



Kolba P.M., Kotkowski R. (2013), *Wskaźniki cyklu koniunkturalnego a krótkookresowe prognozy polskiej produkcji przemysłowej*, „Oeconomia Copernicana”, nr 3, ss. 65-79, DOI: <http://dx.doi.org/10.12775/OeC.2013.023>

*Paweł M. Kolba**

Uniwersytet Mikołaja Kopernika w Toruniu

*Radosław Kotkowski**

Szkoła Główna Handlowa

Wskaźniki cyklu koniunkturalnego a krótkookresowe prognozy polskiej produkcji przemysłowej

Klasyfikacja JEL: C32, C53, E23

Słowa kluczowe: *wskaźniki cyklu koniunkturalnego, prognoza krótkoterminowa, produkcja przemysłowa*

Abstrakt: *Celem artykułu jest zbadanie, jaki wpływ na jakość krótkoterminowych prognoz produkcji przemysłowej ma zastosowanie w modelu wskaźników cyklu koniunkturalnego. Badanie przeprowadzone zostało na gospodarce polskiej przy użyciu metodologii zaproponowanej przez M. Kleina.*

© Copyright Instytut Badań Gospodarczych & Polskie Towarzystwo Ekonomiczne Oddział w Toruniu

Tekst wpłynął 25 maja 2013 r., został zaakceptowany do publikacji 10 sierpnia 2013 r.

* Dane kontaktowe autorów: pkolba@o2.pl, Uniwersytet Mikołaja Kopernika, Wydział Nauk Ekonomicznych i Zarządzania, ul. Gagarina 13a, 87-100 Toruń; raddek.kotkowski@gmail.com, Szkoła Główna Handlowa, Al. Niepodległości 162, 02-554 Warszawa

Business Cycles Indicators and Short-term Forecasts of Polish Industry Production Index

JEL Classification: *C32, C53, E23*

Keywords: *business cycle indicators, short-term forecast, industrial production*

Abstract: *The aim of this paper is to evaluate the impact of using popular business cycle indicators on the forecasts of industry production index. Research is conducted on Polish economy, by using methodology proposed by M. Klein.*

Wprowadzanie

Wielkość produkcji przemysłowej jest jedną z najważniejszych miar aktywności gospodarczej kraju. Jej szerokie zastosowanie prognostyczne wynika z dużego wpływu koniunktury sektora wytwórczego na inne wielkości gospodarki realnej – m.in. wzrost PKB, zatrudnienie, itp.

Wzrost poziomu indeksów produkcji przemysłowej stanowi korzystny sygnał dla rynków kapitałowych i walutowych przynosząc na pierwszych hossa, a na drugich prowadząc do aprecjacji kursu krajowego pieniądza. Z tego względu także prognoza tego wskaźnika przekazuje bardzo istotną informację zwrotną, o szczególnej wartości dla sektora finansowego i agend publicznych, które mogą na jej podstawie podejmować decyzje w zakresie prowadzonej przez siebie polityki gospodarczej.

W niniejszym artykule postanowiono zbadać, czy zastosowanie popularnych wskaźników cyklu koniunkturalnego może istotnie poprawić jakość krótkoterminowych prognoz wielkości polskiej produkcji przemysłowej.

Wcześniejsze badania

Badania dotyczące wpływu wskaźników koniunktury na jakość prognoz produkcji przemysłowej przeprowadzane były w przeszłości wielokrotnie i dotyczyły zarówno pojedynczych krajów, jak i całych grup.

Analizy pojedynczych gospodarek przeprowadzali m.in.: Funke (1997, s. 90–102), Fritsche i Stephan (2002, s. 289–315), Hüfner i Schröder (2002) oraz Dreger i Schumacher (2005, s. 71–87) – badania gospodarki niemieckiej; Marchetti i Parigi (2000, s. 419–440), Bruno i Lupi (2004, s. 647–671)

- badania gospodarki włoskiej; oraz Emerson i Hendry (1996, s. 271–291)
- badania gospodarki brytyjskiej.

Analizy grup krajów, zwłaszcza Unii Europejskiej, prowadzone były przez m.in.: Bodo, Golinelli i Parigi (2000, s. 541–561), Camba-Mendez, Kapetanios, Smith i Weale (2001, s. S56–S90), Forni i in. (2001, s. 62–85), Marcellino, Stock i Watson (2003, s. 1–18), Camba-Mendez, Kapetanios, Smith i Weale (2004, s. 386–408), Ozyildirim, Schaitkin i Zarnowitz (2010, s. 6–28) oraz Carstensen, Wohlrabe i Ziegler (2011, s. 82–106).

W artykule M. Kleina (2012) pt. „In-sample and out-of-sample performance of alternative business cycle indicators in core European countries”, którego metodologia stanowiła podstawę dla tego badania, analizie poddane zostały trzy gospodarki: niemiecka, francuska oraz włoska.

Metodyka badania

Do przeprowadzenia badania została użyta rekursywna estymacja parametrów (ang. *rolling regression*) ze stałą wielkością obserwacji. Metoda ta zgodnie ze stwierdzeniem Kleina (2012) (który opierał się na badaniach: Stocka i Watsona (1996, s. 11–30), Marcellino, Stocka i Watsona (2003, s. 1–18), Dregera i Schumachera (2005, s. 71–87), Ozyildirima, Schaitkina i Zarnowitza (2010, s. 6–28) oraz Carstensena i in. (2011, s. 82–106), pozwoliła dostrzec różnicę pomiędzy różnymi wskaźnikami cyklu koniunkturalnego, a także ustrzec się przed wpływem niestałości relacji w czasie na ocenę i interpretację wyników. Następnie została przeprowadzona jednomiesięczna prognoza produkcji przemysłowej z uwzględnieniem wskaźników koniunktury, a jej wyniki porównano z prognozą na podstawie modelu autoregresyjnym o 13 opóźnień.

Rozpatrywana hipoteza modelowa przyjęła postać:

$$y_t = \alpha_{t_*} + \sum_{i=1}^p \phi_{i,t_*} y_{t-i} + \theta_{t_*} x_{t-1} + \varepsilon_t \quad (1)$$

gdzie:

y_t – wzrost produkcji przemysłowej rok do roku;

x_t – wartość wybranego wskaźnika koniunktury;

t – miesiąc;

t_* – okres obserwacji w rekursywnej estymacji parametrów dla stałego T ;

α_{t_*} , ϕ_{i,t_*} , θ_{t_*} – parametry strukturalne modelu w okresie t_* (przy czym najistotniejszy dla niniejszego badania jest współczynnik θ stojący przed wskaźnikiem cyklu koniunkturalnego);

p – maksymalny rząd opóźnienia zmiennej zależnej;
 ε_t – błąd losowy.

Prognoza została obliczona na podstawie wzoru:

$$y_t^f = \hat{\alpha}_{t_*} + \sum_{i=1}^p \hat{\varphi}_{i,t_*} y_{t-1} + \hat{\theta}_{t_*} x_{t-1} \quad (2)$$

gdzie:

y_t^f – prognozowany wzrost produkcji przemysłowej rok do roku;
 $\hat{\alpha}_{t_*}$, $\hat{\varphi}_{i,t_*}$, $\hat{\theta}_{t_*}$ – oceny parametrów wyliczone w równaniu (1).

Prognoza służąca za porównanie dla oceny stopnia w jakim wskaźniki koniunktury poprawiają prognozy wyznaczona zostanie według równania:

$$y_t^f = \hat{\alpha}_{t_*} + \sum_{i=1}^p \hat{\varphi}_{i,t_*} y_{t-1} \quad (3)$$

Wielkość podpróby dla każdej estymacji (T) została ustalona na 72 miesiące, czyli 6 pełnych lat. Wiąże się to z wynikami badań empirycznych, które wykazały, że cykl koniunkturalny w Polsce jest kształtowany przez fluktuacje o okresie 3 lat oraz o okresie 6-7 lat (Skrzypczyński, 2008, s. 21). Wpływ wprowadzenia do analizy wskaźników koniunktury został zbadany za pomocą porównania pierwiastków błędów średniokwadratowych predykcji (ang. *root mean squared error* – RMSE), dobrze nadającego się do porównywania różnych prognoz (za Klein (2012): Armstrong i Collopy (1992, s. 69–80), Franses (1998), Fildes i Ord (2004, s. 322–353) oraz West (2006, s. 99–134)), prognozy naiwnej oraz uwzględniającej dany wskaźnik.

Materiał badawczy

Do badania wykorzystano 11 szeregów czasowych o częstotliwości miesięcznej przedstawionych w tabeli 1.

Tabela 1. Wskaźniki wykorzystane w badaniu


Symbol	Wskaźnik	Źródło
IPI	Industry Production Index	Eurostat
INOI	Industry New Order Index	
ESI_EC	Economic Sentiment Indicator	Komisja Europejska
BCI_EC	Business Climate Indicator	
CLI_OECD	Composite Leading Indicator	OECD
BCI_OECD	Business Confidence Indicator	
WOKK	Wskaźnik Ogólnego Klimatu Koniunktury (przetwórstwo przemysłowe)	GUS
CCI_IPSOS	Consumer Confidence Indicator	Ipsos
WKG	Wskaźnik Klimatu Gospodarczego	
PMI	Purchasing Managers' Index	Markit Economics
PENGAB	PENGAB	Pentor

Źródło: opracowanie własne.

Rolę zmiennej endogenicznej pełnił Indeks Produkcji Przemysłowej (IPI), pozostałe zmienne miały charakter egzogeniczny. Wszystkie zmienne obejmowały 136 okresów – dla zmiennych objaśniających zakres od stycznia 2001 r. (2001M01) do kwietnia 2012 roku (2012M04), natomiast dla zmiennej objaśnianej, odpowiednio od lutego 2001 roku (2001M02) do maja 2012 (2012M05).

Zebrane wskaźniki koniunktury gospodarczej skonstruowane i zaprezentowane zostały według trzech głównych schematów: jako odchylenia od określonej wartości bazowej (0, 50 lub 100), jako wielkości bezwzględne, gdzie bazą jest jeden z okresów (np. 100=2007M01) oraz jako względne przyrosty w różnym horyzoncie czasowym (rocznym lub miesięcznym). W bieżącym opracowaniu postanowiono zachować ich oryginalną postać.

Kształtowanie się produkcji przemysłowej przedstawione zostało na wykresie 1, natomiast statystyki deskryptywne zmiennej endogenicznej zaprezentowano w tabeli 2.

Wykres 1. Kształtowanie się Indeksu Produkcji Przemysłowej w okresie 02.2001-05.2012

Źródło: opracowanie własne na podstawie danych Eurostat.

Tabela 2. Statystyki deskryptywne Indeksu Produkcji Przemysłowej

Statystyka	Wartość
Średnia	6,0215
Mediana	7,4000
Minimalna	-14,2000
Maksymalna	22,2000
Odchylenie standardowe	6,4959
Współczynnik zmienności	1,0788
Skośność	-0,5554
Kurtoza	0,4859

Źródło: opracowanie własne na podstawie danych Eurostat.

Najwyższą wartość indeksu zanotowano w kwietniu 2004 r., kiedy wyniósł on 22,2, najniższą zaś – w konsekwencji wybuchu światowego kryzysu gospodarczego – w lutym 2009 r. (-14,2). Średnia wielkość wskaźnika w badanym okresie to 5,93 przy medianie równej 7,3, co świadczy o dużej dynamice wzrostu produkcji przemysłowej w Polsce. Lewostronna asymetria rozkładu oznacza przewagę okresów wzrostowych nad spadkowymi.

Wyniki badań

Pierwszym krokiem w badaniu było ustalenie rzędu opóźnienia zmiennej zależnej w równaniach (1)-(3). W tym celu oszacowano modele dane wzorem (3) dla różnych p (do maksymalnego rzędu równego 20% wielkości podpróby) i porównano trafności ich prognoz. Wyniki przedstawia tabela 3.

Tabela 3. Prognozy naiwne dla różnych rzędów opóźnienia

p	1	2	3	4	5	6	7	8	9	10	11	12	13	14
RMSE	2,995	2,812	2,839	2,790	2,806	2,824	2,883	2,889	2,880	2,922	2,999	2,940	2,769	2,773

Źródło: Opracowanie własne na podstawie wyliczeń programu GRETL.

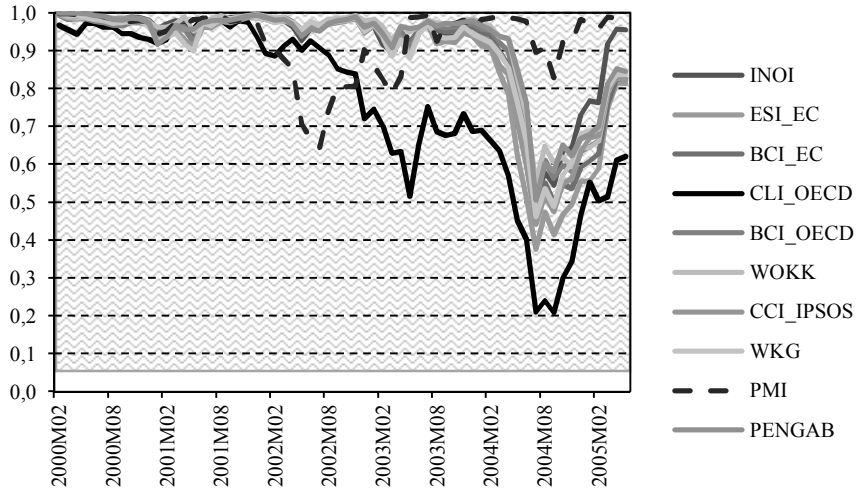
Na podstawie RMSE wybrano rząd opóźnienia równy 13, co potwierdza empirycznie założenie przyjęte przez Carstensa i in. (2011, s. 82–106) oraz Kleina (2012), że szok egzogeniczny zazwyczaj wpływa na zmienną endogeniczną maksymalnie przez rok. Następnie przy użyciu klasycznej metody najmniejszych kwadratów estymowano modele dane wzorem (2) dla 10 wskaźników koniunktury i 64 podprób, z których każda miała długość 72 miesiący. Łącznie oszacowano i poddano badaniu 640 równań.

Dla sprawdzenia czy dane nie wykazują autokorelacji posłużono się testem Ljunga-Boxa Q dla maksymalnego rzędu opóźnienia równego 13. Jego wyniki przedstawia poniższy wykres.

Wysokie p -value wszystkich zmiennych dla każdej z podprób wskazuje na brak podstaw do odrzucenia hipotezy zerowej, która w teście Ljunga-Boxa mówi o braku autokorelacji składnika losowego (Ljung i Box, 1978, s. 297–303).


Badanie jednorodności składnika losowego zostało przeprowadzone za pomocą testu White'a (1980, s. 817–838). Rezultaty przedstawione na wykresie 3 pokazują, że przy poziomie istotności $\alpha = 0,05$ w żadnym z szacowanych modeli nie występuje heteroskedastyczność reszt, w konsekwencji czego można używać KMNK jako metody estymacji parametrów.

Wykres 2. Wartości p testu Ljung-Boxa dla estymowanych równań



Źródło: opracowanie własne na podstawie wyciżen programu GRETL.


Wykres 3. Wartości p testu White'a dla estymowanych równań



Źródło: opracowanie własne na podstawie wyciżen programu GRETL.

Kształtowanie się parametrów θ stojących przed danymi wskaźnikami cyklu koniunkturalnego przedstawia wykres 4, a wybrane statystyki opisowe tabela 4.

Wykres 4. Wielkości współczynnika θ dla estymowanych równań



Źródło: opracowanie własne na podstawie wyliczeń programu GRETL.

Tabela 4. Wybrane statystyki deskryptywne parametru θ szacowanego dla różnych próbek

	INOI	ESI_EC	BCI_EC	CLI_OECD	BCI_OECD	WOKK	CCI_IPSOS	WKG	PMI	PEN GAB
Średnia	0,016	0,008	0,075	1,736	0,551	0,085	0,008	-0,007	0,836	0,078
Odchylenie standardowe	0,006	0,043	0,081	0,344	0,424	0,051	0,029	0,021	0,221	0,042
Współczynnik zmienności	0,355	5,569	1,075	0,198	0,769	0,601	3,867	3,114	0,265	0,533


Źródło: opracowanie własne na podstawie wyliczeń programu GRETL.

W badanych próbkach najmniejszymi wahaniami cechowały się oceny parametru stojącego przed zmienną *Composite Leading Indicator*, której wielkość różniła się przeciętnie od średniej o 19,8%, stosunkowo niewiel-

kie fluktuacje wykazywały także oceny współczynnika θ dla *Purchasing Managers' Index* (26,5%) oraz *Industry New Order Index* (35,5%). Najbardziej niestabilne w czasie okazały się oceny dla wskaźników: Wskaźnik Koniunktury Gospodarczej, *Consumer Confidence Indicator* oraz *Economic Sentiment Indicator*, których wysoki współczynnik zmienności (analogicznie: 331,4%, 386,7%, 557,9%) praktycznie wyklucza modelowanie w długim okresie.

Istotność parametru zbadana została testem t-Studenta, którego wyniki zostały zobrazowane na wykresie 5.

Wykres 5. Wartości testu t-Studenta parametru θ dla estymowanych równań



Źródło: opracowanie własne na podstawie wyliczeń programu GRETL.

Wśród przebadanych wskaźników tylko w przypadku jednego – *Composite Leading Indicator* – można odrzucić hipotezę zerową testu mówiącą o nieistotności badanego parametru dla wszystkich podprób. *Purchasing Managers' Index* okazał się nieistotny w trzech spośród 64 podprób, zaś pozostałe wskaźniki koniunktury są nieistotne w większości analizowanych okresów. Mimo tego, wszystkie ujęte w niniejszym opracowaniu wskaźniki zastosowano do badania jakości prognoz krótkoterminowych. Otrzymane wyniki prezentuje tabela 5.

Tabela 5. Pierwiastki błędów średniokwadratowych predykcji

Model	RMSE
<i>Composite Leading Indicator</i>	2,591934
<i>Consumer Confidence Indicator</i>	2,746630
<i>Business Climate Indicator</i>	2,751738
<i>Economic Sentiment Indicator</i>	2,767281
Wskaźnik Klimatu Gospodarczego	2,768565
AR = 13	2,769326
<i>Business Confidence Indicator</i>	2,769945
<i>Industry New Order Index</i>	2,783826
Wskaźnik Ogólnego Klimatu Koniunktury	2,803986
PENGAB	2,819482
<i>Purchasing Managers' Index</i>	2,859812

Źródło: opracowanie własne na podstawie wycięcia programu GRETL.

Tylko połowa z badanych wskaźników zmniejszyła błąd RSME jednomiesięcznych prognoz, wobec przyjmowanej za *benchmark* prognozy naiwnej, jednakże tylko jeden był istotny statystycznie (*Composite Leading Indicator*).

Zakończenie

Celem artykułu było zbadanie wpływu 10 najpopularniejszych wskaźników cyklu koniunkturalnego na krótkoterminowe prognozy polskiej produkcji przemysłowej.

Badanie przeprowadzono metodą rekursywnej estymacji parametrów o stałej wielkości próby równej 72 miesiące. Poprawność oszacowanych równań przetestowano testami Ljunga-Boxa oraz White'a, które wykazały zarówno brak występowania autokorelacji w całym testowanym okresie, jak i brak heteroskedastyczności reszt. Parametry stojące przed wskaźnikami koniunkturalnymi przebadano testem t-Studenta, a wyniki wskazały na statystyczną istotność jedynie dwóch z nich (*Composite Leading Indicator* oraz *Purchasing Managers' Index*) przez większość badanego okresu.

Oszacowane dla wszystkich zmiennych jednomiesięczne prognozy porównano z prognozami naiwnymi opartymi tylko i wyłącznie na kształtowaniu się produkcji przemysłowej w ostatnich 13 miesiącach. Spośród wskaźników statystycznie istotnych jedynie *Composite Leading Indicator* poprawił jakość modelu pod kątem błędu średniokwadratowego prognozy.

Nieistotność większości wskaźników cyklu koniunkturalnego może wynikać ze zastosowanej metodologii, dlatego też przedmiotem dalszych badań powinna być weryfikacja obserwowanego zjawiska za pomocą innych metod badawczych.

Literatura

- Armstrong J.S., Collopy F. (1992), *Error measures for generalizing about forecasting methods: Empirical comparisons*, „International Journal of Forecasting”, Vol. 8, No. 1. [doi:10.1016/0169-2070\(92\)90008-W](https://doi.org/10.1016/0169-2070(92)90008-W).
- Bodo G., Golinelli R. i Parigi G. (2000), *Forecasting industrial production in the Euro area*, „Empirical Economics”, Vol. 25, No. 4. [doi:10.1007/s001810000032](https://doi.org/10.1007/s001810000032).
- Bruno G., Lupi C. (2004), *Forecasting industrial production and the early detection of turning points*, „Empirical Economics”, Vol. 29, No. 3. [doi:10.1007/s00181-004-0203-y](https://doi.org/10.1007/s00181-004-0203-y).
- Camba-Mendez G., Kapetanios G., Smith R.J. i Weale M.R. (2001), *An automatic leading indicator of economic activity: forecasting GDP growth for European countries*, „Econometrics Journal”, Vol. 4, No. 1. [doi:10.1111/1368-423X.00053](https://doi.org/10.1111/1368-423X.00053).
- Camba-Mendez G., Kapetanios G., Smith R.J. i Weale M.R. (2004), *The forecasting performance of the OECD Composite Leading Indicators for France, Germany, Italy and the UK* [w:] M.P. Clements, D.F. Hendry (red.), *A companion to economic forecasting*, Blackwell Publishing, Oxford. [doi:10.1002/9780470996430.ch17](https://doi.org/10.1002/9780470996430.ch17).
- Carstensen K., Wohlrabe K. i Ziegler C. (2011), *Predictive ability of business cycle indicators under test: A case study for the Euro Area industrial production*, „Journal of Economics and Statistics”, Vol. 231, No. 1.
- Dreger C., Schumacher C. (2005), *Out-of-sample performance of leading indicators for the German business cycle vs. combined forecasts*, „Journal of Business Cycle Measurement and Analysis”, Vol. 2, No. 1, [doi:10.1787/jbcma-2005-5km7v183qs0v](https://doi.org/10.1787/jbcma-2005-5km7v183qs0v).
- Emerson R.A., Hendry D.F. (1996), *An evaluation of forecasting using leading indicators*, „Journal of Forecasting”, Vol. 15, No. 4. [doi:10.1002/\(SICI\)1099-131X\(199607\)15:4<271::AID-FOR623>3.0.CO;2-7](https://doi.org/10.1002/(SICI)1099-131X(199607)15:4<271::AID-FOR623>3.0.CO;2-7).
- Fildes R., Ord K. (2004), *Forecasting competitions: Their role in improving forecasting practice and research* [w:] M.P. Clements, D.F. Hendry (red.), *A companion to economic forecasting*, Blackwell Publishing, Oxford. [doi:10.1002/9780470996430.ch15](https://doi.org/10.1002/9780470996430.ch15).
- Forni M., Hallin M., Lippi M. i Reichlin L. (2001), *Coincident and leading indicators for the Euro Area*, „The Economic Journal”, Vol. 111, No. 471, [doi:10.1111/1468-0297.00620](https://doi.org/10.1111/1468-0297.00620).
- Franses P.H. (1998), *Time series models for business and economic forecasting*, Cambridge University Press, Cambridge.

- Fritsche U., Stephan S. (2002), *Leading indicators of German business cycles*, „Journal of Economics and Statistics”, Vol. 222, No. 3.
- Funke N. (1997), *Predicting recessions: Some evidence for Germany*, „Weltwirtschaftliches Archiv”, Vol. 133, No. 1, [doi:10.1007/BF02707678](https://doi.org/10.1007/BF02707678).
- Hüfner F.P., Schröder M. (2002), *Forecasting economic activity in Germany – How useful are sentiment indicators?*, „ZEW Discussion Paper”, No. 02-56. [ftp://ftp.zew.de/pub/zew-docs/dp/dp0256.pdf](http://ftp.zew.de/pub/zew-docs/dp/dp0256.pdf) (10.07.2013).
- Klein M. (2012), *In-sample and out-of-sample performance of alternative business cycle indicators in core European countries*. http://www.boeckler.de/pdf/v_2012_10_25_klein.pdf (10.07.2013).
- Ljung G.M., Box G.E.P. (1978), *On a measure of lack of fit in time series models*, „Biometrika”, Vol. 65, No. 2. [doi:10.1093/biomet/65.2.297](https://doi.org/10.1093/biomet/65.2.297).
- Marcellino M., Stock J.H. i Watson M.W. (2003), *Macroeconomic forecasting in the Euro area: Country specific versus area-wide information*, „European Economic Review”, Vol. 47, No. 1, [doi:10.1016/S0014-2921\(02\)00206-4](https://doi.org/10.1016/S0014-2921(02)00206-4).
- Marchetti D.J., Parigi G. (2000), *Energy consumption, survey data and the prediction of industrial production in Italy: a comparison and combination of different models*, „Journal of Forecasting”, Vol. 19, No. 5, [doi:10.1002/1099-131X\(200009\)19:5<419::AID-FOR749>3.0.CO;2-J](https://doi.org/10.1002/1099-131X(200009)19:5<419::AID-FOR749>3.0.CO;2-J).
- Ozyildirim A., Schaitkin B. i Zarnowitz V. (2010), *Business cycles in the euro area defined with coincident economic indicators and predicted with leading economic indicators*, „Journal of Forecasting”, Vol. 29, No. 1-2, [doi:10.1002/for.1146](https://doi.org/10.1002/for.1146).
- Skrzypczyński P. (2008), *Wahania aktywności gospodarczej w Polsce i strefie euro*, „Materiały i Studia NBP”, Nr 227.
- Stock J.H., Watson M.W. (1996), *Evidence on structural instability in macroeconomic time series relations*, „Journal of Business & Economic Statistics”, Vol. 14, No. 1. [doi:10.1080/07350015.1996.10524626](https://doi.org/10.1080/07350015.1996.10524626).
- West K. D. (2006), *Forecast evaluation* [w:] G. Elliott, C.W.J. Granger, A. Timmermann (red.), *Handbook of Economic Forecasting, Volume 1*, North Holland, Amsterdam, [doi:10.1016/S1574-0706\(05\)01003-7](https://doi.org/10.1016/S1574-0706(05)01003-7).
- White H. (1980), *A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity*, „Econometrica”, Vol. 48, No. 4, [doi:10.1912934](https://doi.org/10.1912934).

Aneks

Zastosowana w badaniu rekursywna metoda estymacji, nie należy do metod oferowanych w ramach używanego oprogramowania statystycznego GRET. Skrypt ją implementujący został stworzony przez autorów badania, a z uwagi na jego możliwą przydatność w innych pracach, zamieszczono go poniżej:

```
#wyłączenie komunikatów i echa
set messages off
set echo off

T = 72 #długość jednego 'okienka'
AR = 13 #rząd opóźnienia zmiennej zależnej

#deklaracja opóźnionych o 1 okres zmiennych egzogenicznych
#pierwsza_zmienna..ostatnia_zmienna
list zmienne = INOI_1..PENGAB_1

n = lastobs(IPI)-T
l_wierszy = n-AR
l_kolumn = nelem(zmienne)

#utworzenie macierzy do przechowywania wyników estymacji i testów
matrix wspolczynniki = zeros(l_wierszy,l_kolumn)
colnames(wspolczynniki, zmienne)
matrix t_studenta = zeros(l_wierszy,l_kolumn)
colnames(t_studenta, zmienne)
matrix ljunga_boxa = zeros(l_wierszy,l_kolumn)
colnames(ljunga_boxa, zmienne)
matrix RMSE_prog = zeros(l_wierszy,l_kolumn)
colnames(RMSE_prog, zmienne)
matrix normalnosc = zeros(l_wierszy,l_kolumn)
colnames(normalnosc, zmienne)
matrix jednorodn_war = zeros(l_wierszy,l_kolumn)
colnames(jednorodn_war, zmienne)

j=1
loop foreach x zmienne
  i=1
  loop pierw_obs=AR+1..n

    #ustalenie wielkości próby i generowanie modeli
    smpl pierw_obs pierw_obs+T-1
    ols IPI const $x IPI(-1 to -AR) --quiet

    #wyciąganie wyników estymacji i przeprowadzanie testów
    wsp = $coeff($x)
    tstud = $coeff($x)/$stderr($x)

    lb = ljungbox($uhat, 13)
    ljungboxQ = pvalue(X, 13, lb)
```

```
modtest --white
jedn_war = $pvalue

modtest --normality
norm = $pvalue

fcast pierw_obs+T pierw_obs+T --quiet
RMSE_wyn = abs(IPI[pierw_obs+T] - $fcast)

wspolczynniki[i,j] = wsp
t_studenta[i,j] = tstud
ljunga_boxa[i,j] = ljungboxQ
jednorodn_war[i,j] = jedn_war
normalnosc[i,j] = norm
RMSE_prog[i,j] = RMSE_wyn

    i++
  endloop
  j++
endloop
```