recovered from an estimate of the moving average representation:

$$\Delta x_t = A(L)u_t, \quad (2)$$

where the polynomial $A(L)$ is the identity matrix and the disturbance vector u_t has an estimated variance-covariance matrix Σ .

Assuming a linear relationship, $u_t = c_0\varepsilon_t$, the 2×2 matrix c_0 makes it possible to recover the vector of structural shocks, ε_t , from the estimated disturbance vector, u_t . Combining three of the four restrictions that are required from the symmetric matrix $\Sigma c_0 c_0'$ and the fourth one along the lines of economic theory, the long-run representation of (1) can be written as:

$$\begin{bmatrix} \Delta e_t \\ \Delta y_t \end{bmatrix} = \begin{bmatrix} c_{11} & c_{12} \\ 0 & c_{22} \end{bmatrix} \begin{bmatrix} \varepsilon_{Nt} \\ \varepsilon_{Pt} \end{bmatrix}. \quad (3)$$

The long-run identifying restriction $c_{21} = 0$ implies that the neutral shock to exchange rate has no long-run effect on output. On the other hand, the permanent (or non-neutral) shock affects either output or the nominal exchange rate. It is common to assume that in a two-variable model, neutral shocks include monetary/financial market (LM) shocks, while permanent shocks are identified as supply shocks (Borghijis & Kuijs 2004, p. 9). Although using the long-run zero restrictions might be considered too stringent (Farrant & Peersman 2006, pp. 939–961), it is a good reference point for alternative approaches in identification of the shock-absorbing properties of exchange rate flexibility, such as short-run zero restrictions or sign restrictions.

¹ The wealth effect refers to a direct relationship between the value of financial and other assets in real terms and output, with depreciation being restrictionary due to an increase in the price level (this link could be weakened by an increase in the value of foreign currency-denominated assets). The balance sheet effect implies that depreciation increases the real value of foreign debt, thus exerting the adverse effect on output.

Following the predictions of the Mundell-Fleming model, a positive permanent (supply) shock results in an increase in output and in exchange rate depreciation due to excess supply of home-produced goods (Masten 2002, p. 25). A positive nominal shock is associated with a decrease in the interest rate and nominal (real) depreciation and output expansion as well.

Empirical studies have been rather inconclusive, as results depend on the exact model specification and data used (Stażka 2006). Extra difficulties are created by the abovementioned use of variables in relative or direct form (Artis & Ehrmann 2006, pp. 874–893), the identification scheme or sample size used. For example, S.-S. Chen (2004, pp. 25–32) found that monetary shocks are more important in a longer sample set. The presence of shock-absorbing properties of a floating exchange rate is found for the U.S. (Juvenal 2009), Sweden and Canada, but not for Australia, New Zealand and the U.K. (Alexius & Post 2008, pp. 527–541). Using a new identification strategy of sign restrictions instead of more traditional long-run zero restrictions, K. Farrant and G. Peersman (2006, pp. 939–961) determined that shock-absorption properties are lost for the U.K., euro area, Japan and Canada *vis-à-vis* the U.S., though that was not the case in an earlier study by R. Clarida and J. Gali (1994, pp. 1–56). Consequently, the exchange rate can be considered to be a source of shocks rather than a shock absorber. M. Canzoneri, J. Valles and J. Vinals (1996) reached the same conclusions for a number of European countries, as supply shocks explain most output changes but can hardly explain exchange rate variation. Studying time series of the US *vis-à-vis* an aggregate of industrialised countries and splitting the supply shock into a traditional productivity and the cost push shocks², B. Gehrke and F. Yao (2013) confirm that the former are not an important driver of RER volatility (3–10%), but the latter account for up to 30% of the variability of the RER volatility.

Borghijis and Kuijs (2004) find that exchange rates in CEE countries (aside from Poland) react more to monetary and financial shocks, while being unable to absorb real shocks. A. Stażka has reported on the stabilising properties of Poland's exchange rate (2006) while J. López and J. Chacón (2006) confirm that the exchange rate could be a stabilising tool for Poland and the Czech Republic, though not for Hungary. Earlier S. Dibooglu and A. Kutun (2001, pp. 257–275) concluded that nominal shocks determine a sizable proportion of real exchange rate (RER) variability in Poland (up to 63% on impact), but not in Hungary. I. Masten (2002) determined that the real exchange rate does not have a shock-absorbing role for Hungary as well as the Czech Republic, Slovenia, Denmark and the U.K. Recently, A. Volha and F. Brázdik (2012) have established for the Czech Republic that the shock-absorbing properties of the exchange rate outweigh

² Cost-push factors that affect a firm's marginal costs of production comprise factors such as labour market institutions, demographics, and international competition (Gehrke & Yao 2013).

their shock-generating counterparts. O. Arratibel and H. Michaelis (2014) have concluded that the Polish economy has become more resilient over time to monetary policy and exchange rate shocks.

Among studies for other CEE countries, N. Erjavec, B. Cota and S. Jakšić (2012, pp. 27–46) argue that the exchange rate in Croatia seems to be a shock absorber, as volatility of RER is mainly influenced by demand shocks, with the impact of supply shocks being insignificant. Z. Kontolemis and K. Ross (2005) find that the impact of real shocks upon the RER varies across CEE countries. S. Ahmed, C. Gust, S. Kamin and J. Huntley (2002) suggest that exchange rate movements may be more destabilising in developing countries than in industrial countries, regardless of the exchange rate regime chosen.

3. Data and Statistical Methodology

For empirical study, quarterly time series data are used for the Czech Republic, Hungary, Poland and Romania for the period 1999–2013, as provided by the online IMF's *International Financial Statistics*. Both nominal and real effective exchange rates, NEER_t and REER_t, respectively, are used as the exchange rate measure (Fig. 1). By using the RER, not just the nominal exchange rate, it is possible to take into account the adjustment through relative prices (Masten 2002, p. 2). For the Czech Republic and Poland, there is not much difference between the real and nominal rates, though a common trend in both indicators is quite different in both countries. While there is a clear nominal and real appreciation in the former, much higher exchange rate volatility in the latter does not imply any change in the equilibrium value. Exchange rate developments have been quite similar in Hungary and Romania over the last decade, despite different patterns in the nominal rates over the 1999–2004 period.

Output is proxied with the gross domestic product and industrial production, Y_t and IND_t , respectively (Fig. 2)³. Although most empirical studies specify output as relative to the corresponding variable of the large neighbouring area (it is based on the assumption that the exchange rate itself is a “relative” variable), this approach can identify only asymmetric shocks (Artis & Ehrmann 2006, pp. 874–893). Thus it is difficult to identify which country has to bear the adjustment costs, assuming that transmission mechanisms can differ between countries. Using the variables of the economies itself seems to be preferable in that case. However, output in relative terms is used later in our sensitivity analysis, thus

³ A. Borgjjs and L. Kuijs (2004) use industrial output expressed relative to the euro area to capture asymmetric shocks relative to the economic area against which the exchange rate is assessed.

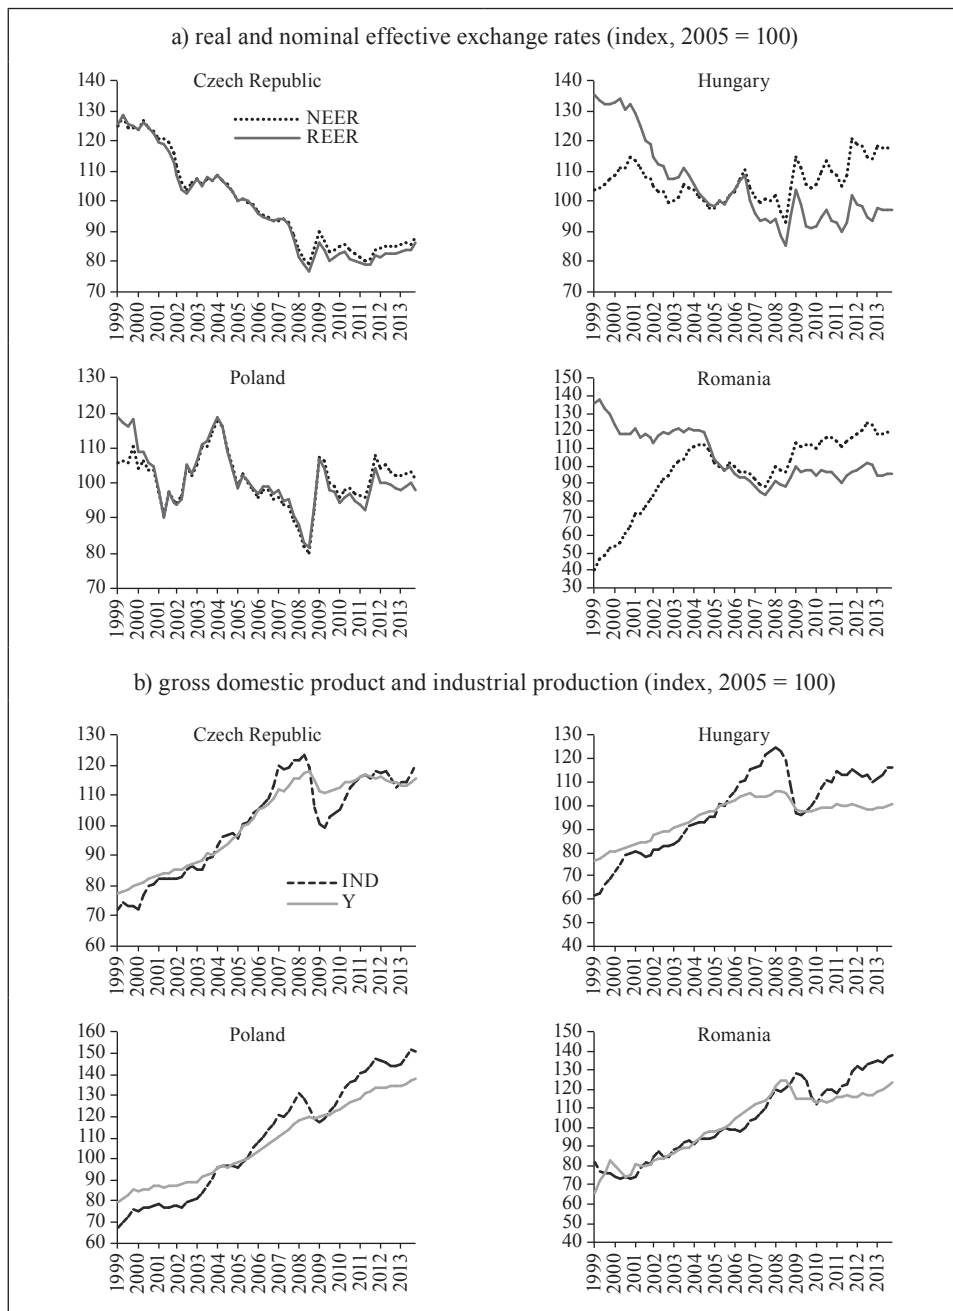


Fig. 1. The CEE Countries: Exchange Rate and Output, 2000–2013

Source: the IMF *International Financial Statistics* online database.

providing ground for useful comparisons between both specifications, in our particular case the four countries that make up the CEE.

With the trend and intercept included, the results of the Augmented Dickey-Fuller (ADF) test indicate that in almost all cases the (level) data are I(1) and not integrated of a higher order, as the null hypothesis of a unit root in the level of either a nominal (real) effective exchange rate or output (GDP or industrial output) cannot be rejected, while it is the opposite for the difference of both time series (Table 1).

Table 1. ADF Test Statistics

Variable	Czech Republic 1999Q1: 2013Q4	Hungary 1999Q1: 2013Q4	Poland 2000Q1: 2013Q4	Romania 2000Q1: 2013Q4
NEER	-2.28 -5.93*	-2.57 -2.79***	-2.46 -3.89**	-2.68 -5.23*
REER	-2.15 -5.10*	-0.97 -3.83**	-3.06 -3.94**	-1.29 -5.71*
Y	-0.34 -5.34*	-0.81 -3.14***	-1.88 -6.93*	-1.23 -3.45***
IND	-2.18 -5.27*	-2.03 -4.09**	-2.23 -3.87**	-2.99 -5.52*

Note: * null hypothesis can be rejected at the 1% level (**, *** at the 5% and 10% level, respectively). Lags are based on the automatic criteria selection by the Schwartz criterion.

Source: the author's calculations.

The model (3) is estimated in turn for each of four countries. Depending on the particular country, country-specific SVARs are estimated using two to three lags and a dummy for the 2008–2009 world financial crisis, ensuring that the residuals are stationary. As it is assumed that foreign output is exogenous, industrial output in Germany is included in the SVAR model. Among other independent variables, the lagged London Inter-Bank Offered Rate (LIBOR) is counted for in estimates for Poland. Identified SVAR models are used to recover the dynamic effects of the structural shocks on the nominal (real) exchange rates and output. First of all, the impulse response functions are obtained in order to gain a general picture of the neutral and permanent effects on the exchange rate and output. Then the variance decompositions are used to investigate the relative contribution of each of the identified shocks to the error variance in forecasting these rates. In order to test the robustness of the empirical results, a shorter subsample of the 2004–2013

period is first used to estimate the model (3), followed by an alternative specification of output.

4. Impulse-response and Variance Decomposition Results

Figures 2 to 5 present the impulse response functions for the nominal (real) effective exchange rate and output (GDP), respectively. The vast majority of the impulse responses are as expected. In response to the (positive) neutral shock, the nominal exchange rate uniformly depreciates in all countries, regardless of the output indicator chosen (Fig. 2a). Following a one standard deviation shock to NEER, there is an immediate depreciation in the nominal rate, which then edges down gradually in about four quarters. For Poland and Hungary, there is a local strengthening of the exchange rate with a two-quarter lag.

The (positive) permanent shock leads to a temporary appreciation of the NEER on impact in the Czech Republic and Hungary, but there is an opposite outcome in Poland and Romania (Fig. 2b). For all four countries, the exchange rate appreciates with a quarter lag, which is consistent with the predictions of a monetary model of the exchange rate determination, but since that point the convergence path to a steady state is different. The magnitude of NEER appreciation gradually decreases for two countries – Poland and Romania – where it is preceded with an initial depreciation, and there is depreciation of the exchange rate in the Czech Republic and Hungary, where an initial appreciation on impact is observed. However, any differences regarding the NEER reaction to a permanent shock on impact disappear in the specification with industrial production, with no possibility of further appreciation. Some similarities are seen in that the exchange rate depreciation on impact in both Poland and Romania is followed by local appreciation of the NEER.

Although it is assumed that neutral shocks do not have any long-run output effects, it is nevertheless interesting to compare relevant impulse response functions as a source of information on the direction of exchange rate effects (Fig. 3a). The responses of GDP (left panel) are smaller than those for industrial production (right panel), but display similar dynamics patterns. However, output does not react to exchange rate shock in a uniform and consistent way. For all countries, the directions of these responses are asymmetric at different lags. Temporary increases in GDP, as predicted by the Mundell-Fleming model, are found for the Czech Republic, Hungary and Poland, and followed by a restrictionary correction in two to five quarters. For Romania, the sequence of exchange rate effects is just the opposite. In general, the exchange rate effects are stronger in respect to industrial output than GDP. Permanent shock brings about an increase in output across

all countries (Fig. 3b), though with a slight restrictive correction in Romania and the Czech Republic (specification with industrial production).

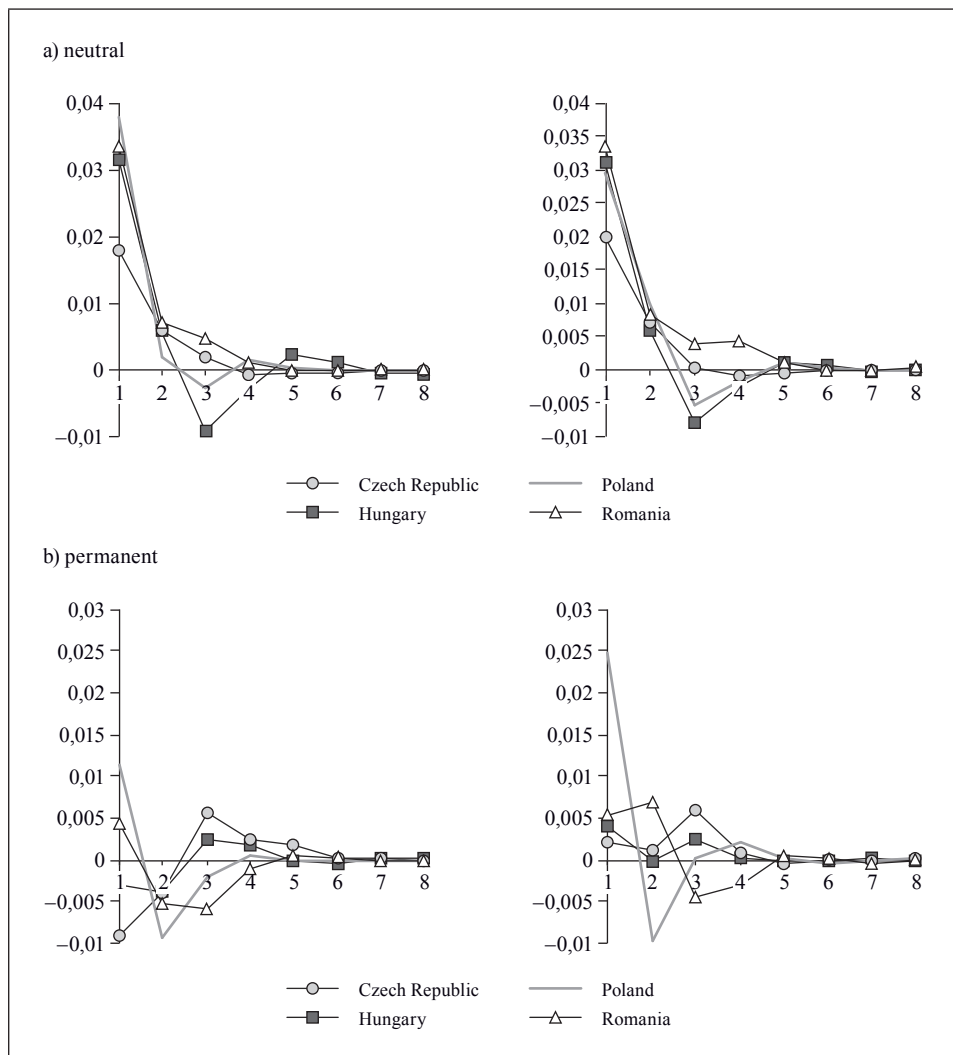


Fig. 2. Effects of VAR Shocks on the Nominal Effective Exchange Rate

Note: impulse responses for the nominal and real effective exchange rates are on the left and right graphs, respectively.

Source: the author's calculations.

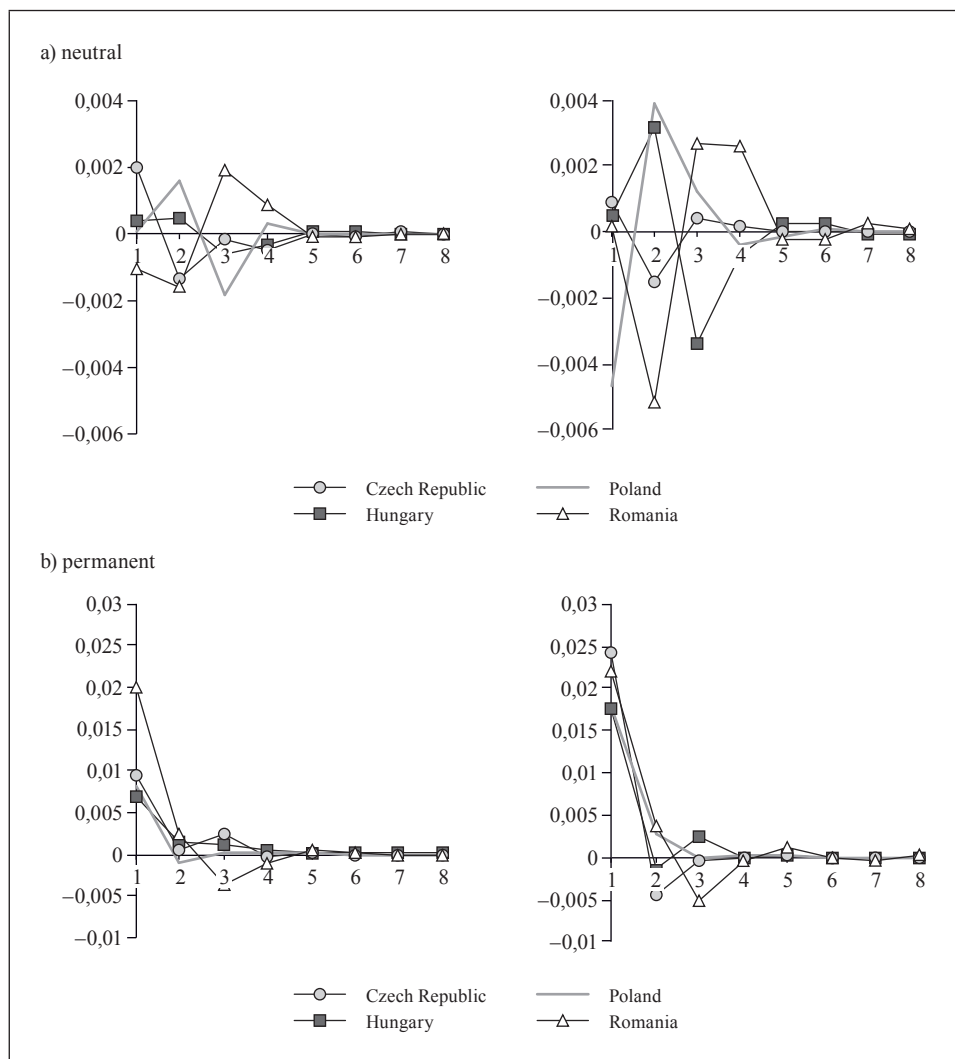


Fig. 3. Effects of VAR Shocks on Output (Specification with NEER)

Source: the author's calculations.

The pattern of neutral effects for the RER is not much different from that obtained for the NEER, i.e. depreciation on impact followed by a short-lived (and much weaker) appreciation with two to three quarter lags (Fig. 4a). The permanent effects follow almost the same pattern as the NEER estimates, especially for Hungary, Poland and Romania. For the Czech Republic, the initial apprecia-

tion on impact is stronger and there is no such abrupt correction of a subsequent depreciation as in the case of NEER estimates.

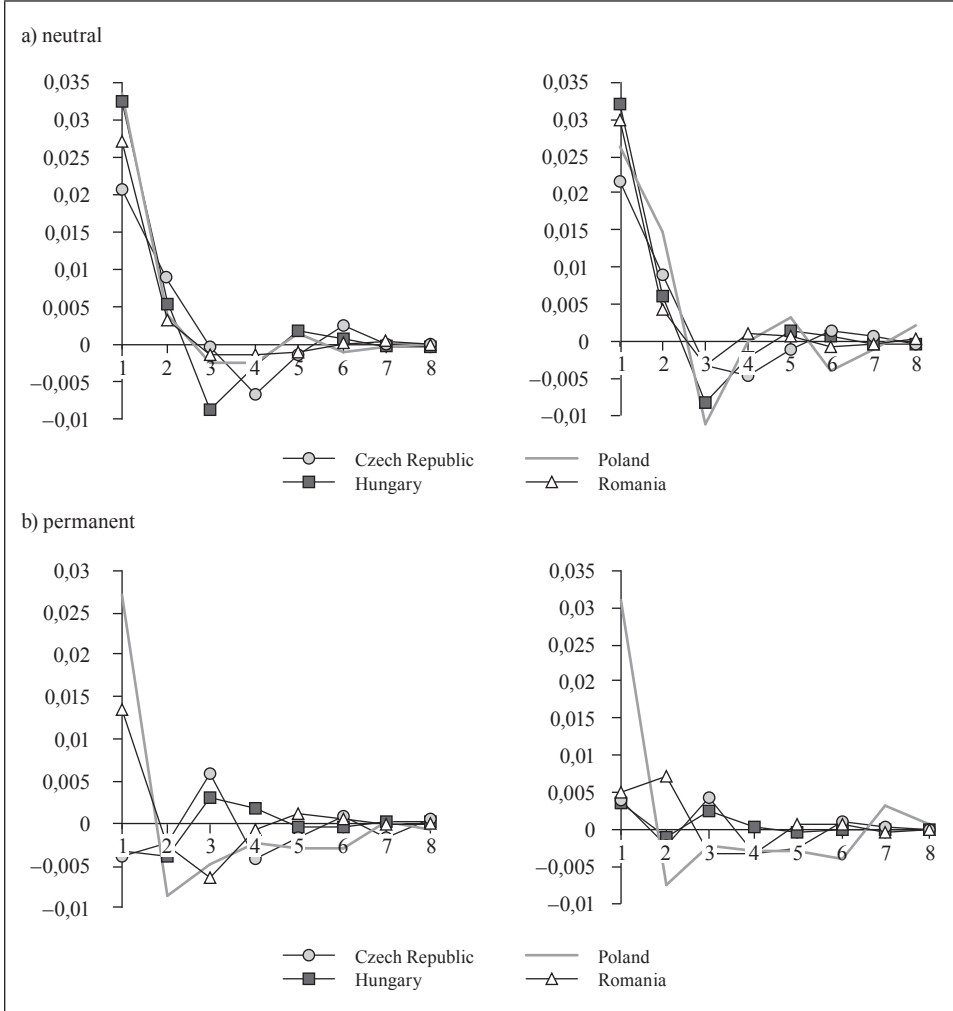


Fig. 4. Effects of VAR Shocks on the Real Effective Exchange Rate
 Note: impulse responses and variance decomposition are on the left and right graphs, respectively.
 Source: the author’s calculations.

For the Czech Republic, Hungary and Poland, the RER effects on output (Fig. 5a) are not significantly different from the NEER estimates. As for Romania, the neutral shock effects reveal a stronger but shorter restrictionary effect on

impact regarding GDP estimates. Similar to NEER estimates, the RER effects on output are asymmetrical over a year time span, which does not bode well for the use of the exchange rate as a stabilisation policy tool, even if the nominal (real) exchange rate does react significantly to permanent (supply) shocks. Permanent shock is expansionary and not persistent (Fig. 5b).




Fig. 5. Effects of VAR Shocks on the Output (Specification with RER)

Source: the author's calculations.

Table 2 reports the variance decompositions for the estimated model at a horizon of 4 quarters, which is the horizon over which monetary policy and exchange rate flexibility are presumed to be most potent. Similar to other studies

(Borgjis & Kuijs 2004), at least three quarters of variability in the NEER is explained by the neutral shock, except for the somewhat lower share for the Czech Republic at 72%, which is not surprising as this country has employed a floating exchange rate regime since 1997. At the same time, the neutral shock is responsible for 87% of the variance decomposition of Poland's nominal exchange rate, another well-known floater among the CEE countries. Using the real exchange rate, the share of its own shock in the variance of the exchange rate decreases to 61% in the specification, which is a much better indication of the shock-absorbing properties of a floating exchange rate regime. Also, the neutral shock becomes responsible for up to 21% of the variance of GDP.

Table 2. Forecast Error Variance Decomposition for the Exchange Rate and Output (in Percentage)

Variable	Czech Republic		Hungary		Poland		Romania	
	N	P	N	P	N	P	N	P
NEER	72	28	97	3	87	13	95	5
Y	6	94	2	98	7	93	4	96
RER	88	12	98	2	61	39	80	20
Y	13	87	2	98	20	80	8	92
NEER	91	9	98	2	60	40	92	8
IND	1	99	7	93	8	92	7	93
RER	91	9	98	2	53	47	90	10
IND	1	99	7	93	15	85	9	91

Note: N is for neutral shock and P is for permanent shock.

Source: the author's calculations.

For Romania, the share of permanent shock in the variance of the RER increases to 24% compared with just 7% for the NEER. In contrast to Poland, there is no significant increase in the share of nominal shock in explaining the variance of GDP, suggesting much weaker stabilising properties. The Czech Republic is different from Poland and Romania in that the RER is more dependent on its own shock compared to the NEER. Our results contrast with estimates by A. Volha and F. Brázdik (2012), who found that the nominal shock determines about 50% of the RER variance, though its share in the changes of GDP is the same. There is no difference in variance decomposition between NEER and RER estimates for Hungary.

Using industrial production as a proxy for output led to no significant changes in the variance decomposition for Hungary. The share of permanent shock in the decomposition of NEER and RER decreases substantially for the Czech Republic,

while being even higher for industrial production. This further strengthens the suggestion that output does not react to the nominal shock. Romania showed no change for the variance decomposition in specification with the NEER, while arguments (albeit weak ones) in favour of the shock-absorbing properties are completely lost in specification with the RER. Poland is the only country where using industrial production instead of GDP as the output indicator improves the shock-absorbing properties of exchange rate in both aspects: (i) reaction of the exchange rate to permanent shocks and (ii) output effects. The share of permanent shock in the variance decomposition of the RER is as high as 49% in the specification with the RER, while it determines 22% of variation in industrial production. However, the depreciation is contractionary on impact, while a short-lived expansionary effect is obtained with a quarter lag.

5. Robustness Check

Our sensitivity analysis regards sub-sample stability and the use of alternative definition for output. Table 3 reports the variance decompositions for the estimated model at a horizon of 4 quarters for the shorter sample of the 2004–2013 period. Except for the Czech Republic (specification with the GDP), there is no significant difference between the estimates of the variance decomposition for the 1999–2013 and 2004–2013 periods across three other countries. It is especially the case for specifications with the GDP as a proxy for output. Using industrial production, there is some weakening of stabilisation properties for nominal and real exchange rates in Poland, but the difference is not substantial. As for the Czech Republic, there is an increase in the share of permanent shock in the variance decomposition of either nominal or real exchange rates, while changes in the GDP reveal stronger reaction to the nominal shock. However, the specification with industrial production does not support the assumption that exchange rate flexibility exhibits shock-absorbing properties. To sum up, empirical estimates for a shorter sub-sample do not suggest that the transmission of exchange rate and output shocks have changed significantly over time.

Using the alternative definition of output as relative to Germany's GDP and industrial production, Y/Y^* and IND/IND^* , respectively, the variance decomposition in respect to nominal and permanent shocks for the extended sample of the 1999–2013 period is presented in Table 4. In general, the share of the nominal shock in the variance decomposition of output increased, especially for Hungary and Poland. The significance of the permanent shock in changes of a nominal exchange rate increases for Romania (specification with GDP), while decreasing for the Czech Republic. Shock-absorbing properties become almost perfect for

Poland in the specification with industrial production, but this result does not hold in the specification with GDP.

Table 3. Forecast Error Variance Decomposition for the Exchange Rate and Output (in Percentage), Sub-sample of the 2004–2013 Period

Variable	Czech Republic		Hungary		Poland		Romania	
	N	P	N	P	N	P	N	P
NEER	46	53	96	4	99	1	81	19
Y	17	83	2	98	9	91	7	93
RER	61	39	96	4	89	11	86	14
Y	41	59	12	88	18	82	4	96
NEER	92	8	97	3	75	25	96	4
IND	1	99	4	96	5	95	7	93
RER	83	17	98	2	79	21	97	3
IND	3	97	3	97	5	95	11	89

Note: N is for neutral shock and P is for permanent shock.

Source: the author's calculations.

Table 4. Forecast Error Variance Decomposition for the Exchange Rate and Relative Output (in Percentage), the Sample of 1999–2013 Period

Variable	Czech Republic		Hungary		Poland		Romania	
	N	P	N	P	N	P	N	P
NEER	95	5	92	8	84	16	88	12
Y/Y*	15	85	25	75	22	78	4	96
RER	96	4	98	2	86	14	70	30
Y/Y*	14	86	25	75	24	76	10	90
NEER	89	11	98	2	32	68	94	6
IND/IND*	10	90	12	88	34	66	2	98
RER	87	13	94	6	29	71	91	9
IND/IND*	5	95	12	88	40	60	2	98

Note: N is for neutral shock and P is for permanent shock.

Source: the author's calculations.

6. Conclusions

One of the most persistent arguments in favour of a flexible exchange rate regime is its hypothetical ability to absorb asymmetric real shocks. Based on quarterly data for the 1999–2013 period, this was not found to be the case for all CEE countries, as more than 80% of variability in the nominal exchange rate over the four-quarter horizon is explained by the neutral shock (except for the Czech Republic and Poland), while variability in output (GDP and industrial production) is mostly determined to the same extent by the permanent shock, as it is extracted from a two-variable SVAR model based on the familiar Blanchard-Quah decomposition. For Poland, the shock-absorbing properties of the exchange rate look more credible when the RER for specification of a neutral exchange rate shock and industrial production for specification of the permanent shock are used, especially for a shorter subsample of the 2004–2013 period. The contribution of the permanent shock to the variance of GDP ranges from 80% in Poland to over 90% in the other three CEE countries in the baseline specification (Table 2). This result was also confirmed for a shorter sample of the 2004–2013 period (except for the Czech Republic, in the specification with real exchange rate and GDP).

As empirical results suggest that the nominal exchange rate does not respond to the shocks that seem to cause the bulk of fluctuations in output, it is possible to conclude that the exchange rate does not serve as a shock-absorber for Hungary and Romania, although this conclusion is somewhat weaker in the case of Poland and the Czech Republic (to a lesser extent). It is worth noting that using relative output strengthens the shock-absorbing properties of the exchange rate for Poland, while the results for other countries are not much changed.

Bibliography

- Ahmed S., Gust C. J., Kamin S. B., Huntley J. (2002), *Are Depreciations as Contractionary as Devaluations? A Comparison of Selected Emerging and Industrial Economies*, International Finance Discussion Papers, no. 737, Board of Governors of the Federal Reserve System, Washington.
- Alexius A., Post E. (2008), *Exchange Rates and Asymmetric Shocks in Small Open Economies*, "Empirical Economics", 35(3), <http://dx.doi.org/10.1007/s00181-007-0177-7>.
- Arratibel O., Michaelis H. (2014), *The Impact of Monetary Policy and Exchange Rate Shocks in Poland: Evidence from a Time-varying VAR*, ECB Working Paper Series, no. 1636, European Central Bank, Frankfurt am Main.
- Artis M., Ehrmann M. (2006), *The Exchange Rate: A Shock-absorber or Source of Shocks? A Study of Four Open Economies*, "Journal of International Money and Finance", 25(6), <http://dx.doi.org/10.1016/j.jimonfin.2006.07.003>.

- Aysun U. (2008), *Automatic Stabilizer Feature of Fixed Exchange Rate Regimes*, “Emerging Markets Review”, 9(4), <http://dx.doi.org/10.1016/j.ememar.2008.10.004>.
- Borghijis A., Kuijs L. (2004), *Exchange Rates in Central Europe: A Blessing or a Curse?*, IMF Working Paper, no. 4/2, International Monetary Fund, Washington.
- Canzoneri M., Valles J., Vinals J. (1996), *Do Exchange Rates Move to Address International Macroeconomic Imbalances?*, CEPR Discussion Papers, no. 1498, Centre for Economic Policy Research, London.
- Chen S.-S. (2004), *Real Exchange Rate Fluctuations and Monetary Shocks: A Revisit*, “International Journal of Finance and Economics”, 9(1), <http://dx.doi.org/10.1002/ijfe.218>.
- Clarida R., Gali J. (1994), *Sources of Real Exchange Rate Fluctuations: How Important are Nominal Shocks?*, “Carnegie-Rochester Conference on Public Policy”, 41, [http://dx.doi.org/10.1016/0167-2231\(94\)00012-3](http://dx.doi.org/10.1016/0167-2231(94)00012-3).
- Dibooglu S., Kutan A. M. (2001), *Sources of Real Exchange Rate Fluctuations in Transition Economies: The Case of Poland and Hungary*, “Journal of Comparative Economics”, 29(2), <http://dx.doi.org/10.1006/jceec.2001.1707>.
- Erjavec N., Cota B., Jakšić S. (2012), *Sources of Exchange Rate Fluctuations: Empirical Evidence from Croatia*, “Privredna Kretanja i Ekonomska Politika”, 132(1).
- The Exchange Rate and Macroeconomic Adjustment* (2003), HM Treasury, London.
- Farrant K., Peersman G. (2006), *Is the Exchange Rate a Shock Absorber or a Source of Shocks? New Empirical Evidence*, “Journal of Money, Credit and Banking”, 38(4).
- Gehrke B., Yao F. (2013), *Sources of Real Exchange Rate Fluctuations: The Role of Supply Shocks Revisited*, Beiträge zur Jahrestagung des Vereins für Socialpolitik 2013: Wettbewerbspolitik und Regulierung in einer globalen Wirtschaftsordnung – Session: Applied Time Series, no. B20-V3, ZBW, Leibniz-Informationzentrum Wirtschaft, Kiel–Hamburg.
- Juvenal L. (2009), *Sources of Exchange Rate Fluctuations: Are They Real or Nominal?*, Working Paper 2009-040B, Federal Reserve Bank of St. Louis, St. Louis.
- Kontolemis Z., Ross K. (2005), *Exchange Rate Fluctuations in the New Member States of the European Union*, Economics Working Paper Archive, no. 0504015.
- López J., Chacón J. (2006), *Following the Yellow Brick Road? The Euro, the Czech Republic, Hungary and Poland*, Working Paper ECON, no. 06.12, Universidad Pablo de Olavide de Sevilla, Sevilla.
- Masten I. (2002), *How Important Is the Shock-absorbing Role of the Real Exchange Rate?*, EUI Working Paper, no. 2002/06, EEA, Venice.
- Stażka A. (2006), *Sources of Real Exchange Rate Fluctuations in Central and Eastern Europe – Temporary or Permanent?*, CESifo Working Paper, no. 1876, CESifo, München.
- Stażka-Gawrysiak A. (2009), *The Shock-Absorbing Capacity of the Flexible Exchange Rate in Poland. Focus on European Economic Integration*, Oesterreichische Nationalbank, Vienna.
- Volha A., Brázdík F. (2012), *Monetary Policy and Exchange Rate Dynamics: The Exchange Rate as a Shock Absorber*, Working Paper Series, no. 9, Czech National Bank, Prague.

Właściwości amortyzacyjne płynnego kursu walutowego w gospodarkach Europy Środkowej i Wschodniej (Streszczenie)

Biorąc pod uwagę znane zalety kursu płynnego jako amortyzatora niekorzystnych wstrząsów makroekonomicznych, otrzymane rezultaty na podstawie modelu SVAR z dwoma zmiennymi sugerują, że oczekiwane teoretycznie korzyści od większej giętkości kursu walutowego nie są obserwowane dla Węgier i Rumunii, ponieważ więcej niż 80% zmienności nominalnego (realnego) kursu walutowego w obrębie roku jest wyjaśnione przez neutralny wstrząs strukturalny. Jednocześnie zmienność produkcji zależy głównie od własnych wstrząsów permanentnych. Świadczenia na korzyść stabilizacyjnych właściwości kursu walutowego są bardziej wiarygodne dla Polski i Czech (w mniejszym stopniu), gdzie od 30% do 40% zmian nominalnego (realnego) kursu walutowego można tłumaczyć permanentnymi wstrząsami ze strony sektora realnego. Otrzymane wyniki zależą jednak od wykorzystanych danych.

Słowa kluczowe: system kursu walutowego, SVAR, dekompozycja Blancharda-Quah, gospodarki transformacyjne.

Iwona Foryś

Barbara Batóg

Instytut Ekonometrii i Statystyki
Uniwersytet Szczeciński

Modelowanie aktywności nabywców mieszkań na rynku województwa zachodniopomorskiego

Streszczenie

Aktywność uczestników rynku mieszkaniowego jest ściśle związana z kondycją ekonomiczną gospodarstw domowych, a ta skorelowana jest z koniunkturą gospodarczą. Ogólna tendencja osłabienia aktywności na rynku nieruchomości w okresie dekonjunktury gospodarczej nie ma tego samego natężenia na wszystkich rynkach regionalnych. Celem badania było sprawdzenie intensywności zawierania umów kupna-sprzedaży mieszkań w różnych okresach konjunktury w województwie zachodniopomorskim. Badanie objęło analizę liczby zawieranych transakcji w czasie, z podziałem na podokresy konjunktury i dekonjunktury gospodarczej oraz z uwzględnieniem sezonowości liczby transakcji ogółem. Zbadana została również zależność liczby zawieranych umów kupna-sprzedaży na rynku mieszkaniowym od zmiennych charakteryzujących stan gospodarki, takich jak dochody gospodarstw domowych, przychody ze sprzedaży w sektorze przedsiębiorstw, liczba nabytych samochodów, wartość sprzedaży detalicznej i stopa bezrobocia. Analizy przeprowadzono w ujęciu miesięcznym dla województwa zachodniopomorskiego. Wykorzystano dane z rejestrów cen i wartości nieruchomości w starostwach powiatowych, NBP oraz statystyki publicznej. W pracy wykorzystano modele ekonometryczne ze zmiennymi opóźnionymi oraz modele trendu z sezonowością.

Słowa kluczowe: rynek nieruchomości, liczba transakcji, modele ekonometryczne, modele trendu z sezonowością.

1. Wprowadzenie

Na podstawie intensywności sprzedaży mieszkań na danym rynku można określać aktywność uczestników tego segmentu rynku nieruchomości w określonej fazie cyklu koniunkturalnego. Rosnąca liczba zawieranych umów kupna-sprzedaży mieszkań świadczy o poprawie koniunktury, natomiast malejąca stanowi niepokojący sygnał na rynku mieszkaniowym [Foryś 2011]. Niezaspokojone potrzeby mieszkaniowe powinny powodować intensywny obrót mieszkaniami, warunkiem koniecznym jest jednak dostępność kapitału dla potencjalnych nabywców. Warunek ten jest ściśle związany z kondycją ekonomiczną gospodarstw domowych, a ta skorelowana jest z koniunkturą gospodarczą. Ponadto należy zauważyć, że ogólna tendencja osłabienia aktywności na rynku nieruchomości w okresie dekonunktury gospodarczej nie ma tego samego natężenia na wszystkich rynkach regionalnych. Na danym rynku regionalnym umowy sprzedaży (zakupu) mieszkań również podlegają zjawisku sezonowości. Dzięki obserwacji rynku można stwierdzić nasilenie liczby transakcji w okresie wiosennym oraz jesiennym, co może wynikać także z cyklu inwestycyjnego w budownictwie mieszkaniowym (przeciętnie 18–22 miesiące). Należy ponadto uwzględnić opóźnione w czasie reakcje sprzedających i kupujących mieszkania w stosunku do ogólnych tendencji rynkowych – zwłaszcza na rynkach regionalnych w stosunku do tendencji globalnych [Batóg i Foryś 2011; Batóg i Foryś 2013].

Celem badania jest analiza i modelowanie intensywności zawierania umów kupna-sprzedaży mieszkań w okresie dekonunktury na regionalnym rynku nieruchomości województwa zachodniopomorskiego w latach 2009–2013 oraz sezonowości liczby zawieranych umów. Badanie obejmuje analizę liczby zawieranych transakcji w czasie (dane miesięczne i kwartalne).

2. Charakterystyka danych

Dane dotyczące liczby transakcji pochodzą ze szczecińskiego systemu Walor, w którym znajdują się informacje na temat wszystkich umów rynkowych kupna-sprzedaży nieruchomości mieszkalnych (aktów notarialnych) zawartych na terenie województwa zachodniopomorskiego, zgromadzone przez rzeczoznawców majątkowych – sygnatariuszy systemu. Przyjmując założenie o rzetelnym gromadzeniu informacji, można uznać, że badanie jest pełne, a dane w analizowanym okresie były gromadzone w ten sam sposób. Dane obejmują transakcje zarówno na rynku pierwotnym, jak i na rynku wtórnym, z wyłączeniem umów nierynkowych, przy założeniu, że strony umowy były od siebie niezależne, nie działały pod przymusem, a mieszkanie było wyeksponowane na rynku dostatecznie długo. Dodatkowo podjęto próbę zbadania zależności liczby

transakcji od wybranych zmiennych opisujących sytuację gospodarczą województwa zachodniopomorskiego oraz tych samych zmiennych, lecz opóźnionych.

W badaniu uwzględniono następujące zmienne:

- t – zmienna czasowa (miesiące, kwartały),
- y_t – liczba transakcji,
- z_{1t} – produkcja sprzedana budownictwa (w mln zł),
- z_{2t} – produkcja sprzedana budownictwa – budowa budynków (w mln zł),
- z_{3t} – przeciętne miesięczne wynagrodzenie brutto (w zł),
- z_{4t} – przeciętne miesięczne wynagrodzenie brutto w budownictwie (w zł),
- z_{5t} – pracujący w sektorze przedsiębiorstw,
- z_{6t} – pracujący w budownictwie,
- z_{7t} – pracujący w budownictwie – budowa budynków,
- z_{8t} – przeciętne zatrudnienie w budownictwie,
- z_{9t} – sprzedaż detaliczna ogółem (w mln zł),
- z_{10t} – sprzedaż pojazdów samochodowych, motocykli, części (analogiczny okres roku poprzedniego = 100),
- z_{11t} – mieszkania oddane do użytkowania – budownictwo indywidualne,
- z_{12t} – mieszkania oddane do użytkowania – przeznaczone na sprzedaż lub wynajem,
- z_{13t} – stopa bezrobocia rejestrowanego (w %).

3. Koncepcja badania

W pierwszej kolejności analizie poddano kształtowanie się miesięcznej oraz kwartalnej liczby transakcji w rozpatrywanym okresie. W przypadku liczby transakcji zbadano występowanie trendu oraz sezonowości. W tym celu oszacowano model trendu liniowego ze stałą sezonowością (1) dla danych w postaci szeregów czasowych kwartalnych oraz miesięcznych [Zeliaś 1997, Judge i in. 1985]:

$$y_t = \delta_0 + \delta_1 t + \sum_{k=1}^m d_{0k} Q_{kt} + U_t, \quad (1)$$

gdzie:

- y_t – zmienna objaśniana,
- t – zmienna czasowa,
- δ_0, δ_1 – parametry trendu liniowego,
- m – liczba sezonów (4 dla danych kwartalnych, 12 dla danych miesięcznych),
- k – numer sezonu,
- Q_{kt} – zmienna zerojedynkowa (1 dla sezonu k , 0 dla pozostałych),
- d_{0k} – parametry sezonowe,
- U_t – składnik losowy.

W następnej kolejności wyznaczono współczynniki korelacji liniowej Pearsona pomiędzy miesięczną liczbą transakcji a potencjalnymi zmiennymi objaśniającymi z_{1t} – z_{13t} oraz ich opóźnieniami. Współczynniki te były podstawą do wyboru ostatecznych zmiennych objaśniających w liniowym modelu ekonometrycznym (2) [Maddala 2006, Johnston 1991]:

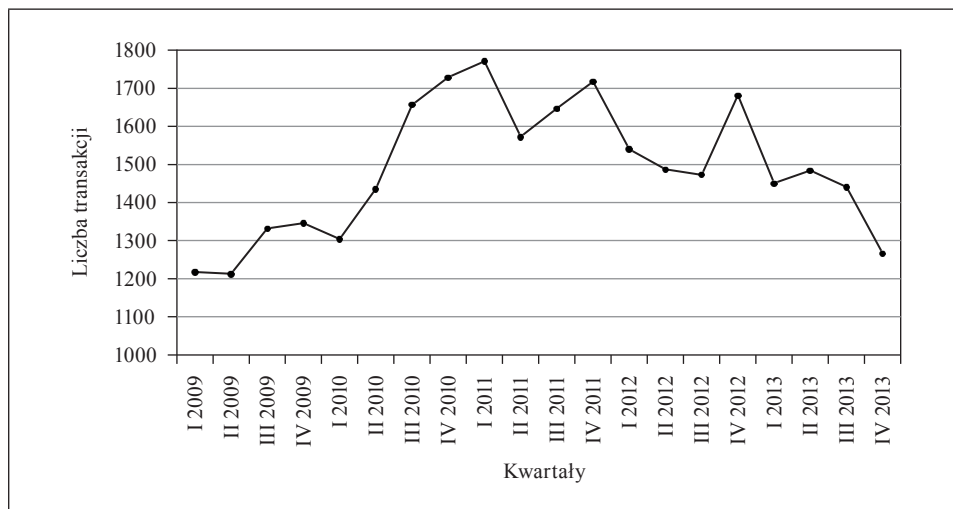
$$y_t = \alpha_0 + \sum_{i=1}^r \alpha_i X_{it} + U_t, \quad (2)$$

gdzie:

- y_t – zmienna objaśniana,
- X_{it} – i -ta zmienna objaśniająca,
- α_0, α_i – parametry strukturalne,
- r – liczba zmiennych objaśniających,
- U_t – składnik losowy.

4. Wyniki empiryczne

W pierwszej kolejności badaniu podlegała kwartalna liczba transakcji w województwie zachodniopomorskim. Kształtowanie się tej zmiennej w rozpatrywanym okresie przedstawiono na rys. 1.



Rys. 1. Liczba transakcji w poszczególnych kwartałach lat 2009–2013

Źródło: obliczenia własne na podstawie danych z aktów notarialnych.

Kwartalna liczba transakcji w okresie od I kwartału 2009 r. do II kwartału 2010 r. charakteryzowała się znacznie niższym poziomem niż w okresie od III kwartału 2010 r. do III kwartału 2013 r. Z tego też względu oszacowano model trendu liniowego ze stałą sezonowością (1) na podstawie danych tylko z drugiego okresu. Wyniki oszacowania zamieszczono w tabeli 1. Należy ponadto nadmienić, że w modelu nie został uwzględniony IV kwartał 2013 r., gdyż liczba transakcji w tym kwartale znacząco spadła i na chwilę obecną nie można rozstrzygnąć, czy jest to nowa tendencja, czy w kwartale tym nie zostały jeszcze uwzględnione wszystkie transakcje.

Tabela 1. Oszacowanie modelu trendu liniowego ze stałą sezonowością kwartalną

Zmienna	Liczba transakcji			
	Ocena parametru	Błąd standardowy	Statystyka t	Poziom p
Wyraz wolny	1847,701	63,564	29,068	0,000
t	-19,705	4,702	-4,1911	0,003
Q_{1t}	-4,208	- ^a	- ^a	- ^a
Q_{2t}	-57,170	31,219	-1,831	0,104
Q_{3t}	-37,042	28,114	-1,318	0,224
Q_{4t}	98,420	31,219	3,153	0,014
$R^2 = 0,811$, $F(4, 8) = 8,57$, $p = 0,005$, $DW = 2,868$ Błąd standardowy estymacji: 62,38				


^a parametr dla pierwszego kwartału został wyznaczony z warunku pobocznego, nie można zatem ocenić jego istotności.

Źródło: obliczenia własne.

Oszacowany model trendu liniowego ze stałą sezonowością kwartalną charakteryzuje się wysokim dopasowaniem do danych, przewagą wyjaśnionej wariacji zmiennej objaśnianej nad wariacją niewyjaśnioną oraz niskim błędem standardowym estymacji. Wartość statystyki Durbina-Watsona nie pozwala wnioskować o występowaniu bądź niewystępowaniu zjawiska autokorelacji, dlatego dodatkowo przeprowadzono test Breuscha-Godfrey [Wooldridge 2013]. Otrzymana wartość statystyki testowej nie daje podstaw do odrzucenia hipotezy o braku autokorelacji (poziom istotności 0,05). Kwartalna liczba transakcji w drugiej części badanego okresu charakteryzuje się malejącym trendem liniowym – parametr przy zmiennej czasowej t jest istotny (na poziomie istotności 0,05) oraz ujemny. Dla tej zmiennej występuje również sezonowość – parametr przy zmiennej Q_{4t} jest istotny (na poziomie istotności 0,05) oraz dodatni, co świadczy o zwiększonej liczbie transakcji zawieranych w czwartych kwartałach analizowanych lat. Ze względu na brak możliwości oszacowania modelu (1) w zapisanej

postaci, z modelu tego usuwa się jedną ze zmiennych zerojedynkowych. Zwykle jest to zmienna reprezentująca ostatni sezon. W przypadku liczby transakcji okazało się, że po usunięciu zmiennej zerojedynkowej reprezentującej ostatni sezon, parametry sezonowe nie były istotne. Zdecydowano się zatem na usunięcie z modelu zmiennej reprezentującej sezon pierwszy – ze względu na specyfikę rynku nieruchomości właśnie w końcu roku można było spodziewać się istotnego parametru sezonowego.

W drugiej kolejności badaniu podlegała miesięczna liczba transakcji w województwie zachodniopomorskim. Kształtowanie się tej zmiennej w rozpatrywanym okresie przedstawiono na rys. 2.



Rys. 2. Liczba transakcji w poszczególnych miesiącach lat 2009–2013

Źródło: obliczenia własne na podstawie danych z aktów notarialnych.

Miesięczna liczba transakcji w okresie od stycznia 2009 r. do czerwca 2010 r. charakteryzowała się znacznie niższym poziomem niż w okresie od lipca 2010 r. do listopada 2013 r. Z tego też względu podobnie jak w przypadku kwartalnej liczby transakcji model został oszacowany na podstawie danych z drugiego okresu. Należy ponadto nadmienić, że w modelu nie został uwzględniony grudzień 2013 r., gdyż liczba transakcji w tym miesiącu znacząco spadła i na chwilę obecną nie można rozstrzygnąć, czy jest to nowa tendencja, czy nie zostały jeszcze uwzględnione wszystkie transakcje w grudniu. Wyniki oszacowania zamieszczono w tabeli 2.

Tabela 2. Oszacowanie modelu trendu liniowego ze stałą sezonowością miesięczną

Zmienna	Liczba transakcji			
	Ocena parametru	Błąd standardowy	Statystyka t	Poziom p
Wyraz wolny	614,188	23,037	26,661	0,000
t	-2,204	0,565	-3,899	0,001
Q_{1t}	41,029	- ^a	- ^a	- ^a
Q_{2t}	-52,433	23,313	-2,249	0,033
Q_{3t}	7,438	23,306	0,319	0,752
Q_{4t}	-6,358	23,313	-0,273	0,787
Q_{5t}	-45,821	23,334	-1,964	0,060
Q_{6t}	-4,617	23,368	-0,198	0,845
Q_{7t}	-41,637	20,490	-2,032	0,052
Q_{8t}	-38,933	20,466	-1,902	0,067
Q_{9t}	43,771	20,458	2,139	0,041
Q_{10t}	83,475	20,466	4,079	0,000
Q_{11t}	-58,071	20,490	-2,834	0,008
Q_{12t}	72,159	23,368	3,088	0,005
$R^2 = 0,719$, $F(12, 28) = 5,97$, $p < 0,000$, $DW = 1,691$ Błąd standardowy estymacji: 42,36				


^a parametr dla pierwszego miesiąca został wyznaczony z warunku pobocznego, zatem nie można ocenić jego istotności.

Źródło: obliczenia własne.

Oszacowany model trendu liniowego ze stałą sezonowością miesięczną charakteryzuje się wysokim dopasowaniem do danych (choć niższym niż w przypadku danych kwartalnych), przewagą wyjaśnionej wariancji zmiennej objaśnianej nad wariancją niewyjaśnioną oraz niskim błędem standardowym estymacji. Podobnie jak w przypadku modelu dla danych kwartalnych wartość statystyki Durбина-Watsona nie pozwala wnioskować o występowaniu bądź niewystępowaniu zjawiska autokorelacji. Dla tego modelu również przeprowadzono test Breusch-Godfrey [Wooldridge 2013]. Otrzymana wartość statystyki testowej nie daje podstaw do odrzucenia hipotezy o braku autokorelacji (poziom istotności 0,05). Miesięczna liczba transakcji w drugiej części badanego okresu charakteryzuje się malejącym trendem liniowym – parametr przy zmiennej czasowej t jest istotny oraz ujemny. Dla tej zmiennej występuje także sezonowość – parametry przy zmiennych Q_{2t} , Q_{9t} , Q_{10t} , Q_{11t} , Q_{12t} są istotne (na poziomie istotności 0,05). Ze znaków istotnych parametrów sezonowych wynika, że w drugiej części badanego okresu liczba transakcji w lutym oraz w listopadzie kształtowała

się poniżej trendu, natomiast we wrześniu, październiku i grudniu – powyżej trendu. Podobnie jak w przypadku oszacowania modelu dla danych kwartalnych z modelu usunięto zmienną zerowejedynkową reprezentującą pierwszy sezon.

W kolejnej części badania obliczono najpierw współczynniki korelacji liniowej Pearsona pomiędzy liczbą transakcji a wybranymi zmiennymi ekonomicznymi oraz ich opóźnieniami (rys. 3).



Rys. 3. Współczynniki korelacji pomiędzy liczbą transakcji a zmiennymi ekonomicznymi oraz ich opóźnieniami

Źródło: obliczenia własne.

Dla większości analizowanych potencjalnych zmiennych objaśniających oraz ich opóźnień współczynniki korelacji mieściły się w przedziale od $-0,3$ do $0,4$. Wyjątkiem są zmienne: z_{6t} – pracujący w budownictwie oraz z_{8t} – przeciętne zatrudnienie w budownictwie przy małych opóźnieniach, z_{13t} – stopa bezrobocia rejestrowanego przy środkowych opóźnieniach, z_{4t} – przeciętne miesięczne wynagrodzenie brutto w budownictwie – przy dużych opóźnieniach, oraz z_{5t} – pracujący w sektorze przedsiębiorstw – dość silna korelacja ujemna przy dużych opóźnieniach.

Następnie oszacowano model liniowy zależności miesięcznej liczby transakcji od tych zmiennych, dla których oszacowany model charakteryzował się najlep-

szymi własnościami. Ostateczne zmienne objaśniające wybrano, kierując się obliczonymi współczynnikami korelacji oraz wspomagając je regresją krokową postępującą. Procedura postępowania była następująca: w pierwszej kolejności do modelu wybrano pierwszą zmienną objaśniającą z opóźnieniem, dla którego współczynnik korelacji ze zmienną objaśnianą był największy (było to opóźnienie 0), następnie dla drugiej zmiennej objaśniającej sprawdzono, czy poprawia się istotnie jakość modelu przy jej wprowadzaniu z kolejnymi opóźnieniami (dla każdego opóźnienia osobno), a dalsze postępowanie przeprowadzono dla kolejnych zmiennych objaśniających tak jak dla drugiej. Oszacowanie wybranego do prezentacji modelu zamieszczono w tabeli 3.

Tabela 3. Oszacowanie modelu liniowego dla miesięcznej liczby transakcji

Zmienna	Liczba transakcji			
	Ocena parametru	Błąd standardowy	Statystyka t	Poziom p
Wyraz wolny	1392,364	400,980	3,472	0,001
z_{1t}	0,136	0,029	4,769	0,000
z_{3t} – opóźnienie 3 miesiące	-0,009	0,003	-3,239	0,002
z_{9t} – opóźnienie 1 miesiąc	0,349	0,094	3,706	0,000
z_{12t} – opóźnienie 1 miesiąc	-0,083	0,022	-3,693	0,001
$R^2 = 0,519$, $F(4, 54) = 14,58$, $p < 0,000$, $DW = 1,616$ Błąd standardowy estymacji: 52,98				

Źródło: obliczenia własne na podstawie danych z aktów notarialnych.

W modelu zaprezentowanym w tabeli 3 zmienne objaśniające to: z_{1t} – produkcja sprzedana budownictwa (bez opóźnienia), z_{3t} – pracujący w sektorze przedsiębiorstw (opóźnienie 3 miesiące), z_{9t} – sprzedaż detaliczna ogółem (opóźnienie 1 miesiąc), z_{12t} – mieszkania oddane do użytkowania – przeznaczone na sprzedaż lub wynajem (opóźnienie 1 miesiąc). Wszystkie te zmienne charakteryzowały się istotnymi parametrami. Podobnie jak w przypadku modeli trendu z sezonowością wartość statystyki Durбина-Watsona nie pozwala wnioskować o występowaniu bądź niewystępowaniu zjawiska autokorelacji. Również dla tego modelu przeprowadzono test Breuscha-Godfrey'a [Wooldridge 2013]. Otrzymana wartość statystyki testowej nie daje podstaw do odrzucenia hipotezy o braku autokorelacji (poziom istotności 0,05). W celu wyeliminowania możliwości występowania regresji pozornej porównano wartość statystyki Durбина-Watsona ze współczynnikiem dopasowania R^2 . Okazało się, że wartość statystyki Durбина-Watsona (1,616) była znacznie wyższa niż współczynnik dopasowania R^2 (0,519). Taka zależność potwierdza brak występowania regresji pozornej [Koško, Osińska

i Stempińska 2007]. Dopasowanie modelu (najlepszego) na poziomie 0,519 jest raczej umiarkowane, pomimo tego, że oszacowany model charakteryzował się przewagą wariacji wyjaśnionej nad niewyjaśnioną oraz stosunkowo niskim błędem standardowym estymacji (współczynnik zmienności resztowej wyniósł tylko 10,7%).

5. Wnioski

W ujęciu kwartalnym liczba transakcji charakteryzowała się trendem liniowym oraz stałą sezonowością. W analizowanym okresie liczba transakcji spadała – oszacowany współczynnik trendu jest ujemny. W czwartym kwartale, w którym liczba transakcji wzrasta, składnik sezonowy jest istotny oraz dodatni.

W ujęciu miesięcznym liczba transakcji charakteryzowała się trendem liniowym oraz stałą sezonowością. W analizowanym okresie liczba transakcji spadała – oszacowany współczynnik trendu jest ujemny. Składniki sezonowe są istotne i ujemne w lutym i listopadzie, natomiast istotne i dodatnie – we wrześniu, październiku i grudniu.

Współczynniki korelacji pomiędzy liczbą transakcji a zmiennymi ekonomicznymi oraz ich opóźnieniami w większości przypadków mieszczą się w przedziale $(-0,2; 0,4)$, co oznacza słabą zależność.

Do wyboru zmiennych objaśniających wykorzystano procedurę regresji krokowej (postępującej). W efekcie do modelu jako zmienne objaśniające weszły: produkcja sprzedana budownictwa (bez opóźnienia), pracujący w sektorze przedsiębiorstw (opóźnienie 3 miesiące), sprzedaż detaliczna ogółem (opóźnienie 1 miesiąc) oraz mieszkania oddane do użytkowania – przeznaczone na sprzedaż lub wynajem (opóźnienie 1 miesiąc). Mimo iż parametry stojące przy zmiennych okazały się istotne, dopasowanie modelu nie jest zbyt wysokie, co może oznaczać, że z otoczenia gospodarczego nie płyną jednoznaczne sygnały mające wpływ na liczbę zawieranych umów kupna-sprzedaży.

Tendencje w zakresie liczby transakcji zawartych na terenie województwa zachodniopomorskiego potwierdzają specyfikę rynku mieszkaniowego na tle całego rynku nieruchomości. Na rynku mieszkaniowym niezaspokojone potrzeby powodują odmienne, nie zawsze skorelowane z sytuacją gospodarczą, zachowania kupujących.

Literatura

- Batóg B., Foryś I. [2011], *Modele logitowe w analizie transakcji na warszawskim rynku mieszkaniowym*, „Studia i Materiały Towarzystwa Naukowego Nieruchomości”, vol. 19, nr 3.
- Batóg B., Foryś I. [2013], *Zastosowanie modeli zmiennych jakościowych do badania wpływu cech mieszkań na cenę rynkową kwalifikującą je do finansowania w programie „Rodzina na swoim”*, „Wiadomości Statystyczne”, nr 5.
- Foryś I. [2011], *Spoleczno-gospodarcze determinanty rozwoju rynku mieszkaniowego w Polsce. Ujęcie ilościowe*, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin.
- Johnston J. [1991], *Econometric Methods*, McGraw-Hill Book Company, New York.
- Judge G.G., Griffiths W.E., Hill R.C., Lutkepohl H., Lee T.-C. [1985], *The Theory and Practice of Econometrics*, John Wiley and Sons, New York.
- Kośko M., Osińska M., Stempińska J. [2007], *Ekonometria współczesna*, Wydawnictwo „Dom Organizatora”, Toruń.
- Maddala G.S. [2006], *Ekonometria*, Wydawnictwo Naukowe PWN, Warszawa.
- Wooldridge J.M. [2013], *Introductory Econometrics. A Modern Approach*, South-Western, Mason.
- Zeliaś A. [1997], *Teoria prognozy*, PWE, Warszawa.

Modeling the Activity of Apartment Buyers on the Zachodniopomorskie Voivodship Market

(Abstract)

The activity of participants on the housing market is related to the economic situation of the households, which itself is related to the overall business climate. The tendency for activity on the housing market to weaken during economic recession is not the same on different local markets. The aim of the paper is to analyse the intensity of the purchase-sale transactions during different business cycles in the West Pomeranian voivodship. The research includes analysis of the number of transactions in time, split into different business cycles or different seasons. The dependency of the number of purchase-sale transactions on the housing market and economic variables such as household income, sales revenue, retail sales and the unemployment rate is also analysed. The econometric models with lagged variables and time series models with seasonality are also applied. The data concerning transactions come from the real estate price and value registers from the District Governor's Office, the National Bank of Poland and the Central Statistical Office.

Keywords: real estate market, number of transactions, econometric models, time series models with seasonality.

Justyna Brzezińska

Department of Economic and Financial Analysis
University of Economics in Katowice

The Problem of Zero Cells in the Analysis of Contingency Tables*

Abstract

Log-linear analysis is a statistical tool used to analyse the independence of categorical data in contingency tables. With this method, any number of nominal or ordinal variables can be analysed: interactions can be included in the model, various types of association can be analysed, and the analysis provides a formal model equation. Although log-linear analysis is a versatile statistical method, there are some limitations in using it due to zero cells. Zero cells in contingency table are of two types: fixed (structural) and sampling zeros. Fixed zeros occur when it is impossible to observe values for certain combinations of the variable. Sampling zeros are due to sampling variations and the relatively small size of the sample when compared with a large number of cells.

In the paper several options will be presented for how to deal with zero cells in a table. All calculations will be conducted in **R**.

Keywords: zero cell, categorical data analysis, contingency tables, log-linear analysis.

1. Introduction

The analysis of discrete multivariate data, especially in the form of cross-classification, has occupied a prominent place in multivariate statistical analysis.

* The article was written for a project financed by a National Science Centre grant based on decision DEC-2012/05/N/HS4/00174.

A variety of data from the social, medical, psychological and biological sciences come in the form of cross-classified table counts, commonly referred to as contingency tables. A two- or multi-way table gives the observed counts simultaneously for the categories of two- or more categorical variables.

One of the most useful and powerful methods for analysing qualitative data is log-linear analysis. This method enables examination of the relationship between categorical data. It includes the analysis of multi-way tables where the dimensionality of the table refers to the number of variables. And it is an appropriate modelling method concerning multi-way tables, including interactions which are useful in identifying. In log-linear analysis, the expected value of observation is given by a linear combination of a number of parameters. Maximum likelihood method is used to estimate the parameters, and the estimated parameter values may then be used in identifying which variables are of greatest importance in predicting the observed values (Everitt 1977). This method has a variety of advantages and can give more complex and detailed information about data structure and association type. Log-linear analysis can be used for nominal as well as ordinal variables, and it provides a variety of models describing the association path (Brzezińska 2015).

Categorical data are usually described in contingency tables (cross-table), and can be split into two parts in the table:

- 1) the fully classified cases where information on all the categories is available (complete tables),
- 2) the partially classified cases where information on some of the categories is zero (zero cell tables).

Zero cells may cause some problems with further categorical data analysis (Fienberg 1980, Andersen 1997, Smirnov 2003).

In this paper I present an analysis of contingency tables with zero cells. All calculations are done in **R**.

2. Contingency Tables Containing Zero Cells

A contingency table is incomplete if one or more cells have a zero count. We distinguish between sampling (random) and structural (fixed) zeros.

Sampling zeros are due to sampling variation and the relatively small size of the sample when compared to the large number of cells. These zeros disappear when the sample size is increased sufficiently. Sampling zeros occur when there is no observation in the cell, i.e. $n_{hj} = 0$, but probabilistically there is a chance of observing this value and the probability of observation in a cell is $\pi_{hj} > 0$. Increasing the sample size might yield the result $n_{hj} > 0$. Sampling zeros typically correspond to small expected counts, however, so they can indicate that the usual

asymptotic approximations for goodness-of-fit tests, tests of significance, etc., might not be valid.

Structural zeros occur when it is impossible to observe values for a certain combination of the variable, i.e. $n_{hj} = 0$ and $\pi_{hj} = 0$. Tables with structural zeros are structurally incomplete and they are known as incomplete tables. Such cases are different from those in which it is not possible to completely cross-classify all individuals or units. When we deal with tables containing structural zeros, the cells cannot be filled in with zeros, nor can the table be collapsed until there are no zeros in the table, nor can the analysis simply be abandoned.

3. Multi-way Frequency Analysis for Contingency Tables with Zero Cells

Correspondence analysis is a method applicable for analyses of contingency tables to analyse the relations between two or more categorical variables (Greenacre 1984). The method is performed in three steps. The first is to calculate the categorical profiles (i.e., the relative frequencies) and masses (marginal proportions). The next is to compute the chi-square distances between the points and find the n -dimensional space that best fits the points (Clausen 1998). The graphical representation of correspondence analysis is usually presented in a perception map. Because correspondence analysis is so widely known, details of its use are not presented here – only an application for zero-cell tables is shown in comparison to log-linear analysis.

Log-linear analysis is a standard tool for analysing the path of association between nominal or ordinal variables in a multi-way contingency table. The criteria to be analysed are the expected cell frequencies m_{hjk} represented as a function of all variables in the survey. There are several types of log-linear models related to several types of association, depending on the number of variables and interactions included. Models are built with the hierarchy principle saying that a parameter of lower order cannot be removed when there is still a parameter of higher order that concerns at least one of the same variable.

The goodness of fit of a log-linear model for a two-way table is tested using the Pearson's chi-square statistic or the likelihood ratio statistic:

$$G^2 = 2 \sum_{h=1}^H \sum_{j=1}^J n_{hj} \ln \left(\frac{n_{hj}}{m_{hj}} \right). \tag{1}$$

Therefore, larger G^2 values indicate that the model does not fit the data well and thus it should be rejected. In order to find the best model from a set of possible models, additional measures should be considered (determination coef-

ficients, information criteria). It is also advisable to compute G^2/df where a value close to 1 indicates a model that fits well.

The Akaike Information Criterion AIC is based on information theory, but a heuristic way to think about it is a criterion that seeks a model that has a good fit to the truth but few parameters. The chosen model is the one that minimises the Kullback-Leibler distance between the model and the truth. Akaike information criterion refers to the information contained in a statistical model according to the equation (Akaike 1973):

$$AIC = G^2 - 2df, \quad (2)$$

where df is the residual degrees of freedom.

Another information measurement is Bayesian information criterion (Raftery 1986):

$$BIC = G^2 - df \cdot \ln n, \quad (3)$$

where n is the total sample size.

The model that minimises AIC and BIC will be chosen. A rule of thumb to determine the degrees of freedom for the table without zeros is $df = \text{number of cells} - \text{number of free parameters}$. In order to test the goodness of fit of a model that uses an observed set of marginal totals with at least one zero entry, we must reduce the degrees of freedom associated with the statistic. This is because if an observed margin entry is zero, both expected and the observed entries for all cells is known to be perfect once it is observed that the marginal entry is zero. As a result, we must delete those degrees of freedom associated with the fit of the zero cell values. A general formula for computing degrees of freedom in cases where some of the margins fitted contain sampling zeros is the following (Fienberg 1980):

$$df = (T_e - Z_e) - (T_p - Z_p), \quad (4)$$

where:

- T_e – the number of cells in the table that are being fitted,
- T_p – the number of parameters fitted by model,
- Z_e – the number of cells containing zero estimated expected values,
- Z_p – the number of parameters that cannot be estimated because of zero marginal totals.

Log-linear analysis is a widely known statistical method used to analyse categorical data in contingency tables. Although log-linear models are versatile statistical models, there are some limitations in using them, largely due to zero cells that may arise in the contingency table. There are two consequences of the zero cells problem. First, we cannot include many variables in the analysis. This is related to the second consequence: eventual collapsing of the variables in

order to avoid zero cells in the table, which may distort the process being modeled and may result in a loss of some valuable data. Also, odds and odds ratios are undefined with zeros in the denominator (Ishii-Kuntz 1994).

Other than collapsing variable categories, several options are available for analysing a table with zero cells:

1) add a small value (0.5 is frequently suggested) to every cell in the table when fitting the saturated model (Goodman 1970),

2) add a small quantity (such as 0.2) only to zero cells (Evers & Namboodiri 1977),

3) add the value $\frac{1}{r}$ to zero cells, where r equals the number of response categories (Grizzle, Starmer & Koch 1969),

4) arbitrarily define zero divided by zero to be zero (Fienberg 1980),

5) increase the sample size sufficiently to remove all zero cells (Knoke & Burke 1980),

6) replace sampling zeros by 0.1×10^{-8} , or a smaller number and then check results against those obtained without such an adjustment (Clogg & Eliason 1988).

Technically, sampling and structural zeros are treated in the same way. The reason is that in any test statistic, a term corresponding to a cell with a zero count will cancel out. Only for the saturated model is it necessary that the table be complete with no zeros (Smirnov 2003). Researchers need to consider carefully the limitations of log-linear models in order to analyse the categorical data in the table effectively.

A comparison of these approaches in log-linear analysis for a contingency table containing zeros will be presented.

4. Application in R

Data come from the Central Statistical Office of Poland, from the Local Data Bank, and show the number of individuals fatally injured in accidents at work in the first three quarters of 2013. A two-dimensional contingency table for 2 variables was worked out and analysed:

1) *Voivodeship* (1. Dolnośląskie, 2. Kujawsko-pomorskie, 3. Lubelskie, 4. Lubuskie, 5. Łódzkie, 6. Małopolskie, 7. Mazowieckie, 8. Opolskie, 9. Podkarpackie, 10. Podlaskie, 11. Pomorskie, 12. Śląskie, 13. Świętokrzyskie, 14. Warmińsko-mazurskie, 15. Wielkopolskie, 16. Zachodniopomorskie),

2) *Cause of the accident* (1. Electricity, 2. Explosion, fire, 3. Ignition, 4. Material slipping and falling or collapsing on the person, 5. The person slipping and falling).

Out of 80 cells (16×5), 48 cells contain zeros. The sample size is 55.

Now we compare some options of transformation for dealing with zero cells in log-linear analysis. As the saturated model should be built only for non-zero cells, this model will not be analysed. The effects of zero cell action for the independence model [*Voivodeship*][*Cause*] are presented in table 1.

Table 1. Adjustment and Goodness of Fit Criteria for a Two-way Zero-cells Table

Adjustment	G^2	df	G^2/df	AIC	BIC
No adjustment for zeros	47.380	60	0.790	-72.620	-193.060
$n \rightarrow n + 0.5$	21.331	60	0.356	-98.669	-219.109
$n = 0 \rightarrow n + 0.2$	21.331	60	0.356	-98.669	-219.109
$n = 0 \rightarrow n = 0.1 \times 10^{-8}$	21.331	60	0.356	-98.669	-219.109

Source: the author's own calculations in **R** based on data from the Central Statistical Office (www.stat.gov.pl).

The goodness of fit statistics for no adjustment seem to be the best for the independence model. The comparison for other transformations shows that the result for the adjustments conducted is the same and no significant differences are seen.

The second example is based on data `Titanic{datasets}` summarised in a four-way table. Data provides information on the fate of passengers on the fatal maiden voyage of the ocean liner Titanic summarised according to the variables *Class*, *Sex*, *Age* and *Survival*. Out of 32 cells ($4 \times 2 \times 2 \times 2$), 8 cells are zeros. The sample size is 2201.

The effects of zero cell action for the independence model [*Class*][*Sex*][*Age*][*Survived*] are summarised in Table 2.

Table 2. Adjustment and Goodness of Fit Criteria for the [*Class*][*Sex*][*Age*][*Survived*] Model

Adjustment	G^2	df	G^2/df	AIC	BIC
No adjustment for zeros	1243.663	25	49.747	1193.663	1051.246
$n \rightarrow n + 0.5$	1216.387	25	48.655	1166.387	1023.970
$n = 0 \rightarrow n + 0.2$	1229.594	25	49.184	1179.594	1037.177
$n = 0 \rightarrow n = 0.1 \times 10^{-8}$	1243.663	25	49.747	1193.663	1051.246

Source: the author's own calculations in **R**.

Table 2 shows that the best transformation for zero cells is adding 0.5 to all cells. The likelihood criteria, as well as information criteria, are minimal for

this adjustment, and G^2/df is closest to 1. These results show that the best fit is obtained for the adjustment where we add 0.5 to each cell in the table.

As the interaction between *Class* and *Survived* seems to be interesting, the second model tested is the conditional association model [*ClassSurvived*][*Sex*][*Age*]. The goodness of fit statistics are summarised in Table 3.

Table 3. Adjustment and Goodness of Fit Criteria for the [*ClassSurvived*][*Sex*][*Age*] Model

Adjustment	G^2	df	G^2/df	<i>AIC</i>	<i>BIC</i>
No adjustment for zeros	1062.762	22	48.307	1018.762	893.435
$n \rightarrow n + 0.5$	1036.113	22	47.096	992.113	866.786
$n = 0 \rightarrow n + 0.2$	1049.425	22	47.701	1005.425	880.098
$n = 0 \rightarrow n = 0.1 \times 10^{-8}$	1062.762	22	48.307	1018.762	893.435

Source: the author’s own calculations in **R**.

The result is the same as for the previous model. The best fit is obtained for the adjustment where 0.5 is added to each cell.

As the interaction between *Class*, *Sex* and *Survived* is interesting, the next model tested is the conditional association model [*ClassSurvivedSex*][*Age*]. The goodness of fit statistics are summarised in Table 4.

Table 4. Adjustment and Goodness-of-fit Criteria for the [*ClassSurvivedSex*][*Age*] Model

Adjustment	G^2	df	G^2/df	<i>AIC</i>	<i>BIC</i>
No adjustment for zeros	225.338	15	15.023	195.338	109.888
$n \rightarrow n + 0.5$	210.616	15	14.041	180.616	95.166
$n = 0 \rightarrow n + 0.2$	214.707	15	14.314	184.707	99.257
$n = 0 \rightarrow n = 0.1 \times 10^{-8}$	225.338	15	15.023	195.338	109.888

Source: the author’s own calculations in **R**.

Table 4 shows a similar result: the best fit is obtained for the adjustment where we add 0.5 to each cell.

The results presented in Tables 2, 3 and 4 prove that the best transformation of the zero cell in a multi-way table is obtained when we add 0.5 to each cell. The other adjustments are not significantly worse and the difference in the fit is not large.

The differences between the presented adjustments for a two- and four-way table are not significantly different and the results obtained may not be general-

ised, as some of them show only very little improvement. However, for the four-way table, adding 0.5 to each cell in the table leads to the best fitting model.

5. Visualising Categorical Data

There are many techniques and methods for visualising categorical data in contingency tables. They may be defined as a recursive generalisation of bar charts. This visualisation in log-linear analysis is possible with the use of mosaic plot and association plot. Both are available in **R** in the `vcd` package (*visualising categorical data*), which was developed by *Visualising Categorical Data* (Friendly 1991, 2000; Cohen 1980). There are not many publications on visualising categorical data in the Polish literature (Brzezińska 2013).

Visualisation graphically brings out the departure of an observed table from the expected table. Mosaic plot is one of the most popular and useful methods for log-linear modelling, which generalises readily to multi-way tables. Friendly (2000) extended the use of mosaic plots for fitting log-linear models. A mosaic represents each cell of a table with a rectangle (or tile) whose area is proportional to the cell count. The mosaic is constructed by dividing a unit square vertically by one variable, then horizontally by the other. Further variables are introduced by recursively subdividing each tile by the conditional proportions of the categories of the next variable in each cell, alternating between the vertical and horizontal dimensions of the display. The mosaic plot shows that the difference between observed and expected cell counts are small and all Pearson's residuals

$(d_{hj} = \frac{n_{hj} - m_{hj}}{\sqrt{m_{hj}}})$ are $|d_{hj}| < 2$ and the fit of the model is good. Visualising log-linear

models in mosaic plot in **R** is possible with the use of the `mosaic{vcd}` function (Brzezińska 2014).

Mosaic plots are presented for different adjustments of zero cells for the independence model [*Voivodeship*][*Cause*] (Figures 1–4). Voivodeship names are coded from 1 to 16, according to the notation in the beginning of Section 4.

The result of the mosaic plots is very similar for every adjustment except the first one. The largest departure of an observed cell from a theoretical one exists in Fig. 1, in the cell for the Zachodniopomorskie region for the cause of the accident: explosion or fire. The other plots (Figures 2, 3 and 4) do not show significant departures between observed and expected cell counts and they indicated that the fit of those models is very good. Similar results occur for the tables of higher dimensions for the second dataset.

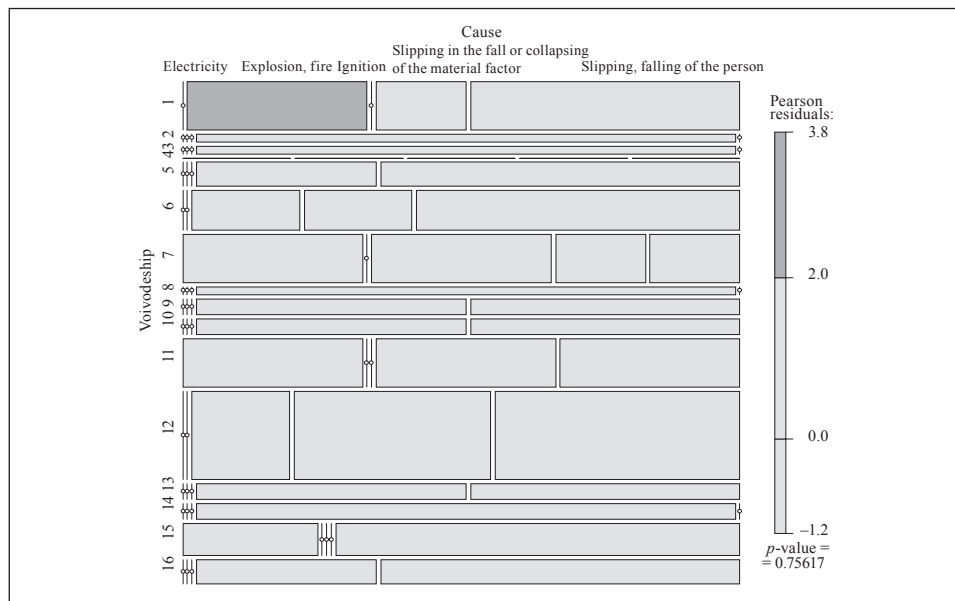


Fig. 1. Mosaic Plot for the Independence Model for No Adjustment of the Zero Cell
Source: the author's own calculations in **R**.

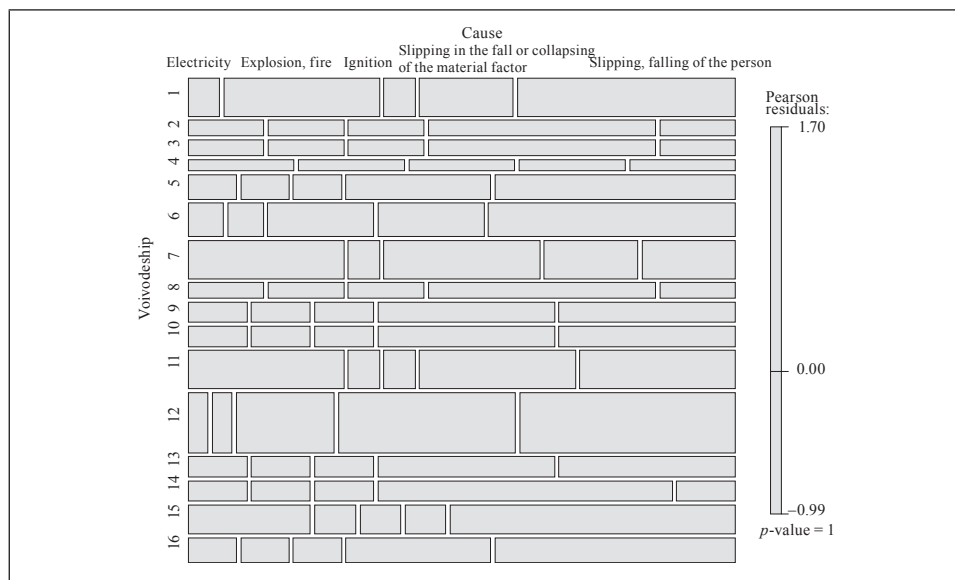


Fig. 2. Mosaic Plot for the Independence Model for Adjustment $n \rightarrow n + 0.5$
Source: the author's own calculations in **R**.

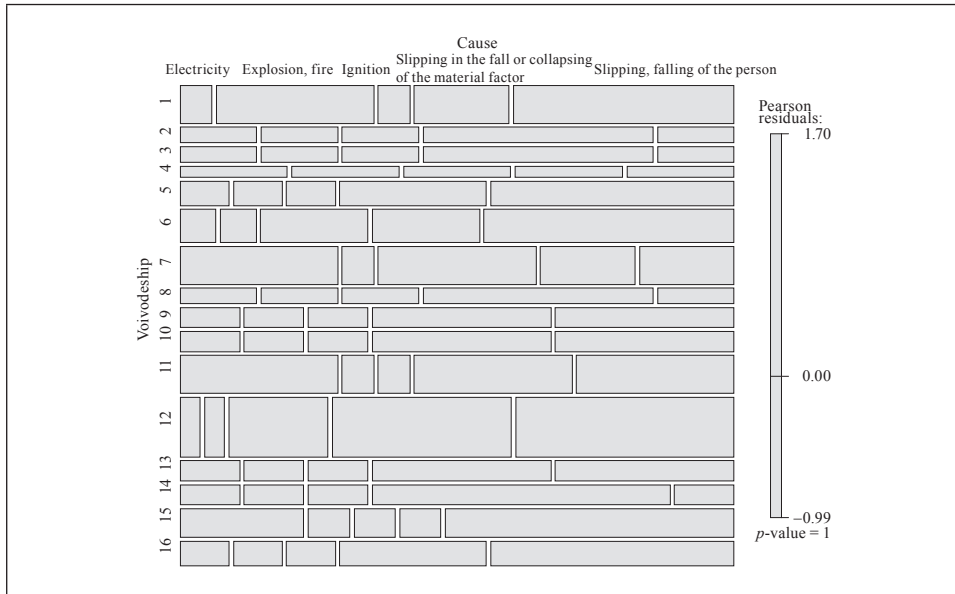


Fig. 3. Mosaic Plot for the Independence Model for Adjustment $n = 0 \rightarrow n + 0.2$

Source: the author's own calculations in **R**.

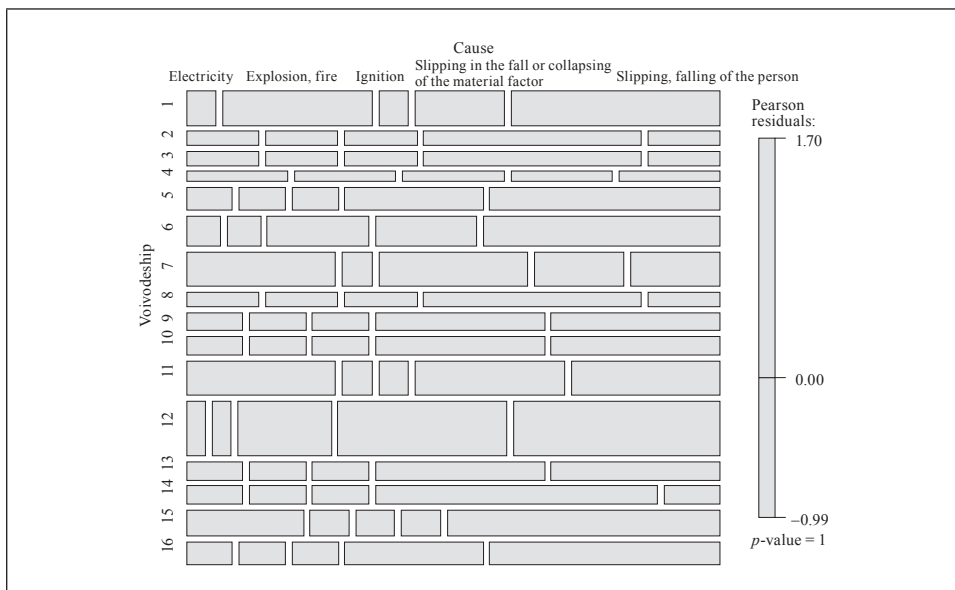


Fig. 4. Mosaic Plot for the Independence Model for Adjustment $n = 0 \rightarrow n = 0.1 \times 10^{-8}$

Source: the author's own calculations in **R**.

6. Conclusions

Log-linear models are a standard tool used to analyse structures of dependency in multi-way contingency tables. The criteria to be analysed are the expected cell frequencies in the table as a function of all the variables in the survey. The analysis of such a table may be troublesome when some cells are zeros. For log-linear models, most of the derivations of expected frequencies and other quantities assume $n_{hj} > 0$; however, in research we may have tables containing zeros. Zero frequencies may occur in a contingency table for two reasons: sampling and structural zeros. To avoid this problem, steps must be taken.

A mosaic plot graph represents a contingency table, with each cell corresponding to a piece of the plot, the size of which is proportional to the cell entry. Extended mosaic displays show the standardised residuals of a log-linear model of the counts by the colour and outline of the mosaic's tiles (standardised residuals are often referred to as standard normal distribution). Negative residuals are drawn in shades of red and with broken outlines; positive ones are rendered in blue with solid outlines. Thus, mosaic plots are perfect to visualise associations within a table and to detect cells which create dependencies. The association plot puts deviations from independence in the foreground: the area of each box is made proportional to the observed – expected frequency. Both log-linear analysis and visualising categorical data tools are a useful and practical tool that help to analyse the independence between the categorical data in a contingency table.

In this paper some solutions for zero-cell frequencies are presented. For two- and four-way tables, different solutions are compared with the use of likelihood statistics and information criteria (*AIC*, *BIC*). Visualising tools with the use of mosaic plots for contingency tables with zero cells have also been presented. This analysis may be helpful in looking for the best solution in the analysis of high dimensional tables.

Bibliography

- Akaike H. (1973), *Information Theory and an Extension of the Maximum Likelihood Principle*, Proceedings of the 2nd International Symposium on Information, Budapest.
- Andersen E. B. (1997), *Introduction to the Statistical Analysis of Categorical Data*, New York, Springer.
- Brzezińska J. (2013), *Metody wizualizacji danych jakościowych w programie R*, Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu, 279, Klasyfikacja i analiza danych – teoria i zastosowania, 21: 182–190.
- Brzezińska J. (2014), *Visual Models for Categorical Data in Economic Research*, M. Spiliopoulou, L. Schmids-Thieme, R. Janning (eds), Studies in Classification,

- Data Analysis, and Knowledge Organization: Data Analysis, Machine Learning and Knowledge Discovery, Springer: 33–40.
- Brzezińska J. (2015), *Analiza logarytmiczno-liniowa. Teoria i zastosowania z wykorzystaniem programu R*, C.H. Beck, Warszawa.
- Clausen S. E. (1998), *Applied Correspondence Analysis. An Introduction*, Sage Publications, Thousand Oaks.
- Clogg C. C., Eliason S. R. (1988), *Some Common Problems in Log-linear Analysis* (in:) J. S. Long (ed.), *Common Problems/Proper Solutions*, Sage, Newbury Park, CA.
- Cohen A. (1980), *On the Graphical Display of the Significant Components in a Two-way Contingency Table*, “Communications in Statistics – Theory and Methods”, 9(10): 1025–1041, <http://dx.doi.org/10.1080/03610928008827940>.
- Everitt B. (1977), *The Analysis of Contingency Tables*, Chapman and Hall, London.
- Evers M., Namboodiri N. K. (1977), *A Monte Carlo Assessment of the Stability of Log-linear Estimates in Small Samples*, Proceedings of the American Statistical Association, Social Statistics Section, American Statistical Association, Washington, DC.
- Fienberg S. E. (1980), *The Analysis of Cross-classified Categorical Data*, MIT Press, Cambridge.
- Friendly M. (1991), *The SAS System for Statistical Graphics*, SAS Institute Inc., Carry, NC.
- Friendly M. (2000), *Visualizing Categorical Data*, SAS Institute Inc., Carry, NC.
- Goodman L. A. (1970), *The Multivariate Analysis of Qualitative Data: Interaction among Multiple Classifications*, “Journal of the American Statistical Association”, 65(329): 226–256, <http://dx.doi.org/10.1080/01621459.1970.10481076>.
- Greenacre M. J. (1984), *Theory and Applications of Correspondence Analysis*, Academic Press, London.
- Grizzle J. E., Starmer C. F., Koch G. C. (1969), *Analysis of Categorical Data by Linear Models*, “Biometrics”, 25(3): 489–504, <http://dx.doi.org/10.2307/2528901>.
- Ishii-Kunts M. (1994), *Ordinal Log-linear Models*, Sage University Paper Series on Quantitative Applications in the Social Science, series no. 07-097, Sage, Beverly Hills–London.
- Knoke D., Burke P. J. (1980), *Log-linear Models*, Sage University Paper Series on Quantitative Applications in the Social Science, series no. 07-020, Sage, Beverly Hills–London.
- Raftery A. E. (1986), *Choosing Models for Cross-classification*, “American Sociological Review”, 51: 145–146.
- Smirnoff J. S. (2003), *Analyzing Categorical Data*, Springer Texts in Statistics, Springer, New York.
- Snee R. D. (1974), *Graphical Display of Two-way Contingency Tables*, “The American Statistician”, 28(1): 9–12, <http://dx.doi.org/10.2307/2683520>.

Problem zerowych liczebności w analizie tablic kontyngencji

(Streszczenie)

Analiza logarytmiczno-liniowa jest metodą badania zależności pomiędzy zmiennymi niemetrycznymi w tablicy kontyngencji, która pozwala analizować dowolną liczbę zmiennych nominalnych i porządkowych. Pomimo że jest ona uniwersalną metodą

analizy zmiennych niemetrycznych, występują jednak pewne ograniczenia w jej stosowaniu ze względu na zerowe liczebności. Zera występujące w tablicy mogą być dwójakiego rodzaju: strukturalne lub związane ze schematem losowania. Zera strukturalne pojawiają się wtedy, gdy nie jest możliwa obserwacja kategorii zmiennej, a zera związane ze schematem losowania występują w małych próbach i znikają, gdy próba zostanie odpowiednio zwiększona.

W artykule zaprezentowano sposoby radzenia sobie z zerowymi liczebnościami w tablicy kontyngencji. Wszystkie obliczenia przeprowadzono w programie **R**.

Słowa kluczowe: zerowe liczebności, analiza danych jakościowych, tablice kontyngencji, analiza logarytmiczno-liniowa.

Katarzyna Frodyma

Katedra Statystyki

Uniwersytet Ekonomiczny w Krakowie

Rynek energii ze źródeł odnawialnych w Unii Europejskiej – analiza statystyczna

Streszczenie

Dynamiczny rozwój cywilizacyjny wiąże się z rosnącym zapotrzebowaniem na energię. Wykorzystywanie tradycyjnych źródeł energii, takich jak węgiel, ropa naftowa i gaz ziemny, wiąże się nie tylko ze wzrostem zanieczyszczenia środowiska, ale powoduje także wyczerpywanie się zasobów naturalnych. Alternatywę dla nieodnawialnych nośników energii, jakimi są paliwa kopalniane, stanowią odnawialne źródła energii.

Głównym celem artykułu jest ocena zmian zachodzących na rynku energii ze źródeł odnawialnych w Unii Europejskiej. Na podstawie tych dostępnych danych przeprowadzono liniowe uporządkowanie krajów ze względu na udział energii ze źródeł odnawialnych w produkcji energii elektrycznej. Omówione zostały zmiany w strukturze produkcji energii ze źródeł odnawialnych. Kraje podzielono na grupy ze względu na strukturę produkcji energii ze źródeł odnawialnych.

Słowa kluczowe: energia ze źródeł odnawialnych, porządkowanie liniowe, grupowanie, współczynnik tau-Kendalla, miara Randa.

1. Wprowadzenie

Dynamiczny rozwój cywilizacyjny, który obecnie ma miejsce, wiąże się z rosnącym zapotrzebowaniem na energię. Wykorzystywanie tradycyjnych źródeł energii, takich jak węgiel, ropa naftowa i gaz ziemny, związane jest nie tylko ze wzrostem zanieczyszczenia środowiska, ale powoduje także wyczerpywanie się

zasobów naturalnych. Alternatywę dla nieodnawialnych nośników energii, jakimi są paliwa kopalniane, stanowią odnawialne źródła energii. Statystyka dotycząca energii jest w centrum zainteresowania ze względu na jej strategiczne znaczenie dla zrównoważonego rozwoju gospodarczego. W ostatnich latach w Unii Europejskiej rozważanych jest kilka ważnych kwestii związanych z energią, takich jak zmienność cen ropy, przerwy w dostawie energii z krajów nienależących do Unii Europejskiej oraz trudności w dostępie do rynku dla dostawców w przypadku gazu i energii elektrycznej. Kwestie te sprawiły, że temat energii stał się jednym z głównych tematów politycznych w krajach europejskich, zaś wykorzystanie odnawialnych źródeł energii jest postrzegane jako kluczowy element polityki energetycznej. W 2009 r. przyjęto pakiet znany jako cel 20-20-20 [Dyrektywa 2009/28/WE z dnia 23 kwietnia 2009 r. ...]. W pakiecie klimatyczno-energetycznym zawarte są następujące cele na rok 2020:

- redukcja emisji gazów cieplarnianych w UE o co najmniej 20% poniżej poziomu z 1990 r.;
- co najmniej 20% końcowego zużycia energii brutto w UE ma pochodzić z odnawialnych źródeł energii;
- co najmniej 10% końcowego zużycia energii transportowych w UE ma pochodzić z odnawialnych źródeł energii;
- zmniejszenie o 20% zużycia energii pierwotnej w porównaniu z przewidywanymi poziomami; zmniejszenie to ma zostać osiągnięte poprzez poprawę efektywności energetycznej.

Głównym celem badania jest ocena zmian zachodzących na rynku energii ze źródeł odnawialnych w Unii Europejskiej. W niniejszym artykule kraje Unii Europejskiej uporządkowane zostały ze względu na udział energii odnawialnej w produkcji energii elektrycznej. Na podstawie współczynnika tau-Kendalla potwierdzona została hipoteza, że uporządkowania te nie ulegały istotnym zmianom w latach 2004–2012. Następnie państwa Unii Europejskiej pogrupowane zostały ze względu na strukturę produkcji energii elektrycznej z poszczególnych nośników odnawialnych źródeł energii. Grupowanie to przeprowadzone zostało metodą Warda z wykorzystaniem odległości euklidesowej. W celu potwierdzenia hipotezy badawczej, zgodnie z którą wyniki grupowania w latach 2004–2012 nie różnią się między sobą, wykorzystano klasyczną miarę Randa podobieństwa składów klas.

Głównym źródłem danych jest opracowanie Głównego Urzędu Statystycznego *Energia ze źródeł odnawialnych w 2012 r.* [2013] oraz strona internetowa Eurostatu (<http://epp.eurostat.ec.europa.eu>, dostęp: 20.04.2014 r.). Wiele artykułów związanych z energią odnawialną znaleźć można w miesięczniku „Energetyka” – m.in. *Kierunki polityki energetycznej Polski oraz Unii Europejskiej w latach 2007–2030* [Karpieńska i Dul 2014], *Energetyka wiatrowa. Aktualne*

trendy rozwoju w Polsce [Badyda 2013] czy *Rozproszone źródła energii elektrycznej ze szczególnym uwzględnieniem odnawialnych źródeł energii* [Czechowicz 2012]. Informacje o nośnikach energii ze źródeł odnawialnych w Polsce i Unii Europejskiej w latach wcześniejszych prezentuje m.in. artykuł *Wykorzystanie odnawialnych i nieodnawialnych źródeł energii w Polsce i w krajach UE* [Sadowski, Świdorski i Lewandowski 2008], zaś *Energia odnawialna w Polsce w 2012* [2012] to raport przygotowany przez portal Gramzielone.pl dotyczący nośników energii w Polsce.

2. Udział energii odnawialnej w końcowym zużyciu energii w latach 2004–2012

W tabeli 1 zaprezentowano całkowite zużycie energii w tys. ton w przeliczeniu na 1000 mieszkańców w poszczególnych krajach Unii Europejskiej w latach 2004–2012. Największe zużycie energii w przeliczeniu na 1000 mieszkańców odnotowano w Luksemburgu, najmniejsze zaś w Rumunii. Wzrost zużycia w badanym okresie nastąpił tylko w Estonii, na Łotwie i w Polsce. Największy spadek zużycia zaobserwowano m.in. na Cyprze, w Irlandii oraz w Wielkiej Brytanii. W takich krajach jak Austria i Bułgaria w badanym okresie zużycie energii pozostało na niezmiennym poziomie.


Tabela 1. Zużycie energii w tys. ton w przeliczeniu na 1000 mieszkańców w latach 2004–2012

Kraj	2004	2005	2006	2007	2008	2009	2010	2011	2012
Belgia	5,7	5,6	5,5	5,3	5,6	5,3	5,6	5,4	5,1
Bułgaria	2,4	2,5	2,6	2,6	2,7	2,3	2,4	2,6	2,5
Czechy	4,5	4,4	4,5	4,5	4,4	4,1	4,3	4,1	4,1
Dania	3,7	3,6	3,9	3,8	3,7	3,5	3,6	3,4	3,3
Niemcy	4,2	4,1	4,3	4,1	4,1	3,9	4,1	3,9	3,9
Estonia	4,1	4,1	4,1	4,6	4,4	4,0	4,6	4,7	4,6
Irlandia	3,7	3,7	3,7	3,7	3,5	3,3	3,3	3,1	3,0
Grecja	2,8	2,8	2,8	2,8	2,8	2,7	2,6	2,5	2,4
Hiszpania	3,3	3,3	3,3	3,3	3,1	2,8	2,8	2,7	2,7
Francja	4,4	4,4	4,3	4,2	4,2	4,0	4,1	4,0	4,0
Chorwacja	2,0	2,1	2,1	2,2	2,1	2,0	2,0	2,0	1,9
Włochy	3,2	3,2	3,2	3,2	3,1	2,9	2,9	2,9	2,7
Cypr	3,4	3,5	3,5	3,6	3,7	3,5	3,3	3,2	2,9
Łotwa	2,0	2,0	2,1	2,2	2,1	2,1	2,2	2,1	2,2
Litwa	2,7	2,6	2,6	2,9	2,9	2,7	2,2	2,3	2,4

cd. tabeli 1

Kraj	2004	2005	2006	2007	2008	2009	2010	2011	2012
Luksemburg	10,3	10,4	10,1	9,7	9,6	8,8	9,2	8,9	8,5
Węgry	2,6	2,7	2,7	2,7	2,7	2,5	2,6	2,5	2,4
Malta	2,3	2,4	2,3	2,4	2,4	2,1	2,3	2,2	2,2
Holandia	5,0	5,0	4,9	5,1	5,1	4,9	5,2	4,8	4,9
Austria	4,1	4,2	4,2	4,1	4,1	3,9	4,1	4,0	4,0
Polska	2,4	2,4	2,5	2,5	2,6	2,5	2,6	2,6	2,5
Portugalia	2,6	2,6	2,5	2,5	2,4	2,4	2,3	2,2	2,1
Rumunia	1,8	1,8	1,9	1,9	2,0	1,7	1,8	1,8	1,8

Źródło: obliczenia własne.



Rys. 1. Kraje Unii Europejskiej charakteryzujące się najniższym udziałem energii ze źródeł odnawialnych w końcowym zużyciu energii (poniżej średniej unijnej) w latach 2004–2012 oraz cel na 2020 r.


Źródło: opracowanie własne.

Jako jeden z celów określonych w pakiecie klimatyczno-energetycznym przyjęto, że co najmniej 20% końcowego zużycia energii brutto ma pochodzić

z odnawialnych źródeł energii, przy czym w każdym z krajów Unii Europejskiej udział ten ma być na innym poziomie. Jak wynika z rys. 1–3, różny jest udział odnawialnych źródeł energii w końcowym zużyciu energii w poszczególnych krajach. Średnia dla Unii Europejskiej w 2012 r. wyniosła 16,85%, mediana miała wartość 13,90%, a rozkład był prawostronnie asymetryczny (współczynnik asymetrii¹ wyniósł 1,12), co oznacza, że większość krajów charakteryzowała się niższym udziałem, niż wynosi średnia.

Na podstawie rys. 1 można stwierdzić, że najwięcej do zrealizowania zamierzonego celu zawartego w dyrektywie z 2009 r. brakuje Holandii (cel – 16,0%; w 2012 r. – 4,5%) oraz Wielkiej Brytanii (cel – 15,0%; w 2012 r. – 4,2%).

Na rys. 2 zaprezentowane są kraje, których cel jest zbliżony do ogólnego celu dla Unii Europejskiej. Wśród tych krajów najmniej do realizacji celu brakuje Czechom (cel – 13,0%; w 2012 r. – 11,2%), zaś najwięcej Hiszpanii (cel – 20,0%; w 2012 r. – 14,3%).




Rys. 2. Kraje Unii Europejskiej charakteryzujące się wyższym udziałem energii ze źródeł odnawialnych w końcowym zużyciu energii (poniżej średniej unijnej) w latach 2004–2012 oraz cel na 2020 r.

Źródło: opracowanie własne.

¹ Standaryzowany moment centralny rzędu trzeciego.

Trzy kraje: Bułgaria (cel – 16,0%; w 2012 r. – 16,3%), Estonia (cel – 25,0%; w 2012 r. – 25,2%) i Szwecja (cel – 49,0%; w 2012 r. – 51,0%) już w 2012 r. zrealizowały swoje zobowiązania wynikające z pakietu klimatyczno-energetycznego (por. rys. 3).



Rys. 3. Kraje Unii Europejskiej charakteryzujące się najwyższym udziałem energii ze źródeł odnawialnych w końcowym zużyciu energii (powyżej średniej unijnej) w latach 2004–2012 oraz cel na 2020 r.

Źródło: opracowanie własne.

W celu porównania uporządkowań krajów ze względu na udział energii ze źródeł odnawialnych w końcowym zużyciu energii w kolejnych latach wyznaczono współczynnik tau-Kendalla. W pracy wykorzystany został współczynnik korelacji tau-Kendalla o postaci (zob. [Walesiak 2006]):

$$\Gamma_{lh} = \frac{\sum_{i=2}^{16} \sum_{k=1}^{i-1} a_{ikl} b_{ikh}}{\left[\sum_{i=2}^{16} \sum_{k=1}^{i-1} a_{ikl}^2 \sum_{i=2}^{16} \sum_{k=1}^{i-1} b_{ikh}^2 \right]^{1/2}},$$

gdzie:

$i, k = 1, \dots, n$ – numer obiektu (kraju),

l, h – numer zmiennej;

z podstawieniem:

$$a_{ikl}(b_{ikh}) = \begin{cases} 1, & \text{gdy } x_{il} > x_{kl} \quad (x_{ih} > x_{kh}) \\ 0, & \text{gdy } x_{il} = x_{kl} \quad (x_{ih} = x_{kh}) \\ -1, & \text{gdy } x_{il} < x_{kl} \quad (x_{ih} < x_{kh}) \end{cases},$$

gdzie:

x_{il} – i -ta obserwacja dla l -tej zmiennej,

x_{kl} – k -ta obserwacja dla l -tej zmiennej

Współczynnik tau-Kendalla przyjmuje wartości z przedziału $[-1, 1]$. Wartość 1 oznacza pełną zgodność uporządkowań, zaś wartość -1 pełną ich przeciwstawność.


Tabela 2. Wartości współczynnika tau-Kendalla

Rok	2005	2006	2007	2008	2009	2010	2011	2012
2004	0,98	0,94	0,96	0,92	0,94	0,91	0,90	1,00
2005	×	0,94	0,95	0,93	0,95	0,91	0,90	0,98
2006	×	×	0,98	0,91	0,91	0,87	0,88	0,94
2007	×	×	×	0,93	0,93	0,90	0,89	0,96
2008	×	×	×	×	0,96	0,93	0,90	0,92
2009	×	×	×	×	×	0,95	0,93	0,94
2010	×	×	×	×	×	×	0,96	0,91
2011	×	×	×	×	×	×	×	0,90

Źródło: obliczenia własne.

Jak wynika z tabeli 2, uporządkowania w kolejnych latach są niemal identyczne. We wszystkich krajach w badanym okresie obserwowany jest wzrost udziału energii ze źródeł odnawialnych w końcowym zużyciu energii, ale uporządkowania krajów pozostają prawie bez zmian. Co ciekawe, w 2012 r. uporządkowanie państw Unii Europejskiej jest identyczne jak to w 2004 r. (współczynnik tau-Kendalla wynosi 1,00).

Szczegółowe cele polityki energetycznej Polski to wzrost udziału energii ze źródeł odnawialnych w końcowym zużyciu energii do poziomu 15,5% w 2020 r. (19,3% w przypadku energii elektrycznej, 17% – ciepłownictwa i chłodnictwa, 10,2% – paliw transportowych). Na rys. 4 zaprezentowano udział energii z odna-

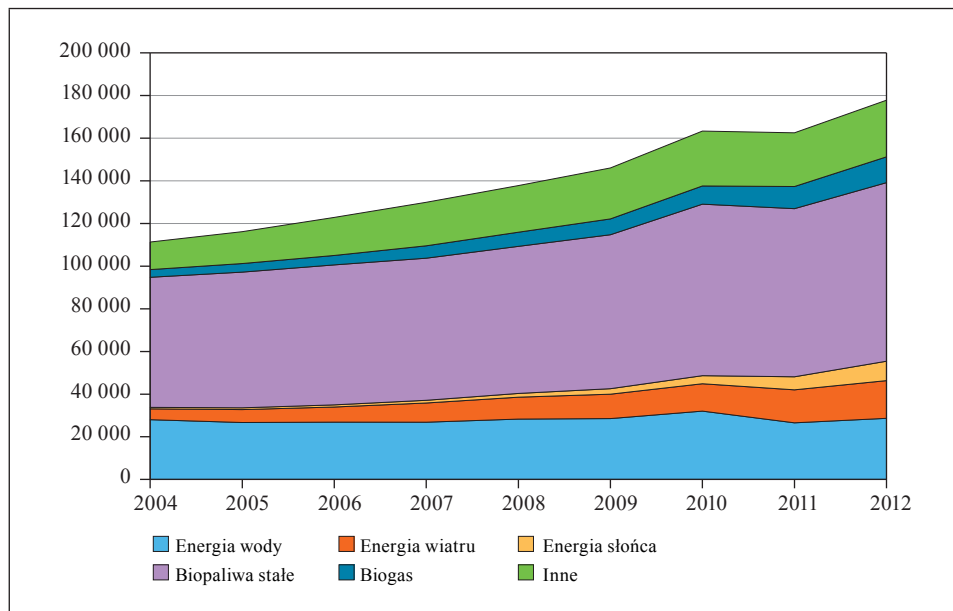


Rys. 4. Udział energii ze źródeł odnawialnych w całkowitym zużyciu energii w Polsce
Źródło: opracowanie własne.

wialnych źródeł w całkowitym zużyciu energii w Polsce w latach 2004–2012 w podziale na dziedziny. W największym stopniu udało się zrealizować zobowiązania w zakresie ciepłownictwa i chłodziwnictwa (brakuje tylko 3,3 pkt proc. do osiągnięcia założonego celu), najgorzej jest w zakresie energii elektrycznej (brakuje jeszcze 8,6 pkt proc., ale wzrost w ciągu 8 lat był w tym przypadku największy i wyniósł 8,8 pkt proc.). W przypadku paliw transportowych do osiągnięcia zamierzonego celu brakuje jeszcze 4,1 pkt proc. Biorąc pod uwagę, że w 2012 r. udział energii ze źródeł odnawialnych w całkowitym zużyciu paliw transportowych wynosił w Polsce 6,1%, aby cel został osiągnięty, w ciągu kolejnych 8 lat udział ten musi wzrosnąć o ponad 60% wartości z 2012 r.

3. Struktura produkcji energii z odnawialnych nośników energii w krajach Unii Europejskiej

Badając strukturę produkcji energii z odnawialnych nośników energii, zaobserwowano przede wszystkim znaczny wzrost produkcji energii elektrycznej z odnawialnych źródeł energii w latach 2004–2012 (por. rys. 5). Największa część energii ze źródeł odnawialnych pochodzi z biopaliw stałych.



Rys. 5. Nośniki energii ze źródeł odnawialnych w Unii Europejskiej w latach 2004–2012

Źródło: opracowanie własne.

W 2012 r. energia pochodząca z biopaliw stałych stanowiła 47,08% całkowitej produkcji energii ze źródeł odnawialnych w Unii Europejskiej, ale udział produkcji energii z tego nośnika zmalał w badanym okresie (z 54,80% w 2004 r.). Drugim co do wielkości nośnikiem energii odnawialnej jest woda, udział energii wody w całkowitej produkcji energii ze źródeł odnawialnych wynosił w 2012 r. 16,11%. Wciąż najmniej energii ze źródeł odnawialnych pochodzi z energii słońca – tylko 5,12% w 2012 r. Zauważyć jednak należy, że w latach 2004–2012 nastąpił największy wzrost (ponad siedmiokrotny, z 0,62% w 2004 r.) udziału tego nośnika w całkowitej produkcji energii ze źródeł odnawialnych. Ponad dwukrotnie w stosunku do 2004 r. zwiększył się udział energii wiatru w całkowitej produkcji energii ze źródeł odnawialnych (udział ten w 2004 r. wynosił 4,55%, zaś w 2012 r. 9,95%) oraz udział biogazu (w 2004 r. wynosił on 3,23%, zaś w 2012 r. 6,80%).

Na podstawie dostępnych danych przeprowadzono grupowanie państw Unii Europejskiej. Kraje grupowane były ze względu na udział produkcji energii odnawialnej z takich nośników energii, jak: woda, wiatr, słońce, biopaliwa stałe, biogaz oraz pozostałe (wśród nich m.in.: odpady komunalne, biobenzyna, biodiesel, energia geotermalna, energia pływów oceanu) w produkcji energii ogółem.

Tabela 3. Grupowanie państw Unii Europejskiej ze względu na strukturę produkcji energii z odnawialnych nośników energii w latach 2004–2012

Rok	Grupa I	Grupa II	Grupa III	Grupa IV	Grupa V	Grupa VI
2004	Belgia, Luksemburg, Holandia, Dania, Niemcy, Włochy	Czechy, Węgry, Łotwa, Finlandia, Estonia, Litwa, Polska	Cypr, Malta	Bułgaria, Rumunia, Portugalia, Irlandia, Grecja, Hiszpania, Francja	Chorwacja, Austria, Słowacja, Słowenia, Szwecja	Wielka Brytania
2005	Belgia, Niemcy, Luksemburg, Dania, Irlandia, Hiszpania, Wielka Brytania	Czechy, Portugalia, Węgry, Łotwa, Finlandia, Estonia, Litwa, Polska	Cypr, Malta	Bułgaria, Rumunia, Słowenia, Grecja, Francja, Chorwacja, Austria, Szwecja, Słowacja	Włochy, Holandia	–
2006	Belgia, Luksemburg, Dania, Niemcy, Włochy, Holandia	Czechy, Węgry, Łotwa, Finlandia, Estonia, Litwa, Polska	Cypr, Malta	Bułgaria, Rumunia, Słowenia, Szwecja, Grecja, Portugalia, Francja, Chorwacja, Austria, Słowacja	Irlandia, Hiszpania, Wielka Brytania	–
2007	Belgia, Niemcy, Holandia, Dania, Włochy, Wielka Brytania	Czechy, Węgry, Estonia, Litwa, Polska, Łotwa, Finlandia	Cypr, Malta	Bułgaria, Rumunia, Grecja, Portugalia, Luksemburg, Irlandia, Hiszpania	Francja, Chorwacja, Austria, Słowacja, Szwecja, Słowenia	–
2008	Belgia, Holandia, Dania, Niemcy, Włochy, Wielka Brytania	Bułgaria, Rumunia, Łotwa, Finlandia, Grecja, Portugalia, Luksemburg, Czechy, Litwa, Polska, Estonia, Węgry	Cypr, Malta	Irlandia, Hiszpania	Francja, Słowacja, Chorwacja, Austria, Szwecja, Słowenia	–

Rok	Grupa I	Grupa II	Grupa III	Grupa IV	Grupa V	Grupa VI
2009	Belgia, Holandia, Dania, Niemcy, Luksemburg, Wielka Brytania, Włochy	Bulgaria, Rumunia, Łotwa, Finlandia, Czechy, Węgry, Litwa, Polska, Estonia	Cypr, Malta	Irlandia, Hiszpania	Grecja, Portugalia, Francja, Słowacja, Chorwacja, Austria, Słowenia, Szwecja	-
2010	Belgia, Holandia, Włochy, Malta	Czechy, Węgry, Litwa, Polska, Estonia, Łotwa, Finlandia	Cypr	Bulgaria, Rumunia, Francja, Słowacja, Szwecja, Austria, Słowenia, Chorwacja, Grecja, Portugalia, Hiszpania	Dania, Niemcy, Luksemburg, Irlandia, Wielka Brytania	-
2011	Belgia, Holandia, Włochy	Czechy, Węgry, Estonia, Litwa, Polska, Łotwa, Finlandia	Cypr, Malta	Bulgaria, Rumunia, Francja, Słowacja, Chorwacja, Słowenia, Austria, Szwecja	Dania, Grecja, Portugalia, Hiszpania, Irlandia, Niemcy, Luksemburg, Wielka Brytania	-
2012	Włochy, Holandia, Malta	Bulgaria, Rumunia, Łotwa, Finlandia, Estonia, Litwa, Polska	Cypr	Francja, Słowacja, Chorwacja, Słowenia, Austria, Szwecja	Dania, Grecja, Portugalia, Hiszpania, Irlandia	Belgia, Węgry, Czechy, Luksemburg, Niemcy, Wielka Brytania

Źródło: opracowanie własne.

Zmienne poddane zostały normalizacji z wykorzystaniem przekształcenia ilorazowego z parametrami stałymi w czasie. Grupowanie przeprowadzono² metodą Warda³ z wykorzystaniem odległości Euklidesa⁴. Liczbę grup ustalono, analizując wartości współczynnika sylwetkowego⁵.

Grupa I to kraje charakteryzujące się dużym udziałem produkcji energii odnawialnej z biopaliw w produkcji energii ogółem; wśród tych krajów są także takie, które w znacznym stopniu korzystają z energii wiatru, a największy odsetek produkcji pochodzi z pozostałych źródeł energii. Są to kraje, w których udział produkcji energii z odnawialnych źródeł energii (OZE) w produkcji energii ogółem przyjmuje wartości poniżej średniej dla Unii Europejskiej. W grupie tej następowały największe zmiany w badanym okresie, ale zwykle należały do niej takie państwa, jak Belgia i Holandia.

Grupa II to kraje korzystające niemal tylko z biopaliw. Są to państwa, w których udział produkcji energii z OZE w produkcji energii ogółem jest wysoki. Do tej grupy należała m.in. Estonia, jeden z krajów, w którym już w 2012 r. osiągnięty został cel na 2020 r. Do grupy II należały także niezmiennie: Polska, Czechy, Węgry, Łotwa, Finlandia i Litwa.

Cypr oraz na ogół Malta tworzyły grupę III, charakteryzującą się największym wykorzystaniem energii słońca, zaś udział produkcji energii z OZE w produkcji energii ogółem jest najniższy wśród krajów Unii Europejskiej.

Do grupy IV należały na ogół takie kraje, jak Bułgaria, Rumunia, Szwecja i Grecja. Charakterystyczne w tej grupie jest to, że najwięcej energii odnawialnej pochodzi z biopaliw i energii wody. Państwa należące do grupy IV to państwa z najwyższym udziałem produkcji energii z OZE w produkcji energii ogółem w UE.

Grupa V obejmowała kraje z dużym udziałem produkcji energii z OZE, przy czym energia ta pochodzi głównie z wody i biopaliw. W grupie tej na ogół znajdowała się Chorwacja i Austria.


Grupa VI, która została wyodrębniona w 2004 i 2012 r., to kraje, gdzie energia odnawialna w znacznej części pochodzi z biogazu, ale udział energii pochodzącej z OZE w końcowym zużyciu energii jest niewysoki.

² Obliczenie przeprowadzono z wykorzystaniem pakietu Statistica.

³ Ze względu na małą liczbę krajów zdecydowano się na metodę aglomeracyjnego grupowania hierarchicznego. Budując dendrogram, uzyskano dobry obraz struktury grupowej.

⁴ Zastosowano odległość euklidesową jako najczęściej wykorzystywaną odległość w przypadku danych mierzonych na skali przedziałowej i ilorazowej. Wyniki grupowania z wykorzystaniem kwadratu odległości euklidesowej były analogiczne.

⁵ Współczynnik sylwetkowy (indeks silhouette) zaprezentowany został w pracy [Kaufmann i Rousseeuw 1990]. Wybiera się liczbę skupień, dla której wartość współczynnika była największa.



Rys. 6. Wyniki grupowania państw Unii Europejskiej ze względu na poszczególne nośniki energii odnawialnej w 2012 r.

Źródło: opracowanie własne.

Podobieństwo wyników podziałów klas zbadano, wykorzystując miarę skonstruowaną przez W.M. Randa (za: [Walesiak 2005]):

$$R = \frac{Z}{\binom{n}{2}}$$

gdzie:

$$Z = \binom{n}{2} + \sum_{s=1}^u \sum_{r=1}^v n_{sr}^2 - \frac{1}{2} \left(\sum_{s=1}^u n_{s\bullet}^2 + \sum_{r=1}^v n_{\bullet r}^2 \right),$$

przy czym u, v to liczby klas w porównywanych podziałach $P^{(q)} = \{P_1^{(q)}, \dots, P_u^{(q)}\}$, $P^{(t)} = \{P_1^{(t)}, \dots, P_v^{(t)}\}$; $s = 1, \dots, u$; $r = 1, \dots, v$; n_{sr} to liczba obiektów, które jednocześnie należą do klas $P_s^{(q)}$ i $P_r^{(t)}$; $n_{\bullet r}$ – liczba obiektów w klasie $P_r^{(t)}$; $n_{s\bullet}$ – liczba obiektów w klasie $P_s^{(q)}$.

Miarę tę interpretuje się jako odsetek par obiektów zgodnych w obu klasyfikacjach (w przypadku prowadzonej analizy w wybranych dwóch latach) w ogólnej liczbie par obiektów określonych na zbiorze. Wartość 0 oznacza, że podziały są zupełnie niepodobne, zaś wartość 1 oznacza podziały identyczne.

Tabela 4. Miara podobieństwa składów klas

Rok	2005	2006	2007	2008	2009	2010	2011	2012
2004	0,83	0,90	0,90	0,82	0,87	0,85	0,85	0,79
2005	×	0,90	0,81	0,80	0,84	0,89	0,90	0,74
2006	×	×	0,84	0,80	0,90	0,92	0,88	0,72
2007	×	×	×	0,85	0,84	0,81	0,85	0,75
2008	×	×	×	×	0,88	0,75	0,78	0,75
2009	×	×	×	×	×	0,84	0,81	0,78
2010	×	×	×	×	×	×	0,89	0,72
2011	×	×	×	×	×	×	×	0,77

Źródło: obliczenia własne.

Jak wynika z tabeli 4, podziały w kolejnych latach są do siebie bardzo podobne. Najmniejsze wartości miernika zaobserwować można dla 2012 r., ale nawet tutaj udział par zgodnych w stosunku do podziałów z lat wcześniejszych wynosi ponad 70%.

4. Wnioski

Największy udział energii ze źródeł odnawialnych w ogólnym zużyciu energii odnotowano w Szwecji, a najmniejszy na Malcie. We wszystkich krajach Unii Europejskiej w badanym okresie nastąpił wzrost tego udziału – największy na Malcie (jest to kraj, który ma najniższy cel do osiągnięcia, ale mimo to wciąż brakuje niemal 9 pkt proc.), wysokim wzrostem tego udziału charakteryzują się także: Belgia, Wielka Brytania, Luksemburg i Irlandia (tu wzrost wyniósł ponad 300% w stosunku do 2004 r.). Najmniejszy wzrost zaobserwować można m.in. na Łotwie (jest to państwo, które już w 2012 r. zrealizowało cel na 2020 r.) i w Finlandii (do realizacji celu brakuje jeszcze 4 pkt proc.).

Jak wynika z analizy wartości współczynnika tau-Kendalla, uporządkowania krajów ze względu na udział energii odnawialnej w końcowym zużyciu energii w kolejnych latach są niemal identyczne.

Z analizy miernika Randa, który określa podobieństwo składów klas, wynika że rezultaty grupowania wybranych krajów Unii Europejskiej ze względu na strukturę produkcji energii elektrycznej z odnawialnych nośników energii w latach 2004–2012 nie różnią się znacząco między sobą. Grupy utworzone w poszczególnych latach są mniej więcej stałe i dość jednorodne. Kraje należące do poszczególnych grup mają bardzo podobną strukturę nośników energii odnawialnej, która w kolejnych latach nie ulega znaczącym zmianom. Ponadto są to państwa o podobnym udziale energii odnawialnej w końcowym zużyciu energii. W badanym okresie Polska należała do grupy państw, w której głównym źródłem energii odnawialnej są biopaliwa i energia wody (grupa II).

W toku są dalsze badania związane z energią ze źródeł odnawialnych, które dotyczyć będą źródeł finansowania energii ze źródeł odnawialnych oraz zależności między poziomem rozwoju poszczególnych krajów a udziałem energii ze źródeł odnawialnych w końcowym zużyciu energii.

Literatura

- Badyda K. [2013], *Energetyka wiatrowa. Aktualne trendy rozwoju w Polsce*, „Energetyka”, nr 5/2013.
- Czechowicz Z. [2012], *Rozproszone źródła energii elektrycznej ze szczególnym uwzględnieniem odnawialnych źródeł energii*, „Energetyka” nr 2/2012.
- Dyrektywa 2009/28/WE z dnia 23 kwietnia 2009 r. w sprawie promowania stosowania energii ze źródeł odnawialnych zmieniająca i w następstwie uchylająca dyrektywy 2001/77/WE oraz 2003/30/WE, Dz.Urz. UE, L 140/16, 5.06.2009.
- Energia odnawialna w Polsce w 2012* [2012], http://gramwzielone.pl/uploads/files/ENERGIA%20ODNAWIALNA%20W%20POLSCE%202012_10_21.pdf.
- Energia ze źródeł odnawialnych w 2012 r.* [2013], Główny Urząd Statystyczny, Warszawa.
- Karpińska M., Dul Ł. [2014], *Kierunki polityki energetycznej Polski oraz Unii Europejskiej w latach 2007–2030*, „Energetyka”, nr 3/2014.
- Kaufmann L., Rousseeuw P.J. [1990], *Finding Groups in Data: An Introduction to Cluster Analysis*, Wiley, New York.
- Sadowski T., Świdorski G., Lewandowski W. [2008], *Wykorzystanie odnawialnych i nieodnawialnych źródeł energii w Polsce i w krajach UE*, „Energetyka”, nr 4/2008.
- Walesiak M. [2005], *Rekomendacje w zakresie strategii postępowania w procesie klasyfikacji zbioru obiektów* [w:] *Przestrzenno-czasowe modelowanie i prognozowanie zjawisk gospodarczych*, red. A. Zeliaś, Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków.
- Walesiak M. [2006], *Uogólniona miara odległości w statystycznej analizie wielowymiarowej*, wyd. drugie rozszerzone, Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu, Wrocław.

The Market of Renewable Energy Sources in the European Union – a Statistical Analysis

(Abstract)

The ongoing dynamic development of civilization has translated into growing demand for energy. The use of traditional energy sources such as coal, oil and natural gas is not only associated with an increase in pollution, but also causes the depletion of natural resources. Renewable sources of energy are an alternative to non-renewable energy sources such as fossil fuels.

The main aim of this article is to assess the changes occurring in the market of renewable energy in the European Union. Based on available data, countries were ordered linearly, according to the share of energy from renewable sources they used to produce electricity. Changes in how energy from renewable sources is obtained are discussed. The countries were classified according to how they obtained energy from renewable sources.

Keywords: renewable energy, linear ordering, classified, Kendall tau coefficient, Rand index.

Jan Acedański

Department of Economics
University of Economics in Katowice

Overlapping Generation Models with Heterogeneous Agents and Aggregate Uncertainty in Macroeconomic Modelling*

Abstract

The paper introduces the methodology of the overlapping generations models with heterogeneous agents and aggregate uncertainty – macroeconomic, stochastic general equilibrium models that account for consumer heterogeneity mainly with respect to age and wealth. Taking as an example my own model, which additionally allows for labour market status and skill heterogeneity, I show how consumer consumption and investment decision rules are derived. I also provide a detailed discussion of the most popular computational algorithms used to deal with those models. The model is then used to examine welfare gains from eliminating business cycle fluctuations on the labour market in Poland for different groups of consumers.

Keywords: DSGE models, overlapping generations, heterogeneous agents, business cycle, computational algorithms.

*The article was written for a project financed by a Polish National Science Centre grant based on decision DEC-2011/01/D/HS4/03430.

1. Introduction

Dynamic stochastic general equilibrium models (DSGE) are a cornerstone of modern macroeconomic research methodology (Mankiw 2006, Blanchard 2008, *Post Walrasian...* 2006). Although they are still not very common in the Polish literature, they have been attracting increasing attention (*Raport...* 2009, Grabek, Kłós & Koloch 2010, Wróbel-Rotter 2013). A characteristic feature of this class of models is their solid microfoundations as the key equations are derived from optimality conditions of microeconomic agents. For example, consumers choose consumption paths to maximise their expected lifetime utility and firms' investments are set to maximise the value of enterprises. It is also common practice to assume that agents hold rational expectations. DSGE models are not only utilized as a reliable macroeconomic policy analysis tool, but also for forecasting. Recent studies (Del Negro & Schorfheide 2013, Kolasa, Rubaszek & Skrzypczyński 2012) show that their forecast accuracy is already comparable to the accuracy of (B)VAR models and professional forecasters.

DSGE models are usually founded on the representative agent assumption, which states that all agents of the same type in the model are homogenous. In most cases, that significantly reduces the model's complexity without affecting its aggregate properties. However, if one wants to study distributional or lifecycle problems, for example, this assumption can no longer be used: heterogeneous agent models must be substituted. Moreover, some authors (Chang, Kim & Schorfheide 2013) suggest that estimated parameters in the traditional DSGE models that do not take into account agents' heterogeneity may not be policy invariant, which makes them prone to the famous Lucas critique (1976). This is a particularly severe drawback, as the whole DSGE methodology is expected to refer to the policy-invariant, "deep" parameters only.

Formally, variable dynamics in DSGE models are implicitly described by a set of nonlinear stochastic difference equations. To obtain the explicit law of motions, one has to resort to complicated numerical procedures. Fortunately, MATLAB package Dynare offers a set of excellent tools that allow researchers to analyse many large-scale homogeneous agent DSGE models with little programming effort. This is one of the most important reasons for the widespread popularity of the homogeneous agents DSGE modelling.

As far as the models with heterogeneous agents are concerned, in most cases they cannot be analysed using Dynare. As a result, routines tailored to deal with the specific problem must be relied upon, which makes the modelling process considerably more demanding in terms of programming and computations. Additionally, the literature on the heterogeneous agent DSGE modelling is rather scarce, especially Poland's contribution (Rubaszek 2012, Brzoza-Brzezina *et al.*

2013 are notable exceptions). I see that paucity as a serious obstacle to wider applications of this powerful analytical tool for studies on the Polish economy.

With this paper, I seek to begin to fill this gap. I present a heterogeneous agent DSGE model with aggregate uncertainty that accounts for both age and wealth heterogeneity among consumers. The model allows consumers to differ with respect to their labour market status as well as their skill level. I provide a detailed description of the model's building phases: derivation, numerical solution and simulation, then calibrate the parameters of the model to match basic stylised facts regarding labour market and macroeconomic aggregate dynamics in Poland. To illustrate the model's abilities I use it to assess the potential welfare gains from removing business cycle fluctuations for different groups of consumers. I can provide the MATLAB codes that replicate all the computations upon request.

Dynamic, stochastic economies with rational expectations and continuum of heterogeneous consumers with respect to wealth were first studied by M. Huggett (1993) and R. Aiyagari (1994). However, they considered the models without aggregate risk where all macroeconomic aggregates are constant in time. The models with aggregate fluctuations were computationally intractable until the concept of approximate aggregation was introduced by P. Krusell and A. A. Smith (1998). Their model was further extended to include other sources of consumer heterogeneity (see Krusell & Smith 2006 for a review). The model presented in the paper, already used by J. Acedański (2014) to examine the welfare consequences of the recent pension reforms in Poland, is closely related to the work of K. Storesletten, C. I. Telmer and A. Yaron (2007), who also consider the model with wealth and skill heterogeneity as well as the overlapping generations. However, they focus on modelling individual income risk while I concentrate on labour market risk. The two models also differ in terms of asset structure.

The discussion of the welfare consequences of business cycle fluctuations was triggered by the seminal work of R. E. Lucas (1987), who argued that very little is gained from eliminating business cycles. A more detailed review of the copious literature on this topic was done by J. Acedański (2007), among others. Here I only point out that K. Storesletten, C. I. Telmer and A. Yaron (2001) used a simplified version of their abovementioned later model to examine the cost of the business cycle in the overlapping generation setup.

An excellent discussion of the computational tools used to analyse heterogeneous agent DSGE models can be found in a textbook written by B. Heer and A. Maussner (2009). Recent developments in this field are nicely compared and summarised by W. J. Den Haan, K. L. Judd and M. Juillard (2010) and W. J. Den Haan (2010). In my study, I use the algorithm proposed by L. Maliar, S. Maliar and F. Valli (2010).

The rest of the paper is organised as follows. The equations for the model are derived in the next section while Section 3 describes the calibration of the model's parameters. Section 4 provides a discussion the computational algorithms. Finally, I present the results of my exercise.

2. Model

2.1. General Framework

The economy is populated by a continuum of finitely lived agents indexed by i that differ in terms of age a , skill level s , employment status ε and wealth k . For the sake of simplicity I omit the time subscripts and use primes to denote next periods. One period in the model corresponds to one year. The agents enter the market at the age of 20, work for 40 years, then retire and live, at most, up to the age of 99. As a result, each cohort in the model lives for 80 years.

Young agents either work ($\varepsilon = 1$) or are unemployed ($\varepsilon = 0$). If employed, they supply $\xi_{s,a} l$ effective units of labour and get the pre-tax income $\xi_{s,a} l W$, where W stands for the aggregate wage, l is the constant for all agents' exogenous labour supply and $\xi_{s,a}$ denotes the efficiency factor. The unemployed agents collect unemployment benefits that are proportional to the mean wage in the economy $\theta_u \bar{\xi} l W$, where θ_u is the unemployment replacement rate and $\bar{\xi}$ denotes the mean labour efficiency across employed agents. Retirees receive pensions that are proportional to the wage of an employed agent of age 59 $\theta_r \xi_{s,59} l W$, where θ_r represents the pension replacement rate. Moreover, all agents collect interest from their wealth according to aggregate interest rate R . An agent i 's work-related income d is given by:

$$d_i = (1 - \tau) l W \left[\xi_{s,a} \cdot I(a_i < 60, \varepsilon_i = 1) + \theta_u \bar{\xi} \cdot I(a_i < 60, \varepsilon_i = 0) + \theta_r \xi_{s,59} \cdot I(a_i \geq 60) \right], \quad (1)$$

where I stands for the indicator function and τ is the labour tax rate.

I assume that the agents who die leave their capital for the new-born agents that replace them, but do not take into account leaving the bequest when facing their consumption-investment problems as the bequest does not enter the agent's utility function. This assumption helps to keep the model closer to the data without making the agents' decision horizon infinite. Alternatively, one can assume that the wealth of dead agents is collected by the government and immediately spent on public consumption. Another possibility is to extend the agents utility function to account for the bequest amount (but not the utility from the bequest for future generations). That would motivate agents to lower their consumption and keep some wealth for a future generation.

The production sector consists of one representative firm that hires capital and labour from agents and produces a single consumption good according to the standard Cobb-Douglas technology:

$$Y = ZK^\alpha L^{1-\alpha} \quad (2)$$

where Z is the stochastic aggregate productivity shock and K and L are the aggregate capital and aggregate effective labour, respectively:

$$K = \int k_i di, \quad L = l \int \xi_{s,a} I(a_i < 60, \varepsilon_i = 1) di. \quad (3)$$

Note that both variables depend on the aggregate productivity shock. For the aggregate labour supply, this is the case because the fraction of the employed agents fluctuates with business cycles. Since the firm operates on the competitive market, it sets the aggregate wage and interest rate equal to the marginal products of labour and capital:

$$W = (1 - \alpha) ZK^\alpha L^{-\alpha}, \quad R = \alpha ZK^{\alpha-1} L^{1-\alpha}. \quad (4)$$

The model also accounts for government, which imposes taxes on the income from work to finance the unemployment benefits and pensions. The tax rate is set so that the government budget is balanced for every period:

$$\tau = \frac{\theta_u \bar{\xi} \int I(a_i < 60, \varepsilon_i = 0) di + \theta_r \int \xi_{s,59} I(a_i \geq 60) di}{\int \xi_{s,a} \cdot I(a_i < 60, \varepsilon_i = 1) di + \theta_u \bar{\xi} \int I(a_i < 60, \varepsilon_i = 0) di + \theta_r \int \xi_{s,59} I(a_i \geq 60) di}. \quad (5)$$

2.2. The Decision Problem Agents Face

In every period an agent of age a faces the following consumption-saving problem: given her capital stock k , the aggregate state of the economy Z and the individual income d , she has to decide how much of her current wealth to consume and how much to save to maximise her expected lifetime utility. For clarity, the variables below are indexed by an agent's age. But still, the time subscripts are omitted.

The problem can be written as follows:

$$\max_{c_a k_{a+1}} E \sum_{h=0}^{99-a} \beta^h q_{a+h, a+h+1} U(c_{a+h}) \quad s.t. \quad (6)$$

$$k_{a+h+1} = (1 - \delta + R_{a+h})k_{a+h} + d_{a+h} - c_{a+h}, \quad (7)$$

$$k_{a+h+1} \geq \underline{k}, \quad h = 0, 1, \dots, 99 - a, \quad (8)$$

where E is the expectation operator, β – the discount factor, $q_{a, a+1}$ – the survival probability from age a to $a + 1$, δ – the capital depreciation rate, c – individual consumption, \underline{k} – debt limit, and

$$U(c) = \frac{c^{1-\gamma} - 1}{1-\gamma} \quad (9)$$

is the one-period utility function (referred to as the constant relative risk aversion – CRRA), with γ denoting the risk aversion parameter.

It should be noted that there is a series of constraints (7) that describe the laws of motion for the individual capital – one for every period of an agent's remaining life. This is also the case for the debt limit conditions (8) that result from the borrowing constraints. However, for an agent at age a there are only two decision variables: current consumption c_a and the next period capital stock k_{a+1} .

Due to the non-negativity constraints, the first-order optimality conditions that characterise an agent's decision rules are given by the Kuhn-Tucker theorem:

$$c_a^{-\gamma} - \lambda_a = \beta q_{a,a+1} E \left[c_{a+1}^{-\gamma} (1 - \delta + R_{a+1}) \right], \quad (10)$$

$$k_{a+1} = (1 - \delta + R_a)k_a + d_a - c_a, \quad (11)$$

$$k_{a+1} \geq \underline{k}, \quad \lambda_a \geq 0, \quad \lambda_a (k_{a+1} - \underline{k}) = 0. \quad (12)$$

Here, λ_a is the Lagrange multiplier associated with the borrowing constraint (8). If it is not binding, then $\lambda_a = 0$. Equation (10) is the well-known intertemporal optimality condition. An agent should choose the consumption path so that the utility loss from one unit of the current consumption (l.h.s) equals the discounted expected utility gain from the higher consumption in the next period (r.h.s).

Plugging (11) into (10) to eliminate the current and the future consumption yields what is known as the Euler equation for the capital stock. It implicitly describes the sequence of optimal decision rules regarding the individual capital stock:

$$k_{a+1} = (1 - \delta + R_a)k_a + d_a - \left[\lambda_a + \beta q_{a,a+1} E \left(\frac{1 - \delta + R_{a+1}}{[(1 - \delta + R_{a+1})k_{a+1} + d_{a+1} - k_{a+2}]^\gamma} \right) \right]^{\frac{1}{\gamma}}. \quad (13)$$

Together with budget constraint (11), this relationship implicitly determines an agent's optimal consumption-saving behaviour.

At this point it is worth mentioning that problem (6)–(9) can also be stated in an alternative form using dynamic programming notation and the Bellman optimality principle:

$$V(k, a, \varepsilon, s, K, Z) = \max_{c_a, k_{a+1}} \left\{ U(c_a) + \beta q_{a,a+1} E \left[V(k', a+1, \varepsilon', s, K', Z') \mid \varepsilon, K, Z \right] \right\} \text{ s.t.} \quad (14)$$

$$k_{a+1} = (1 - \delta + R_a)k_a + d_a - c_a, \quad k_{a+1} \geq \underline{k}. \quad (15)$$

The value function V for an agent of age a represents a maximal discounted expected utility from her current and future consumption:

$$V(k, a, \varepsilon, s, K, Z) = \max_{c_a, k_{a+1}} \left\{ E \sum_{h=0}^{99-a} \beta^h q_{a+h, a+h+1} U(c_{a+h}) \right\} \quad s.t. \quad (15). \quad (16)$$

It is possible to obtain exactly the same optimality conditions (10)–(12) from problem (14)–(15) using the first order conditions of the maximum on the r.h.s. of (14) as well as the envelope theorem that shows how to differentiate value function V .

2.3. The Stochastic Structure of the Economy

There are three stochastic shocks in the model. The aggregate productivity shock Z is represented by a two-state Markov chain with the transition matrix P_Z . The states $Z = \{Z_b, Z_g\}$ represent the recession and expansion periods in the economy. The individual employment shock ε is also modelled as a two-state Markov chain with the transition matrix $P_\varepsilon(Z, Z', s, a)$ that depends on the current and the future state of the economy as well as an agent's skill level and age. Finally, the lifetime in the model is stochastic. For every cohort a , there is a fraction $1 - q_{a, a+1}$ of agents who die. It should also be noted that in my model I do not allow agents to change their skill level. However, this assumption can easily be relaxed.

3. Calibration

The baseline calibration is presented in Table 1. The capital share of output α is set at 0.45, which is close to the value observed in Poland. The values of the capital depreciation rate $\delta = 0.055$ and the discount rate $\beta = 0.98$ are calibrated jointly to match the interest rate of about 5% and the average share of investment in output, which is about 20% in Poland. I use the standard value for the coefficient of relative risk aversion $\gamma = 2$. The compensation rates for agents who do not work equal $\theta_u = 0.2$ and $\theta_r = 0.6$. As far as the skill level is concerned, we have three groups of agents in the model: low-, medium- and high-skilled, which broadly correspond to people with a primary, secondary and tertiary education. This breaks down to 15%, 70% and 15% of the Polish population, respectively. Finally, the debt limit equals 75% of the wage in the model and varies across the skill levels.

The individual efficiency factors ξ shown in Table 2 are calibrated to match the observed differences in wages according to the Structure of Earnings Survey conducted by Eurostat. The data show that the earnings of the low-skilled (primary-educated) workers are about 20% lower than those of the medium-

-skilled (secondary-educated), while the high-skilled (tertiary-educated) earn about 65% more. Similarly, in Poland young people (20–29 years) earn about 20% lower wages than those in other age brackets. The differences for the other age groups are small, so we have left them out.

Table 1. Baseline Calibration of the Model

Description	Parameter	Value
Capital share of output	α	0.45
Capital depreciation rate	δ	0.055
Discount rate	β	0.98
Risk aversion	γ	2
Net unemployment benefit rate	θ_u	0.2
Net pension replacement rate	θ_r	0.6
Share of low-, medium- and high-skilled workers	ω	{0.15; 0.7; 0.15}
Individual labour supply	l	1
Debt limit	\underline{k}	$-0.75(1-\tau)lW\xi_s$

Source: the author's calculations.

Table 2. Calibration of the Individual Labour Efficiency Factors

Parameter	Skill level			Parameter	Age	
	low	medium	high		20–29	30–59
ξ_s	0.8	1	1.65	ξ_a	0.8	1

Source: the author's calculations.

To calibrate the Markov chain for aggregate productivity I calculate log-deviations from the HP-filtered trend of yearly data on Polish GDP covering the period 1996–2013. This implies a symmetric business cycle where each phase lasts 3.75 years on average and productivity shock values of $Z_b = 0.986$ during the recessions and $Z_g = 1.014$ for periods of growth. The transition probabilities P_ϵ are calibrated to match the average level \bar{u} and the duration u_l of the unemployment in Poland during booms and recession for workers of different skill levels and age based on the data from the Labour Force Survey. Since the data on the mean level of unemployment are grouped into 5-year bins, the values for each age were linearly interpolated. According to the data on the length of unemployment, I also assume that it is equal for all education levels and distinguish only two age groups: 20–39 and 40–59. Based on these data, I calculate the transition probabilities in the following way. The probability of staying unemployed is:

$$p_{uu}(a, Z) = 1 - u_l^{-1}(a, Z) \quad (17)$$

while the probability of losing a job is:

$$p_{eu}(a, s, Z) = [\bar{u}(a+1, s, Z') - \bar{u}(a, s, Z) \cdot (1 - p_{uu}(a, Z))] \cdot [1 - \bar{u}(a, s, Z)]^{-1}, \quad (18)$$

where $\bar{u}(a, s, Z)$ denotes the mean unemployment rate for a worker of age a and skill level s when the state of the economy is Z . Finally, the survival rates $q(a, a+1)$ are taken from Polish unisex lifetables from the year 2012.

4. Computational Algorithms

4.1. General Outline of the Computational Procedure

The dynamics of individual capital and consumption evolve according to equations (13) and (11). Below, I describe how to compute the explicit decision rules of the form:

$$k_{a+1} \equiv k_{a+1}(k, a, \varepsilon, s, K, Z) \quad \text{and} \quad c_a \equiv c_a(k, a, \varepsilon, s, K, Z). \quad (19)$$

My algorithm uses three important concepts. First, a backward iteration is employed to exploit the finite lifetime of agents and the recursive nature of their decision problem. Then, the Euler equation iteration algorithm proposed by L. Maliar, S. Maliar and F. Valli (2010) is used to find the explicit decision rules of agents from a given cohort, followed by the approximate aggregation property discussed by P. Krusell and A. A. Smith (1998). Their algorithm iterates on the first two concepts to find the law of motion for the aggregate capital that fulfils the rational expectation requirements. I start the discussion looking at the third algorithm and then move to the previous ones.

4.2. Krusell and Smith Algorithm

From (13), it is clear that the optimal level of the next period capital k' depends on the expected aggregate interest rate in the next period R' , among other things. This, in turn, is related to the mean level of the aggregate capital K' , which is determined by decisions taken by every individual. As a result, a fully rational agent should take into account the decisions of all other agents in the model. Eventually, to make fully rational decisions, an agent should track the whole distribution of the wealth across agents, which is an infinite dimensional object. However, this assumption seems as unrealistic as it is computationally infeasible. P. Krusell and A. A. Smith showed that it can be sufficient to take into account only the first few moments of the capital distribution to predict the next period's

mean aggregate capital accurately. In fact, my model assumes that agents use the autoregressive law of motion for forecasting the mean level of the aggregate capital:

$$K' = b_{0b} + b_{1b}K \quad \text{if } Z = Z_b, \quad K' = b_{0g} + b_{1g}K \quad \text{if } Z = Z_g. \quad (20)$$

This is precisely the reason for including K as the argument of the decision rules (19) as well as the value function (14). The coefficients $b = [b_{0b}, b_{1b}, b_{0g}, b_{1g}]$ are set to achieve the highest possible consistency between the perceived laws of motion (20) and the actual dynamics of the mean aggregate capital in the model. To sum up, the iterative algorithm proceeds as follows:

1. Set initial values of the coefficients $b^{(0)}$.
2. For the given $b^{(j)}$, find the individual's decision rules $c_a = c_a(k, a, \varepsilon, s, K, Z)$ and $k_{a+1} = k_{a+1}(k, a, \varepsilon, s, K, Z)$ that solve the individual's consumption-saving problem (6)–(8) for all cohorts a .
3. Given the decision rules, simulate the model for T periods and compute a time path for the mean aggregate capital.
4. Estimate the new autoregressive coefficients $b^{(j+1)}$ using ordinary least squares.
5. If $\|b^{(j+1)} - b^{(j)}\| < v_b$ then stop; otherwise update vector $b^{(j+1)} = \eta_b b^{(j+1)} + (1 - \eta_b)b^{(j)}$ and return to step 2.

4.3. Solving the Individual Decision Problem with Backward Iteration and Euler Equation Iteration

As far as step 2 is concerned, the backward iteration method is used. Because agents do not derive utility from leaving bequests, the optimal decisions for 99-year-old agents are:

$$k_{100}(k, a, \varepsilon, s, K, Z) = 0 \quad \text{and} \quad c_{99}(k, a, \varepsilon, s, K, Z) = k_{99} + d_{99}. \quad (21)$$

To find the decision rules for younger agents, I follow L. Maliar, S. Maliar and F. Valli (2010) and discretise the state space for the individual and the aggregate capital and look for the optimal next period's capital by iterating the Euler equation (13). More precisely, with some initial decision rule $k_{a+1}^{(0)}$ and coefficients, $b^{(j)}$ the r.h.s. of (13) is calculated on the predefined grid and used to update the decision rule. It is then iterated until convergence. To calculate the expectation term, the transition probabilities are used as well as the decision rule of the next cohort (for k_{a+2} term). This part of the solution procedure can be summarised as follows:

- 2.1. Compute the decision rules for the last generation given by (21).
- 2.2. For agents of age $a = 99 - s$:

2.2.1. Set the initial policy $k_{a+1}^{(0)} = k_{a+2}$, where k_{a+2} is taken from the next cohort policy.

2.2.2. Set $\lambda_a = 0$. Compute the new policy function $k_{a+1}^{(i+1)}$ on the predefined grid from the r.h.s. of (13). The expectation term is based on the transition probabilities P_Z and P_ε . The next period interest rate R_{a+1} is computed using the coefficients $b^{(j)}$ for the mean aggregate capital perceived laws of motion.

2.2.3. If some elements of $k_{a+1}^{(i+1)}$ lay outside the capital grid domain, set them to the boundary values.

2.2.4. Update the policy function $k_{a+1}^{(i+1)} = \eta_k k_{a+1}^{(i+1)} + (1 - \eta_k) k_{a+1}^{(i)}$.

2.2.5. If $\|k_{a+1}^{(i+1)} - k_{a+1}^{(i)}\| < v_k$, then move to step 2.2.6; otherwise return to step 2.2.2.

2.2.6. Compute the optimal consumption policy from the budget constraint (15).

2.3. Repeat step 2.2. for all $s = 1, 2, \dots, 79$.

4.4. Simulating the Model

Step 3 simulates the model. Here, I do not perform full Monte Carlo simulations with some predefined number of agents but instead follow B. Heer and A. Maussner (2009, p. 541–545) and simulate only the aggregate productivity shock. Then, for every period, the individual capital density functions are analytically computed for each skill level and age by taking advantage of the fact that the discretised individual capital level dynamics are described by a Markov chain with transition probabilities depending on the current and the future state of the economy.

To be more specific, let k^i denote i -th point on the individual capital grid and define the following probabilities:

$p_k^{(i,j)}(a, \varepsilon, s, K, Z)$ is the probability that an agent of age a , employment status ε , skill level s changes their capital stock from k^i to k^j , $i, j \in \{1, 2, \dots, n_k\}$,

$p_Z^{(i,j)}$ is the probability that the aggregate state of the economy switches from Z_i to Z_j , $i, j \in \{b, g\}$;

$p_\varepsilon^{(i,j)}(a, s, Z, Z')$ is the probability that the employment status of an agent moves from i to j , $i, j \in \{0, 1\}$.

If $k^j \leq k_{a+1}(k^i, a, \varepsilon, s, K, Z) \leq k^{j+1}$, then $p_k^{(i,j)}(a, \varepsilon, s, K, Z) = \frac{k_{a+1}(k^i, a, \varepsilon, s, K, Z) - k^j}{k^{j+1} - k^j}$ and $p_k^{(i,j+1)}(a, \varepsilon, s, K, Z) = 1 - p_k^{(i,j)}(a, \varepsilon, s, K, Z)$. The probabilities $p_\varepsilon^{(i,j)}(a, s, Z, Z')$ and $p_Z^{(i,j)}$ are taken from the matrices P_ε and P_Z .

For a given mean aggregate capital K , the evolution of an agent's capital stock can be described by the multi-dimensional Markov chain with states $G(k, a, \varepsilon, s, Z)$. The probabilities of moving from $g(k^{ik}, a, \varepsilon^i, s, Z^Z)$ to $g(k^{jk}, a+1, \varepsilon^j, s, Z^Z)$ are given

by $p_k^{(ik, jk)}(a, \varepsilon^{ie}, s, K, Z^{iZ}) \cdot q_{a, a+1} \cdot p_Z^{(iZ, jZ)} \cdot p_\varepsilon^{(ie, je)}(a, s, Z^{iZ}, Z^{jZ})$. For agents who die, the transition probabilities from $g(k^{ik}, a, \varepsilon^{ie}, s, Z^{iZ})$ to $g(k^{ik}, 20, 0, s, Z^{jZ})$ (new-born unemployed agents) equal $(1 - q_{a, a+1}) \cdot \bar{u}(20, s, Z^{jZ}) \cdot p_Z^{(iZ, jZ)} \cdot p_\varepsilon^{(ie, je)}(a, s, Z^{iZ}, Z^{jZ})$ and to $g(k^{ik}, 20, 1, s, Z^{jZ})$ (new-born employed agents) the probabilities are given by $(1 - q_{a, a+1}) \cdot (1 - \bar{u}(1, s, Z^{jZ})) \cdot p_Z^{(iZ, jZ)} \cdot p_\varepsilon^{(ie, je)}(a, s, Z^{iZ}, Z^{jZ})$, where $\bar{u}(20, s, Z^{jZ})$ denotes the mean unemployment rate for 20-year-old agents when the aggregate state of the economy is Z^{jZ} . All other transition probabilities are 0. Note that transitions between the skill level s are not allowed.

This multi-dimensional chain can easily be transformed to a one-dimensional chain with $n_k \cdot 80 \cdot 2 \cdot 3 \cdot 2$ states, where n_s represents the number of different skill levels, and the transition matrix $P(K)$. If Π_0 denotes the initial distribution of the capital across all agents, than the distribution in period t is simply given by:

$$\Pi_t = \Pi_0 \prod_{i=1}^t P(K_{i-1}). \quad (22)$$

4.5. Parametrisation

For the individual capital holdings the decision rule is approximated on the interval $[k; 50]$ with 150 grid points. Following L. Maliar, S. Maliar and F. Valli (2010), a polynomially spaced grid of 7th order is used; it is much denser near the borrowing constraint where the decision rule is far from linear. For the aggregate capital a uniformly spaced 10-point grid in interval $[5.9; 7.2]$ is used. The law of motion for the aggregate capital for $T = 4000$ periods is simulated. In this step, equispaced interval for the individual capital stock with 300 grid points is employed. The updating parameters equal: $\eta_b = 0.5$ and $\eta_k = 0.5$.

The capital distribution Markov chain has 216 000 states. Therefore, the transition matrix $P(K)$ has about $5 \cdot 10^{10}$ entries. However, it can easily be handled as a sparse matrix as the vast majority of its entries are zeros.

5. Application – the Welfare Cost of Business Cycles in Poland

5.1. Calculating the Cost

To study the welfare cost of business cycles in Poland, two versions of the economy are considered: with the aggregate fluctuations (economy A), and without (economy B). The first one coincides exactly with the model described in previous sections. The second corresponds to the model where $Z = 1$ and the labour market transition probabilities are constant in time. Following J.-O. Hairault, F. Langot and S. Osotimehin (2010) and also M. Reiter (2012), we set the labour market transition matrices in the economy without business

cycles as the equally-weighted average of the transition matrices for booms and recessions in the economy with the aggregate fluctuations. However, the differences across age and skill level are still taken into account. A more detailed description of the methodology can be found in (Acedański 2015).

To assess the welfare gain from eliminating business cycles, I compare utilities from consumption in the two economies. Two measures of the gain are considered: the expected lifetime gain for new-born agents and a one-period or a momentary gain for agents of a given age. Following R. E. Lucas (1987), the welfare gain is defined as an average percentage increase in individuals' consumption in economy B needed to achieve the same utility level as in economy A. The gains are measured for every period of the transition from economy A to economy B. The average lifetime gain λ_t for a given period t of the transition is calculated as follows:

$$\lambda_t = 100 \cdot \left[\frac{E(V_t^{(A)}(k, 20, \varepsilon, s, H_t(K)))}{E(V_t^{(B)}(k, 20, \varepsilon, s, K, Z))} \right]^{\frac{1}{1-\gamma}} - 1, \quad (23)$$

where $V_t^{(A)}$ and $V_t^{(B)}$ denotes the value functions in period t of the transition for economy A and for economy B, respectively, while $H_t(K)$ represents the law of motion for the aggregate capital on the transition path. Function H returns the aggregate capital level in period t of the transition, given the aggregate capital level K at the beginning of the transition. It takes the same autoregressive form as in (20), but without distinguishing good and bad periods. Similarly, its parameters are set using an appropriately modified version of the Krusell-Smith procedure. The expectations in (23) are calculated across all arguments of the value functions excluding age.

The one-period gain $\lambda_{a,t}$ for a cohort a is calculated in an analogous manner:

$$\lambda_{a,t} = 100 \cdot \left[\frac{E(U[c_{a,t}^{(A)}(k, a, \varepsilon, s, H_t(K))])}{E(U[c_a^{(B)}(k, a, \varepsilon, s, K, Z)])} \right]^{\frac{1}{1-\gamma}} - 1. \quad (24)$$

Now, instead of the expected value function, expected one-period utilities are compared. The expectations in (24) are calculated across all arguments of the consumption policy functions excluding age. To integrate over the aggregate capital K , I build a discrete density function for K based on a simulated long time series of the aggregate capital from economy B.

In other words, the one-period gain measures the difference in consumption for a given cohort between economies A and B. The lifetime gain equals, approximately, the expected, discounted one-period gains. The results reported below are calculated as averages across all transition periods.

5.2. Results

Table 3 provides the average lifetime gains for agents with different skill levels and initial employment status. We can see that an average new-born agent would pay 0.127% of her annual consumption every year to switch from economy A to economy B. The gain is lower for the low-skilled agents (0.094%) and slightly higher for the medium-skilled (0.135%) and the high-skilled (0.136%) ones. The differences are caused by the constant unemployment benefits that, relatively, are much higher for the low-skilled agents. From the Table 3 we can also see that the gains are moderately higher for agents who enter the labour market as unemployed.

Table 3. Average Lifetime Gains (% of lifetime consumption) for Agents with a Different Skill Level and Initial Employment Status

Specification	All	Low-skilled	Medium-skilled	High-skilled
All	0.127	0.094	0.135	0.136
Unemployed	0.136	0.102	0.143	0.151
Employed	0.117	0.091	0.125	0.116

Source: the author's calculations.

Figure 1 shows the age profiles of the one-period gains. Clearly, the gains are much higher for the young agents. For example, annual consumption of an average 20-year-old agent, measured in utility terms, is about 0.3% lower due to business cycles. For the high-skilled agent, the figure even exceeds 0.4%. For agents 35 years old and above, the one-period gains stabilise below 0.1%.

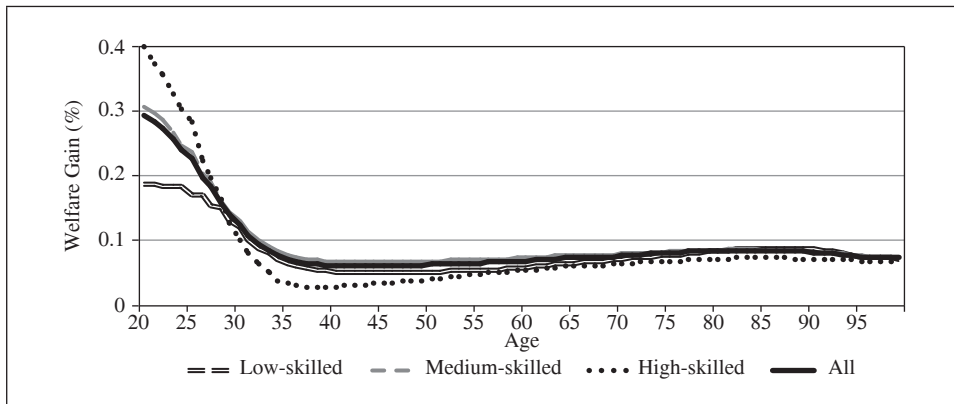


Fig. 1. One-period Gains for Cohorts and Skill Groups for the Baseline Calibration

Source: the author's own calculations.

Below, I additionally report the results for the model with the higher risk aversion $\gamma = 4$. Here the gains are doubled. The average lifetime gain equals 0.273% of the lifetime consumption and the gain for the high-skilled agents exceeds 0.5%. There are also significant differences in the lifetime gains between the medium- and the high-skilled agents, which was not the case under the baseline calibration.

Table 4. Average Lifetime Gains for Agents with a Different Skill Level and Initial Employment Status for the Higher Risk Aversion $\gamma = 4$

Specification	All	Low-skilled	Medium-skilled	High-skilled
All	0.273	0.199	0.302	0.503
Unemployed	0.296	0.211	0.323	0.579
Employed	0.215	0.169	0.234	0.338

Source: the author's calculations.

Figure 2 depicts the one-period gains' distribution across cohorts. As in the previous case, the young agents benefit the most from eliminating business cycles. The gain for the average new-born agent is close to 0.5%, while for the high-skilled one the figure reaches almost 0.9%. Interestingly, the one-period gains for 40–60-year-olds are negative, which means that these cohorts would be worse if business cycles were eliminated.




Fig. 2. One-period Gains for Cohorts and Skill Groups under the Higher Risk Aversion
Source: the author's own calculations.

6. Conclusion

In this paper I have focused on the methodology of the overlapping generation, heterogeneous agent DSGE model with aggregate risk. Using an exemplary model, I discuss the key steps of the model building procedure and provide a detailed discussion of the most popular computational algorithms used to deal with those models. Together with the codes I have provided and the literature listed in the paper, this description should allow interested researchers to conduct their own studies using this methodology.

The paper also illustrates that for the moderate cost of programming efforts, one receives a powerful tool for studying important macroeconomic problems involving various forms of consumer heterogeneity, which, as my empirical study documents, does matter as far as the gains from eliminating business cycles are concerned. I show that in Poland the gains are much higher for young and high-skilled consumers.

Finally, the popularity of the analysed models will obviously hinge on the availability of user-friendly, reliable and fast computational tools. Therefore, as computational technology and algorithms improve, we should definitely see increased interest and applications of the methodology I have discussed.

Bibliography

- Acedański J. (2007), *Metody szacowania kosztów wahań koniunkturalnych*, “Zeszyty Naukowe Akademii Ekonomicznej w Katowicach. Studia Ekonomiczne”, 46.
- Acedański J. (2014), *Pension Reforms and Welfare Gains from Eliminating Business Cycle in Poland* (in:) J. Talasova, J. Stoklasa, T. Talasek (eds), *Proceedings of 32nd International Conference Mathematical Methods in Economics*, Palacky University, Olomouc.
- Acedański J. (2015), *Youth Unemployment and Welfare Gains from Eliminating Business Cycle – The Case of Poland*, manuscript.
- Aiyagari S. R. (1994), *Uninsured Idiosyncratic Risk and Aggregate Saving*, “Quarterly Journal of Economics”, 109(3), <http://dx.doi.org/10.2307/2118417>.
- Blanchard O. (2009), *The State of Macro*, “Annual Review of Economics”, 1(1), <http://dx.doi.org/10.1146/annurev.economics.050708.142952>.
- Brzoza-Brzezina M., Kolasa M., Koloch G., Makarski K., Rubaszek M. (2013), *Monetary Policy in Non-representative Agent Economy: A Survey*, “Journal of Economic Surveys”, 27(4), <http://dx.doi.org/10.1111/j.1467-6419.2011.00710.x>.
- Chang Y., Kim S. B., Schorfheide F. (2013), *Labor-market Heterogeneity, Aggregation and Policy Invariance of DSGE Model Parameters*, “Journal of the European Economic Association”, 11(S1), <http://dx.doi.org/10.1111/j.1542-4774.2012.01098.x>.
- Del Negro M., Schorfheide F. (2013), *DSGE Model-based Forecasting* (in:) G. Elliott, A. Timmermann (eds), *Handbook of Economic Forecasting*, vol. 2, Elsevier, Amsterdam.

- Den Haan W. J., Judd K. L., Juillard M. (2010), *Computational Suite of Models with Heterogeneous Agents: Incomplete Markets and Aggregate Uncertainty*, "Journal of Economic Dynamics and Control", 34(1), <http://dx.doi.org/10.1016/j.jedc.2009.07.001>.
- Den Haan W. J. (2010), *Comparison of Solutions to the Incomplete Markets Model with Aggregate Uncertainty*, "Journal of Economic Dynamics and Control", 34(1), <http://dx.doi.org/10.1016/j.jedc.2008.12.010>.
- Grabek G., Kłos B., Koloch G. (2010), *SOE PL 2009 – Model DSGE malej otwartej gospodarki estymowany na polskich danych*, "Materiały i Studia", no. 251, NBP, Warszawa.
- Hairault J.-O., Langot F., Osotimehin S. (2010), *Matching Frictions, Unemployment Dynamics and the Cost of Business Cycles*, "Review of Economic Dynamics", 13(4), <http://dx.doi.org/10.1016/j.red.2010.05.001>.
- Heer B., Maussner A. (2009), *Dynamic General Equilibrium Modeling. Computational Methods and Applications*, 2nd ed., Springer, Berlin–Heidelberg.
- Huggett M. (1993), *The Risk-free Rate in Heterogeneous-agent Incomplete-insurance Economies*, "Journal of Economic Dynamics and Control", 17(5–6), [http://dx.doi.org/10.1016/0165-1889\(93\)90024-m](http://dx.doi.org/10.1016/0165-1889(93)90024-m).
- Kolasa M., Rubaszek M., Skrzypczyński P. (2012), *Putting the New Keynesian DGSE Model to the Real-time Forecasting Test*, "Journal of Money, Credit and Banking", 44(7), <http://dx.doi.org/10.1111/j.1538-4616.2012.00533.x>.
- Krusell P., Smith A. A. (1998), *Income and Wealth Heterogeneity in the Macroeconomy*, "Journal of Political Economy", 106(5), <http://dx.doi.org/10.1086/250034>.
- Krusell P., Smith A. A. (2006), *Quantitative Macroeconomic Models with Heterogeneous Agents* (in: R. Blundell, W. Newey, T. Pearson (eds), *Advances in Economic and Econometrics: Theory and Applications, Ninth World Congress*, Cambridge University Press, Cambridge).
- Lucas R. E. (1976), *Econometric Policy Evaluation: A Critique*, "Carnegie-Rochester Conference Series on Public Policy", 1, [http://dx.doi.org/10.1016/s0167-2231\(76\)80003-6](http://dx.doi.org/10.1016/s0167-2231(76)80003-6).
- Lucas R. E. (1987), *Models of Business Cycles*, Basil Blackwell, Oxford.
- Maliar L., Maliar S., Valli F. (2010), *Solving the Incomplete Markets Model with Aggregate Uncertainty Using the Krusell-Smith Algorithm*, "Journal of Economic Dynamics and Control", 34(1), <http://dx.doi.org/10.1016/j.jedc.2009.03.009>.
- Mankiw G. N. (2006), *Macroeconomists as Scientist and Engineer*, "Journal of Economic Perspectives", 20(4), <http://dx.doi.org/10.1257/jep.20.4.29>.
- Post Walrasian Macroeconomics. Beyond the Dynamic Stochastic General Equilibrium Model* (2006), ed. D. Colander, Cambridge University Press, Cambridge.
- Raport na temat pełnego uczestnictwa Rzeczypospolitej Polskiej w trzecim etapie Unii Gospodarczej i Walutowej* (2009), NBP, Warszawa.
- Reiter M. (2012), *On the Welfare Costs of Unemployment Fluctuations*, manuscript.
- Rubaszek M. (2012), *Mortgage Down-payment and Welfare in a Life-cycle Model*, "Bank i Kredyt", 43(4).
- Storesletten K., Telmer C. I., Yaron A. (2001), *The Welfare Cost of Business Cycles Revisited: Finite Lives and Cyclical Variation in Idiosyncratic Risk*, "European Economic Review", 45(7), [http://dx.doi.org/10.1016/s0014-2921\(00\)00101-x](http://dx.doi.org/10.1016/s0014-2921(00)00101-x).
- Storesletten K., Telmer C. I., Yaron A. (2007), *Asset Pricing with Idiosyncratic Risk and Overlapping Generations*, "Review of Economic Dynamics", 10(4), <http://dx.doi.org/10.1016/j.red.2007.02.004>.

Wróbel-Rotter R. (2013), *Estymowane modele równowagi ogólnej i wektorowa autoregresja: model hybrydowy*, "Bank i Kredyt", 44(5).

Modele międzypokoleniowe z niejednorodnymi podmiotami i zagregowanym ryzykiem w badaniach makroekonomicznych

(Streszczenie)

W pracy przedstawiono metodologię budowy międzypokoleniowych modeli DSGE z niejednorodnymi podmiotami i zagregowanym ryzykiem. Te stochastyczne modele makroekonomiczne pozwalają na uwzględnienie zróżnicowania konsumentów przede wszystkim ze względu na wiek oraz zasób majątku. Na przykładzie autorskiego modelu, który dodatkowo uwzględnia niejednorodność ze względu na status na rynku pracy oraz zdolności, pokazano sposób wyprowadzania kluczowych równań opisujących decyzje konsumpcyjne i inwestycyjne podmiotów. W pracy przedstawiono również najważniejsze algorytmy obliczeniowe stosowane do analiz omawianych modeli. Na końcu pokazano przykład zastosowania modelu do analizy kosztów wahań cyklicznych na rynku pracy w Polsce dla różnych grup konsumentów.

Słowa kluczowe: modele DSGE, modele międzypokoleniowe, niejednorodne podmioty, cykl koniunkturalny, algorytmy obliczeniowe.

Magdalena Okupniak

Studia Doktoranckie Wydziału Informatyki
i Gospodarki Elektronicznej
Uniwersytet Ekonomiczny w Poznaniu

Zastosowanie analizy blokowej w badaniu struktury polskich przedsiębiorstw

Streszczenie

Analiza układu bloków była dotąd stosowana w obszarach związanych z rolnictwem, biologią, medycyną, inżynierią bądź fizyką. W przeprowadzonym badaniu podjęto próbę przeniesienia metody analizy układu bloków na grunt ekonomii. Z tego względu głównym celem artykułu jest przedstawienie wyników analizy układu bloków w badaniu struktury i zależności zachodzących pomiędzy podstawowymi wielkościami dotyczącymi przedsiębiorstw w Polsce. Analizie poddano takie zmienne, jak liczba przedsiębiorstw, liczba pracowników czy przychody przedsiębiorstw, o których informacje zaczerpnięto z publikacji GUS pt. *Działalność przedsiębiorstw niefinansowych w Polsce w 2010 roku*.

Słowa kluczowe: analiza wewnątrzblokowa, analiza międzyblokowa, przedsiębiorstwo niefinansowe, analiza blokowa.

1. Wprowadzenie

Rozwijająca się – w ostatnim czasie w sposób bardzo widoczny – dziedzina statystyki stosowanej, w szczególności dotycząca oceny działalności przedsiębiorstw, umożliwiła pomiar i odpowiednią charakterystykę rozwoju działalności gospodarczej kraju. Co więcej, źródłem wielu przedsięwzięć i projektów samorządowych stały się cele stawiane statystyce gospodarczej przez Radę

Europejską. Im również podporządkowana została publikacja zawierająca podstawowe definicje i wskazówki metodologiczne z zakresu *business demography* [Eurostat – OECD Manual... 2007]. Sformułowane w niej wskaźniki służą syntetycznej ocenie gospodarki na poziomie kraju, zatrudnienia, ochrony środowiska, edukacji oraz kwestii społecznych i regionalnych, co umożliwia dokonywanie porównań między krajami Unii Europejskiej. Zarówno w Polsce, jak i w innych krajach Wspólnoty prowadzone są badania, których celem jest zaproponowanie metodyki pozwalającej na dostarczenie informacji z zakresu statystyki gospodarczej na niskim poziomie agregacji. Niniejszy artykuł nawiązuje do tego nurtu badań. Jego celem jest przeanalizowanie zależności pomiędzy takimi zmiennymi, jak liczba przedsiębiorstw, liczba pracowników i przychody przedsiębiorstw, a zmiennymi charakteryzującymi rodzaj prowadzonej działalności, klasę wielkości przedsiębiorstwa, województwo. Do realizacji tak sformułowanego celu zaproponowano wykorzystanie stosunkowo rzadko stosowanej metody analizy blokowej, która dotąd najczęściej wykorzystywana była w obszarach związanych z rolnictwem, biologią czy medycyną [Oktaba 1974].

2. Ogólne założenia metody

Głównym założeniem analizy blokowej jest posiadanie danych dla jednostek eksperymentalnych, które można podzielić na b grup (bloków) tak, by zawarte w nich jednostki jak najmniej różniły się między sobą w obrębie danej grupy. Przyjmuje się, że każdy blok zawiera k_j jednostek ($j = 1, \dots, b$). Na tak przygotowanych danych stosowanych jest v obiektów, które zostały losowo przypisane do poszczególnych jednostek eksperymentalnych. Każdy z obiektów pojawia się w badaniu (jest replikowany) r_i razy ($i = 1, \dots, v$) [Raghavarao i Padgett 2005]. Warto zwrócić uwagę na to, że obiektami mogą być zarówno różne czynniki, jak i poziomy jednego stosowanego czynnika.

Zapis formalny modelu doświadczenia można przedstawić następująco:

$$Y = \mu \mathbb{1}_n + \mathbf{\Delta}' \underline{\tau} + \mathbf{D} \underline{\beta}' + \varepsilon, \quad (1)$$

gdzie:

Y – wartość badanej zmiennej,

μ – średnia ogólna,

$\underline{\tau}$ – wektor efektów obiektowych,

$\underline{\beta}$ – wektor efektów blokowych,

ε – wektor błędów losowych,

$\mathbf{\Delta} = (\delta_{is})$, gdzie dla s -tej obserwacji ($s = 1, \dots, n$) mamy:

$$\delta_{is} = \begin{cases} 0 & s\text{-ta obserwacja nie jest związana z obiektem } i, \\ 1 & s\text{-ta obserwacja dotyczy } i\text{-tego obiektu.} \end{cases}$$

$D = (\gamma_{js})$, gdzie dla s -tej obserwacji ($s = 1, \dots, n$) mamy:

$$\gamma_{js} = \begin{cases} 0 & s\text{-ta obserwacja nie pochodzi z } j\text{-tego bloku,} \\ 1 & s\text{-ta obserwacja pochodzi z } j\text{-tego bloku.} \end{cases}$$

Warto zwrócić uwagę na to, że w doświadczeniu prowadzonym metodą układu bloków nie zachodzi interakcja między efektem blokowym a efektem obiektowym. Ponadto w metodzie tej normalność rozkładu badanej cechy nie jest wymagana, a o błędach losowych ε zakładamy, że:

- 1) ε jest wektorem nieskorelowanych błędów losowych,
- 2) $\varepsilon \sim N(0_n, \sigma^2 I_n)$.

Własności wielowymiarowego rozkładu normalnego zostały szeroko omówione w publikacji [Krzyśko 2011].

Wprowadzenie pojęć właściwych dla analizy wewnątrz- i międzyblokowej wymaga zdefiniowania pojęcia kontrastu. Przez kontrast będziemy rozumieć liniową funkcję parametryczną $\ell' \underline{\rho}$ wektora $\underline{\rho} = [\rho_1, \rho_2, \dots, \rho_d]$, jeśli $\ell' \mathbb{1}_d = 0$. Kontrast nazywamy kontrastem elementarnym, jeśli ℓ ma tylko dwa niezerowe elementy i są one równe -1 i 1 [Raghavarao i Padgett 2005].

3. Analiza wewnątrzblokowa

Metoda ta ma na celu eliminację efektu podziału jednostek eksperymentalnych na bloki i odpowiedź na pytanie, czy efekty pochodzące z zastosowanych (rozważanych) obiektów mają wpływ na wyniki doświadczenia. Z uwagi na fakt, że każdy parametr z osobna nie jest estymowalny, to analizowany jest poniższy układ hipotez dotyczący ich kontrastów:

$$\begin{aligned} H_0: \tau_1 - \tau_v = \tau_2 - \tau_v = \dots = \tau_{v-1} - \tau_v = 0, \\ H_1: \sim H_0. \end{aligned} \quad (2)$$

Powołując się na następujące twierdzenie [Raghavarao i Padgett 2005], możemy łatwo określić rząd macierzy C , która odgrywa główną rolę w obliczaniu wartości statystyki testowej Walda weryfikującej układ hipotez (2): wszystkie elementarne kontrasty efektów obiektowych są estymowalne wtedy i tylko wtedy, gdy $rz(C) = v - 1$.

Statystyka Walda określona jest następującym wzorem [Raghavarao i Padgett 2005]:

$$F = \frac{\frac{Q' C^{-1} Q}{v-1}}{\frac{R_0^2}{n-b-v+1}}, \quad (3)$$

gdzie:

$$\begin{aligned}
 C &= R - NK^{-1}N', \\
 C^- &\text{ oznacza } g\text{-odwrotność macierzy } C, \\
 Q &= T - NK^{-1}B, \\
 R_0^2 &= SS_T - SS_B - SS_{T|B}, \\
 K &= \text{diag}(k_1, k_2, \dots, k_b), \\
 R &= \text{diag}(r_1, r_2, \dots, r_v), \\
 B &= (B_1, \dots, B_b)', \text{ gdzie } B_j = \sum_{i=1}^v Y_{ij}, \\
 T &= (T_1, \dots, T_v)', \text{ gdzie } T_i = \sum_{j=1}^b Y_{ij}.
 \end{aligned}$$

Macierz N jest macierzą incydencji wymiarów $v \times b$.

4. Analiza międzyblokowa

Badanie prowadzone tą metodą ma na celu eliminację efektu pochodzącego z zastosowania danego obiektu i rozważenie problemu, czy podział jednostek na możliwie jednorodnie grupy wpływa na wyniki doświadczenia. Ze względu na fakt, że parametry efektów blokowych nie są estymowalne z osobna, analizowany jest poniższy układ hipotez dotyczący ich kontrastów:

$$\begin{aligned}
 H_0: \beta_1 - \beta_b = \beta_2 - \beta_b = \dots = \beta_{b-1} - \beta_b = 0, \\
 H_1: \sim H_0.
 \end{aligned} \tag{4}$$

Powołując się na następujące twierdzenie [Raghavarao i Padgett 2005], możemy łatwo określić rząd macierzy D^* , która odgrywa ważną rolę w wyznaczaniu wartości statystyki testowej Walda, służącej do weryfikacji układu hipotez (4): wszystkie elementarne kontrasty efektów blokowych są estymowalne wtedy i tylko wtedy, gdy $\text{rz}(D^*) = b - 1$.

Statystyka Walda dla analizy międzyblokowej opisana jest następującym wzorem [Raghavarao i Padgett 2005]:

$$F = \frac{\frac{P(D^*)^- P}{b-1}}{\frac{R_0^2}{n-b-v+1}}, \tag{5}$$

gdzie:

$$\begin{aligned}
 D^* &= K - NR^{-1}N, \\
 (D^*)^- &\text{ oznacza } g\text{-odwrotność macierzy } D^*,
 \end{aligned}$$

$$P = B - NR^{-1}T,$$
$$R_0^2 = SS_T - SS_{Tr} - SS_{B|Tr}.$$

5. Schemat i wyniki przeprowadzonego badania

Jednym z najważniejszych źródeł informacji, na podstawie których można dokonać oceny zmian sytuacji gospodarczej kraju, są wyniki badań prowadzonych w ramach statystyki publicznej. Z perspektywy prowadzonego badania warto zwrócić uwagę na bogate źródło informacji, jakim jest Bank Danych Lokalnych Głównego Urzędu Statystycznego, a także szereg publikacji w zakresie problematyki podmiotów gospodarczych, ich wyników finansowych, rynku pracy czy wynagrodzeń. Źródła te zawierają informacje opracowane na podstawie sprawozdawczości statystycznej czy badań szczegółowo wymienionych w *Programie badań statystycznych statystyki publicznej* (zob. np. [Rozporządzenie Rady Ministrów z dnia 9 sierpnia 2013 r. ...]) publikowanego na każdy rok kalendarzowy przez Radę Ministrów RP. W niniejszym artykule wykorzystano dane zawarte w publikacji GUS [*Działalność przedsiębiorstw niefinansowych...* 2011]. Opracowanie zawiera m.in. wyniki oszacowane na podstawie reprezentacyjnego badania mikroprzedsiębiorstw prowadzonego na podstawie formularza SP-3 (sprawozdania o działalności gospodarczej przedsiębiorstw). Dodatkowo w publikacji prezentowane są wyniki pełnego badania przedsiębiorstw zatrudniających co najmniej 10 osób, zbierane na podstawie sprawozdania SP (rocznej ankiety przedsiębiorstw) i F-01 (statystycznego sprawozdania finansowego). Przedmiotem niniejszego badania były przedsiębiorstwa niefinansowe, czyli podmioty zaklasyfikowane (niezależnie od liczby pracujących w nich osób) do odpowiednich sekcji ustalonych w ramach polskiej klasyfikacji działalności pochodzącej z 2007 r.

Celem przeprowadzonej analizy była weryfikacja hipotez zakładających istnienie zależności pomiędzy klasą wielkości przedsiębiorstwa bądź jego lokalizacją (uwzględniono przekrój województw) a wybranymi, podstawowymi charakterystykami działalności podmiotów gospodarczych, takimi jak liczba przedsiębiorstw, liczba pracowników czy przychody przedsiębiorstw.

Na potrzeby przeprowadzonego badania przyjęto następujące definicje dla zastosowanej metody:

1. Obiekty:

- a) klasy wielkości przedsiębiorstwa:
 - mikro (do 9 pracowników),
 - małe (od 10 do 49 pracowników),
 - średnie (od 50 do 249 pracowników),
 - duże (co najmniej 250 pracowników);

b) rodzaj działalności przedsiębiorstwa:

- przemysł,
- budownictwo,
- handel i naprawa pojazdów,
- transport i gospodarka magazynowa,
- zakwaterowanie i gastronomia,
- informacja i komunikacja,
- obsługa rynku nieruchomości,
- działalność profesjonalna, naukowa i techniczna,
- administrowanie i działalność wspierająca,
- edukacja,
- opieka zdrowotna i pomoc społeczna,
- kultura i rekreacja,
- pozostała działalność;

2. Bloki – województwa.

W analizie przyjęto następujące zmienne charakteryzujące przedsiębiorstwa:

- 1) liczba przedsiębiorstw,
- 2) liczba pracowników,
- 3) przychody przedsiębiorstw (w mln zł).

W wyniku przeprowadzonego badania, czyli dokonania analizy wewnątrz- i międzyblokowej dla liczby przedsiębiorstw oraz liczby pracowników przedsiębiorstwa w przekroju województw i rodzaju działalności przedsiębiorstwa oraz dla przychodów w przekroju województw i klasy wielkości przedsiębiorstwa, otrzymano szacunki, które przedstawiono w tabeli 1.

Tabela 1. Wyniki analizy blokowej dla przedsiębiorstw niefinansowych w Polsce w 2010 r.

Analiza wewnątrzblokowa				Analiza międzyblokowa			
F	wartość p	df_1	df_2	F	wartość p	df_1	df_2
Liczba przedsiębiorstw w przekroju województw i klasy wielkości przedsiębiorstwa							
39,076	0,000	3	45	1,12	0,367	15	45
Liczba przedsiębiorstw w przekroju województw i rodzaju działalności przedsiębiorstwa							
40,773	0,000	12	180	12,879	0,000	15	180
Liczba pracowników w przekroju województw i klasy wielkości przedsiębiorstwa							
35,133	0,000	3	45	15,451	0,000	15	45
Liczba pracowników w przekroju województw i rodzaju działalności przedsiębiorstwa							
24,788	0,000	12	180	8,616	0,000	15	180


cd. tabeli 1

Analiza wewnątrzblokowa				Analiza międzyblokowa			
F	wartość p	df_1	df_2	F	wartość p	df_1	df_2
Przychody przedsiębiorstw w przekroju województw i klasy wielkości przedsiębiorstwa							
4,806	0,005	3	45	6,297	0,000	15	45

Objaśnienie: wartości df_1 i df_2 oznaczają liczbę stopni swobody dla statystyki F .

Źródło: opracowanie własne na podstawie [Działalność przedsiębiorstw niefinansowych... 2011].

Ze względu na wyróżniające się dwa województwa – zachodniopomorskie i opolskie – oraz główny cel maksymalizacji przychodów rozważany np. z punktu widzenia potencjalnych inwestorów na danym obszarze czy władz samorządu terytorialnego na szczególną uwagę zasługuje udział procentowy przychodów przedsiębiorstw według klasy wielkości przedsiębiorstwa i województwa (por. rys. 1).



Rys. 1. Procentowy udział przychodów przedsiębiorstw według klasy wielkości przedsiębiorstw i województw

Źródło: opracowanie własne na podstawie [Działalność przedsiębiorstw niefinansowych... 2011].

Przychody mikro- i małych przedsiębiorstw stanowią średnio 40% przychodów osiągniętych w danym województwie w przypadku działalności gospodarczej. Proporcje przychodów mikro-, małych i średnich przedsiębiorstw dla wszystkich województw są bardzo zbliżone. Przeciętnie 25% przychodów osiągają mikroprzedsiębiorstwa, 16% przychodów przedsiębiorstwa małe, a 21% – przedsiębiorstwa średnie.

6. Podsumowanie

Na podstawie wyników przeprowadzonej analizy blokowej (przyjmując w badaniu $\alpha = 0,05$ poziom istotności) można sformułować następujące wnioski:

1. Istnieje zależność pomiędzy lokalizacją przedsiębiorstw w województwach a ich wielkością, która zmierzona została za pomocą liczby przedsiębiorstw. To z kolei oznacza, że liczba pracowników przedsiębiorstwa ma ścisły związek z liczbą podmiotów prowadzących działalność w danym województwie. Wyniki analizy wskazują ponadto, że lokalizacja danej firmy nie wpływa na zróżnicowanie liczby przedsiębiorstw pod względem klasy ich wielkości.

2. Na liczbę przedsiębiorstw w przekroju województw ma wpływ rodzaj prowadzonej działalności określonej w ramach polskiej klasyfikacji działalności. To może świadczyć o rozwoju poszczególnych gałęzi działalności gospodarczej w zależności od regionu.

3. Lokalizacja przedsiębiorstwa w danym województwie wpływa na liczbę pracowników przedsiębiorstwa w przekroju rodzaju działalności przedsiębiorstwa.

4. Na liczbę pracowników przedsiębiorstwa w przekroju województw wpływa rodzaj prowadzonej działalności. Świadczy to o sytuacji, w której zarówno pracujący, jak i poszukujący pracy muszą dostosowywać swoje kompetencje do rodzaju działalności firmy funkcjonującej na danym terenie.

5. Badanie potwierdza intuicyjne założenie, że klasa wielkości przedsiębiorstwa wpływa na jego dochody. Ponadto na podstawie przeprowadzonego badania można stwierdzić istotne różnice w zakresie osiągniętych dochodów wynikające z położenia podmiotu gospodarczego.

6. Analizując rys. 1, można łatwo zauważyć zbliżony udział średnich i dużych przedsiębiorstw w przychodach województw. Przykładem mogą być województwa zachodniopomorskie i opolskie. Ponadto w wymienionych województwach przychody mikroprzedsiębiorstw przewyższają osiągnięcia dużych przedsiębiorstw, a działalność dużych przedsiębiorstw generuje najmniejsze przychody.

Literatura

- Działalność przedsiębiorstw niefinansowych w Polsce w 2010 roku* [2011], GUS, Warszawa.
- Eurostat – OECD Manual on Business Demography Statistics. Methodologies and Working Papers* [2007], European Communities, OECD, Luxembourg.
- Krzyśko M. [2011], *Wielowymiarowa analiza statystyczna*, Uniwersytet im. Adama Mickiewicza w Poznaniu, Poznań.
- Oktaba W. [1974], *Elementy statystyki matematycznej i metodyka doświadczalnictwa*, Państwowe Wydawnictwo Naukowe PWN, Warszawa.
- Raghavarao D., Padgett L.V. [2005], *Block Designs*, World Scientific, Singapore.
- Rozporządzenie Rady Ministrów z dnia 9 sierpnia 2013 r. w sprawie programu badań statystycznych statystyki publicznej na rok 2014, Dz.U. z 2013 r., poz. 1159.

Application of Block Analysis to the Study of Structure Polish Enterprises

(Abstract)

Intra- and interblock analysis has been used in agriculture, biology, medicine, engineering and the physical sciences. In this research I attempt to use block analysis in the field of economics, to examine the structure of Polish enterprises and the relationships that exist between them. The study was based on such variables as: number of enterprises, persons employed and revenues. Data came from a Central Statistical Office of Poland publication entitled *Activity of non-financial enterprises in 2010*.

Keywords: intrablock analysis, interblock analysis, non-financial company, block analysis.

Łukasz Klimczak

Studia Doktoranckie Wydziału Ekonomii
i Stosunków Międzynarodowych
Uniwersytet Ekonomiczny w Krakowie

Model grawitacyjny jako narzędzie analizy handlu zagranicznego*

Streszczenie

Celem pracy jest odpowiedź na pytanie, czy standardowy model grawitacyjny może być efektywnym narzędziem analizy handlu, czy też istnieje potrzeba uzupełnienia go o dodatkowe miary dystansu. Badanie obejmuje region Bałkanów Zachodnich w latach 1995–2012.

Wyniki estymacji modelu standardowego są porównywane do wyników modelu rozszerzonego o następujące zmienne: efekt granicy, efekty działań wojennych, mniejszości narodowe, różnice w rozwoju, dystans religijny i komunikacyjny, umowy o wolnym handlu oraz zasób BIZ. W celu sprawdzenia odporności wyników, poza estymacją typu *pooled*, szacowane są modele z jedno- i dwukierunkowymi efektami stałymi, z efektami losowymi, a także zawierające alternatywne zmienne.

Rezultaty badania pokazują, że istnieją liczne determinanty handlu specyficzne dla regionu, które powinny być uwzględnione w modelu. Zaliczyć do nich można w szczególności podobieństwo struktur wyznaniowych i językowych, wojny czy porozumienia o wolnym handlu.

Słowa kluczowe: Bałkany Zachodnie, model grawitacyjny, handel międzynarodowy, determinanty handlu.

* Artykuł powstał w wyniku realizacji projektu sfinansowanego ze środków Narodowego Centrum Nauki przyznanych na podstawie decyzji numer DEC-2013/11/N/HS4/03642. Autor pragnie wyrazić podziękowania Panu dr. Sławomirowi Śmiechowi z Uniwersytetu Ekonomicznego w Krakowie za cenne uwagi dotyczące niniejszego badania.

1. Wprowadzenie

Model grawitacyjny jest narzędziem często wykorzystywanym w analizach handlu zagranicznego z uwagi na swój intuicyjny charakter, a także zdolność do wyjaśniania determinant handlu w badaniach empirycznych. W swojej formie podstawowej model ten miał wyjaśniać wartość handlu za pomocą „mas” partnerów handlowych oraz „dystansu” pomiędzy nimi, co stanowiło analogię do równania grawitacji Newtona (por. [Tinbergen 1962, Pöyhönen 1963, Linneman 1966]). Masa była zazwyczaj przybliżana przez PKB i (lub) populację badanych krajów, natomiast dystans – poprzez fizyczną odległość pomiędzy ich stolicami albo najbardziej rozwiniętymi regionami gospodarczymi, choć występowały w tym charakterze także inne zmienne (por. [Kandogan 2009, Wydymus 2012]). Jako że model okazał się dobrym narzędziem w wyjaśnianiu determinant handlu, jego różne postaci ewoluowały, przynosząc szereg nowych zmiennych dodawanych do prawej strony równania. Nasuwają się więc dwa pytania:

1) czy, a jeśli tak, to jakie dodatkowe zmienne powinny znaleźć się w modelu?

2) jaka jest ich relacja do głównego konceptu modelu grawitacji, wyjaśniającego wartość handlu przez masę oraz dystans?

Odpowiedzią na pierwsze z powyższych pytań jest zdolność modelu „standardowego” (tzn. niezawierającego zmiennych dodatkowych) do wyjaśniania wartości handlu. Jeżeli PKB i populacja partnerów handlowych oraz dystans fizyczny pomiędzy nimi wyjaśniałyby go w stopniu wystarczającym, nie istniałyby przesłanki do wskazywania dodatkowych czynników potencjalnie wpływających na handel. Przeprowadzona analiza pokazuje jednak, że włączenie dodatkowych zmiennych skutkuje dużo lepszym dopasowaniem modelu do danych empirycznych.

Odpowiadając na drugie pytanie, należy zaznaczyć, że istnieje potrzeba skategoryzowania wszystkich zmiennych określających dystans w grupach reprezentujących jego fizyczne, ekonomiczne, polityczne, kulturowe, komunikacyjne oraz historyczne aspekty. Pomoże to w lepszym zrozumieniu ich natury oraz ich skutków.

Region Bałkanów Zachodnich (dalej BZ) wydaje się dobrym obiektem w badaniach nad znaczeniem dla handlu czynników natury historyczno-kulturowej, ponieważ charakteryzuje się następującymi cechami:

– jego mieszkańcy są wyznawcami trzech wielkich religii (katolicyzmu, prawosławia i islamu),

– jego mieszkańcy mówią zasadniczo podobnymi, choć nie takimi samymi językami (nie licząc Albanii)¹,

– w niedalekiej przeszłości region ten był obszarem działań wojennych²,

– występują znaczące różnice w poziomie rozwoju tego regionu³.

Nie można pominąć również faktu, że region Bałkanów Zachodnich odgrywał w ostatnich latach niezwykle istotną rolę w polityce zagranicznej Unii Europejskiej [Molendowski 2011], a wszystkie państwa wchodzące w jego skład biorą udział w procesie integracji z Unią⁴.

Celem przeprowadzonej analizy jest odpowiedź na pytanie, czy w przypadku państw regionu Bałkanów Zachodnich można zdefiniować inne czynniki wpływające na wartość handlu wzajemnego niż te zawarte w standardowej postaci modelu grawitacyjnego, a jeżeli tak, to jakie.

W artykule przybliżono pojęcia masy i dystansu w handlu oraz zaprezentowano zmienne dodatkowe ujęte w modelu. Przedstawiono matematyczne postaci modelu standardowego oraz modelu rozszerzonego. Zaprezentowano wyniki analizy regresji oraz ich interpretację. Następnie zbadano odporność wyników zarówno na zmienioną specyfikację ekonometryczną modelu, jak i na zastosowanie alternatywnych zmiennych objaśniających. W podsumowaniu przedstawiono główne wnioski z przeprowadzonej analizy oraz rekomendacje dotyczące dalszych badań.

2. Wybrane ujęcia masy oraz dystansu w rozszerzonych modelach grawitacyjnych

Założenia teorii grawitacji w handlu opierają się na dwóch kluczowych pojęciach: masie oraz dystansie, które określają zbiór zmiennych mających charakteryzować odpowiednio:

¹ Serbski, chorwacki i bośniacki należą do południowo-zachodnich języków słowiańskich, natomiast macedoński – do południowo-wschodnich (za: www.ethnologue.com, dostęp: 30.09.2013).

² Począwszy od pierwszego roku analizy, a więc 1995, region doświadczył konfliktów zbrojnych pomiędzy Bośnią a Serbią (1995), Chorwacją a Serbią (1995), Kosowem a Serbią (1998, 1999) oraz Kosowem a Macedonią (2001) [UCDP Datasets... 2013]. W niniejszym badaniu konflikty, w których Kosowo jest jedną ze stron, są przypisane Albanii w związku z bliskością etniczną obu narodów.

³ W 1995 r. Bośnia miała najniższy poziom PKB *per capita* (w cenach stałych z 2005 r.) w całym regionie – 904 USD, natomiast Chorwacja najwyższy – 6536 USD. W 2012 r. najniższą wartością PKB *per capita* charakteryzowała się Serbia – 3348 USD, natomiast najwyższą ciągle Chorwacja – 10 346 USD (za: unctadstat.unctad.org, dostęp: 19.11.2013).

⁴ Chorwacja jako pierwszy z krajów Bałkanów Zachodnich została przyjęta do Unii w 2012 r.

- każdy z dwóch krajów uczestniczących w bilateralnej wymianie handlowej,
- różnorakie relacje, w jakich się te kraje znajdują⁵.

Zmienne określające masę powinny z jednej strony odzwierciedlać potencjał podażowy kraju eksportera, a z drugiej – potencjał popytowy kraju importera [Czarny i Folfas 2011]. W przeprowadzonej analizie przyjęto dla obu powyższych przypadków podział tych zmiennych na zmienne określające potencjał:

- gospodarczy (np. PKB, PKB *per capita*),
- ludnościowy (np. populacja, zasób siły roboczej, odsetek ludności z wyższym wykształceniem),
- technologiczny (np. zasób BIZ, *unit export value*).

Znacznie częściej w literaturze przedmiotu omawiane są jednakże analizy czynników określających relację pomiędzy dwoma konkretnymi krajami, a więc określające dystans je dzielący. Podział zmiennych reprezentujących dystans wprowadzono w pracy *Ekonometria przestrzenna* [1991], dzieląc odległości na:

- fizyczną,
- czasową (czas konieczny do pokonania danej odległości),
- ekonomiczną (nakład pracy niezbędny do pokonania dystansu wyrażony np. jako koszt transportu⁶),
- społeczną (np. liczba wolnych miejsc pracy czy natężenie rozmów telefonicznych),
- polityczną (jako zmienna 0–1, oznaczająca preferowanie stosunków/relacji między danymi krajami).

Należy przy tym zwrócić uwagę, że pierwsze trzy typy dystansu są *de facto* różnymi miarami tej samej charakterystyki, czyli odległości fizycznej. Niezależnie, czy mierzona w kilometrach, w godzinach koniecznych na jej pokonanie, czy też w złotówkach, które trzeba wydać, ażeby przesłać partię towaru, są to ciągle charakterystyki odległości fizycznej. Dwa ostatnie typy odległości stanowią natomiast odrębne kategorie.

W literaturze anglojęzycznej punktem odniesienia są często prace J.E. Andersona i E. van Wincoopa [2003, 2004], w których przedstawiono i uporządkowano znaczną część wcześniejszych ustaleń badaczy w tym zakresie, przyczyniając się jednocześnie do rozpoczęcia szerszej dyskusji na temat kosztów w handlu. Powołując się na opisany przez J. McCalluma [1995] tzw. efekt granicy (*border*

⁵ O problemach związanych z właściwym doбором zmiennych charakteryzujących masę oraz dystans pisał m.in. S. Wydymus [2012].

⁶ Wśród współczesnych analiz handlu zagranicznego wykorzystujących model grawitacyjny problematykę związaną z transportem towarów jako podstawę konstrukcji miernika odległości ekonomicznej podjęli m.in. N. Drzewoszewska, M.B. Pietrzak i J. Wilk [2013].

effect), autorzy poszerzają analizę na większą liczbę krajów oraz, w szczególności, prezentują nowy podział kosztów (odległości) na:

– polityczne (*policy barrier*, bazujące na stawkach celnych i ograniczeniach pozataryfowych),

– transportowe (*transport costs*; bezpośrednio – stawki transportowe i ubezpieczeniowe, pośrednio – związane z procesem przygotowania produkcji eksportowej),

– dystrybucji hurtowej i detalicznej (*wholesale and retail distribution costs*).

J.E. Anderson i E. van Wincoop wyszczególniają dystans związany z posiadaniem lub nieposiadaniem wspólnego języka, a także przedstawiają prace analizujące odległość jako poziom dyspersji cenowej pomiędzy krajami, która to charakterystyka obejmować ma całokształt kosztów-odległości pomiędzy krajami. Z drugiej strony postulują oni włączanie do analiz zmiennej *multilateral trade resistance* (MTR)⁷, która odnosi się do relatywnych barier w handlu [Anderson i van Wincoop 2003, 2004].

Za kolejne kamienie milowe w badaniach nad znaczeniem odległości w handlu można uznać prace J. Melitza [2008] oraz J. Melitza i F. Toubala [2012]. W odróżnieniu od większości wcześniejszych badań, stawiających w centrum uwagi głównie bariery geograficzne oraz polityczne, autorzy ci kierują swą uwagę na bariery komunikacyjne i kulturowe. W wielu wcześniejszych pracach kwestia wpływu języka na handel już się pojawiała, była ona jednakże sprowadzana najczęściej do zmiennej binarnej odzwierciedlającej ten sam język urzędowy. Autorzy obu przywołanych wyżej prac wprowadzają w nich bardziej kompleksowe miary możliwości komunikacyjnych pomiędzy obywatelami poszczególnych krajów⁸.

W przeprowadzonej analizie przyjęto podział dystansu (lub też odległości, barier czy kosztu) pomiędzy krajami na sześć kategorii:

1) dystans fizyczny – związany z geograficznym położeniem jednego kraju względem drugiego. Nie ma przy tym znaczenia sposób jego mierzenia (kilometry, godziny potrzebne na jego pokonanie czy złotówki, które trzeba wydać

⁷ Popularną miarą zmiennej ogólnego oddalenia (*remoteness variable*) lub wielostronnego oporu (*multilateral resistance*) danego kraju jest wskaźnik wyrażony wzorem:

$$Rem_i = \sum_j \frac{dist_{ij}}{(PKB_j / PKB_{ROW})}$$

gdzie licznik stanowi dystans fizyczny pomiędzy dwoma krajami,

natomiast mianownik to relacja PKB kraju-partnera do PKB „reszty świata” [Gomez i Milgram 2009].

⁸ Równoległa dyskusja nad typologią odległości w handlu toczyła się w literaturze z obszaru zarządzania (por. [Berry i in. 2010, Ellis 2007, Ghemawat 2001, Hofstede 1980, House i in. 2004, Williamson 1985]).

na przemieszczenie ładunku). Do dystansu fizycznego zaliczono także kwestie związane z istnieniem granic państwowych⁹;

2) dystans polityczny – związany z efektami decyzji politycznych, np. członkostwo w WTO, przynależność do strefy wolnego handlu, unii celnej bądź walutowej;

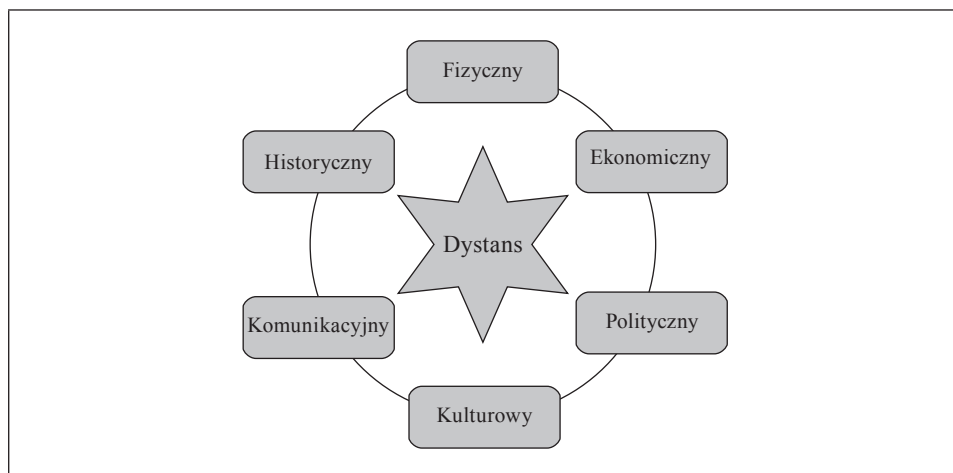
3) dystans ekonomiczny – wyrażający zróżnicowanie poziomu rozwoju gospodarczego badanych krajów lub też ich wyposażenia w czynniki produkcji, np. różnica w poziomie PKB *per capita*, różnica w *export unit value*;

4) dystans kulturowy – określający wpływ różnorodności kulturowej na handel, w tym różnorodności religijnej, np. podobieństwo struktur wyznaniowych, liczba lub procent imigrantów z kraju eksportera;

5) dystans komunikacyjny – odzwierciedlający problemy związane z brakiem możliwości bezpośredniej komunikacji, np. obowiązujący język urzędowy, możliwość bezpośredniej komunikacji;

6) dystans historyczny – pokazujący, jak wspólna historia determinuje obecne relacje handlowe, np. dawne relacje kolonialne, prowadzenie działań wojennych, dawna wspólna państwowość.

Główne elementy powyższego podziału przedstawiono na rys. 1.



Rys. 1. Rodzaje dystansu w handlu

Źródło: opracowanie własne.

⁹ Odrębny kierunek badań światowych wskazuje także na konieczność uwzględniania jako zmiennej kontrolnej tzw. dystansu wewnętrznego (*internal distance*). Jest to związane z faktem, że kwestie odległości fizycznej pomiędzy krajami mogą być zaburzone przez geograficzną wielkość ich samych (por. [Head i Mayer 2000]). Popularną miarę dystansu wewnętrznego wprowadził E. Leamer [1997], określając go jako pierwiastek kwadratowy z powierzchni kraju.

W przeprowadzonej analizie zmienne dodatkowe, rozszerzające model standardowy, przypisano do sześciu zaproponowanych kategorii dystansu. Ogólny opis poszczególnych zmiennych określających dystans zawartych w modelu rozszerzonym przedstawiono w tabeli 1, natomiast bardziej szczegółową ich charakterystykę zawierają prace Ł. Klimczaka [2014] oraz J. Trivić i Ł. Klimczaka [2015]. Matematyczną postać wskaźników *RELIG* oraz *LANG*, a także wskaźnika *RELIG 1* estymowanego w punkcie 5 artykułu przedstawiają poniższe wzory:

1) matematyczna postać zmiennej *RELIG*:

$$RELIG_{ij} = 1 - \sum_{k=1, \dots, n} \frac{|R_{ik} - R_{jk}|}{2}, \quad (1)$$

gdzie:

$RELIG_{ij}$ – wskaźnik podobieństwa struktur wyznaniowych krajów i i j ,

R_{ik} – udział osób należących do grupy wyznaniowej k w kraju i ,

R_{jk} – udział osób należących do grupy wyznaniowej k w kraju j ;

2) matematyczna postać wskaźnika *LANG*:

$$LANG_{ij} = \sum_{\substack{k=1, \dots, n \\ l=1, \dots, n}} S_{ik} \cdot S_{jl} \cdot sim_{kl}, \quad (2)$$

gdzie:

$LANG_{ij}$ – wskaźnik podobieństwa językowego krajów i i j ,

S_{ik} – udział osób posługujących się k -tym językiem w kraju i ,

S_{jl} – udział osób posługujących się l -tym językiem w kraju j ,

sim_{kl} – stopień pokrewieństwa języków k i l , przyjmujący wartości 0; 0,25; 0,5; 0,75 bądź 1 w zależności od wzajemnego położenia na tzw. drzewie języków zaczerpniętym ze strony www.ethnologue.com (dostęp 19.11.2013);

3) matematyczna postać wskaźnika *RELIG 1*:

$$RELIG 1_{ij} = \sum_{k=1, \dots, n} R_{ik} \cdot R_{jk}, \quad (3)$$

gdzie:

$RELIG 1_{ij}$ – wskaźnik podobieństwa struktur wyznaniowych krajów i i j ,

R_{ik} – udział osób należących do grupy wyznaniowej k w kraju i ,

R_{jk} – udział osób należących do grupy wyznaniowej k w kraju j .

Tabela 1. Zmienne określające dystans zastosowane w modelu rozszerzonym

Nazwa zmiennej	Rodzaj dystansu	Opis zmiennej	Źródło danych
<i>DIST</i>	fizyczny	określa odległość geograficzną pomiędzy stolicami danych krajów (<i>great circle distance</i>)	CEPII
<i>BORDER</i>	fizyczny	przyjmuje wartość 1 w przypadku, gdy kraje sąsiadują ze sobą	atlas geograficzny
<i>FTA</i>	polityczny	przyjmuje wartość 1, gdy kraje mają podpisaną umowę o wolnym handlu	różne źródła
<i>PERCAP_</i> <i>DIFF</i>	ekonomiczny	wartość bezwzględna z różnicy w poziomie PKB <i>per capita</i> obu krajów	UNCTAD STAT
<i>MINOR</i>	kulturowy	liczebność diaspory kraju eksportera w kraju importera	różne źródła
<i>RELIG</i>	kulturowy	wskaźnik wyrażający podobieństwo struktur wyznaniowych (wzór (1))	worldmapper.org
<i>LANG</i>	komunikacyjny	wskaźnik wyrażający prawdopodobieństwo, że dowolnie wybrane dwie osoby będą mogły się porozumieć, ważony podobieństwem języków (wzór (2))	ethnologue.com
<i>WAR*</i>	historyczny	przyjmuje wartość 1 w przypadku, gdy oba kraje w danym roku były w stanie wojny	UCDP Datasets
<i>WAR + X*</i>	historyczny	przyjmuje wartość 1 w przypadku, gdy oba kraje <i>x</i> lat przed analizowanym rokiem były w stanie wojny	UCDP Datasets

* W przypadku wojny w Kosowie wskaźniki *WAR* oraz *WAR + X* dla tego terytorium zostały przypisane Albanii.

Źródło: opracowanie własne.

Model zawiera osiem zmiennych binarnych (*BORDER*, *FTA*, *WAR* i *WAR+1* do *WAR+5*), trzy zmienne w postaci logarytmów naturalnych liczb nieujemnych (*DIST*, *PERCAP_DIFF*, *MINOR*) oraz dwa wskaźniki, których wartości zawierają się w przedziale $\langle 0, 1 \rangle$, a więc *RELIG* i *LANG*. Ponadto do modelu włączono dodatkową zmienną określającą masę eksportera, a mianowicie zasób bezpośrednich inwestycji zagranicznych (*FDI*).

3. Specyfikacja modelu

W celu stwierdzenia, czy istnieją specyficzne determinanty wymiany handlowej pomiędzy państwami regionu BZ, porównano stopień dopasowania do danych empirycznych modelu grawitacyjnego w swojej podstawowej postaci z modelem rozszerzonym o specyficzne dla regionu zmienne. Niski stopień dopasowania modelu standardowego sugerowałby konieczność uwzględniania części lub wszystkich dodatkowych zmiennych w analizie handlu regionu.

Model podstawowy

W modelu podstawowym objaśniającym wartość eksportu z kraju i do kraju j w roku t jako zmienne egzogeniczne przyjęto wartości PKB i populacji obu partnerów handlowych (jako reprezentację ich mas) oraz dystans fizyczny pomiędzy ich stolicami. Model ma charakter potęgowy, co umożliwi interpretację parametrów stojących przy zmiennych jako ich elastyczności¹⁰:

$$EXP_{ijt} = a_0 PKB_{it}^{a1} PKB_{jt}^{a2} POP_{it}^{a3} POP_{jt}^{a4} DIST_{ij}^{a5} e^{\delta}, \quad (4)$$

gdzie:

EXP_{ijt} – eksport z kraju i do kraju j w roku t ,

PKB_{it} – PKB kraju i w roku t ,

PKB_{jt} – PKB kraju j w roku t ,

POP_{it} – populacja kraju i w roku t ,

POP_{jt} – populacja kraju j w roku t ,

$DIST_{ij}$ – dystans fizyczny pomiędzy stolicami krajów i i j ,

a_0 – wyraz wolny,

$a1$ – $a5$ – parametry modelu,

δ – składnik losowy.

Poprzez obustronne zlogarytmowanie uzyskano postać liniową, umożliwiającą szacowanie parametrów metodą regresji liniowej. Badanie objęło eksport w obrębie krajów BZ¹¹ w latach 1995–2012 (18 lat), co dało 375 obserwacji¹². Okres analizy związany był z jednej strony z podpisaniem w 1995 r. układu w Dayton, kończącego wojnę w Bośni, a z drugiej strony ze wstąpieniem Chorwacji do Unii Europejskiej w 2013 r. Decyzja o przyjęciu eksportu – a nie eksportu i importu – jako zmiennej zależnej spowodowana była faktem, że inne

¹⁰ Jest to jedna z najpopularniejszych postaci modelu grawitacji [Czarny i Folfas 2011].

¹¹ Albanii, Bośni i Hercegowiny, Chorwacji, Macedonii oraz Serbii i Czarnogóry (jako jednego państwa do 2007 r. oraz oddzielnie od 2008 r.). W analizie nie uwzględniono Kosowa z uwagi na brak danych dla większości zmiennych.

¹² Z wyłączeniem obserwacji zerowych.

czynniki mogą wpływać na eksport niż na import¹³. Tym samym przyjęcie jako zmiennej zależnej tylko eksportu czyni analizę dokładniejszą (por. [Śledziwska 2012]).

Warto zwrócić uwagę, że takie podejście do badania handlu z wykorzystaniem modelu grawitacji, w którym analizuje się handel „wszystkich ze wszystkimi” w pewnym regionie, jest raczej rzadkie (por. [Metody statystyki... 1988]). Większość tego typu analiz zawęża liczbę krajów raportujących, rozszerzając jednocześnie liczbę krajów – partnerów handlowych.

Wysoki stopień dopasowania modelu podstawowego do danych empirycznych mogłoby oznaczać brak przesłanek rozszerzania go o kolejne zmienne reprezentujące potencjalne determinanty handlu. Szczególnie miarodajne wydaje się w tym przypadku oszacowanie modelu bez efektów stałych dla par krajów, gdyż efekty te zawierają w sobie informacje dostarczane przez zmienne dystansu.

Model rozszerzony

We wzorze, który opisuje model rozszerzony, z uwagi na dużą liczbę zmiennych przyjęto zapis wektorowy. Dwa pierwsze wektory ujmują zmienne charakteryzujące masy odpowiednio eksportera i importera, natomiast sześć kolejnych zawiera zmienne charakteryzujące dystans według podziału przedstawionego w punkcie 2 artykułu. Model ten ma następującą postać:

$$EXP_{ijt} = a_0 x_{it}^{\beta_1} m_{jt}^{\beta_2} df_{ij}^{\beta_3} dp_{ij}^{\beta_4} de_{ij}^{\beta_5} dku_{ij}^{\beta_6} dko_{ij}^{\beta_7} dh_{ij}^{\beta_8} e^{\delta}, \quad (5)$$

gdzie:

EXP_{ijt} – eksport z kraju i do kraju j w roku t ,

x_{it} – masa kraju eksportera (i),

m_{jt} – masa kraju importera (j),

df_{ij} – dystans fizyczny między i oraz j ,

dp_{ij} – dystans polityczny między i oraz j ,

de_{ij} – dystans ekonomiczny między i oraz j ,

dku_{ij} – dystans kulturowy między i oraz j ,

dko_{ij} – dystans komunikacyjny między i oraz j ,

dh_{ij} – dystans historyczny między i oraz j ,

a_0 – stała,

β_1 – β_8 – wektory parametrów,

δ – wyraz wolny.

Większość analiz wykorzystujących model grawitacji sprzed lat 90. XX w. była przeprowadzana na podstawie danych przekrojowych, dopiero od tego czasu autorzy skłaniają się ku korzystaniu z danych panelowych [Baltagi, Egger

¹³ Na przykład zasób BIZ w kraju eksportera czy diaspora eksportera w kraju importera.

i Pfaffermayr 2003]. Nie istnieje jednak jedna powszechnie przyjęta metoda estymacji. Stąd dla oszacowania parametrów model przedstawiono w trzech postaciach¹⁴:

- typu *pooled*, szacowany MNK,
- z efektami stałymi (*fixed effects*), wraz z dodatkowym oszacowaniem parametrów dla zmiennych niezmiennych w czasie¹⁵,
- z efektami losowymi (*random effects*).

W przypadku pierwszego z modeli przyjmowane jest założenie o niewystępowaniu efektu indywidualnego, czyli że populacja jest homogeniczna, a za odchylenia wartości rzeczywistej od teoretycznej w przypadku zmiennej objaśnianej odpowiada wyłącznie składnik losowy. Panel traktowany jest wtedy jako zbiór danych przekrojowych. Jeśli założenie to jest niespełnione, co w analizach handlu zagranicznego jest wysoce prawdopodobne, estymator ten jest nieefektywny.

Założeniem estymacji modelu z efektami stałymi jest nieprzypadkowy charakter efektów indywidualnych. Istotnym problemem jest fakt, że modele z efektami stałymi nie pozwalają szacować wartości parametrów zmiennych stałych w czasie. W celu rozwiązania tego problemu posłużono się metodą zaproponowaną przez I.W. Chenga i H.J. Walla [2005]¹⁶, składającą się z dwóch etapów. W pierwszym z nich buduje się model typu *fixed*, w drugim natomiast dokonuje się regresji zmiennych stałych w czasie na efektach stałych – wyrazie wolnym, uzyskanym z szacowania w etapie pierwszym. Wartości szacowane w drugim etapie są w tabelach 3 i 4 zapisane pogrubioną czcionką. Tę metodę stosowali także m.in. M. Bussière, J. Fidrmuc i B. Schnatz [2005], badając procesy integracji handlowej krajów Europy Środkowo-Wschodniej. W przeprowadzonej analizie problem zmiennych stałych w czasie dotyczył pięciu zmiennych: *DIST*, *BORDER*, *RELIG*, *LANG* oraz *MINOR*.

W przypadku modelu z efektami losowymi przyjmuje się założenie, że efekty indywidualne mają charakter losowy i są częścią składnika losowego. Ze względu na występującą autokorelację składnika losowego model typu *random* nie może być szacowany KMNK, ale UMNK.

Wyniki szacowania oraz testy pomocnicze miały dać odpowiedź na pytanie o charakter zbioru danych, a także o potrzebę dalszego włączania do modelu zmiennych specyficznych dla regionu BZ.

¹⁴ Oszacowania parametrów modelu dokonywane były przy użyciu programu GRETL 1.9.6 cvs.

¹⁵ Dodatkowe oszacowanie dotyczy tylko modelu rozszerzonego.

¹⁶ Innym podejściem pozwalającym rozwiązać ten problem jest estymacja metodą Hausmana-Taylor (por. [Cieślik, Michałek i Mycielski 2009, Czarny i Folfas 2011, Czarny i Śledziwska 2012]).

4. Wyniki analizy regresji

W standardowym modelu ujęto pięć zmiennych egzogenicznych najbardziej charakterystycznych dla modeli grawitacji: PKB i populację obu krajów oraz dystans fizyczny pomiędzy ich stolicami. Na tym etapie badania (bez zmiennych dodatkowych) przeanalizowano także istotność statystyczną oraz siłę wpływu podstawowych zmiennych objaśniających na wartość eksportu w handlu bilateralnym.

Tabela 2. Oszacowania parametrów modelu podstawowego

Wyszczególnienie	<i>Pooled – MNK</i>		<i>Fixed</i>		<i>Random</i>	
	współczynnik	wartość <i>p</i>	współczynnik	wartość <i>p</i>	współczynnik	wartość <i>p</i>
<i>const</i>	2,83	0,1264	105,20	0,0000***	2,56	0,5975
<i>PKB exp</i>	2,38	< 0,00001***	2,43	< 0,00001***	2,60	< 0,00001***
<i>POP exp</i>	1,43	< 0,00001***	2,01	< 0,00001***	1,92	< 0,00001***
<i>PKB imp</i>	-1,10	< 0,00001***	-4,78	0,0135**	-1,18	0,0062***
<i>POP imp</i>	-0,56	0,0076***	-11,87	< 0,00001***	-1,30	0,0026***
<i>DIST</i>	-2,53	< 0,00001***	×	×	-2,48	0,0008***
<i>R</i> ²	0,40		0,88		×	
Skorygowane <i>R</i> ²	0,39		0,87		×	
Liczba obserwacji	339		399		399	

Objaśnienie: * statystyczna istotność przy $p < 0,1$, ** statystyczna istotność przy $p < 0,5$,

*** statystyczna istotność przy $p < 0,01$.

Źródło: opracowanie własne.

Istotną kwestią dla dalszego procesu badawczego była wartość skorygowanego współczynnika determinacji R^2 dla oszacowań metodami *pooled* i *fixed*. Dla modelu *pooled* wyniósł on zaledwie 0,39, podczas gdy dla modelu *fixed* – 0,87. Oznaczało to, że pomiędzy parami krajów istnieją duże różnice, których zmienność wyjaśnia prawie połowę zmienności wartości eksportu. Stanowiło to podstawę do włączenia do modelu zmiennych dodatkowych.

Po włączeniu do modelu dodatkowych zmiennych reprezentujących dystans oraz jednej zmiennej reprezentującej masę eksportera (zasób BIZ) skorygowany współczynnik determinacji R^2 dla modelu *pooled* wzrósł aż do 0,72, natomiast dla modelu *fixed* do 0,89. Oznacza to, że zmienne dodatkowe pomogły wyjaśnić znaczną większość zmienności zmiennej objaśnianej (wartości eksportu), która w modelu podstawowym wyjaśniona była przez efekty stałe. Potwierdza to tezę o konieczności rozszerzania standardowego modelu handlu o zmienne kulturowe, komunikacyjne, polityczne i (lub) historyczne.

Interpretując poszczególne oceny parametrów regresji, należy zwrócić uwagę na fakt, że nie są one standaryzowane, co uniemożliwia ich hierarchizowanie. Parametr drugiej po odległości między stolicami zmiennej określającej dystans fizyczny – *BORDER* – w modelu *pooled* okazał się statystycznie istotny przy $p < 0,01$ (wartość parametru: 0,82), natomiast nieistotny w modelu *random*. Jako że zmienna ta jest stała w czasie, oszacowanie parametru przy niej stojącego było możliwe w modelu z efektami stałymi jedynie metodą Chenga-Walla – wyniosła ona 6,66.

Tabela 3. Oszacowania parametrów modelu rozszerzonego

Wyszczególnienie	<i>Pooled – MNK</i>		<i>Fixed</i>		<i>Random</i>	
	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p
<i>const</i>	-2,82	0,1436	62,03	0,0311**	-13,57	0,0025***
<i>PKB exp</i>	1,53	0,0001***	2,63	<0,00001***	2,60	<0,00001***
<i>PKB imp</i>	0,44	0,1059	2,04	<0,00001***	1,73	<0,00001***
<i>POP exp</i>	-0,94	0,0036***	-1,86	0,0135	-1,40	0,0010***
<i>POP imp</i>	-0,29	0,3104	-9,62	<0,00001***	-1,27	0,0022***
<i>DIST</i>	0,69	0,0238**	6,66	<0,00001***	0,15	0,8392
<i>PERCAP_DIFF</i>	-0,31	<0,00001***	-0,06	0,3264	-0,05	0,3219
<i>BORDER</i>	0,82	0,00001***	5,02	<0,00001***	0,73	0,1914
<i>RELIG</i>	0,46	0,4093	9,06	<0,00001***	4,32	0,0001***
<i>LANG</i>	6,52	<0,00001***	13,21	<0,00001***	6,33	0,0001***
<i>FTA</i>	1,22	<0,00001***	0,22	0,1821	0,33	0,0473**
<i>MINOR</i>	-0,01	0,5173	-0,26	0,0003***	-0,02	0,7600
<i>WAR</i>	-1,62	0,0026***	-1,10	0,0017***	-1,25	0,0004***
<i>WAR + 1</i>	-3,36	<0,00001***	-2,51	<0,00001***	-2,66	<0,00001***
<i>WAR + 2</i>	-0,37	0,4079	-0,08	0,7782	-0,13	0,6612
<i>WAR + 3</i>	-0,44	0,3317	-0,24	0,4085	-0,27	0,3562
<i>WAR + 4</i>	-0,74	0,0981*	-0,23	0,4306	-0,29	0,3284
<i>WAR + 5</i>	-0,30	0,5095	0,10	0,7327	0,06	0,8316
<i>FDI</i>	-0,13	0,2408	-0,12	0,2389	-0,09	0,3676
R^2	0,73		0,91		×	
Skorygowane R^2	0,72		0,89		×	
Liczba obserwacji	375		375		375	

Objaśnienie: wartości oznaczone pogrubioną czcionką dotyczą wyniku drugiego etapu analizy regresji metodą zaproponowaną przez I.H. Chenga i H.J. Walla [2005]; * statystyczna istotność przy $p < 0,1$, ** statystyczna istotność przy $p < 0,5$, *** statystyczna istotność przy $p < 0,01$.

Źródło: opracowanie własne na podstawie danych zawartych w tabeli 1.

Następnymi potencjalnymi determinantami eksportu było sześć zmiennych binarnych charakteryzujących stan wojny pomiędzy państwami (*WAR*) bądź kolejne lata po jej zakończeniu (*WAR+1* do *WAR+5*). Zgodnie z oczekiwaniami we wszystkich trzech modelach wszystkie parametry przy nich stojące okazały się ujemne, przy czym najwyższe ich wartości oraz statystyczną istotność odnotowano przy zmiennych *WAR+1* oraz *WAR*. Można się zastanowić nad faktem, że kolejne lata po wojnach, reprezentowane przez zmienne od *WAR+2* do *WAR+5*, mają znikomy wpływ na wartość eksportu¹⁷. Najwyraźniej, choć działania wojenne odbijają się negatywnie na relacjach handlowych pomiędzy krajami, życie gospodarcze odradza się znacząco już w dwa lata po wojnie.

Wśród zmiennych określających dystans kulturowy pierwszą stanowi liczebność diaspory eksportera w kraju importera (*MINOR*). Wbrew oczekiwaniom parametr stojący przy tej zmiennej miał wartości ujemne, choć niewielkie ($-0,01$; $-0,26$ i $-0,02$), i był statystycznie nieistotny. Pamiętać jednak należy o niedostatkach przyjętego miernika. Po pierwsze, budowany jest on na podstawie danych szacunkowych, a więc występuje problem ich dokładności. Po drugie, choć migracja jest procesem dynamicznym (szczególnie w okresach wojen), informacje o diasporze pochodzą tylko z jednego roku (najczęściej z 2008 r.).

Jako zmienną reprezentującą dystans ekonomiczny przyjęto wartość bezwzględną różnicy w PKB *per capita*. Określa ona różnicę w bogactwie krajów, ale także w stopniu ich rozwoju oraz w wyposażeniu w czynniki produkcji. Zgodnie z założeniami nowej teorii handlu kraje bardziej podobne do siebie pod względem poziomu bogactwa/rozwoju powinny ze sobą więcej handlować, co wydają się potwierdzać wyniki analizy. W modelu *pooled* parametr stojący przy tej zmiennej przyjął wartość $-0,31$ i był istotny statystycznie. W modelach *fixed* i *random* wartość parametru była bliska 0 (odpowiednio $-0,06$ i $-0,05$).

Druga zmienna reprezentująca dystans kulturowy, a więc podobieństwo struktur religijnych (*RELIG*), w modelu *fixed* była szacowana metodą Chenga-Walla, a wartość parametru przy niej stojącego wyniosła 9,06. W modelu *pooled* okazała się ona mieć pozytywny, choć niewielki wpływ na wartość eksportu (0,46). W modelu *random* natomiast wpływ ten był silny (4,32), a parametr stojący przy zmiennej był statystycznie istotny przy $p < 0,01$. Oznacza to, że podobieństwo struktur religijnych jest jedną z ważniejszych determinant wpływających na wartość i kierunki współpracy handlowej w regionie BZ. Wyniki te ukazują trudność, jaką muszą pokonać eksporterzy chcący z sukcesem konkurować na rynku odmiennym pod względem wyznaniowym.

Kolejna ważna z perspektywy celów badania zmienna – możliwość bezpośredniej komunikacji (*LANG*) – jako jedyna reprezentuje dystans komunikacyjny.

¹⁷ Wyjątkami są tu istotna statystycznie *WAR+4* w modelu *pooled*, a także dodatnie znaki ocen parametrów stojących przy zmiennej *WAR+5* w modelach *fixed* i *random*.

Jej dosyć złożona konstrukcja ma na celu jak najdokładniejsze odzwierciedlenie możliwości porozumiewania się mieszkańców poszczególnych krajów. W badaniu parametr stojący przy tej zmiennej okazał się istotny statystycznie i przyjmował wysokie wartości. Dla modelu *pooled* miał on wartość 6,52, natomiast dla modelu *random* – 6,33. Oznacza to, że bariery komunikacyjne należą do poważnych przeszkód w handlu pomiędzy krajami. Podobnie jak w przypadku zmiennej *RELIG*, szacowanie metodą Chenga-Walla dało bardzo wysoką wartość parametru – 13,21.

Dystans polityczny reprezentowała zmienna *FTA*, odzwierciedlająca procesy liberalizacji handlu. Niezależnie od modelu parametr przy niej stojący przyjmował wartości dodatnie, odpowiednio 1,22, 0,22 i 0,33 dla modeli *pooled*, *fixed* i *random*. W przypadku modeli *pooled* i *random* był on istotny statystycznie, natomiast w modelu *fixed* – nie. Wyniki te świadczą o tym, że liberalizacja handlu, która dokonała się poprzez podpisanie umów o wolnym handlu, wpłynęła w pewnym stopniu na wzrost jego wartości.

Ostatnią zmienną w modelu rozszerzonym był zasób bezpośrednich inwestycji zagranicznych w kraju eksportera (*FDI*). Jest to zmienna określająca masę jako potencjał technologiczny kraju eksportera (por. klasyfikacja w punkcie 2). Wyniki badania wskazały, że niezależnie od modelu parametr stojący przy tej zmiennej przyjmuje wartości ujemne w przedziale od $-0,13$ (w modelu *pooled*) do $-0,09$ (w modelu *random*), natomiast w żadnym przypadku nie jest on istotny statystycznie.

W modelu rozszerzonym przeprowadzono testy mające dać odpowiedź na pytanie, która z szacowanych postaci modelu jest najwłaściwsza. Test na zróżnicowanie wyrazu wolnego w grupach wykazał, że model uwzględniający specyficzne efekty dla par krajów lepiej odpowiada danym empirycznym niż model ich nieuwzględniający (statystyka testu: $F(35, 326) = 17,21$, z wartością $p = P(F(35, 326) > 17,21) = 5,7407e-055$). Z kolei zgodnie z testem Breusch-Pagana, model z efektami losowymi lepiej odzwierciedla rzeczywistość niż model typu *pooled*. Przy hipotezie zerowej zakładającej, że wariancja błędu w jednostce = 0, asymptotyczna statystyka testu chi-kwadrat wyniosła 465,689, z wartością $p = 2,77849e-103$. Wyniki testu Hausmana nie dały podstaw do potwierdzenia zgodności estymatora UMNK, którym szacowany był model z efektami losowymi. Asymptotyczna statystyka testu: chi-kwadrat = 34,52, z wartością $p = 0,001$. Oznacza to, że nawet po wprowadzeniu do modelu zmiennych charakteryzujących dystans nadal najbardziej odpowiednim modelem jest model *fixed*.

5. Odporność rezultatów na zmiany w specyfikacji modeli oraz w metodach estymacji

Prawidłowe wnioskowanie na podstawie analizy ekonometrycznej wymaga sprawdzenia odporności jej rezultatów na zmiany w specyfikacji modelu oraz na inne metody jego szacowania. Z tego powodu poniżej przedstawiono wyniki analizy jedno- oraz dwukierunkowych efektów stałych, a także zastępowania dotychczasowych zmiennych zmiennymi alternatywnymi, głównie zaczerpniętymi z literatury przedmiotu.

Analiza efektów stałych

Efekty stałe dla poszczególnych par krajów bądź lat mogą dać odpowiedź na wiele szczegółowych pytań dotyczących kierunków handlu lub warunków zewnętrznych determinujących w określonych latach zachowania rynkowe. Stąd do modelu *pooled* dołączono najpierw zmienne binarne określające daną parę krajów (jednokierunkowe, *one-way*), a następnie także rok obserwacji (dwukierunkowe, *two-way*).

Dołączenie do modelu efektów stałych dla par krajów sprawiło, że parametry stojące przy niektórych zmiennych objaśniających stały się istotne statystycznie, natomiast parametry kilku innych tę cechę utraciły. Do pierwszej z tych grup zaliczyć można parametry zmiennych *PKB imp* i *POP imp*. Wyniki te można interpretować w ten sposób, że kontrolowanie efektów bilateralnych uwypukla znaczenie potencjału kraju importera, a więc popytowego aspektu handlu. W drugiej grupie istotność statystyczną straciły parametry stojące przy zmiennych:

- dystansu: *PERCAP_DIFF*, *FTA*, *WAR+4*,
- masy: *POP exp*.

Znaczna część informacji dostarczanych przez te cztery zmienne została więc ujęta w efektach bilateralnych.

W kolejnym etapie dołączono efekty czasowe (model *two-way*), co sprawiło, że parametr stojący przy zmiennej *FTA* zyskał istotność statystyczną. Może to oznaczać, że nie należy rozpatrywać dynamicznych zmian związanych z liberalizacją handlu w oderwaniu od zmian w makrooczeniu, np. światowego kryzysu gospodarczego, którego skutki zostały ujęte w efektach czasowych.

Alternatywne miary wybranych rodzajów dystansu

Ostatnim etapem analizy modelu było jego oszacowanie po uprzednim włączeniu kolejno szeregu alternatywnych miar niektórych rodzajów dystansu. Zabieg ten miał służyć dwóm celom:

- sprawdzeniu, jak zmieniają się oszacowania parametrów po wstawieniu alternatywnych postaci zmiennych,

– sprawdzeniu, czy wnioski na temat wpływu zjawisk, które były reprezentowane przez zmienne pierwotne, zostaną podtrzymane, gdy zmienne te przyjmą inną postać.

Tabela 4. Oszacowania parametrów modelu rozszerzonego z jedno- i dwukierunkowymi efektami stałymi

Wyszczególnienie	Pooled – MNK		Pooled – MNK (<i>du</i>)		Pooled – MNK (<i>du, dt</i>)	
	współczynnik	wartość <i>p</i>	współczynnik	wartość <i>p</i>	współczynnik	wartość <i>p</i>
<i>const</i>	-2,82	0,1436	72,62	0,0126**	62,93	0,0424**
<i>PKB exp</i>	1,53	0,0001***	2,64	< 0,00001***	3,59	< 0,00001***
<i>PKB imp</i>	0,44	0,1059	2,04	< 0,00001***	2,43	< 0,00001***
<i>POP exp</i>	-0,94	0,0036***	-1,83	0,3848	-1,80	0,4130
<i>POP imp</i>	-0,29	0,3104	-9,56	< 0,00001***	-9,93	< 0,00001***
<i>DIST</i>	0,69	0,0238**	6,66	< 0,00001***	5,07	< 0,00001***
<i>PERCAP_DIFF</i>	-0,31	< 0,00001***	-0,06	0,3262	-0,07	0,2959
<i>BORDER</i>	0,82	0,00001***	5,02	< 0,00001***	4,32	< 0,00001***
<i>RELIG</i>	0,46	0,4093	9,06	< 0,00001***	9,55	< 0,00001***
<i>LANG</i>	6,52	< 0,00001***	13,21	< 0,00001***	12,66	< 0,00001***
<i>FTA</i>	1,22	< 0,00001***	0,22	0,1745	0,47	0,0259**
<i>MINOR</i>	-0,01	0,5173	-0,26	0,0003***	-0,34	0,0000***
<i>WAR</i>	-1,62	0,0026***	-1,10	0,0015***	-0,92	0,0115**
<i>WAR + 1</i>	-3,36	< 0,00001***	-2,52	< 0,00001***	-2,46	< 0,00001***
<i>WAR + 2</i>	-0,37	0,4079	-0,08	0,7733	0,03	0,9193
<i>WAR + 3</i>	-0,44	0,3317	-0,24	0,4016	-0,12	0,6965
<i>WAR + 4</i>	-0,74	0,0981*	-0,23	0,4244	0,02	0,9362
<i>WAR + 5</i>	-0,30	0,5095	0,10	0,7308	0,19	0,5329
<i>FDI</i>	-0,13	0,2408	-0,12	0,2266	0,21	0,2227
<i>R</i> ²	0,73		0,91		0,91	
Skorygowane <i>R</i> ²	0,72		0,89		0,89	
Liczba obserwacji	375		385		375	

Objaśnienie: wartości oznaczone pogrubioną czcionką dotyczą wyniku drugiego etapu analizy regresji metodą zaproponowaną przez I.H. Chenga i H.J. Walla [2005]; oznaczenia modeli: *du* – model zawierający efekty stałe dla par krajów, *dt* – model zawierający efekty stałe dla czasu; * statystyczna istotność przy $p < 0,1$, ** statystyczna istotność przy $p < 0,5$, *** statystyczna istotność przy $p < 0,01$.

Źródło: obliczenia własne.

Zmienną *LANG* postanowiono zastąpić kolejno przez trzy zmienne alternatywne:

– *LANG 1* – niespotkana przez autora wcześniej w literaturze przedmiotu, stanowiła zmienną binarną przyjmującą wartość 1 w przypadku, gdy oba kraje posiadały wspólne języki urzędowe lub gdy ich języki urzędowe były najbliższej spokrewnione (na najniższej gałęzi drzewa językowego),

– *LANG 2* – stanowiła najpowszechniej wykorzystywaną miarę podobieństwa językowego, czyli zmienną przyjmującą wartość 1 w przypadku tych samych języków urzędowych,

– zmienna „historyczna” *SMCTR* – przyjmująca wartość 1 dla pary krajów, które w latach po II wojnie światowej należały do jednego wspólnego organizmu państwowego¹⁸.

Zmienną alternatywną dla *RELIG* była *RELIG 1*, określająca prawdopodobieństwo, że dwie losowo wybrane osoby z dwóch krajów będą tego samego wyznania (por. [Helble 2007, Guiso 2009, Melitz i Toubal 2012]).

Zmienna *RELIG 1* przyjmuje, podobnie jak zmienna *RELIG*, wartości z przedziału $(0, 1)$. Jej cechą charakterystyczną jest to, że przyjmuje ona niższe wartości w przypadku krajów zróżnicowanych wyznaniowo, co zdaniem autora stanowi jej poważne ograniczenie. Nawet obliczając wartość tego wskaźnika dla dwóch identycznych, ale wewnętrznie zróżnicowanych pod względem religijnym krajów, można otrzymać bardzo niski wynik¹⁹. Drugą cechą charakterystyczną wskaźnika *RELIG 1* jest jego mniejsza wariancja niż w przypadku wskaźnika *RELIG* (dla badanej próby państw BZ odpowiednio 0,02 i 0,08).

Ostatnią zmienną alternatywną była *MINOR 1*. W przeciwieństwie do *MINOR* miała ona charakter binarny, przyjmowała wartość 1 w przypadku, gdy w kraju importera występowała diaspora kraju eksportera. Ponieważ kwestią umowną jest to, od jakiej liczby lub odsetka mieszkańców uznawać istnienie diaspory, przyjęto jako cenzus występowanie jej w bazie danych ethnologue.com.

Analizując zmienne reprezentujące dystans komunikacyjny, można dostrzec, że obie zmienne (*LANG 1* i *LANG 2*) wykazały dodatni (odpowiednio 0,69 i 1,85) i statystycznie istotny (przy $p < 0,05$ (*LANG 1*) lub $p < 0,01$ (*LANG 2*)) wpływ na wartość eksportu. Parametry stojące przy obu tych zmiennych przyjmują jednakże niższe wartości niż parametr przy zmiennej *LANG*. Potwierdza to założenie, że opieranie się na językach faktycznie używanych w danym kraju, a nie tylko urzędowych, przy uwzględnieniu ich wzajemnego podobieństwa,

¹⁸ Przynależność do jednego organizmu państwowego ma szerszą interpretację, implikuje bowiem także nasilone powiązania handlowe pomiędzy firmami, tworzenie wspólnych łańcuchów produkcji itd.

¹⁹ Przykładowo wartość wskaźnika *RELIG 1* przy konfiguracji krajów Albania–Albania wyniósłby 0,38, a dla Bośnia–Bośnia – 0,44.

Tabela 5. Oszacowania parametrów modelu rozszerzonego zawierającego zmienne alternatywne

Wyszczególnienie	Pooled – MNK		Pooled – MNK (LANG 1)		Pooled – MNK (LANG 2)		Pooled – MNK (SMCTR)		Pooled – MNK (RELIG 3)		Pooled – MNK (MINOR 0-1)	
	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p
<i>const</i>	-2,82	0,1436	5,38	0,0123**	5,22	0,0099***	4,37	0,0160**	-6,23	0,0008***	-3,21	0,1071
<i>PKB exp</i>	1,53	0,0001***	1,88	0,0000***	1,87	<0,00001***	1,15	0,0017***	1,84	<0,00001***	1,52	0,0001***
<i>POP exp</i>	-0,94	0,0036***	0,75	0,0261**	0,76	0,0122**	0,21	0,4313	0,71	0,0075***	0,47	0,0857*
<i>PKB imp</i>	0,44	0,1059	-1,22	0,0014***	-1,52	0,0000***	-0,47	0,1415	-1,16	0,0002***	-0,95	0,0033***
<i>POP imp</i>	-0,29	0,3104	-0,45	0,1813	-0,78	0,0138**	0,17	0,5408	-0,50	0,0650*	-0,29	0,3115
<i>DIST</i>	0,69	0,0238**	-0,36	0,3314	0,38	0,2829	-0,81	0,0035***	0,78	0,0077***	0,73	0,0158**
<i>PERCAP_DIFF</i>	-0,31	<0,00001***	-0,46	<0,00001***	-0,44	<0,00001***	-0,21	0,0010***	-0,24	0,0002***	-0,31	<0,00001***
<i>BORDER</i>	0,82	0,00001***	1,38	<0,00001***	1,76	<0,00001***	1,33	<0,00001***	0,69	0,0011***	0,83	0,0001***
<i>RELIG</i>	0,46	0,4093	-1,92	0,0017***	-1,40	0,0155**	-1,47	0,0032**			0,50	0,3675
<i>LANG</i>	6,52	<0,00001***							6,95	<0,00001***	6,36	<0,00001***
<i>FTA</i>	1,22	<0,00001***	1,21	0,0000***	1,10	0,0000***	1,13	<0,00001***	1,13	<0,00001***	1,20	<0,00001***
<i>MINOR</i>	-0,01	0,5173	0,05	0,0137**	0,02	0,3094	0,00	0,8712	-0,01	0,5496		
<i>WAR</i>	-1,62	0,0026***	-2,09	0,0010***	-1,97	0,0010***	-1,46	0,0049***	-1,45	0,0061***	-1,62	0,0027***
<i>WAR+1</i>	-3,36	<0,00001***	-3,91	<0,00001***	-3,52	<0,00001***	-3,31	<0,00001***	-3,18	<0,00001***	-3,35	<0,00001***
<i>WAR+2</i>	-0,37	0,4079	-0,72	0,1788	-0,43	0,3878	-0,52	0,2322	-0,27	0,5376	-0,37	0,4079
<i>WAR+3</i>	-0,44	0,3317	-0,81	0,1294	-0,53	0,2879	-0,56	0,1922	-0,35	0,4357	-0,44	0,3304
<i>WAR+4</i>	-0,74	0,0981*	-1,13	0,0328**	-0,83	0,0954*	-0,85	0,0500**	-0,60	0,1750	-0,74	0,0988*
<i>WAR+5</i>	-0,30	0,5095	-0,72	0,1720	-0,43	0,3835	-0,37	0,3896	-0,16	0,7144	-0,30	0,5094
<i>FDI</i>	-0,13	0,2408	-0,23	0,0763*	-0,17	0,1558	-0,03	0,8013	-0,17	0,1080	-0,13	0,2533
<i>MINOR_0-1</i>	-	-	-	-	-	-	-	-	-	-	0,07	0,6619
<i>RELIG 1</i>	-	-	-	-	-	-	-	-	3,46	0,0002***	-	-

cd. tabeli 5

Wyszczególnienie	Pooled – MNK		Pooled – MNK (LANG 1)		Pooled – MNK (LANG 2)		Pooled – MNK (SMCTR)		Pooled – MNK (RELIG 3)		Pooled – MNK (MINOR 0-1)	
	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p	współczynnik	wartość p
LANG 1	–	–	0,69	0,0191**	–	–	–	–	–	–	–	–
LANG 2	–	–	–	–	1,85	<0,00001***	–	–	–	–	–	–
SMCTR	–	–	–	–	–	–	2,04	<0,00001***	–	–	–	–
R ²	0,73		0,63		0,67		0,76		0,74		0,73	
Skorygowane R ²	0,72		0,61		0,65		0,75		0,73		0,72	
Liczba obserwacji	375		375		375		365		375		375	

Objaśnienie: * statystyczna istotność przy $p < 0,1$, ** statystyczna istotność przy $p < 0,5$, *** statystyczna istotność przy $p < 0,01$.

Źródło: opracowanie własne.

w pełniejszym stopniu oddaje charakter dystansu komunikacyjnego niż znane miary alternatywne.

Włączenie do modelu zmiennej *SMCTR* w miejsce blisko skorelowanej zmiennej *LANG* daje interesujący rezultat. Zgodnie z przewidywaniami jej parametr ma wartość dodatnią (2,04) i jest statystycznie istotny. Jednakże przy zastosowaniu tej zmiennej, niosącej ze sobą duży ładunek informacyjny, statystyczną istotność zyskuje parametr stojący przy zmiennej *RELIG*. Może to nasuwać interpretację, że fakt dawnej przynależności do jednego państwa wzmacnia efekty związane z różnicami w strukturach wyznaniowych.

Interesujący rezultat daje także włączenie do modelu zmiennej *RELIG 1* w miejsce *RELIG*. Zmienna *RELIG 1* wykazuje bowiem kilkukrotnie większy wpływ na wartość eksportu niż zmienna *RELIG*. Odwołując się do charakterystyki zmiennej *RELIG 1*, można wysunąć wniosek, że na wartość eksportu ma wpływ nie tylko podobieństwo struktur wyznaniowych, ale także ich wewnętrzne zróżnicowanie w obrębie obu krajów. Stąd tylko krok do stwierdzenia, że kraje jednolite pod względem religijnym eksportują więcej. Ta teza wymaga jednak potwierdzenia za pomocą nieco innego aparatu badawczego.

Ostatnia zmienna alternatywna, *MINOR 1*, wykazała się dodatnią wartością parametru przy niej stojącego, w przeciwieństwie do zmiennej *MINOR* (odpowiednio 0,06 i -0,01). Parametr ten w obu przypadkach okazał się nieistotny statystycznie. Wyniki te nie dają jednoznacznej odpowiedzi na pytanie, jak traktować kwestie mniejszości narodowych w analizach handlu zagranicznego.

6. Podsumowanie

Przedstawione badanie przyczyniło się do lepszego rozumienia kilku kwestii związanych z grawitacyjnym modelem handlu. Po pierwsze, wydaje się, że tzw. model standardowy, w którym wartość obrotów handlowych jest wyjaśniana przez PKB, populację oraz fizyczny dystans, w niewystarczającym stopniu odpowiada danym empirycznym. Istnieje więc konieczność uzupełnienia go o zmienne reprezentujące inne rodzaje dystansu, w szczególności dystans polityczny, ekonomiczny, historyczny, komunikacyjny oraz kulturowy.

Po drugie, model z efektami stałymi okazał się najlepiej dopasowany do danych spośród wszystkich modeli; następny pod względem dopasowania był model z efektami losowymi. Oznacza to, że nawet kontrolując wiele różnych zmiennych charakterystycznych dla par krajów, nieobserwowalne bilateralne efekty mają istotny wpływ na wartość obrotów handlowych. Model typu *pooled*, jak wynika z analizy składnika losowego, nie jest odpowiednim rodzajem estymacji modelu grawitacyjnego.

Po trzecie, w przypadku krajów Bałkanów Zachodnich zazwyczaj zaniedbywane pozaekonomiczne kwestie, takie jak język, kultura czy historia, zdają się odgrywać niezwykle ważną rolę w wyjaśnianiu wartości handlu zagranicznego. Jako że ten wniosek może być częściowo efektem wewnętrznego zróżnicowania analizowanego regionu, dalsze badania na większej liczbie krajów są potrzebne, żeby potwierdzić lub zakwestionować przedstawione rezultaty.

Literatura

- Anderson J.E., van Wincoop E. [2003], *Gravity with Gravitas: A Solution to the Border Puzzle*, „American Economic Review”, vol. 93, nr 1, <http://dx.doi.org/10.1257/000282803321455214>.
- Anderson J.E., van Wincoop E. [2004], *Trade Costs*, „Journal of Economic Literature”, vol. 42, nr 3, <http://dx.doi.org/10.1257/0022051042177649>.
- Baltagi B.H., Egger P., Pfaffermayr M. [2003], *A Generalized Design for Bilateral Trade Flow Models*, „Economics Letters”, vol. 80, nr 3, [http://dx.doi.org/10.1016/s0165-1765\(03\)00115-0](http://dx.doi.org/10.1016/s0165-1765(03)00115-0).
- Berry H., Guillén M.F., Zhou N. [2010], *An Institutional Approach to Cross-national Distance*, „Journal of International Business Studies”, vol. 41, <http://dx.doi.org/10.1057/jibs.2010.28>.
- Bussière M., Fidrmuc J., Schnatz B. [2005], *Trade Integration of Central and Eastern European Countries: Lessons from a Gravity Model*, European Central Bank Working Paper, nr 545, European Central Bank, Frankfurt am Main.
- Cheng I.H., Wall H.J. [2005], *Controlling for Heterogeneity in Gravity Models of Trade and Integration*, „Federal Reserve Bank of St. Louis Review”, vol. 87, nr 1.
- Cieślak A., Michałek J.J., Mycielski J. [2009], *Prognoza skutków handlowych przystąpienia do Europejskiej Unii Monetarnej dla Polski przy użyciu uogólnionego modelu grawitacyjnego*, „Bank i Kredyt”, vol. 40, nr 1.
- Czarny E., Folfas P. [2011], *Modele grawitacji jako narzędzie analityczne w ekonomii międzynarodowej [w:] Rola informatyki w naukach ekonomicznych i społecznych. Innowacje i implikacje interdyscyplinarne*, red. Z.E. Zieliński, Wyższa Szkoła Handlowa im. Bolesława Markowskiego w Kielcach, Kielce.
- Czarny E., Śledziwska K. [2012], *Międzynarodowa współpraca gospodarcza w warunkach kryzysu*, PWE, Warszawa.
- Drzewoszevska N., Pietrzak M.B., Wilk J. [2013], *Grawitacyjny model przepływów handlowych między krajami Unii Europejskiej w dobie globalizacji*, „Collegium of Economic Analysis Annals”, nr 30/2013.
- Ekonometria przestrzenna* [1991], red. A. Zeliaś, PWE, Warszawa.
- Ellis P.D. [2007], *Paths to Foreign Markets: Does Distance to Market Affect Firm Internationalisation?*, „International Business Review”, vol. 16, nr 5, <http://dx.doi.org/10.1016/j.ibusrev.2007.06.001>.
- Ghemawat P. [2001], *Distance Still Matters: The Hard Reality of Global Expansion*, „Harvard Business Review”, vol. 79, nr 8.

- Gómez E., Milgram B.J. [2009], *Are Estimation Techniques Neutral to Estimate Gravity Equations? An Application to the Impact of EMU on Third Countries' Exports*, Proceeding of the XI Conference on International Economics, Universidad de Barcelona, Barcelona.
- Guiso L., Sapienza P., Zingales L. [2009], *Cultural Biases in Economic Exchange?*, „Quarterly Journal of Economics”, vol. 124, nr 3, <http://dx.doi.org/10.1162/qjec.2009.124.3.1095>.
- Head K., Mayer T. [2000], *Non-Europe: The Magnitude and Causes of Market Fragmentation in the EU*, „Weltwirtschaftliches Archiv”, vol. 136, nr 2, <http://dx.doi.org/10.1007/bf02707689>.
- Helble M. [2007], *Is God Good for Trade?*, „Kyklos”, vol. 60, nr 3, <http://dx.doi.org/10.1111/j.1467-6435.2007.00377.x>.
- Hofstede G. [1980], *Culture's Consequences: International Differences in Work-related Values*, Sage, Beverly Hills.
- House R.J., Hanges P.J., Javidan M., Dorfman P., Gupta V. [2004], *Culture, Leadership, and Organizations: The GLOBE Study of 62 Societies*, Sage, Thousand Oaks.
- Kandogan Y. [2009], *A Gravity Model for Components of Imports*, „Review of Applied Economics”, vol. 5, nr 1–2.
- Klimczak Ł. [2014], *Determinanty handlu wzajemnego państw Bałkanów Zachodnich*, „Zeszyty Naukowe Podkarpackiej Szkoły Wyższej im. bł. ks. Władysława Findysza w Jaśle”, nr 11.
- Leamer E. [1997], *Access to Western Markets, and Eastern Effort Levels [w:] Lessons from the Economic Transition: Central and Eastern Europe in the 1990s*, red. S. Zecchini, Kluwer Academic Publishers, Dordrecht–Boston.
- Linneman H. [1966], *An Econometric Study of World Trade Flows*, North-Holland Publishing Co., Amsterdam.
- McCallum J. [1995], *National Borders Matter: Canada-U.S. Regional Trade Patterns*, „The American Economic Review”, vol. 85, nr 3.
- Melitz J. [2008], *Language and Foreign Trade*, „European Economic Review”, vol. 52, nr 4, <http://dx.doi.org/10.1016/j.euroecorev.2007.05.002>.
- Melitz J., Toubal F. [2012], *Native Language, Spoken Language, Translation and Trade*, Centre for Economic Policy Research Discussion Paper, nr 8994, CEPR, London.
- Metody statystyki międzynarodowej* [1988], red. A. Zeliaś, PWE, Warszawa.
- Molendowski E. [2011], *Western Balkan Countries – Main Issues Concerning Co-operation and Integration with the European Union [w:] Scientific Conference „Contemporary Issues in Business, Management and Education ‘2011”*, Vilnius Gediminas Technical University, Vilnius.
- Pöyhönen K. [1963], *Towards a General Theory of International Trade*, „Ekonomiska Samfundet Tidskrift”, nr 16.
- Śledziewska K. [2012], *Regionalizm handlowy w XXI wieku. Przesłanki teoretyczne i analiza empiryczna*, Wydawnictwo Uniwersytetu Warszawskiego, Warszawa.
- Tinbergen J. [1962], *Shaping the World Economy. Suggestions for an International Economic Policy*, The Twentieth Century Fund, New York.
- Trivić J., Klimczak Ł. [2015], *The Determinants of Intra-Regional Trade in the Western Balkans*, „Proceedings of Rijeka Faculty of Economics: Journal of Economics and Business”, vol. 33, nr 1.
- UCDP Datasets* [2013], www.pcr.uu.se/research/ucdp/datasets (dostęp: 19.11.2013).

Williamson O.E. [1985], *The Economic Institutions of Capitalism*, Free Press, New York.
Wydymus S. [2012], *System współzależności wskaźników makroekonomicznych w grawitacyjno-potencjalowym modelu polskiego handlu zagranicznego* [w:] *Handel i współpraca międzynarodowa w warunkach kryzysu gospodarczego*, red. S. Wydymus, M. Maciejewski, Fundacja Uniwersytetu Ekonomicznego w Krakowie, Kraków.

The Gravity Model as a Tool for the Analysis of International Trade

(Abstract)

The aim of the paper is to determine whether a standard gravity model of trade can work effectively or if a need exists to supplement it with additional measures of “distance”. The region of the Western Balkans from 1995 to 2012 was studied.

The estimation results of the standard model are compared to the results of the model augmented by variables: border effect, war and post-war effects, minorities, difference in development, religious and language distance, FTA and FDI stock. In order to check for robustness of the results, apart from “pooled” type estimation, models with random effects, one-way and two-way fixed effects were estimated. A model with alternative explanatory variables was also considered.

The findings show that there are a number of trade determinants specific to this region, which need to be included in the model. The most important are: similarities in language and religious structures, wars and free trade agreements.

Keywords: Western Balkans, gravity model, international trade, trade determinants.

Monika Hadaś-Dyduch

Katedra Metod Statystyczno-Matematycznych w Ekonomii
Uniwersytet Ekonomiczny w Katowicach

Produkty strukturyzowane – analiza stóp zwrotu osiągniętych w latach 2000–2013

Streszczenie

Celem artykułu jest przedstawienie rynku produktów strukturyzowanych w Polsce w kontekście zysków i strat z zakończonych inwestycji w produkty strukturyzowane, jak również pokazanie, kiedy inwestycja w produkty strukturyzowane przynosiła inwestorom straty, a kiedy zyski. W tym celu wyznaczono stopę zwrotu brutto oraz roczną stopę zwrotu netto zakończonych w latach 2000–2013 produktów strukturyzowanych. Stopy zwrotu produktów strukturyzowanych zestawiono z inflacją oraz ze średnim rocznym oprocentowaniem lokat na okres 12 miesięcy. Szczegółowo opisano najlepszy i najgorszy pod względem stopy zwrotu brutto produkt strukturyzowany zakończony na polskim rynku kapitałowym w latach 2000–2013. Analizie zostało poddanych 1820 produktów strukturyzowanych, które pojawiły się na rynku w okresie od 2000 r. do 2013 r.

Słowa kluczowe: produkty strukturyzowane, inwestycje alternatywne, struktury, instrumenty pochodne.

1. Wprowadzenie

Produkty strukturyzowane należą do gatunku tzw. inwestycji alternatywnych, czyli do inwestycji, których pozytywny wynik nie zależy od ciągłych, pozytywnych wzrostów na rynkach akcji. Według GPW w Warszawie są to instrumenty finansowe, których cena jest uzależniona od wartości określonego wskaźnika rynkowego. Są emitowane przez instytucje finansowe, najczęściej banki lub

domy maklerskie. Emitent produktu strukturyzowanego zobowiązuje się w stosunku do nabywcy (inwestora), że w terminie wykupu instrumentu wypłaci mu kwotę rozliczenia kalkulowaną według określonego wzoru.

Dzięki swojej specyficznej konstrukcji produkty strukturyzowane zapewniają inwestorowi ochronę kapitału (pełną lub częściową) i jednocześnie dają możliwość (choć nie pewność) uzyskania dochodu, przy czym funkcja wypłaty ma zawsze charakter opcyjny. Podobnie jak w przypadku innych produktów inwestycyjnych stopa zwrotu nie jest znana *ex ante*.

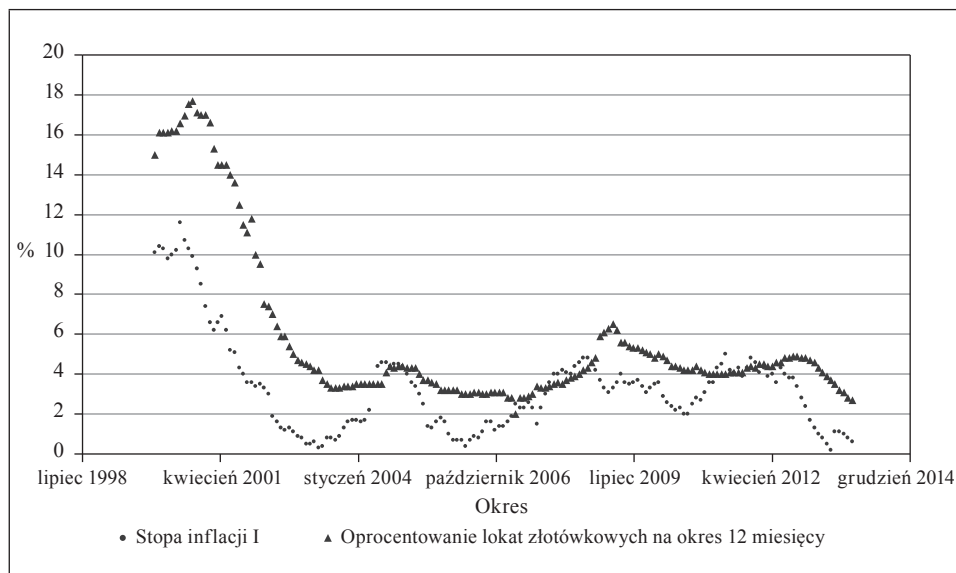
Produkty strukturyzowane pomimo podobnej konstrukcji i funkcji ekonomicznej występują na rynku w różnych formach i w związku z tym mają charakter międzysektorowy. Produktem strukturyzowanym może być np. lokata, której oprocentowanie nie zależy jedynie od stóp procentowych, lecz także np. od kursu akcji, ceny ropy lub złota, produkt ubezpieczeniowy, obligacja czy certyfikat inwestycyjny. Określona forma prawna nie przesądza przy tym, że dystrybutorem zostaje podmiot finansowy z odpowiedniego sektora, np. banki oferują klientom produkty strukturyzowane w formie produktów ubezpieczeniowych. Ze względu na charakter funkcjonalny produkty strukturyzowane są traktowane jako połączenie instrumentów oszczędnościowych i inwestycyjnych.

Instytucje finansowe wprowadzające na rynek tego rodzaju instrumenty uzyskują dochód (marżę), którego wysokość wynika z konstrukcji konkretnego produktu i jest ustalana *ex ante*, tj. w chwili zamknięcia subskrypcji. Wysokość marży zwykle nie jest podawana do publicznej wiadomości.

W czasach, kiedy banki i różne instytucje finansowe oferują bardzo niskie oprocentowanie (zazwyczaj w granicach inflacji) na tradycyjnych produktach bankowych, takich jak np. lokaty bankowe, najwłaściwszą formą inwestycji wydaje się inwestycja w produkty strukturyzowane. Taka inwestycja jest właściwa dla wszystkich inwestorów, można jednakże wnioskować, że jest ona skierowana w szczególności do osób, które nie są zainteresowane inwestycjami na giełdach z uwagi na brak doświadczenia i dużą awersję do ryzyka towarzyszącego inwestycjom giełdowym, ale zainteresowane są pomnażaniem majątku w sposób nieklasyczny i w pewnym sensie powiązany z giełdą. Można zatem stwierdzić, że w obecnych czasach inwestycje w produkty strukturyzowane stanowią uzupełnienie lub wręcz zastąpienie tradycyjnego inwestowania w akcje, obligacje oraz lokaty. Dają możliwość połączenia inwestowania z zainteresowaniami oraz ponadprzeciętnymi zyskami.

Należy w tym miejscu postawić jednak pytanie, czy zawsze inwestycja w produkty strukturyzowane jest zyskowna, przynosząca ponadprzeciętne zyski i korzystna dla inwestora. Warto zastanowić się, czy lokowanie oszczędności w produkty strukturyzowane naprawdę się opłaca oraz czy jest to trafna decyzja inwestycyjna. Odpowiedzi na te i inne pytania można uzyskać jedynie poprzez

gruntowne zrozumienie działania produktów strukturyzowanych na rynku oraz analizę zysków i strat zakończonych dotychczas na polskim rynku kapitałowym produktów strukturyzowanych.



Rys. 1. Zestawienie stopy inflacji I (względem analogicznego miesiąca roku poprzedniego) ze stopą procentową lokat gotówkowych w głównych bankach komercyjnych na okres 12 miesięcy w latach 2000–2013


Źródło: opracowanie własne na podstawie danych GUS.

Wyniki badań przedstawionych w artykule są w pełni autorskie, częściowo oparte na wcześniejszych autorskich badaniach tej problematyki [Hadaś-Dyduch 2013a, 2013b, 2013c, 2013d, 2013e, 2013f, 2013g, 2014a, 2014b, 2014c, 2014d, 2014e; 2014f, Dyduch 2013]. Obliczenia oparto na danych na temat podstawowych parametrów mierzalnych dotyczących produktów strukturyzowanych. Dane niezbędne do przeprowadzenia zaprezentowanego w artykule badania uzyskano z portali finansowych <http://www.knf.gov.pl> i <http://www.structus.pl> oraz z banków i instytucji finansowych emitujących produkty strukturyzowane.

2. Charakterystyka zakończonych produktów strukturyzowanych


Od momentu pojawienia się na polskim rynku kapitałowym pierwszego produktu strukturyzowanego z roku na rok następował systematyczny wzrost liczby emitowanych produktów strukturyzowanych, jak i kończących się

produktów. Odnotowuje się, że od momentu pojawienia się na polskim rynku produktów strukturyzowanych, czyli od 2000 r., do 2013 r. zostało zakończonych 1820 produktów strukturyzowanych. Najwięcej produktów strukturyzowanych zostało zakończonych w 2012 r. – 560, co stanowi 30,77% ogółu zakończonych w latach 2003–2013 produktów strukturyzowanych (zob. rys. 2).



Rys. 2. Liczba produktów strukturyzowanych zakończonych w Polsce w latach 2003–2013

Źródło: opracowanie własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).



Rys. 3. Liczba produktów strukturyzowanych zakończonych w Polsce w poszczególnych miesiącach w latach 2000–2013

Źródło: opracowanie własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

Tabela 1. Liczba produktów strukturyzowanych zakończonych w Polsce w poszczególnych miesiącach w latach 2003–2013

Miesiąc	Rok zakończenia produktu	Liczba zakończonych produktów	Miesiąc	Rok zakończenia produktu	Liczba zakończonych produktów
Styczeń	2005	1	Czerwiec	2003	1
	2007	2		2006	1
	2008	2		2007	2
	2009	9		2008	1
	2010	10		2009	10
	2011	20		2010	18
	2012	31		2011	34
	2013	33		2012	45
Luty	2004	1	Lipiec	2013	25
	2007	1		2005	3
	2008	2		2006	1
	2009	1		2007	3
	2010	15		2008	2
	2011	32		2009	7
	2012	36		2010	26
	2013	30		2011	36
Marzec	2005	2	Sierpień	2012	49
	2006	2		2013	37
	2007	6		2007	2
	2008	1		2008	1
	2009	4		2009	10
	2010	30		2010	28
	2011	46		2011	41
	2012	50		2012	56
Kwiecień	2013	33	Wrzesień	2013	37
	2005	1		2007	1
	2006	1		2008	1
	2007	2		2009	9
	2008	3		2010	31
	2009	4		2011	36
	2010	28		2012	35
	2011	40		2013	32
Maj	2012	48	Październik	2003	2
	2013	37		2004	2
	2007	1		2006	3
	2008	3		2007	4
	2009	20		2008	1
	2010	29		2009	9
	2011	23		2010	24
2012	56	2011	36		
2013	31	2012	61		
			2013	42	

cd. tabeli 1

Miesiąc	Rok zakończenia produktu	Liczba zakończonych produktów	Miesiąc	Rok zakończenia produktu	Liczba zakończonych produktów
Listopad	2006	2	Grudzień	2003	1
	2007	3		2007	2
	2008	3		2008	6
	2009	15		2009	6
	2010	18		2010	15
	2011	28		2011	41
	2012	45		2012	48
	2013	27		2013	28

Źródło: opracowanie własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

W badanym okresie najwięcej produktów strukturyzowanych zakończyło się w październiku (10,11%) a najmniej w styczniu (5,93%) i lutym (6,48%), co szczegółowo prezentuje zestawienie na rys. 3 i w tabeli 1.


Spośród skatalogowanych produktów strukturyzowanych w 2009 r. w Polsce dostępnych dla wszystkich było około 60%. W 31,7% przypadków wymagane było założenie rachunku bankowego, a w 8,3% przypadków były to produkty strukturyzowane jako inwestycje dla wybranej grupy klientów (*private banking*).

Dane wskazują, że pod względem rozpoczętych subskrypcji najlepszym rokiem spośród analizowanych był 2009 r. (zob. rys. 4). Sprzedano w nim 473 produkty strukturyzowane. Od 2010 r. obserwowalny jest jednak niewielki spadek liczby zakończonych subskrypcji produktów strukturyzowanych w stosunku do 2009 r. (szczegółowe tendencje w zakresie liczby rozpoczętych inwestycji w produkty strukturyzowane zaprezentowano na rys. 4). W 2010 r. był to spadek zaledwie o 0,42% w stosunku do 2009 r., w 2011 r. o 15,43%, w 2012 r. o 34,46%, a w 2013 r. o 31,92%.

Najwięcej produktów strukturyzowanych w latach 2000–2013 zakończyło subskrypcję i rozpoczęło tzw. czas trwania w marcu (10,89%) i w czerwcu (10,05%), a najmniej w styczniu (5,34%), co szczegółowo zaprezentowano na rys. 5 i w tabeli 2.

Należy nadmienić, że wartość produktów strukturyzowanych w obiegu w Polsce wynosiła: na koniec 2009 r. – około 15 mld zł, na koniec 2008 r. – 13 mld zł, na koniec 2007 r. – 9,5 mld zł, na koniec 2006 r. – 6,5 mld zł.

Wzrost pomiędzy 2007 a 2008 r. był większy niż pomiędzy 2008 a 2009 r., co na tle głębokich spadków na giełdach akcji, deprecjacji polskiej waluty czy wskazań parametrów makroekonomicznych (sprzedaż detaliczna, produkcja przemysłowa) można uznać za objaw prężności rynku (szerzej ten temat jest omówiony na stronie Komisji Nadzoru Finansowego). W 2009 r. wartość nominalna produktów strukturyzowanych



Rys. 4. Liczba rozpoczętych subskrypcji produktów strukturyzowanych w Polsce w latach 2000–2013 według roku zakończenia

Źródło: opracowanie własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).



Rys. 5. Liczba rozpoczętych produktów strukturyzowanych w Polsce w poszczególnych miesiącach w latach 2000–2013

Źródło: opracowanie własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

ryzowanych znajdujących się w obiegu w relacji do PKB wyniosła zaledwie około 1,1% ogółu zakończonych w latach 2000–2013 produktów strukturyzowanych, co stanowi niższy poziom nie tylko w porównaniu z krajami Europy Zachodniej, ale również z państwami Europy Środkowo-Wschodniej. W latach 2007–2008 wartość

Tabela 2. Liczba rozpoczętych produktów strukturyzowanych w Polsce w poszczególnych miesiącach w latach 2000–2013

Miesiąc	Rok rozpoczęcia produktu	Liczba rozpoczętych produktów	Miesiąc	Rok rozpoczęcia produktu	Liczba rozpoczętych produktów
Styczeń	2005	1	Maj	2003	1
	2006	4		2006	2
	2007	9		2007	3
	2008	6		2008	24
	2009	12		2009	46
	2010	34		2010	45
	2011	31		2011	27
	2012	21		2012	25
Luty	2001	1	Czerwiec	2001	1
	2004	1		2002	3
	2006	2		2004	1
	2007	3		2005	1
	2008	21		2006	5
	2009	31		2007	14
	2010	39		2008	43
	2011	37		2009	48
Marzec	2012	26	2010	42	
	2013	27	2011	39	
	2002	3	2012	28	
	2005	2	2013	27	
	2006	15	Lipiec	2001	2
	2007	12		2005	2
	2008	25		2006	6
	2009	62		2007	12
2010	58	2008		20	
2011	36	2009		41	
2012	29	2010		36	
2013	31	2011		31	
Kwiecień	2002	1	2012	30	
	2004	2	2013	27	
	2006	4	Sierpień	2005	3
	2007	8		2006	6
	2008	18		2007	12
	2009	53		2008	41
	2010	48		2009	37
	2011	41		2010	36
2012	25	2011		35	
2013	24	2012		25	
			2013	24	

cd. tabeli 2

Miesiąc	Rok rozpoczęcia produktu	Liczba rozpoczętych produktów	Miesiąc	Rok rozpoczęcia produktu	Liczba rozpoczętych produktów
Wrzesień	2000	1	Listopad	2000	1
	2004	1		2001	1
	2005	2		2003	1
	2007	13		2004	1
	2008	38		2005	4
	2009	33		2006	5
	2010	40		2007	13
	2011	36		2008	11
	2012	24		2009	35
	2013	33		2010	31
Październik	2001	4	2011	30	
	2003	3	2012	29	
	2005	3	2013	26	
	2006	7	Grudzień	2003	1
	2007	13		2004	1
	2008	27		2005	4
	2009	37		2006	10
	2010	35		2007	13
	2011	32		2008	16
	2012	29		2009	38
2013	35	2010		27	
				2011	25
				2012	19
			2013	24	


Źródło: opracowanie i obliczenia własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

nominalna produktów strukturyzowanych znajdujących się w obiegu w relacji do PKB wyniosła około 1,5%, a w latach 2003–2006 odpowiednio 0,22%, 0,16%, 0,38% i 0,55%.

3. Stopa zwrotu brutto produktów strukturyzowanych zakończonych w latach 2000–2013


Stopa zwrotu brutto produktów zakończonych w latach 2000–2013 kształtowała się w przedziale od –62,83% do 154,33% (zob. rys. 6 i 7).

Najgorszy wynik, czyli –62,83%, osiągnął produkt strukturyzowany, którego dystrybutorem była instytucja Wealth Solutions Sp. z o.o., a partnerem Royal



Rys. 6. Ujemna stopa zwrotu brutto (w skali roku) produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013

Źródło: opracowanie i obliczenia własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).



Rys. 7. Dodatnia stopa zwrotu brutto (w skali roku) produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013

Źródło: opracowanie i obliczenia własne na podstawie danych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

Polska TUnŻ SA. Był to produkt o 6-miesięcznym okresie trwania¹ i minimalnej kwocie inwestycji na poziomie 10 000 zł. Produkt miał formę prawną grupo-

¹ Subskrypcja od 9 czerwca do 17 czerwca 2008 r. Czas trwania inwestycji: od 27 czerwca do 29 grudnia 2008 r.

wego ubezpieczenia na życie i dożycie, gdzie stroną zawierającą umowę ubezpieczenia był Royal Polska TUnŻ SA oraz Wealth Solutions Sp. z o.o. Wpłata wnoszoną przez inwestora była składka ubezpieczeniowa. Środki wypłacane po zakończeniu inwestycji były świadczeniem ubezpieczeniowym z tytułu dożycia. Suma ubezpieczenia z tytułu śmierci ubezpieczonego wynosiła 101% wartości składki zainwestowanej. Suma ubezpieczenia z tytułu śmierci ubezpieczonego w wypadku komunikacyjnym wynosiła 106% wartości składki zainwestowanej. Zysk oparty był na koszyku złożonym z akcji sześciu rosyjskich spółek: Lukoil, Gazprom, Rosneft, Norilsk Nickel, Surgutneftgaz, Tatneft. W karcie informacyjnej produktu strukturyzowanego napisano: „Inwestycja daje szansę na 13% zysku od zainwestowanego kapitału po 6 miesiącach. Zysk, wolny od podatku Belki, zostanie wypłacony wówczas, gdy notowania akcji żadnej z sześciu spółek w trakcie trwania inwestycji nie spadną o 30% lub więcej w odniesieniu do ich wartości w dniu startu inwestycji. W sytuacji, gdy notowania przynajmniej jednej ze spółek spadną o 30% lub więcej poniżej poziomu z dnia 27 czerwca, na zakończenie inwestycji inwestor otrzyma 113% zainwestowanego kapitału pomniejszone o najniższą stopę zwrotu osiągniętą w dniu zakończenia inwestycji spośród wyników wszystkich sześciu spółek (pod warunkiem że będzie to ujemna stopa zwrotu). Jeśli jednak na koniec okresu inwestycji pomimo pokonania w trakcie bariery –30% żadna ze spółek nie przyniesie ujemnej stopy zwrotu, inwestor otrzyma zysk w wysokości 13% zainwestowanych środków” (Wealth Solutions, <https://wealth.pl>, dostęp: 31.12.2013). W okresie trwania inwestycji możliwe było wycofanie środków po aktualnej wartości instrumentów finansowych składających się na lokatę. Opłata za wycofanie środków wynosiła 0%.

Największą stopę zwrotu brutto, tj. stopę zwrotu na poziomie 154,33%, osiągnął produkt strukturyzowany o nazwie Arka Global Index 2007, którego emitentem była instytucja BZ WBK AIB TFI. Był to produkt w formie funduszu inwestycyjnego zamkniętego, o 48-miesięcznym okresie trwania² i minimalnej kwocie inwestycji na poziomie 5000 zł. Zysk z inwestycji oparty był na koszyku złożonym z indeksów S&P 500, DJ Eurostoxx 50, Nikkei 225.

Średnia stopa zwrotu brutto zakończonych w latach 2000–2013 produktów strukturyzowanych wynosiła 4,31% i była o 1 pkt proc. wyższa od średniej stopy inflacji w latach 2000–2013. Ponadto 50% zakończonych produktów strukturyzowanych z wyznaczoną stopą zwrotu odnotowało stopę zwrotu brutto co najwyżej na poziomie 0,1% (zob. tabela 3).

Najczęściej zakończone produkty strukturyzowane miały stopę zwrotu brutto na poziomie 0%. Takich produktów strukturyzowanych było 728 w badanym okresie, co stanowi 40% ogółu zakończonych produktów strukturyzowanych na

² Subskrypcja od 10 listopada do 25 listopada 2003 r. Czas trwania inwestycji: od 1 grudnia 2003 r. do 28 grudnia 2007 r.

Tabela 3. Podstawowe statystyki stóp zwrotu brutto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013 oraz stopy inflacji I względem analogicznego miesiąca roku poprzedniego

Statystyki	Stopa zwrotu brutto (%)	Inflacja (%)
Średnia	0,043	3,335
Błąd standardowy	0,002	0,187
Mediana	0,001	3,300
Odchylenie standardowe	0,101	2,425
Wariancja próbki	0,010	5,880
Minimum	-0,628	0,200
Maksimum	1,543	11,600

Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

Tabela 4. Zestawienie stóp zwrotu brutto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013

Wyszczególnienie	Liczba zakończonych produktów strukturyzowanych	Odsetek produktów w stosunku do ogółu zakończonych produktów strukturyzowanych z wyznaczoną stopą zwrotu
Produkty strukturyzowane zakończone z ujemną stopą zwrotu	81	4,85
Produkty strukturyzowane zakończone ze stopą zwrotu 0%	728	43,57
Produkty strukturyzowane zakończone z dodatnią stopą zwrotu	862	51,59
Stopa zwrotu nieokreślona	149	8,92
Stopa zwrotu w przedziale [-1%,10%)	40	2,39
Stopa zwrotu w przedziale [-10%,-20%)	18	1,08
Stopa zwrotu na poziomie -20%	20	1,20
Stopa zwrotu na poziomie -36,87%	1	0,06
Stopa zwrotu na poziomie -40,37%	1	0,06
Stopa zwrotu na poziomie -62,83%	1	0,06
Stopa zwrotu w przedziale (0% , 1%)	101	6,04
Stopa zwrotu w przedziale [1 % , 2%)	77	4,61
Stopa zwrotu w przedziale [2% , 3%)	73	4,37
Stopa zwrotu w przedziale [3 % , 4%)	79	4,73
Stopa zwrotu w przedziale [4% , 5%)	56	3,35
Stopa zwrotu w przedziale [5% , 6%)	45	2,69

cd. tabeli 4

Wyszczególnienie	Liczba zakończonych produktów strukturyzowanych	Odsetek produktów w stosunku do ogółu zakończonych produktów strukturyzowanych z wyznaczoną stopą zwrotu
Stopa zwrotu w przedziale [6%, 7%)	37	2,21
Stopa zwrotu w przedziale [7%, 8%)	37	2,21
Stopa zwrotu w przedziale [8 %, 9%)	34	2,03
Stopa zwrotu w przedziale [9%, 10%)	25	1,50
Stopa zwrotu w przedziale [10%,11%)	41	2,45
Stopa zwrotu w przedziale [11%, 12%)	17	1,02
Stopa zwrotu w przedziale [12%, 20%)	132	7,90
Stopa zwrotu w przedziale [20%, 30%)	60	3,59
Stopa zwrotu w przedziale [30%, 50%)	40	2,39
Stopa zwrotu w przedziale [50%, 155%)	8	0,48

Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

polskim rynku kapitałowym oraz 43,57% ogółu produktów, dla których znany jest zysk w dniu zakończenia inwestycji. Spośród 1820 zakończonych w latach 2000–2013 produktów strukturyzowanych 1671 ma określoną stopę zwrotu brutto, z czego 862 zakończyło się z dodatnią stopą zwrotu, a 81 z ujemną stopą zwrotu (zob. tabela 4).

4. Roczna stopa zwrotu netto produktów strukturyzowanych zakończonych w latach 2000–2013


Poza stopą zwrotu brutto z inwestycji w produkty strukturyzowane możemy również mówić o efektywności produktów poprzez analizę rocznej stopy zwrotu netto zamkniętych produktów strukturyzowanych. Roczna stopa zwrotu netto zakończonych w latach 2000–2013 produktów kształtowała się w przedziale od –125,66% do 31,25%.

Średnia roczna stopa zwrotu netto produktów strukturyzowanych zakończonych w latach 2000–2013 wyniosła 2,14% i była o 3,66% niższa od średniej stopy zwrotu z lokat rocznych, wyznaczonej na podstawie obserwacji z okresu styczeń 2000 – grudzień 2013, oraz była wyższa o 1,19% od średniego poziomu inflacji w badanym okresie (tabela 5, rys. 8 i 9).

Tabela 5. Podstawowe statystyki rocznych stóp zwrotu netto produktów strukturyzowanych zakończonych w latach 2000–2013 oraz oprocentowania lokat na 12 miesięcy

Statystyki	Roczna stopa zwrotu netto produktów strukturyzowanych (%)	Oprocentowanie lokat na okres 12 miesięcy
Średnia	2,14	5,8
Błąd standardowy	0,13	0,31
Mediana	0,08	4,3
Minimum	-125,66	2
Maksimum	31,25	17,6


Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).



Rys. 8. Ujemna roczna stopa zwrotu netto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013

Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).


Najczęściej zakończone produkty strukturyzowane miały roczną stopę zwrotu netto na poziomie 0%. Takich produktów strukturyzowanych było 730 w badanym okresie, co stanowi 40,11% ogółu zakończonych produktów strukturyzowanych na polskim rynku kapitałowym oraz 43,69% ogółu produktów, dla których znana jest roczna stopa zwrotu netto w dniu zakończenia inwestycji. Spośród 1820 zakończonych w latach 2000–2013 produktów strukturyzowanych 1671 ma określoną roczną stopę zwrotu netto, z czego 860 zakończyło się z dodatnią stopą zwrotu.



Rys. 9. Dodatnia roczna stopa zwrotu netto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013 bez wartości krańcowych


Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

Najwyższą średnią roczną stopę zwrotu netto odnotowano w 2003 r. (rys. 10 i 11), wynosiła ona 0,731%. Produkt ten stworzyły instytucje BZ WBK i Bank BPH (tabela 6).



Rys. 10. Średnia roczna stopa zwrotu netto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013 w zestawieniu ze średnim rocznym oprocentowaniem lokat na 12 miesięcy

Źródło: opracowanie własne.



Rys. 11. Średnia roczna stopa zwrotu netto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013 w zestawieniu ze średnią roczną stopą inflacji

Źródło: opracowanie własne na podstawie danych GUS oraz danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

Tabela 6. Charakterystyka produktów strukturyzowanych zakończonych w 2003 r.

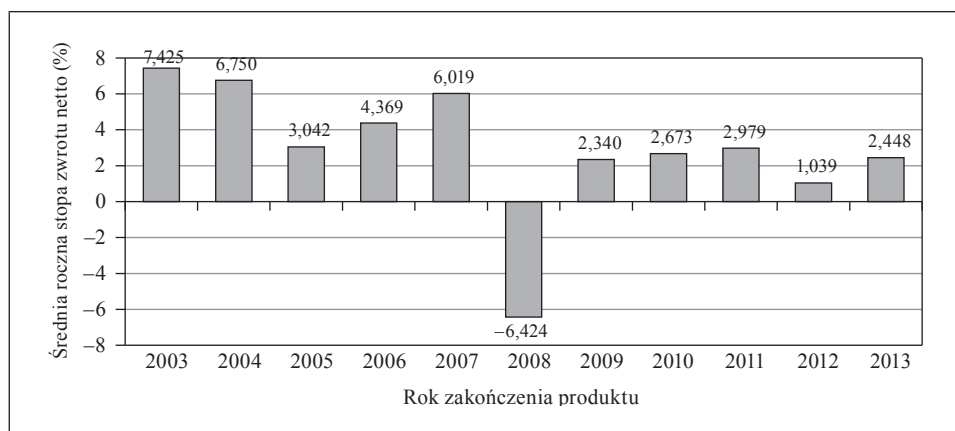
Instytucja	Produkt	Koszyk	Czas trwania w miesiącach	Początek inwestycji	Stopa zwrotu brutto (%)	Roczna stopa zwrotu netto (%)	Forma prawna
BZ WBK	Amer Index	S&P500	48	17.10.2003	19,77	4,0	lokata inwestycyjna
BZ WBK	Euro Index	DJ Euro Stoxx 50	48	17.10.2003	22,62	4,6	lokata inwestycyjna
BZ WBK	Amer Index	S&P500	48	6.06.2003	25,91	5,3	lokata inwestycyjna
Bank BPH	Lokata Eurostopa zwrotu	DJ Euro Stoxx 50, WIG20	36	31.10.2003	22,7	6,1	bankowe papiery wartościowe
BZ WBK AIB TFI	Arka Global Index 2007	S&P500; DJ Euro Stoxx 50; Nikkei 225	48	29.12.2003	154,33	31,3	FIZ

Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

Najniższą stopę zwrotu netto wśród zakończonych w latach 2000–2013 produktów strukturyzowanych odnotowano w 2007 r. Wartość końcową zysku tworzyły 119 produktów, z czego dla 15 produktów nie określono rocznej stopy zwrotu netto z uwagi na brak odpowiednich danych. Spośród rozpoczętych w 2007 r. produktów strukturyzowanych największą stopę zwrotu osiągnął produkt o nazwie 5Y Obligacja powiązana z koszykiem spółek Luxury Goods, którego emitentem i dystrybutorem był Citi Handlowy. Najniższą stopę zwrotu spośród produktów rozpoczętych w 2007 r. osiągnął produkt strukturyzowany o nazwie Climate Core³, którego emitentem i dystrybutorem był Nwai. Inwestycja była oparta na trzech aktywnie zarządzanych funduszach operujących w:

- branży energii odnawialnej,
- branży związanej z gospodarką wodną,
- branży towarów rolnych.

Udziały poszczególnych funduszy były równe – wynosiły 1/3. Minimalna kwota inwestycji wynosiła 100 000 zł, a poziom ochrony kapitału – 80%.



Rys. 12. Średnia roczna stopa zwrotu netto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013


Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).

Jak już wspomniano, największą średnią roczną stopę zwrotu netto osiągniętą przez zakończone produkty strukturyzowane odnotowuje się dla

³ Forma inwestycji: Ubezpieczenie na życie i dożycie. Ubezpieczyciel: TU Allianz Życie Polska SA. Ubezpieczający: New World Sp. z o.o. Agent kalkulacyjny: Merrill Lynch International. Rachunek escrow: ING Bank Śląski SA.

produktów rozpoczętych w 2003 r. (10,24% na rok), a najmniejszą, wynoszącą 0,73%, w 2007 r. Rokiem, w którym zakończyły się produkty strukturyzowane z najwyższą roczną stopą zwrotu netto spośród wszystkich analizowanych lat, był 2003 r.

W 2008 r. obserwujemy znaczną stratę (zob. rys. 12) oraz największe odchylenie stopy zwrotu z zakończonych produktów strukturyzowanych od średniej rocznej stopy inflacji (rys. 13).



Rys. 13. Średnia stopa zwrotu netto produktów strukturyzowanych zakończonych w Polsce w latach 2000–2013 w zestawieniu ze średnią roczną stopą inflacji

Źródło: opracowanie własne na podstawie danych dotyczących poszczególnych produktów strukturyzowanych dostępnych na stronie internetowej serwisu Structus.pl (<http://www.structus.pl>, dostęp: 2.12.2014).


Produkty strukturyzowane zakończone w 2008 r. odnotowały średnią stratę w skali roku na poziomie $-6,424\%$. Na stratę złożyło się 14 produktów strukturyzowanych, a w szczególności produkt o nazwie Skarby Rosji. Najkorzystniej zakończył się produkt o nazwie Indeks na Zysk nr ILD01 – Hang Seng Indeks, którego emitentem i dystrybutorem był Bank Pekao SA⁴. Kapitał był objęty 100-procentową ochroną przy wskaźniku partycypacji na poziomie 100–130%.

⁴ Subskrypcja od 24 czerwca do 30 czerwca 2005 r. Czas trwania inwestycji: od 30 czerwca 2005 r. do 30 czerwca 2008 r.

5. Zakończenie

W artykule przedstawiono rynek produktów strukturyzowanych w Polsce w kontekście stóp zwrotu z zakończonych inwestycji w produkty strukturyzowane. Wyznaczono stopy zwrotu brutto oraz roczne stopy zwrotu netto zakończonych w latach 2000–2013 produktów strukturyzowanych. Stopy zwrotu produktów strukturyzowanych zestawiono z inflacją oraz ze średnim rocznym oprocentowaniem lokat na okres 12 miesięcy.

Produkty strukturyzowane czy inwestycje alternatywne jak każda inwestycja posiadają zarówno wady, jak i zalety. Zapewniają wprawdzie ochronę nominalnej wartości pieniądza, ale nie chronią wartości realnej pieniądza. Czy zapewniają satysfakcjonujący zysk? Na to pytanie każdy inwestor musi odpowiedzieć indywidualnie, ponieważ każdy ma inne preferencje, inną skalę ryzyka oraz inny poziom zadowolenia i satysfakcji z inwestycji. Należy jednakże wziąć pod uwagę fakty, zgodnie z którymi zaledwie 51% produktów strukturyzowanych w okresie 2000–2013 zakończyło się, osiągając dodatnią stopę zwrotu (rys. 14).



Rys. 14. Struktura badanej zbiorowości ze względu na roczną stopę zwrotu netto zakończonych produktów strukturyzowanych

Źródło: opracowanie własne na podstawie wykonanych badań.

Przeprowadzone w artykule analizy mogą być podstawą do dalszych badań nad produktami strukturyzowanymi, w szczególności w zakresie analizy portfelowej. Szczegółowe informacje odnośnie do stóp zwrotu poszczególnych form prawnych można znaleźć w pracach [Hadaś-Dyduch 2013a, 2013b, 2013c, 2013d, 2013e, 2013f, 2013g, 2014a, 2014b, 2014c, 2014d, 2014e, 2014f, Dyduch 2013].

Literatura

- Dyduch M. [2013], *Bankowe papiery wartościowe strukturyzowane* [w:] *Prognostyczne uwarunkowania ryzyka gospodarczego i społecznego*, red. W. Szkutnik, Studia Ekonomiczne, Zeszyty Naukowe Wydziałowe, nr 124, Uniwersytet Ekonomiczny w Katowicach, Katowice.
- Hadaś-Dyduch M. [2013a], *Efektywność inwestycji w Bankowe Papiery Wartościowe* [w:] *Zarządzanie finansami. Mierzenie wyników przedsiębiorstw i ocena efektywności inwestycji*, Zeszyty Naukowe, nr 760, Finanse, Rynki Finansowe, Ubezpieczenia, nr 59, red. D. Zarzecki, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin.
- Hadaś-Dyduch M. [2013b], *Metoda wspomagająca wycenę składowych inwestycji alternatywnych* [w:] *Problemy społeczno-ekonomiczne w uwarunkowaniach ryzyka i statystycznej nieokreśloności. Metody i modele w rozwoju regionów*, red. W. Szkutnik, Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach, Katowice.
- Hadaś-Dyduch M. [2013c], *Ranking produktów strukturyzowanych wyemitowanych na polskim rynku kapitałowym w latach 2001–2010* [w:] *Zastosowanie metod ilościowych w naukach ekonomicznych*, Zeszyty Naukowe Wyższej Szkoły Bankowej we Wrocławiu, nr 2(34), red. S. Forlicz, Wyższa Szkoła Bankowa w Poznaniu, Wrocław.
- Hadaś-Dyduch M. [2013d], *Stopa bezrobocia jako instrument bazowy lokaty strukturyzowanej* [w:] *Problemy społeczno-ekonomiczne w uwarunkowaniach ryzyka i statystycznej nieokreśloności. Metody i modele w rozwoju regionów*, red. W. Szkutnik, Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach, Katowice.
- Hadaś-Dyduch M. [2013e], *Szacowanie efektywności wybranej strategii inwestowania w produkty strukturyzowane na polskim rynku kapitałowym* [w:] *Rynek kapitałowy. Skuteczne inwestowanie*, Zeszyty Naukowe, nr 768, Finanse, Rynki Finansowe, Ubezpieczenia, nr 63, red. W. Gos, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin.
- Hadaś-Dyduch M. [2013f], *Wycena produktu bankowego na przykładzie lokaty indeksowej* [w:] *Tendencje w ekonomii i finansach. Konteksty teoretyczne i rozwiązania praktyczne*, red. H. Buk i in., Uniwersytet Ekonomiczny w Katowicach, Centrum Badań i Ekspertyz, Katowice.
- Hadaś-Dyduch M. [2013g], *Wykorzystanie metod analizy falkowej do mierzenia efektywności polisy inwestycyjnej*, „Wiadomości Ubezpieczeniowe. Nauka dla Praktyki”, nr 1/2013.
- Hadaś-Dyduch M. [2014a], *Charakterystyka rynku produktów strukturyzowanych oferowanych w formie Funduszy Inwestycyjnych Zamkniętych zakończonych w latach 2000–2013*, „Wiadomości Ubezpieczeniowe. Nauka dla Praktyki”, nr 2/2014.
- Hadaś-Dyduch M. [2014b], *Efektywność alternatywnych inwestycji kapitałowych na przykładzie polisy inwestycyjnej* [w:] *Modelowanie preferencji a ryzyko '14*, Studia Ekonomiczne, Zeszyty Naukowe Wydziałowe Uniwersytetu Ekonomicznego w Katowicach, nr 178, red. T. Trzaskalik, Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach, Katowice.
- Hadaś-Dyduch M. [2014c], *Inwestycje alternatywne w kontekście efektywności inwestycji kapitałowej na przykładzie produktów strukturyzowanych*, Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach, Katowice.

- Hadaś-Dyduch M. [2014d], *Inwestycje alternatywne z uwzględnieniem otwartych funduszy emerytalnych* [w:] *Ubezpieczenia wobec ryzyka długowieczności/starości*, red. J. Lisowski, K. Łyskawa, Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu, Poznań.
- Hadaś-Dyduch M. [2014e], *The Market for Structured Products in the Context of Inflation* [w:] *Proceedings of the 8th Professor Aleksander Zelias International Conference on Modelling and Forecasting of Socio-Economic Phenomena*, M. Papież, S. Śmiech (eds), Foundation of the Cracow University of Economics, Cracow, <http://pliki.konferencjazakopiainska.pl/proceedings.html>.
- Hadaś-Dyduch M. [2014f], *Koncepcja oceny efektywności finansowej inwestycji w certyfikaty dyskontowe na przykładzie LOTOS SA* [w:] *Zarządzanie ryzykiem kapitałowym i ubezpieczeniowym oraz społecznymi uwarunkowaniami ryzyka rynku pracy*, Studia Ekonomiczne, Zeszyty Naukowe Wydziałowe Uniwersytetu Ekonomicznego w Katowicach, nr 181, red. W. Szkutnik, Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach, Katowice.

An Analysis of Returns Generated by Structured Products in the Years 2000–2013

(Abstract)

The aim of this article is to present the structured products market in Poland in the context of gains and losses from completed investments in structured products. It shows when an investment in structured products brought investors profits and when losses. In order to do the analysis, the return rate of gross and net annual rate of return over the period 2000–2013 were assigned to structured products. The rate of return on structured products was compared with inflation and the average annual interest rate of deposits for a period of 12 months. The paper offers a detailed description of the best and the worst in terms of the gross rate of return for structured products on the Polish capital market during the years 2000–2013. The analysis looked at 1800 products available during from early 2000 to the end of 2013.

Keywords: structured products, alternative investments, finance, capital market.