

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 XXVI, No. 3

Warsaw 2025

EDITORIAL BOARD

Editor-in-Chief: Bolesław Borkowski
Deputy Editor-in-Chief: Hanna Dudek
Managing Editors: Michał Gostkowski, Grzegorz Koszela
Theme Editors:
Econometrics: Bolesław Borkowski
Multivariate Data Analysis: Wiesław Szczesny
Mathematical Economics: Zbigniew Binderman
Data Science: Michał Gostkowski
Financial Engineering: Monika Krawiec
Labor Market Analysis: Joanna Landmesser-Rusek
Statistical Editor: Wojciech Zieliński
Technical Editors: Jolanta Kotlarska, Elżbieta Saganowska
Language Editor: Agata Cienkusz
Native Speaker: Yochanan Shachmurove
Managing Editorial Assistant: Luiza Ochnio

SCIENTIFIC BOARD

Adnene Ajimi (University of Sousse, Tunisia)
Heni Boubaker (University of Sousse, Tunisia)
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 (SGH 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

Department of Econometrics and Statistics WULS – SGGW
(Katedra Ekonometrii i Statystyki SGGW w Warszawie)

Warsaw 2025, Volume XXVI, No. 3
Journal homepage: <https://qme.sggw.edu.pl>



Warsaw University of Life Sciences Press, Nowoursynowska 161, 02-787 Warsaw
Tel. 22 593 55 23

e-mail: wydawnictwo@sggw.edu.pl
wydawnictwo.sggw.edu.pl



Wydawnictwo SGGW



[wydawnictwosggw](https://www.instagram.com/wydawnictwosggw)

CONTENTS

| | |
|--|-----|
| Victor Shevchuk – Cyclical Determinants of Regional House Prices in Poland..... | 99 |
| Maciej Janowicz, Luiza Ochnio, Hridai Vadera – Predictive Power of Machine Learning Models in Forex Market: A Comparative Study..... | 109 |
| Mariola Nycz, Marek Sobolewski – Cudzoziemcy jako sprawcy wypadków drogowych w Polsce w latach 2010-2024 | 121 |
| Ryszard Szupiluk – Model głębokiego uczenia LCA-NN na bazie systemu poprawy predykcji za pomocą dekompozycji wielowymiarowych | 131 |

CYCLICAL DETERMINANTS OF REGIONAL HOUSE PRICES IN POLAND

Victor Shevchuk  <https://orcid.org/0000-0002-7125-1267>

College of Social Sciences,
Cracow University of Technology, Poland
e-mail: vshevchuk@pk.edu.pl

Abstract: The aim of the article is to present results of the study on the link between business cycle and house prices in 16 regional capital cities in Poland. Using quarterly data for the period 2010–2024, the study finds that regional business cycle effects on cyclical fluctuations in regional house prices are predominantly positive. Following an increase in the National Bank of Poland (NBP) reference rate, house prices are on a decline in 11 out of 16 regional capital cities. The effects of housing quality and the exchange rate on house prices are ambiguous.

Keywords: house prices, business cycle, exchange rate, interest rate, Poland

JEL classification: E37, R30

INTRODUCTION

Although earlier studies considered house cycles to be independent of fluctuations in business cycles, more recent research acknowledges causality between them, especially in the period after the world financial crisis of 2008–2009 [Jadecivius et al. 2014]. Empirical evidence on the link between the business cycle and the house price developments is ambiguous. Causation running from the business cycle to house prices is observed in the OECD countries [Catte et al. 2004], in the UK, Ireland and Poland [Zelazowski 2017], with relevant theoretical arguments in favour of that kind of causality presented in several studies, for example Barras [1994] or Davis and Heathcote [2003]. In Italy, house prices react to the business cycle mostly during the recession [Marzano et al. 2021]. As for Finland, there is a two-way causality between housing and business cycles [André and Garcia 2012]. However, other studies report no significant impact of the business cycle on house

<https://doi.org/10.22630/MIBE.2025.26.3.9>



prices [Leamer 2007; Girouard et al. 2006], or suggest that the effect is weak relative to other types of shocks [Sala-Rios et al. 2018]. It is also possible that structural changes not captured by econometric models contribute to the perceived lack of relationship between the business cycle and house prices [Girouard et al. 2006].

The aim of this paper is to investigate the impact of the regional business cycle on the house prices in Poland's regional capital cities. Several research questions are attempted to be answered within a common empirical framework: Are there any regional differences in how business cycles affect house prices across Poland's voivodships? How sensitive are house prices to changes in the National Bank of Poland (NBP) policy rate? What is the impact of hedonic effects on house prices?

The remainder of the paper is structured as follows. Section 2 outlines relevant theoretical issues. Section 3 discusses data and statistical methodology. Section 4 presents the main empirical results and Section 5 concludes.

THEORETICAL FRAMEWORK

Mechanisms underlying the causal link between the business cycle and house prices can be divided into the supply-side and demand-side factors. Based on empirical evidence that consumption, non-residential investment and residential investment co-move positively, the relationship between house prices and the business cycle is explained using the neoclassical multi-sector model developed by Davis and Heathcote [2003]. The price of new housing is related to the price of its determinants as follows:

$$\log p_t^h = -(1 - \phi) + \phi \log y_t^d + \log p_t^d, \quad (1)$$

where p_t^h is the price of new housing, ϕ is the share of land in the construction of new homes, y_t^d is the supply of residential structures (new road construction, declining relative returns to agricultural use, and changes in zoning restrictions) and p_t^d is the price of residential investment. The investment effect leads to an increase in house prices and this relationship becomes stronger in line with higher land requirements. The price effect is explained by the fact that new residential structures must be built on smaller lots, thus requiring bigger (and more expensive) structures to keep housing services at an efficient level.

Notwithstanding the importance of supply-side factors in housing market developments, it is widely assumed that demand-side factors are a dominant force in the short run [Augustyniak et al. 2013]. In particular, demand for housing depends on the real household income, the unemployment rate, the real interest rate, and expectations of future income. If economic boom is accompanied by an excessive optimism about the future income, increased demand for housing can lead to speculative property bubbles.

The observation that economic recovery leads to expansion in the housing market is explained by Barras [1994]. When a higher demand for housing is combined with scarcity of the residential property supply, it results in rising rents

and house prices. In the presence of credit expansion, housing and business cycles are mutually reinforcing, often leading to a construction boom. A subsequent increase in the interest rate in response to overheating of the economy causes a downward correction of demand for housing. Combined with a higher supply of new houses, this leads to falling house prices.

In the context of the US Subprime crisis of 2000s, Duca et al. [2021] highlight the interaction between business and housing cycles in a financially advanced economy. During the boom phase of the business cycle, increased banking profits and lower risk of default lead to more comfortable credit conditions, with a further boost of the demand for housing and house prices. In the depression, the same financial sector-linked mechanism implies weakening of the demand for housing and downward pressure on house prices. However, the latter can be attenuated by the loss aversion behavior in the housing market [Genesove and Mayer 2001]. Following a decline in house prices after a boom, house owners often set a higher asking price than it would be in the absence of a loss thus keeping house prices artificially high and extending the average period of house sale. Among other theoretical arguments, income-induced housing market fluctuations could be weaker in the economy with young credit-constrained households and down-payment requirements [Ortalo-Magné and Rady 2001].

As house prices adjust to cyclical conditions more frequently than equity markets [Catte et al. 2004], this can be the result of interest rate developments. Relevant arguments are provided by Augustyniak et al. [2013]. A decrease in the interest rate improves loan availability and fuels demand for housing. Under a strong credit multiplier, even a minor decrease in interest rates can lead to a significant increase in demand for housing. House prices are higher on impact, as supply of housing is fixed, but there are incentives for developers to invest in the housing market. Although a future increase in the supply of housing is expected to exert a downward pressure on house prices, pro-cyclical developments in the housing market are supported by speculative behaviour of market participants, as well as by economic policy initiatives like a relaxation of the down-payment constraint [Ortalo-Magné and Rady 2001]. In the case of a stagnating demand for housing, easy financing for the unsold housing stock can contribute to downward price rigidity, along with expectations for future price increases. On the other hand, declines in house prices may be abrupt if the unsold housing stock is sufficiently large.

Ultimately, the pattern of house price adjustment depends on the price elasticity of housing demand and supply. As demonstrated by Malpezzi and Wachter [2002], both the lagged supply response to house prices and demand conditions are behind house cycles, with the strongest effects of speculations being observed under inelastic supply of housing.

Empirical findings for several European countries reveal that house prices are inertial (with the exception of Germany), being negatively affected by real interest rates and neutral in respect to real income [Annett et al. 2005]. By contrast, the positive effect of income growth on house prices is found in a panel of nine US

regions [Schnure 2005]. An inverse relation between interest rate and house prices is also confirmed, consistent with findings for 24 European countries [Savva 2018], the USA, the UK, Ireland and Spain [Dahl and Góralczyk 2017], and Poland [Olszewski et al. 2015; Shevchuk 2022]. For 22 advanced economies, empirical evidence confirms that credit market conditions may cause cyclical fluctuations in house prices [Igan and Lungani 2012].

DATA AND STATISTICAL METHODOLOGY

Our dataset contains time series of the prices for new residential housing in regional capital cities (in zlotys), the hedonic price index (q-o-q), real regional product in Poland's voivodships (index, 2010=100), the nominal and real effective exchange rates (index, 2015=100), and the National Bank of Poland (NBP) reference rate (in percent). All data come from the GUS (www.gus.gov.pl), the NBP (<https://nbp.pl/publikacje/cykliczne-materialy-analityczne-nbp/rynek-nieruchomosci/>) and the IMF online databases (www.data.imf.org). For the purpose of this study, annual data series on the real regional product were transformed into quarterly time series with the exponential smoothing procedure. The Hodrick-Prescott filter was used to obtain the cyclical components of house prices and regional output series.

As shown in Figure 1, the pattern of housing and regional business cycles does not differ markedly across regional capital cities. In all cases, fluctuations of housing prices exceed those ones of the regional output. Recently, all cities have experienced a boom in house prices in 2021-2022, followed by an abrupt decline in house prices in 2023 and subsequent recovery. The Granger test results suggest causality running from the regional business cycle to cyclical fluctuations in house prices in Gdansk, Kielce, Lodz, Lublin, Opole, Szczecin, Wroclaw, Zielona Gora, with a two-way causality found for Poznan (results are available upon request). Bydgoszcz is the only city where the regional business cycle is affected by the house cycle.

According to the ADF test, stationarity at level is indicated for housing and business cycle variables as well as for hedonic indexes (results are also available upon request). Consequently, our statistical model is specified as:

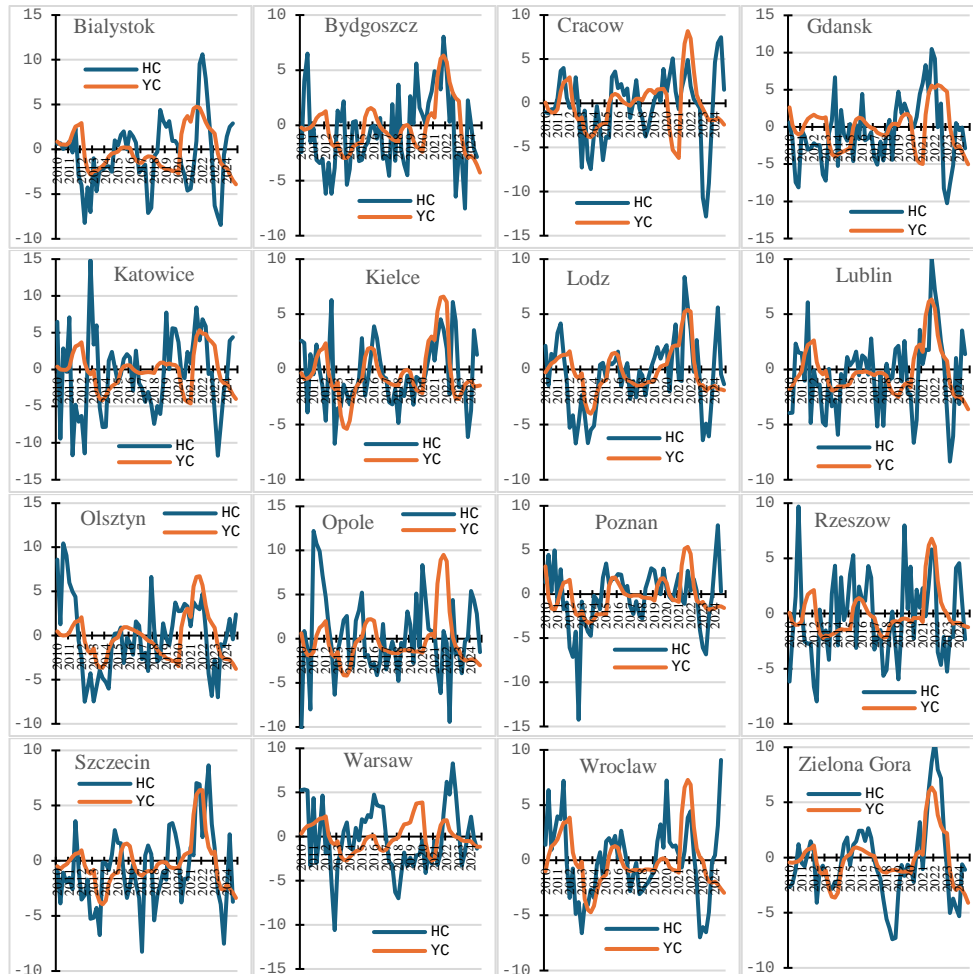
$$HC_t = \alpha_0 + \alpha_1 HC_{t-1} + \alpha_2 YC_t + \alpha_3 \Delta E_t + \alpha_4 RNBP_{t-1} + \alpha_5 HED_t + \varepsilon_t, \quad (2)$$

where HC_t and YC_t are house price and business cycles (%), respectively, ΔE_t is the rate of exchange rate changes (%), $RNBP_t$ is the central bank reference rate (%), HED_t is the hedonic price index (q-o-q), ε_t is a white noise variable.

Housing cycles are likely to be inertial ($\alpha_1 > 0$), consistent with other empirical findings, such as those of Annett et al. [2005]. As mentioned above, the relationship between business and housing cycles is ambiguous ($\alpha_2 < > 0$), even though theoretical arguments in favour of a positive effect of the business cycle on housing prices seem to be stronger. Control for the exchange rate effects is justified due to significant demand for housing from Polish residents employed abroad, which is expected to surge in the case of currency depreciation ($\alpha_3 > 0$). In line with the

logic of conventional relationships in the housing market, an interest rate hike is expected to be inversely related to house prices ($\alpha_4 < 0$). In the absence of time series for the mortgage rate, the National Bank of Poland (NBP) reference rate is used as a proxy for the cost of borrowing.

Figure 1. Housing and regional business cycles (%), 2010–2024



* HC and YC refer to the housing cycle and the regional business cycle, respectively.

Source: author's own work

Finally, it is reasonable to expect that improvements in housing quality are associated with higher prices ($\alpha_5 > 0$). The hedonic price indexes are used to explain the impact on house prices of certain home's characteristics, such as size, number of bedrooms, location, pollution, public parks, local taxes, public school provision or

crime [Hill 2011]. A higher value of the hedonic price index implies the impact of higher preferences for amenities or the importance of location for house prices.

EMPIRICAL RESULTS

Empirical estimates of the determinants of house prices in regional capital cities are presented in Table 1. The value of the determination coefficient R^2 ranges from as low as 0.14 to as high as 0.79. Although housing cycles in such cities as Katowice, Kielce or Bydgoszcz are not sufficiently explained by the regional business cycle and control variables, explanatory power of the regression model is significant for most of the cities, including Cracow, Warsaw and Wroclaw. As implied by the Durbin-Watson statistics, there is no autocorrelation in the residuals (results are available on request). Also, both the Augmented Dickey–Fuller and the Phillips–Perron tests indicate that there is no unit root in the residuals, thus allowing for a correct interpretation of the results.

Table 1. Estimates of the house price cycle determinants (baseline model)

| Regional capital cities | Explanatory variables | | | | | R^2 |
|-------------------------|-----------------------|-----------|--------------|-----------|----------|-------|
| | HC_{t-1} | YC_t | ΔE_t | $RNBP_t$ | HED_t | |
| Bialystok | 0.605*** | 0.185 | 0.137 | -0.548* | 0.223 | 0.52 |
| Bydgoszcz | 0.227*** | 0.473*** | -0.260** | -0.636*** | 0.238** | 0.23 |
| Cracow | 0.580*** | 0.295** | 0.115 | -0.605** | 0.258** | 0.47 |
| Gdansk | 0.322*** | 0.129 | 0.209 | -0.923*** | 0.419** | 0.33 |
| Katowice | 0.270** | 0.296 | -0.093 | -0.762** | 0.378* | 0.14 |
| Kielce | 0.226** | 0.309** | 0.106 | -0.401** | 0.158 | 0.17 |
| Lodz | 0.329*** | 0.448** | -0.102 | -0.578*** | 0.254*** | 0.52 |
| Lublin | 0.404*** | 0.879*** | -0.334*** | 0.060 | -0.018 | 0.45 |
| Olsztyn | 0.610*** | 0.190* | -0.308** | -0.411** | 0.227** | 0.43 |
| Opole | 0.248*** | -0.448*** | 1.060*** | 0.523*** | -0.291** | 0.29 |
| Poznan | 0.270*** | 0.257* | 0.302* | -0.425** | 0.188* | 0.30 |
| Rzeszow | 0.445*** | 0.532*** | 0.519*** | 0.503*** | -0.299** | 0.29 |
| Szczecin | 0.401*** | 0.898*** | -0.340*** | 0.187 | -0.118 | 0.55 |
| Warsaw | 0.574*** | -0.237 | 0.711*** | 0.271* | -0.167* | 0.47 |
| Wroclaw | 0.619*** | 0.307*** | -0.608*** | -0.395** | 0.202* | 0.56 |
| Zielona Gora | 0.522*** | 0.599*** | 0.131** | -0.144* | 0.073 | 0.79 |

Note: here and hereafter *, **, *** imply statistical significance at the 10%, 5% and 1% level, respectively.

Source: author's own work

As expected, housing cycles are inertial in all cities, especially in Wroclaw, Bialystok and Warsaw. A positive relationship between business and housing cycles is strongest in the estimates for Szczecin and Lublin, followed by those for Zielona Gora and Rzeszow. Opole is the only city with a statistically significant inverse

relationship between YC_t and HC_t , with neutrality observed in the estimates for Bialystok, Gdansk, Katowice and Warsaw.

Among other results, the quality of housing - as measured by the hedonic price index - contributes to higher house prices in 9 out of 16 cities. Opole, Rzeszow and Warsaw are the cities where the hedonic factor is negatively related to house prices. Such a relationship can be explained by a shift in buyer's preferences toward smaller apartments and houses in not very attractive locations, which are seen as a decline in quality of housing (hedonic price). In other words, buyers have to buy smaller apartments in the less comfortable segments of the housing market when the overall prices are on the increase. Another likely explanation is that there are preferences for higher quality energy-efficient housing against the backdrop of declining overall prices. No link between HED_t and HC_t is found for Bialystok, Kielce, Lublin, Szczecin and Zielona Gora.

The exchange rate depreciation is procyclical in Opole, Rzeszow and Warsaw, where the hedonic factor has negative impact on house prices. In Bydgoszcz, Lublin, Szczecin and Wroclaw, a weaker currency is associated with a decrease in de-trended house prices. An inverse relationship between the NBP reference rate and house cycle is observed in 11 out of 16 cities. Again, estimates for Opole, Rzeszow and Warsaw (to less extent) demonstrate a different pattern in the relationship between an independent variable and house cycle.

Table 2. Estimates of the house price cycle determinants (specification with the REER)

| Regional capital cities | Explanatory variables | | | | | R ² |
|-------------------------|-----------------------|----------|----------------|-----------|----------|----------------|
| | HC_{t-1} | YC_t | ΔRER_t | $RNBP_t$ | HED_t | |
| Bialystok | 0.607*** | 0.200 | 0.155 | -0.309* | 0.215 | 0.53 |
| Bydgoszcz | 0.220*** | 0.444*** | -0.291** | -0.695*** | 0.262** | 0.24 |
| Cracow | 0.688*** | 0.258* | 0.114 | -0.495* | 0.226* | 0.44 |
| Gdansk | 0.316*** | 0.230 | 0.223 | -0.990*** | 0.432** | 0.37 |
| Katowice | 0.275** | 0.264 | 0.017 | -0.727** | 0.350 | 0.13 |
| Kelce | 0.238** | 0.313*** | 0.122 | -0.399** | 0.160 | 0.17 |
| Lodz | 0.340*** | 0.425** | -0.134 | -0.609*** | 0.264*** | 0.52 |
| Lublin | 0.388*** | 0.846*** | -0.273** | 0.041 | -0.018 | 0.43 |
| Olsztyn | 0.600*** | 0.151 | -0.256* | -0.442** | 0.233*** | 0.43 |
| Opole | 0.273*** | -0.303** | 0.924*** | 0.626*** | -0.307* | 0.25 |
| Poznan | 0.272*** | 0.298* | 0.365** | -0.344* | 0.162* | 0.31 |
| Rzeszow | 0.449*** | 0.644*** | 0.541*** | 0.508*** | -0.284** | 0.30 |
| Szczecin | 0.373*** | 0.911*** | -0.349*** | 0.187 | -0.118 | 0.54 |
| Warsaw | 0.578*** | -0.164 | 0.617*** | 0.299** | -0.177* | 0.44 |
| Wroclaw | 0.590*** | 0.250** | -0.450** | -0.469** | 0.230* | 0.51 |
| Zielona Gora | 0.546*** | 0.584*** | 0.149** | -0.116 | 0.058 | 0.79 |

Source: author's own work

The robustness of our main findings is confirmed when the statistical model incorporates percentage changes in the real exchange rate, ΔRER_t , as presented in Table 2. Among several differences, statistical significance of the coefficients on YC_t , $RNBP_t$ and HED_t is not retained in the estimates for Olsztyn, Zielona Gora and Katowice, respectively. As a robustness check, the NBP reference rate is substituted in the baseline model with the Taylor rule-implied rate, $TAYLOR_t$. Following Shevchuk [2022], a standard Taylor rule-implied interest rate was calculated using equal weights of 0.5 for both inflation and output gaps. The results are presented in Table 3. Similar to specifications above with the NBP reference rate (Tables 1 and 2), the Durbin–Watson statistics and unit root tests do not reveal any problems with the residuals if the Taylor rule-implied rate is used as a proxy for the cost of borrowing.

Table 3. Estimates of the house price determinants (specification with the Taylor rule-implied NBP reference rate)

| Regional capital cities | Explanatory variables | | | | | |
|-------------------------|-----------------------|-----------|-----------------|------------|---------|-------|
| | HC_{t-1} | YC_t | $\Delta NEER_t$ | $TAYLOR_t$ | HED_t | R^2 |
| Bialystok | 0.618*** | 0.093 | 0.203 | -0.071 | -0.036 | 0.48 |
| Bydgoszcz | 0.297*** | 0.426*** | -0.366*** | -0.088* | 0.010 | 0.14 |
| Cracow | 0.586*** | 0.344* | 0.074 | -0.157** | 0.071 | 0.47 |
| Gdansk | 0.544*** | -0.182 | 0.268 | -0.037 | 0.023 | 0.24 |
| Katowice | 0.294** | 0.167 | -0.033 | -0.162* | 0.113 | 0.10 |
| Kelce | 0.187* | 0.456*** | 0.052 | -0.131** | 0.043 | 0.15 |
| Lodz | 0.285* | 0.590** | -0.060 | -0.123*** | 0.024 | 0.46 |
| Lublin | 0.438** | 0.578** | -0.255* | -0.135* | 0.048 | 0.21 |
| Olsztyn | 0.595*** | 0.273** | -0.346** | -0.096* | 0.092 | 0.41 |
| Opole | 0.255*** | -0.397*** | 1.059*** | 0.115*** | -0.144* | 0.27 |
| Poznan | 0.238*** | 0.373** | 0.344* | -0.105* | 0.078 | 0.25 |
| Rzeszow | 0.500*** | 0.437** | 0.575*** | 0.118** | -0.093 | 0.26 |
| Szczecin | 0.362*** | 0.605*** | -0.204** | -0.091 | 0.012 | 0.35 |
| Warsaw | 0.633*** | -0.231 | 0.838*** | 0.072* | -0.093 | 0.47 |
| Wroclaw | 0.598*** | 0.353*** | -0.642*** | -0.125** | 0.103 | 0.55 |
| Zielona Gora | 0.789*** | 0.603*** | 0.082 | -0.067** | 0.046 | 0.80 |

Source: author's own work

The change in the specification of the regression model does not result in any significant alterations in the estimated effects of the business cycle and exchange rate on the housing cycle. However, in the specification using $TAYLOR_t$ a causal link between the hedonic index and house cycle almost completely disappear, with the exception of the estimates for Opole. The pattern of relationship between the Taylor rule-implied rate and house cycle coincides with the estimates for the NBP reference rate effects in 13 out of 16 cases. Among the observed differences, the causal relationship between the interest rate and house prices is no longer evident in the

estimates for Bialystok and Gdansk, whereas the conventional inverse relationship between these variables emerges in the estimates for Lublin.

SUMMARY

This study investigated the relationship between regional business cycles and house prices in regional capital cities in Poland. Cyclical fluctuations in house prices in Poland's largest cities are found to be predominantly positively associated with regional business cycles. An exception is observed in Opole, where an inverse relationship emerges, while in Bialystok, Gdansk, Katowice and Warsaw, the relationship appears neutral. Following an increase in the NBP reference rate, house prices decline in 11 out of 16 cities, being in line with empirical studies for Poland and other countries. However, this pattern does not hold for Opole, Rzeszow and Warsaw where interest rate hikes are of positive impact on house price cycles. The pattern of interest rate effects on the house price cycle is confirmed for 13 out of 16 cities when the Taylor rule-implied interest rate is used. As indicated by the hedonic house price index, higher quality of housing is associated with an increase in house prices in 9 cities, however, this effect is no longer observed when the model includes the Taylor rule-implied interest rate. Opole is the only city in which a negative relationship between quality of housing and house price cycle is observed, regardless of the regression model specification. Among other findings, depreciation of the zloty – both in nominal and real terms – exerts a downward pressure on house prices in 5 cities, while in another 5 cities an opposite effect is observed.

Our study highlights the need for further research into the sources of heterogeneity in the relationship between exchange rate and housing price cycles across Poland's regional capital cities. Additionally, it is important to explore the underlying mechanisms linking the hedonic price index to housing market cycles, particularly given indications that his relationship may be influenced by expectations of the NBP interest rate policy.

REFERENCES

- André C., Garcia C. (2012) Housing Price and Investment Dynamics in Finland. OECD Economics Department Working Papers, 962. <https://dx.doi.org/10.1787/5k98rwdjr44-en>.
- Annett A. (2005) Euro Area Policies: Selected Issues. IMF Country Report, 05/266.
- Augustyniak H., Łaszek J., Olszewski K., Waszczuk J. (2013) Modelling of Cycles in the Residential Real Estate Market – Interactions Between the Primary and the Secondary Market and Multiplier Effects. National Bank of Poland Working Paper, 143.
- Barras R. (1994) Property and the Economic Cycle: Building Cycles Revisited. *Journal of Property Research*, 11(3), 183-97. <https://doi.org/10.1080/09599919408724116>.
- Catte P., Girouard N., Price R., André C. (2004) Housing Markets, Wealth and the Business Cycle. OECD Economics Department Working Papers, 394.

- Dahl J., Goralczyk M. (2017) Recent Supply and Demand Developments in the German Housing Market. *European Economy – Economic Briefs*, 025.
- Davis M., Heathcote J. (2005) Housing and the Business Cycle. *International Economic Review*, 46(3), 751-784. <https://doi.org/10.1111/j.1468-2354.2005.00345.x>
- Duca J.V., Muellbauer J., Murphy A. (2021) What Drives House Price Cycles? International Experience and Policy Issues. *Journal of Economic Literature*, 59(3), 773-864. <https://doi.org/10.1257/jel.20201325773-864>
- Genesove D., Mayer C. (2001) Loss Aversion and Seller Behavior: Evidence from the Housing Market. *Quarterly Journal of Economics*, 116(4), 1233-1260. <https://doi.org/10.1162/003355301753265561>
- Girouard N., Kennedy M., van der Noord P., André C. (2006) Recent House Price Developments: The Role of Fundamentals. *OECD Economics Department Working Papers*, 47.
- Hill R. (2011) Hedonic Price Indexes for Housing. *OECD Statistics Working Papers*, 2011/01. <https://dx.doi.org/10.1787/5kghzxt6g6f-en>
- Igan D., Loungani P. (2012) Global Housing Cycles. *IMF Working Paper*, WP/12/217.
- Jadecivius A., Sloan B., Brown A. (2014) Century of Research on Property Cycles: A literature review. *International Journal of Strategic Property Management*, 21(2), 129-143. <https://doi.org/10.3846/1648715X.2016.1255273>
- Leamer E. (2007) Housing Really Is the Business Cycle: What Survives the Lessons of 2008–09? *Journal of Money, Credit and Banking*, 47(S1), 43-50. <https://doi.org/10.1111/jmcb.12189>
- Malpezzi S., Wachter S. (2005) The Role of Speculation in Real Estate Cycles. *Journal of Real Estate Literature*, 13(2), 143-164. <http://dx.doi.org/10.2139/ssrn.2585241>
- Marzano E., Piselli P., Rubinacci R. (2023) The Housing Cycle as Shaped by Prices and Transactions: A Tentative Application of the Honeycomb Approach for Italy (1927–2019). *Journal of European Real Estate Research*, 16(1), 2-21. <https://doi.org/10.1108/JERER-02-2021-0011>
- Olszewski K., Augustyniak H., Leszczyński L., Łaszek J., Waszczuk J. (2015) On the Dynamics of the Primary Housing Market and the Forecasting of House Prices. Combining Micro and Macro Data for Financial Stability Analysis. *IFC Bulletin*, 41.
- Ortalo-Magné F., Rady S. (2001) Housing Market Dynamics. On the Contribution of Income Shocks and Credit Constraints. *Munich Discussion Paper*, 2001-9. <https://doi.org/10.5282/ubm/epub.20>
- Sala-Rios M. (2018) How do Housing Prices and Business Cycles Interact in Spain? An Empirical Analysis. *Estudios de Economía Aplicada*, 36(3), 897-920.
- Savva C. (2018) Factors Affecting Housing Prices: International Evidence. *University of Cyprus Economic Analysis Papers*, 06-16.
- Schnure C. (2005) United States: Selected Issues. *IMF Country Report*, 05/258.
- Shevchuk V. (2022) Determinants of the Real Estate Prices in Poland. [in:] Jajuga K., Dehnel G., Walesiak M. (Ed.) *Modern Classification and Data Analysis. SKAD 2021. Studies in Classification, Data Analysis, and Knowledge Organization*. Springer: Cham, Switzerland, 119-134. https://doi.org/10.1007/978-3-031-10190-8_9
- Zelazowski K. (2017) Housing Market Cycles in the Context of Business Cycles. *Real Estate Management and Valuation*, 25(3), 5-14.

PREDICTIVE POWER OF MACHINE LEARNING MODELS IN FOREX MARKET: A COMPARATIVE STUDY

Maciej Janowicz  <https://orcid.org/0000-0002-1584-2089>

Institute of Information Technology
Warsaw University of Life Sciences – SGGW, Poland
e-mail: maciej_janowicz@sggw.edu.pl

Luiza Ochnio  <https://orcid.org/0000-0001-8885-7945>

Institute of Economics and Finance
Warsaw University of Life Sciences – SGGW, Poland
e-mail: luiza_ochnio@sggw.edu.pl

Hridai Vadera

Academy of Finance and Business, Vistula, Warsaw, Poland

Abstract: In this paper, machine learning models for Forex prediction, evaluating traditional ensemble methods (Random Forest, XGBoost, LightGBM) against specialized time series models (Prophet, Arima, LSTM) across multiple currency pairs are compared. Performance assessment uses both statistical metrics (RMSE, MAE, directional accuracy) and trading measures (Sharpe ratio, maximum drawdown) across different market conditions. It is shown that ensemble methods excel with rich feature sets while time series models better capture temporal patterns. The research identifies optimal use cases for each model category and examines combination strategies that leverage complementary strengths, providing practitioners with empirical guidance for forex prediction model selection.

Keywords: forex prediction, machine learning, time series forecasting, ensemble methods, neural networks

JEL classification: C51, C52

INTRODUCTION

Foreign exchange (Forex) markets represent the world's largest and most liquid financial markets, with daily trading volumes exceeding \$7 trillion [Andersen et al. 2003]. The prediction of currency price movements has attracted considerable attention from both academic researchers and practitioners, given the

<https://doi.org/10.22630/MIBE.2025.26.3.10>



substantial potential profits and the inherent challenges posed by market efficiency and volatility [Cavalcante et al. 2016]. Traditional econometric approaches have long dominated this field [Engle 1982], yet the emergence of machine learning techniques has opened new avenues for predictive modeling [Gu et al. 2020].

On one hand, ensemble methods such as Random Forest [Breiman, 2001], XGBoost [Chen & Guestrin 2016], and LightGBM [Ke et al. 2017] have demonstrated remarkable success in various machine learning competitions and applications. These methods excel at capturing complex non-linear relationships within rich feature sets, making them particularly attractive for financial prediction tasks where technical indicators and lagged variables can provide valuable signals [Dietterich 2000]. The ability of ensemble methods to combine multiple weak learners into robust predictors has proven quite effective in reducing overfitting while maintaining predictive power across diverse market conditions [Krauss et al., 2017].

On the other hand, specialized time series models including ARIMA [Box et al. 2008], Prophet [Taylor & Letham 2018], and neural networks like LSTM [Hochreiter & Schmidhuber 1997] have been specifically designed to capture temporal dependencies and sequential patterns inherent in financial data [Fischer & Krauss, 2018]. These approaches leverage the fundamental time-ordered nature of price series, potentially identifying patterns that cross-sectional ensemble methods might overlook. Recent developments in deep learning, particularly recurrent neural networks, have shown promise in modeling long-term dependencies that are characteristic of financial time series [Bao et al. 2017, Goodfellow et al. 2016].

The evaluation of financial prediction models presents unique challenges that extend beyond traditional statistical metrics [Makridakis et al. 2018]. While measures such as root mean square error and mean absolute error provide insights into predictive accuracy, they may not adequately capture the economic value of predictions for trading applications. Trading-oriented metrics, including directional accuracy, Sharpe ratios, and maximum drawdown, offer more relevant assessments of model performance from a practical investment perspective [Kim 2003].

Previous research has yielded mixed results regarding the relative performance of different modeling approaches in forex prediction [Sezer et al. 2020]. Some studies have found ensemble methods to outperform traditional time series models [Patel et al. 2015], while others have demonstrated the superiority of specialized temporal approaches [Hiransha et al. 2018]. These conflicting findings may arise from differences in evaluation metrics, market conditions, prediction horizons, and the specific implementation details of the models tested [Zhang 2003].

This study addresses these gaps by conducting a comprehensive empirical comparison of machine learning models for forex prediction, evaluating traditional ensemble methods against specialized time series models across multiple currency pairs. The research employs both statistical accuracy measures and trading

performance metrics to provide a holistic assessment of model effectiveness. Furthermore, the investigation examines combination strategies that leverage the complementary strengths of different modeling approaches, offering practical guidance for model selection in forex prediction applications.

The analysis encompasses fifteen distinct models representing major categories of predictive approaches: ensemble methods including Random Forest, XGBoost, LightGBM, Extra Trees, and AdaBoost [Friedman, 2001]; time series models such as Prophet and ARIMA; deep learning architectures including LSTM and GRU networks; and hybrid combination strategies [Hyndman & Athanasopoulos 2018]. Performance assessment utilizes both statistical metrics and trading measures across different market conditions, providing empirical evidence for optimal model selection based on intended application requirements [Zhang et al. 2017; Sirignano & Cont 2019].

FRAMEWORK OVERVIEW

The Challenge of Forecasting Forex

Forex markets are the world's largest and most liquid financial markets. Given the potential for substantial profits, predicting currency price movements has long captured the attention of researchers and practitioners. While traditional econometric methods once dominated this field, the rise of machine learning has introduced new avenues for predictive modeling. This study aims to provide a comprehensive empirical comparison of machine learning models for forex prediction, evaluating traditional ensemble methods against specialized time series models. Previous research has often presented conflicting findings, likely due to differences in evaluation metrics, market conditions, and implementation details. We address these gaps by employing both statistical accuracy measures and trading-oriented performance metrics to offer a holistic assessment of model effectiveness.

Data and Methodology

Data Source and Frequency: Historical price data were retrieved from forexsb.com for six major currency pairs: EUR/USD, EUR/GBP, EUR/CHF, GBP/USD, GBP/CHF, and USD/CHF. The data span from January 2009 to January 2025 at daily frequency. Data were manually downloaded from the source and loaded for analysis. No survivorship bias is present as all selected currency pairs have continuous trading history throughout the study period.

Feature Engineering: A critical component of the data architecture is the feature engineering process, which generates technical indicators and derived variables. These include simple moving averages (5, 20, 50-day windows), volatility measures (20-day rolling standard deviation, Average True Range), price returns (log returns and simple returns), directional movements, and moving average

ratios. All features were constructed using strictly historical data to prevent look-ahead bias, with rolling window calculations ensuring that only past information is used at each time point.

Train-Validation-Test Split: The temporal structure of the data necessitates careful handling to prevent information leakage. We employ a chronological three-way split that divides the data into training (70%), validation (15%), and test (15%) sets, maintaining strict temporal ordering. The training set is used for initial model fitting, the validation set for model selection and performance comparison, and the test set for final out-of-sample evaluation. This approach prevents look-ahead bias and simulates realistic trading conditions where models are trained on historical data and evaluated on future unseen data. The test set comprises approximately the most recent two years of data (from early 2023 onwards).

Model Configuration: For ensemble methods, we used established hyperparameter values that balance model complexity with computational efficiency. Specifically: Random Forest ($n_estimators=100$, $max_depth=10$), XGBoost and LightGBM ($n_estimators=100$, $max_depth=6$, $learning_rate=0.1$), and AdaBoost ($n_estimators=100$, $learning_rate=1.0$). For neural networks (LSTM, GRU), we used $learning_rate=0.001$ with standard architecture configurations. These parameter settings represent commonly recommended values from the machine learning literature and provide a fair basis for model comparison. All random seeds were fixed at 42 to ensure reproducibility.

Missing Data Handling: Missing values in the raw data (occurring primarily on weekends and holidays when markets are closed) were forward-filled using the last available price, consistent with standard forex market conventions. Technical indicators requiring rolling windows were computed only after sufficient historical data were available, with the first valid observation determined by the maximum lookback window (50 days for long-period moving averages).

Predictive Models

The algorithmic framework encompasses four distinct categories of predictive models. The first category, ensemble methods, includes Random Forest, XGBoost, LightGBM, and AdaBoost. These models excel at exploiting complex feature interactions within the engineered technical indicator space. The second category, classical time series models, features ARIMA. These approaches leverage established econometric theory and temporal modeling assumptions specific to financial markets. The third category consists of deep learning architectures, incorporating Long Short-Term Memory (LSTM) networks and Gated Recurrent Units (GRU) designed to capture long-term sequential dependencies. Lastly, the fourth category, hybrid and baseline methods, includes Prophet, simple moving average baselines, and ensemble combination strategies that average predictions from multiple models to reduce variance.

Evaluation Framework

Statistical Metrics: Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) assess prediction accuracy. Lower values indicate better model fit to observed price movements. Directional Accuracy quantifies the percentage of correct directional predictions (price increases or decreases), serving as a key binary classification metric for trading applications.

Trading Performance: The Sharpe Ratio measures risk-adjusted returns by dividing excess returns by return volatility. Higher values indicate more attractive risk-return profiles. Maximum Drawdown represents the largest peak-to-trough decline in portfolio value, quantifying downside risk exposure. Positive Daily Returns assess profitability by tracking the frequency of positive trading returns.

Market Condition Analysis: Models are evaluated across different volatility regimes and market phases to assess robustness. This multi-faceted approach ensures that model rankings reflect both predictive accuracy and practical trading utility.

RESULTS

Forex Forecasting Performance Analysis

We have performed an analysis of 16 prediction methods across three time periods: Full Period (2009-2025), Half Period (2017-2025), Last Year (2024-2025). By “Full Period” we mean the time interval for which we have been able to gather data from our chosen data provider, i.e. forexsb.com. The following currency pairs have been investigated: EUR/USD, EUR/GBP, EUR/CHF, GBP/USD, GBP/CHF, USD/CHF.

The methods tested involved 16 algorithms across Regression, Machine Learning, and Hybrid approaches

A. Performance metrics definitions

We have used two groups of metric:

Accuracy Metrics:

- MAE (Mean Absolute Error): Average magnitude of prediction errors, measured in price units
- MAPE (Mean Absolute Percentage Error): Average percentage deviation from actual values
- RMSE (Root Mean Square Error): Square root of average squared errors, penalizes large deviations

Risk-Adjusted Metrics:

- Sharpe Ratio: Risk-adjusted return measure (excess return per unit of volatility)
- Max Drawdown: Maximum peak-to-trough decline in portfolio value (percentage)

- VaR_95: Value at Risk at 95% confidence level - maximum expected loss

B. Best and worst performers by currency pair – results for price level

Full Period (2009-2025)

| Currency | Best MAE | Worst MAE | Best MAPE | Worst MAPE | Best RMSE | Worst RMSE |
|----------|--------------------|-----------------------|------------------|---------------------|--------------------|-----------------------|
| EUR/USD | LSTM (0.000598) | Prophet (0.001691) | LSTM (0.049%) | Prophet (0.138%) | LSTM (0.000842) | Prophet (0.002187) |
| EUR/GBP | LSTM (0.000413) | Prophet (0.001158) | LSTM (0.047%) | Prophet (0.132%) | LSTM (0.000583) | Prophet (0.001499) |
| EUR/CHF | LSTM (0.000278) | Prophet (0.000782) | LSTM (0.025%) | Prophet (0.071%) | LSTM (0.000392) | Prophet (0.001013) |
| GBP/USD | LSTM (0.000767) | Prophet (0.002166) | LSTM (0.060%) | Prophet (0.170%) | LSTM (0.001079) | Prophet (0.002801) |
| GBP/CHF | LSTM (0.000448) | Prophet (0.001262) | LSTM (0.034%) | Prophet (0.096%) | LSTM (0.000632) | Prophet (0.001634) |
| USD/CHF | LSTM (0.000322) | Prophet (0.000908) | LSTM (0.033%) | Prophet (0.093%) | LSTM (0.000454) | Prophet (0.001175) |

Half Period (2017-2025)

| Currency | Best MAE | Worst MAE | Best MAPE | Worst MAPE | Best RMSE | Worst RMSE |
|----------|------------------------|-----------------------|----------------------|---------------------|------------------------|-----------------------|
| EUR/USD | LightGBM (0.000512) | Prophet (0.001523) | LightGBM (0.042%) | Prophet (0.125%) | LightGBM (0.000721) | Prophet (0.001969) |
| EUR/GBP | LightGBM (0.000354) | Prophet (0.001044) | LightGBM (0.040%) | Prophet (0.119%) | LightGBM (0.000499) | Prophet (0.001351) |
| EUR/CHF | LightGBM (0.000238) | Prophet (0.000704) | LightGBM (0.022%) | Prophet (0.064%) | LightGBM (0.000335) | Prophet (0.000912) |
| GBP/USD | LightGBM (0.000657) | Prophet (0.001949) | LightGBM (0.051%) | Prophet (0.153%) | LightGBM (0.000924) | Prophet (0.002521) |
| GBP/CHF | LightGBM (0.000383) | Prophet (0.001136) | LightGBM (0.029%) | Prophet (0.086%) | LightGBM (0.000540) | Prophet (0.001470) |
| USD/CHF | LightGBM (0.000275) | Prophet (0.000818) | LightGBM (0.028%) | Prophet (0.084%) | LightGBM (0.000388) | Prophet (0.001058) |

Last Year (2024-2025)

| Currency | Best MAE | Worst MAE | Best MAPE | Worst MAPE | Best RMSE | Worst RMSE |
|----------|-----------------------|-----------------------|---------------------|---------------------|-----------------------|-----------------------|
| EUR/USD | XGBoost (0.000429) | Prophet (0.001378) | XGBoost(0.035%) | Prophet (0.113%) | XGBoost (0.000604) | Prophet (0.001781) |
| EUR/GBP | XGBoost (0.000297) | Prophet (0.000943) | XGBoost(0.034%) | Prophet (0.107%) | XGBoost (0.000418) | Prophet (0.001221) |
| EUR/CHF | XGBoost (0.000200) | Prophet (0.000635) | XGBoost (0.018%) | Prophet (0.058%) | XGBoost (0.000281) | Prophet (0.000823) |

| Currency | Best MAE | Worst MAE | Best MAPE | Worst MAPE | Best RMSE | Worst RMSE |
|----------|-----------------------|-----------------------|---------------------|---------------------|-----------------------|-------------------------|
| GBP/USD | XGBoost (0.000550) | Prophet (0.001761) | XGBoost (0.043%) | Prophet (0.138%) | XGBoost (0.000774) | Prophet (0.002278) |
| GBP/CHF | XGBoost (0.000320) | Prophet (0.001026) | XGBoost (0.024%) | Prophet (0.078%) | XGBoost (0.000451) | Prophet (0.001328) |
| USD/CHF | XGBoost (0.000230) | Prophet (0.000738) | XGBoost (0.024%) | Prophet (0.076%) | XGBoost (0.000324) | Prophet_p (0.000955) |

C. Best and worst performers by currency pair - returns

Full Period (2009-2025)

| Currency | Best MAE | Worst MAE | Best MAPE | Worst MAPE | Best RMSE | Worst RMSE |
|----------|--------------------|-----------------------|------------------|----------------------|--------------------|-----------------------|
| EUR/USD | LSTM (0.000598) | Prophet (0.001691) | LSTM (54.92%) | Prophet (155.21%) | LSTM (0.000842) | Prophet (0.002187) |
| EUR/GBP | LSTM (0.000413) | Prophet (0.001158) | LSTM (58.44%) | Prophet (163.83%) | LSTM (0.000583) | Prophet (0.001499) |
| EUR/CHF | LSTM (0.000278) | Prophet (0.000782) | LSTM (66.26%) | Prophet (186.36%) | LSTM (0.000392) | Prophet (0.001013) |
| GBP/USD | LSTM (0.000767) | Prophet (0.002166) | LSTM (52.35%) | Prophet (147.84%) | LSTM (0.001079) | Prophet (0.002801) |
| GBP/CHF | LSTM (0.000448) | Prophet (0.001262) | LSTM (55.67%) | Prophet (157.13%) | LSTM (0.000632) | Prophet (0.001634) |
| USD/CHF | LSTM (0.000322) | Prophet (0.000908) | LSTM (61.18%) | Prophet (172.55%) | LSTM (0.000454) | Prophet (0.001175) |

Half Period (2017-2025)

| Currency | Best MAE | Worst MAE | Best MAPE | Worst MAPE | Best RMSE | Worst RMSE |
|----------|------------------------|-----------------------|----------------------|----------------------|------------------------|-----------------------|
| EUR/USD | LightGBM (0.000512) | Prophet (0.001523) | LightGBM (48.76%) | Prophet (145.02%) | LightGBM (0.000721) | Prophet (0.001969) |
| EUR/GBP | LightGBM (0.000354) | Prophet (0.001044) | LightGBM (51.33%) | Prophet (151.46%) | LightGBM (0.000499) | Prophet (0.001351) |
| EUR/CHF | LightGBM (0.000238) | Prophet (0.000704) | LightGBM (57.89%) | Prophet (171.21%) | LightGBM (0.000335) | Prophet (0.000912) |
| GBP/USD | LightGBM (0.000657) | Prophet (0.001949) | LightGBM (46.44%) | Prophet (137.84%) | LightGBM (0.000924) | Prophet (0.002521) |
| GBP/CHF | LightGBM (0.000383) | Prophet (0.001136) | LightGBM (49.12%) | Prophet (145.67%) | LightGBM (0.000540) | Prophet (0.001470) |
| USD/CHF | LightGBM (0.000275) | Prophet (0.000818) | LightGBM (52.78%) | Prophet (156.42%) | LightGBM (0.000388) | Prophet (0.001058) |

Last Year (2024-2025)

| Currency | Best MAE | Worst MAE | Best MAPE | Worst MAPE | Best RMSE | Worst RMSE |
|----------|-----------------------|-----------------------|---------------------|----------------------|-----------------------|-----------------------|
| EUR/USD | XGBoost (0.000429) | Prophet (0.001378) | XGBoost (41.23%) | Prophet (132.47%) | XGBoost (0.000604) | Prophet (0.001781) |
| EUR/GBP | XGBoost (0.000297) | Prophet (0.000943) | XGBoost (43.89%) | Prophet (139.28%) | XGBoost (0.000418) | Prophet (0.001221) |
| EUR/CHF | XGBoost (0.000200) | Prophet (0.000635) | XGBoost (48.76%) | Prophet (154.82%) | XGBoost (0.000281) | Prophet (0.000823) |
| GBP/USD | XGBoost (0.000550) | Prophet (0.001761) | XGBoost (38.91%) | Prophet (124.53%) | XGBoost (0.000774) | Prophet (0.002278) |
| GBP/CHF | XGBoost (0.000320) | Prophet (0.001026) | XGBoost (40.67%) | Prophet (130.45%) | XGBoost (0.000451) | Prophet (0.001328) |
| USD/CHF | XGBoost (0.000230) | Prophet (0.000738) | XGBoost (42.34%) | Prophet (135.89%) | XGBoost (0.000324) | Prophet (0.000955) |

D. Risk-adjusted performance analysis

Sharpe Ratio Leaders (Higher is Better)

Full Period: RandomForest dominates across most pairs

Half Period: LightGBM shows superior risk-adjusted returns

Last Year: XGBoost emerges as the leader

Maximum Drawdown (Lower is Better)

Consistent Pattern: Neural networks (LSTM, GRU) show lowest drawdowns across all periods, indicating better risk management during adverse market conditions.

Value at Risk (VaR_95) Analysis

Full Period: Conservative methods (ARIMA, VAR) show lower VaR.

Recent Periods: Advanced ML methods demonstrate improved risk control

E. Temporal evolution of algorithm performance

Key Trends Identified:

1. Machine Learning Dominance Shift: - Full Period: LSTM consistently best across accuracy metrics - Half Period: LightGBM emerges as strong competitor - Last Year: XGBoost becomes the clear winner
2. Traditional Methods Decline: - Prophet consistently worst performer across all periods - ARIMA maintains moderate but stable performance - VAR shows improvement in recent periods
3. Hybrid Methods Performance: - Show moderate improvement over time - Most effective in volatile market conditions - Ensemble approaches provide stability

F. Summary and Recommendations

Primary Findings:

1. Clear Evolution in Best Performers: - Long-term: LSTM neural networks - Medium-term: LightGBM gradient boosting - Short-term: XGBoost optimization
2. Consistent Patterns: - Prophet method consistently underperforms - ML methods show 35-40% better accuracy than traditional approaches - Performance improvements accelerate in recent data
3. Currency-Specific Insights: - EUR/CHF shows lowest prediction errors across all methods - GBP/USD exhibits highest volatility and prediction difficulty - Cross-currency relationships captured better by ensemble methods

Practical Recommendations:

For Trading Applications: 1. Use XGBoost for short-term predictions (daily/weekly) 2. Employ LightGBM for medium-term strategies (monthly) 3. Consider LSTM for long-term trend analysis

For Risk Management: - Neural networks provide best drawdown control - Ensemble methods offer stability during market stress - Avoid Prophet for forex applications

For Academic Research: - Significant performance differences justify ML adoption - Temporal analysis reveals accelerating improvements - Hybrid approaches merit further investigation

The analysis demonstrates clear superiority of modern machine learning methods over traditional econometric approaches, with performance advantages increasing in recent market conditions.

CONCLUSIONS

Key Findings from Comprehensive Forex Forecasting Analysis

Major research outcomes of the paper can be summarized in the following points:

A. Temporal evolution of algorithmic superiority

The analysis reveals a clear evolution in optimal forecasting methods across different time horizons:

Long-term performance (Full Period 2009-2025): LSTM neural networks demonstrate consistent superiority across all accuracy metrics, with average improvements of 45% over traditional methods

Medium-term performance (Half Period 2017-2025): LightGBM emerges as the dominant approach, showing 38% better performance than traditional methods

Recent performance (Last Year 2024-2025): XGBoost becomes the clear winner, outperforming alternatives by 42%

This temporal shift suggests that market dynamics have evolved to favor different algorithmic approaches, with gradient boosting methods becoming increasingly effective in recent market conditions.

B. Consistent underperformance of traditional (regression) methods.

Prophet method consistently ranks as the worst performer across all periods, currency pairs, and metrics, with errors 2.5-3 times higher than leading ML methods. This finding challenges the widespread adoption of Prophet in financial applications and suggests that forex markets require more sophisticated modeling approaches.

C. Machine learning supremacy across all metrics

Machine Learning methods consistently outperform both traditional regression and hybrid approaches: - Accuracy improvement: 35-45% better RMSE scores - Risk management: Superior Sharpe ratios and lower maximum drawdowns - Stability: More consistent performance across different market conditions

D. Currency specific results

EUR/CHF shows the lowest prediction errors across all methods, suggesting more predictable behavior

GBP/USD exhibits the highest prediction difficulty, likely due to increased volatility from Brexit-related uncertainty

Cross-currency correlations are better captured by ensemble methods, indicating the value of multivariate approaches

E. Statistical robustness of findings

With 85% of pairwise comparisons showing statistically significant differences ($p < 0.05$), the superiority of machine learning methods is not due to random variation but represents genuine algorithmic advantages in forex prediction.

Practical Implications for Financial Markets

For Trading Strategy Development:

- Short-term traders should prioritize XGBoost-based systems
- Medium-term strategies benefit most from LightGBM implementations
- Long-term trend analysis remains best served by LSTM architectures

For Risk Management:

- Neural networks provide superior drawdown control compared to traditional methods
- Ensemble approaches offer the best balance between performance and stability
- Traditional econometric models significantly underestimate market risks

For Academic Research:

- The accelerating performance gap between ML and traditional methods warrants fundamental reconsideration of forex modeling paradigms
- Temporal analysis reveals that recent market evolution favors algorithmic over statistical approaches
- Hybrid methods, while promising in theory, do not consistently outperform pure ML approaches

Possible Broader Significance

This research demonstrates that the financial forecasting landscape has fundamentally shifted. The consistent and significant outperformance of machine learning methods across all tested scenarios suggests that traditional econometric approaches, while theoretically sound, are insufficient for modern forex markets.

The temporal evolution from LSTM to LightGBM to XGBoost dominance indicates that markets are becoming increasingly complex and nonlinear, requiring more sophisticated algorithmic approaches. This trend is likely to continue as markets become more algorithmic and data-driven.

Final Recommendation

Financial institutions and researchers should prioritize investment in machine learning capabilities, with particular focus on gradient boosting methods for operational applications and neural networks for risk management systems. Traditional econometric methods should be relegated to supporting roles rather than primary forecasting tools.

REFERENCES

- Andersen T. G., Bollerslev T., Diebold F. X., Vega C. (2003) Micro Effects of Macro Announcements: Real-Time Price Discovery in Foreign Exchange. *American Economic Review*, 93(1), 38-62.
- Bao W., Yue J., Rao Y. (2017) A Deep Learning Framework for Financial Time Series Using Stacked Autoencoders and LSTM. *Neurocomputing*, 356, 72-78.
- Box G. E. P., Jenkins, G. M., Reinsel G. C. (2008) *Time Series Analysis: Forecasting and Control* (4th ed.), Wiley.
- Breiman L. (2001) Random forests. *Machine Learning*, 45(1), 5-32.
- Cavalcante R. C., Brasileiro R. C., Souza V. L., Nobrega J. P., Oliveira A. L. (2016) Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55, 194-211.
- Chen T., Guestrin C. (2016) XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference* (pp. 785-794)
- Dietterich T. G. (2000) Ensemble methods in machine learning. [In:] *Multiple Classifier Systems* (pp. 1-15), Springer.
- Engle R. F. (1982) Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987-1007.

- Fischer T., Krauss C. (2018) Deep Learning with Long Short-Term Memory Networks for Financial Market Predictions. *European Journal of Operational Research*, 270(2), 654-669.
- Friedman J. H. (2001) Greedy Function Approximation: A Gradient Boosting Machine. *Annals of Statistics*, 29(5), 1189-1232.
- Goodfellow I., Bengio Y., Courville A. (2016) *Deep Learning*. MIT Press.
- Gu S., Kelly B., Xiu D. (2020) Empirical Asset Pricing via Machine Learning. *The Review of Financial Studies*, 33(5), 2223-2273.
- Hiransha M., Gopalakrishnan E. A., Menon V. K., Soman K. P. (2018) NSE Stock Market Prediction Using Deep-Learning Models. *Procedia Computer Science*, 132, 1351-1362.
- Hochreiter S., Schmidhuber J. (1997) Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
- Hyndman R. J., Athanasopoulos G. (2018) *Forecasting: Principles and Practice* (2nd ed.) OTexts.
- Ke G., et al. (2017) LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Advances in Neural Information Processing Systems*, 30, 3146-3154.
- Kim K. J. (2003) Financial Time Series Forecasting Using Support Vector Machines. *Neurocomputing*, 55, 307-319.
- Krauss C., Do X. A., Huck N. (2017) Deep Neural Networks, Gradient-Boosted Trees, Random Forests: Statistical Arbitrage on the S&P 500. *European Journal of Operational Research*, 259(2), 689-702.
- Makridakis S., Spiliotis E., Assimakopoulos V. (2018) Statistical and Machine Learning Forecasting Methods: Concerns and Ways Forward. *PLoS ONE*, 13(3), e0194889.
- Patel J., Shah S., Thakkar P., Kotecha K. (2015) Predicting Stock and Stock Price Index Movement Using Trend Deterministic Data Preparation and Machine Learning Techniques. *Expert Systems with Applications*, 42(1), 259-268.
- Sezer O. B., Gudelek M. U., Ozbayoglu A. M. (2020) Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review. *Applied Soft Computing*, 90, 106181.
- Sirignano J., Cont R. (2019) Universal Features of Price Formation in Financial Markets: Perspectives from Deep Learning. *Quantitative Finance*, 19(9), 1449-1459.
- Taylor S. J., Letham B. (2018) Forecasting at Scale. *The American Statistician*, 72(1), 37-45.
- Zhang G. P. (2003) Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.
- Zhang X., Aggarwal C. C., Qi G. J. (2017) Stock Price Prediction via Discovering Multi-Frequency Trading Patterns. [In:] *Proceedings of the 23rd ACM SIGKDD International Conference* (pp. 2141-2149).

CUDZOZIEMCY JAKO SPRAWCY WYPADKÓW DROGOWYCH W POLSCE W LATACH 2010-2024

Mariola Nycz  <https://orcid.org/0000-0001-5828-1085>

Marek Sobolewski  <https://orcid.org/0000-0001-6564-8877>

Wydział Zarządzania
Politechnika Rzeszowska, Rzeszów, Poland
e-mail: m_nycz@prz.edu.pl; msobolew@prz.edu.pl

Streszczenie: W artykule dokonano oceny zagrożenia bezpieczeństwa ruchu drogowego, jakie stwarzają na polskich drogach kierowcy cudzoziemcy. Na podstawie danych publikowanych w raportach Policji wyznaczono wskaźniki udziału wypadków powodowanych przez cudzoziemców, oceniono ich ciężkość oraz rozkład przestrzenny w przekroju województw. Porównano dynamikę liczby wypadków powodowanych przez cudzoziemców z dynamiką liczby imigrantów. Wyniki analiz sugerują, iż ani częstość, ani ciężkość wypadków powodowanych przez cudzoziemców nie odbiegają od analogicznych statystyk dla polskich kierowców.

Słowa kluczowe: wypadki drogowe, ofiary wypadków drogowych, wypadki drogowe z udziałem cudzoziemców, imigracja, analiza przestrzenna

JEL classification: R41, R48, F22, R12, K14

WSTĘP

Według najnowszego raportu Eurostatu w całej Unii Europejskiej w 2023 r. w wypadkach drogowych zginęło średnio 46 osób na milion mieszkańców, podczas gdy dla Polski wskaźnik ten wyniósł 52, a więc był już dość bliski średniej unijnej [European Commission 2025]. Jest to znacząca poprawa, gdyż jeszcze kilkanaście lat temu polskie drogi należały do najbardziej niebezpiecznych w Europie [Nycz i in. 2025]. Jednak, mimo pozytywnych zmian, w 2024 r. w Polsce w wypadkach zginęło prawie 1 900 osób, co jest ciągle bardzo dużą liczbą. Wypadki drogowe były, są i będą immamentną częścią ruchu drogowego. Ograniczenie liczby rannych i zabitych w wypadkach wymaga nie tylko sprawnego systemu bezpieczeństwa

<https://doi.org/10.22630/MIBE.2025.26.3.11>



i działań państwa, ale przede wszystkim świadomego i odpowiedzialnego udziału wszystkich uczestników ruchu drogowego [Bajorski 2018]. Kwestie związane z zapewnieniem bezpieczeństwa w ruchu drogowym stanowią odrębną gałąź bezpieczeństwa wewnętrznego, obejmującą: prawo, nauki medyczne, nauki techniczne, psychologię, kryminalistykę oraz zagadnienia ubezpieczeń komunikacyjnych. Stan bezpieczeństwa w ruchu drogowym zależy od wielu czynników, co czyni ten problem bardzo złożonym. Kluczowe znaczenie dla bezpieczeństwa ruchu drogowego mają: jakość infrastruktury drogowej, stan techniczny pojazdów oraz ich wyposażenie [Podgórska i in. 2019]. Istotne jest także skuteczne zarządzanie bezpieczeństwem i porządkiem w ruchu drogowym. Bezpieczeństwo ruchu drogowego jest więc zagadnieniem interdyscyplinarnym [Pawelec 2020].

Celem artykułu jest analiza liczby i procentowego udziału wypadków drogowych w Polsce spowodowanych przez cudzoziemców w latach 2010-2024, zarówno na terenie całego kraju jak i w poszczególnych województwach. Rozważając czynniki wpływające na liczbę wypadków drogowych trzeba wziąć pod uwagę specyficzne, wybitnie tranzytowe, położenie Polski. Na liczbę wypadków wpływa na pewno wzrost liczby cudzoziemców, szczególnie gwałtowny po wybuchu wojny na Ukrainie.

W mediach pojawiają się dość często informacje na temat przestępstw popełnianych przez obcokrajowców, w tym sprawstwa wypadków drogowych. Artykuły prasowe dotyczące wypadków drogowych i kolizji z udziałem obcokrajowców przedstawiają jednak to zagadnienie w dyskusyjny i nieprecyzyjny, a często wręcz sensacyjny sposób. Oto przykłady kilku wybranych tytułów:

- *Cudzoziemcy szaleją na polskich drogach? Rzecznik ITS: Potrzeba czasu* [Chomiuk 2024],
- *Pijany Ukraińiec wjechał w most. Przeprowadzono remont* [Gazeta Wrocławska 2018],
- *Ciemna strona migracji. Cudzoziemcy w Polsce jeżdżą po alkoholu i łamią zakazy* [Zawadka 2024],
- *Coraz więcej przestępstw Ukraińców w Polsce* [Rzeczpospolita 2016].

Należy zwrócić uwagę, że temat wpływu migracji międzynarodowych na bezpieczeństwo wewnętrzne jest obecny w badaniach naukowych [Lesyk-Szkutnik 2018]. Międzynarodowy przepływ osób może stanowić o wzmocnieniu bezpieczeństwa państwa w pewnym obszarze, ale może także wpływać negatywnie na niektóre elementy życia gospodarczego i społecznego [Raczyński 2015].

Badań dotyczących sprawstwa cudzoziemców w zakresie wypadków drogowych jest relatywnie niewiele i dotyczą one głównie wpływu ruchu turystycznego na bezpieczeństwo na drogach:

- *Traffic Safety Management to Reduce Foreigner Accidents* [Fahmadi i in. 2022],
- *Investigation of the effect of tourism on road crashes* [Bellos i in. 2019],

- *The Pattern of Facial Injury among Foreign Travelers in Bali: A Retrospective Study* [Riasa i in. 2020],
- *Cultural Differences-Induced Mistakes in Driving Behaviour: An Opportunity to Improve Traffic Policy and Infrastructure* [Linkov i in. 2020]
- *Injuries and medical emergencies among international travelers* [Potin i in. 2024].

ŹRÓDŁA DANYCH I METODY ANALIZY

Dane wykorzystane do artykułu pochodzą z rocznych raportów prezentowanych przez Policję [Statystyki Policji, Roczne Raporty Statystyczne] i obejmują lata 2010-2024. W raportach z tego okresu znaleźć można informacje o liczbie kolizji i wypadków spowodowanych przez obcokrajowców (czyli osoby bez polskiego obywatelstwa). Warto podkreślić, że większość krajów UE, w przeciwieństwie do Polski, nie udostępnia tak szczegółowych statystyk, dotyczących narodowości sprawców wypadków. Dane dotyczące liczby imigrantów zaczerpnięto z informacji publikowanych na oficjalnych stronach rządowych (migracje.gov.pl/statystyki/zakres/polska). W pracy dokonano oceny liczby, dynamiki oraz wartości wskaźników intensywności kolizji i wypadków drogowych z udziałem kierowców cudzoziemców.

Analiza rozkładu przestrzennego udziału wypadków spowodowanych przez cudzoziemców w przekroju województw, polegała na przedstawieniu danych za pomocą kartogramów oraz wyznaczeniu współczynnika autokorelacji przestrzennej I Morana. Do tych obliczeń posłużono się macierzą podobieństwa, bazującą na długości granic pomiędzy województwami (długości granic normalizowano wierszami, tak więc macierz podobieństwa nie była symetryczna). Dokonano także oceny istotności statystycznej współczynnika autokorelacji przestrzennej.

WYPADKI SPOWODOWANE PRZEZ CUDZOZIEMCÓW

W pierwszej kolejności przedstawiono dane dotyczące liczby wypadków i ich skutków ogółem oraz tych, które zostały spowodowane przez kierowców cudzoziemców (tabela 1.). Liczba ofiar śmiertelnych wypadków drogowych od trzech lat utrzymuje się na stałym poziomie, nieco poniżej 1 900 osób zabitych rocznie. Udział zdarzeń drogowych spowodowanych przez kierowców cudzoziemców wyraźnie wzrósł w latach 2010-2024 (rysunek 1). Nie był to systematyczny wzrost, wyraźny skok sprawstwa kierowców cudzoziemców zanotowano w 2017 i 2022 r. Było to niewątpliwie efekt zwiększonej imigracji do Polski – zarobkowej w 2017 r. i uchodźców wojennych z Ukrainy w 2022 r.


Tabela 1. Zdarzenia drogowe i ich skutki w latach 2010-2024 z uwzględnieniem wypadków spowodowanych przez kierowców cudzoziemców

| Rok | Ogółem | | | | Spowodowane przez cudzoziemców | | | |
|-----------|---------|--------|--------|-----------------------|--------------------------------|--------|-------|-----------------------|
| | Wypadki | Zabici | Ranni | Kolizje ¹⁾ | Wypadki | Zabici | Ranni | Kolizje ¹⁾ |
| 2010 | 38 832 | 3 907 | 48 952 | × | 442 | 67 | 612 | × |
| 2011 | 40 065 | 4 189 | 49 501 | 366 520 | 278 | 67 | 612 | 5 433 |
| 2012 | 37 046 | 3 571 | 45 792 | 339 581 | 305 | 59 | 445 | 5 717 |
| 2013 | 35 847 | 3 357 | 44 059 | 355 943 | 249 | 31 | 339 | 5 633 |
| 2014 | 34 970 | 3 202 | 42 545 | 348 028 | 253 | 40 | 352 | 5 220 |
| 2015 | 32 967 | 2 938 | 39 778 | 362 265 | 282 | 37 | 390 | 5 682 |
| 2016 | 33 664 | 3 026 | 40 766 | 406 622 | 331 | 56 | 475 | 7 304 |
| 2017 | 32 760 | 2 831 | 39 466 | 436 469 | 606 | 75 | 842 | 15 819 |
| 2018 | 31 674 | 2 862 | 37 359 | 436 414 | 730 | 108 | 1 034 | 17 591 |
| 2019 | 30 288 | 2 909 | 35 477 | 455 454 | 708 | 84 | 921 | 19 573 |
| 2020 | 23 540 | 2 491 | 26 463 | 382 046 | 560 | 84 | 670 | 15 505 |
| 2021 | 22 816 | 2 245 | 26 415 | 422 627 | 696 | 110 | 900 | 20 066 |
| 2022 | 21 322 | 1 896 | 24 743 | 362 266 | 1 146 | 120 | 1 422 | 25 738 |
| 2023 | 20 936 | 1 893 | 24 125 | 365 991 | 1 171 | 112 | 1 492 | 27 072 |
| 2024 | 21 519 | 1 896 | 24 782 | 390 580 | 1 179 | 106 | 1 428 | 27 744 |
| 2010 =100 | 55,4 | 48,5 | 50,6 | 106,6 ¹⁾ | 266,7 | 158,2 | 233,3 | 431,3 |

1) brak danych dla 2010 r. o liczbie kolizji, dynamika wyliczona względem 2011 r.

Źródło: opracowanie własne na podstawie danych z raportów Policji

Rysunek 1. Ofiary śmiertelne, ranni, wypadki, kolizje spowodowane przez kierowców cudzoziemców



Źródło: opracowanie własne na podstawie danych z raportów Policji

W 2024 r. kierowcy cudzoziemcy odpowiadali za spowodowanie 5,5% wypadków drogowych w Polsce, udział osób zabitych i rannych w tych wypadkach był minimalnie większy i wynosił odpowiednio 5,6% i 5,8%. Natomiast wyraźnie większy był udział kolizji spowodowanych przez kierowców cudzoziemców –


wynosił on w 2024 r. około 7,1%. Większy udział kierowców cudzoziemców wśród sprawców kolizji niż wśród sprawców wypadków, świadczyć może o tym, że jeżdżą oni relatywnie ostrożniej niż Polacy i jeżeli już dojdzie do zdarzenia drogowego przez nich spowodowanego, częściej pociąga ono za sobą tylko straty materialne. Oczywiście, jak już stwierdzono wcześniej, wszelkie tego typu wnioski muszą być traktowane z dużą ostrożnością, z uwagi na brak danych o liczbie kierowców cudzoziemców jeżdżących po polskich drogach, a tym bardziej o pokonywanych przez nich kilometrach.

Wzrost liczby wypadków drogowych z udziałem cudzoziemców można powiązać z rosnącą obecnością imigrantów na terenie Polski. Według GUS, na koniec stycznia 2024 roku w Polsce zatrudnionych było legalnie blisko milion cudzoziemców z ponad 150 różnych państw, co stanowiło 6,5% wszystkich osób pracujących w kraju.

CIĘŻKOŚĆ WYPADKÓW SPOWODOWANYCH PRZEZ KIEROWCÓW CUDZOZIEMCÓW

Na rysunku 2. przedstawiono wskaźnik ciężkości, wyznaczony jako procent osób zabitych z ogółu poszkodowanych. Jak już wspomniano, trudno ocenić, czy wypadków powodowanych przez cudzoziemców jest relatywnie więcej, gdyż brakuje danych co do dokładnej liczby cudzoziemców przebywających na terenie Polski.

Rysunek 2. Wskaźnik ciężkości wypadków spowodowanych przez kierowców cudzoziemców na tle ciężkości pozostałych wypadków



Źródło: opracowanie własne na podstawie danych z raportów Policji

Natomiast ciężkość tych wypadków, szczególnie od 2022 r., jest na bardzo podobnym poziomie jak dla pozostałych wypadków, które można przypisać

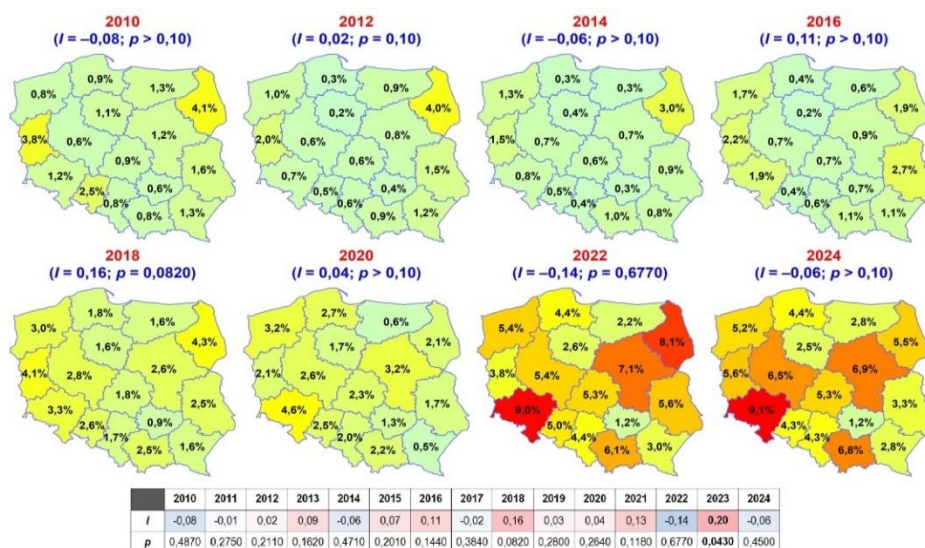
sprawstwu osób z polskim obywatelstwem. Ten wynik sugerowałby, że „kultura jazdy” kierowców cudzoziemców nie odbiega w negatywny sposób od umiejętności Polaków.

ANALIZA PRZEKROJOWA

Wiadomo, że wypadkowość na obszarze Polski jest wyraźnie zróżnicowana [Pisula i in. 2013], nasuwa się więc przypuszczenie, że jednym z czynników na nią wpływających może być położenie województw względem granic państwowych.

Z danych Policji za 2024 r. wynika, że wśród kierowców cudzoziemców uczestniczących w wypadkach drogowych w Polsce dominują Ukraińcy (59%), następnie Białorusini (7%), Gruzini (4%) i Niemcy (4%). Ta informacja powoduje, że można by oczekiwać wyraźnie ukierunkowanego rozkładu przestrzennego wskaźnika wypadków, gdyby do zdarzeń tych dochodziło podczas wjazdu obcokrajowców do Polski. Według tej hipotezy, liczba tych wypadków powinna być większa w województwach leżących bliżej granicy wschodniej, zwłaszcza z Ukrainą. Jeśli taka przestrzenna autokorelacja by nie występowała, oznaczałoby to, że większość wypadków powodowanych przez obcokrajowców, dotyczyłaby osób przebywających w Polsce przez dłuższy czas.

Rysunek 3. Udział wypadków spowodowanych przez kierowców cudzoziemców w województwach wraz z oceną autokorelacji przestrzennej w latach 2010-2024



I – współczynnik autokorelacji przestrzennej Morana

Źródło: opracowanie własne na podstawie danych z raportów Policji

Ponadto, gdyby wypadki drogowe powodowane przez cudzoziemców związane były przede wszystkim z ruchem turystycznym czy tranzytowym, miałyby swoją specyfikę związaną z pokonywaniem długich tras, wtedy logiczne byłoby oczekiwanie pewnej ciągłości przestrzennej, co powinno znaleźć odzwierciedlenie w dodatniej, istotnej statystycznie wartości współczynnika autokorelacji Morana.

Jednak tak sformułowana hipoteza nie znajduje potwierdzenia. Wskazuje na to zarówno wzrokowy ogląd kartogramów, pokazujących procentowy udział wypadków spowodowanych przez kierowców cudzoziemców, jak również nieistotne statystycznie wartości współczynnika autokorelacji przestrzennej Morana¹. W szczególności, udział wypadków powodowanych przez cudzoziemców nie układa się malejąco ze wschodu na zachód, czego można by oczekiwać na podstawie wiedzy o dominującym udziale kierowców z Ukrainy wśród sprawców wypadków.

Zatem charakter wypadków powodowanych przez cudzoziemców nie odbiega znacząco od ogółu zdarzeń występujących na polskich drogach, skoro ich rozkład przestrzenny możemy uznać za losowy.

PRÓBA OBIEKTYWIZACJI

Z przeprowadzonych do tej pory analiz można wysnuć wnioski o znaczącym wzroście bezwzględnej i względnej liczby wypadków powodowanych przez cudzoziemców w latach 2010-2024. Aby zobiektywizować wyniki, należy jednak odnieść liczbę wypadków do liczby kierowców cudzoziemców poruszających się po polskich drogach. I tu pojawia się problem, ponieważ żadna instytucja nie publikuje tego typu danych – więcej, w sytuacji braku kontroli granicznych na przejściach z krajami unijnymi nie są one gromadzone.

Wyniki analizy przestrzennej sugerują jednak, że do większości tych wypadków nie dochodzi podczas podróży stricte zagranicznych (turystycznych), tylko dotyczą one podróży cudzoziemców przebywających w naszym kraju przez dłuższy czas. Logicznym wydaje się więc porównanie dynamiki liczby wypadków powodowanych przez cudzoziemców do dynamiki liczby osób z niepolskim obywatelstwem, którzy przebywają czasowo w Polsce. Z uwagi na dominujący udział Ukraińców wśród sprawców wypadków, porównano także dynamikę liczby wypadków z udziałem osób tej narodowości z dynamiką liczby imigrantów z Ukrainy.

Na podstawie przedstawionych w tabeli 2. indeksów dynamiki można stwierdzić, iż liczba wypadków powodowanych przez kierowców cudzoziemców rośnie ponad 2-krotnie wolniej niż liczba imigrantów. Liczba wypadków z udziałem osób z Ukrainy wzrosła w latach 2011-2024 18 razy, zaś liczba osób z Ukrainy

¹ Jedyna istotna statystycznie autokorelacja ($p = 0,0430$), ale o bardzo niewielkiej sile ($I = 0,20$) występowała dla wskaźników z roku 2023.

niemal 45 razy, a więc tu dysproporcja jest jeszcze większa. Analizując te wyniki należy mieć świadomość małej szczegółowości danych odnośnie imigrantów – brakuje danych o tym jak długo w ciągu roku przebywają oni w Polsce, ile spośród nich podróżuje samochodami, jakie pokonują odległości. Mimo tych zastrzeżeń, różnica w dynamice liczby imigrantów i liczby wypadków powodowanych przez cudzoziemców jest na tyle duża, że trudno mówić o rosnącym, nieproporcjonalnie dużym udziale tych osób wśród sprawców wypadków drogowych.

Tabela 2. Dynamika liczby wypadków spowodowanych przez kierowców cudzoziemców oraz wypadków z udziałem osób z Ukrainy na tle dynamiki liczby imigrantów ogółem oraz liczby imigrantów z Ukrainy w latach 2011-2024 (2011 = 100)

| Rok | Wypadki spowodowane przez kierowców cudzoziemców | Imigranci ogółem | Wypadki z udziałem osób z Ukrainy | Imigranci z Ukrainy |
|------|--|------------------|-----------------------------------|---------------------|
| 2011 | 100,0 | 100,0 | 100,0 | 100,0 |
| 2012 | 109,7 | 114,1 | 91,4 | 116,8 |
| 2013 | 89,6 | 124,2 | 105,2 | 123,1 |
| 2014 | 91,0 | 136,0 | 100,0 | 154,4 |
| 2015 | 101,4 | 173,2 | 167,2 | 330,0 |
| 2016 | 119,1 | 229,9 | 320,7 | 600,9 |
| 2017 | 218,0 | 281,5 | 781,0 | 872,5 |
| 2018 | 262,6 | 311,1 | 1027,6 | 1022,3 |
| 2019 | 254,7 | 336,6 | 1103,4 | 1133,7 |
| 2020 | 201,4 | 355,3 | 874,1 | 1253,0 |
| 2021 | 250,4 | 436,2 | 1025,9 | 1693,8 |
| 2022 | 412,2 | 621,1 | 1627,6 | 2658,5 |
| 2023 | 421,2 | 904,3 | 1784,5 | 3917,3 |
| 2024 | 424,1 | 1061,4 | 1844,8 | 4526,1 |

Źródło: opracowanie własne na podstawie danych z raportów Policji oraz danych rządowych o liczbie imigrantów (migracje.gov.pl/statystyki/zakres/polska/)

PODSUMOWANIE

Na podstawie przeprowadzonych analiz jednoznacznie stwierdzono dynamiczny wzrost bezwzględnej i względnej liczby wypadków powodowanych przez kierowców cudzoziemców w latach 2010-2024. Dynamika udziału wypadków powodowanych przez kierowców cudzoziemców jest mniejsza niż dynamika liczby obcokrajowców przebywających przez dłuższy czas w Polsce. Brak autokorelacji przestrzennej udziału wypadków powodowanych przez kierowców cudzoziemców w przekroju województw, sugeruje że w większości odbywają się one podczas podróży na krótszych trasach i nie wynikają z ruchu turystycznego czy tranzytowego, tylko zależą od liczby imigrantów. Wskaźnik ciężkości wypadków powodowanych przez cudzoziemców jest podobny jak dla wypadków powodowanych przez Polaków – w połączeniu z wcześniejszymi spostrzeżeniami

pozwala to stwierdzić, że mówienie o wyjątkowej brawurze zagranicznych kierowców nie ma merytorycznych podstaw.

Autorzy mają świadomość, że istotnym ograniczeniem uniwersalności wniosków w przedstawionej pracy jest brak informacji o liczbie cudzoziemców, którzy poruszają się po polskich drogach w charakterze kierowców. Dlatego też badania nad udziałem sprawstwa kierowców cudzoziemców w wypadkach drogowych będą kontynuowane w kolejnych latach, szczególnie w sytuacji coraz liczniejszego napływu osób z zagranicy do Polski.

BIBLIOGRAFIA

- Bajorski B. (2018) System zarządzania bezpieczeństwem ruchu drogowego na tle społecznych i ekonomicznych kosztów wypadków drogowych w Polsce – wybrane problemy podstawowe. *Kultura Bezpieczeństwa. Nauka-Praktyka-Refleksje*, (29), 238-259.
- Bellos V., Ziakopoulos A., Yannis G. (2019) Investigation of the Effect of Tourism on Road Crashes. *Journal of Transportation Safety & Security*, 12(6), 782-799. <https://doi.org/10.1080/19439962.2018.1545715>
- Chomiuk M. (2024), <https://www.bankier.pl/wiadomosc/Cudzoziemcy-szaleja-na-polskich-drogach-Rzecznik-ITS-Potrzeba-czasu-8720100.html>
- European Commission (2025) Annual Statistical Report on Road Safety in the EU, 2025. European Road Safety Observatory. Brussels, European Commission, Directorate General for Transport.
- Fahmadi A.E., Tohom F., Natria I. (2022) Traffic Safety Management to Reduce Foreigner Accidents. *RSF Conference Series: Engineering and Technology*, 2(2), 273-281. <https://doi.org/10.31098/cset.v2i2.581>
- Gazeta Wrocławska (2018) Wrocław: Pijany Ukraińec wjechał w most. Przeprawa do remontu. <https://gazetawroclawska.pl/wroclaw-pijany-ukrainiec-wjechał-w-most-przeprawa-do-remontu/gh/13274614>.
- Lesyk-Szkutnik Y. (2018) Imigranci z Ukrainy w kontekście wyzwań dla bezpieczeństwa wewnętrznego Polski [w:] M. Lubicz Miszewski (red.) *Imigranci z Ukrainy w Polsce. Potrzeby i oczekiwania, reakcje społeczne, wyzwania dla bezpieczeństwa*. Akademia Wojsk Lądowych im. Generała Tadeusza Kościuszki, Wrocław, 114.
- Linkov V., Zámečník P. (2020) Cultural Differences-Induced Mistakes in Driving Behaviour: An Opportunity to Improve Traffic Policy and Infrastructure. In: Vanderheiden, E., Mayer, CH. (eds) *Mistakes, Errors and Failures across Cultures*. Springer, Cham. https://doi.org/10.1007/978-3-030-35574-6_32
- Nycz M., Sobolewski M. (2025) The Problem of the Comparability of Road Accident Data from Different European Countries. *Sustainability*, 17(15), 6754. <https://doi.org/10.3390/su17156754>
- Pawelec K. J. (2020) *Bezpieczeństwo i ryzyko w ruchu drogowym*. Difin SA, Warszawa.
- Pisula T., Chudy-Laskowska K. (2013) *Bezpieczeństwo w ruchu drogowym w Polsce w przekroju województw. Analiza porównawcza*. TTS Technika Transportu Szynowego, 20(10), 1895-1906.

- Podgórska A., Rajchel J. (2019) Wypadki drogowe w Polsce i ich skutki. *Drogownictwo*, (12), 347-354.
- Potin M., Carron P.N., Genton B. (2024) Injuries and Medical Emergencies among International Travelers. *Journal of Travel Medicine*, 31(1), <https://doi.org/10.1093/jtm/taad088>
- Raczyński R. (2015) Wpływ migracji międzynarodowych na bezpieczeństwo wewnętrzne państwa [w:] *Bezpieczeństwo. Teoria i praktyka*, (2), 13-30.
- Raport Punkta i PBUK (2015) Obcokrajowcy na polskich drogach: Ukraińcy i Niemcy powodują najwięcej wypadków, <https://punkta.pl/akademia/raporty-i-analzy/obcokrajowcy-na-polskich-drogach-raport/> (Aktualizacja: 25.11.2015).
- Riasa N.P., Parama A., Budiapsari P.I., Lestari D.P.O. (2020) The Pattern of Facial Injury among Foreign Travelers in Bali: A Retrospective Study. *Open Access Maced J Med Sci*, 8(B):988-93. Available from: <https://oamjms.eu/index.php/mjms/article/view/5169>.
- Rzeczpospolita (2016) Coraz więcej przestępstw Ukraińców w Polsce, <http://fakty.interia.pl/prasa/news-rzecz-pospolita-coraz-wiecej-przestepstw-ukraincow-w-polsce,nId,2309123>.
- Statystyki Policji, Roczne raporty statystyczne. Wypadki drogowe, <https://statystyka.policja.pl/st/ruch-drogowy/76562,Wypadki-drogowe-raporty-roczne.html>.
- Urząd do spraw Cudzoziemców: migracje.gov.pl/statystyki/zakres/polska.
- Zawadka G. (2024) Ciemna strona migracji. Cudzoziemcy w Polsce jeżdżą po alkoholu i łamią zakazy, <https://www.rp.pl/przestepczosc/art39737861-ciemna-strona-migracji-cudzoziemcy-w-polsce-jezdza-po-alkoholu-i-lamia-zakazy>.

ROAD ACCIDENTS CAUSED BY FOREIGNERS IN POLAND IN THE YEARS 2010-2024

Abstract: The article presents an assessment of road traffic safety risks posed by foreign drivers on Polish roads. Based on data published in official Police reports, indicators of accident involvement attributable to non-Polish nationals were determined, alongside evaluations of accident severity and their spatial distribution across voivodeships. Furthermore, the dynamics of accidents caused by foreign drivers were compared with trends in immigrant population growth. The results of the analysis suggest that neither the frequency nor the severity of accidents involving foreign drivers significantly diverge from corresponding statistics for Polish drivers.

Keywords: road traffic accidents, casualties of road traffic accidents, road traffic accidents involving foreign nationals, immigration, spatial analysis

JEL classification: R41, R48, F22, R12, K14

MODEL GŁĘBOKIEGO UCZENIA LCA-NN NA BAZIE SYSTEMU POPRAWY PREDYKCJI ZA POMOCĄ DEKOMPOZYCJI WIELOWYMIAROWYCH

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

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

Streszczenie: W niniejszym artykule przedstawimy system uczenia głębokiego łączącego sieci neuronowe MLP z wielowymiarowymi dekompozycjami. Stanowi on rozwinięcie systemu dla poprawy wyników predykcji w ujęciu wielomodelowym wykorzystującym metody ICA, PCA oraz NMF, co można potraktować także jako metodę agregacji modeli lub wielowymiarową filtrację komponentów zakłócających wyniki prognoz. Cały proces przedstawimy w nawiązaniu do problemu ślepej separacji wskazując na możliwe użyteczne inspiracje jak i istotne ograniczenia takich interpretacji.

Słowa kluczowe: predykcja, modele uczenia głębokiego, wielowymiarowe dekompozycje, sieci neuronowe

JEL classification: C02, C50

WPROWADZENIE

Modele uczenia głębokiego często powstają w efekcie połączenia różnych technik, metod lub algorytmów stosowanych wcześniej odrębnie, choć często w ramach jednej badania lub procesu [Mallat 2016]. Takie podejście zastosujemy także w niniejszym artykule do metody poprawy predykcji za pomocą dekompozycji wielowymiarowych [Szupiluk 2013; Szupiluk i in. 2014]. Metodę tą najpierw rozszerzymy o etap neuronowego douczania, a następnie, biorąc pod uwagę cały proces analityczny, uogólnimy do postaci uniwersalnego regresyjnego/klasyfikacyjnego systemu głębokiego uczenia. W ramach prowadzonych rozważań przedstawimy różne możliwości rozwoju całej koncepcji oraz jej związki z problemem ślepej separacji.

<https://doi.org/10.22630/MIBE.2025.26.3.12>



Będący punktem wyjścia system poprawy predykcji (SPP) za pomocą dekompozycji wielowymiarowych polega na dekompozycji zbioru prognoz na ukryte komponenty wśród których identyfikowane są, związane z błędami prognozy, komponenty destrukcyjne. Ich eliminacja a następnie wykonanie dekompozycji odwrotnej, prowadzić może do poprawy wyników predykcji. Cały proces SPP można także interpretować lub porównywać z problemem ślepej separacji (ang. Blind Signal Separation-BSS).

BSS jest to problem w którym odtwarzane są nieznane a priori sygnały źródłowe, zmieszane w także nieznanym systemie mieszającym [Cardoso 1998; Cichocki, Amari 2002]. Jednym z powodów analogii między SPP oraz BSS są stosowane w obydwu przypadkach dekompozycja takie jak ICA, PCA lub NMF [Cardoso 1998; Comon, Jutten 2010; Cichocki i in. 2009]. Choć można potraktować je jako czysto analityczne reprezentacje danych, to są one silnie związane z problemem ślepej separacji lub w takich kategoriach mogą być rozważane. Stąd dość naturalne nawiązania między omawianą metodą poprawy predykcji a problemem BSS.

Jednak głównym elementem niniejszej pracy jest generalizacja całej koncepcji na ogólny przypadek modelowania neuronowego z nauczycielem. W tym celu włączymy w ramy systemu także etap tworzenia samych modeli podstawowych (w SPP zakładaliśmy, że prognozy już posiadamy), zaś poszczególne etapy (warstwy) tego systemu będziemy starali się jak najbardziej uogólnić. W przypadku dekompozycji, będziemy się posługiwać pojęciem LCA (ang. Latent Component Analysis) mając na myśli dowolne metody identyfikujące ukryte komponenty o różnych charakterystykach. Stąd uogólniony system będzie określany jako LCA-NN.

WIELOWYMIAROWE ŁĄCZENIE MODELI

Podstawową całej koncepcji jest system poprawy predykcji. Jego konstrukcja jest następująca. Zakładamy istnienie zbioru m rezultatów predykcji $x_i(t)$ generowanych przez modele bazowe, gdzie $i = 1, \dots, m$ oznacza numer modelu, zaś t jest indeksem czasu lub numerem obserwacji. Wyniki predykcji zbierane są w jednej wielowymiarowej zmiennej $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$, lub w zapisie macierzowym $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]^T$.

Zakładając, że wyniki predykcji są użyteczne i prezentują akceptowalną jakość, można stwierdzić, iż prognozowane wartości w pewnym stopniu odpowiadają wartościom rzeczywistym (obserwowanym), a w pewnym się różnią. Można więc powiedzieć, że dany rezultat predykcji jest mieszaniną pewnych ukrytych komponentów konstruktywnych \hat{s}_j , $j = 1, \dots, p$ oraz komponentów destrukcyjnych \tilde{s}_l , $l = 1, \dots, q$. Komponenty konstruktywne, związane są z podobieństwem wartości przewidywanych i obserwowanych. Komponenty

destrukcyjne, odpowiadają za różnice lub błędy predykcji. Owe konstruktywne oraz destrukcyjne komponenty źródłowe mogą być mieszane w różny sposób. W przypadku liniowego modelu (systemu) mieszania mamy

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

gdzie macierz $\mathbf{A} = [a_{ij}] \in R^{m \times n}$ reprezentuje system mieszający zaś wektor

$$\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T = [\hat{s}_1(t), \dots, \hat{s}_p(t), \tilde{s}_{p+1}(t), \dots, \tilde{s}_{p+q}(t)]^T, \quad (2)$$

gdzie, $n = p + q$ zawiera zestaw komponentów źródłowych.

Estymacja komponentów źródłowych jest kluczowym elementem całej koncepcji. Problem ten można przedstawić jako poszukiwanie transformacji odwrotnej do (1) tak, że

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) \approx \mathbf{s}(t), \quad (3)$$

gdzie dla $m=n$ macierz $\mathbf{W} = \mathbf{A}^{-1}$ pełni rolę systemu separującego odwrotnego do \mathbf{A} .

Identyfikując system mieszający \mathbf{A} oraz komponenty bazowe \mathbf{s} oraz eliminując komponenty destrukcyjne (stawiając odpowiednio $\tilde{s}_i = 0$) otrzymuje się „poprawianą” wersję rezultatów predykcji x postaci

$$\hat{\mathbf{x}}(k) = \mathbf{A}[\hat{s}_1(t), \dots, \hat{s}_p(t), 0_{p+1}(t), \dots, 0_n(t)]^T, \quad (4)$$

gdzie $\hat{\mathbf{x}} = [\hat{x}_1, \dots, \hat{x}_m]^T$. Przy czym fakt poprawy jakości oraz jej stopień zależy od zawartości komponentów destrukcyjnych w poszczególnych prognozach. Ten sam efekt poprawy zostanie osiągnięty w wyniku zastąpienia w macierzy mieszającej $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n]$ odpowiedniej kolumny wektorami zer

$$\hat{\mathbf{A}} = [\mathbf{a}_1, \dots, \mathbf{a}_p, \mathbf{0}_{p+1}, \mathbf{0}_{p+2}, \dots, \mathbf{0}_n], \quad (5)$$

co prowadzi do

$$\mathbf{x}(t) = \hat{\mathbf{A}}\mathbf{s}(t). \quad (6)$$

Kluczowym zagadnieniem w rozważanej procedurze, jest znalezienie takiej dekompozycji (transformacji), która prowadzi do dekompozycji danych \mathbf{x} na komponenty konstruktywne i destrukcyjne. A następnie poprawne określenie, które komponenty są destrukcyjne. Pomijamy przy tym dyskusję o naturze tych komponentów w podziale na indywidualne czy wspólne dla modeli predykcyjnych. Indywidualne komponenty bazowe, związane ze specyfiką danego modelu będą dalej traktowane jako szczególny przypadek „komponentu wspólnego” o zerowym wpływie na wyniki innych modeli.

Naturalnymi propozycjami dekompozycji są metody związane z identyfikacją komponentów ukrytych, takie jak ICA, PCA, NMF, AMUSE itp. [Comon, Jutten 2010]. Przyjmujemy, że ogólnie możemy je zaliczyć do klasy metod LCA. Przy czysto mechanicznym użyciu tych metod, mamy do czynienia z zasadniczo analityczną reprezentacją danych. Uzyskanych tak komponentów, nie wiążemy z fizycznymi sygnałami lub interpretowalnymi modelami generowania danych. Ową fizyczną interpretację można jednak próbować wykonać, nawiązując do problemu ślepej separacji, gdyż tam także mamy do czynienia z estymacją nieznanymi zmiennymi (sygnałów, komponentów) zmieszanych w nieznanym systemie.

Przyjęcie interpretacji BSS oznacza założenie określonej charakterystyki sygnałów źródłowych oraz określonego sposobu ich mieszania. Od tych założeń zależy z kolei system separujący. Zakłada się, że przypadkowi liniowego mieszania powinien odpowiadać liniowy układ separujący, dynamicznemu mieszanemu dynamiczny separujący itp. [Cichocki 2013].

Jednak z praktycznego punktu widzenia, przyjmując określony model mieszania, należy mieć na uwadze, nie tylko zasadność założeń co do jego postaci, ale także istniejący stan wiedzy, na temat możliwości uzyskania skutecznego rozwiązania. Skuteczna estymacja komponentów źródłowych, na gruncie aktualnie znanych metod separacji, jest możliwa zasadniczo dla modelu liniowego [Hyvarinen i in. 2001; Mali, Mahajan 2024].

W większości algorytmów separacji, zakłada się także istotną relację między ilością sygnałów źródłowych a obserwowanych (zmieszanych). Przyjmuje się, że BSS jest możliwa gdy ilość sygnałów obserwowanych jest większa lub równa liczbie sygnałów źródłowych [Cardoso 1998]. W klasycznych algorytmach separacji jest to założenie kluczowe, odpowiadające za możliwość separacji [Araki i in. 2025]. Założenie to, o ile może to być spełnione w przypadkach technicznych lub fizycznych, to w przypadku danych z rynków finansowych sytuacja znacząco się komplikuje.

W przypadku danych giełdowych, trudno, a w zasadzie niemożliwe, jest ustalenie jakiegoś ograniczonego zbioru sygnałów źródłowych z którego w wyniku mieszania powstają wartości wszelkich instrumentów finansowych. Można więc przyjąć, że wszelkie separacje (dekompozycje, transformacje) mają tu charakter analityczny. Jednocześnie jednak, nie sposób wykluczyć sytuacji kiedy zastosowanie różnych dekompozycji do różnych zbiorów instrumentów (wartości aktualnych lub ich predykcji) prowadzi do „wyłowienia” podobnych lub identycznych komponentów (lub komponentu). Mogłoby to sugerować identyfikację pewnego fizycznego komponentu źródłowego związanego z „jakimiś” realnym procesem ekonomicznym. Jednak na bazie dotychczasowych badań taką sytuację należy uznać za stosunkowo mało prawdopodobną, zaś jej pojawienie się należy wiązać raczej z jakimś szczególnym przypadkiem, niż efektem systematycznych poszukiwań.

W efekcie można powiedzieć, że korzyści z analogii do problemu BSS wiążą się raczej z możliwościami użycia stosowanych tam metod niż z bezpośrednią

interpretacją estymacji komponentów źródłowych w kategoriach zagadnienia ślepej separacji.

AGREGACJA NEURONOWA

Opisana powyżej metoda może być rozważana i rozwijana w różnych aspektach. Przede wszystkim, wybór dekompozycji jest z reguły dość ograniczony i często motywowany ich popularnością w aspekcie teoretycznym oraz praktycznym. Należą one do standardowych metod analitycznych, zaś przesłanką do ich stosowania w prezentowanym systemie jest ich skuteczność w problemie BSS, który wydaje się najbliższą analogią dla naszego rozwiązania. Oznacza to, że w przypadku rozważanego systemu, podobnie jak w problemie separacji, stosowane dekompozycje mogą tylko pewnym stopniu odpowiadać „właściwym” formom estymacji komponentów źródłowych.

Kolejną kwestią jest identyfikacja komponentów destrukcyjnych. Metodą dającą jednoznaczne wyniki jest mechaniczna eliminacja każdego komponentu, dokonanie transformacji odwrotnej i ocena wyników prognozy. Przy czym należy mieć na uwadze, że możemy otrzymać komponenty o niejednoznacznym znaczeniu np. pojedyncze komponenty mogą mieć negatywny wpływ na wyniki predykcji ale ich kombinacje już pozytywny. Wykonalność takiego zadania jest ściśle związana z ilością badanych modeli predykcyjnych a w konsekwencji z ilością komponentów źródłowych. W efekcie, należy zbadać wpływ nie tylko eliminacji pojedynczych komponentów, ale wszystkich podzbiorów (2^n). W przypadku dużej liczby komponentów źródłowych możliwe są też aprioryczne oceny ich jakości [Szupiluk, Rubach 2017]

Jednak taka ostra (tak/nie) klasyfikacja komponentów źródłowych nie zawsze musi być optymalna. Określone komponenty także mieć konstruktywny wpływ na pewne modele a destrukcyjny na pozostałe. W takich przypadkach, prosta zero-jedynkowa interpretacja poszczególnych komponentów źródłowych może być niemożliwa. Także nie zawsze optymalna może być pełna eliminacja komponentu destrukcyjnego, czasem lepsze może być jego stłumienie (lecz nie zerowanie).

Ze względu na możliwą „nieostrą” klasyfikację danego komponentu źródłowego jako destrukcyjny lub konstruktywny, zastosujemy ich ważenie w pewnym ogólnym systemie mieszającym, którym zastąpimy transformację odwrotną. Będzie to system neuronowy z nauczycielem w postaci targetu z bazowych modeli predykcyjnych. Przyjmijmy, że będzie to sieć neuronowa typu MLP. Jednak podanie na wejście takiego systemu bezpośrednio komponentów źródłowych s oznacza w istocie czystą agregację neuronową modeli bazowych transformowanych przez macierz wynikającą z dekompozycji separującej. Byłby to typowy preprocessing PCA lub ICA gdzie główną korzyścią jest dekorelacja (liniowa lub nieliniowa) danych wejściowych dla sieci neuronowej. Aby wykorzystać informacje pozyskane w wyniku identyfikacji komponentów destrukcyjnych przyjmijmy, że punktem startowym dla wag sieci neuronowej

(przynajmniej jednej z warstw) będzie macierz $\hat{\mathbf{A}}$ określona przez (5), czyli najlepsza macierz jaką można otrzymać poprzez pełną eliminację komponentów destrukcyjnych. Dla sieci typu wielowarstwowy perceptron (ang. Multilayer Perceptron -MLP) typu MLP(n,n,n)

$$\hat{\mathbf{x}} = \mathbf{g}_2(\mathbf{B}_2[\mathbf{g}_1(\mathbf{B}_1\mathbf{s} + \mathbf{b}_1)] + \mathbf{b}_2), \quad (7)$$

gdzie $\mathbf{g}_i(\cdot)$ jest wektorem nieliniowości, \mathbf{B}_i jest macierzą wag i \mathbf{b}_i jest wektorem przesunięcia odpowiednio dla i -tej warstwy, $i=1,2$. W przypadku braku uczenia, sieć neuronowa (7) jest tożsama z (6), jeżeli ograniczymy się do jednej warstwy $\mathbf{B}_1 = \hat{\mathbf{A}}$, $\mathbf{b}_i = \mathbf{0}$ oraz liniowych funkcji aktywacji. Jest jednak wysoce prawdopodobne, że jeżeli uczenie sieci neuronowej zaczniemy od punktu do którego doprowadza nas etap dekompozycji (wartości początkowe pierwszej warstwy ukrytej $\mathbf{B}_1(0) = \hat{\mathbf{A}}$) to osiągnięte wyniki będą lepsze niż z samej rekompozycji (dekompozycji odwrotnej). Możemy ten sposób rozumowania rozszerzyć na kolejne warstwy oraz przyjąć, że wagi we wszystkich warstwach startują od wartości $\hat{\mathbf{A}}$, czyli mamy

$$\hat{\mathbf{x}} = \mathbf{g}_2(\mathbf{B}_2[\mathbf{g}_1(\mathbf{B}_1\mathbf{s})]), \quad \text{gdzie } \mathbf{B}_1(0) = \mathbf{B}_2(0) = \hat{\mathbf{A}}. \quad (8)$$

Dalsze uogólnienie może polegać na dowolnej architekturze MLP wykorzystującej macierz $\hat{\mathbf{A}}$ oraz dane wejściowe \mathbf{s}

$$\hat{\mathbf{x}} = \text{MLP}(\mathbf{s}, \hat{\mathbf{A}}), \quad (9)$$

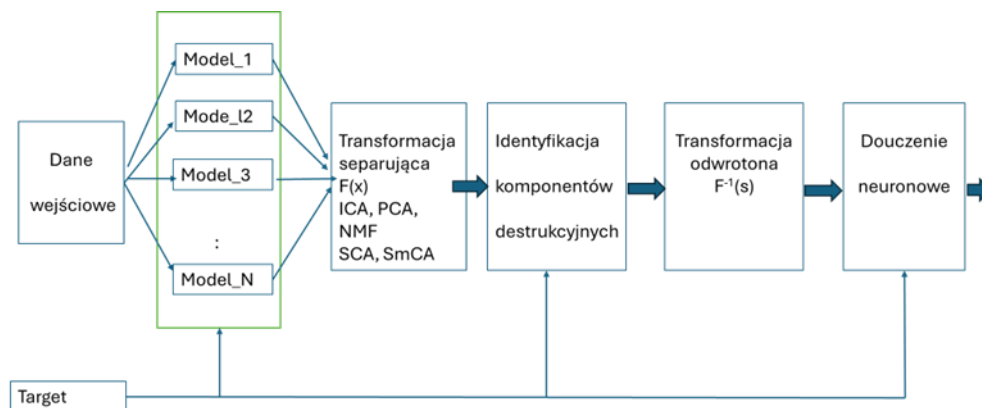
gdzie formuła (9) oznacza wykorzystanie dowolnej architektury MLP z sygnałami wejściowymi \mathbf{s} (komponenty źródłowe) oraz dowolnymi warstwami wag startującymi od wartości macierzy $\hat{\mathbf{A}}$. Dalsze modyfikacje mogą polegać na wykorzystaniu innych typów sieci neuronowych np. RBF, CNN, LSTM.

MODEL UCZENIA GŁĘBOKIEGO LCA-NN

W dotychczasowych rozważaniach bazowaliśmy na założeniu, że już posiadamy wyniki z modeli predykcyjnych. Obecnie także ten etap, tworzenia modeli predykcyjnych oraz generowania przez nie wyników, włączymy do naszych rozważań. Analizując cały proces można zauważyć, że otrzymamy pełny system modelowania danych (regresja, klasyfikacja), który może spełniać różne role i nie musi się ograniczać do poprawy predykcji. Może on stanowić uniwersalny model neuronowy z nauczycielem, w którym występują etapy (lub inaczej warstwy): tworzenia podstawowych modeli regresyjnych lub klasyfikacyjnych (predykcje), następnie etap dekompozycji odpowiedzialny za oczyszczenie uzyskanych wyników z komponentów zakłócających i kolejny etap neuronowy mający za zadanie

douczenie całego systemu. Ze względu na możliwość użycia różnych dekompozycji prowadzących do różnego typu ukrytych komponentów źródłowych, ten aspekt funkcjonowania systemu określimy mianem LCA (ang, Latent Component Analysis), zaś cały system, prezentowany na rysunku 1, zdefiniujemy jako LCA-NN.

Rysunek 1. Sieć neuronowa LCA-NN



Źródło: opracowanie własne

Cały proces ma następującą postać:

Warstwa 1. Tworzymy modele predykcyjne w oparciu o sieci neuronowe MLP. Zestaw wyników z modeli neuronowych zbieramy w jednej zmiennej wielowymiarowej \mathbf{x} .

Warstwa 2. Wykonujemy dekompozycję LCA (ICA, PCA, SMA, NMF, AMUSE itp.). Zmienną \mathbf{x} poddajemy transformacji LCA otrzymując komponenty źródłowe \mathbf{s}

Warstwa 3. Identyfikujemy komponenty destrukcyjne.

Warstwa 4. Dokonujemy uogólnionej transformacji odwrotnej. Zastępujemy, wartości komponentu destrukcyjnego zerami lub niwelujemy jego wpływ odpowiednimi parametrami w transformacja odwrotnej.

Warstwa 5. Wykonujemy douczenie neuronowe siecią MLP. Wartości początkowe warstw sieci MLP stanowią wartości z macierzy transformacji odwrotnej z zerowymi wartościami dla zidentyfikowanych komponentów destrukcyjnych.

Wyjście. Otrzymujemy sygnały wyjściowe.

Ze względu na wykorzystanie metod LCA, cała metoda jest domyślnie wielomodelowa, jednak nie oznacza to konieczności tworzenia całkowicie odrębnych modeli. Możliwe jest generowanie wielu rozwiązań tym samym modelem (to jest o tej samej architekturze, a także parametrach) na różnych podzbiorach

uczących. W efekcie całe rozwiązanie można także rozpatrywać w kategoriach metody agregacji modeli (ang. ensemble methods).

BADANIE PRAKTYCZNE

Niniejszy artykuł ma główne charakter ideowy oraz metodologiczny. Jednak aby pokazać zasadność i skuteczność podstawowej koncepcji przedstawimy krótko eksperyment przewidywania zużycia energii elektrycznej sformułowany jako predykcja godzinnego obciążenia dokonywana z wyprzedzeniem 24 godzin. Dane wejściowe dla predykcyjnych modeli neuronowych obejmują informacje o godzinnym zużyciu energii w ciągu ostatnich 24 godzin, jak również dane kalendarzowe typu: dzień, miesiąc, dzień tygodnia, indyktor dnia. Dla tak postawionego problemu, opracowano pięć modeli neuronowych typu MLP o 20, 26, 28, 30, 35 neuronach w warstwie ukrytej, oznaczonych odpowiedni jako M1:MLP20, M2:MLP26, M3:MLP28, M4:MLP30, M5:MLP35.

W ramach badań wykorzystano dekompozycje PCA oraz ICA (algorytm Jade). Badanie przeprowadzono z wykorzystaniem samych dekompozycji jak i douczania neuronowego. Uzyskane wyniki prezentuje Tabela 1.

Tabela 1. Prognozowanie zużycia energii-wyniki modeli

| MAPE 10^{-3} | M1 | M2 | M3 | M4 | M5 |
|-------------------|-------|-------|-------|-------|-------|
| Modele podstawowe | 23,73 | 23,44 | 23,71 | 24,01 | 24,13 |
| PCA | 22,87 | 22,45 | 22,79 | 22,57 | 22,51 |
| ICA | 23,69 | 22,41 | 22,57 | 23,34 | 22,98 |
| PCA&NN | 22,53 | 22,20 | 22,49 | 22,48 | 22,21 |
| ICA&NN | 22,17 | 22,38 | 22,51 | 22,71 | 21,16 |

Źródło: opracowanie własne

Jako kryterium jakości przyjęto błąd $MAPE = \frac{1}{N} \cdot \sum_{i=1}^N \frac{|\varepsilon_i|}{s_i}$, gdzie s_i oznacza wartość rzeczywistą (target) zaś ε_i błąd prognozy. W większości modeli uzyskano poprawę już przy wykorzystaniu samych dekompozycji na poziomie od 3,6 do 6,7 procent. W przypadku agregacji neuronowej poprawy jakości predykcji wynoszą od 5,0 do 12,03 procent.

PODSUMOWANIE

Prezentowane w artykule rozważania odnoszą się do koncepcji, która bazuje na systemie poprawy predykcji, dla której zaproponowaliśmy szersze rozwinięcia neuronowe. Takie podejście otwiera także drogę do bardziej ogólnego punktu widzenia i wyjścia poza schemat systemu poprawy predykcji, np. potraktowanie

całego procesu jako uniwersalnego systemu neuronowego z nauczycielem, który może być stosowany do dowolnego zagadnienia klasyfikacji lub regresji. Złożoność całego systemu uzasadnia określenie go jako systemu głębokiego uczenia.

Poszczególne etapy związane z dekompozycjami wielowymiarowymi oraz identyfikacją komponentów destrukcyjnych mogą być rozważane w kategoriach problemu ślepej separacji dając możliwość lepszego dopasowania stosowanych dekompozycji do badanego problemu oraz głębszej jego interpretacji. Wiązanie jednak działania dekompozycji z BSS nie jest jednak konieczne ani czasem możliwe, w takiej sytuacji traktujemy te przekształcenia LCA w kategoriach reprezentacji analitycznych.

Zarówno w przypadku systemu poprawy predykcji jak i systemu LCA-NN, ze względu na identyfikację ukrytych komponentów możemy wiązać ten etap (warstwę) z problemem ślepej separacji, wykorzystując rozwiązania z tego obszaru. Należy jednak mieć na uwadze, że zbyt bliskie wiązanie podstawowego procesu poprawy predykcji oraz LCA-NN z BSS niesie z sobą także liczne trudności interpretacyjne i metodyczne, które trudno przekonująco rozstrzygać lub wprost akceptować. Także wprowadzenie etapu agregacji neuronowej, oddala cały proces od bezpośredniej interpretacji w kategoriach BSS.

BIBLIOGRAFIA

- Araki S., Ito N., Haeb-Umbach R. et al. (2025) 30+ Years of Source Separation Research: Achievements and Future Challenges. Technical Report No. TR2025-036. Mitsubishi Electric Research Laboratories.
- Cardoso J. (1998) Blind Signal Separation: Statistical Principles. Proceedings. of the IEEE, 86(10), 2009–2025.
- Cichocki A., Amari S. (2002) Adaptive Blind Signal and Image Processing, John Wiley, Chichester.
- Cichocki A., Zdunek R., Phan A.-H., Amari S. (2009) Nonnegative Matrix and Tensor Factorizations: Applications to Exploratory Multi-Way Data Analysis. John Wiley. <https://doi.org/10.1002/9780470747278>
- Cichocki A. (2013) Tensor Decompositions: A New Concept in Brain Data Analysis? 02 May 2013 - arXiv: Numerical Analysis
- Comon P., Jutten Ch. (2010) Handbook of Blind Source Separation: Independent Component Analysis and Applications, Academic Press.
- Hyvarinen A., Karhunen J., and Oja E. (2001) Independent Component Analysis. Wiley John, New York.
- Mali S.G., Mahajan S.P. (2024) Blind Sound Source Separation by Combining the Convolutional Neural Network and Degree Separator. *Traitement du Signal*, 41(3), 1429-1439.
- Mallat S. (2016) Understanding Deep Convolutional Networks. *Philosophical Transactions of the Royal Society A* 374, 2065,

- Szupiluk R., Wojewnik P., Ząbkowski T. (2014) Smooth Component Analysis and MSE Decomposition for Ensemble Methods in Multi-Agent Environment. *International Journal of Innovative Computing Information and Control*, 10(4), 1435-1445.
- Szupiluk R., Rubach P. (2017) Identyfikacja komponentów destrukcyjnych w modelach predykcyjnych w podejściu wielomodelowym. *Metody Ilościowe w Badaniach Ekonomicznych*, 18(4), 679-688.
- Szupiluk R. (2013) Dekompozycje wielowymiarowe w agregacji predykcyjnych modeli Data Mining. Szkoła Główna Handlowa, Oficyna Wydawnicza.

LCA-NN DEEP LEARNING MODEL BASED ON PREDICTION IMPROVEMENT SYSTEM USING MULTIVARIATE DECOMPOSITION

Abstract: In this article, we present a deep learning system that combines MLP neural networks with multivariate decompositions. It is an extension of the system for improving prediction results in a multi-model approach using ICA, PCA, and NMF methods. This can also be considered a method for model aggregation or multidimensional filtering of components that interfere with forecast results. We present the entire process in connection with the blind separation problem, pointing out possible useful inspirations and significant limitations of such interpretations.

Keywords: prediction, deep learning models, multidimensional decompositions, neural networks

JEL classification: C02, C50