

Warsaw University of Life Sciences – SGGW  
Institute of Economics and Finance  
Department of Econometrics and Statistics

**QUANTITATIVE METHODS  
IN ECONOMICS**

**METODY ILOŚCIOWE W BADANIACH  
EKONOMICZNYCH**

**Volume XXIII, No. 3**

Warsaw 2022

## **EDITORIAL BOARD**

Editor-in-Chief: Bolesław Borkowski

Vice-Editor-in-Chief: Hanna Dudek

Managing Editor: Michał Gostkowski, Grzegorz Koszela

Theme Editors:

Econometrics: Bolesław Borkowski

Multidimensional Data Analysis: Wiesław Szczesny

Mathematical Economy: Zbigniew Binderman

Analysis of Labour Market: Joanna Landmesser-Rusek

Financial Engineering: Monika Krawiec

Data Science: Michał Gostkowski

Theory of Risk: Marek Andrzej Kociński

Statistical Editor: Wojciech Zieliński

Technical Editors: Jolanta Kotlarska, Elżbieta Saganowska

Language Editor: Agata Cienkusz

Native Speaker: Yochanan Shachmurove

Editorial Assistant: Luiza Ochnio, Łukasz Pietrych

## **SCIENTIFIC BOARD**

Adnene Ajimi (University of Sousse, Tunisia)

Heni Boubaker (University of Sousse, Tunisia)

Vasily Dikussar (Russian Academy of Sciences, Russia)

Peter Friedrich (University of Tartu, Estonia)

Paolo Gajo (University of Florence, Italy)

Agnieszka Gehringer (University of Göttingen, Germany)

Anna Maria Gil-Lafuente (University of Barcelona, Spain)

Jaime Gil-Lafuente (University of Barcelona, Spain)

Vasile Glavan (Moldova State University, Moldova)

Francesca Greselin (University of Milano-Bicocca, Italy)

Ana Kapaj (Agriculture University of Tirana, Albania)

Jirawan Kitchaicharoen (Chiang Mai University, Thailand)

Yuriy Kondratenko (Black Sea State University, Ukraine)

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

Karol Kukula (University of Agriculture in Krakow, Poland)

Kesra Nermend (University of Szczecin, Poland)

Nikolas N. Olenev (Russian Academy of Sciences, Russia)

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

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

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

Marina Z. Solesvik (Nord University, Norway)

Ewa Syczewska (Warsaw School of Economics, Poland)

Achille Vernizzi (University of Milan, Italy)

Andrzej Wiatrak (University of Warsaw, Poland)

Dorota Witkowska (University of Lodz, Poland)

ISSN 2082-792X

e-ISSN 2543-8565

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

Warsaw 2022, Volume XXIII, No. 3

Journal homepage: <https://qme.sggw.edu.pl>

Published by Warsaw University of Life Sciences Press

## CONTENTS

Zbyrowski Rafał – Przyczynowość cen na rynku nieruchomości w Polsce.....	67
Szupiluk Ryszard – Funkcja $\log(\cosh)$ i jej rola w ślepej separacji sygnałów .....	78
Shevchuk Victor – Time-Varying Exchange Rate Pass-through in Eastern Europe .....	88

## PRZYCZYNOWOŚĆ CEN NA RYNKU NIERUCHOMOŚCI W POLSCE

Rafał Zbyrowski  <https://orcid.org/0000-0001-8499-8899>

Katedra Metod Ilościowych  
Wydział Zarządzania  
Uniwersytet Warszawski  
e-mail: rzbyrowski@wz.uw.edu.pl

**Streszczenie:** W artykule poddano analizie ekonometrycznej zmienne ilościowe związane z rynkiem nieruchomości w Polsce. Autor rozpatruje zależności występujące na rynku mieszkaniowym wykorzystując test przyczynowości w sensie Grangera. Rezultatem przeprowadzonej analizy jest określenie zależności pomiędzy cenami na rynku nieruchomości i stanem koniunktury gospodarczej oraz zdolnością kredytową nabywców. Wyniki badań wzbogacono wnioskami wynikającymi z obserwacji zmian zachodzących na polskim rynku obrotu nieruchomościami oraz w zakresie zmieniających się średnich wynagrodzeń brutto na przestrzeni dekady.

**Słowa kluczowe:** przyczynowość, rynek nieruchomości, test Granger'a, analiza ekonometryczna, ekonometria, modelowanie, zdolność kredytowa, wynagrodzenie brutto, wskaźnik koniunktury, kointegracja

**JEL classification:** C01, C5, R31, E3

### WSTĘP

Celem głównym artykułu jest weryfikacja zmiennych oddziałujących na ceny nieruchomości mieszkaniowych w długim okresie w Polsce. Rynek nieruchomości jest podatny na wpływ spekulacji i wielu czynników przypadkowych, które zakłócają występowanie prawidłowości ekonomicznych. Sprzedawcy mieszkań w Polsce, ale również poza granicami naszego kraju stosują przemyślane strategie sprzedażowe, którym towarzyszy często tendencja do zawyżania cen. Stało się to przedmiotem badań prowadzonych przez Lukas'a, Mollica, Nagi'go, Trück'a [Lukas i in. 2018], które ponadto wykazały spadek skuteczności reklamy wraz ze wzrostem cen nieruchomości. Sugeruje to, że

<https://doi.org/10.22630/MIBE.2022.23.3.7>

potencjalni nabywcy są w stanie zidentyfikować istotnie zawyżone ceny. Jednak w przypadku nieruchomości nietypowych oraz w obszarach o silnym wzroście cen, nabywcy nieruchomości stawali się bardziej podatni na reklamę i inne działania wdrażane przez sprzedawców. W literaturze dotyczącej rynku nieruchomości dostrzega się również niesłuchanie istotne znaczenie wpływu lokalizacji na poziom cen. Stąd prowadzone są liczne analizy przestrzenne wspomagające modelowanie cen nieruchomości [Curto i in. 2017]. Złożony charakter rynku nieruchomości wraz z presją na jego rozwój prowadzą do powstawania tzw. baniek spekulacyjnych, które charakteryzują się znaczą heterogenicznością nawet w obrębie tego samego miasta, co jest szczególnie widoczne w okresie kryzysów [Liu i in. 2016]. Istotnym problemem w zakresie monitorowania rynku nieruchomości i prowadzenia badań jest również niewystarczająca dostępność danych o wysokiej jakości informacyjnej [Curto, Fregonara 2019]. Biorąc pod uwagę zasygnalizowaną tylko fragmentarycznie głębię procesów zachodzących na rynku nieruchomości należy przyjąć w tym kontekście, że empiryczne potwierdzenie tez niekontrowersyjnych ekonomicznie może stanowić wyzwanie z powodu występowania mechanizmów spekulacyjnych, marketingowych oraz znacznego zróżnicowania przestrzennego cen nieruchomości. W ujęciu teoretycznym ceny na rynku nieruchomości rosną wraz ze wzrostem zdolności kredytowej nabywców. Mieszkania są kapitałochłonne, więc znaczna ich liczba jest nabywana na kredyt. Zatem wzrost zdolności kredytowej powoduje zwykle wzrost popytu, co przy danym zasobie mieszkaniowym kraju jest stabilizowane przez wzrost cen. Taki mechanizm widoczny był już w innych badaniach [Zbyrowski 2017], które jednak odnosiły się do krótszego horyzontu czasowego oraz zawierały mniejszy zbiór zmiennych egzogenicznych.

Koniunktura gospodarcza wywiera wpływ na ceny mieszkań. Z tego względu należy oczekiwać, że wraz z lepszą oceną ogólnej koniunktury zarówno inwestorzy jak i nabywcy indywidualni skłonni są zaakceptować wyższe ceny. Zmiany średnich wynagrodzeń brutto w gospodarce determinują siłę nabywczą Polaków na rynku mieszkaniowym. Warto zaznaczyć, że w pierwszej kolejności wzrost wynagrodzeń powoduje wzrost zdolności kredytowej gospodarstw domowych. Ostatecznie jednak wzrost wynagrodzeń może pośrednio generować wzrost cen na rynku nieruchomości. Z tego względu poddano osobnemu testowaniu zmiany średnich zarobków brutto w relacji do zmian indeksu cen nieruchomości mieszkaniowych. Badanie wydaje się interesujące z racji pojawiających się tez [Sadowski 2018], że wzrosty cen mieszkań na przestrzeni dekady poddanej badaniu były dość umiarkowane. Jednocześnie średnie wynagrodzenia brutto rosły dość znacząco w ujęciu nominalnym.

## SZEREGI CZASOWE WYKORZYSTANE W BADANIU

Badanie zostało zaprojektowane w taki sposób, aby umożliwić empiryczną weryfikację zależności cen mieszkań w Polsce od fundamentalnych czynników

ekonomicznych (tj. zdolność kredytowa, średnie wynagrodzenia brutto) oraz syntetycznego wskaźnika koniunktury gospodarczej GUS. Ogólny wskaźnik koniunktury (OWKt) stanowi wypadkową wskaźników koniunktury z różnych dziedzin gospodarki i można go utożsamiać z oceną stanu koniunktury kraju. Stąd w artykule sformułowano następującą hipotezę badawczą: Ceny nieruchomości mieszkaniowych w Polsce zależą od czynników fundamentalnych bezpośrednio związanych z rynkiem obrotu nieruchomościami oraz od stanu oceny koniunktury gospodarczej w Polsce.

Oznaczenia zmiennych wykorzystanych w badaniu:

ICNt – indeks cen nieruchomości w okresie t


ZDKt – zdolność kredytowa w okresie t


OWKt – ogólny (tj. syntetyczny) wskaźnik koniunktury w okresie t

WYNt – średnie wynagrodzenie brutto w okresie t

Dane użyte do budowy modelu zostały zaczerpnięte ze strony internetowej Głównego Urzędu Statystycznego oraz firm Home Broker i Open Finance. Obejmują one okres od września roku 2008 do maja roku 2018, czyli prawie dekadę (z miesięczną częstotliwością pomiarów). Dodatkowo przetestowano również wpływ konsekwentnie rosnących średnich miesięcznych wynagrodzeń (WYNt) na ceny nieruchomości mieszkaniowych w Polsce.

Rysunek 1. Szeregi czasowe wykorzystanych w badaniu zmiennych OWKt, WYNt, ZDKt oraz ICNt





Źródło: opracowanie własne

Tabela 1. Test stacjonarności ADF badanych szeregów czasowych na poziomach i pierwszych różnicach

	ICN		OWK		WYN		ZDK	
	t-Statistic	Prob.	t-Statistic	Prob.	t-Statistic	Prob.	t-Statistic	Prob.
ADF level	-1,9504	0,3084	-1,5688	0,4952	-0,0918	0,9468	-0,9052	0,7837
Test (ADF level) critical values 5% level	-2,8867		-2,8872		-2,8882		-2,8855	
ADF 1st difference	-7,8660	0,0000	-7,6228	0,0000	-4,2262	0,0009	-12,1489	0,0000
Test (ADF 1st difference) critical values 5% level	-2,8867		-2,8874		-2,8882		-2,8857	

Źródło: opracowanie własne na podstawie obliczeń w programie Eviews

Badanie stacjonarności szeregów czasowych wykazało, że wszystkie zmienne są zintegrowane w stopniu pierwszym i w takiej postaci zostaną uwzględnione w dalszej części analizy (tabela 1). Testy stacjonarności szeregów czasowych przeprowadzono z wykorzystaniem rozszerzonego testu Dickey-Fuller'a (ADF, Augmented Dickey-Fuller test). Test ten wykorzystuje model regresji pomocniczej o postaci:

$$\Delta y_t = \delta y_{t-1} + \sum_{i=1}^k \gamma_i \Delta y_{t-i} + \varepsilon_t \quad (1)$$

gdzie:  $\delta$  i  $\gamma$  – parametry szacowane metodą najmniejszych kwadratów,  $k$  – liczba opóźnień,  $\Delta y_{t-1}$  – wartość szeregu pierwszych różnic badanego zjawiska w okresie  $t-1$ ,  $\varepsilon_t$  – składnik losowy [Maddala 2006]. Hipoteza zerowa testu stanowi, że szereg  $y_t$  jest niestacjonarny z powodu występowania pierwiastka jednostkowego, natomiast hipoteza alternatywna mówi, że badany szereg czasowy jest stacjonarny.

## ANALIZA PRZYCZYNOWOŚCI PRZYROSTÓW BADANYCH ZMIENNYCH

Prowadzenie badań empirycznych jest związane z pojęciem przyczynowości, które jest w istocie pojęciem filozoficznym (Demokryt, Hume, Berkeley). Najczęściej spotykaną operacyjną definicją przyczynowości [Jacobs i in. 1979; Spohn 1984] w ekonometrii jest definicja Wienera-Grangera lub definicja przyczynowości Grangera [Charemza, Deadman 1992]: „ $x$  jest przyczyną (w sensie Grangera)  $y$ , co zapisujemy jako  $x \rightarrow y$ , jeśli bieżące wartości  $y$  można wyprognozować z większą dokładnością przez przeszłe wartości  $x$ , niż w inny sposób, przy zasadzie *ceteris paribus*”. Zgodnie z podejściem zaproponowanym przez Grangera, weryfikacja przyczynowości typu  $x \rightarrow y$  polega na sprawdzeniu, czy zmienna  $x$  może być usunięta z tej części modelu VAR [Sims 1980], która opisuje  $y$  [Granger 1969]. Pomimo, że w literaturze zaproponowano wiele testów przyczynowości [Geweke i in. 1983; Guilkey, Salemi 1982] to jednym z częściej spotykanych jest tzw. test blokowej nie – przyczynowości Grangera [Pesaran 1997]. Test ten przeprowadzono w dalszej części opracowania. W testach uwzględniono pierwsze przyrosty zmiennych. Badanie zależności przyczynowo-skutkowych w sensie Grangera, pozwala stwierdzić czy wybrana zmienna jest przyczyną zmian wartości drugiej zmiennej. Zgodnie z powyższym zmienna  $x$  jest przyczyną w sensie Grangera zmian zmiennej  $y$  wtedy, gdy wartości zmiennej  $y$  mogą być precyzyjniej poddane prognozowaniu poprzez uwzględnienie przeszłych wartości zmiennej  $x$  niż bez uwzględniania tych wartości. Testowanie przyczynowości w sensie Grangera sprowadza się do wykorzystania następującego układu równań:

$$\begin{aligned} Y_t &= \beta_0 + \sum_{j=1}^m \beta_j Y_{t-j} + \sum_{k=1}^n \beta_k X_{t-k} + u_t \\ X_t &= \beta_0 + \sum_{j=1}^m \beta_j X_{t-j} + \sum_{k=1}^n \beta_k Y_{t-k} + u_t \end{aligned} \quad (2)$$

gdzie:  $Y_t$  – wartości zmiennej w okresie bieżącym,  $X_t$  – wartości zmiennej  $X$  w okresie bieżącym,  $\beta$  – parametry strukturalne modelu,  $u_t$  – składnik losowy modelu [Granger 1969].

Hipoteza zerowa w teście przyczynowości w sensie Grangera mówi, że wszystkie parametry  $\beta_k$  są równe zero, co oznacza brak przyczynowości. Hipoteza



alternatywna natomiast zakłada występowanie przyczynowości w sytuacji gdy występują parametry  $\beta_k$  różne od zera.

Tabela 2. Test nie – przyczynowości Grangera dla zmiennych  $D(ICN_t)$  i  $D(OWK_t)$

Null Hypothesis:	Obs	F-Statistic	Prob.
DOWK does not Granger Cause DICN	109	2,98904	0,0224
DICN does not Granger Cause DOWK		0,70803	0,5883

Źródło: opracowanie własne w programie Eviews

Na podstawie przeprowadzonego testu (tabela 2) można stwierdzić, że przyrosty ogólnego wskaźnika koniunktury ( $DOWK_t$ ) są przyczyną w sensie Grangera przyrostów indeksu cen nieruchomości ( $DICN_t$ ).

Tabela 3. Test nie – przyczynowości Grangera dla zmiennych  $D(ICN_t)$  i  $D(ZDK_{t-4})$

Null Hypothesis:	Obs	F-Statistic	Prob.
DZDK_4 does not Granger Cause DICN	114	0,47953	0,0000
DICN does not Granger Cause DZDK_4		1,21923	0,0000

Źródło: opracowanie własne w programie Eviews

W tabeli 3 wykorzystano przyrost zdolności kredytowej z czteromiesięcznym opóźnieniem  $D(ZDK_{t-4})$  ponieważ z wcześniejszych badań autora wynika że zmiany zdolności kredytowej oddziałują na ceny nieruchomości z takim właśnie opóźnieniem [Zbyrowski 2017]. Zatem opóźnione przyrosty zdolności kredytowej  $D(ZDK_{t-4})$  są przyczyną w sensie Grangera przyrostów indeksu cen nieruchomości ( $DICN_t$ ). Wnioski z tabeli 3 sugerują również, że przyrosty indeksu cen nieruchomości ( $DICN_t$ ) mogą być przyczyną w sensie Grangera przyrostów zdolności kredytowej  $D(ZDK_{t-4})$ . Jest to jednak wniosek wątpliwy z merytorycznego punktu widzenia. Warto podkreślić że przeprowadzony test jest jedynie testem nie – przyczynowości w sensie jego autora (tj. Grangera). Natomiast decyzja ostateczna o występowaniu związku przyczynowo-skutkowego powinna uwzględniać szerszy kontekst ekonomiczny.

Tabela 4. Test nie – przyczynowości Grangera dla zmiennych  $D(WYN_t)$  i  $D(ICN_t)$

Null Hypothesis:	Obs	F-Statistic	Prob.
DWYN does not Granger Cause DICN	110	0,58960	0,7379
DICN does not Granger Cause DWYN		0,66104	0,6812

Źródło: opracowanie własne w programie Eviews

Kolejny przeprowadzony test (tabela 4) wykazał brak przyczynowości w sensie Grangera pomiędzy przyrostami średnich wynagrodzeń brutto  $D(WYN_t)$  i przyrostami indeksu cen nieruchomości  $D(ICN_t)$ .

Tabela 5. Test nie – przyczynowości Grangera dla zmiennych  $D(WYN_t)$  i  $D(ZDK_t)$ 

Null Hypothesis:	Obs	F-Statistic	Prob.
DZDK does not Granger Cause DWYN	117	0,98463	0,4192
DWYN does not Granger Cause DZDK		2,47485	0,0486

Źródło: opracowanie własne w programie Eviews

Wykazano także możliwość występowania zależności w sensie Grangera (tabela 5) pomiędzy przyrostami średnich wynagrodzeń brutto  $D(WYN_t)$ , a przyrostami zdolności kredytowej  $D(ZDK_t)$ . Taki związek może posiadać uzasadnienie ekonomiczne, ponieważ systematyczny wzrost wynagrodzeń brutto może dodatkowo wpływać na zdolność kredytową Polaków. Następnie na podstawie testów nie – przyczynowości w sensie Grangera wyszczególniono zmienne do modelu autoregresyjnego VECM. Model VECM oszacowano dla opóźnień od 6 do 6, które ustalono w oparciu o testy długości opóźnień [Kusideł 2000]. Zredukowanie wymiaru szacowanego modelu wpłynęło na ograniczenie liczby parametrów wymagających oszacowania. Na podstawie przyjętej specyfikacji modelu VECM przeprowadzono w dalszej kolejności test kointegracji Johansena [Enders 2003] koncentrując się na wnioskach płynących z zależności długookresowej. Analiza elastyczności krótkookresowych została pominięta z uwagi na przyjęty cel niniejszego opracowania. Tabela 6 potwierdza występowanie dokładnie jednego wektora kointegracji pomiędzy badanymi zmiennymi. W pierwszym etapie procedury wartość testu śladu (50,822) jest znacząco większa od wartości krytycznej 35,193. Stąd liczba wektorów kointegracji jest większa od 0. Jednocześnie w drugim etapie procedury Johansena test śladu 8,589 jest mniejszy od wartości krytycznej 20,262. Zatem liczba wektorów kointegracji wynosi dokładnie jeden.

Tabela 6. Test liczby wektorów kointegracji Johansena dla zmiennych  $ICN_t$ ,  $OWK_t$  i  $ZDK_t$ 

Series: LOG(ICN) LOG(OWK) LOG(ZDK)				
Lags interval (in first differences): 6 to 6				
Unrestricted Cointegration Rank Test (Trace)				
Hypothesized		Trace	0,05	
No. of CE(s)	Eigenvalue	Statistic	Critical Value	Prob.**
None *	0,326114	50,82157	35,19275	0,0005
At most 1	0,069311	8,589348	20,26184	0,7739
At most 2	0,008409	0,903577	9,164546	0,9632

Źródło: opracowanie własne w programie Eviews

Oszacowany wstępnie wektor kointegracji wyraża długookresową zależność pomiędzy badanymi zmiennymi [Brooks 2012]. Jego elementy po znormalizowaniu zawiera tabela 7.

Tabela 7. Znormalizowany wektor kointegracji dla zmiennych  $ICN_t$ ,  $WYN_t$  i  $ZDK_t$ 

Normalized cointegrating coefficients (standard error in parentheses)			
LOG(ICN)	LOG(OWK)	LOG(ZDK)	C
1,000000	-0,950041	0,214785	-3,658240
	(0,12337)	(0,04370)	(0,50796)

Źródło: opracowanie własne w programie Eviews

Wstępną postać relacji kointegrującej można zapisać jako [Syczewska 1999, Majsterek 2014]:

$$\log(ICN_t) = 0,950041 * \log(OWK_t) - 0,214785 * \log(ZDK_t) + 3,65824$$

Z oszacowanego równania wynika, że wzrost wartości ogólnego wskaźnika koniunktury w gospodarce o 1% powoduje średnio wzrost indeksu cen nieruchomości o 0,95 % w długim okresie przy założeniu ceteris paribus [Gajda 2004; Borkowski i in. 2007]. Wpływ koniunktury gospodarczej na ceny nieruchomości jest zatem znaczący.

Ponadto model wskazuje na dość kontrowersyjny ekonomicznie wniosek dotyczący ujemnej zależności zdolności kredytowej  $ZDK_t$  oraz indeksu cen nieruchomości  $ICN_t$ . W rzeczywistości trudno jest zgodzić się ze stwierdzeniem, że zwiększenie zdolności kredytowej zbiega się ze spadkiem cen nieruchomości w długim okresie. Należy zwrócić uwagę na szczególny charakter danych empirycznych, gdzie wykazano związek w sensie Grangera pomiędzy rosnącym średnim wynagrodzeniem brutto  $WYN_t$  i zdolnością kredytową  $ZDK_t$  (tabela 5). Tymczasem indeks cen nieruchomości  $ICN_t$  charakteryzował się niemalże w całym badanym okresie trendem malejącym i dopiero od 2018 roku gwałtownie zaczął wzrastać. Zatem uprawnione jest stwierdzenie, że wzrost zdolności kredytowej napędzany był wzrostem średnich płac. Natomiast ceny nieruchomości (mierzone indeksem  $ICN_t$ ) przez wiele lat średnio zmniejszały się na skutek korekty po globalnym kryzysie (2008 roku) i związanej z nim stagnacji na rynku. Było to możliwe z powodu silnych wzrostów cen nieruchomości przed rokiem 2008. Wzrosty te wynikały z boomu na rynku mieszkaniowym oraz tak zwanej bańki spekulacyjno-kredytowej przed 2008 rokiem. W konsekwencji kryzysu ceny nieruchomości spadły i zmieniły swój trend na wiele kolejnych lat, aby dopiero w roku 2018 przejść do dynamicznych wzrostów. Podsumowując nie należy się zgodzić z ujemną zależnością pomiędzy zmiennymi  $ZDK_t$  oraz  $ICN_t$  lecz przyjąć, że wynika ona z niedoskonałości modelu, który odzwierciedla zmienność badanych kategorii w dość długim i jednocześnie specyficznym okresie dostosowań cen na rynku nieruchomości. Ostatecznie usunięto zmienną  $ZDK_t$  z relacji kointegrującej otrzymując jeden wektor kointegrujący (tabela 8) dla dwóch zmiennych  $ICN_t$ , oraz  $WYN_t$ . Występowanie wektora kointegrującego w ramach zmodyfikowanej zależności zostało potwierdzone testem kointegracji Johansena według analogicznej procedury jak omówiono wcześniej.

Tabela 8. Znormalizowany wektor kointegracji dla zmiennych  $ICN_t$ ,  $WYN_t$ 

LOG(ICN)	LOG(OWK)	C
1,000000	- 0,940340	- 2,410158
	(0,19602)	(0,89426)

Źródło: opracowanie własne w programie Eviews

Ostateczną postać relacji kointegrującej należy zapisać zatem następująco [Syczewska 1999, Majsterek 2014]:

$$\log(ICN_t) = 0,94034 * \log(OWK_t) + 2,410158$$

## UWAGI KOŃCOWE

Na przestrzeni badanej dekady (2008-2018) indeks cen nieruchomości wielokrotnie zmieniał swoją wartość. Najnowsze dane publikowane na temat cen transakcyjnych przez NBP ukazują podwyżki cen mieszkań w okresie pandemii COVID-19. Jednocześnie choć ceny materiałów budowlanych rosną to z danych publikowanych przez NBP na podstawie Secocenbud [Narodowy Bank Polski 2018] wynika, że różnica pomiędzy kosztami budowy 1m<sup>2</sup> powierzchni użytkowej mieszkania PUM i ceną transakcyjną 1m<sup>2</sup> może być liczona nawet w tysiącach złotych [Gajda, Zbyrowski 2017]. Po roku 2008 deweloperzy zintensyfikowali wysiłki na rzecz stosowania wyszukanych strategii sprzedaży, których istotnym elementem stała się polityka cenowa [Yang, Yavas 1995]. Jak wynika z przeprowadzonego badania na wzrost cen nieruchomości w Polsce oddziałują w sensie Grangera także czynniki fundamentalne związane ze stanem koniunktury gospodarczej oraz dostępnością środków pieniężnych. Ponadto indeks zdolności kredytowej zwiększał swoją wartość na skutek wzrostu średnich wynagrodzeń brutto w okresie od 2008 do roku 2018. Okres ostatnich lat charakteryzował się silnymi wzrostami cen na rynku nieruchomości, czas pokaże czy trend ten zostanie utrzymany w obliczu pojawiających się kryzysów. Nieruchomości są postrzegane jako bezpieczna przystań dla kapitału, a szczególnie dzieje się tak w okresach zawirowań gospodarczych. Jednocześnie należy dodać, że rynek nieruchomości i związany z nim poziom cen niełatwo poddaje się modelowaniu i prognozowaniu. Z tego punktu widzenia nawet potwierdzenie występowania dość fundamentalnych zależności w ramach badanego rynku może wydawać się istotne z ekonomicznego punktu widzenia.

## BIBLIOGRAFIA

- Borkowski B., Dudek H., Szczesny W. (2007) *Ekonometria. Wybrane zagadnienia*. PWN, Warszawa.
- Brooks Ch. (2012) *Introductory Econometrics for Finance. Second Edition*. Cambridge University Press, Cambridge.

- Charemza W. W., Deadman D. A. (1992) *New Directions in Econometric Practice*. Edward Elgar, Lyme.
- Dickey D. A., Fuller W. A. (1979) Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*, 74, 427-431.
- Curto R., Fregonara E., Semeraro P. (2017) A Spatial Analysis for the Real Estate Market Applications. [in:] M. d'Amato, T. Kauko (ed.) *Advances in Automated Valuation Modeling*. *Studies in Systems, Decision and Control*, 86, 163-179.
- Curto R., Fregonara E. (2019) Monitoring and Analysis of the Real Estate Market in a Social Perspective. Results from the Turin's (Italy) Experience. *Sustainability*, 11(11), 3150-3172.
- Enders W. (2003) *Applied Econometric Time Series*. John Wiley & Sons, New York.
- Gajda J. (2004) *Ekonometria*. C.H. BECK, Warszawa.
- Gajda J., Zbyrowski R. (2017) Rola kosztów budowy w kształtowaniu cen mieszkań w Polsce. *Roczniki Kolegium Analiz Ekonomicznych*, 47, 83-100.
- Geweke J., Meese R., Dent W. (1983) Comparing Alternative Tests of Causality in Temporal Systems. *Journal of Econometrics*, 21(2), 161-194.
- Granger, C. W. J. (1969) Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica*, 37(3), 424-438.
- Guilkey D. K., Salemi M. K. (1982) Small Sample Properties of Tree Tests for Granger-Causal Ordering in a Bivariate Stochastic System. *Review of Economics and Statistics*, 64, 668-680.
- Jacobs R. L., Leamer E. E., Ward M. P. (1979) Difficulties with Testing for Causation. *Economic Inquiry*, 17(3), 401-413.
- Kusideł E. (2000) Modele wektorowo – aut regresyjne VAR: metodologia i zastosowania. [w:] B. Suhecki (red.) *Dane panelowe i modelowanie wielowymiarowe w badaniach ekonomicznych*. Tom 3. Absolwent, 1-179.
- Liu C., Nowak A., Rosenthal S. (2016) Housing Price Bubbles, New Supply and Within-City Dynamics. *Journal of Urban Economics*, 96, 55-72.
- Lukas M., Mollica V., Nagi M., Trück S. (2018) Over the Top? Overpricing and Advertising Effectiveness. *Macquarie University Faculty of Business & Economics Research Paper, SSRN Paper Series*, 1-38.
- Maddala G. S. (2006) *Ekonometria*. PWN, Warszawa.
- Majsterek M. (2014) Modelowanie systemów skointegrowanych. *Aspekty teoretyczne*. *Bank i Kredyt*, 45(5), 433-466.
- Narodowy Bank Polski (2018) Informacja o cenach mieszkań i sytuacji na rynku nieruchomości mieszkaniowych i komercyjnych w Polsce w I kwartale 2018 roku, Departament Stabilności Finansowej Narodowego Banku Polskiego, Warszawa.
- Pesaran M. H, Pesaran B. (1997) *Working with Microfit 4.0*. Oxford University Press, New York.
- Sadowski J. (2018) Ceny mieszkań w Polsce rosną, ale wciąż są niższe niż w 2008 roku. <http://forsal.pl/artykuly/1105030,ceny-mieszkan-w-polsce-rosna-ale-wciaz-sa-nizsze-niz-w-2008-roku.html> [dostęp: 20.06.2021].
- Sims C. (1980) *Macroeconomics and Reality*. *Econometrica*, 48, 1-48.
- Spohn W. (1984) Probabilistic Causality: from Hume via Suppes to Granger [in:] M. C. Galavotti, G. Gambetta (ed.) *Causalita e modelli probabilistica*. Clueb, Bologna.

- Syczewska E. (1999) Analiza relacji długookresowych: estymacja i weryfikacja. Monografie i opracowania Szkoły Głównej Handlowej, 462, 1-132.
- Yang S., Yavas A. (1995) The Strategic Role of Listing Price in Marketing Real Estate. Theory and Evidence. *Real Estate Economics*, 23(3), 347-368.
- Zbyrowski R. (2017) The Long Term Modeling of Residential Property Prices in Poland. *Quantitative Methods in Economics*, 18(1), 143-156.

### PRICE CAUSALITY IN THE REAL ESTATE MARKET IN POLAND

**Abstract:** The article contains an econometric analyse of quantitative variables related to the real estate market in Poland. The author considers dependencies on the housing market using the popular Granger causality test. The result of the conducted analyse is also the long-term estimation of dependency between prices of the real estate market and the economic situation as well as the creditworthiness of buyers. The results of the research were enriched with conclusions considering changes taking place on the Polish real estate market.

**Keywords:** real estate market, causality, real estate market, Granger test, econometric analysis, econometrics, modeling, creditworthiness, gross earnings, business cycle index, cointegration

**JEL classification:** C01, C5, R31, E3

## FUNKCJA LOG(COSH) I JEJ ROLA W ŚLEPEJ SEPARACJI SYGNAŁÓW

Ryszard Szupiluk  <https://orcid.org/0000-0002-4416-7131>

Kolegium Analiz Ekonomicznych  
Szkola Główna Handlowa w Warszawie  
e-mail: rszupi@sgh.waw.pl

**Streszczenie:** W niniejszym artykule przedstawimy szczególną właściwość algorytmów ślepej separacji jaką jest występowanie funkcji  $\log(\cosh)$  w funkcjach celu, z których owe algorytmy są wyprowadzane. Wskażemy, że zakładane jako zasadniczo różne metody separacji, oparte na odmiennych kryteriach takich jak statystyczna niezależność, rzadkość lub gładkość, mogą lub są w praktyce sprowadzane do eksploracji w istocie tej samej matematycznej charakterystyki.

**Słowa kluczowe:** analiza składowych niezależnych, ślepa separacja, analiza składowych gładkich, rzadkie dane

**JEL classification:** C02, C50

### WSTĘP

Ślepa separacja sygnałów, zwana także ślepą separacją źródeł (ang. Blind Singnal/Source Sepration–BSS), jest problemem intensywnie badanym w dwóch ostatnich dekadach [Comon, Jutten 2010; Piccolotto et al. 2022]. Zasadnicza idea BSS polega na odtworzeniu nieznanymi *a priori* sygnałów źródłowych, zmieszanych w także nieznanym systemie mieszającym. W zależności od kontekstu rozważań cały proces może być określany jako ślepa: separacja, identyfikacja lub estymacja [Cichocki et al. 2002]. Zagadnienie BSS może być rozważane w kategoriach praktycznych problemów lub czysto matematycznych przekształceń. W tym drugim przypadku BSS można przestawić jako zadanie poszukiwania interesujących transformacji i reprezentacji danych. W związku z tym zagadnieniem powstały, zostały rozwinięte lub zaadoptowane takie metody jak analiza składowych

<https://doi.org/10.22630/MIBE.2022.23.3.8>

niezależnych [Cardoso 1999], analiza składowych rzadkich [Zibulevsky, Pearlmutter 2001], analiza składowych gładkich [Szupiluk et al. 2006], nieujemna faktoryzacja macierzy [Berry et al. 2007], nieliniowa analiza składowych głównych [Oja 1995] i wiele innych. W większości przypadków ww. metody wymagają zastosowania metod numerycznych, co powoduje, że są, lub mogą być, klasyfikowane także jako metody uczenia maszynowego [Haykin 2009].

Cechą charakterystyczną dla problematyki BSS jest oczekiwanie, że niezależnie od wybranych metod separacji, otrzymane wyniki będą podobne lub identyczne. W przypadku praktycznych zastosowań przyjmuje się, że ze zmieszanych danych obserwowanych zostaną wyodrębnione, rzeczywiste, odrębne sygnały źródłowe. Przykładem może być tu odtworzenie pojedynczej wypowiedzi z gwaru rozmów (tzw. cocktail party problem) [Koutras, 2002]. Podobnie oczekiwania adresowane są w przypadku czysto analitycznych reprezentacji danych. Oznacza to, że zarówno w przypadkach praktycznych jak i symulacjach teoretycznych oczekuje się wyodrębnienia sygnałów (używane są także określenia: komponentów, składowych, zmiennych, szeregów czasowych) o niejako fizycznym charakterze. Osiągnięcie takich rezultatów, metodami o różnych właściwościach, bazującymi na różnych kryteriach i założeniach, zazwyczaj wyjaśnia się faktem istnienia różnych charakterystyk sygnałów, których eksploracja może doprowadzić do ich wyodrębnienia. Pojawia się jednak pytanie, w jakim stopniu poszczególne formalnie „różne” metody, są w istocie różne.

W niniejszym artykule wykażemy, że pozornie odmienne kryteria jak wzajemna niezależność sygnałów oraz indywidualne charakterystyki sygnałów jak rzadkość lub gładkość w kontekście ślepej separacji, na pewnym poziomie rozważań wykazują znaczące podobieństwa.

## PROBLEM ŚLEPEJ SEPARACJI

Zadanie ślepej separacji można przedstawić następująco. Przyjmuje się, że pewne nieznanne a *priori* sygnały źródłowe zostały zmieszane w także nieznanym systemie mieszającym. Należy odtworzyć sygnały źródłowe dysponując jedynie obserwacjami zmieszanymi. Dla rozwiązania tego problemu przyjmowane są pewne robocze założenia dotyczące postaci systemu mieszającego oraz sygnałów źródłowych, co prowadzi do zdefiniowania systemu generującego. W zależności od przyjętego/założonego systemu mieszającego możemy mówić o BSS: statycznym, dynamicznym, nieliniowym statycznym lub nieliniowym dynamicznym [Cichocki, Amari 2002]. Najczęściej rozważanym jest przypadek liniowego statycznego systemu postaci

$$\mathbf{x}(k) = \mathbf{A}\mathbf{s}(k), \quad (1)$$



gdzie:  $\mathbf{A} \in R^{N \times M}$ ,  $\mathbf{x}(k) = [x_1(k), \dots, x_N(k)]^T$  jest wektorem sygnałów obserwowanych, zaś  $\mathbf{s}(k) = [s_1(k), \dots, s_M(k)]^T$  źródłowych,  $k$  oznacza indeks czasu lub numer obserwacji. Z reguły przyjmuje się także, następujące dodatkowe założenia:  $M \leq N$  - oznacza to, iż liczba sygnałów obserwowanych nie może być mniejsza od liczby sygnałów źródłowych, w naszych rozważaniach  $N=M$ , zaś kolumny macierzy  $\mathbf{A}$  są liniowo niezależne [Cardoso 1998].

W celu znalezienia  $\mathbf{x}$ , poszukuje się takiego systemu separującego, reprezentowanego przez macierz  $\mathbf{W}$ , że dla sygnałów separowanych  $\mathbf{y}(k) = [y_1(k), \dots, y_M(k)]^T$  zachodzi

$$\mathbf{y}(k) = \mathbf{W}\mathbf{x}(k) = \mathbf{W}\mathbf{A}\mathbf{s}(k) = \mathbf{P}\mathbf{D}\mathbf{s}(k), \quad (2)$$

gdzie:  $\mathbf{P}$  - macierz permutacji określająca kolejność estymowanych sygnałów,  $\mathbf{D}$  - diagonalna macierz skalująca. Równanie (3) oznacza, że estymowane sygnały źródłowe  $\mathbf{y}$  mogą być przeskalowaną oraz w innej kolejności uporządkowaną „wersją” sygnałów  $\mathbf{s}$ . Jest to nieunikniona konsekwencja faktu, iż przyjmując  $N=M$ , dla dowolnej odwracalnej macierzy  $\mathbf{E} \in R^{N \times N}$  zachodzi  $\mathbf{x} = \mathbf{A}\mathbf{E}\mathbf{E}^{-1}\mathbf{s}(k)$ .

Rozwiązanie tak postawionego problemu wymaga z reguły jeszcze dodatkowych założeń związanych ze specyfiką danej metody separacji. W dalszych rozważaniach skupimy się na podejściach eksplorujących takie charakterystyki sygnałów jak statystyczna niezależność, gładkość o rzadkość danych.

## ANALIZA SKŁADOWYCH NIEZALEŻNYCH

Analiza składowych niezależnych jest jedną z pierwszych metod BSS. Jest także metodą uważaną za podstawową w tym obszarze, a w początkowej fazie rozwoju problematyki ślepej separacji, metoda ICA oraz problem BSS były traktowane zgoła jako tożsame. Z formalnego punktu widzenia, analiza składowych niezależnych stawia sobie za cel wydzielenie z obserwacji komponentów (składników, sygnałów) statystycznie niezależnych. Oznacza to, że dla modelu (1)-(2) poszukujemy takiego  $\mathbf{W}$ , że transformacja  $\mathbf{y}=\mathbf{W}\mathbf{x}$  prowadzi do spełnienia warunku statystycznej niezależności estymowanych danych [Comon 1994]

$$p_1(y_1)p_2(y_2)\dots p_n(y_n) = p_{1\dots n}(y_1, y_2, \dots, y_n), \quad (3)$$

gdzie  $p_i(y_i)$  oznacza funkcję gęstości prawdopodobieństwa zmiennej  $y_i$ , zaś prawa strona równania (3) oznacza łączną funkcję gęstości prawdopodobieństwa sygnałów separowanych. Do oceny spełnienia równania (3) przyjmowane są różne praktyczne kryteria matematyczne. Jednym z nich może być wzajemna informacja [Amari et al. 1999]

$$I(\mathbf{y}) = \int_{-\infty}^{+\infty} p(y_1, \dots, y_N) \log \frac{p(y_1, \dots, y_N)}{\prod_i p(y_i)} dy. \quad (4)$$

Wyrażenie (4) może być przyjęte jako funkcja celu, co sprowadza zagadnienie znajdowania składników niezależnych do problemu optymalizacji [Cardoso 1997]

$$\mathbf{W}_{opt} = \min_{\mathbf{W}} I(\mathbf{y}) = \min_{\mathbf{W}} I(\mathbf{W}\mathbf{x}). \quad (5)$$

Minimalizacja (5) wiąże się zwykle z przekształceniem wyrażania (4) do postaci wygodniejszej dla wyprowadzenia algorytm uczenia. Jedną z możliwości jest wykorzystanie pojęcia negentropii [Girolami, Fyfe 1996]

$$J(\mathbf{y}) = H_G(\mathbf{y}) - H(\mathbf{y}), \quad (6)$$

gdzie  $H(\mathbf{y}) = - \int_{-\infty}^{+\infty} p(\mathbf{y}) \log(p(\mathbf{y})) d\mathbf{y}$  jest entropią zmiennej  $\mathbf{y}$  zaś  $H_G(\mathbf{y})$  jest entropią

zmiennej  $\mathbf{y}$  o rozkładzie Gaussowskim, z taką samą średnią oraz kowariancją jak  $p(\mathbf{y})$ . Wyrażenie (5) można traktować jako miarę niegaussowości zmiennej  $\mathbf{y}$ . Negentropia, w odróżnieniu od zwykłej entropii, jest niezmiennicza dla transformacji odwracalnych, czyli dla  $\mathbf{y} = \mathbf{W}\mathbf{z}$  zachodzi  $J(\mathbf{y}) = J(\mathbf{W}\mathbf{z}) = J(\mathbf{z})$ . Można wykazać, że jeżeli dane  $\mathbf{x}$  poddamy procesowi dekorelacji  $\mathbf{z} = \mathbf{Q}\mathbf{x}$ , gdzie  $\mathbf{Q}$  jest macierzą dekorującą to otrzymamy następującą zależność [Lee 1998].

$$I(\mathbf{y}) = J(\mathbf{z}) - \sum_{i=1}^N J_i(y_i), \quad (7)$$

Przyjmując, że dla  $\mathbf{y} = \mathbf{W}\mathbf{z} = \mathbf{W}\mathbf{Q}\mathbf{x}$ , macierz  $\mathbf{W}$  nie wpływa na  $J(\mathbf{z})$  problem ślepej separacji sprowadza się do następującego zadania optymalizacji

$$\min_{\mathbf{W}} I(\mathbf{y}) = \max_{\mathbf{W}} \sum_{i=1}^N J_i(y_i). \quad (8)$$

Dla rozwiązania problemu (8) można wykorzystać następującą aproksymację negentropii [Hyvarinen 1998]

$$J(y) \approx q_1(E\{G_1(y)\})^2 + q_2(E\{G_2(y)\} - E\{G_2(v_G)\})^2, \quad (9)$$

gdzie  $E\{\cdot\}$  jest operatorem wartości oczekiwanej,  $G_1(y)$ ,  $G_2(y)$  są niekwadratowymi funkcjami nieliniowymi określającymi odpowiednio stopień niesymetryczności oraz stromości zmiennej  $y$ ,  $v_G$  oznacza dowolną zmienną o

rozkładzie gaussowskim,  $q_1, q_2$  są odpowiednio dobranymi stałymi. Wyrażenie (9) można uprościć dla rozkładów symetrycznych do


$$J(y) \approx [E\{G_2(y)\} - E\{G_2(v_G)\}]^2, \quad (10)$$

Dobór funkcji  $G_2(y)$  może opierać się na różnych motywacjach, jedną z nich może być kontekst uczenia maszynowego w jakim postawiony może być problem optymalizacji funkcji (8). W takim kontekście funkcją, która spełnia warunki aproksymacji a jednocześnie ma sprawdzone i dobrze interpretowalne własności w kategoriach uczenia maszynowego jest funkcja [Oja 1995]

$$f(y) = \log \cosh(y). \quad (11)$$

Jest używana m.in. jako aproksymacja wartości bezwzględnej, co jest korzystne w przypadku gradientowych metod optymalizacji, rysunek 1.

Rysunek 1. Wykresy funkcji  $\log(\cosh)$  oraz wartości bezwzględnej



Źródło: opracowanie własne

Wstawiając  $G_2(y) = f(y)$  oraz uwzględniając człony zależne od  $w$  otrzymuje się następującą aproksymację negentropii

$$J(y) = [E\{\log(\cosh(y))\} - E\{\log(\cosh(v_G))\}]^2. \quad (12)$$

Prowadzi to ostatecznie do następującej funkcji celu

$$F_1 = \sum_{i=1}^N [E\{\log(\cosh(y_i))\} - E\{\log(\cosh(v_G))\}]^2, \quad (13)$$

stanowiącej podstawę algorytmów estymacji niezależnych komponentów a w kontekście ślepej separacji algorytmów odtwarzających zmieszane sygnały.

## ANALIZA SKŁADOWYCH RZADKICH

Analiza składowych rzadkich (ang. Sparse Component Analysis–SCA) eksploruje charakterystykę danych określaną jako rzadkość [Zibulevsky, Pearlmutter 2001]. Za sygnały rzadkie uznaje się sygnały, w których dominuje jedna wartość np. zero, zaś

„rzadko” pojawia się wartość niezerowa. W ogólnym przypadku wartość dominująca może być dowolna. Rzadkość danych ma istotne znaczenie w zagadnieniach reprezentacji oraz kompresji danych. W przypadku metod analitycznych charakterystyka ta może pełnić pewną dodatkową rolę jako element kary, ograniczeń lub dodatkowych warunków. Przyjmując rzadkość jako główne kryterium wyodrębniania sygnałów można mówić o zdefiniowaniu problemu analizy składowych rzadkich. Może ona zostać sformowana następująco. Dla obserwacji  $\mathbf{x}(k) = [x_1(k), \dots, x_N(k)]^T$  poszukujemy takiej kombinacji liniowej (2), że uzyskane zmienne  $y_i$  charakteryzuje się jak największą rzadkością (od największej do najmniejszej). Kluczowym elementem jest tu określenie kryterium rzadkości, które z reguły pełni jednocześnie rolę funkcji celu dla algorytmu separacji. Typowymi miarami rzadkości sygnałów są kurtoza, norma zero lub  $p$ -norma z  $p=1$  postaci [Georgiev et al. 2005]

$$l_s = \sum_{k=1}^K |y(k)|, \quad (14)$$

Występująca w (14) wartość bezwzględna jest zwykle zastępowana wygodniejszą z punktu widzenia algorytmów uczenia aproksymacją za pomocą funkcji (11) co prowadzi do funkcji celu postaci

$$F_2 = E\{\log(\cosh(y(k)))\}, \quad (15)$$

Eksploracja rzadkiej charakterystyki danych, często wiązana jest i innymi kryteriami w efekcie mamy takie metody „mieszane” jak rzadka analiza składowych niezależnych [Khan, Kim 2009], rzadka analiza składowych głównych [Zou et al. 2006].

## ANALIZA SKŁADOWYCH GŁADKICH

Analiza składowych gładkich (ang. Smooth Component Analysis – SmCA), eksploruje charakterystykę, którą możemy określić jako zmienność (lub zmiany) między kolejnymi wartościami sygnału, przy czym, jest to metoda adresowana do danych posiadających strukturę czasową tzn. w których kolejność obserwacji jest istotna (sygnały, szeregi czasowe) [Szupiluk et al. 2012]. W przypadku małych zmian, sygnał można potraktować jako gładki. Kryterium oceny gładkości stanowiące jednocześnie funkcję celu na bazie której wprowadzany jest algorytm SaCA można przyjąć postaci [Szupiluk et al. 2006]

$$P_1(y) = \frac{\frac{1}{N} \sum_{k=2}^N |y(k) - y(k-1)|}{\rho(\max(y) - \min(y))}, \quad (16)$$

gdzie

$$\rho(u) = \begin{cases} 1 & \text{dla } u = 0 \\ u & \text{dla } u \neq 0 \end{cases} \quad (17)$$

Miara (16) ma wartość maksymalną, kiedy zmiany dla kolejnych obserwacji, są równe zakresowi sygnału (maksymalne zmiany), zaś miara jest minimalna, kiedy sygnał jest stały. Możliwe wartości miary  $P_1(y)$ , zawierają się w przedziale od 1 do 0. Funkcja jedyńki  $\rho(\cdot)$ , w mianowniku, wprowadzona została aby uniknąć dzielenia przez zero. Miarę gładkości (16), można uogólnić, zastępując wartość średnią w liczniku wartością oczekiwaną.

Przyjmując, że mamy dane znormalizowane do przedziału  $\langle -1, 1 \rangle$  oraz zastępując wartość bezwzględną funkcją  $\log(\cosh)$ , z powodów jak wyżej, otrzymujemy funkcję celu postaci  $F_3 = E\{\log(\cosh(y(k)) - \log(\cosh(y(k-1))))\}$ .

W przypadku sygnałów „wysoco” gładkich, gdzie  $y(k) \approx y(k-1)$ , możliwe jest wprowadzenie wag dla wartości w chwili  $k$  oraz  $k-1$ . Co prowadzi do

$$F_3 = (b_1 - b_2)E\{\log(\cosh(y(k)))\} \quad (18)$$

Dla  $b_1 = 2, b_2 = 1$  funkcja (18) jest tożsama z (15).

## ALGORYTMY SEPARACJI I ICH DZIAŁANIE

Mając zdefiniowaną funkcję celu, można na jej bazie wyprowadzić algorytm uczenia. Kolejne komponenty źródłowe, wyznaczane są, jako kolejne kombinacje liniowe sygnałów  $x_i$  spełniające kryteriom separacji. Dla modelu (2) poszukiwana jest więc taka macierz  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N]$ , że  $y_1(k) = \mathbf{w}_1^T \mathbf{x}(k)$  maksymalizuje  $F_1(y_1)$ , czyli

$$\mathbf{w}_1 = \arg \max_{\|\mathbf{w}\|=1} (F_1(\mathbf{w}^T \mathbf{x})) \quad (19)$$

W funkcji występuje warunek ograniczający  $\|\mathbf{w}\|=1$ , co zapobiega dążeniu wag do wartości nieskończonych.

Mając estymowane pierwszych  $k-1$  komponentów źródłowych eliminujemy je z obserwacji poprzez ortogonalizację Gram-Schmidt'a i powtarzamy procedurę optymalizacji otrzymując kolejne komponenty


$$\mathbf{w}_k = \arg \max_{\|\mathbf{w}\|=1} (P(\mathbf{w}^T (\mathbf{x} - \sum_{i=1}^{k-1} \mathbf{y}_i \mathbf{y}_i^T \mathbf{x}))), \quad (20)$$

gdzie  $\mathbf{y}_i = \mathbf{w}_i^T \mathbf{x}$ ,  $i = 1 \dots k$ .

Zwróćmy uwagę, że analogiczna procedura może być zastosowana do (15) oraz (18) z tym, że tym razem poszukiwane będzie minimum. Niemniej w każdym z tych przypadków, czyli: statystycznej niezależności sygnałów, gładkości sygnałów oraz rzadkości sygnałów podstawą algorytmu estymującego komponenty danej metody jest (lub może być) „podobna” funkcja celu.

Konkretne algorytmy separacji bazujące na (19)-(20) mogą mieć postać różnych procedur numerycznych, co zależy między innymi od przyjętej metody optymalizacji [Hyvariene et al., 2001, Cichocki i Amari 2001, Szupiluk et al. 2012] Niemniej uzyskane wyniki będą z reguły podobne. Przykładowe działanie algorytmu separacji prezentuje rysunek 2.

Rysunek 2. Sygnały a) źródłowe, b) zmieszane, c) separowane



Źródło: opracowanie własne

## PODSUMOWANIE

W niniejszym artykule przedstawiliśmy szczególną rolę jaką odgrywa funkcja  $\log(\cosh)$  w problemie ślepej separacji. Zasadniczo funkcja ta nie jest wiązana bezpośrednio z jakąś szczególną charakterystyką danych. A jednak, przy bliższym wglądzie w głąb algorytmów separacji pojawia się jako podstawa dla aproksymacji wydawałoby się odmiennych pojęć jak statystyczna niezależność, gładkość oraz rzadkość danych. Standardowa interpretacja osiągnięcia podobnych wyników separacji mówi o tym, że eksploracja różnych, odmiennych charakterystyk sygnałów powinna prowadzić do podobnych wyników. Jednak jak widzimy te odmienności na poziomie technicznych przekształceń prowadzących do końcowego algorytm znacząco się zacierają. Można powiedzieć, że w istocie eksplorowana jest właściwość  $\log(\cosh(y))$ , która nie ma bezpośredniej interpretacji fizycznej.

## BIBLIOGRAFIA

- Amari S., Cichocki A., Yang H. (1999) Unsupervised Adaptive Filtering, chapter Blind Signal Separation and Extraction - Neural and Information Theoretic Approaches. John Wiley.
- Berry M., Browne M., Langville A., Pauca P., Plemmons R. (2007) Algorithms and Applications for Approximate Nonnegative Matrix Factorization. *Computational Statistics & Data Analysis*, 52(1), 155-173.
- Cardoso J. (1998) Blind Signal Separation: Statistical Principles. *Proceedings. of the IEEE*, 86(10), 2009-2025.
- Cardoso J. (1999) High-Order Contrasts for Independent Component Analysis. *Neural Computation*, 11(1), 157-192.
- Cardoso J. (1997) Infomax and Maximum Likelihood for Source Separation. *IEEE Letters on Signal Processing*, 4(4), 112-114.
- Cichocki A., Amari S. (2002) Adaptive Blind Signal and Image Processing. John Wiley, Chichester.
- Comon P., Jutten Ch. (2010) Handbook of Blind Source Separation: Independent Component Analysis and Applications. Academic Press.
- Georgiev P., Theis F., Cichocki A. (2005) Sparse Component Analysis and Blind Source Separation of Underdetermined Mixtures. *IEEE Transactions on Neural Networks*, 16(4), 992-996.
- Girolami M., Fyfe C. (1996) Negentropy and Kurtosis as Projection Pursuit Indices Provide Generalized ICA Algorithms. *Advances in Neural Information Processing Systems, NIPS'96 Workshop*, Snowmaas.
- Haykin S. (2009) *Neural Networks and Learning Machines*. Upper Saddle River: Pearson Education.
- Hyvarinen A. (1998) New Approximations of Differential Entropy for Independent Component Analysis and Projection Pursuit. *Advances in Neural Information Processing Systems*, 10, 273-279, Cambridge, MA: MIT Press.
- Hyvarinen A., Karhunen J., Oja E. (2001) *Independent Component Analysis*. Wiley John, New York.
- Khan A., Kim I. (2009) Sparse Independent Component Analysis with Interpolation for Blind Source Separation. *2nd International Conference on Computer, Control and Communication*.
- Koutras A. (2002) Blind Speech Separation for Solving the Cocktail Party Problem in Real Room Environments. *Info-M Journal*, 1, 29-32.
- Lee T. (1998) *Independent Component Analysis: Theory and Applications*. Kluwer Academic Publishers.
- Oja E. (1995) The Nonlinear PCA Learning Rule and Signal Separation – Mathematical Analysis. Helsinki Univ. of Technology, Lab. of Computer and Information Science, Report A26.
- Piccolotto N., Bögl M., Muehlmann C., Nordhausen K., Filzmoser P., Miksch S. (2022) Visual Parameter Selection for Spatial Blind Source Separation. *Computer Graphics Forum*, 41,3, 157-168.

- Szupiluk R., Wojewnik P., Ząbkowski T. (2012) Smooth Component Analysis and MSE Decomposition for Ensemble Methods. *Lectures Notes in Artificial Intelligence*, 7327, 595-603.
- Szupiluk R., Wojewnik P., Ząbkowski T. (2006) Prediction Improvement via Smooth Component Analysis and Neural Network Mixing. *ICANN 2006, Lecture Notes in Computer Science*, 4132, 133-140, Springer, Berlin, Heidelberg.
- Szupiluk R., Wojewnik P., Ząbkowski T. (2007) Smooth Component Analysis as Ensemble Method for Prediction Improvement. *Lecture Notes in Computer Science*, 4666, 277-284. Springer, Berlin, Heidelberg.
- Szupiluk R. (2014) Dekompozycje wielowymiarowe w agregacji predykcyjnych modeli Data Mining. Szkoła Główna Handlowa, Oficyna Wydawnicza.
- Zibulevsky M., Pearlmutter B. (2001) Blind Source Separation by Sparse Decomposition in a Signal Dictionary. *Neural Computation*, 13, 863-882.
- Zou H., Hastie T., Tibshirani R. (2006) Sparse Principal Component Analysis, *Journal of Computational and Graphical Statistics*, 15(2), 262-286.

#### THE LOG (COSH) FUNCTION AND ITS ROLE IN THE PROBLEM OF BLIND SEPARATION

**Abstract:** In this article, we will present a special feature of blind separation algorithms, which is the presence of  $\log(\cosh)$  functions in the objective functions from which these algorithms are derived. We point out that, assumed as fundamentally different methods of separation, based on different criteria such as statistical independence, sparsity or smoothness, can or are in practice reduced to the exploration of essentially the same mathematical characteristic.

**Keywords:** independent component analysis, smooth component analysis, blind signals separation, sparse data

**JEL classification:** C02, C50



## TIME-VARYING EXCHANGE RATE PASS-THROUGH IN EASTERN EUROPE

**Victor Shevchuk**  <http://orcid.org/0000-0002-7125-1267>  
Council of Social Sciences  
Cracow University of Technology, Poland  
e-mail: vshevchuk@pk.edu.pl

**Abstract:** Using quarterly data for the 1998–2021 period, and with the application of Kalman filter estimates it is shown that the incomplete exchange rate pass-through (ERPT) is somewhat stronger for countries with a floating exchange rate regime, especially for producer prices. Since the middle of 2000s, the ERPT to consumer and producer prices for 11 Central and Eastern European (CEE) countries, as well as for the Baltic States, seems to be relatively stable in most of the countries. With the exception of the Czech Republic, Romania, and Estonia, there is a tendency for strengthening of the ERPT to producer prices in the wake of the world financial crisis of 2008–2009.

**Keywords:** inflation, exchange rate pass-through (ERPT), Eastern Europe, Kalman filtering

**JEL classification:** C22, E31

### INTRODUCTION

The causality running from exchange rate movements to domestic prices, known as exchange rate pass-through (ERPT), is a key channel for the international transmission of inflation and economic cycles [Aron, Macdonald and Muellbauer 2014]. Initially, the ERPT referred to reaction of import prices to a 1 percent change in the exchange rate but later the definition has been extended to the effect of exchange rate movements on consumer or producer prices. As recently, one of the well-established facts is a decrease in the magnitude of the ERPT to consumer prices over the last decades, for example Lopez-Villavicencio and Mignon [2017], especially in the developing economies since 2010 [Jašová, Moessner and Takáts 2019]. Among the CEE countries, a recent decline of the ERPT is found mainly for

the countries with more flexible exchange rate regimes [Baxa, Šestořád 2019; Mirdala 2014]. It is common to attribute a lower ERPT to numerous factors ranging from low inflation in a more credible monetary policy environment to structural shifts [Aron, Macdonald and Muellbauer 2014]. On the other hand, a recent surge in inflation cannot but attract attention to the likely effects of significant exchange rate depreciations observed in several CEE countries. For example, since January 2020 the Polish zloty and Hungarian forint have depreciated to the basket of foreign currencies by 10 and 19 percent, respectively. For the countries with a fixed exchange rate, inflationary pressure can result from a significant weakening of the euro by 9 percent since the beginning of 2021.

The objective of our paper is to provide empirical evidence on the short-term ERPT to both consumer and producer prices for 14 Eastern European countries, with a focus on likely differences between countries with flexible and fixed exchange rates. As of the end of 2022, the issue should be highly relevant to policymakers since the recent surge in inflation can be explained by depreciation pressure. The contribution of this paper to the ERPT literature is two-fold. First, time-varying pattern of the ERPT for several Eastern European countries is analysed. Second, potential differences between pre-crisis and post-crisis ERPT since 2010 are highlighted.

The remainder of the paper proceeds as follows. Section 2 provides a brief review of the theoretical issues regarding time-varying properties of the ERPT. In Section 3, data and statistical methodology are presented. Section 4 contains the econometric results and Section 5 summarizes main conclusions.

## LITERATURE SURVEY

A recent trend of a decrease in the magnitude of the ERPT can be explained in numerous ways. Among those explanations which can be relevant for the CEE countries, quality adjustments, structural changes in trading basket and geographical composition of trading partners [Aron, Macdonald and Muellbauer 2014], trade integration [Gust et al. 2010], use of high-quality inputs [Bernini and Tomasi 2015], as well as improved monetary policy performance [García-Schmidt, Garcia-Cicco 2020; Takhtamanova 2010], are worth attention. For the sample of 14 emerging countries over the 1994Q1–2015Q3 period, it is found that ERPT to consumer prices is reduced by adoption of an inflation target [López-Villavicencio, Mignon 2017]. It suggests that the CEE countries with inflation targeting regime may experience a lower ERPT. Using time series for a longer time span of 1996–2015, Ben Cheikh and Ben Zaied [2020] obtain for 10 new EU Member States that for inflation levels above a threshold of 4.5 percent the degree of pass-through is higher and reaches a full ERPT. Consequently, the shift towards a stable and low-inflation regime contributes to a significant decline in the ERPT. Vonnák [2010] established that low inflation may decrease the ERPT in the Czech Republic, Hungary and Poland and

thus help to ignore exchange rate shocks. Estimated ERPT impulse response functions are fairly similar for the CEE countries studied. On the other hand, no reduction in the ERPT to the aggregate import prices is found for seven countries of Southeast Europe by Kurtović et al. [2018].

While it is common in the literature to find a lower ERPT in countries with more flexible exchange rate regimes in the presence of credible inflation targets that strengthens the shock-absorbing capabilities of the economy [Ha, Stocker and Yilmazkuday 2020], a lower exchange rate volatility under a fixed exchange rate regime can be the most likely factor behind the higher ERPT, as it is found for the CEE countries by Jimborean [2013].

Several studies utilize models with time-varying parameters, which can provide more precise information in comparison to time-invariant models estimated on sub-samples. Using the dataset of 88 countries with the time-varying ERPT measure, Ozkan and Erden [2015] show that the relation between exchange rate and inflation has been low and declining since mid-1980s, being positively influenced by inflation while negatively affected by exchange rate volatility, the degree of openness and output gap. Earlier estimates of time-varying parameters for six major industrial countries (the United States, Japan, Germany, the United Kingdom, France and Italy) reported a decline in the ERPT to consumer prices due to the low and stable inflation environment as well as the rise in import penetration [Sekine 2006].

A downward tendency for the ERPT for the Czech Republic can be explained by a flattened Phillips curve, or rising quality of exports and participation in global value chains, or favourable inflation expectations [Baxa and Šestořád 2019]. Also, it is mentioned that at the zero lower bound (ZLB) there is a possibility of the ERPT being higher than in normal times. Such an assumption corresponds with a proposal presented by Svensson [2000] that the zero lower bound can be overcome by a temporary exchange rate peg causing real depreciation of the domestic currency and by the temporary adoption of price-level targeting. Consequently, higher costs of imported goods should stimulate output and contribute to both lower real interest rates and higher inflation expectations.

The rolling window regression results reveal that the experience of several industrial countries in the post-crisis environment since 2009 is quite heterogeneous [Cunningham et al. 2017]. Another study reports that average ERPT to consumer inflation for 17 emerging market economies has declined in the years following the global financial crisis of 2008 [Patra et al. 2020].

There is a noticeable post-crisis decline in the ERPT for Hungary presented by Hajnal et al. [2015], but Mirdala [2014] does not confirm it in his study. Among other CEE countries, an increase in the ERPT in comparison to the pre-crisis level is found for Bulgaria, Czech Republic, Poland, and Romania, with a decrease in the ERPT for Estonia and Slovenia and no changes between pre- and post-crisis ERPT for Latvia, Lithuania, and Slovakia. The post-crisis increase in the ERPT is experienced by countries with a floating exchange rate regime.

Most of the abovementioned ERPT studies for the CEE countries implement VAR models [Baxa and Šestořád 2019; Hajnal 2016, Mirdala 2014, Vonnák 2010]. Among other estimation approaches with the parameters being constant over time, the dynamic GMM panel-data estimators [Jimborean 2013; López-Villavicencio, Mignon 2017] and the ARDL model [Kurtović et al. 2018] are utilized. In order to account for instability in the relationship between exchange rate and inflation, a nonlinear panel smooth transition regression is implemented by Ben Cheikh and Ben Zaied [2020] and the rolling window regression is used by Hajnal [2016].

## DATA AND STATISTICAL METHODOLOGY

Our empirical model is estimated for 14 Eastern European economies, using variables of the consumer and producer prices (index, 2010=100),  $CPI_t$  and  $PPI_t$ , respectively, the nominal effective exchange rate (index, 2010=100),  $NEER_t$ , variability of consumer and producer price inflation,  $CPIVAR_t$  and  $PPIVAR_t$ , respectively, the consumer prices in Germany (index, 2010=100),  $CPIGER_t$ , and the world price for crude oil (index, 2015=100),  $BRENT_t$ . The exchange rate depreciation means that  $NEER_t$  goes up, while the nominal exchange rate appreciation means that  $NEER_t$  goes down. All consumer and producer price indexes were seasonally adjusted with the X-12 method. All data come from the Eurostat and IMF International Financial Statistics online databases. The estimation samples for the individual economies are from 2000Q1 to 2021Q4, except for Albania, 2002Q1 to 2009Q4, and Serbia, 2010Q1 to 2021Q4, due to availability of time series for the producer prices. The Czech Republic, Hungary, Poland, Romania, Albania, Croatia and Serbia can be classified as countries with substantial exchange rate flexibility, while Bulgaria, North Macedonia, Slovakia, Slovenia and the Baltic States maintain different kind of fixed exchange rate arrangements. Similar to other studies [Cunningham et al. 2017; López-Villavicencio, Mignon 2017], the relationship between the NEER and inflation is augmented by accounting for external conditions.

The Phillips-Perron (PP) unit root test is applied to check the orders of integration of the three times series, with autoregressive lags being chosen according to the Akaike information criterion. The PP tests show that majority of the variables included in the analysis are  $I(1)$ , except for CPI for Slovakia and Slovenia and NEER for Bulgaria and Lithuania which are stationary in levels (Table 1).

Sims [1982] advocated the time-varying coefficients model as a useful way of dealing with changes in government policy and economic institutions. In contrast to the STAR-type time specification that assumes a particular path and a smooth transition between the regimes which could be too restrictive for the case of ERPT, the use of the Kalman filter for the maximum likelihood estimation of time-varying coefficients provides with flexibility [Darvas 2013]. The Markov switching specification, as another alternative, assumes a limited number of states and thus seems less attractive for the case CEE economies, which used to evolve gradually and may not return to an earlier regime.

For the purpose of this study, the algorithm of the Kalman filter is represented by the following state space model:

$$\Delta p_t = a_0 PVAR_t + \Phi_{t-1} \Delta p_{t-1} + \Gamma_{t-1} \Delta x_{t-1} + \mathbf{M}_{t-1} \varepsilon_{t-1}, \quad (1)$$

$$z_t = \mathbf{H}_t p_t + \mathbf{\Omega}_t x_t + v_t, \quad (2)$$

where  $p_t$  is a vector of consumer or producer prices at the time  $t$  (in logarithms, as indicated by lowercase letters), the matrix  $\Phi_{t-1}$  represents the state transition between the time periods  $t-1$  and  $t$ ,  $x_t$  is a vector of observed variables that are predetermined ( $x_t \in [neer_t, cpiger_t, brent_t]$ ),  $\Gamma_{t-1}$  is the matrix of coefficients for observed variables,  $PVAR_t$  is volatility of consumer (or producer) price inflation,  $\varepsilon_t$  is a white noise error vector, and  $\Delta$  is the operator of first differences.

Table 1. Results of the Phillips–Perron unit root test

Country	CPI		PPI		NEER	
	Level	First Diff	Level	First Diff	Level	First Diff
Czech Rep	-2.03	-4.54***	-1.98	-4.79***	-1.89	-6.80***
Hungary	-2.33	-5.41***	-1.51	-5.36***	-1.92	-14.80***
Poland	-2.61	-3.66**	-2.05	-4.54***	-0.16	-7.72***
Romania	2.93	-3.81***	2.90	-3.25***	1.67	-5.54***
Albania	-2.58	-16.46***	-2.59	-6.54***	-1.64	-8.97***
Croatia	-1.44	-6.36***	-1.83	-3.13**	-2.10	-8.85***
Serbia	2.15	-3.42***	-2.13	-3.02**	0.86	-8.58***
Bulgaria	-1.74	-5.57***	-1.87	-4.16***	-2.41*	-7.64***
North Macedonia	-2.53	-6.14***	-1.85	-5.34***	-2.72	-7.94***
Slovakia	-3.18*	-4.52***	1.77	-2.88***	-0.87	-7.73***
Slovenia	-4.17***	-5.45***	-1.43	-1.77*	0.78	-7.71***
Estonia	-0.88	-3.46**	-1.44	-1.76*	-2.35	-9.98***
Latvia	-1.18	-3.28**	-0.40	-3.01**	-1.48	-8.75***
Lithuania	-1.67	-4.55***	-2.33	-7.75***	-4.42***	-9.49***

\* a model with intercept and trend is used in most of the cases, with seasonally adjusted series for CPI and PPI used; a model with no intercept and trend is used for CPI (Estonia, Romania, Serbia), PPP (Croatia, Latvia, Slovakia, Slovenia), NEER (Poland, Romania, Serbia, Slovenia); \*\*\*, \*\* and \* denote statistical significance at the 1%, 5% and 10% level, respectively.

Source: own calculations


It is assumed that inflation is inertial, being affected by its volatility, exchange rate, commodity and foreign price shocks. Similar to Cunningham et al. [2017], the ERPT is estimated with control for oil demand shock. For the CEE countries, it is quite natural to proxy external prices with the consumer price index in Germany as the largest European economy.

Time-varying coefficients for the lagged value of  $p_t$  are modelled as driftless random walk which can capture various time paths of the parameters. On the other hand, time-varying coefficients for predetermined variables are modelled as recursive ones which implies relative stability of the relationships. The EViews 10 statistical package was used for estimations.

## EMPIRICAL RESULTS

The TVP estimates of the ERPT to consumer price inflation are presented in Figures 1 and 2. Among countries with a floating exchange rate regime (Fig. 1), Poland experienced a steep drop in the ERPT to CPI at the beginning of the 2000s (similar developments but on a much smaller scale are present in Albania and Serbia). A post-crisis strengthening of the ERPT is very sharp in Hungary, Serbia and Croatia. For other countries, the value of the ERPT has not changed significantly since 2010 but statistical significance of the estimated time-varying parameters has become somewhat higher. It suggests that in a post-crisis environment of low inflation and extremely low interest rates the ERPT to CPI is more stable.

Figure 1. Estimates of the ERPT to CPI for the countries with a flexible exchange rate regime




\* here and hereafter point estimates are presented within the band of  $\pm 2$  standard deviations.  
Source: own preparation

For countries with a fixed exchange regime (Fig. 2), the ERPT seems to be stronger, with no sign of an increase in its value or statistical significance for a post-crisis period of 2010–2021 (except Bulgaria and Latvia). A downward trend in the ERPT since the beginning of 2000s is observed in Estonia, Slovakia and Slovenia.

Except Albania, the Czech Republic, and Croatia, the ERPT to producer prices is stronger in comparison to the ERPT to consumer prices for countries with a floating exchange rate regime (Fig. 3). We notice a higher post-crisis ERPT to PPI


in Croatia, Hungary, and Poland, while it is the opposite in the Czech Republic. Among countries with a fixed exchange rate, the same outcome of stronger ERPT to PPI is observed for Bulgaria and the Baltic States (Fig. 4). Slovakia and Lithuania have experienced a sustained significant increase in the ERPT to PPI since 2010, while it was temporary in Latvia.

Figure 2. Estimates of the ERPT to CPI for the countries with a fixed exchange rate regime



Source: own preparation

Figure 3. Estimates of the ERPT to PPI for the countries with a flexible exchange rate regime

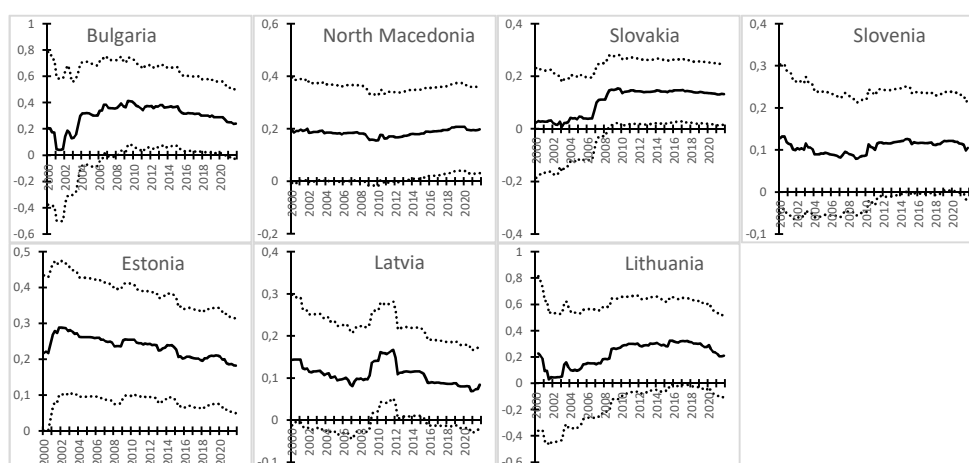


Source: own preparation

For convenience, the results are aggregated for several groups of countries in Table 2. On average, the ERPT to PPI is much higher in comparison to ERPT to CPI for the Float-4 (the Czech Republic, Hungary, Poland, Romania) and the Baltic countries for both pre- and post-crisis periods. A higher post-crisis ERPT to CPI is

observed for the Float-3 countries (Albania, Croatia, Serbia), with an opposite outcome for the Fixed-4 countries (Bulgaria, Slovakia, Slovenia, North Macedonia); however, it is not the case for the ERPT to PPI for the latter. In the post-crisis period, all groups of countries demonstrate a decrease in the standard deviation of estimated time-varying parameters for the ERPT to both consumer and producer prices.

Figure 4. Estimates of the ERPT to PPI for the countries with a fixed exchange rate regime



Source: own preparation

Table 2. Comparison of the ERPT to consumer and producer prices

Countries	CPI		PPI	
	2004Q1–2008Q2	2010Q1–2021Q4	2004Q1–2008Q2	2010Q1–2021Q4
Float-4	0.070 (0.041)	0.059 (0.026)	0.210 (0.053)	0.225 (0.034)
Float-3	0.088 (0.044)	0.136 (0.036)	—	0.111 (0.075)
Fixed-4	0.190 (0.094)	0.177 (0.078)	0.169 (0.107)	0.192 (0.088)
Baltic-3	0.092 (0.046)	0.081 (0.040)	0.165 (0.119)	0.206 (0.099)

\* average standard deviation is in parentheses.

Source: own calculations

Our results mean that a widely recognized tendency for a decrease in the magnitude of the ERPT, as found in international studies [Lopez-Villavicencio and Mignon 2017, Patra, Khundrakpam and John 2020], is present in the CEE countries but it is not extraordinarily strong. Except for Croatia, Serbia and Latvia, there is no support for a significant increase in the magnitude of ERPT to CPI in a post-crisis period since 2010, as it is found for the developing economies [Jašová, Moessner and Takáts 2019]. In relation to a study by Jimborean [2013], it is confirmed that a lower exchange rate volatility can be a factor behind the higher ERPT, but it is only a case for the magnitude of ERPT to CPI, not ERPT to PPI.



Among other results, inflationary effects of the world oil prices for CPI is strong for Slovakia and North Macedonia, while in Hungary, Slovenia and Estonia it is observed since 2020. As expected, sensitivity of the PPI to the world oil prices is much more widespread. Besides Slovakia and North Macedonia, it is observed since the beginning of 2000s in Croatia, Bulgaria and the Baltic States, while in other countries this kind of relationship it is a more recent phenomenon (since the middle of last decade). Except for Romania, Albania, Serbia, North Macedonia and Bulgaria, domestic consumer prices are influenced by the German CPI. For the producer prices, only Bulgaria and Estonia lack statistically significant relation to foreign prices. Variability of CPI contributes to inflationary dynamics in almost all countries, except Albania and Poland. On the other hand, variability of PPI is a significant factor behind producer prices only in Serbia and Slovenia.

## SUMMARY

Our study demonstrates that on average the incomplete ERPT is stronger for countries with a fixed exchange rate regime, being in accordance with the results of earlier studies. Since the middle of 2000s, the ERPT seems to be fairly stable in most of the countries. A post-crisis strengthening of the estimated ERPT to consumer prices is very sharp in Hungary and Serbia which practise inflation targeting, as well as in Bulgaria and Latvia, both countries supporting a fixed exchange rate of their currencies. With the exception of the Czech Republic, Romania, and Estonia, there is a tendency for strengthening of the ERPT to producer prices in the wake of the world financial crisis of 2008–2009. As a positive link between exchange rate and the consumer and producer prices is observed in majority of countries (except the Czech Republic), it argues in favour of using the exchange rate appreciation as an anti-inflationary tool. Obviously, strengthening of the euro in respect to other world currencies should be helpful for the countries which decided to peg their currencies to the European common currency. Besides nominal exchange rate changes, for most of the countries both consumer and producer prices are influenced by the consumer price dynamics in Germany and by the world oil prices, though the latter is a more recent phenomenon. Variability of CPI is a significant inflationary factor in almost all countries, except Albania and Poland, while variability of PPI is a significant factor behind producer prices only in Serbia and Slovenia.

## REFERENCES

- Aron J., Macdonald R., Muellbauer J. (2014) Exchange rate pass-through in developing and emerging markets: A survey of conceptual, methodological and policy issues, and selected empirical findings. *Journal of Development Studies*, 50(1), 101-143.
- Baxa J., Šestořád T. (2019) The Czech exchange rate floor: Depreciation without inflation? Working Paper Series, 1/2019. Czech National Bank, Prague, the Czech Republic.
- Ben Cheikh N., Ben Zaied Y. (2020) Revisiting the pass-through of exchange rate in the transition economies: New evidence from new EU member states. *Journal of International Money and Finance*, 100, 102093.

- Bernini M., Tomasi C. (2015) Exchange rate pass-through and product heterogeneity: Does quality matter on the import side? *European Economic Review*, 77(C), 117-138.
- Cunningham R., Friedrich C., Hess K., Kim M. J. (2017) Understanding the time variation in exchange rate pass-through to import prices. Staff Discussion Paper, 2017-12. Bank of Canada, Ottawa.
- Darvas Z. (2013) Monetary transmission in three Central European economies: evidence from time-varying coefficient vector autoregressions. *Empirics*, 40(2), 363-390.
- García-Schmidt M., García-Cicco J. (2020) Revisiting the exchange rate pass through: A general equilibrium perspective. *Journal of International Economics*, 127(C), 103389.
- Gust C., Leduc S., Vigfusson R. (2010) Trade integration, competition, and the decline in exchange-rate pass-through. *Journal of Monetary Economics*, 57(3), 309-324.
- Ha J., Stocker M., Yilmazkuday H. (2020) Inflation and exchange rate pass-through. Policy Research Working Paper, 8780. World Bank, Washington, DC.
- Hajnal M., Molnár G., Várhegyi J. (2015) Exchange rate pass-through after the crisis: The Hungarian experience. MNB Occasional Papers, 121. Magyar Nemzeti Bank, Budapest, Hungary.
- Jašová M., Moessner R., Takáts E. (2019) Exchange rate pass-through: What has changed since the crisis? *International Journal of Central Banking*, 15(3), 27-58.
- Jimborean R. (2013) The exchange rate pass-through in the new EU member States. *Economic Systems*, 37(2), 302-329.
- Kurtović S., Šehić-Kršlak S., Halili B., Maxhuni N. (2018) Exchange rate pass-through into import prices of Croatia. *Exchange Rate Pass-Through into Import Prices of Croatia. Naše gospodarstvo/Our Economy*, 64(4), 60-73.
- López-Villavicencio A., Mignon V. (2017) Exchange rate pass-through in emerging countries: Do the inflation environment, monetary policy regime and central bank behavior matter? *Journal of International Money and Finance*, 79(C), 20-38.
- Mirdala R. (2014) Exchange rate pass-through to consumer prices in the European transition economies. *Procedia Economics and Finance*, 12, 428-436.
- Ozkan I., Erden L. (2015) Time-varying nature and macroeconomic determinants of exchange rate pass-through. *International Review of Economics and Finance*, 38(C), 56-66.
- Patra M. D., Khundrakpam J. K., John J. (2020) Exchange Rate Pass-through in emerging economies. RBI Working Paper Series, 01/2020. Reserve Bank of India, Delhi, India.
- Sekine T. (2006) Time-varying exchange rate pass-through: experiences of some industrial countries. BIS Working Papers, 22. Bank of International Settlements, Basel, Switzerland.
- Sims C. A. (1982) Policy analysis with econometric models. *Brookings Papers on Economic Activity*, 13(1), 107-164.
- Svensson L. (2000) Open-economy inflation targeting. *Journal of International Economics*, 50(1), 155-183.
- Takhtamanova Y. (2010) Understanding changes in exchange rate pass-through. *Journal of Macroeconomics*, 32(4), 1118-1130.
- Vonnák B. (2010) Risk premium shocks, monetary policy and exchange rate pass-through in the Czech Republic, Hungary and Poland. MNB Working Papers, 2010/1, Magyar Nemzeti Bank (Central Bank of Hungary), Budapest.