

Gospodarka, społeczeństwo i rynki finansowe w dobie wyzwań współczesnego świata

Redakcja naukowa

Adrianna MASTALERZ-KODZIS

Katarzyna ZEUG-ŻEBRO



Wydawnictwo Uniwersytetu Ekonomicznego
w Katowicach

Gospodarka, społeczeństwo i rynki finansowe w dobie wyzwań współczesnego świata

Redakcja naukowa

Adrianna Mastalerz-Kodzis

Katarzyna Zeug-Żebro



Katowice 2023

Praca naukowa

Komitet redakcyjny

Janina Harasim (przewodnicząca), Monika Ogrodnik (sekretarz),
Małgorzata Pańkowska, Jacek Pietrucha, Irena Pyka, Anna Skórska,
Maja Szymura-Tyc, Artur Świerczek, Tadeusz Trzaskalik, Ewa Ziemia

Recenzent

Józef Stawicki

Redakcja i korekta językowa

Patrycja Keller

Skład tekstu

Daria Liszowska

Projekt okładki

Janusz Gumulak

Ilustracja na okładce © videoflow – Photogenica

ISBN 978-83-7875-829-7

doi.org/10.22367/uekat.9788378758297

© Copyright by Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach 2023



Publikacja na licencji Creative Commons Uznanie autorstwa 4.0 Międzynarodowa
(CC BY 4.0), <https://creativecommons.org/licenses/by/4.0/legalcode.pl>



WYDAWNICTWO UNIWERSYTETU EKONOMICZNEGO W KATOWICACH
ul. 1 Maja 50, 40-287 Katowice, tel.: +48 32 257-76-33
www.wydawnictwo.ue.katowice.pl, e-mail: wydawnictwo@ue.katowice.pl
Facebook: [@wydawnictwouekatowice](https://www.facebook.com/wydawnictwouekatowice)

Spis treści

Wstęp	5
-------------	---

Część I

Analiza tempa zmian oraz zakresu rozwoju społeczno-gospodarczego w Polsce w wybranych krajach UE w latach 2000-2021

1. Wpływ kryzysu finansowego 2007-2009 oraz pandemii SARS-CoV-2 na poziom wybranych wskaźników makroekonomicznych – ilościowa analiza danych dla Polski w latach 2000-2021 (<i>Adrianna Mastalerz-Kodzis</i>).....	8
2. Zastosowanie LHDI do oceny rozwoju ekonomiczno-społecznego w województwach Polski w latach 2005-2019 (<i>Monika Miśkiewicz-Nawrocka</i>)	25
3. Analiza rozwoju społecznego województw w Polsce z uwzględnieniem okresu przed i w czasie pandemii COVID-19 (<i>Anna Janiga-Ćmiel</i>)	41
4. Zastosowanie metod przestrzennych w analizie zjawiska przestępczości (<i>Katarzyna Zeug-Żebro</i>).....	67
5. Analiza aktualnych wyzwań i zagrożeń rozwoju społeczeństwa informacyjnego w dobie pandemii COVID-19 (<i>Anna Janiga-Ćmiel</i>)	89
6. Ocena podobieństwa rozwoju przedsiębiorstw sektora MMS oraz dużych przedsiębiorstw w wybranych krajach UE w latach 2010 i 2019 za pomocą diagramu Czekanowskiego (<i>Monika Miśkiewicz-Nawrocka</i>)	104

Część II

Funkcjonowanie rynku kapitałowego w pierwszym 20-leciu XXI wieku

7. Pomiar efektywności inwestowania w dobie kryzysów XXI wieku (<i>Adrianna Mastalerz-Kodzis</i>).....	122
8. Badanie przyczynowości między stopami zmian cen metali szlachetnych a ich determinantami w obliczu procesów zachodzących we współczesnej gospodarce (<i>Katarzyna Zeug-Żebro</i>).....	135
9. Analiza szeregów czasowych kontraktów terminowych na miedź przy wykorzystaniu modelu ARIMA i GARCH z uwzględnieniem wpływu pandemii COVID-19 na wycenę surowców (<i>Łukasz Sroka</i>).....	150
10. Inwestowanie w akcje w okresie pandemii COVID-19 (<i>Ewa Pośpiech</i>)	169
11. Wpływ epidemii COVID-19 na wybór modelu regresji wielorakiej stóp zwrotu kontraktów terminowych na aluminium i ropę naftową WTI (<i>Łukasz Sroka</i>).....	184
Aneks	199

Wstęp

Gospodarka światowa w XXI wieku zmienia się bardzo dynamicznie, a zmiany te mają charakter stochastyczny. Na obserwowane wielkości w gospodarce ma wpływ wiele czynników społecznych, ekonomicznych, ale także politycznych. Zrozumienie praw oraz zasad funkcjonowania gospodarki, zależności pomiędzy wybranymi charakterystykami, pozwala na sprawne budowanie modeli ekonometrycznych, prognozowanie oraz konstruowanie możliwych scenariuszy, które mogą mieć miejsce w przyszłości.

Celem monografii jest pokazanie skali oraz kierunku zmian zachodzących w otaczającym świecie w aspekcie społecznym i ekonomicznym w pierwszym 20-leciu XXI wieku. Metodologię badań stanowią wybrane narzędzia statystyczne i ekonometryczne. Posłużono się metodami statystyki opisowej, matematycznej oraz przestrzennej. Wykorzystano wybrane metody ekonometrii klasycznej, przestrzennej, dynamicznej oraz finansowej.

Monografia składa się z dwóch części zasadniczych.

W pierwszej z nich, w kolejnych sześciu rozdziałach, omówiono zmiany zachodzące w sferze społeczno-gospodarczej w Polsce i na świecie. Analizowano zmiany wiodących wskaźników makroekonomicznych i ich wpływ na rozwój gospodarczy w Polsce, obliczono miernik rozwoju społeczno-gospodarczego dla województw Polski, wskazując na zróżnicowanie w aspekcie składowych wskaźnika LHDI. W szczególności zwrócono uwagę na zmiany wartości wskaźników rozwoju w dwóch okresach – przed i po pandemii COVID-19. Analizowano zjawisko przestępczości za pomocą mierników statystyki i ekonometrii przestrzennej, a także badano wyzwania oraz zagrożenia, które stały się realne w dobie pandemii w aspekcie funkcjonowania i rozwoju społeczeństwa informacyjnego. Badano także rozwój sektora mikro-, średnich i małych przedsiębiorstw w krajach członkowskich Unii Europejskiej.

Druga część monografii zawiera pięć rozdziałów, w których zamieszczono analizy dotyczące rynku kapitałowego. Porównano funkcjonowanie wybranych światowych rynków kapitałowych. Ocenie podlegała efektywność i ryzyko inwestowania w akcje, wybrane metale szlachetne, między innymi złoto i srebro, miedź, aluminium, ale także badano ryzyko inwestowania w ropę naftową. Za pomocą wybranych metod analizy szeregów czasowych oraz grupowania wskazano inwestycje, które cechują się znaczącą efektywnością także w czasie dużych zmian na rynkach kapitałowych.

Według autorów, badanie zależności pomiędzy charakterystykami społeczno-ekonomicznymi stanowi istotny element procesu poznania złożoności funkcjonowania systemu gospodarek na świecie. Autorzy mają nadzieję, że zaprezentowane wnioski wynikające z badań empirycznych pozwolą na zapisanie nowych spostrzeżeń dotyczących funkcjonowania gospodarki Polski i wybranych gospodarek światowych, w tym także rynków kapitałowych, oraz przyczynią się do podejmowania właściwych decyzji na różnych poziomach zarządzania gospodarką.

Część I

Analiza tempa zmian oraz zakresu rozwoju społeczno-gospodarczego w Polsce w wybranych krajach UE w latach 2000-2021

1. Wpływ kryzysu finansowego 2007-2009 oraz pandemii SARS-CoV-2 na poziom wybranych wskaźników makroekonomicznych – ilościowa analiza danych dla Polski w latach 2000-2021

(Adrianna Mastalerz-Kodzis)

1.1. Wprowadzenie

Dwudziesty pierwszy wiek w Europie i na świecie cechuje się szybkim tempem rozwoju wielu państw, w tym także Polski. Analiza wybranych wskaźników makroekonomicznych pokazuje intensywność i kierunek tych zmian oraz daje możliwość zareagowania na negatywne trendy, ale także pozwala na wspomaganie zrównoważonego i harmonijnego rozwoju gospodarczego.

Rozwój gospodarczy państwa, regionu jest procesem traktowanym jako realizacja procesu stochastycznego, na który wpływa wiele czynników natury ekonomicznej, społecznej, ale także demograficznej. Liczne czynniki są ze sobą skorelowane, zatem zmiana jednego z nich oddziałuje na pozostałe wielkości. Rozważanie rozwoju gospodarczego danego państwa w kontekście kryzysów finansowych czy pandemii jest trudne, dotychczas stabilne warunki zewnętrzne ulegają bowiem zmianie, proces zostaje wytrącony ze stanu stacjonarnego, lub quasi-stacjonarnego, co powoduje skutki, które nie do końca da się przewidzieć.

Na kryzys finansowy, który wystąpił w latach 2007-2009, gospodarki światowe zareagowały, jego skutki zostały złagodzone. Kryzys ten nauczył ekonomistów radzenia sobie z przeciwnościami. Czy można zatem wyciągnąć wnioski z tego kryzysu i przełożyć pozytywne działania w kierunku zapobiegania negatywnym skutkom pandemii z lat 2020-2021?

W pracy do zobrazowania przebiegu procesu rozwoju gospodarczego posłużą wybrane wskaźniki makroekonomiczne, między innymi: PKB per capita, stopa bezrobocia rejestrowanego, przeciętne miesięczne nominalne wynagrodzenie brutto w sektorze przedsiębiorstw oraz przeciętna miesięczna nominalna emerytura i renta brutto z pozarolniczego systemu ubezpieczeń społecznych, ale także dochody i wydatki budżetu państwa, import i eksport towarów, wielkość handlu wewnętrznego, zadłużenie sektora finansów publicznych, nakłady inwestycyjne, sprzedaż detaliczna towarów oraz wskaźnik ogólnego klimatu koniunktury gospodarczej.

Celem niniejszego rozdziału jest pokazanie zmian jakie miały miejsce w okresie 1.01.2000-31.12.2021 w kontekście wskaźników makroekonomicznych, ze szczególnym uwzględnieniem kryzysu finansowego, który wystąpił w latach 2007-2009, oraz pandemii koronawirusa, notującej swój początek w Europie w 2020 roku. Można zadać pytanie, czy w istotnym stopniu zmieniły się wartości zmiennych makroekonomicznych w analizowanym okresie, bezpośrednio po tym okresie oraz czy było to spowodowane kryzysami i jaki miało to skutek społeczno-ekonomiczny. Czy rozmiar i skutki tych dwóch kryzysów są porównywalne w kontekście wskaźników makroekonomicznych?

Praca składa się z trzech zasadniczych podrozdziałów: omówienia kryzysu finansowego z lat 2007-2009, okresu pandemicznego oraz analizy statystycznej wybranych wskaźników makroekonomicznych w latach 2000-2021. Na końcu zamieszczono wnioski i podsumowanie.

1.2. Przyczyny i skutki kryzysu finansowego 2007-2009

Ogólnosiwiatowy kryzys gospodarczy na rynkach finansowych i bankowych, który wystąpił w latach 2007-2009, został zapoczątkowany zapaścią na rynku pożyczek hipotecznych w Stanach Zjednoczonych. Banki udzielały kredytów wysokiego ryzyka osobom o niewystarczających zdolnościach kredytowych. Było to bezpośrednią przyczyną załamania się funkcjonowania światowego systemu finansowego (Dorosz, 2014; Kołodko, 2010). Zaczęto obniżać stopy procentowe, zaś inflacja wzrastała. Spowodowało to przeniesienie lokat na rynek nieruchomości. Niskie stopy procentowe zachęcały inwestorów do zaciągania kredytów hipotecznych. Zaczęto zarabiać na nieruchomościach. Napędziło to tak zwaną bańkę spekulacyjną, czyli proces niezrównoważonego wzrostu cen dóbr na rynku. Według Alana Greenspana (2014, s. 79), „przyczyny baniek i rynki, na których się pojawiają, są bardzo różne, lecz schematy ich rozwoju są bardzo zbliżone”.

Następnie w Stanach Zjednoczonych zaczęto podnosić stopy procentowe, co spowodowało także podniesienie rat kredytów hipotecznych. Znaczna część kredytobiorców stała się wówczas niewypłacalna. Ceny nieruchomości zaczęły spadać.

Ogólnosiwiatowy kryzys finansowy, który miał miejsce w latach 2007-2009 jest uważany za największy po kryzysie z lat 30. XX wieku. W początkowym okresie omijał on Polskę, jednakże z czasem i tutaj banki znacznie ograniczyły udzielanie kredytów, zaś wartość złotego osłabła. Nastąpiło spowolnienie gospodarcze oraz zwiększyła się stopa bezrobocia. Pogorszyła się też jakość kredytów, zarówno dla przedsiębiorstw, jak i dla osób fizycznych. Nastąpiły duże zmiany w wielkości i strukturze konsumpcji, popytu, podaży (Kołodko, 2010).

W związku z zaistniałą sytuacją władze w Polsce podejmowały szereg działań na różnych poziomach gospodarki. Między innymi Urząd Komisji Nadzoru Finansowego miał za zadanie zapewnić płynność finansową polskim bankom, zapobiegać odpływom środków pieniężnych do innych spółek kapitałowo powiązanych z bankami. Polski bank centralny, czyli Narodowy Bank Polski, zobowiązał się do prowadzenia standardowej polityki pieniężnej, a także do wprowadzenia mechanizmów tymczasowej substytucji rynku. Ministerstwo Finansów ogłosiło dla Polski tak zwany Plan stabilności i rozwoju, którego celem było podniesienie gwarancji depozytów bankowych, stworzenie mechanizmu wsparcia instytucji finansowych, a także wprowadzenie mechanizmu rekapitalizacji zagrożonych instytucji finansowych oraz rozszerzenie systemu gwarancji rządowych. Powyższe działania spowodowały, że Polska nie odczuła tak bardzo kryzysu finansowego, jak np. Grecja czy też Hiszpania.

Kryzys finansowy doprowadził do upadku wielu instytucji finansowych na świecie, liczne banki miały problem z płynnością, także w Polsce. Znacząco wzrosły wydatki państw. Najbardziej istotnym negatywnym skutkiem kryzysu było załamanie się handlu światowego, w tym spadek konsumpcji, załamanie się rynku inwestycji, wzrost stopy bezrobocia. Skutki kryzysu dotkliwie odczuły zarówno gospodarstwa domowe, jak i przedsiębiorstwa (Dorosz, 2014).

Szczegółowa analiza makroekonomicznych danych ilościowych dotyczących kryzysu finansowego na tle pierwszego 20-lecia XXI wieku znajduje się w kolejnych podrozdziałach pracy.

1.3. Społeczno-gospodarcze skutki pandemii SARS-CoV-2

Jesienią 2019 roku świat obiegła informacja o pojawieniu się wirusa w chińskim mieście Wuhan, a już w początkach 2020 roku wirus ten został także wykryty w Europie. Od tego czasu sytuacja społeczno-gospodarcza zarówno w Polsce, jak i na całym świecie uległa zmianie.

Analizując dane dotyczące liczby zachorowań w poszczególnych regionach świata można zauważyć okresy, w których pandemia przybierała na sile, regiony, w których zachorowalność była bardzo duża. Szczegółowe dane można na bieżąco monitorować na przykład na stronie internetowej Światowej Organizacji Zdrowia (<https://www.who.int>) oraz na wielu innych, ogólnodostępnych stronach internetowych. Biorąc pod uwagę dane na dzień 31 grudnia 2021, skumulowana liczba potwierdzonych przypadków zachorowań na świecie wynosiła 287 051 488 osób, zaś 5 438 920 osób zmarło. Sytuacja dotycząca zachorowań była odmienna w różnych regionach świata oraz zmieniała się w czasie, jednak swoim zasięgiem dotknęła każdy kontynent kuli ziemskiej.

Pandemia wywołała wiele negatywnych skutków społecznych oraz gospodarczych, co zostanie pokazane w kolejnych podrozdziałach pracy. Celem ograniczenia rozprzestrzeniania się wirusa wprowadzono liczne obostrzenia, które jednak nie spowodowały cofnięcia się pandemii. Kolejne fale wirusa COVID-19 nie omijały także Polski.

Ograniczenia w działalności gospodarczej, praca zdalna oraz zdalne nauczanie spowodowały znaczące zmiany w gospodarce oraz w codziennym życiu Polaków. Podobnie jak w przypadku kryzysu z lat 2007-2009, banki oferowały niskie oprocentowanie kredytów hipotecznych, co skutkowało ożywieniem na rynku nieruchomości. Widoczne stało się znacznie większe zainteresowanie kupnem nieruchomości, zarówno na rynku pierwotnym, jak i wtórnym. Ceny nieruchomości istotnie wzrosły w okresie pandemii. Pytanie, co stanie się w przypadku podniesienia stóp procentowych, a tym samym zwiększenia obciążenia kredytobiorców. Czy kredytobiorcy będą w stanie nadal regularnie spłacać swoje zobowiązania? Wydaje się, że tak, jednak istotnym elementem będzie także pomoc państwa. Pomoc socjalna oferowana Polakom oraz przedsiębiorstwom w czasie pandemii związana z brakiem możliwości wykonywania pracy bądź koniecznością opieki nad dziećmi spowodowała znaczny dopływ gotówki na rynek, wzrost popytu na wybrane dobra.

Można zadać pytanie, czy w sferze społecznej i gospodarczej istnieją analogie pomiędzy kryzysem 2007-2009 a pandemią oraz jak wykorzystać wiedzę, którą niosą dane makroekonomiczne odnotowane po kryzysie finansowym, aby zmniejszyć ekonomiczne negatywne skutki pandemii. Obecnie sytuacja w Polsce w wielu aspektach gospodarki przypomina sytuację z lat 2007-2009 i późniejszych. Biorąc pod uwagę zmiany makroekonomiczne po kryzysie finansowym, można prognozować, jakie zmiany czekają Polskę i Polaków po okresie pandemii.

1.4. Analiza wybranych wielkości makroekonomicznych dla Polski w latach 2000-2021


Do analizy posłużą dane zaczerpnięte z bazy Głównego Urzędu Statystycznego za okres 1.01.2000-31.07.2021. Aby dokładnie pokazać okresy kryzysów, najczęściej brano pod uwagę dane miesięczne, jednakże podczas poniższych analiz występują także dane o częstotliwości rocznej.

1.4.1. Wpływ kryzysów na PKB per capita w Polsce

W rachunkach narodowych jako jeden z podstawowych mierników efektów pracy społeczeństwa danego kraju wykorzystywany jest produkt krajowy brutto. PKB opisuje zagregowaną wartość dóbr oraz usług finalnych wytworzonych


przez narodowe, a także zagraniczne czynniki produkcji na terenie danego kraju w ściśle określonym przedziale czasowym, najczęściej tym przedziałem jest rok (Taylor, Mankiw, 2009). PKB jest miernikiem wielkości gospodarki (Begg, i in., 2007). Wzrost bądź też spadek realnego PKB, a także jego dynamika są powszechnie stosowaną miarą wzrostu gospodarczego.

PKB per capita, czyli PKB w przeliczeniu na jednego mieszkańca, jest jedną z miar zamożności społeczeństwa. Często w opracowaniach społeczno-gospodarczych stosuje się jako miarę dobrobytu wielość PKB per capita. Na rysunku 1.1 przedstawiono PKB na 1 mieszkańca dla Polski w cenach bieżących w latach 2000-2020 oraz teoretyczną funkcję trendu uzyskaną metodą najmniejszych kwadratów wraz jej ze stopniem dopasowania do danych empirycznych (Barczak, Biolik, 2008). Zmienna x symbolizuje rok (rok 2000 to rok pierwszy, zaś zmienna y oznacza PKB na mieszkańca w zł). Na rysunku 1.2 dodano prognozowaną przez Główny Urząd Statystyczny wartość PKB per capita w roku 2021. Dodanie obserwacji prognozowanej wpłynęło na zmianę współczynnika funkcji trendu. Współczynnik kierunkowy linii trendu znacząco się zwiększył. Z powodu pandemii PKB per capita osiągnął jednak niższe wartości aniżeli wynikało to z prognozy GUS.



Rys. 1.1. PKB na 1 mieszkańca dla Polski w cenach bieżących w latach 2000-2020

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>




Rys. 1.2. PKB na 1 mieszkańca dla Polski w cenach bieżących w latach 2000-2020, prognoza PKB na 1 mieszkańca według GUS na 2021 rok

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bd1.stat.gov.pl>

Zauważalny jest wzrost PKB na mieszkańca rok do roku, jednak tempo wzrostu wyraźnie zmalało w latach 2011-2016, po kryzysie finansowym z lat 2007-2009. Tendencja wzrostowa lat 2017-2019 z pewnością nie będzie już tak silna w kolejnych latach ze względu na pandemię koronawirusa.

W celu wykonania porównań międzynarodowych, wielkość PKB przelicza się według bieżącego kursu wymiany, na przykład na dolary amerykańskie, lub też według tak zwanego parytetu siły nabywczej, który pokazuje realną wartość dochodu obywateli danego kraju.

Na rysunku 1.3, zaczerpniętym ze strony Międzynarodowego Funduszu Walutowego, można zobaczyć relacje pomiędzy PKB w dolarach międzynarodowych według parytetu siły nabywczej dla wybranych państw europejskich. Na tym wykresie bardzo wyraźnie widać skutki kryzysu w latach 2007-2009, spadek siły nabywczej pieniądza, duży spadek PKB w przypadku Grecji i Portugalii. Na wykresie widoczny jest kryzys związany z pandemią koronawirusa – rok 2020. Międzynarodowy fundusz walutowy wyznaczył także prognozę PKB według parytetu siły nabywczej na lata 2021-2025 – wynik prognozy także zamieszczono na wykresie. Wartości niższe aniżeli w roku 2019 będą najprawdopodobniej występować do roku 2022, w zależności od kraju. Zatem skutki gospodarcze kryzysu jeszcze długo będą odczuwalne zarówno dla mieszkańców, jak i dla przedsiębiorców. Według wstępnych szacunków ekonomistów, po 2022 roku najprawdopodobniej nastąpi wzrost PKB według parytetu siły nabywczej.




Rys 1.3. PKB w dolarach międzynarodowych według parytetu siły nabywczej, dane za lata 2004-2020, prognoza na lata 2021-2025 (dane roczne)

Źródło: Na podstawie danych MFW zaczerpniętych ze strony <https://300gospodarka.pl/news/mfw-czechy-pkb-per-capita> (październik 2020).

1.4.2. Zmiany na rynku pracy w Polsce w obliczu kryzysów

Rynek pracy jest w znacznym stopniu zależny od kryzysów. Jako wskaźnik tego rynku posłuży stopa bezrobocia rejestrowanego podawana przez GUS w procentach. Na rysunku 1.4 pokazano wartości tej stopy w ujęciu miesięcznym w okresie styczeń 2000 – lipiec 2021.



Rys 1.4. Stopa bezrobocia rejestrowanego w Polsce w okresie styczeń 2000 – lipiec 2021

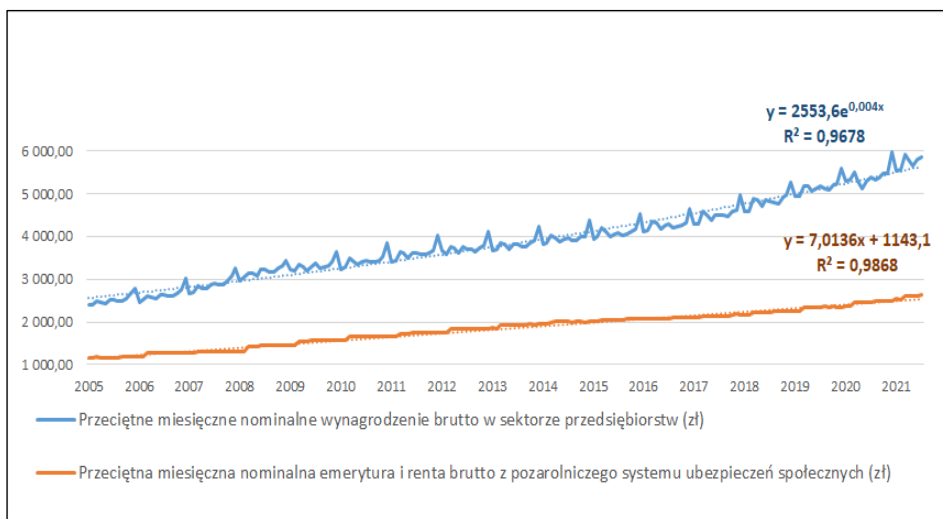
Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bd1.stat.gov.pl>

Dane brane pod uwagę mają częstotliwość miesięczną, więc bardzo wyraźnie widać sezonowość. W okresie wiosenno-letnim stopa bezrobocia spada, zaś w okresie jesienno-zimowym wzrasta. Badając tendencje roczne, bez uwzględniania sezonowości, w Polsce w latach 2000-2004 stopa ta była w trendzie wzrostowym, w latach 2005-2008 w trendzie spadkowym. Po kryzysie finansowym 2007-2009 zauważa się wzrost bezrobocia rejestrowanego do roku 2013. W październiku 2008 roku wynosiło 8,8%, natomiast już w lutym 2013 osiągnęło poziom 14,4%. Było to jednym ze skutków kryzysu. Następnie od 2014 roku do 2020 bezrobocie spadało, aż w październiku 2019 osiągnęło poziom 5,0%. Bardzo widoczny jest skutek pandemii koronawirusa od jesieni 2020 roku oraz w pierwszej połowie 2021 roku. Wyraźnie widać wzrost stopy bezrobocia rejestrowanego pomimo licznych tarcz ochronnych oferowanych przez państwo polskie. W styczniu 2021 roku bezrobocie wyniosło 6,5 %. Z powodu kolejnej fali koronawirusa oraz uwzględniając sezonowość rynku pracy, jesienią 2021 roku nastąpił wzrost stopy bezrobocia.

Po kryzysie finansowym wzrost bezrobocia notowano jeszcze przez kolejne 4 lata. Czas pokaże, czy i jak długo będzie utrzymywać się wyższy poziom bezrobocia po pandemii. W czasie pierwszej i drugiej fali koronawirusa państwo oferowało wiele udogodnień, tarcz dla pracodawców i pracowników, co miało znaczący wpływ na wartość stopy bezrobocia rejestrowanego. Ponadto wiele firm podczas pandemii zaczęło pracować zdalnie – ich pracownicy pracują w domach, co znacznie obniżyło koszty pracy. Należy się spodziewać, że część z pracodawców będzie dążyło do kontynuowania tego trendu. Liczne sklepy oferują także sprzedaż internetową, co także ograniczyło zapotrzebowanie na pracowników w sektorze handlu. Ten trend ograniczania zatrudnienia jest widoczny w wielu sektorach gospodarki oraz w administracji. Ponadto takie działania są uzasadnione także szybkim rozwojem technologii informacyjno-komunikacyjnych oraz większym dostępem do Internetu gospodarstw domowych. Zatem biorąc pod uwagę powyższe rozważania, można stwierdzić, że w kolejnych latach nastąpi wzrost stopy bezrobocia rejestrowanego w Polsce.

Biorąc pod uwagę rynek pracy trzeba także odnieść się do wysokości wynagrodzeń. Na rysunku 1.5 zamieszczono przeciętne miesięczne nominalne wynagrodzenie brutto w sektorze przedsiębiorstw oraz przeciętną miesięczną nominalną emeryturę i rentę brutto z pozarolniczego systemu ubezpieczeń społecznych.

Przeciętne miesięczne wynagrodzenie pozostawało w trendzie wzrostowym w latach 2005-2020. Z poziomu 2385,27 zł w styczniu roku 2005 wzrosło do 5973,75 zł w grudniu 2020 roku. Analizując dane, nie zauważono znaczącej zmiany w wielkości miesięcznych wynagrodzeń wywołanych kryzysem lat 2007-2009. Podnoszenie minimalnej płacy w Polsce także w dużej mierze zniwelowało skutki pandemii jednakże widoczna jest zmiana (obniżenie wynagrodzeń) w roku 2020.




Rys. 1.5. Przeciętne miesięczne nominalne wynagrodzenie brutto w sektorze przedsiębiorstw oraz przeciętna miesięczna nominalna emerytura i renta brutto z pozarolniczego systemu ubezpieczeń społecznych w Polsce w okresie styczeń 2005-lipiec 2021

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

1.4.3. Kondycja budżetu państwa


Przeanalizowano dochody oraz wydatki budżetu państwa w okresie styczeń 2000 – czerwiec 2021. Dane zaprezentowano na rysunku 1.6. Można zauważyć wzrost rocznych dochodów (dane z grudnia każdego roku), ale także towarzyszący temu zjawisku wzrost wydatków. Najwyższe dochody odnotowano w roku 2020, wynosiły one 400 535,3 mln zł, zaś wydatki w tym samym roku – 414 273 mln zł. Można zauważyć także, że wydatki w czerwcu 2021 (205 979,6 zł) roku są znacznie niższe aniżeli wydatki w czerwcu 2020 roku (214 512,3), co jest skutkiem pandemii. Można zauważyć także znaczny wzrost wydatków w kolejnych trzech latach po kryzysie finansowym (2008-2010). Usunięcie ekonomicznych skutków pandemii również będzie wymagać zwiększonych wydatków budżetowych w kolejnych latach po pandemii.



Rys. 1.6. Dochody oraz wydatki budżetu państwa w okresie styczeń 2000 – czerwiec 2021

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

Warto także pokazać wykres salda budżetowego w badanym okresie – rysunek 1.7.




Rys. 1.7. Saldo budżetu państwa w okresie styczeń 2000 – czerwiec 2021

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

Wynik budżetu państwa dla większości okresów ma wartość ujemną, co oznacza, że wydatki były większe od dochodów. Po kryzysie finansowym z lat 2007-2009 można zauważyć w roku 2011 znaczącą wartość ujemną salda w grudniu 2011 – wynosiła ona 44 591,3 mln zł na minusie. Ujemnym saldem zakończył się także rok pandemii 2020 – wartość salda to 84 980, 5 mln zł na minusie.

Rysunek 1.8 przedstawia zadłużenie sektora finansów publicznych Polski w mln zł w latach 2000-2019. Po okresie kryzysu finansowego, w 2013 roku, zadłużenie wynosiło ponad 882 mln zł. W roku 2019 wartość zadłużenia wynosiła już ponad 990 mln zł. Było to spowodowane zaangażowaniem się państwa w niwelowanie skutków kryzysów. Po kryzysie finansowym dług malał w 2014 roku, w kolejnych latach wzrastał. Przewiduje się, że jeszcze przez kilka lat Polska będzie odczuwać skutki kryzysu związanego z COVID-19, zatem wartość zadłużenia będzie wzrastać. Z zadłużeniem będą musiały zmierzyć się przyszłe pokolenia Polaków.

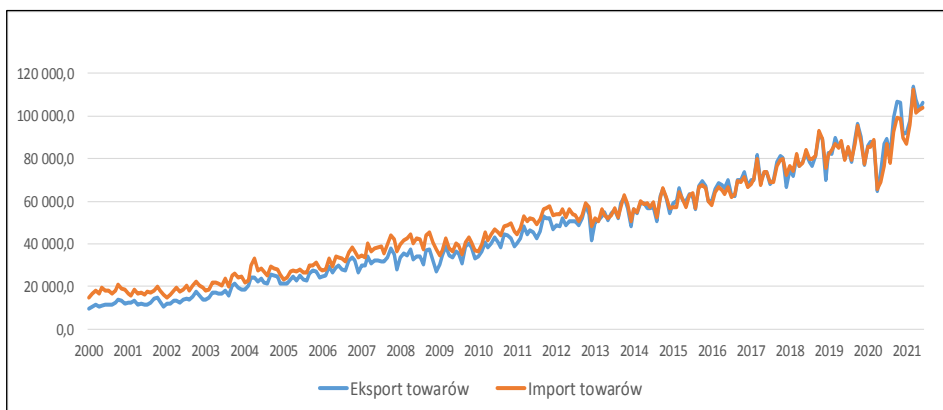


Rys. 1.8. Zadłużenie sektora finansów publicznych w mln zł

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>


1.4.4. Handel zagraniczny Polski w dobie kryzysu

Kryzys finansowy oraz pandemia znacząco wpłynęła także na rozmiar handlu. Na rysunku 1.9 zaznaczono eksport oraz import towarów w cenach bieżących w mln zł dla Polski. Skutki kryzysu finansowego wyraźnie widać w latach 2009-2012. Po kryzysie w Stanach Zjednoczonych, w Polsce eksport i import zmalały w kolejnych latach.



Rys. 1.9. Eksport oraz import towarów w cenach bieżących w mln zł dla Polski w okresie styczeń 2000 – czerwiec 2021

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>




Rys. 1.10. Saldo obrotów towarowych handlu zagranicznego ogółem w mln zł dla Polski w okresie styczeń 2000-czerwiec 2021 (dane miesięczne GUS)

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

W latach 2000-2012 saldo obrotów handlu zagranicznego było ujemne. Od roku 2013 saldo przyjmowało także wartości dodatnie. Warto zwrócić uwagę za wielkość salda w czerwcu 2020 roku, wówczas saldo obrotów osiągnęło maksymalną dodatnią wartość i wyniosło 10 448,8 mln zł (rysunek 1.10).

Dynamika eksportu towarów wyraźnie zmalała w czasie kryzysu finansowego, w latach 2007-2009, w roku 2009 odnotowano ujemny wskaźnik eksportu (rysunek 1.11, dane roczne). W czasie koronakryzysu także zanotowano wiele luk w łańcuchach dostaw.




Rys. 1.11. Dynamika eksportu towaru dla Polski w latach 2000-2020

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

1.4.5. Handel wewnętrzny w czasach kryzysów

Handel wewnętrzny można scharakteryzować poprzez analizę danych dotyczących sprzedaży detalicznej towarów ogółem. Na rysunku 1.12 przedstawiono dynamikę sprzedaży w latach 2000-2020. Skutki kryzysu finansowego z lat 2007-2009 były widoczne w Polsce w latach 2009-2013, czyli jeszcze cztery lata po kryzysie. W roku 2020 spadła sprzedaż detaliczna w Polsce w związku z koronakryzysem. Najprawdopodobniej jeszcze kilka lat ta tendencja będzie się utrzymywać. Jest to związane z niepewną sytuacją ludności, pracowników i przedsiębiorców, brakiem pracy, stresem związanym z chorobą COVID-19. Nawyki konsumpcyjne ulegają zmianie w związku z zagrożeniem epidemicznym. Także podaż towarów na rynku w czasie pandemii zmieniała się. Zmalała dostępność niektórych dóbr, na przykład nowych samochodów, w czasie kolejnych fal pandemii także dostępność niektórych usług była znacząco ograniczona (gastronomia, hotelarstwo, usługi kosmetyczne i fryzjerskie).




Rys. 1.12. Zmiany sprzedaży detalicznej towarów ogółem w Polsce w latach 2000-2020 (rok poprzedni = 100)

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

1.4.6. Wysokość nakładów inwestycyjnych w czasie kryzysu

Skutkiem globalnego kryzysu finansowego było także zmniejszenie nakładów inwestycyjnych w Polsce (rysunek 1.13).




Rys. 1.13. Nakłady inwestycyjne w cenach bieżących dla Polski w mln zł

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

W latach 2008-2009 nastąpiło spowolnienie wzrostu nakładów, zaś w roku 2010 wartość nakładów inwestycyjnych zmalała w porównaniu z rokiem poprzednim. Tendencję spadkową odnotowano także w latach 2012-2013. Pandemia COVID-10 także spowodowała zmniejszenie nakładów na inwestycje w 2022 roku, najprawdopodobniej w kolejnych latach to spowolnienie będzie jeszcze widoczne.

1.4.7. Wskaźnik ogólnego klimatu koniunktury gospodarczej w dobie kryzysów

Miernikiem stanu gospodarki publikowanym przez GUS jest wskaźnik ogólnego klimatu koniunktury gospodarczej. Jest to wskaźnik syntetyczny, obliczany jako średnia arytmetyczna sald odpowiedzi na pytania z ankiety miesięcznej, dotyczącej bieżącej i przewidywanej sytuacji gospodarczej przedsiębiorstw. Gdy jego wartość jest większa od zera, odnotowywany jest tzw. dobry klimat koniunktury. Natomiast w przypadku wartości ujemnej, klimat oceniany jest jako zły, niepokojący.



Rys. 1.14. Wskaźnik ogólnego klimatu koniunktury gospodarczej

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://bdl.stat.gov.pl>

Dla danych za okres styczeń 2000 – czerwiec 2022 zebrano wielkości wskaźnika dotyczące trzech wiodących sektorów: przetwórstwa przemysłowego, budownictwa oraz dla sektora handlu i naprawy pojazdów samochodowych (rysunek 1.14). Dla sektora budowlanego bardzo wyraźna jest sezonowość. W Polsce po kryzysie finansowym, w roku 2009, wartości tego wskaźnika zmalały dla wszystkich analizowanych obszarów działalności. Wskaźnik ten już nie osiągał wartości z lat 2003-2008 dla przetwórstwa przemysłowego oraz budow-

nictwa. Kolejny kryzys związany z pandemią jeszcze bardziej pomniejszył wartości wskaźnika we wszystkich badanych obszarach. W kwietniu 2020 roku osiągnął on najniższą wartość w badanym okresie. Nadal jego wartości są ujemne, co świadczy o dużym niepokoju, niepewności wśród Polaków i przedsięwzięciach działających na terenie Polski.

1.5. Podsumowanie

W pierwszym 20-leciu XXI wieku można odnotować dwa wielkie kryzysy: finansowy z lat 2007-2009 oraz spowodowany pandemią wirusa SARS-CoV-2, zapoczątkowany w roku 2020. Zmiany spowodowane tymi kryzysami w gospodarce światowej są odczuwalne w każdym kraju na świecie, także w Polsce.

Światowa globalizacja jest procesem pożądanym ze względu na rozwój państw i kultur, jednakże przyczynia się ona także do szybszego rozprzestrzeniania się negatywnych zjawisk w gospodarce. Kryzys finansowy, który został zapoczątkowany w Stanach Zjednoczonych pod koniec pierwszego dziesięciolecia, wpłynął na wiele wskaźników makroekonomicznych w większości państw na świecie. W Polsce obserwuje się jego skutki analizując PKB, rynek pracy, rynek inwestycji, wielkość handlu zagranicznego oraz stan deficytu państwa. Podobne skutki można także obserwować po pierwszym roku pandemii SARS-CoV-2. Duże zmiany na rynku pracy, znaczące wydatki państwa oraz pogorszenie wskaźnika ogólnego klimatu koniunktury gospodarczej.

Znaczące wahania w gospodarce powodują wytrącenie się gospodarki ze stanu stabilnego, quasi-stabilnego, powodują odchylenia od wartości prognozowanych na podstawie metod ilościowych. Jednakże znając zachowanie się gospodarki po kryzysach, które wystąpiły w przeszłości, jesteśmy w stanie szybko reagować na kolejne niekorzystne zmiany, tak aby zminimalizować ich rozmiar i siłę.

Omówione w pracy dwa specyficzne, ekstremalne okresy kryzysów, chociaż mają zupełnie inne przyczyny, to jednak można wskazać ich wspólne cechy o charakterze społecznym i gospodarczym – powodują zbieżne skutki społeczno-gospodarcze, między innymi znaczne zaburzenia w funkcjonowaniu gospodarki, wytrącając ją ze stanu quasi-równowagi. Przyczyniają się także do spowolnienia wzrostu gospodarczego, zubożenia społeczeństwa oraz niepokoju związanego ze zmianami klimatu koniunktury gospodarczej. Jednakże na pewne negatywne zjawiska rządy państw nie są w stanie zareagować, nie są w stanie przeciwdziałać przyczynom ich powstania, mogą natomiast wpływać na rozmiar skutków ich negatywnego oddziaływania na gospodarkę i poziom życia ludności.

Literatura

- Barczak, A., Biolik, J. (2008). *Podstawy ekonometrii*. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Begg, D., Dornbusch, R., Fischer, S. (2007). *Makroekonomia*. Warszawa: Polskie Wydawnictwo Ekonomiczne.
- Dorosz, A. (red.). (2014). *Wpływ globalnego kryzysu finansowego na działalność wybranych sfer gospodarki*. Warszawa: Akademia Finansów i Biznesu Vistula.
- Greenspan, A. (2014). *Mapa i terytorium: ryzyko, natura ludzka, przewidywania*. Warszawa: Wydawnictwo Prószyński i S-ka.
- Kołodko, G. W. (2010). *Globalizacja, kryzys i co dalej?* Warszawa: Wydawnictwo Poltext.
- Taylor, M., Mankiw, G. (2009). *Makroekonomia*. Warszawa: PWE.

2. Zastosowanie LHDI do oceny rozwoju ekonomiczno-społecznego w województwach Polski w latach 2005-2019

(Monika Miśkiewicz-Nawrocka)

2.1. Wprowadzenie

Jednym z najpopularniejszych podejść do oceny szeroko pojętej jakości życia mieszkańców jednostek terytorialnych, uwzględniającym również pozafinansowe aspekty, jest wskaźnik HDI (Human Development Index), który jest miarą syntetyczną wykorzystywaną przez UNDP (United Nations Development Programme) do tworzenia corocznego rankingu państw na podstawie ich poziomu rozwoju społeczno-ekonomicznego. Oryginalna metodyka HDI pomiaru rozwoju społecznego uwzględnia trzy czynniki życia ludzkiego: długie i zdrowe życie, wiedzę kompetencje oraz godny standard życia. Wskaźnik HDI został stworzony, aby w ocenie poziomu rozwoju kraju podkreślić rolę ludzi i ich możliwości. Jednak należy zdać sobie sprawę, że HDI nie oddaje wszystkiego tego, co wiąże się z rozwojem społecznym i poziomem życia człowieka, ani też nie bierze pod uwagę takich kwestii, jak np. nierówność płci, nierówności rasowe, bezpieczeństwo ludności, ubóstwo.

HDI jest stosowany przez UNDP na poziomie krajowym nie uwzględniając zróżnicowania regionalnego wewnątrz krajów. Badanie lokalnych zależności jest bardzo istotne, ponieważ może pomóc w zrozumieniu przyczyn zarówno istniejących już problemów społecznych, jak i przyszłych (Laskowska, Dańska-Borsiak, 2018). Lokalny wskaźnik LHDI odnosi się do rozwoju lokalnego, który jest niezbędny dla rozwoju społeczno-ekonomicznego kraju. Rozwój lokalny oprócz czynników zewnętrznych powinien również opierać się na wykorzystaniu sił wewnętrznych regionu, które mogą przeciwdziałać powstawaniu dysproporcji pomiędzy regionami (Parysek, 2001). Polityka regionalna oprócz rozwoju ekonomicznego powinna uwzględniać również rozwój społeczny, rozumiany jako poziom dobrobytu, opieki zdrowotnej, jakości środowiska (Nelson, 2013). Do oceny rozwoju ekonomiczno-społecznego na poziomie lokalnym w literaturze można znaleźć różne podejścia (Borys, 2005; Borys & Rogala, 2008; Singh et al., 2009; Tanguaya et al., 2010). Pierwsze próby oszacowania wskaźnika HDI w ujęciu regionalnym dla Polski sięgają lat 90. XX wieku – *Raporty o Rozwoju Społecznym* (1995-1999) (Akder, 1994) i wiązały się z oceną wskaźników cząstkowych HDI, zasadnością ich stosowania oraz dostępnością danych (UNDP, 2012).

Oszacowanie HDI na poziomie lokalnym pozwala nie tylko wskazać regiony słabiej rozwinięte, ale opierając się na składowych cząstkowych, może pokazać, czy o wartości wskaźnika rozwoju decydowały zdrowie ludności, wysoka jakość edukacji, czy dobre wyniki gospodarcze (Laskowska, Dańska-Borsiak, 2018).

Celem opracowania jest ocena poziomu rozwoju społeczno-ekonomicznego województw Polski z wykorzystaniem lokalnego wskaźnika LHDI oraz jego składowych. Zbadane zostanie również, czy w badanym okresie przybierał on na sile oraz czy wraz z upływem czasu pogłębiały się różnice pomiędzy województwami czy też zacierały się.

2.2. Indeks HDI w Polsce

HDI jest miarą syntetyczną stosowaną do oceny poziomu rozwoju społeczno-ekonomicznego krajów. Opiera się na trzech istotnych elementach życia ludzkiego: długim życiu w zdrowiu, dostępie do edukacji i dostatnym standardzie życia. Co roku na podstawie wartości wskaźnika HDI oszacowanych dla wszystkich państw UNDP przygotowuje ranking krajów od najbardziej do naj słabiej rozwiniętych (UNDP, 2020). Obecnie HDI jest szacowany jako średnia geometryczna znormalizowanych indeksów dla każdego z trzech wspomnianych wymiarów (UNDP, 2019):

$$HDI = \sqrt[3]{LEI \cdot EI \cdot GNII}, \quad (1)$$

gdzie:

LEI – oczekiwana długość trwania życia w zdrowiu (indeks zdrowia),

EI – indeks edukacji,

GNII – PKB per capita (indeks dobrobytu).

Oczekiwana długość życia w zdrowiu jest wyrażona jako przeciętne dalsze trwanie życia noworodków. Druga cecha związana z dostępem do edukacji szacowana jest jako średnia liczby lat edukacji ludności w wieku 25 lat i więcej oraz oczekiwanej liczby lat edukacji dzieci rozpoczynających kształcenie. Natomiast standard życia szacowany jest w oparciu o PKB per capita (Hozer-Koćmiel, 2018). Taka konstrukcja wskaźnika pozwala uwzględnić w ocenie rozwoju społeczno-gospodarczego kluczowe aspekty, które powinny być szczególnie wspierane przez państwo.

HDI przyjmuje wartości z przedziału [0, 1] i pozwala podzielić wszystkie kraje na cztery grupy: kraje bardzo wysoko rozwinięte ($0,800 < HDI$), kraje wysoko rozwinięte ($0,700 < HDI < 0,799$), kraje średnio rozwinięte ($0,550 < HDI < 0,699$) i kraje słabo rozwinięte ($HDI < 0,550$) (Hozer-Koćmiel, 2018).

Na szczycie rankingu UNDP od 2009 roku pozostaje Norwegia, dla której w 2019 roku HDI = 0,957. W 2019 roku w pierwszej dziesiątce oprócz Norwegii znalazły się Szwajcaria (0,955), Irlandia (0,955), Islandia, Hong-Kong (Chiny), Niemcy, Szwecja, Holandia i Australia. Najsłabszą sytuację odnotowano dla Nigru (0,394), Republiki Środkowoafrykańskiej (0,397) i Czadu (0,398). W 2019 roku Polska, dla której wartość HDI = 0,88 zajęła 35 lokatę w rankingu UNDP. W tabeli 2.1 przedstawiono wartości wskaźnika HDI oraz jego składowych: indeksu zdrowia (LEI), indeksu edukacji (EI) oraz indeksu standardu życia mierzonego za pomocą PKB per capita (GNII) dla Polski w latach 1990-2019 oraz pozycje Polski w rankingu UNDP na tle wszystkich krajów (Rangi świat) i na tle krajów UE (Rangi UE).

Analizując dane zawarte w tabeli 2.1 można zauważyć, że pod względem rozwoju społeczno-ekonomicznego w latach 1990-2019 w Polsce poprawiła się sytuacja społeczno-gospodarcza na tle innych krajów (wzrost o 10 pozycji w rankingu). Od 1996 roku Polska znajduje się w czwartej dziesiątce najbardziej rozwiniętych krajów rankingu UNDP. Na tle krajów UE w badanym okresie pozycja Polski była bardziej stabilna (tabela 2.1). W latach 1990-2019 Polska zajmowała 20-23 pozycję w rankingu, przy czym dominującą była 20 lokata. W tabeli 2.1 przedstawiono również pozycje Polski w rankingach wskaźnika HDI, indeksu zdrowia (LEI), indeksu edukacji (EI) oraz indeksu zamożności mierzonego za pomocą PKB per capita (GNII), utworzonych dla krajów UE w latach 1990-2019. Kraje europejskie charakteryzują się bardzo wysokim poziomem HDI i są zaliczane do krajów bardzo wysoko rozwiniętych. Dodatkowo w tabelach A1-A3 załączonych w aneksie zamieszczono rankingi krajów UE na podstawie indeksów LEI, EI i GNII w latach 1990-2019.

Na podstawie składowych HDI można zauważyć, że w badanym okresie najbardziej stabilną sytuację Polski na tle innych krajów odnotowano w zakresie edukacji, mierzonej jako średnią liczbę lat edukacji ludności w wieku powyżej 24 lat oraz oczekiwanej liczby lat edukacji dzieci rozpoczynających kształcenie. Ze względu na wartość EI w latach 1990-2004 Polska zajmowała 20-22 lokatę w rankingu (tabela 2.1), a w kolejnych latach 23-24 pozycję, wyjątkiem był rok 2012 (31 lokata), 2009 (26 lokata) i 2014 (25 lokata). Zmiany te były spowodowane zmianami w systemie edukacji zarówno w Polsce, jak i w innych krajach.

Tabela 2.1. Wskaźnik HDI oraz indeksy LEI, EI i GNII dla Polski oraz pozycje Polski w rankingu UNDP na tle wszystkich krajów oraz krajów UE w latach 1990-2019

Rok	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004
HDI	0,718	0,716	0,719	0,73	0,739	0,745	0,753	0,764	0,774	0,783	0,79	0,796	0,804	0,809	0,807
Rangi świat	45	45	43	40	39	41	39	38	36	35	38	38	36	36	37
Rangi UE	22	23	23	21	21	22	21	20	20	20	20	21	20	20	21
EI	0,665	0,671	0,676	0,698	0,71	0,713	0,723	0,741	0,756	0,77	0,777	0,787	0,804	0,811	0,796
Rangi świat	21	22	22	21	20	21	21	21	20	20	20	20	19	20	22
Rangi UE	11	12	12	11	10	11	11	11	11	11	11	11	11	12	13
LEI	0,782	0,784	0,786	0,789	0,793	0,797	0,803	0,808	0,814	0,82	0,826	0,832	0,836	0,841	0,844
Rangi świat	60	59	60	59	60	59	57	56	55	52	51	51	50	49	49
Rangi UE	23	23	23	22	22	22	22	22	21	21	21	21	21	21	21
GNII	0,712	0,698	0,699	0,705	0,718	0,727	0,737	0,746	0,753	0,76	0,768	0,77	0,773	0,778	0,782
Rangi świat	69	75	73	66	61	61	59	57	56	54	51	52	50	50	51
Rangi UE	28	28	28	26	24	24	24	24	24	24	23	24	24	25	25

Rok	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
HDI	0,813	0,819	0,824	0,829	0,834	0,84	0,845	0,842	0,856	0,858	0,863	0,869	0,873	0,877	0,88
Rangi świat	37	37	38	36	35	33	33	36	34	35	33	33	34	34	35
Rangi UE	22	21	22	21	20	20	20	21	20	21	20	20	20	20	21
EI	0,804	0,808	0,811	0,815	0,822	0,832	0,833	0,817	0,853	0,849	0,855	0,866	0,866	0,866	0,869
Rangi świat	23	23	24	24	26	24	24	31	23	25	24	23	22	23	23
Rangi UE	14	14	14	14	15	15	15	17	13	15	15	14	14	14	14
LEI	0,848	0,851	0,854	0,858	0,862	0,867	0,872	0,876	0,881	0,886	0,89	0,894	0,898	0,901	0,904
Rangi świat	49	47	47	46	46	45	45	45	44	43	42	41	40	41	41
Rangi UE	21	21	21	21	21	21	21	21	21	21	21	20	20	20	20
GNII	0,79	0,798	0,807	0,815	0,818	0,823	0,83	0,833	0,835	0,84	0,845	0,849	0,856	0,864	0,87
Rangi świat	53	56	55	54	52	48	47	48	48	46	46	45	44	43	43
Rangi UE	26	26	26	26	26	25	23	23	23	23	23	23	23	22	22

Źródło: Na podstawie raportu Human Development Data Center zaczerpniętego ze strony <https://hdr.undp.org/en/data>

W latach 1990-2019 poziom edukacji w krajach UE charakteryzował się bardzo dużym zróżnicowaniem (tabela A1). Największe zmiany w rankingu indeksów edukacji odnotowano dla Czech (pozycja 24 w 1992 roku, pozycja 8 w latach 2013-2015), Łotwy (pozycja 26 w latach 1994-1995, pozycja 10 w 2009 roku), Słowacji (pozycja 7 w latach 1990-1991, pozycja 21 w 2001 roku) i Francji (pozycja 8 w latach 1994-1996, pozycja 22 od 2017 roku). Najwyższy poziom edukacji odnotowano dla Holandii (1990-1992, 1994-1996) i Szwecji (1997-2003). Od 2006 roku pierwszą pozycję w rankingu indeksu edukacji zajmują Niemcy, a kolejne Finlandia i Dania. Natomiast na ostatniej pozycji znajduje się Chorwacja (1990-1999), Malta (2000-2003), Portugalia (2004-2017) i Rumunia (2018-2019). Na tle krajów UE Polska zajmowała pozycje od 10 do 17, a w 2019 roku pozycję 14 (tabela 2.1).

Dla Polski największe zmiany wśród składowych HDI zaobserwowano dla indeksu GNII, gdzie w 1991 roku uplasowała się na 75 pozycji, a w 2019 roku na 43 pozycji (tabela 2.1). Analizując poziom zamożności mierzony za pomocą GNI per capita dla krajów UE (tabela A3), można zauważyć, że w badanym okresie pierwszą pozycję w rankingu zajmował Luksemburg. W latach 1990-2008 dochód narodowy brutto na 1 mieszkańca w Luksemburgu był blisko dwukrotnie wyższy niż w kraju zajmującym drugą pozycję w rankingu – Dania (1990-1999, 2001-2007), Holandia (2000), Austria (2008) i od 6 do prawie 9,5 razy większy niż w krajach zajmujących ostatnią pozycję w rankingu – Polska (1990-1992), Łotwa (1993-1996), Bułgaria (1997-2008). Sytuacja odmieniła się wraz z przystąpieniem kolejnych państw do Wspólnoty Europejskiej. Różnice w dochodach narodowych na 1 mieszkańca pomiędzy krajami UE znacznie się zmniejszyły. W 2009 roku poziom GNI per capita dla Luksemburgu uległ zmniejszeniu o ok. 30%, a w pozostałych krajach wzrósł. W 2019 roku wspomniany indeks przewyższał tylko o 6% indeks GNI dla Irlandii, która od 2016 roku pozostaje na 2 pozycji w rankingu. Dla Bułgarii, która od 2008 roku zajmuje ostatnią pozycję indeks GNI per capita był nieco ponad trzykrotnie niższy niż indeks oszacowany dla Luksemburgu. Najbardziej dynamiczną sytuację odnotowano dla Irlandii, dla której indeks zamożności w 1990 roku zajmował 15 pozycję, a następnie systematycznie wzrastał i w 2015 roku zajmował 3 pozycję w rankingu, następnie spadł na 10 pozycję w 2011, a od 2016 roku Irlandia znajduje się na 2 pozycji. W Polsce w badanych latach poziom zamożności stopniowo wzrastał, co pozwoliło na zmianę pozycji w rankingu z 28 w 1990 roku na 22 w 2019 roku (tabela 2.1).

W latach 1990-2019 znacznej poprawie na tle innych krajów uległa również oczekiwana długość trwania życia w Polsce. W badanym okresie nastąpił wzrost o 20 pozycji w rankingu wskaźnika LEI, jest to spowodowane wydłużeniem o 8 lat długości trwania życia w Polsce z 70,8 do 78,7 lat. Analizu-

jąc indeks LEI dla krajów UE (tabela A2) można zauważyć, że mieszkańcy Hiszpanii, Włoch i Szwecji charakteryzują się najdłuższym życiem w zdrowiu w badanym okresie. Najgorszą sytuację odnotowano dla Łotwy, która w badanych latach zajmowała pozycje 28-27, oraz Bułgarii, która odnotowała spadek z 21 pozycji w 1990 roku na pozycję 28 w 2019 roku. Największą pozytywną zmianę odnotowano dla Irlandii, wzrost z 15 na 6 pozycję w rankingu. Natomiast Polska zajmowała 23-21 lokatę (tabela 2.1).

2.3. Lokalny HDI

Metodyka badań na poziomie lokalnym została zaproponowana w Krajowym Raporcie o Rozwoju Społecznym (UNDP, 2012) i podobnie jak HDI koncentruje się na trzech wymiarach ludzkiego życia: długości życia (zdrowie), wiedzy i kompetencjach (edukacja) oraz takim standardzie, który pozwala na godne życie (reprezentowanego przez poziom dochodu – zamożności). Lokalny HDI szacowany jest jako średnia geometryczna, zgodnie z formułą (UNDP, 2012):

$$LHDI_i = \sqrt[3]{HI_i \cdot EI_i \cdot WI_i}, \quad (2)$$

gdzie:

HI_i – wskaźnik zdrowia w i -tym regionie,

EI_i – wskaźnik edukacji w i -tym regionie,

WI_i – wskaźnik zamożności w i -tym regionie,

$i = 1, 2, \dots, n$.

Wskaźnik zdrowia dla LHDI jest mierzony za pomocą oczekiwanego dalszego trwania życia noworodka (ang. *life expectancy at birth* – LE), oraz współczynnika najczęstszej przyczyny przedwczesnych zgonów. Oczekiwane dalsze trwanie życia noworodka jest szacowane jako liczba lat, jaką ma do przeżycia nowo narodzone dziecko, natomiast za najczęstszą przyczynę zgonów w Polsce uznano zgony z powodu raka i chorób układu krążenia na 100 tys. osób (UNDP, 2012).

Wskaźnik Zdrowia (ang. *Health Index*) jest średnią geometryczną dwóch wskaźników cząstkowych: wskaźnika przeciętnego trwania życia (ang. *Life-Expectancy Index* – LEI) i zagregowanego współczynnika zgonów na nowotwory i choroby serca (ang. *Crude Death Rate Index* – CDRI).

Obliczany jest na podstawie formuły (UNDP, 2012):

$$HI_i = \sqrt{LEI_i \cdot CDRI_i}, \quad (3)$$

gdzie:

$$LEI_i = 1 + 99 \cdot \frac{LE_i - LE_{min}}{LE_{max} - LE_{min}} \quad (4)$$

$$CDRI_i = 1 + 99 \cdot \frac{CDR_{max} - CDR_i}{CDR_{max} - CDR_{min}}, \quad (5)$$

LEI_i – oczekiwana długości trwania życia noworodka w i -tym regionie,
 LE_{min}, LE_{max} – wartości odpowiednio minimalne i maksymalne oczekiwanej długości trwania życia noworodka zaobserwowane w badanych regionach w wybranym okresie,

$CDRI_i$ – współczynnik zgonów na nowotwory i na choroby układu krążenia w i -tym regionie,

CDR_{min}, CDR_{max} – wartości odpowiednio minimalne i maksymalne współczynników zgonów na nowotwory i na choroby układu krążenia zaobserwowane w badanych regionach w wybranym okresie.

Kolejną składową LHDI jest wskaźnik edukacji. Dostęp do edukacji jest bardzo istotnym składnikiem rozwoju społecznego, ponieważ jej jakość oraz osiągnięty poziom wykształcenia w istotnym stopniu wpływają na dorosłe życie człowieka i przekładają się zarówno na standard życia (dochody), jak i stan zdrowia. Ważnym czynnikiem późniejszego sukcesu ludzi w życiu dorosłym jest edukacja przedszkolna, która jest również postrzegana jako dobre narzędzie polityki gospodarczej (Rolnick, Grunewald, 2007). Na poziomie krajowym indeks edukacji wskaźnika HDI jest mierzony za pomocą średniej liczby lat edukacji ludności w wieku 25 lat i więcej oraz oczekiwanej liczby lat edukacji dzieci rozpoczynających kształcenie. Poziom edukacji można również zmierzyć za pomocą współczynnika skolaryzacji, jednak wielu autorów wskazuje, że kapitał ludzki mierzony na podstawie efektów kształcenia ma silniejszy związek ze wzrostem gospodarczym (Hanushek i Wößmann, 2012; Krueger, Lindahl, 2011; Pritchett, 2006). W *Krajowym raporcie o rozwoju społecznym* (UNDP, 2012) do oszacowania wskaźnika edukacji na poziomie lokalnym w przypadku Polski brany jest pod uwagę: odsetek dzieci uczęszczających do przedszkoli w wieku 3-4 lat oraz średni wynik egzaminu gimnazjalnego z części matematyczno-przyrodniczej.

Wskaźnik Edukacji (ang. *Education Index*) jest liczony jako średnia geometryczna dwóch wskaźników cząstkowych: Wskaźnika Edukacji Przedszkolnej (ang. *Pre-school Education Index* – PEI) i Wskaźnika Wyników Egzaminu Gimnazjalnego (ang. *Performance in Lower Secondary School Education Index* – PLSSEI) (UNDP, 2012):

$$EI_i = \sqrt[2]{PEI_i \cdot PLSSEI_i}, \quad (6)$$

gdzie:

$$PEI_i = 1 + 99 \cdot \frac{PE_i}{PE_{max}}, \quad (7)$$

$$PLSSEI_i = 1 + 99 \cdot \frac{PLSSE_i - PLSSE_{min}}{PLSSE_{max} - PLSSE_{min}}, \quad (8)$$

PE_i – odsetek dzieci w edukacji przedszkolnej (przedział wiekowy 3-4 lata) w i -tym regionie,

PE_{max} – wartość maksymalna odseteka dzieci w edukacji przedszkolnej (przedział wiekowy 3-4 lata) zaobserwowane w badanych regionach w wybranym okresie,

$PLSSE_i$ – odchylenie od średniej z wyników egzaminu gimnazjalnego w i -tym regionie,

$PLSSE_{min}, PLSSE_{max}$ – wartości odpowiednio minimalne i maksymalne odchylenia od średniej z wyników egzaminu gimnazjalnego zaobserwowane w badanych regionach w wybranym okresie.

Wskaźnik Zamożności (ang. *Welfare Index*) jest szacowany jako suma dochodu podatników ogółem przed opodatkowaniem (PIT-36, PIT-36L, PIT-37), dochodu z rolnictwa na bazie hektarów przeliczeniowych oraz suma wydatków na pomoc społeczną oraz inne zadania polityki społecznej, tj. suma świadczeń społecznych oraz wydatków na politykę rodzinną w budżetach lokalnych władz samorządowych z wyłączeniem świadczeń z tytułu klęsk żywiołowych podzielona przez liczbę mieszkańców powiatu.

Wartość wskaźnika WI_i dla rejonów można oszacować na podstawie formuły dystansowej (UNDP, 2012):

$$WI_i = 1 + 99 \cdot \frac{WI_{ei} - WI_{min}}{WI_{max} - WI_{min}}, \quad (9)$$

gdzie:

WI_{ei} – średni poziom zamożności w i -tym regionie,

WI_{min}, WI_{max} – wartości odpowiednio minimalne i maksymalne średniego poziomu zamożności zaobserwowane w badanych regionach w wybranych latach.

2.4. Lokalny HDI w województwach Polski

Przedmiotem badania były województwa Polski w latach 2005-2019. W badaniu wzięto pod uwagę następujące zmienne: oczekiwana dalsza długość trwania życia noworodka, zagregowany współczynnik zgonów na nowotwory i choroby serca, odsetek dzieci w edukacji przedszkolnej, średnia z wyników egzaminu maturalnego, średni poziom zamożności. Dane wykorzystane do analizy pochodzą z Banku Danych Lokalnych GUS (www.stat.gov.pl).

W pierwszym etapie badania oszacowano lokalny wskaźnik zdrowia HI, lokalny wskaźnik edukacji EI, lokalny wskaźnik zamożności WI, stosunek wartości maksymalnej do wartości minimalnej każdego z wybranych wskaźników oraz indeksy jednopodstawowe wyrażające zmianę poziomu wymienionych miar

w 2019 roku w stosunku do poziomu z 2005 roku. Następnie zbadano różnice pomiędzy województwami za pomocą klasycznych miar zróżnicowania odchylenia standardowego i współczynnika zmienności.

W tabeli 2.2 zaprezentowano wartości wskaźnika zdrowia HI, podstawowe statystyki dla HI oraz indeksy jednopodstawowe dla województw w latach 2005-2019. Przy obliczaniu HI wskaźniki LE dla kobiet i mężczyzn zostały zagregowane na podstawie proporcji płci wśród noworodków w Polsce.

Analizując dane zawarte w tabeli 2.2 można zauważyć, że w wybranych latach przeciętne trwanie życia w zdrowiu zwiększyło się we wszystkich województwach i największe wartości osiągnęło w 2019 roku. Oznacza to, że w 2019 roku ludzie średnio żyli w zdrowiu dłużej niż w poprzednich latach. Największe wartości przeciętnego trwania życia w badanych latach odnotowano dla województwa podkarpackiego (2005-2008, 2010-2014, 2016-2019) oraz pomorskiego (2009 i 2015), co oznacza, że mieszkańcy tych województw średnio dłużej żyją w zdrowiu niż w pozostałych. Najniższe wartości oczekiwanego trwania życia w zdrowiu odnotowano dla województw łódzkiego (2005-2014, 2017-2018) oraz świętokrzyskiego (2015-2016 i 2019). Mieszkańcy tych województw żyją przeciętnie krócej niż pozostali mieszkańcy Polski. Na podstawie indeksu jednopodstawowego scharakteryzowano dynamikę badanej zmiennej w 2019 roku w porównaniu z 2005 roku. Tempo zmian oczekiwanej długości życia w zdrowiu jest zróżnicowane, jednak dla wszystkich województw odnotowano wzrosty. Największy wzrost HI w stosunku do roku 2005 odnotowano dla województwa łódzkiego, natomiast najmniejszy dla świętokrzyskiego.

W tabeli 2.3 zaprezentowano wartości oszacowanego dla województw Polski lokalnego wskaźnika edukacji EI, podstawowe statystyki dla EI oraz indeksy jednopodstawowe w latach 2005-2019. Na podstawie danych zawartych w tabeli 2.2 można zauważyć, że w wybranych latach poziom edukacji we wszystkich województwach zwiększył się. Największe zmiany odnotowano dla podlaskiego, które w 2019 roku znalazło się na pierwszym miejscu w rankingu. Najwyższym poziomem edukacji charakteryzowało się małopolskie, które w badanych latach zajmowało 1 lub 2 pozycję w rankingu. Najniższe wartości poziomu edukacji najczęściej odnotowano dla województwa zachodniopomorskiego (2005, 2013-2015, 2018-2019) oraz warmińsko-mazurskiego (2010-2012, 2016-2017). Najbardziej stabilną sytuację odnotowano dla województwa śląskiego. Na podstawie oszacowanych indeksów jednopodstawowych wynika, że tempo zmian poziomu edukacji jest zróżnicowane, jednak dla wszystkich województw odnotowano wzrosty. Największy wzrost HI w stosunku do roku 2005 odnotowano dla podlaskiego i pomorskiego, natomiast najmniejszy dla śląskiego. Stosunek wartości maksymalnej do minimalnej zmniejsza się z 11,94 w 2005 roku do 2,10 w 2019 roku, co świadczy o tym że różnice ze względu na oczekiwaną długość życia w zdrowiu pomiędzy województwami zmniejszyły się.

Tabela 2.2. Wartości wskaźnika zdrowia HI dla województw Polski w latach 2005-2019

Województwo	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2019/2005
Dolnośląskie	33,99	32,76	32,59	29,62	33,26	46,22	48,67	44,81	49,02	55,13	48,28	57,64	50,69	47,99	56,97	1,68
Kujawsko-pomorskie	41,41	41,36	37,41	44,36	44,53	46,06	57,64	56,07	59,63	67,86	57,70	69,38	69,80	62,63	66,03	1,59
Lubelskie	35,04	40,91	37,71	38,02	39,70	43,70	48,92	52,99	55,57	63,50	57,67	56,35	60,26	60,97	66,49	1,90
Lubuskie	42,31	40,97	40,13	44,93	43,67	54,03	54,32	60,25	56,72	71,96	60,25	67,45	66,32	63,37	68,85	1,63
Łódzkie	5,10	8,43	10,20	15,09	14,45	23,11	26,60	27,00	29,23	37,17	31,93	41,40	39,97	39,71	49,92	9,80
Małopolskie	59,28	62,32	61,67	63,41	63,44	72,32	74,90	72,06	76,12	78,42	69,13	76,42	77,41	75,02	75,66	1,28
Mazowieckie	50,57	51,28	48,99	49,04	48,73	56,19	59,84	56,21	59,86	62,83	61,89	69,86	72,52	75,43	81,57	1,61
Opolskie	51,67	52,65	53,06	51,34	56,57	57,07	62,69	55,94	59,34	67,86	54,75	71,21	55,91	60,01	58,53	1,13
Podkarpackie	60,82	69,39	69,42	72,23	66,39	74,57	79,91	79,02	82,17	91,66	73,78	85,34	91,38	90,00	87,62	1,44
Podlaskie	59,72	52,90	57,71	65,09	59,87	65,42	71,31	69,85	69,89	73,68	68,58	72,97	70,00	66,75	73,89	1,24
Pomorskie	57,86	57,08	57,54	65,68	67,43	73,59	77,44	71,22	77,18	79,12	75,40	77,14	76,80	74,49	74,22	1,28
Śląskie	32,84	34,66	34,16	36,78	37,85	41,85	45,27	42,33	42,90	47,91	40,86	49,17	45,39	44,70	48,55	1,48
Świętokrzyskie	41,69	40,74	41,85	41,86	31,45	36,85	51,27	40,64	38,77	50,80	8,43	30,95	44,34	40,18	41,81	1,00
Warmińsko-mazurskie	46,70	49,57	47,52	51,96	49,96	59,85	64,73	65,10	58,73	72,96	66,18	68,09	69,25	66,79	67,96	1,46
Wielkopolskie	49,46	49,20	51,35	56,21	56,91	66,34	70,18	68,43	69,99	78,09	72,87	80,70	80,45	74,05	77,47	1,57
Zachodniopomorskie	40,86	41,65	43,39	45,45	45,51	49,76	58,12	56,80	54,80	62,56	57,05	60,73	58,89	54,36	52,50	1,28
max/min	11,94	8,23	6,81	4,79	4,67	3,23	3,00	2,93	2,81	2,47	8,94	2,76	2,29	2,27	2,10	
Średnia	44,33	45,37	45,30	48,19	47,48	54,44	59,49	57,42	58,74	66,34	56,55	64,68	64,34	62,28	65,50	
Odczylenie standardowe	13,55	13,48	13,58	14,22	13,86	13,77	13,42	13,31	13,89	13,26	16,95	14,17	13,99	13,72	12,60	
Wsółczynnik zmienności	0,31	0,30	0,30	0,30	0,29	0,25	0,23	0,23	0,24	0,20	0,30	0,22	0,22	0,22	0,19	

Źródło: Na podstawie wykonanych obliczeń, przedstawiając dane Banku Danych Lokalnych GUS, zaczerpnięte ze strony www.stat.gov.pl, do wzoru nr (3).

Tabela 2.3. Wartości wskaźnika EI dla województw Polski w latach 2005-2019

Województwo	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2019/2005
Dolnośląskie	41,56	26,52	32,08	30,08	53,63	64,47	61,57	62,28	64,78	52,82	63,32	56,32	53,94	54,10	60,99	1,47
Kujawsko-pomorskie	39,72	44,87	49,30	48,59	60,19	61,77	54,30	55,49	64,01	62,48	58,89	64,98	63,60	58,70	54,89	1,38
Lubelskie	45,66	47,51	49,08	56,91	57,61	49,88	51,85	58,56	56,71	59,30	61,62	68,07	65,14	68,48	69,08	1,51
Lubuskie	34,94	39,27	32,23	30,08	39,46	64,41	71,29	70,61	73,25	84,16	81,66	84,72	77,89	71,74	65,90	1,89
Łódzkie	50,36	59,76	56,29	55,38	62,58	64,47	66,83	62,03	64,59	67,98	70,29	75,60	77,43	69,74	69,30	1,38
Małopolskie	59,31	61,92	61,48	66,51	70,39	67,38	70,81	71,14	77,95	79,18	87,56	86,24	94,08	92,73	97,34	1,64
Mazowieckie	54,79	57,67	60,20	58,34	61,42	67,79	70,50	70,27	67,24	70,02	79,27	90,20	85,67	84,94	84,28	1,54
Opolskie	44,15	7,98	61,98	51,98	60,70	72,44	67,57	67,15	68,99	64,86	80,61	72,82	67,50	65,16	73,47	1,66
Podkarpackie	42,04	44,34	48,86	52,84	61,03	53,60	55,72	57,26	59,82	63,67	73,12	72,67	65,35	76,49	75,08	1,79
Podlaskie	47,59	49,43	54,74	59,81	59,43	55,60	68,71	69,83	66,87	76,89	74,58	79,41	81,36	80,75	91,71	1,93
Pomorskie	29,93	41,68	44,53	46,40	54,76	60,36	57,54	58,50	61,01	64,20	60,37	67,06	66,59	54,42	58,33	1,95
Śląskie	64,75	63,61	57,70	65,53	67,89	68,44	69,97	69,90	71,53	70,02	84,77	63,55	63,90	70,32	69,43	1,07
Świętokrzyskie	39,18	30,45	39,72	37,44	46,53	50,09	62,05	46,20	49,82	65,41	73,78	72,67	67,31	72,47	67,75	1,73
Warmińsko-mazurskie	30,14	37,22	41,91	45,00	40,39	47,93	42,77	44,05	52,06	38,73	42,05	43,45	30,18	52,59	46,14	1,53
Wielkopolskie	53,86	49,09	44,95	39,32	48,51	61,72	62,98	63,72	65,79	62,38	64,74	64,20	69,04	71,02	73,80	1,37
Zachodniopomorskie	29,61	35,73	36,46	42,18	50,99	52,35	46,35	47,62	49,61	29,55	32,83	46,07	33,23	49,84	44,84	1,51
max/min	2,19	7,97	1,93	2,21	1,78	1,51	1,67	1,62	1,57	2,85	2,67	2,08	3,12	1,86	2,17	
Średnia	44,22	43,57	48,22	49,15	55,97	60,17	61,30	60,91	63,38	63,23	68,09	69,25	66,39	68,34	68,90	
Odczylenie standardowe	10,20	14,00	9,68	10,96	8,64	7,38	8,76	8,76	7,94	13,37	14,51	12,75	16,22	11,79	13,98	
Współczynnik zmienności	0,23	0,32	0,20	0,22	0,15	0,12	0,14	0,14	0,13	0,21	0,21	0,18	0,24	0,17	0,20	

Źródło Na podstawie wykonanych obliczeń, przedstawiając dane Banku Danych Lokalnych GUS, zaczerpnięte ze strony www.stat.gov.pl, do wzoru nr (6).

W tabeli 2.4 przedstawiono wartości oszacowanego wskaźnika zamożności WI, podstawowe statystyki dla WI oraz indeksy jednopodstawowe dla województw w latach 2005-2019. Analizując dane zawarte w tabeli 2.4 można zauważyć, że w wybranych latach poziom zamożności mieszkańców znacznie się zwiększył we wszystkich województwach i największe wartości osiągnęło w 2019 roku. W latach 2005-2008 najwyższy poziom zamożności odnotowano dla mazowieckiego, przy czym w 2005 roku wartość wskaźnika WI dla tego województwa był prawie dwukrotnie wyższy niż dla województwa dolnośląskiego, które zajęło drugą pozycję w rankingu. W 2005 roku odnotowano największy współczynnik zmienności oszacowanej miary (74,3%). W kolejnych latach zmienność jest mniejsza i poprawia się poziom zamożności pozostałych województw. W 2009 roku można zauważyć istotną poprawę poziomu zamożności we wszystkich województwach (maksymalna wartość miary wynosi 91,11 dla lubuskiego), a w 2016 roku znaczne pogorszenie poziomu zamożności (maksymalna wartość miary wynosi 56,68 dla opolskiego), w 2019 roku nastąpił kolejny wzrost wartości WI utożsamiany z poprawą poziomu zamożności. W kolejnych latach najwyższe wartości wskaźnika WI przyjmowały różne województwa. Najczęściej pierwszą lub drugą lokatę oprócz mazowieckiego miały województwa podlaskie, warmińsko-mazurskie i lubuskie. Najniższe wartości wskaźnika WI odnotowano dla łódzkiego (2005-2007, 2013-2015, 2018) oraz śląskiego (2008-2012, 2016-2017, 2019). Mieszkańcy tych województw żyją przeciętnie krócej niż pozostali mieszkańcy Polski. Analizując wartości indeksu jednopodstawowego dla badanej zmiennej w 2019 roku w porównaniu z 2005 roku można zauważyć, że tempo zmian poziomu zamożności jest bardzo zróżnicowane. Dla wszystkich województw odnotowano wzrosty, największy dla łódzkiego, a najmniejszy dla mazowieckiego, dolnośląskiego i śląskiego.

W tabeli 2.5 przedstawiono wartości lokalnego wskaźnika HDI podstawowe statystyki dla LHDI oraz indeksy jednopodstawowe dla województw Polski w latach 2005-2019. Na podstawie danych zawartych w tabeli 2.4 można zauważyć, że w badanych latach województwa Polski należały do wszystkich możliwych grup rozwoju gospodarczo-społecznego, świadczą o tym wartości LHDI z przedziału [6,35; 85,11]. Najniższe wartości LHDI odnotowano dla województwa łódzkiego (2005-2014, 2018), śląskiego (2016-2017), świętokrzyskiego (2015) i zachodniopomorskiego (2019), natomiast najwyższe wartości dla mazowieckiego (2005-2008, 2011-2012, 2017), opolskiego (2009-2010, 2016), podkarpackiego (2013,2018) i podlaskiego (2014-2015, 2019). W 2019 roku nastąpił wyraźny wzrost LHDI dla wszystkich województw w porównaniu z 2005 roku. W badanym okresie największy wzrost HDI odnotowano dla województwa łódzkiego, natomiast najmniejszy wzrost dla śląskiego, dolnośląskiego i mazowieckiego. Analizując stosunek wartości maksymalnej do minimalnej, można zauważyć, że w latach 2005-2019 zróżnicowanie między województwami pod względem rozwoju społeczno-ekonomicznego zmniejszało się. W 2005 roku maksymalna wartość LHDI była 6,71 razy wyższa niż wartość minimalna, natomiast w 2019 roku była wyższa tylko 1,73 razy.

Tabela 2.4. Wartości wskaźnika WI dla województw Polski w latach 2005-2019

Województwo	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2019/2005
Dolnośląskie	14,49	19,42	32,46	37,50	58,65	33,49	44,37	66,04	63,81	68,87	46,13	39,44	40,79	45,69	42,04	2,90
Kujawsko-pomorskie	6,17	13,39	20,56	27,08	49,68	39,81	34,02	35,61	35,43	41,52	49,81	34,61	31,20	38,35	45,71	7,41
Lubelskie	3,58	14,42	20,78	26,39	49,39	33,13	39,81	35,03	50,05	72,43	60,10	38,43	42,22	42,21	65,78	18,36
Lubuskie	12,91	23,69	34,40	33,52	91,11	50,31	53,55	45,28	67,76	59,09	52,52	44,38	45,83	44,13	52,92	4,10
Łódzkie	1,00	7,57	15,11	19,94	58,61	27,84	29,48	30,28	26,46	26,63	26,54	24,42	24,22	31,83	40,70	40,70
Małopolskie	4,30	11,23	16,32	24,30	45,96	30,04	40,13	32,47	31,01	35,27	32,04	29,04	40,32	41,38	43,38	10,09
Mazowieckie	27,98	42,57	52,43	54,35	64,85	50,60	50,50	51,12	42,16	50,15	58,02	45,32	51,75	62,54	71,65	2,56
Opolskie	13,63	21,47	24,37	38,81	72,53	53,12	48,29	42,43	50,94	52,26	44,69	56,68	53,09	59,08	63,93	4,69
Podkarpackie	4,73	16,54	20,83	31,43	55,24	43,47	46,34	42,38	60,63	71,54	67,52	33,47	47,21	64,34	61,76	13,06
Podlaskie	3,87	14,64	26,09	30,81	65,27	36,33	41,65	39,65	52,33	75,81	85,81	34,86	52,38	69,43	91,22	23,57
Pomorskie	9,18	19,37	24,66	32,23	59,72	29,43	38,93	39,30	36,56	39,21	36,07	28,91	34,23	47,78	62,63	6,82
Śląskie	11,76	18,12	18,30	18,92	31,03	25,07	25,33	27,06	33,25	34,91	38,91	22,25	23,04	33,65	36,40	3,09
Świętokrzyskie	2,87	14,59	22,31	37,54	72,10	41,80	41,48	50,36	55,88	55,42	59,30	31,29	42,64	59,32	64,83	22,63
Warmińsko-mazurskie	6,88	17,90	27,48	34,74	62,56	34,99	38,76	44,40	71,48	100,00	75,76	34,85	34,75	40,81	51,49	7,48
Wielkopolskie	7,17	14,76	22,41	22,33	64,31	27,99	35,55	29,26	32,14	30,96	29,71	28,53	30,46	34,44	47,22	6,59
Zachodniopomorskie	6,74	15,42	24,82	29,51	74,74	44,87	45,55	49,18	49,75	54,18	48,12	39,68	51,37	62,95	50,94	7,56
max/min	27,98	5,62	3,47	2,87	2,94	2,12	2,11	2,44	2,70	3,75	3,23	2,55	2,30	2,18	2,51	
Średnia	8,58	17,82	25,21	31,21	60,98	37,64	40,86	41,24	47,48	54,27	50,69	35,38	40,34	48,62	55,79	
Odczylenie standardowe	6,38	7,43	8,63	8,44	13,30	8,64	7,20	9,70	13,67	19,16	16,11	8,37	9,53	11,99	13,72	
Współczynnik zmienności	0,74	0,42	0,34	0,27	0,22	0,23	0,18	0,24	0,29	0,35	0,32	0,24	0,24	0,25	0,25	

Źródło Na podstawie wykonanych obliczeń, podstawiając dane Banku Danych Lokalnych GUS, zaczerpnięte ze strony www.stat.gov.pl, do wzoru nr (9).

Tabela 2.5. Wartości wskaźnika LHDI dla województw Polski w latach 2005-2019

Województwo	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2019/2005
Dolnośląskie	27,35	25,65	32,37	32,21	47,12	46,38	51,04	56,91	58,74	58,53	52,05	50,40	48,13	49,13	52,67	1,93
Kujawsko-pomorskie	21,64	29,18	33,60	38,79	51,06	48,39	47,39	48,03	51,33	56,05	55,32	53,83	51,74	52,05	54,92	2,54
Lubelskie	17,90	30,38	33,76	38,51	48,34	41,64	46,57	47,73	54,03	64,85	59,77	52,83	54,93	56,07	67,10	3,75
Lubuskie	26,72	33,65	35,43	35,65	53,94	55,94	59,19	57,75	65,54	71,00	63,69	63,30	61,86	58,54	62,16	2,33
Łódzkie	6,35	15,62	20,55	25,54	37,56	34,62	37,42	37,01	36,83	40,68	39,05	42,44	42,16	44,51	52,02	8,19
Małopolskie	24,73	35,12	39,55	46,80	58,99	52,70	59,70	55,01	56,87	60,28	57,88	57,63	66,47	66,03	68,36	2,76
Mazowieckie	42,64	50,12	53,67	53,78	57,90	57,76	59,73	58,66	55,37	60,43	65,78	65,85	68,50	73,72	78,98	1,85
Opolskie	31,44	20,82	43,11	46,96	62,91	60,33	58,92	54,22	59,30	61,27	58,21	66,48	58,52	61,36	65,03	2,07
Podkarpackie	22,95	37,06	41,34	49,32	60,72	55,80	59,09	57,67	66,80	74,74	71,42	59,21	65,57	76,23	74,07	3,23
Podlaskie	22,24	33,70	43,52	49,31	61,47	50,94	58,87	57,83	62,54	75,45	75,99	58,68	66,82	72,06	85,18	3,83
Pomorskie	25,14	35,85	39,83	46,14	60,41	50,75	55,77	54,71	55,63	58,40	54,76	53,08	55,94	57,86	64,72	2,57
Śląskie	29,24	34,18	33,04	35,72	43,04	42,87	43,13	43,10	46,73	48,92	51,27	41,12	40,58	47,29	49,69	1,70
Świętokrzyskie	16,73	26,25	33,35	38,89	47,25	42,57	50,91	45,56	47,61	56,89	33,29	41,29	50,30	55,69	56,84	3,40
Warmińsko-mazurskie	21,32	32,08	37,97	43,31	50,17	46,47	47,52	50,31	60,23	65,62	59,52	46,89	41,73	52,34	54,45	2,55
Wielkopolskie	26,73	32,92	37,26	36,68	56,20	48,57	53,96	50,34	52,89	53,23	51,94	52,87	55,30	56,58	64,63	2,42
Zachodniopomorskie	20,13	28,42	33,99	38,39	55,77	48,90	49,69	51,05	51,33	46,44	44,83	48,06	46,50	55,45	49,31	2,45
max/min	6,71	3,21	2,61	2,11	1,67	1,74	1,60	1,58	1,81	1,85	2,28	1,62	1,69	1,71	1,73	
Średnia	23,95	31,31	37,02	41,00	53,30	49,04	52,43	51,62	55,11	59,55	55,92	53,37	54,69	58,43	62,51	
Odczylenie standardowe	7,46	7,38	6,83	7,14	7,07	6,49	6,62	5,98	7,31	9,31	10,64	7,91	9,10	9,05	10,28	
Współczynnik zmienności	0,31	0,24	0,18	0,17	0,13	0,13	0,13	0,12	0,13	0,16	0,19	0,15	0,17	0,15	0,16	

Źródło: Na podstawie wykonanych obliczeń, przedstawiając dane Banku Danych Lokalnych GUS, zaczerpnięte ze strony www.stat.gov.pl, do wzoru nr (2).

2.5. Podsumowanie

W opracowaniu przeprowadzono analizę rozwoju społeczno-gospodarczego województw Polski za pomocą lokalnego wskaźnika LHDI oraz jego składowych. Na podstawie przeprowadzonych badań można zauważyć, że województwa rozwijają się, a różnice pomiędzy nimi zmniejszają się dla LHI, LGNII i LHDI. Zapewne jest to związane z faktem swobodnego przepływu dóbr, kapitału, siły roboczej i technologii pomiędzy województwami, co sprzyja rozwojowi regionalnemu zarówno w aspekcie społecznym, jak i gospodarczym. Ponadto w przypadku województw mamy do czynienia z tą samą polityką rządu oraz obowiązujących przepisów prawnych odnośnie do służby zdrowia, edukacji, minimalnych wynagrodzeń, świadczeń społecznych itp. W badanym okresie najwyższe wartości LHDI uzyskano dla województw mazowieckiego, opolskiego, podkarpackiego i podlaskiego, a najniższe wartości dla łódzkiego, śląskiego, świętokrzyskiego i zachodniopomorskiego. W badanym okresie można zauważyć poprawę sytuacji na tzw. ścianie wschodniej. W badanych latach wschodnie województwa istotnie poprawiły swoje pozycje w rankingu.

Wskaźniki LHDI oraz HDI zostały stworzone, aby porównać rejony pod względem rozwoju społeczno-ekonomicznego, podkreślając rolę ludzi i ich możliwości w ocenie rozwoju regionu, jednak należy zdać sobie sprawę, że rozwój społeczny jest bardzo złożonym zjawiskiem i miary syntetyczne nie są w stanie w pełni oddać tej złożoności.

Literatura

- Akder, H. (1994). *A means to closing gaps: Dissagregated Human Development Index* (Human Development Report). New York: UNDP. <https://www.econbiz.de/Record/a-means-to-closing-gaps-disaggregated-human-development-index-akder-halis/10008471295>
- Borys, T. (red.). (2005). *Wskaźniki zrównoważonego rozwoju*. Warszawa-Białystok: Wydawnictwo Ekonomia i Środowisko.
- Borys, T., Rogala, P. (red.). (2008). *Jakość życia na poziomie lokalnym – ujęcie wskaźnikowe*. Warszawa: UNDP.
- Hanushek, E. A., Wößmann, L. (2007). *The role of education quality for economic growth* (Working Papers, No. 4122). Washington, DC: World Bank. <https://openknowledge.worldbank.org/bitstream/handle/10986/7154/wps4122.pdf?sequence=1&isAllowed=y>
- Hozer-Koćmiel, M. (2018), Ocena rozwoju społeczno-ekonomicznego województw za pomocą HDI. *Wiadomości Statystyczne*, 3(682), 40-49. <http://bazekon.icm.edu.pl/bazekon/element/bwmeta1.element.ekon-element-000171513766>

- Krueger, A. B., Lindahl, M. (2001). Education for growth: Why and for whom? *Journal of Economic Literature*, 39(4), 1101-1136. <https://www.jstor.org/stable/2698521>
- Laskowska, I., Dańska-Borsiak, B. (2018). Analiza przestrzennego zróżnicowania rozwoju społecznego w Polsce na poziomie NUTS 3 wykorzystaniem lokalnego indeksu HDI. *Folia Oeconomica. Acta Universitatis Lodzianensis*, 1(333), 111-131. <https://doi.org/10.18778/0208-6018.333.08>
- Nelson, A. C. (1993), *Theories of regional development*. W R. D. Bingham, R. Mier (red.), *Theories of local economic development: Perspectives from across the disciplines* (s. 27-59). Los Angeles Sage Publications.
- Parysek, J. J. (2001). *Podstawy gospodarki lokalnej*. Poznań: Wydawnictwo Uniwersytetu Adama Mickiewicza.
- Pritchett, L. (2006). Does learning to add up add up? The returns to schooling in aggregate data. In E. A. Hanushek, F. Welch (red.), *Handbook of the economics of education* (Vol. 1, s. 635-695). Amsterdam: North Holland. [https://doi.org/10.1016/S1574-0692\(06\)01011-7](https://doi.org/10.1016/S1574-0692(06)01011-7)
- Rolnick, B. A. J., Grunewald, R. (2007). The economics of early childhood development as seen by two fed economists. *Community Investments*, 19(Fall), 13-1430.
- Singh, R. K., Murty, H. R., Gupta, S. K., Dikshit, A. K. (2009). An overview of sustainability assessment methodologies. *Ecological Indicators*, 9(2), 189-212. <https://doi.org/10.1016/j.ecolind.2008.05.011>
- Tanguaya, G. A., Rajaonson, J., Lefebvre, J.-F., Lanoie, P. (2010). Measuring the sustainability of cities: An analysis of the use of local indicators. *Ecological Indicators*, 10(2), 407-418. https://www.academia.edu/47080477/Measuring_the_sustainability_of_cities_An_analysis_of_the_use_of_local_indicators
- UNDP. (2012). *Krajowy raport o rozwoju społecznym. Polska 2012. Rozwój regionalny i lokalny*. Warszawa: Biuro Projektowe UNDP w Polsce.
- UNDP. (2019). *Human Development Reports 2019*. <https://hdr.undp.org/system/files/documents/hdr2019pdf.pdf> (10.11.2020).
- UNDP. (2020). *Towards 2021/2022 HDR* (2022 Human Development Report). <https://hdr.undp.org/en/2020-report> (29.11.2021).
- Human Development Data Center. <https://hdr.undp.org/en/data> (15.11.2021).
- Bank Danych Lokalnych GUS. www.stat.gov.pl (19.11.2021).

3. Analiza rozwoju społecznego województw w Polsce z uwzględnieniem okresu przed i w czasie pandemii COVID-19

(Anna Janiga-Ćmiel)

3.1. Wprowadzenie

Rozwój społeczny jest procesem złożonym, skomplikowanym i długotrwałym. Problematyka badań z zakresu rozwoju społecznego od wielu lat jest poddawana dyskusji, bowiem nie wiemy jakie dobrać ostatecznie odpowiednie dane statystyczne, mierniki by w miarę wiernie zaprezentować i opisać badane zjawisko. Zatem można powiedzieć, że: „[...] rozwój z cywilizacyjnego punktu widzenia jest to całością działań społeczeństwa, podejmowanych świadomie i podświadomie (uwarunkowanych genetycznie i kulturowo), które mają na celu polepszenie warunków bytu i stałe doskonalenie gatunku ludzkiego. Rozwój można zatem postrzegać jako proces przeobrażeń prowadzących do stanów lub form pod pewnymi względami doskonalszych, bardziej złożonych, efektywnych. Rozwój obejmuje wszystkie aspekty życia: osobnicze, rodzinne, społeczne, gospodarcze, przyrodnicze, organizacyjne, polityczne” (Wojnowski, 2002, s. 8). Rozwój społeczny może wpływać na poprawę i kształtowanie tych czynników, które oddziałują na społeczeństwo w zakresie edukacji, ochrony zdrowia, poprawy bezpieczeństwa itp.

Przy ocenie rozwoju społecznego często uwzględnia się w badaniu mierniki, które w miarę możliwości zawierają informacje dotyczące poprawy jakości życia i ograniczenia ubóstwa, ewentualnego wzrostu stabilności sytuacji gospodarczej i społecznej czy też dane obrazujące widoczne pozytywne zmiany wynikające z działalności w kierunku poprawy środowiska przyrodniczego (Strahl, 1998). Najczęściej stosowanym w badaniach miernikiem oceny rozwoju społecznego czy też dynamiki rozwoju gospodarczego jest Produkt Krajowy Brutto na jednego mieszkańca (Strahl, 1998).

W literaturze w zakresie badania rozwoju społecznego czy też rozwoju społeczno-gospodarczego nie znajdujemy propozycji uniwersalnego zestawu zmiennych określających poziom badanego zjawiska jak również wskazania narzędzi badawczych. Przeprowadzone badania umożliwią wyciągnięcie wniosków w zakresie występowania ewentualnego zróżnicowania, występowania dysproporcji w badanym zjawisku. Pomiar poziomu rozwoju społecznego w województwach zależy jest od wyboru odpowiednich i zarazem dostępnych danych, dodatkowo trzeba mieć na uwadze, że podstawowym przedmiotem badań w zakresie poziomu rozwoju społecznego jest ludność.

Celem rozdziału jest próba wykorzystania wybranych metod taksonomii do uporządkowania w analizowanych okresach województw Polski pod kątem podobieństwa rozwoju społecznego, jak i analizy wpływu województw w zakresie rozwoju społecznego na Polskę jako całości.

3.2. Zestaw cech diagnostycznych w zakresie podjętej tematyki

Przedmiotem zaproponowanej analizy jest rozwój społeczny województw Polski w latach 2020, 2015, 2010, ze szczególnym zwróceniem uwagi na okres w czasie pandemii COVID-19. Zestaw cech został dobrany przy uwzględnieniu zakresu tematycznego i dostępności danych. W analizie uwzględniono podział tematyczny cech odnoszący się do rozwoju społecznego zaproponowany w pracy D. Strahl (1998). Właściwy pomiar poziomu rozwoju społecznego poszczególnych województw Polski wymaga doboru odpowiednich mierników jednak brakuje konkretnych i uniwersalnych informacji dotyczących tego zakresu (Strahl, 1998). Dane pochodzą ze strony GUS.

W oparciu o wyznaczone wartości współczynników zmienności oraz przeprowadzoną weryfikacyjną analizę korelacyjną stosując metodę odwróconej macierzy korelacji uwzględniono ostateczny zestaw cech diagnostycznych, które opisuje badane zjawisko w wybranych województwach przy uwzględnieniu określonych zakresów tematycznych badanego zjawiska (Strahl, 1998):

a) cechy z zakresu rozwoju ludności:

x_1 – ludność w tys.,

x_2 – zgony niemowląt na 1 tys. urodzeń żywych,

x_3 – ludność w miastach w % ogółem ludności,

x_4 – ludność w wieku nieprodukcyjnym na 100 osób w wieku produkcyjnym,

x_5 – saldo migracji wewnętrznych i zagranicznych na pobyty stały (na 1000 ludności).

W tabelach 3.1-3.5 zaprezentowano wartości wyznaczonych współczynników zmienności w danym zakresie – rok 2020 (pominięto prezentację tabel wartości współczynników zmienności w pozostałych latach).

Tabela 3.1. Wartości współczynników zmienności dla zmiennych w roku 2020 w zakresie rozwoju ludności

Współczynnik zmienności (%)	Ludność w tys.	Saldo migracji wewnętrznych i zagranicznych na pobyty stały	Zgony niemowląt na 1 tys. urodzeń żywych	Ludność w wieku nieprodukcyjnym na 100 osób w wieku produkcyjnym	Ludność w miastach w % ogółem ludności
Wyznaczone wartości współczynnika zmienności	51,704	1520,411	15,523	57,015	16,037

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stat.gov.pl> (10.09.2021).

b) cechy z zakresu usług zdrowotnych:

x_6 – liczba ludności na lekarza (personel pracujący ogółem),

x_7 – liczba ludności na lekarza dentystę,

x_8 – pielęgniarki i położne na 10 tys. ludności,

x_9 – liczba ludności na łóżko w szpitalach ogólnych,

x_{10} – liczba punktów aptecznych,

x_{11} – opieka nad dziećmi w wieku do lat 3 – żłobki.

Tabela 3.2. Wartości współczynników zmienności dla zmiennych w roku 2020 w zakresie usług zdrowotnych

Współczynnik zmienności (%)	Liczba ludności na łóżko w szpitalach ogólnych	Liczba punktów aptecznych	Opieka nad dziećmi w wieku do lat 3 – żłobki	Liczba ludności na lekarza personel pracujący ogółem)	Liczba ludności na lekarza dentystę	Pielęgniarki i położne na 10 tys. ludności
Wyznaczone wartości współczynnika zmienności	10,616	45,960	65,388	21,316	74,290	14,501

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stat.gov.pl> (10.09.2021).

c) tematyka z zakresu dostępności do usług wychowawczych i oświatowych:

x_{12} – liczba uczniów – szkoły podstawowe,

x_{13} – liczba uczniów – branżowe szkoły,

x_{14} – liczba uczniów – licea ogólnokształcące,

x_{15} – liczba uczniów – technika,

x_{16} – liczba uczniów – ogólnokształcące szkoły artystyczne,

x_{17} – liczba uczniów – szkoły policealne,

x_{18} – liczba studentów – uczelnie wyższe.

Tabela 3.3. Wartości współczynników zmienności dla zmiennych w roku 2020 w zakresie usług zdrowotnych

Współczynnik zmienności (%)	Liczba uczniów – szkoły podstawowe	Liczba uczniów – branżowe szkoły	Liczba uczniów – licea ogólnokształcące	Liczba uczniów – technika	Liczba uczniów – ogólnokształcące szkoły artystyczne	Liczba uczniów – szkoły policealne	Liczba studentów – uczelnie wyższe
Wyznaczone wartości współczynnika zmienności	55,620	50,671	63,448	47,180	64,911	55,636	77,432

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stat.gov.pl> (10.09.2021).

d) tematyka z zakresu usługi kulturalnych:

x_{19} – kina, stałe – miejsca na widowni,

x_{20} – teatry i instytucje muzyczne – miejsca na widowni w stałej sali,

x_{21} – centra kultury, domy i ośrodki kultury.

Tabela 3.4. Wartości współczynników zmienności dla zmiennych w roku 2020 w zakresie usługi kulturalnych

Współczynnik zmienności (%)	Kina stałe – miejsca na widowni	Teatry i instytucje muzyczne – miejsca na widowni w stałej sali	Centra kultury, domy i ośrodki kultury
Wyznaczone wartości współczynnika zmienności	73,287	83,139	38,782

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stat.gov.pl> (10.09.2021).

e) tematyka związana z zatrudnieniem i wynagrodzeniem:

x_{22} – przeciętne wynagrodzenie miesięczne w gospodarce narodowej brutto,

x_{23} – stopa bezrobocia,

x_{24} – świadczenia pomocy społecznej,

x_{25} – liczba bezrobotnych zarejestrowanych w danym roku.

Tabela 3.5. Wartości współczynników zmienności dla zmiennych w roku 2020 w zakresie zatrudnieniem i wynagrodzeniem

Współczynnik zmienności (%)	Przeciętne miesięczne wynagrodzenie brutto	Świadczenia pomocy społecznej	Stopa bezrobocia	Liczba bezrobotnych zarejestrowanych w danym roku
Wyznaczone wartości współczynnika zmienności	13,784	36,430	27,039	44,629

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stat.gov.pl> (10.09.2021).

Kolejny etap analizy obejmował dokonanie klasyfikacji województw Polski.

3.3. Taksonomiczna metoda wyodrębniania jednorodnych grup

Celem zaproponowanej analizy taksonomicznej jest próba oceny poziomu różnicowania obiektów opisanych za pomocą wybranych cech statystycznych oraz wyznaczenie skupisk pod kątem podobieństwa rozwoju analizowanego zjawiska.

W literaturze naukowej można znaleźć wiele ciekawych metod taksonomicznych grupowania obiektów. Każda z tych metod uwzględnia inny algorytm, oparta jest na różnych założeniach, jak również każda z nich ma swoje wady i zalety. W badaniu zaproponowano zastosowanie taksonomicznej metody grupowania typu bezpośredniego, która daje możliwość uzyskania wynikowej klasyfikacji bez przesuwania obiektów między podgrupami na kolejnych etapach klasyfikacji. Metoda ta omówiona została po raz pierwszy w pracach S. Chomątowskiego i A. Sokołowa-

skiego (1978). Dodatkowo w metodzie tej wprowadzone zostały zmiany zaproponowane w pracy (Młodak, 2006). Zastosowanie metody uwzględnia przeprowadzenie kilka kroków odpowiednich przekształceń. W tym celu wyznaczamy kwadratową macierz braku podobieństwa P , stosując odpowiednie miary. W analizie zostanie zastosowana miara Chomątowskiego–Sokołowskiego dana wzorem Młodaka (2006):

$$p_{ik} = 1 - \sum_{j=1}^m \min(x_{ij}, x_{kj}). \quad (1)$$

Macierz $P = [p_{ik}]$, $i, k = 1, 2, \dots, n$ jest macierzą symetryczną, a elementy macierzy przyjmują wartości z przedziału $[0, 1]$. W następnym kroku zgodnie z procedurą zaprezentowaną przez Chomątowskiego–Sokołowskiego należy ustalić krytyczny poziom braku podobieństwa α . Autorzy w zaproponowanej procedurze nie proponują konkretnego sposobu wyznaczania wartości α . W niniejszej analizie zostanie uwzględniona propozycja wyznaczenia wartości α , która została zaprezentowana w pracy Młodaka (2006), mianowicie przyjmujemy:

$$\alpha = \min_{i=1, \dots, n} \max_{k=1, \dots, n} p_{ik}. \quad (2)$$

Wartość α konieczna jest do wyznaczenia kolejnej macierzy P^* , która jest macierzą zero-jedynkową. Macierz P^* wyznaczamy zgodnie z zasadą:

- jeżeli $p_{ik} < \alpha$ to w macierzy przyjmujemy wartość 0,
- jeżeli $p_{ik} \geq \alpha$ to przyjmujemy wartość 1, $i, k = 1, \dots, n$. (Chomątowski, Sokołowski, 1978; Młodak, 2006).

W kolejnym kroku przekształcamy macierz P^* . Niech $p_0 = P^* \cdot \mathbf{1}$. Znajdujemy największą wartość składową wektora p_0 , stanowiącą sumę odpowiedniego wiersza macierzy P^* , a następnie usuwamy wiersz i kolumnę z macierzy P^* , odpowiadającą tej wartości. W pracy Młodak (2006) zaproponowane jest również, aby wybrać wiersz i kolumnę w macierzy odpowiadającą obiektowi, który maksymalizuje medianę wierszy macierzy P , która odpowiada maksymalnym wartościom składowych wektora p_0 . W następnym kroku procedurę powtarzamy, tworząc kolejną macierz zgodnie z wcześniejszym schematem dotyczącym usuwania wierszy i kolumn. Obiekty odpowiadające wierszom i kolumnom, które pozostały w macierzy P , tworzą grupę obiektów podobnych. Dla pozostałych wierszy i kolumn tworzymy nową macierz w oparciu o macierz wyjściową P i powtarzamy procedurę. W ostatnim etapie badania dla wyodrębnionych grup zostanie wyznaczona wariancja międzygrupowa i wewnątrzgrupowa, aby zbadać, czy wyodrębnione grupy są na tyle jednorodne, że nie ma dalszej potrzeby delimitacji wyznaczonych grup (Młodak, 2006). W konstrukcji macierzy P możemy zastosować również inne metody dotyczące pomiaru odległości związane z poziomem braku podobieństwa, jak również propozycje wyznaczenia wartości α .

3.4. Analiza empiryczna podobieństwa

Na podstawie wyselekcjonowanego zestawu cech diagnostycznych przy uwzględnieniu zakresu tematycznego w pierwszej kolejności wytypowano jednorodne grupy województw w roku 2020. W tym celu wyznaczono macierz wskaźników struktury odległości, a na ich podstawie macierz podobieństwa i braku podobieństwa. W ostateczności otrzymano grupy jednorodnego rozwoju województw z zakresu rozwoju ludności. Dodatkowo otrzymane grupy jednorodnego rozwoju z danego zakresu tematycznego w określonym roku zostały zaprezentowane graficznie z wykorzystaniem dodatku Microsoft 3D Mapy Excel (województwa zakwalifikowane do danej grupy zostały oznaczone tym samym stopniem nasycenia danej koloru wybranego dla zakresu tematycznego – rysunek 3.1).

Grupy jednorodnego rozwoju województw z zakresu rozwoju ludności:

$G_{1/2020RL} = \{\text{dolnośląskie, małopolskie, pomorskie, mazowieckie}\},$

$G_{2/2020RL} = \{\text{kujawsko-pomorskie, podkarpackie, łódzkie, świętokrzyskie, warmińsko-mazurskie, lubelskie, śląskie}\},$

$G_{3/2020RL} = \{\text{lubuskie, opolskie, zachodniopomorskie, podlaskie, wielkopolskie}\}.$



Rys. 3.1. Grupy jednorodnego rozwoju województw z zakresu rozwoju ludności (2020)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Następnie wyznaczono grupy jednorodnego rozwoju województw dla cech z zakresu usług zdrowotnych (rysunek 3.2):

$G_{1/2020UZ} = \{\text{dolnośląskie, małopolskie, śląskie, wielkopolskie}\},$

$G_{2/2020UZ} = \{\text{kujawsko-pomorskie, podkarpackie, łódzkie, zachodniopomorskie, lubelskie, pomorskie}\},$

$G_{3/2020UZ} = \{\text{lubuskie, opolskie, podlaskie, świętokrzyskie, warmińsko-mazurskie}\},$

$G_{4/2020UZ} = \{\text{mazowieckie}\}.$



Rys. 3.2. Grupy jednorodnego rozwoju województw z zakresu usług zdrowotnych (2020)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

W kolejnym etapie zaprezentowano grupy jednorodnego rozwoju dla cech z zakresu dostępności do usług wychowawczych i oświatowych (rysunek 3.3):

$$G_{1/2020WO} = \{\text{dolnośląskie, pomorskie, kujawsko-pomorskie, podkarpackie, lubelskie, łódzkie}\},$$

$$G_{2/2020WO} = \{\text{lubuskie, opolskie, podlaskie, świętokrzyskie, warmińsko-mazurskie, zachodniopomorskie}\},$$

$$G_{3/2020WO} = \{\text{małopolskie, śląskie, wielkopolskie}\},$$

$$G_{4/2020WO} = \{\text{mazowieckie}\}.$$



Rys. 3.3. Grupy jednorodnego rozwoju województw z zakresu dostępności do usług wychowawczych i oświatowych (2020)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Grupy jednorodnego rozwoju dla cech z zakresu usługi kulturalnych (rysunek 3.4):

$G_{1/2020UK} = \{ \text{kujawsko-pomorskie, łódzkie, lubelskie, podkarpackie, zachodnio-pomorskie} \},$

$G_{2/2020UK} = \{ \text{świętokrzyskie, warmińsko-mazurskie, lubuskie, opolskie, podlaskie} \},$

$G_{3/2020UK} = \{ \text{dolnośląskie, pomorskie, małopolskie, wielkopolskie} \},$

$G_{4/2020UK} = \{ \text{śląskie, mazowieckie} \}.$



Rys. 3.4. Grupy jednorodnego rozwoju województw z zakresu usług kulturalnych (2020)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

W ostatnim kroku analizy wyznaczono grupy jednorodnego rozwoju województw dla cech z zakresu zatrudnienia i wynagrodzenia (rysunek 3.5):

$G_{1/2020ZW} = \{ \text{dolnośląskie, łódzkie, pomorskie, warmińsko-mazurskie, małopolskie, zachodniopomorskie} \},$

$G_{2/2020ZW} = \{ \text{kujawsko-pomorskie, śląskie, wielkopolskie, podkarpackie, świętokrzyskie} \},$

$G_{3/2020ZW} = \{ \text{lubelskie, lubuskie, opolskie, podlaskie} \},$

$G_{4/2020ZW} = \{ \text{mazowieckie} \}.$

Badanie powtórzono dla tego samego zestawu zmiennych, ale tym razem dla roku 2015, otrzymując grupy jednorodnego rozwoju województw zgodnie z zakresem tematycznym:

Grupy jednorodnego rozwoju dla cech z zakresu rozwoju ludności (rysunek 3.6):

$G_{1/2015RL} = \{ \text{opolskie, świętokrzyskie, lubuskie, podlaskie} \},$

$G_{2/2015RL} = \{ \text{kujawsko-pomorskie, łódzkie, lubelskie, zachodniopomorskie, podkarpackie, warmińsko-mazurskie} \},$

$G_{3/2015RL} = \{ \text{dolnośląskie, małopolskie, pomorskie} \},$

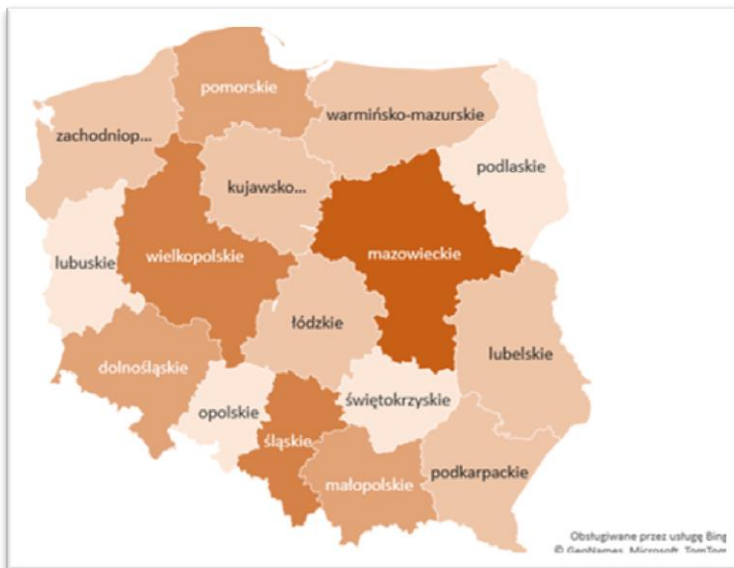
$G_{4/2015RL} = \{ \text{śląskie, wielkopolskie} \},$

$G_{5/2015RL} = \{ \text{mazowieckie} \}.$



Rys. 3.5. Grupy jednorodnego rozwoju województw z zakresu zatrudnienia i wynagrodzenia (2020)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 3.6. Grupy jednorodnego rozwoju województw z zakresu rozwoju ludności (2015)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Grupy jednorodnego rozwoju dla cech z zakresu usług zdrowotnych (rysunek 3.7):

$G_{1/2015UZ} = \{\text{dolnośląskie, wielkopolskie, małopolskie}\},$

$G_{2/2015UZ} = \{\text{kujawsko-pomorskie, lubelskie, pomorskie, podkarpackie, łódzkie}\},$

$G_{3/2015UZ} = \{\text{lubuskie, opolskie, podlaskie, świętokrzyskie, warmińsko-mazurskie, zachodniopomorskie}\},$

$G_{4/2015UZ} = \{\text{śląskie, mazowieckie}\}.$



Rys. 3.7. Grupy jednorodnego rozwoju województw z zakresu usług zdrowotnych (2015)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Grupy jednorodnego rozwoju dla cech z zakresu dostępności do usług wychowawczych i oświatowych (rysunek 3.8):

$G_{1/2015WO} = \{\text{dolnośląskie, kujawsko-pomorskie, podkarpackie, lubelskie, łódzkie, pomorskie}\},$

$G_{2/2015WO} = \{\text{lubuskie, opolskie, podlaskie, świętokrzyskie, warmińsko-mazurskie, zachodniopomorskie}\},$

$G_{3/2015UZ} = \{\text{wielkopolskie, małopolskie, śląskie, mazowieckie}\}.$



Rys. 3.8. Grupy jednorodnego rozwoju województw z zakresu usług wychowawczych i oświatowych (2015)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Grupy jednorodnego rozwoju dla cech z zakresu dostępności do usług kulturalnych (rysunek 3.9):

$G_{1/2015UK} = \{\text{dolnośląskie, małopolskie, wielkopolskie, kujawsko-pomorskie, pomorskie}\},$

$G_{2/2015OK} = \{\text{śląskie, mazowieckie}\},$

$G_{3/2015UZ} = \{\text{podkarpackie, lubelskie, łódzkie, lubuskie, opolskie, podlaskie, świętokrzyskie, warmińsko-mazurskie, zachodniopomorskie}\}.$

Grupy jednorodnego rozwoju dla cech z zakresu zatrudnienia i wynagrodzenia (rysunek 3.10):

$G_{1/2015ZW} = \{\text{dolnośląskie, pomorskie, śląskie}\},$

$G_{2/2015ZW} = \{\text{mazowieckie}\},$

$G_{3/2015ZW} = \{\text{kujawsko-pomorskie, warmińsko-mazurskie, podkarpackie, lubelskie, łódzkie, zachodniopomorskie}\},$

$G_{4/2015ZW} = \{\text{małopolskie, wielkopolskie}\},$

$G_{5/2015ZW} = \{\text{lubuskie, opolskie, podlaskie, świętokrzyskie}\}.$



Rys. 3.9. Grupy jednorodnego rozwoju województw z zakresu dostępności do usług kulturalnych (2015)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 3.10. Grupy jednorodnego rozwoju województw z zakresu zatrudnienia i wynagrodzenia (2015)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Ostatni etap analizy obejmował wyznaczenie grup, uwzględniając ponownie ten sam zestaw zmiennych, ale tym razem dla roku 2010, zgodnie z tym samym zakresem tematycznym, co w poprzednich latach:

Grupy jednorodnego rozwoju dla cech z zakresu rozwoju ludności w roku 2010 (rysunek 3.11):

$G_{1/2010RL} = \{\text{dolnośląskie, małopolskie, pomorskie, śląskie, wielkopolskie}\},$

$G_{2/2010RL} = \{\text{mazowieckie}\},$

$G_{3/2010RL} = \{\text{kujawsko-pomorskie, łódzkie, lubelskie, zachodniopomorskie, warmińsko-mazurskie, podkarpackie}\},$

$G_{4/2010RL} = \{\text{lubuskie, opolskie, podlaskie, świętokrzyskie}\}.$



Rys. 3.11. Grupy jednorodnego rozwoju województw z zakresu rozwoju ludności (2010)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Grupy jednorodnego rozwoju dla cech z zakresu usług zdrowotnych w roku 2010 (rysunek 3.12):

$G_{1/2010UZ} = \{\text{dolnośląskie, łódzkie, małopolskie, wielkopolskie}\},$

$G_{2/2010UZ} = \{\text{mazowieckie, śląskie}\},$

$G_{3/2010UZ} = \{\text{kujawsko-pomorskie, pomorskie, zachodniopomorskie, lubelskie, podkarpackie}\},$

$G_{4/2010UZ} = \{\text{warmińsko-mazurskie, lubuskie, opolskie, podlaskie, świętokrzyskie}\}.$



Rys. 3.12. Grupy jednorodnego rozwoju województw z zakresu usług zdrowotnych (2010)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Grupy jednorodnego rozwoju dla cech z zakresu dostępności do usług wychowawczych i oświatowych w roku 2010 (rysunek 3.13):

$G_{1/2010WO} = \{\text{dolnośląskie, małopolskie, śląskie, wielkopolskie, mazowieckie}\},$

$G_{2/2010WO} = \{\text{kujawsko-pomorskie, podkarpackie, lubelskie, pomorskie, łódzkie}\},$

$G_{3/2010WO} = \{\text{zachodniopomorskie, warmińsko-mazurskie, lubuskie, opolskie, podlaskie, świętokrzyskie}\}.$

Grupy jednorodnego rozwoju dla cech z zakresu usługi kulturalnych w roku 2010 (rysunek 3.14):

$G_{1/2010UK} = \{\text{dolnośląskie, małopolskie, wielkopolskie}\},$

$G_{2/2010UK} = \{\text{śląskie, mazowieckie}\},$

$G_{3/2010UK} = \{\text{kujawsko-pomorskie, łódzkie, pomorskie}\},$

$G_{4/2010UK} = \{\text{podkarpackie, lubelskie, podlaskie, warmińsko-mazurskie, zachodniopomorskie}\},$

$G_{5/2010UK} = \{\text{lubuskie, opolskie, świętokrzyskie}\}.$



Rys. 3.13. Grupy jednorodnego rozwoju województw z zakresu dostępności do usług wychowawczych i oświatowych (2010)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 3.14. Grupy jednorodnego rozwoju województw z zakresu usługi kulinarnych (2010)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Grupy jednorodnego rozwoju dla cech z zakresu zatrudnienia i wynagrodzenia w roku 2010 (rysunek 3.15):

$G_{1/2010ZW} = \{\text{dolnośląskie, pomorskie, śląskie, mazowieckie}\},$

$G_{2/2010ZW} = \{\text{kujawsko-pomorskie, podkarpackie, warmińsko-mazurskie}\},$

$G_{3/2010ZW} = \{\text{lubuskie, podlaskie, świętokrzyskie}\},$

$G_{4/2010ZW} = \{\text{lubelskie, łódzkie}\},$

$G_{5/2010UK} = \{\text{zachodniopomorskie, małopolskie, wielkopolskie, opolskie}\}.$



Rys. 3.15. Grupy jednorodnego rozwoju województw z zakresu zatrudnienia i wynagrodzenia (2010)

Źródło: Opracowanie z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

W ostatnim kroku analizy dla każdego z wyznaczonych zestawów grup wyliczono wariancję wewnątrzgrupową oraz wariancję międzygrupową (Gabiński, Wydymus, Zeliaś, 1989, s. 71-100.; Pocięcha i in., 1988), a także różnice między wariancją międzygrupową i wewnątrzgrupową – każda z wyznaczonych różnic dla poszczególnych grup była dodatnia. Zbadano również istotność statystyczną wyznaczonych różnic, potwierdzając tym samym, że wyznaczone grupy są na tyle jednorodne, że nie ma dalszej potrzeby podziału grup.

3.5. Wielocechowy model taksonomiczny

Teoria gier kooperacyjnych została zapoczątkowana w pracach O. Morgens-
sterna i J. von Neumanna jako gałąź dyscypliny naukowej. L. S. Shapley (1953)
jako pierwszy podał rozwiązanie gry kooperacyjnej, nazwanej wartością Sha-
pleya (Młodak, 2006). W kolejnych latach powstało szereg nowych propozycji
rozwiązań tych rodzajów gier oraz ich zastosowań. Z grą kooperacyjną mamy do
czynienia, gdy gracze mogą współpracować ze sobą, a wyniki tej gry są uzależ-
nione od owej współpracy (Młodak, 2006). Kooperacja jest pojęciem często
stosowanym w teorii gier, to połączenie odpowiednich działań, aby osiągnąć
 pewne korzyści, których na przykład pojedyncze przedsiębiorstwa czy też insty-
tucje nie mogły samodzielnie osiągnąć. Pojęcia związane z teorią gier koopera-
cyjnych są bardzo rozbudowane, a pierwszym skonstruowanym rozwiązaniem
 gry kooperacyjnej była właśnie wartość Shapleya (Młodak, 2006).

Wartością Shapleya gracza $i \in N$ w n -osobowej grze kooperacyjnej $v \in G_N$
nazywamy wielkość (Młodak, 2006):

$$Sh_i(v) = \sum_{S \subseteq N} \frac{n_S!(n-n_S-1)!}{n!} (v(S \cup \{i\}) - v(S)), \quad (3)$$

gdzie:

G_N – zbiór wszystkich gier n -osobowych,

v – funkcja charakterystyczna gry kooperacyjnej, która każdemu podzbiorowi
zbioru graczy przyporządkowuje pewną liczbę rzeczywistą, stanowiącą korzyść
płynącą z gry dla danej koalicji,

$S \subseteq N$ – koalicja,

$N = \{1, 2, 3, \dots, n\}$ – zbiór graczy (n jest liczbą naturalną),

n_S – moc zbioru S (liczba jego elementów).

Powyższa wartość to oczekiwana wartość korzyści, jaką gracz i wnosi do
koalicji (Młodak, 2006).

W przypadku gier w praktyce mamy do czynienia ze zróżnicowanymi pre-
ferencjami graczy. Jeden z graczy może na przykład wykazywać większą skłon-
ność do zawierania sojuszy z pewną liczbą wybranych współuczestników gry
(Młodak, 2006). Natomiast jeżeli powstają tego typu koalicje, to kontynuuje grę
jako nowy gracz, a w sytuacji gdy jeden z jej członków przyłącza się do innego
sojuszu, to robi to z całą koalicją. Mamy wówczas do czynienia z modelem
 gry kooperacyjnej z prekoalicjami. Podstawą wyznaczania tego typu zmodyfi-
kowanej gry kooperacyjnej jest założenie istnienia podziału zbioru graczy na
podzbiory niepuste oraz rozłączne, które są właśnie definiowane jako prekoali-
cje (Młodak, 2006). Wartością koalicji graczy jest liczba c , odpowiadająca mak-
simalnemu typowi gracza, który jest reprezentowany w danej koalicji.

W latach siedemdziesiątych XX wieku zostały opublikowane modyfikacje gry kooperacyjnej, mianowicie gry „lotniskowej”. W praktyce model ten stosowany był w analizie możliwości optymalnej alokacji kosztów wybudowania i eksploatacji pasa startowego w celu przyjmowania samolotów (Młodak, 2006).

Postać rozwiązania takiej gry „lotniskowej” v jest następująca: niech n_i będzie liczbą graczy typu i -tego i wyższych. S. C. Littlechild oraz G. Owen zaprezentowali wartość Shapleya daną wzorem (Młodak, 2006):

$$Sh_i(v) = \frac{c_k - c_{k-1}}{n_k}, \quad (4)$$

gdzie:

n_k – liczba graczy.

Natomiast wartość Shapleya z prekoalicjami gracza typu i , który należy do prekoalicji T_j , została zdefiniowana formułą (Młodak A., 2006):

$$Sh_{(i)j}(v, T) = \sum_{k=1}^i \frac{c_k - c_{k-1}}{m_k t_{kj}}, \quad (5)$$

gdzie:

m_k – liczba prekoalicji T ,

t_{kj} – liczba graczy typu co najmniej k -tego należących do prekoalicji T_j .

Częstym problemem w badaniach jest możliwość ustalenia na przykład udziału regionów w całej zbiorowości. W niniejszym badaniu zostanie podjęta próba zastosowania własności gier „lotniskowych” stanowiących narzędzie, które daje możliwość między innymi rozwiązania problemu ustalenia poziomu udziału danego obiektu w rozwoju całej zbiorowości (Młodak, 2006).

W związku z powyższym rozpatrujemy zbiorowość n obiektów $W = \{W_1, \dots, W_n\}$, które są opisane za pomocą m cech diagnostycznych $X = \{X_1, X_2, \dots, X_m\}$. Niech $Z = \{Z_1, \dots, Z_m\}$ będzie układem cech znormalizowanych przy uwzględnieniu poniższego wzoru (Hellwig, 1968; Panek, 2009, s. 58-114):

$$z_{ij} := \frac{x_{ij} - \bar{x}_j}{\sigma_j}, \quad (6)$$

gdzie:

σ_j – odchylenie standardowe, dla $i = 1, \dots, n, j = 1, 2, \dots, m$.

Następnie konstruujemy cechę kompleksową $C = \{c_1, \dots, c_n\}$, której wartości możemy wyznaczyć dla danego obiektu W_i zgodnie ze wzorem (Młodak, 2006):

$$c_i = \sum_{j=1}^m \omega_j z_{ij}, \quad (7)$$

gdzie:

ω_j – współczynnik ważności cechy X_j , który wyznaczamy według wzoru:

$$\omega_j = \frac{V_j}{\sum_{k=1}^m V_k}, \quad (8)$$

V_j – współczynnik zmienności, $j = 1, \dots, m$.

W sytuacji, gdy wśród wyznaczonych wartości cechy C znajdują się liczby ujemne, należy dokonać korekty zgodnie ze wzorem (Młodak, 2006):

$$C_i^* = c_i + \left| \left[\min_{k=1, \dots, n} c_k \right] \right|. \quad (9)$$

Wartości procentowe (10) uzyskujemy dzieląc każdą wartość rozwiązania (5) przez sumę ich wszystkich, a wynik należy pomnożyć przez 100.

Zastosowanie wartości Shapleya daje między innymi możliwość prezentacji udziału obiektów na tle całej ich zbiorowości (Młodak, 2006).

3.6. Analiza udziału podregionów w rozwoju zjawiska – przykład empiryczny

Celem przeprowadzonej analizy jest zbadanie zróżnicowania podregionów w zakresie tematyki rozwoju społecznego, badając ich procentowy wpływ na analizowane zjawisko (dla uwzględnionej tematycznie problematyki). Zostanie uwzględniona metoda konstrukcji cechy kompleksowej – normalizacja klasyczna. W analizie uwzględniono zestawy cech diagnostycznych z zakresu usług kulturalnych oraz z zakresu ludności w roku 2020. Dane zebrano ze strony internetowej GUS. W badaniu skoncentrowano się na wyznaczeniu wartości Shapleya z prekoalicjami. Województwa wraz z podregionami stanowią w badaniu prekoalicje (Młodak, 2006). Struktury wyznaczone w oparciu o wartości Shapleya (5) zaprezentowano w tabelach 3.6 i 3.7.

Tabela 3.6. Poziom podziałów obiektów – wartość Shapleya z prekoalicjami (zakres tematyczny kultura) w roku 2020 – normalizacja klasyczna

Nazwa	Normalizacja klasyczna
1	2
DOLNOŚLĄSKIE	
Powiat m.Jelenia Góra	20,8320103
Powiat m.Legnica	20,7296809
Powiat m.Wrocław	34,5531879
Powiat m.Wałbrzych od 2013	23,8851209
KUJAWSKO-POMORSKIE	
Powiat m.Bydgoszcz	27,1965701
Powiat m.Grudziądz	22,8584279
Powiat m.Toruń	29,5424682
Powiat m.Włocławek	20,4025338
LUBELSKIE	
Powiat m.Biała Podlaska	15,0953793
Powiat m.Chełm	35,9087369
Powiat m.Lublin	28,5641489
Powiat m.Zamość	20,431735

cd. tabeli 3.6

1	2
LUBUSKIE	
Powiat m.Gorzów Wielkopolski	40,0616821
Powiat m.Zielona Góra	59,9383179
ŁÓDZKIE	
Powiat m.Łódź	54,7918191
Powiat m.Piotrków Trybunalski	18,2188052
Powiat m.Skierniewice	26,9893758
MAŁOPOLSKIE	
Powiat m.Kraków	59,2542274
Powiat m.Nowy Sącz	17,7710832
Powiat m.Tarnów	22,9746894
MAZOWIECKIE	
Powiat m.Ostrołęka	15,1232749
Powiat m.Płock	12,2341979
Powiat m.Radom	14,8410403
Powiat m.Siedlce	7,04879501
Powiat m. st. Warszawa	50,7526919
OPOLSKIE	
Powiat m.Opole	100
PODKARPACKIE	
Powiat m.Krosno	10,9722699
Powiat m.Przemyśl	21,5835696
Powiat m.Rzeszów	25,1995843
Powiat m.Tarnobrzeg	42,2445762
PODLASKIE	
Powiat m.Białystok	25,8863306
Powiat m.Łomża	45,425658
Powiat m.Suwałki	28,6880114
POMORSKIE	
Powiat m.Gdańsk	27,5630862
Powiat m.Gdynia	46,5296971
Powiat m.Słupsk	17,8251517
Powiat m.Sopot	8,08206501
ŚLĄSKIE	
Powiat m.Bielsko-Biała	2,00161532
Powiat m.Bytom	2,10677956
Powiat m.Chorzów	38,4164
Powiat m.Częstochowa	2,20545676
Powiat m.Dąbrowa Górnicza	2,71579093
Powiat m.Gliwice	2,03334164
Powiat m.Jastrzębie-Zdrój	4,57876306
Powiat m.Jaworzno	3,82865901
Powiat m.Katowice	20,7467713
Powiat m.Mysłowice	3,35509906
Powiat m.Piekary Śląskie	5,03086055
Powiat m.Ruda Śląska	2,001512
Powiat m.Rybnik	1,61328764
Powiat m.Siemianowice Śląskie	0,33387854
Powiat m.Sosnowiec	2,75007118
Powiat m.Świętochłowice	0,23036489

cd. tabeli 3.6

1	2
Powiat m.Tychy	2,77042124
Powiat m.Zabrze	1,64091757
Powiat m.Żory	1,64001423
ŚWIĘTOKRZYSKIE	
Powiat m.Kielce	100
WARMIŃSKO-MAZURSKIE	
Powiat m.Elbląg	62,2950072
Powiat m.Olsztyn	37,7049928
WIELKOPOLSKIE	
Powiat m.Kalisz	15,3124487
Powiat m.Konin	20,6024362
Powiat m.Leszno	28,9686949
Powiat m.Poznań	35,1164203
ZACHODNIOPOMORSKIE	
Powiat m.Koszalin	27,41413
Powiat m.Szczecin	39,0288605
Powiat m.Świnoujście	33,5570095

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stat.gov.pl> (10.09.2021).

Badaniu taksonomicznemu poddano zestaw czterech cech statystycznych obrazujących tematykę z zakresu kultury. Ostateczny zestaw danych był zależny również od ich dostępności. Dane uwzględniają rok 2020:

Y_1 – biblioteki publiczne w roku 2020,

Y_2 – liczba ludności na 1 miejsce w kinach stałych,

Y_3 – centra, domy i ośrodki kultury, kluby i świetlice,

Y_4 – zwiedzający muzea na 1 tys. odwiedzających.

W oparciu o zaprezentowaną metodę otrzymane wyniki zamieszczono w tabeli 3.6, która prezentuje struktury wygenerowane na podstawie wartości Shapleya z prekoalicjami. Prekoalicjami są województwa, w skład których wchodzi analizowane podregiony z danego zakresu tematycznego (Młodak, 2006).

Tabela 3.7. Poziom podziałów obiektów – Wartość Shapleya z prekoalicjami (zakres tematyczny ludność) w roku 2020 – normalizacja klasyczna

Nazwa	Normalizacja klasyczna
1	2
DOLNOŚLĄSKIE	
Powiat m.Jelenia Góra	8,145508641
Powiat m.Legnica	18,22854746
Powiat m.Wrocław	60,20166788
Powiat m.Wałbrzych od 2013	13,42427602
KUJAWSKO-POMORSKIE	
Powiat m.Bydgoszcz	29,72027815
Powiat m.Grudziądz	24,62754649
Powiat m.Toruń	26,08695616
Powiat m.Włocławek	19,5652192

cd. tabeli 3.7

1	2
LUBELSKIE	
Powiat m. Biała Podlaska	15,90125775
Powiat m. Chełm	23,90015204
Powiat m. Lublin	31,66459597
Powiat m. Zamość	28,53399424
LUBUSKIE	
Powiat m. Gorzów Wielkopolski	73,86362287
Powiat m. Zielona Góra	26,13637713
ŁÓDZKIE	
Powiat m. Łódź	48,31365417
Powiat m. Piotrków Trybunalski	22,66020605
Powiat m. Skierniewice	29,02613977
MAŁOPOLSKIE	
Powiat m. Kraków	44,83276609
Powiat m. Nowy Sącz	27,26418827
Powiat m. Tarnów	27,90304564
MAZOWIECKIE	
Powiat m. Ostrołęka	14,47047939
Powiat m. Płock	12,58669356
Powiat m. Radom	17,54451797
Powiat m. Siedlce	22,8865972
Powiat m. st. Warszawa	32,51171188
OPOLSKIE	
Powiat m. Opole	100
PODKARPACKIE	
Powiat m. Krosno	23,74634647
Powiat m. Przemyśl	29,12075354
Powiat m. Rzeszów	34,92241472
Powiat m. Tarnobrzeg	12,21048527
PODLASKIE	
Powiat m. Białystok	49,40536419
Powiat m. Łomża	32,53482863
Powiat m. Suwałki	18,05980718
POMORSKIE	
Powiat m. Gdańsk	23,23807111
Powiat m. Gdynia	23,44497652
Powiat m. Słupsk	26,91064216
Powiat m. Sopot	26,40631022
ŚLĄSKIE	
Powiat m. Bielsko-Biała	4,270184226
Powiat m. Bytom	7,365518285
Powiat m. Chorzów	8,142484729
Powiat m. Częstochowa	4,267051297
Powiat m. Dąbrowa Górnicza	1,964348329
Powiat m. Gliwice	4,141734129
Powiat m. Jastrzębie-Zdrój	3,233184658
Powiat m. Jaworzno	1,854695806
Powiat m. Katowice	10,06923619
Powiat m. Mysłowice	3,559009296
Powiat m. Piekary Śląskie	4,285848873

cd. tabeli 3.7

1	2
Powiat m.Ruda Śląska	5,498292476
Powiat m.Rybnik	2,894828304
Powiat m.Siemianowice Śląskie	5,529621769
Powiat m.Sosnowiec	6,798458098
Powiat m.Świętochłowice	11,5605105
Powiat m.Tychy	4,859174918
Powiat m.Zabrze	6,660609213
Powiat m.Żory	3,045208906
ŚWIĘTOKRZYSKIE	
Powiat m.Kielce	100
WARMIŃSKO-MAZURSKIE	
Powiat m.Elbląg	43,38686343
Powiat m.Olsztyn	56,61313657
WIELKOPOLSKIE	
Powiat m.Kalisz	22,61999132
Powiat m.Konin	13,9553341
Powiat m.Leszno	31,25296789
Powiat m.Poznań	32,17170668
ZACHODNIOPOMORSKIE	
Powiat m.Koszalin	41,41103786
Powiat m.Szczecin	50,80520372
Powiat m.Świnoujście	7,783758416

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stat.gov.pl> (10.09.2021).

W kolejnym etapie badaniu taksonomicznemu poddano zestaw czterech cech statystycznych obrazujących drugą tematykę, mianowicie z zakresu ludności. Dane te ostatecznie uwzględniono w zestawie po przeprowadzeniu analizy statystycznej oraz ze względu na dostępność danych. Dane uwzględniają rok 2020, a ich źródłem były publikacje GUS:

Y_5 – bezrobotni zarejestrowani pozostający bez pracy dłużej niż 1 rok w tys.,

Y_6 – urodzenia żywe na 1000 ludności,

Y_7 – ludność w tys.,

Y_8 – migracje wewnętrzne ludności na pobyt stały,

Y_9 – pracujący w tys.

W powyższych tabelach zaprezentowano procentowy poziom udziału każdego z analizowanych podregionów w danym województwie z uwzględnieniem danego zakresu tematycznego.

3.7. Podsumowanie

W niniejszym rozdziale przeprowadzono analizę w dwóch etapach. Celem pierwszego etapu badania było zastosowanie taksonomicznej metody grupowania obiektów w celu wyznaczenia grup obiektów jednorodnych pod względem poziomu rozwoju analizowanego zjawiska. W tym celu zastosowano metodę

grupowania zaproponowaną przez S. Chomątowskiego i A. Sokołowskiego, ale z uwzględnionymi modyfikacjami A. Młodaka. Do analizy wybrano zmienne, które mają istotny wpływ na badane zjawisko. Uwzględniono możliwie szeroką problematykę związaną z rozwojem społecznym uzależnioną od możliwości zebrania materiału statystycznego. Zakres czasowy etapu analizy obejmował lata 2010, 2015, 2020, aby uwzględnić lata przed pandemią COVID-19 i w jej trakcie.

W pierwszym z rozpatrywanych zakresów tematycznych – w zakresie ludnościowym – można zauważyć, że województwa dolnośląskie, małopolskie, pomorskie i mazowieckie zostały zakwalifikowane do jednej grupy, charakteryzującej się podobnym poziomem rozwoju analizowanego zjawiska w roku 2020. Natomiast województwa kujawsko-pomorskie, podkarpackie, łódzkie zachowały skład w rozpatrywanych latach. Województwo małopolskie i mazowieckie w 2020 roku zostały zakwalifikowane do jednej grupy, natomiast w 2015 województwo mazowieckie stanowiło grupę jednoelementową, a małopolskie uwzględniono w grupie z województwami dolnośląskim i pomorskim. W 2010 województwo mazowieckie również tworzyło odrębną grupę, a małopolskie, podobnie jak w 2015 roku, prezentowało poziom rozwoju województw dolnośląskiego i pomorskiego.

W zakresie drugiej tematyki – usług zdrowotnych, w 2020 roku województwo śląskie i małopolskie znalazły się w tej samej grupie, a mazowieckie stanowiło odrębną grupę. W roku 2015 województwa śląskie i mazowieckie należały do jednej grupy z tym samym poziomem rozwoju, a w roku 2010 ponownie województwa śląskie i małopolskie zostały zakwalifikowane do tej samej grupy. Natomiast województwo mazowieckie stanowiło odrębną grupę. Województwa lubuskie, podlaskie, świętokrzyskie i warmińsko-mazurskie w roku 2020, 2015, 2010 były uwzględnione w tej samej grupie. Z zakresu usług wychowawczych i oświatowych w roku 2020 województwo mazowieckie stanowiło odrębną grupę. Województwa małopolskie i śląskie zostały zakwalifikowane do tej samej grupy, podobnie jak województwa lubuskie, podlaskie, opolskie, świętokrzyskie, warmińsko-mazurskie i zachodniopomorskie, tym samym prezentowały ten sam poziom rozwoju zjawiska. W 2015 i 2010 województwa małopolskie, śląskie, mazowieckie występowały w tych samych grupach.

Z zakresu usług kulturalnych w 2020 roku województwa śląskie i mazowieckie stanowiły jedną grupę, a województwo małopolskie zostało ujęte w grupie z województwem dolnośląskim, pomorskim i wielkopolskim. Województwa świętokrzyskie, warmińsko-mazurskie, lubuskie, opolskie, podlaskie zostały ujęte w jednej grupie również w roku 2015. Województwo śląskie w 2015 zostało uwzględnione z województwem dolnośląskim i pomorskim, a województwo mazowieckie stanowiło odrębną grupę. W roku 2010 ten sam poziom rozwoju prezentowały województwa śląskie i mazowieckie, a małopolskie zostało zakwalifikowane do grupy z dolnośląskim i wielkopolskim. Natomiast województwa lubuskie, opolskie,

i świętokrzyskie tworzyły jedną grupę. Z zakresu zatrudnienia i wynagrodzenia w 2020 roku województwo mazowieckie stanowiło odrębną grupę, podobnie w 2015 i 2010. Województwo śląskie prezentowało poziom podkarpackiego, kujawsko-pomorskiego i wielkopolskiego. W roku 2015 województwo śląskie uwzględnione zostało w grupie z województwami dolnośląskimi i pomorskim, natomiast województwo małopolskie – z województwem wielkopolskim. W roku 2010 województwa śląskie i mazowieckie występowały w jednej grupie. Województwo małopolskie zostało zakwalifikowane do grupy z województwami zachodnio-pomorskim, wielkopolskim i opolskim. Województwo lubuskie, podlaskie i świętokrzyskie tworzyły jedną grupę w roku 2015 i 2010, a w 2020 roku lubuskie i podlaskie były w grupie z województwami opolskim i lubelskim.

Drugi etap badania obejmował przeprowadzenie analizy zróżnicowania podregionów w zakresie tematyki rozwoju społecznego, sprawdzając ich procentowy wpływ na całość rozważanego zjawiska. Wykorzystano w tym celu wartość Shapleya z prekoalicjami. Badaniu poddano dwa zakresy tematyczne – kultura i ludność. Na podstawie otrzymanych wyników można określić procentowy poziom udziału każdego z analizowanych podregionów w danym województwie. W oparciu o otrzymane wyniki można ogólnie stwierdzić, że województwa w Polsce rozwijają się na różnym poziomie społecznym. Najbogatszym województwem jest mazowieckie, które zawdzięcza to przede wszystkim Warszawie – mieście biznesu. W niej znajdują się siedziby największych firm czy zagranicznych inwestorów. Dostęp do szkolnictwa, użytkowania nowych technologii, nowoczesnych usług zdrowotnych itp. jest na bardzo wysokim poziomie. Bogatym województwem jest również województwo dolnośląskie ze względu na Wrocław dający również szerokie możliwości rozwoju. Do najbiedniejszych województw należą między innymi województwa lubelskie, podkarpackie i warmińsko-mazurskie. Województwo lubelskie charakteryzuje się najwyższym odsetkiem ludzi ubogich. Badanie dało możliwość potwierdzenia występującego zróżnicowania, prezentując dysproporcje w poziomie rozwoju społecznego oraz zarysowaną różnicę pomiędzy wschodnią i zachodnią częścią kraju. Rozwój społeczny w zakresie analizowanych województw uzależniony jest od wielu czynników zależnych od danego regionu oraz zjawisk i procesów tam występujących. Miasta bogatsze dają możliwość dostępu do większego zakresu służby zdrowia, do Internetu i nowych technologii, wyższego poziomu szkolnictwa, wspomagania rozwoju obszarów wiejskich, jak również zaniżenia bezrobocia itd. Dodatkowo mogą uwzględnić większą ilość środków, w tym również finansowych zasobów, na walkę z pandemią COVID-19 i zarazem jej licznymi skutkami, co jest utrudnione w przypadku regionów biedniejszych. Możemy stwierdzić, że pandemia zwróciła naszą uwagę na wiele poważnych problemów, na przykład nierówność na poziomie życia różnych społeczeństw. Znaczące zróżnicowanie w poziomie rozwoju jest uzależnione od zamieszkiwanego regionu.

Literatura

- Chomątowski, S., Sokołowski, A. (1978). Taksonomia struktur. *Przegląd Statystyczny*, XXV(2), 217-227.
- Hellwig, Z. (1968). Zastosowanie metody taksonomicznej do typologicznego podziału krajów ze względu na poziom ich rozwoju oraz zasoby i strukturę wykwalifikowanych kadr. *Przegląd Statystyczny*, XV(4), 307-327.
- Grabiński, T., Wydymus, A., Zeliaś, A. (1989). *Metody taksonomii numerycznej w modelowaniu zjawisk społeczno-gospodarczych*. Warszawa: PWN.
- Młodak, A. (2006). *Analiza taksonomiczna w statystyce regionalnej*. Warszawa: Difin.
- Panek, T. (2009). *Statystyczne metody wielowymiarowej analizy porównawczej*. Warszawa: Oficyna Wydawnicza Szkoły Głównej Handlowej.
- Pociecha, J., Podolec B., Sokołowski, A., Zając, K. (1988). *Metody taksonomiczne w badaniach społeczno-ekonomicznych*. Warszawa: PWN.
- Shapley, L. (1953). A value for n -person games. W H. W. Kuhn, A. W. Tucker (red.), *Contributions to the theory of games* (Vol. II; s. 306-316). Princeton: Princeton University Press.
- Strahl, D. (1998). *Taksonomia struktur w badaniach regionalnych*. Wrocław: Wydawnictwo Akademii Ekonomicznej.
- Wojnowski, J. (red.). (2002). *Wielka Encyklopedia PWN* (tom 24). Wydawnictwo Naukowe PWN.

4. Zastosowanie metod przestrzennych w analizie zjawiska przestępczości

(Katarzyna Zeug-Żebro)

4.1. Wprowadzenie

Do grupy głównych problemów społecznych obserwowanych współcześnie należy zaliczyć zjawisko przestępczości. Na całym świecie nielegalne działania powodują utratę mienia i życia, a także inne poważne straty. Ponieważ przestępczość wpływa niekorzystnie na sytuację społeczną, a także na warunki życia i rozwoju, również gospodarczego, zwalczanie tego zjawiska stało się nadrzędnym celem wielu państw, jak też organizacji międzynarodowych, między innymi ONZ czy Unii Europejskiej (Bąk, 2015). Poczucie bezpieczeństwa, brak zagrożenia przemocą i przestępczością warunkują właściwe relacje społeczne oraz wspomagają wzrost gospodarczy, a także rozwój zrównoważony. Sprzyjają efektywnemu funkcjonowaniu przedsiębiorstw, zwłaszcza z grupy małych i średnich, oraz przeciwdziałają zjawisku ubóstwa i wykluczenia społecznego (European Forum for Urban Safety [EFUS], 2007).

Ważne jest więc monitorowanie przestępczości w skali kraju, ale także w skali regionów – województw czy powiatów, wykrywanie istniejących zależności, w tym przestrzennych. Według Chaineya i Ratcliffe’a (2005) pomoc w zrozumieniu rozkładu przestrzennego przestępczości można uzyskać poprzez konstruowanie map tematycznych, a badanie mechanizmów, dynamiki i czynników sprzyjających jej rozwojowi poprzez opracowanie modelu regresji przestrzennej. Zwracają oni również uwagę na autokorelację przestrzenną, na podstawie której możliwa jest identyfikacja hot spotów przestępczości, czyli miejsc koncentracji analizowanego zjawiska (Kopczewska, 2011; Szulc, 2008).

Celem rozdziału jest zidentyfikowanie zależności przestrzennych zachodzących w Polsce pod względem przestępczości oraz próba wykorzystania wybranych metod i modeli ekonometrii przestrzennej w badaniach tego problemu. Układ przestrzenny przestępczości został przeanalizowany na poziomie powiatów. W aktualnie obowiązującym w Polsce (według stanu na 1 stycznia 2021 roku) podziale wyróżniono 380 jednostek przestrzennych (powiatów). W poszczególnych częściach rozdziału dokonano krótkiej analizy zjawiska przestępczości w Polsce, następnie zaprezentowano statystyki przestrzenne wykorzystywane w analizach oraz wyniki modelowania przestrzennego tego zjawiska.

Badania przeprowadzono bazując na danych pozyskanych z Banku Danych Lokalnych Głównego Urzędu Statystycznego. Ze względu na ograniczenia wynikające z dostępności danych źródłowych dotyczących powiatów, analizę przeprowadzono tylko dla wybranych lat z okresu 2013-2020. Wszystkie obliczenia wykonano przy użyciu programu R Cran i pakietu Microsoft Excel.


4.2. Zjawisko przestępczości w Polsce

Pod pojęciem przestępczości kryją się wszystkie czyny, które są zabronione przez ustawę pod groźbą kary. Czyny te muszą zostać popełnione na danym terenie lub w danym kraju w określonym czasie. Najczęściej popełnianymi przestępstwami w krajach Unii Europejskiej są: zabójstwa, napaści, rozboje, porwania, kradzieże, przestępstwa związane z narkotykami i przemocą seksualną oraz cyberprzestępstwa.

W ostatnich latach w Polsce wyraźnie widoczny jest trend spadkowy liczby stwierdzonych przez policję przestępstw. Nie przebiegał on jednak równomiernie w całym badanym okresie (rysunek 4.1). W latach 2002-2004 liczba przestępstw wzrastała, jednak od 2005 roku zaczęła spadać i w 2008 roku była o 23% niższa niż w roku 2002. Następnie w latach 2009-2011 liczba ta nieznacznie wzrastała, po czym ponownie zaczęła spadać i w roku 2016 policja stwierdziła w Polsce 748 459 przestępstw. Oznacza to spadek liczby przestępstw stwierdzonych ogółem w stosunku do 2002 roku o prawie 47%. W latach 2017-2019 ponownie można było zaobserwować wzrost do 796 557 przestępstw, jednak w 2020 roku liczba ta ponownie zmalała i ostatecznie osiągnęła poziom 765 408 przestępstw.

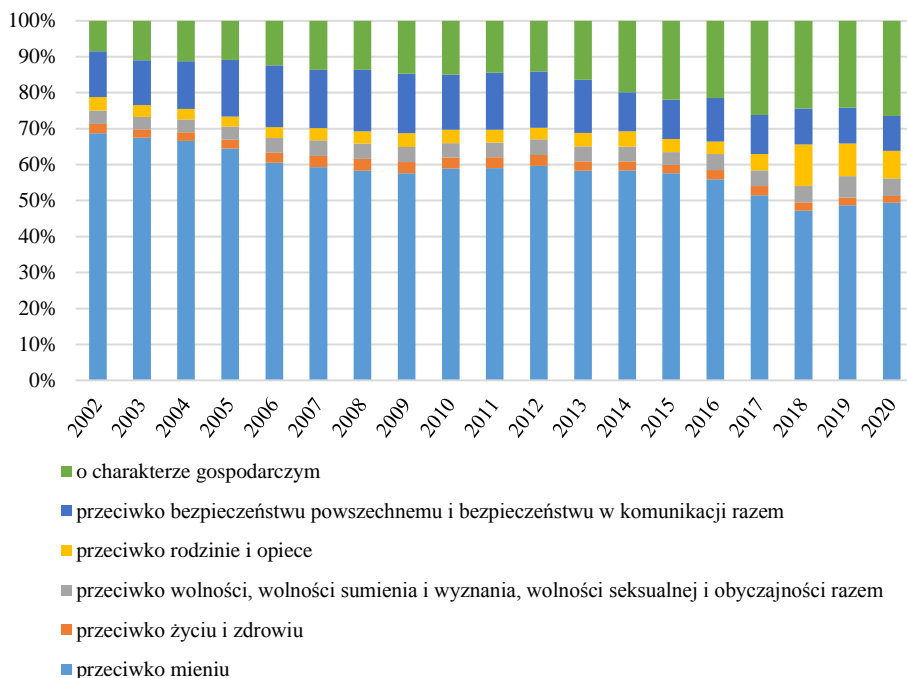
Rysunek 4.2 przedstawia strukturę przestępczości stwierdzonej w Polsce w latach 2002- 2020. W analizowanym okresie dominowały przestępstwa przeciwko mieniu (takie jak kradzieże, włamania, rozboje), jednak ich udział w tej strukturze malał. Wpływ na tę sytuację mogły mieć między innymi spadek stopy bezrobocia, coraz niższy udział osób z niskim wykształceniem w strukturze osób według wykształcenia (Kądziołka, 2016a).

W strukturze przestępczości stwierdzonej w Polsce wyraźnie uwidacznia się wzrost udziału przestępstw o charakterze gospodarczym. Za ten rodzaj przestępstwa zwykle odpowiadają osoby z wyższych grup społecznych, dobrze wykształcone, specjaliści. Do tej grupy czynów należą m.in. przestępstwa przeciwko: przedsiębiorstwom, konsumentom, podstawowym instytucjom gospodarczym, interesom finansowym państwa, a także przestępczość związana z naruszaniem prawa własności intelektualnej (Bąk, 2015). W 2020 roku liczba stwierdzonych przestępstw gospodarczych wyniosła w Polsce 198 163 i była wyższa w porównaniu z rokiem 2002 o ponad 80%.



Rys. 4.1. Liczba przestępstw stwierdzonych w Polsce w latach 2002-2020

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).



Rys. 4.2. Struktura przestępczości stwierdzonej w Polsce w latach 2002-2020

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

Wpływ na wzrost zagrożenia przestępczością gospodarczą ma również rozwój technologii informatycznych. Niektóre przestępstwa zostały przeniesione do Internetu. W dobie koronawirusa przestępcy bardzo szybko zaadaptowali się do nowej sytuacji, wykorzystując niepokoje społeczeństwa (Interpol, 2020). Prawie na całym świecie organy ścigania odnotowały wyraźny wzrost zagrożeń cybernetycznych (Europol, 2020), takich jak złośliwe oprogramowanie i oprogramowanie wymuszające, kradzież tożsamości, a także sprzedaż podrabianych i pirackich produktów, takich jak środki ochrony osobistej czy leki. W tamtym okresie pojawiały się również informacje o fałszywych certyfikatach szczepionek i negatywnych wynikach testów.

Oprócz cyberataków społeczeństwo zmagало się ze wzrostem przemocy domowej (przestępstwa przeciwko rodzinie), wynikającej prawdopodobnie z braku możliwości wyjścia na zewnątrz (kwarantanna, izolacja) oraz przebywanie w tym samym pomieszczeniu (kata i ofiary). Ten rodzaj ograniczeń nierzadko przyczynia się do eskalacji istniejących wcześniej konfliktów (UN, 2020).

Przestępczość nie jest zjawiskiem, które występuje z takim samym nasileniem na całym obszarze Polski. Ponadprzeciętnym natężeniem przestępstw charakteryzują się głównie obszary miejskie, a także powiaty zlokalizowane w pobliżu zachodniej i wschodniej granicy (rysunek 4.3).

Dane dotyczące natężenia przestępczości (przestępstwa stwierdzone przez Policję ogółem na 1000 mieszkańców) mogą stanowić podstawę klasyfikacji powiatów Polski (rysunek 4.3), ze względu na jednorodne grupy, z punktu widzenia osiągniętego stopnia badanego zjawiska (tj. natężenia przestępstw). Grupy te tworzy się według następujących reguł:

- $\bar{y} + S_y \leq y_i$ grupa I (bardzo wysoki poziom natężenia przestępstw),
- $\bar{y} \leq y_i < \bar{y} + S_y$ grupa II (wysoki poziom natężenia przestępstw),
- $\bar{y} - S_y \leq y_i < \bar{y}$ grupa III (średni poziom natężenia przestępstw),
- $y_i < \bar{y} - S_y$ grupa IV (niski poziom natężenia przestępstw),

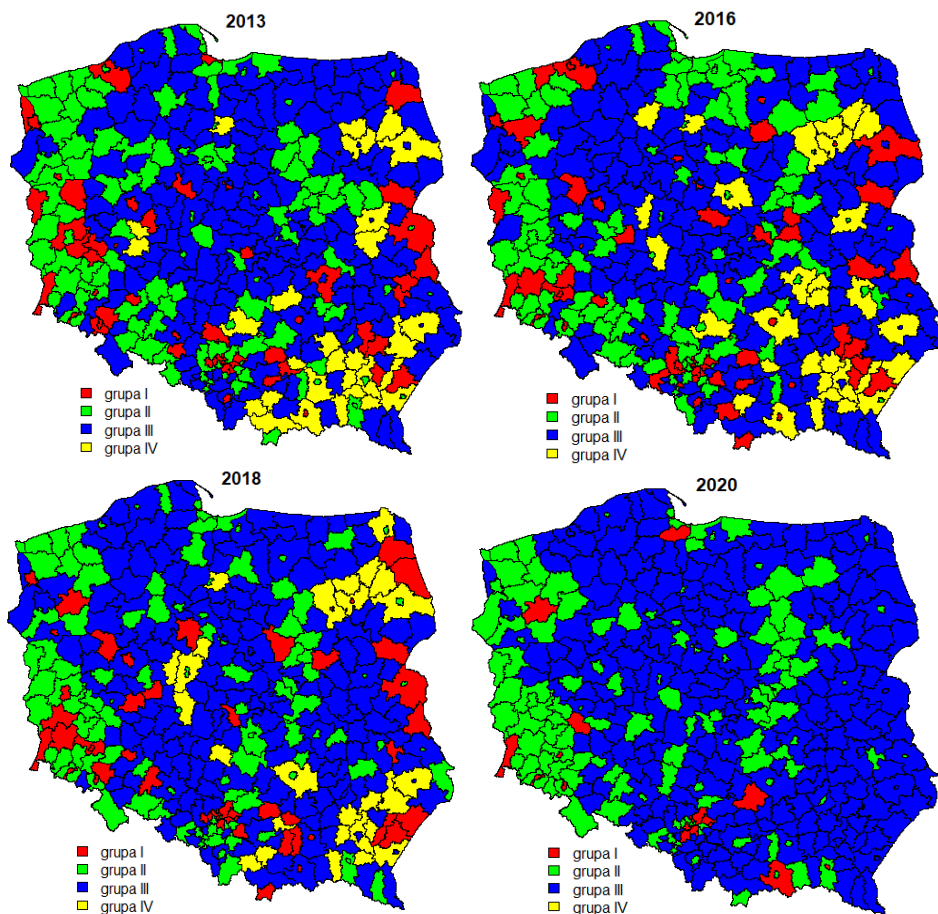
gdzie y_i oznacza wartość natężenia przestępstw w i – tym powiecie,

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i, S_y = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{tabela 4.1}) \quad (1)$$

Tabela 4.1. Średnia i odchylenie standardowe natężenia przestępstw w latach 2013, 2016, 2018 i 2020

Miary	2013	2016	2018	2020
Średnia \bar{y}	25,2716	17,7145	18,5044	19,0767
Odchylenie standardowe S_y	10,3075	7,5099	8,4863	13,6279

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).



Rys. 4.3. Klasyfikacja natężenia przestępstw w latach 2013, 2016, 2018 i 2020

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl/> (18.02.2022).

Tabela 4.2. Liczba powiatów według klasyfikacji natężenia przestępczości

Grupy	Liczba powiatów			
	2013	2016	2018	2020
I	56	62	52	18
II	114	106	108	126
III	181	181	193	236
IV	29	31	27	0

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl/> (18.02.2022).

Najwyższy wskaźnik natężenia przestępstw według przeprowadzonej klasyfikacji (tabela 4.2) w 2013 roku dotyczył 56 powiatów, w 2016 roku liczba powiatów zwiększyła się do 62, w 2018 r. zmalała do 52, a w 2020 roku osiągnęła

najniższy poziom od wielu lat, tj. 18 powiatów (miasta Krosno, Ostrołęka, Sopot, Katowice, Dąbrowa Górnicza, Piekary Śląskie, Ruda Śląska, Jelenia Góra, Legnica, Wałbrzych oraz powiaty nowosądecki, jędrzejowski, gdański, zgorzelecki, będziński, choszczeński, górowski, mikołowski). Wśród powiatów, które we wszystkich analizowanych latach charakteryzowały się największym natężeniem przestępstw, znalazły się miasta: Sopot, Katowice, Dąbrowa Górnicza, Piekary Śląskie, Jelenia Góra, Legnica, Wałbrzych oraz powiat zgorzelecki. Najniższą wartością wskaźnika w latach 2013, 2016 i 2018 charakteryzowało się około 30 powiatów. W 2020 roku do grupy IV nie należał żaden powiat. Najwięcej powiatów należało do grupy III ze średnim poziomem natężenia przestępczości (od 181 w 2013 roku do 236 w 2020 roku) oraz do grupy II, opisującej wysoką wartość wskaźnika przestępczości (od 114 w 2013 roku do 126 w 2020 roku). Skupienie obszarów o średniej i niskiej przestępczości można obserwować w środkowej i wschodniej części kraju.

4.3. Statystyki przestrzenne

Autokorelacja przestrzenna, czyli zależność przestrzenna, opisuje sytuację, gdy poziom zjawiska badanego w jednej jednostce przestrzennej ma wpływ (stymulujący lub destymulujący) na poziom tego zjawiska w jednostkach sąsiednich (Bivand, 1980, s. 23).

W statystyce przestrzennej szacuje się globalne i lokalne miar autokorelacji przestrzennej. Globalna autokorelacja wynika z istnienia korelacji w obrębie całej badanej jednostki przestrzennej, miary lokalne zaś wykazują zależności przestrzenne danej zmiennej z jednostkami sąsiadującymi w konkretnej lokalizacji. Do najczęściej wykorzystywanych miar globalnych należy statystyka *I* Morana [Moran, 1950]. Do miar lokalnych należą: wskaźniki LISA (Anselin, 1995) (lokalna statystyka Morana I_i i Geary'ego C_i) oraz lokalna statystyka Getisa–Orda G_i (Ord, Getis, 1995).

4.4. Globalna statystyka Morana

Globalna statystyka *I* Morana (Moran, 1950) zdefiniowana jest następująco:

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n \sum_{j=1}^n w_{ij} \cdot \sum_{i=1}^n (x_i - \bar{x})^2} = \frac{n}{s_0} \cdot \frac{\mathbf{z}^T \mathbf{W} \mathbf{z}}{\mathbf{z}^T \mathbf{z}} \quad (2)$$

gdzie:

x_i, x_j – wartości zmiennych w jednostce przestrzennej i ,

j, \bar{x} – średnia arytmetyczna wartości zmiennej dla wszystkich jednostek,

n – liczba wszystkich jednostek przestrzennych uwzględnionych w badaniu,
 S_0 – suma wszystkich elementów macierzy wag,
 \mathbf{z} – wektor kolumnowy o elementach $z_i = x_i - \bar{x}$,
 \mathbf{W} – macierz wag przestrzennych stopnia n , definiującą strukturę sąsiedztwa,
 w_{ij} – element zero-jedynkowy macierzy wag \mathbf{W} ($w_{ij} = 1$, gdy jednostka i -ta jest sąsiadem j -tej jednostki).

Istotność statystyczna autokorelacji przestrzennej może być zweryfikowana za pomocą unormowanej statystyki $I^S \sim N(0, 1)$ (Cliff, Ord, 1973):

$$I^S = \frac{I - E(I)}{\sqrt{\text{Var}(I)}}, \quad (3)$$

gdzie:

$E(I)$ – wartość oczekiwana statystyki Morana,

$\text{Var}(I)$ – jej wariancja:

$$E(I) = -\frac{1}{n-1} \quad \text{Var}(I) = \frac{n^2 S_1 - n S_2 + 3 S_0^2}{(n^2 - 1) S_0^2} - \frac{1}{(n-1)^2}, \quad (4)$$

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}, \quad S_1 = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (w_{ij} + w_{ji})^2, \quad S_2 = \sum_{i=1}^n \left(\sum_{j=1}^n w_{ij} + \sum_{j=1}^n w_{ji} \right)^2 \quad (5)$$

Jeżeli statystyka Morana ma wartości $I \approx -\frac{1}{n-1}$, $I^S \approx 0$, mówi się o braku autokorelacji, natomiast gdy $I > -\frac{1}{n-1}$, $I^S > 0$, mamy do czynienia z autokorelacją dodatnią, a dla $I < -\frac{1}{n-1}$, $I^S < 0$ występuje zjawisko autokorelacji ujemnej.

4.5. Wybrane statystyki lokalne

Lokalne statystyki przestrzenne pozwalają na identyfikację tzw. hot spotów, czyli obszarów o wysokich wartościach otoczonych przez jednostki o niższych wartościach, a także klastrów lokalnych przy braku autokorelacji globalnej. Umożliwiają również wskazywanie *outliers* (wartości odstających), dla których statystyki lokalne są wskaźnikami lokalnej niestabilności i lokalnych odchyłeń od globalnego wzorca autokorelacji (Kopczewska, 2020).

4.5.1. Lokalna statystyka Getisa-Orda

Lokalna statystyka G_i wprowadzona przez Orda i Getisa (1995) pozwala na wykrycie istnienia związków przestrzennych w badanej zmiennej. Statystyka ta porównuje sumę wartości w obszarach sąsiedzkich w pewnej odległości z sumą wartości we wszystkich obszarach:

$$G_i = \frac{\sum_{j,j \neq i}^n w_{ij} x_j}{\sum_{j,j \neq i}^n x_j}, \quad (6)$$

gdzie wszystkie element są zdefiniowane jak w statystyce globalnej Morana.

Dodatnie i istotne statystyki G_i ($p\text{-value} < 0.05$) regionie i oznaczają zgrupowanie regionów o wysokich wartościach (regionu i oraz sąsiedzkich), tzw. klaster wartości wysokich. Ujemne wartości statystyki Getisa (istotne dla $p\text{-value} > 0.95$) wskazują na istnienie klastra regionów o niskich wartościach badanej zmiennej, tj. region i jest otoczony przez podobne mu regiony o niskich wartościach (Kopczewska, 2020).

4.5.2. Lokalna heteroskedastyczność przestrzenna

Analizę podobieństwa sąsiedzkiego można dodatkowo rozszerzyć o stabilność zmiennej w przestrzeni. W tym celu wykorzystuje się miarę lokalnej heteroskedastyczności przestrzennej LOSH H_i , będącej uzupełnieniem statystyki lokalnej G_i (Kopczewska, 2020). Połączona analiza obu miar pozwala na identyfikację podobieństwa i niestabilności zmiennej w przestrzeni. LOSH mierzy wariancje zmiennej w sąsiedztwie, wskazując na obszary o jednolitej i zróżnicowanej zmienności, w analogiczny sposób do statystyki Getisa (Ord, Getis, 2012). Miara H_i wyraża się wzorem:

$$H_i(d) = \left[\sum_j w_{ij}(d) |e_j(d)|^a \right] / \left[\sum_j w_{ij}(d) \right], \quad (7)$$

gdzie:

$e_j(d) = x_j - \bar{x}_j(d)$ dla $j \in N(i, d)$ jest resztą,

$$\bar{x}_j(d) = \left[\sum_j w_{ij}(d) x_j \right] / \left[\sum_j w_{ij}(d) \right]. \quad (8)$$

Dla $a = 1$ statystyka H_i jest miarą odchylenia absolutnego oraz wariancji dla $a = 2$. Wysokie wartości H_i wskazują zróżnicowania otoczenia, natomiast niskie wartości oznaczają jego podobieństwo.

4.6. Analiza przestrzenna zjawiska przestępczości w Polsce w latach 2013, 2016, 2018 i 2020

Analiza autokorelacji przestępczości polega na wykrywaniu obecności skupień zdarzeń kryminalnych lub ich braku. W tym celu badaniu poddano natężenie przestępczości (przestępstwa stwierdzone przez policję ogółem na 1000 mieszkańców) w powiatach Polski w latach 2013, 2016, 2018-2020. W pierwszym kroku wyznaczono wartości globalnej statystyki Morana dla macierzy wag, której

kryterium była wspólna granica. Dane wykorzystane w badaniu zostały zaczerpnięte z Banku Danych Lokalnych GUS-u, natomiast do obliczeń i graficznej prezentacji wyników wykorzystano pakiet MS Excel oraz program R CRAN.

Obliczone wartości globalnych statystyk Morana zostały przedstawione w tabeli 4.3.

Tabela 4.3. Wartości statystyk globalnych Morana dla wskaźnika przestępczości w Polsce w ujęciu powiatowym

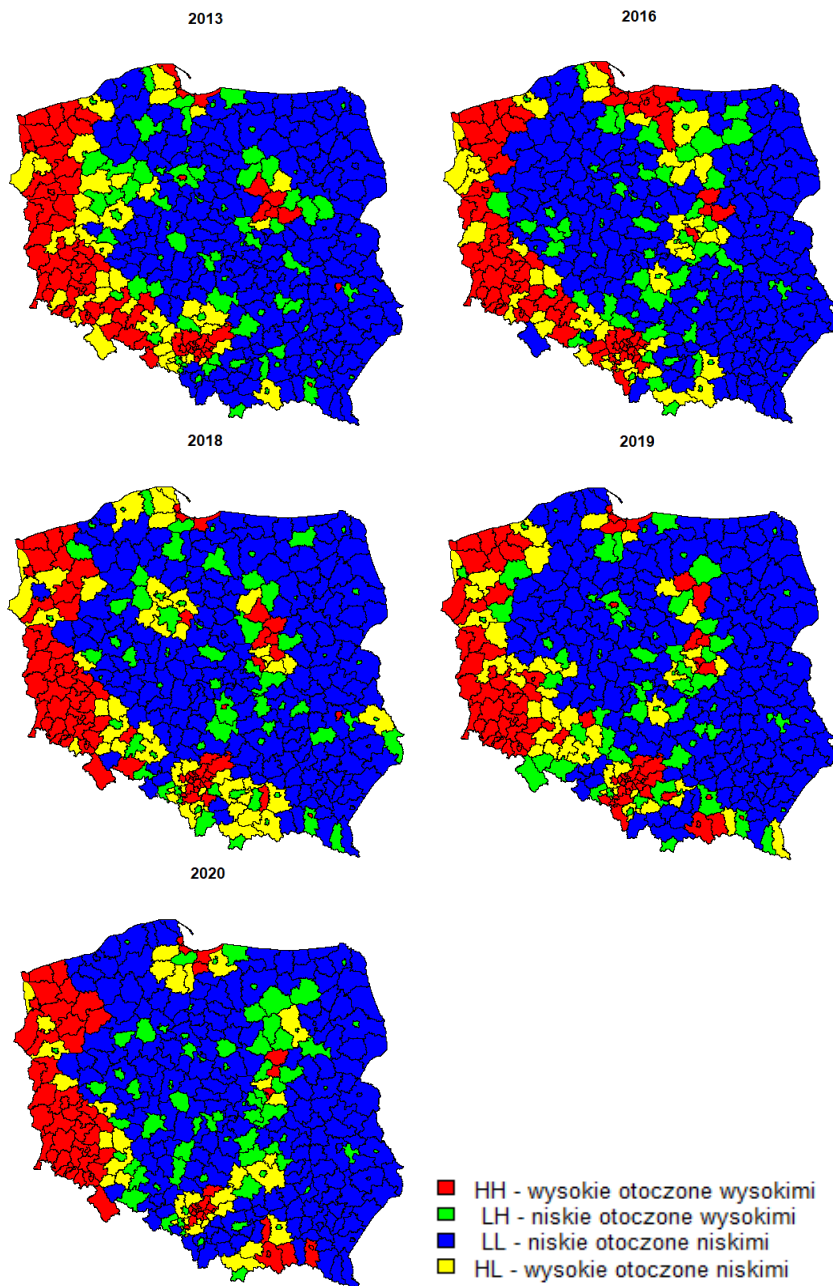
Rok	Statystyka Morana			
	I	$E(I)$	$Var(I)$	$p\text{-value}$
2013	0,29963	-0,00264	0,00113	$2,2 \cdot 10^{-16}$
2016	0,18731	-0,00264	0,00112	$7,1 \cdot 10^{-9}$
2018	0,18593	-0,00264	0,00113	$1,0 \cdot 10^{-8}$
2019	0,26348	-0,00264	0,00113	$1,4 \cdot 10^{-15}$
2020	0,15511	-0,00264	0,00092	$9,4 \cdot 10^{-8}$

Na podstawie uzyskanych wyników (tabela 4.3) można zauważyć, że wartości statystyki globalnej Morana dla badanego okresu przyjmują wartości istotne i większe od wartości oczekiwanej tej statystyki, co wskazuje na dodatnią autokorelację przestrzenną. Wobec tego można przyjąć, że w analizowanym przypadku występuje tendencja do skupiania jednostek przestrzennych o podobnym poziomie natężenia przestępczości. Spadek wartości statystyki globalnej Morana w 2016 i 2020 roku informuje o zachodzącym procesie osłabiania zależności przestrzennej.

Graficzną prezentację statystyki Morana dla wskaźnika przestępczości w latach 2002-2016 przedstawia rysunek 4.4.

Jak można zauważyć, powiaty są podzielone na cztery grupy: obiekty położone w grupie HH i LL charakteryzują się dodatnią autokorelacją przestrzenną (powiaty tego obszaru łączą się w skupienia (klastry) regionów o podobnych, niskich lub wysokich wartościach zmiennej), natomiast obiekty znajdujące się w grupach LH oraz HL cechują się autokorelacją ujemną (oznaczają obiekty nietypowe). Powiaty o odstających wartościach natężenia przestępczości dla poszczególnych lat zaprezentowano w tabeli 4.4.

Pogrubioną czcionką oznaczono powiaty (tabela 4.4), dla których wartości wskaźnika przestępczości przewyższają wartości w regionach sąsiedzkich znacznie bardziej niż by to wynikało z ogólnego wzorca przestrzennego. Są to tzw. hot spots, czyli obszary bardziej niebezpieczne (wysokie natężenie przestępczości) niż sąsiedzi. Pozostałe powiaty wyszczególnione w tabeli 4.4, to regiony bezpieczniejsze, których sąsiedzi mają wyższe niż średnie wartości wskaźnika przestępczości.



Rys. 4.4. Autokorelacja przestrzenna natężenia przestępstw w Polsce według powiatów w latach 2013, 2016, 2018, 2019 i 2020

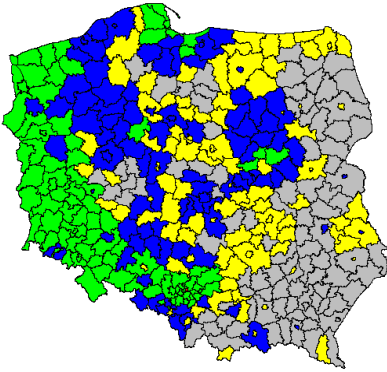
Tabela 4.4. Powiaty o odstających wartościach wskaźnika przestępczości w latach 2013, 2016, 2018, 2019 i 2020

POWIATY				
2013	2016	2018	2019	2020
Rzeszów	Rzeszów	brzeski	leski	Krosno
Nowy Sącz*	tatrzański	bocheński	Krosno	nowosądecki
wschowski	Tarnów	chrzanowski	Rzeszów	Nowy Sącz*
Gorzów Wlk.	Nowy Sącz*	limanowski	Przemyśl	krośnieński
gorzowski	żyrardowski	tatrzański	Nowy Sącz*	Ostrołęka
międzyrzecki	Łomża	Tarnów	Zielona Góra	gdański
nowosolski	Sopot*	wielicki	Ostrołęka	Sopot*
Opole	Wrocław	Nowy Sącz*	leszczyński	Siemianowice
Poznań	Jelenia Góra	Ostrołęka	gostyński	Świętochłowice
Sopot*	Siemianowice	Sopot*	Leszno	Zabrze
Wrocław	Ruda Śląska	Jelenia Góra	Kielce	będziński
głogowski	Gdańsk	Siemianowice	Sopot*	Ruda Śląska
Siemianowice	Chorzów	będziński	świdwiński	tarnogórski
Świętochłowice	Bielsko-Biała	choszczeński	Jelenia Góra	Chorzów
Ruda Śląska	Bytom	Szczecin	zgorzelecki	Bytom
górowski	Dąbrowa Górń.	Sosnowiec	Siemianowice	Piekary Śląskie
Sosnowiec	Piekary Śląskie	tarnogórski	białogardzki	Legnica*
bieruńsko-łędz.	Katowice	Chorzów	kołobrzegi	lubański
Chorzów	Legnica*	Bytom	Szczecin	
Bytom	Wałbrzych	Piekary Śląskie	Dąbrowa Górń.	
Dąbrowa Górń.	polkowicki	Legnica*	Katowice	
Piekary Śląskie	Legnicki	inowrocławski	policki	
Katowice		polkowicki	Legnica*	
Legnica*			lubański	
Wałbrzych			Wałbrzych	
wałbrzyski				


* Powiaty, które powtarzały się w każdym roku.

Dotychczas przeprowadzone badania pozwoliły jedynie na ogólną charakterystykę autokorelacji przestrzennej. W celu uzyskania bardziej szczegółowych informacji w kolejnym kroku analizy wyznaczono lokalną statystykę Getisa oraz miarę lokalnej heteroskedastyczności LOSH. Łączna analiza obu statystyk pozwala na określenie relatywnego poziomu zjawiska (statystyka G_i) oraz jego lokalnego zróżnicowania (statystyka H_i) (Getis, Ord, 2012). Wyniki analiz, dla wybranych lat, obrazuje rysunek 5.5.


GI_2013




HI_2013



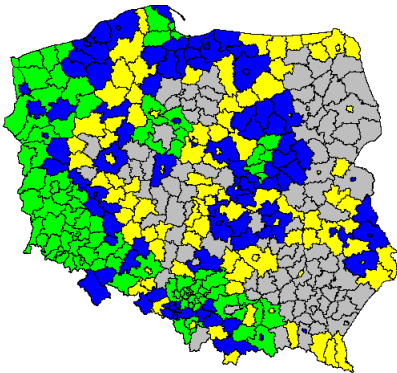
GI_2016




HI_2016

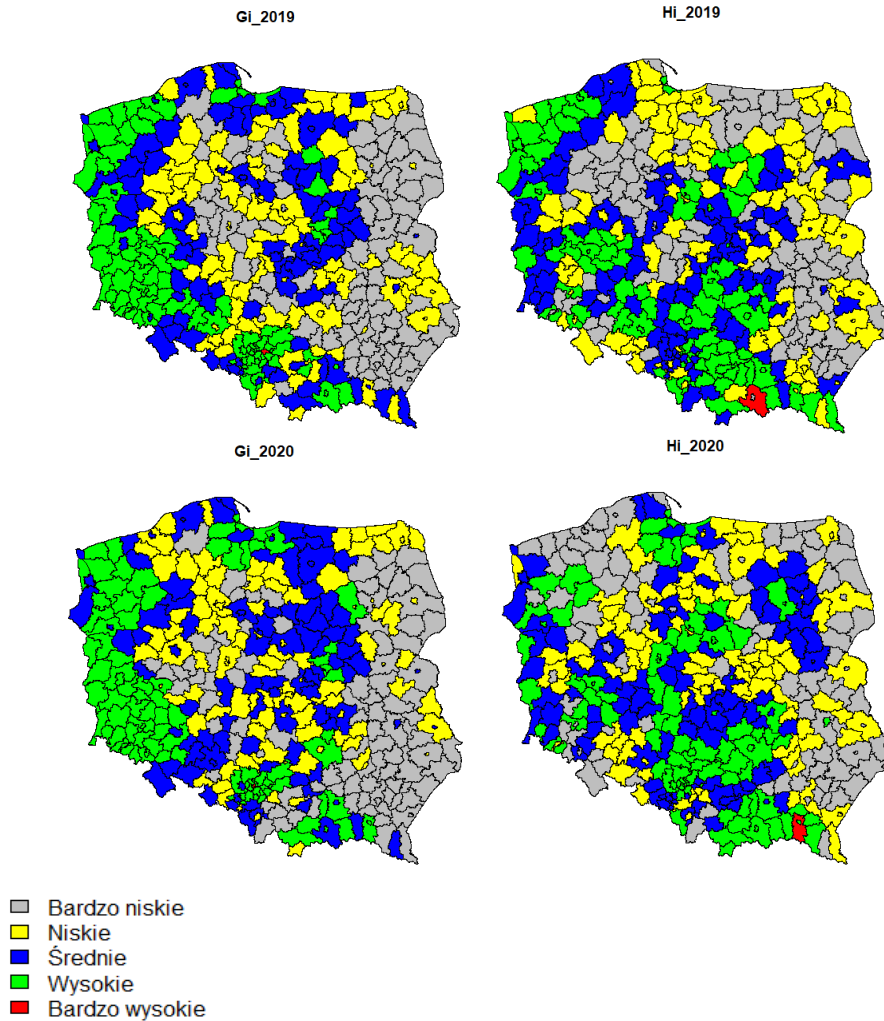


GI_2018



HI_2018





Rys. 4.5. Lokalne statystyki Getisa i heteroskedastyczności przestrzennej w latach 2013, 2016, 2018, 2019 i 2020

Wykresy statystyk G_i (mapy znajdujące się po lewej stronie rysunku 4.5) ilustrują autokorelację przestrzenną. We wszystkich analizowanych okresach w zachodniej części map można dostrzec szerokie obszary wartości wysokich tej miary. Zgrupowania wysokich wartości G_i widoczne są również w województwach śląskim, małopolskim i pomorskim (większe lub mniejsze w zależności od roku). Zestawienie ich z wykresami statystyki LOSH (mapy znajdujące się po prawej stronie rysunku 4.5) pozwala na określenie stabilności wzorca, opartej na wariancji w przestrzeni. Wyjątek stanowią obszary znajdujące się w województwie pomorskim w latach 2013, 2016 i 2019, dla których widoczne są różne poziomy lokalnego zróżnicowania H_i (niskie i średnie w 2013 r. oraz niskie

i bardzo niskie w 2016 i 2019 r.). Oznacza to, że powiaty te są relatywnie stabilnym klastrem wysokiego natężenia przestępczością. Inne wzorce obserwowane są we wschodniej części Polski. Niskie wartości zjawiska, mają niski poziom różnicowania, czyli wykazują lokalną homogeniczność.

Podwyższony wskaźnik LOSH obserwowany w środkowej części kraju, sugeruje nieciągłość przestrzenną. Obszary te stanowią skupisko odróżniających się wartości (natężenia przestępczości) z heterogenicznym otoczeniem, tzn. obszary sąsiedzkie wykazują odmienne wartości wskaźnika przestępczości.

4.7. Modele przestrzenne

Modele przestrzenne, podobnie jak badania autokorelacji przestrzennej, bazują na macierzach wag, czyli uwzględniają sąsiedztwo i położenie jednostek przestrzennych. Przestrzenne podejście do badania regresji polega na wykryciu efektów przestrzennych cech zależnych (nazywanych opóźnieniem przestrzennym) i cech niezależnych (błąd przestrzenny) (Mordwa, 2013). Zgodnie z koncepcją Anselina (2002), jeśli zostaną zidentyfikowane opóźnienia bądź błędy przestrzenne, to model regresji zostanie tak dopasowany, aby te przestrzenne efekty za bardzo nie oddziaływały na siłę wyjaśniającą uzyskanego modelu regresji.

Wyróżnia się kilka grup modeli przestrzennych. Do podstawowych grup zaliczyć można modele opóźnienia przestrzennego, modele błędu przestrzennego, modele regresji krzyżowej oraz warianty mieszane.

4.7.1. Model opóźnienia przestrzennego

Przestrzenny model opóźnienia jest modelem typu autoregresyjnego, tzn. zawiera opóźnioną przestrzennie zmienną endogeniczną $\mathbf{W}y$. Ogólną postać tego modelu można zapisać za pomocą następującego wzoru:

$$y = \beta\mathbf{X} + \alpha\mathbf{W}y + \varepsilon, \varepsilon \sim N(0, \sigma^2\mathbf{I}), \quad (9)$$

gdzie:

β – wektor współczynników modelu,

\mathbf{X} – macierz zmiennych niezależnych,

ε – błąd modelu,

α – współczynnik autokorelacji przestrzennej,

\mathbf{W} – macierz wag przestrzennych $[w_{ij}]$, $i = 1, 2, \dots, n, j = 1, 2, \dots, n$, ($w_{ij} = 1$, gdy jednostka i – ta jest sąsiadem j – tej jednostki).

Za pomocą modelu opóźnienia przestrzennego sprawdza się istotność opóźnionej przestrzennie zmiennej zależnej, tj. czy $\alpha = 0$. Opóźnienie przestrzenne $\mathbf{W}y$ interpretowane jest jako poziom zmiennej zależnej (y) w obszarach sąsiedzkich. W przypadku, gdy to opóźnienie jest istotne, poziom zmiennej zależnej y w i -tym regionie można wyjaśnić przez poziom zjawiska w jednostkach sąsiedzkich j oraz inne czynniki reprezentowane przez pozostałe zmienne objaśniające.

4.7.2. Model błędu przestrzennego

Model błędu przestrzennego zakłada autokorelację przestrzenną reszt modelu. Jego postać można zapisać za pomocą równania:

$$y = \boldsymbol{\beta}\mathbf{X} + \delta, \quad (10)$$

gdzie:

$$\delta = \mu\mathbf{W}\delta + \varphi, \varphi \sim N(0, \sigma^2\mathbf{I}), \quad (11)$$

μ – parametr autokorelacji przestrzennej,

φ – niezależny błąd modelu,

$\mathbf{W}\delta$ – przestrzennie opóźniony błąd,

pozostałe oznaczenia są analogiczne jak w równaniu (9).

Błąd $\mathbf{W}\delta$ można interpretować jako średni błąd z lokalizacji sąsiedzkich.

W modelu błędu przestrzennego testuje się brak autokorelacji przestrzennej, tj. czy $\mu = 0$. Współczynniki $\boldsymbol{\beta}$ estymowane są metodą MNK a parametr μ przez optymalizację.

W tej grupie modeli badana jest przestrzenna zależność reszt. Pojawienie się autokorelacji przestrzennej w błędzie modelu może być skutkiem pominięcia nieobserwowanych zmiennych (np. pogoda, czynniki kulturowe), które mogą być przestrzennie skorelowane (Kopczewska, 2011).

4.7.3. Model mieszany SAC

W modelu SAC testowane jest założenie o jednoczesnym występowaniu autoregresji zmiennej objaśnianej i autokorelacji składnika losowego (Suchecki, 2010). Ogólna postać modelu można zapisać następująco:

$$y = \alpha\mathbf{W}y + \boldsymbol{\beta}\mathbf{X} + \delta, \quad (12)$$

gdzie:

$$\delta = \mu\mathbf{W}\delta + \varphi, \varphi \sim N(0, \sigma^2\mathbf{I}), \quad (13)$$

oznaczenia są analogiczne jak w równaniu (9), (10) i (11).

4.8. Etapy wyboru modelu przestrzennego

Identyfikacja i specyfikacja modelu przestrzennego przebiega w następujących etapach (Anselin, 2006; Koczewska, 2011; Suhecki, 2010):

1. Estymacja modelu liniowego metodą najmniejszych kwadratów (MNK).
2. Badanie autokorelacji przestrzennej reszt w liniowym modelu MNK (Anselin, Rey, 1991) – test *I* Morana dla reszt wzór (2).
3. Kolejnym etapem jest badanie istnienia zależności przestrzennej w modelach liniowych testem LM (mnożnik Lagrange) (Anselin i in., 1996). Można przeprowadzić pięć testów LM: dwa zwykle dla modeli opóźnienia i błędu (LMlag i LMerr), dwa odporne także dla tych modeli (RLMerr, RLMlag) oraz test łączny SARMA dla modelu SAC. Wyniki testów są podstawą decyzji co do wyboru formy przestrzennej zależności. Wyboru dokonuje się w oparciu o najniższe *p-value*.
4. Ostatnim etapem w identyfikacji i specyfikacji modelu przestrzennego jest przeprowadzenie dodatkowych testu diagnostycznego LR oraz porównanie wartości statystycznych tego testu z wartościami testu LM.

4.9. Modelowanie przestrzenne zjawiska przestępczości

Analizę statystyczną wpływu demograficznych i społeczno-ekonomicznych czynników na zjawisko przestępczości przeprowadzono dla 380 powiatów Polski. W tym celu wykorzystano dane z 2019 i 2020 roku pozyskane z Głównego Urzędu Statystycznego. Pod uwagę wzięto te dwa okresy ze względu na prawdopodobieństwo pośredniego wpływu na estymacje modeli – pandemii koronawirusa. Badanie rozpoczęto od wyboru zmiennych, na podstawie których oszacowano dwa modele regresji. Zmienną zależną charakteryzującą przestępczość była liczba przestępstw stwierdzonych przez Policję ogółem na 1000 mieszkańców (*Y*). Poziom przestępczości kształtowany jest przez wiele czynników o różnorodnym charakterze. Wśród nich wymienia się między innymi bezrobocie, zróżnicowanie dochodów, gęstość zaludniania, warunki życia ludności oraz tempo wzrostu gospodarczego. W związku z tym do zbioru potencjalnych zmiennych objaśniających wybrano następujące cechy (tabela 4.5):

W pierwszym etapie badania oszacowano dwa liniowe modele ekonometryczne dla 2019 i 2020 roku. Tabela 4.6 przedstawia wyniki estymacji tych modeli.

Tabela 4.5. Zmienne objaśniające

Symbol zmiennej	Opis zmiennej
X_1	stopa bezrobocia rejestrowanego
X_2	gęstość zaludnienia na 1 km ²
X_3	przeciętne miesięczne wynagrodzenia brutto w relacji do średniej krajowej (Polska = 100)
X_4	wskaźnik wykrywalności sprawców przestępstw stwierdzonych przez policję – ogółem
X_5	beneficjenci środowiskowej pomocy społecznej na 10 tys. ludności
X_6	saldo migracji ogółem na 1000 ludności
X_7	współczynnik feminizacji
X_8	rozwoły na 10 tys. ludności

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

Tabela 4.6. Wyniki estymacji modeli liniowych

Zmienne	Wartości współczynników			
	Model (2019)	<i>p-value</i>	Model (2020)	<i>p-value</i>
X_1	-0,11250*	0,00000	-0,02707*	0,00006
X_2	0,00160	0,33109	0,00350	0,90032
X_3	0,10650*	0,04552	0,09675*	0,02320
X_4	0,30420*	0,00271	0,57320	0,17732
X_5	-0,00095*	0,00000	-0,00026*	0,00000
X_6	0,07411	0,66107	0,22570	0,95482
X_7	0,60350	0,38901	0,83610	0,25184
X_8	0,44330*	0,00009	0,55280*	0,00319
R^2		0,3626		0,2161

* Parametry statystycznie istotne.

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

W skład każdego modelu weszły co najmniej cztery zmienne objaśniające (dla których *p-value* < 0,05). Były to stopa bezrobocia rejestrowanego, przeciętne miesięczne wynagrodzenia brutto w relacji do średniej krajowej, beneficjenci środowiskowej pomocy społecznej na 10 tys. ludności, liczba rozwodów na 10 tys. ludności oraz dodatkowo w modelu 2019 – wskaźnik wykrywalności sprawców przestępstw stwierdzonych przez policję (ogółem). W przypadku natężenia przestępstw wpływ przyjętych zmiennych demograficznych wyniósł 36% dla modelu 2019 i 22% dla modelu 2020, co oznacza przeważające znaczenie innych niż uwzględnione tutaj zmienne. Test *F* na łączną istotność wszystkich współczynników modelu potwierdza, że wszystkie zmienne łącznie są istotne.

W następnym kroku analizy zbadano przestrzenną autokorelację błędów. W tym celu zastosowano test Morana *I* dla reszt modelu. Wyniki badań przedstawiono w tabeli 4.7.

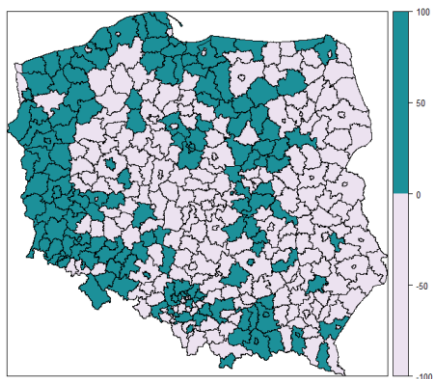
Tabela 4.7. Wartości statystyki Morana I dla reszt modelu MNK

Model (2019)		Model (2020)	
I	p -value	I	p -value
0,31582	$2,2 \cdot 10^{-16}$	0,16422	$1,5 \cdot 10^{-7}$


Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

Dla obu oszacowanych modeli (2019 i 2020) statystyki Morana I są dodatnie i istotne statystycznie. Taka sytuacja wskazuje na obecność autokorelacji przestrzennej, czyli brak przypadkowości w rozkładzie reszt. Rysunek 6 ilustruje rozkład reszt wybranych modeli podzielonych na reszty dodatnie i ujemne.

a) 2019



b) 2020



Rys. 4.6. Wykres reszt modelu w podziale na reszty dodatnie i ujemne

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

Reszty nie są rozłożone losowo, a zależą od położenia. Oznacza to, że wzrost natężenia przestępstw można tłumaczyć przyrostem wartości dodanej wybranych zmiennych objaśniających, ale należy pamiętać, że istnieją jeszcze inne czynniki determinujące zjawisko przestępczości. W powiatach, w których reszty są dodatnie, model nie doszacowuje zmian w liczbie stwierdzonych przestępstw. Wartości badanej zmiennej zależnej są tam wyższe od średniej dla całego badanego obszaru.

Kontynuując diagnostykę modelu zastosowano test LM i sprawdzono, który z modeli, opóźnienia czy błędy przestrzennego będzie lepszy. Wyniki tej analizy zawarte zostały w tabeli 4.8.

Tabela 4.8. Wybór modelu przestrzennego

Test	Model 2019		Model 2020	
	wartość testu	<i>p-value</i>	wartość testu	<i>p-value</i>
LMerr	84,84015	$2,2 \cdot 10^{-16}$	22,94000	$1,7 \cdot 10^{-6}$
LMlag	61,14454	$5,3 \cdot 10^{-15}$	19,64500	$9,3 \cdot 10^{-6}$
RLMerr	23,71536	$1,1 \cdot 10^{-6}$	3,29550	$6,9 \cdot 10^{-2}$
RLMlag	0,01974	$8,9 \cdot 10^{-2}$	0,00088	$9,8 \cdot 10^{-2}$
SARMA	84,85990	$2,2 \cdot 10^{-16}$	22,94100	$1,1 \cdot 10^{-5}$

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

Z powyższego wynika, że najniższe *p-value* ma specyfikacja LMerr, ale odporna specyfikacja RLMerr nie jest już taka dobra. Druga najlepsza jest SARMA, która łączy specyfikację lag i error i jest ona najprawdopodobniej najwłaściwsza.

Dodatkowo w tabeli 4.9 przedstawiono wartości kryteriów informacyjnych: Akaikego (AIC) i bayesowskie (BIC). Uzyskane wyniki pozwalają na porównanie modelu MNK z modelami przestrzennymi (SEM – model błędu przestrzennego, SLM – przestrzenny model opóźnienia, SAC – model mieszany). Najlepszy model to ten, dla którego kryteria AIC i BIC przyjmują najniższe wartości.

Tabela 4.9. Wartości kryteriów informacyjnych

Model		Wartości kryteriów	
		AIC	BIC
2019	SAC	2413,705	2460,987
	SLM	2439,591	2482,933
	SEM	2414,778	2458,120
	MNK	2497,963	2537,365
2020	SAC	2961,343	3008,625
	SLM	2969,599	3012941
	SEM	2962,122	3009,464
	MNK	2990,079	3029,481

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

Wartości kryteriów informacyjnych dla modeli (2019 i 2020) oraz testu LR wyraźnie wskazują model mieszany SAC. Dla modeli (2019 i 2020) stworzono sugerowany model przestrzenny; wyniki estymacji zaprezentowano w tabeli 4.10.

Tabela 4.10. Rezultaty estymacji modelu SAC

Zmienne	Wartości współczynników			
	Model (2019)	<i>p-value</i>	Model (2020)	<i>p-value</i>
X_1	-0,21323*	0,04333	-0,25525	0,23640
X_2	0,00212*	0,00931	0,00198	0,24707
X_3	0,09713*	0,00088	0,07600	0,24266
X_4	0,36038*	0,00000	0,71312*	0,00000
X_5	0,00130	0,53450	0,00184	0,70576
X_6	0,19687*	0,00757	0,31865	0,08431
X_7	0,65624*	0,00001	0,85998*	0,00229
X_8	0,27792*	0,01153	0,50920*	0,03790
μ	0,73100*	$2,2 \cdot 10^{-16}$	0,63749*	$4,1 \cdot 10^{-10}$
α	-0,24356	0,06038	-0,31751	0,05808

* Parametry statystycznie istotne.

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl> (18.02.2022).

Rezultaty estymacji przedstawione w tabeli 4.10 wskazują, że w modelu (2019) istotne statystycznie (na przyjętym poziomie istotności 5%) okazały się prawie wszystkie zmienne za wyjątkiem cechy dotyczącej liczby beneficjentów środowiskowej pomocy społecznej na 10 tys. ludności oraz parametru autokorelacji α , natomiast w modelu (2020) istotnie statystyczne były następujące czynniki: wskaźnik wykrywalności sprawców przestępstw stwierdzonych przez policję – ogółem, współczynnik feminizacji, liczba rozwodów na 10 tys. ludności oraz parametr autokorelacji μ . Uzyskany wynik sugeruje że w obu modelach największy wpływ na natężenie przestępstw miał współczynnik feminizacji, a zaraz po nim wskaźnik wykrywalności sprawców przestępstw i liczba rozwodów. Pozostałe zmienne w umiarkowanym stopniu oddziaływały na zjawisko przestępczości. W modelu (2019) współczynnik przy X_1 miał znak ujemny, co oznacza, że wzrost stopy bezrobocia przyczyni się do spadku natężenia przestępstw. Fakt ten jest dość zastanawiający, jeśli weźmiemy pod uwagę, że w ostatnich latach obserwowano spadek przestępczości przy jednoczesnym spadku stopy bezrobocia.

4.10. Podsumowanie

Przeprowadzone analizy związane z zjawiskiem przestępczości w Polsce ukazały widoczny trend spadkowy liczby stwierdzonych przestępstw ogółem, jak i wybranych ich rodzajów (przeciwko mieniu i przeciwko bezpieczeństwu powszechnemu). Tendencję wzrostową można obserwować dla przestępstw o charakterze gospodarczym, w tym cyberprzestępstw, oraz przeciwko rodzinie i opiece.

Klasyfikacja powiatów ze względu na poziom przestępczości w wybranych latach pokazała istniejące różnice natężenia tego zjawiska w Polsce. Otrzymane wyniki wskazują na wyraźny podział pomiędzy regiony znajdujące się przy zachodniej i wschodniej granicy oraz niektóre miasta (szczególnie te leżące na Śląsku) a resztę kraju. Identyfikacja powiatów zagrożonych przestępczością jest istotna dla opracowywania strategii bezpieczeństwa na danym obszarze, prognozowania kosztów generowanych przez poszczególne kategorie przestępstw, odpowiedniego rozmieszczenia komisariatów, patroli policji czy szacowania kosztów związanych z funkcjonowaniem organów ścigania (Kądziołka, 2016b).

Badania autokorelacji przestrzennej również potwierdziły, że przestępczość w Polsce nie występuje z takim samym nasileniem na całym obszarze kraju. Analiza globalnych i lokalnych miar wyznaczonych dla zjawiska przestępczości wykazała istnienie zależności przestrzennych danej zmiennej w obrębie całego obszaru, ale także w odniesieniu do lokalizacji sąsiednich.

W opracowaniu przedstawiono również badania związane z wpływem wybranych czynników o charakterze społeczno-ekonomicznym na natężenie przestępczości w powiatach Polski. W zaprezentowanych modelach istotne statystycznie okazały się takie zmienne jak: współczynnik feminizacji, wskaźnik wykrywalności sprawców przestępstw i liczba rozwodów. Uzyskane wyniki mogą być wskazówką, na jakie zjawiska należy oddziaływać w celu zmniejszenia przestępczości.

Literatura

- Anselin, L. (1995). Local indicators of spatial association – LISA. *Geographical Analysis*, 27, 93-115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L. (2002). Under the hood: Issues in the specification and interpolation of spatial regression models. *Agricultural Economics*, 27, 247-267. <https://doi.org/10.1111/j.1574-0862.2002.tb00120.x>
- Anselin, L. (2006). *Spatial analysis with GeoDa. 4. Spatial regression*, Urbana-Champaign: University of Illinois.
- Anselin, L., Bera, A. K., Florax, R., Yoon, M. J. (1996). Simple diagnostic tests for spatial dependence. *Regional Science and Urban Economics*, 26, 77-104. [https://doi.org/10.1016/0166-0462\(95\)02111-6](https://doi.org/10.1016/0166-0462(95)02111-6)
- Anselin, L., Rey, S. J. (1991). Properties of tests for spatial dependence in linear regression models. *Geographical Analysis*, 23, 112-131. <https://doi.org/10.1111/j.1538-4632.1991.tb00228.x>
- Bąk, I. (2015). Struktura i typologia przestrzenna przestępczości w Polsce. *Econometrics. Ekonometria. Advances in Applied Data Analytics*, 4(50), 43-61. <https://doi.org/10.15611/ekt.2015.4.03>
- Bivand, R. (1980). Autokorelacja przestrzenna a metody analizy statystycznej w geografii. W Z. Chojnicki (red.), *Analiza regresji w geografii* (s. 23-38). Poznań: PWN.

- Chainey, S., Ratcliffe, J. (2005). *GIS and crime mapping* (1st ed.). John Wiley and Sons.
- Cliff, A. D., Ord, J. K. (1973). *Spatial autocorrelation*. London: Pion.
- European Forum for Urban Safety [EFUS]. (2007). *Guidance on local safety audits. A compendium of international practice*. Barcelona.
- Europol. (2020). *Catching the virus cybercrime, disinformation and the COVID-19 pandemic*. https://www.europol.europa.eu/sites/default/files/documents/catching_the_virus_cybercrime_disinformation_and_the_covid-19_pandemic_0.pdf
- Interpol. (2020). *Cybercrime: Covid-19 impact*. <https://www.interpol.int/content/download/15526/file/COVID-19%20Cybercrime%20Analysis%20Report-%20August%202020.pdf>
- Kądziołka, K. (2016a). Analysis of the crime rate in Poland in spatial and temporal terms. *Central and Eastern European Journal of Management and Economics*, 4(1), 81-96. https://ceejme.eu/wp-content/uploads/2017/04/ceejme_1_6_art_05.pdf
- Kądziołka, K. (2016b). Determinanty przestępczości w Polsce. Analiza zależności z wykorzystaniem drzew regresyjnych. *Ekonomia. Rynek, Gospodarka, Społeczeństwo*, 4, 53-81. <https://yadda.icm.edu.pl/yadda/element/bwmeta1.element.ekon-element-000171437306>
- Kopczewska, K. (2011). *Ekonometria i statystyka przestrzenna z wykorzystaniem programu R Cran*. Warszawa: CeDeWu.
- Kopczewska, K. (red.). (2020). *Przestrzenne metody ilościowe w R: statystyka, ekonometria, uczenie maszynowe, analiza danych*. Warszawa: CeDeWu.
- Moran, P. A. P. (1950). Notes on continuous stochastic phenomena. *Biometrika* 37(1), 17-23. <https://doi.org/10.2307/2332142>
- Mordwa, S. (2013). Zastosowanie GIS w badaniach przestępczości. *Acta Universitatis Lodziensis. Folia Geographica Socio-oconomica*, 14, 77-92. http://foliags-o.geo.uni.lodz.pl/folia14/Mordwa_Zastosowanie%20GIS%20w%20badaniach%20przestepczosci.pdf
- Ord, J. K., Getis, A. (1995). Local spatial autocorrelation statistics: Distributional issues and an application. *Geographical Analysis*, 27(4), 286-306. <https://doi.org/10.1111/j.1538-4632.1995.tb00912.x>
- Ord, J. K., Getis, A. (2012). Local spatial heteroscedasticity (LOSH). *The Annals of Regional Science*, 48(2), 528-539. <http://doi.org/10.1007/s00168-011-0492-y>
- Suchecky, B. (red.). (2010). *Ekonometria przestrzenna. Metody i modele analizy danych przestrzennych*. Warszawa: C.H. Beck.
- Szulc, E. (2008). Analiza struktury ekonomicznych procesów przestrzennych na przykładzie PKB w wybranych krajach europejskich. *Acta Universitatis Nicolai Copernici, Ekonomia*, 38, 7-20. https://doi.org/10.12775/AUNC_ECON.2008.001
- UN. (2020). *Policy brief: The impact of COVID-19 on women*. https://www.un.org/sites/un2.un.org/files/2020/04/policy_brief_on_covid_impact_on_women_9_apr_2020_updated.pdf

5. Analiza aktualnych wyzwań i zagrożeń rozwoju społeczeństwa informacyjnego w dobie pandemii COVID-19

(Anna Janiga-Ćmiel)

5.1. Wprowadzenie

W obecnych czasach jesteśmy świadkami swego rodzaju nieustającej cyfrowej rewolucji. Nowe technologie, a w szczególności ich rozwój, wpływają na większość dziedzin naszego życia, życia społeczeństwa informacyjnego. Rozwój tego społeczeństwa zależy od wielu różnych czynników, między innymi od stopnia informatyzacji i komputeryzacji, barier geograficznych, zmian i poziomu rozwoju gospodarczego, stopnia urbanizacji, poziomu edukacji, struktury zatrudnienia. Szybki rozwój technologii wpływa istotnie na przemiany gospodarcze i nasze codzienne życie. Wzrasta również znaczenie wiedzy w gospodarce, co tworzy istotne oddziaływania między różnymi instytucjami a wiedzą (Goban-Klas, Sienkiewicz, 1999). Dodatkowo rozwój społeczeństwa informacyjnego jest istotnym czynnikiem procesu globalizacji. Możliwości wykorzystania i dostępu do zdobyczy rewolucji komunikacyjnej i informacyjnej stały się powodem zróżnicowania społecznego. Ludzie, wykorzystując różne gadzety technologiczne jako elementy swojej codzienności, uzależniają się od nich. Zachowania te są istotnym czynnikiem wpływającym na naszą kulturę, tradycję. Staliśmy się społeczeństwem sieciowym, społeczeństwem interaktywnym, a świat, w którym funkcjonujemy, stał się światem interaktywnym. W istotnym stopniu wzrasta znaczenie Internetu i multimediów. Miczka (2016) zauważa, że Internet staje się dla społeczeństwa przestrzenią społeczną, gdzie istnieje niebezpieczeństwo, że może zostać przeniesiona pewna część swej ludzkiej aktywności (Bielak, Ptaszek, 2016). Prowadzi to do przekształcenia się społeczeństwa poprzez wpływ postaci cyfrowej w *big data society*. Media również stają się coraz bardziej ważne dla społeczeństwa i kultury jako całości. Społeczeństwo nieświadomie może w swoim życiu uwzględniać szereg nowych przyzwyczajeń, na przykład infoaktywizm, który oznacza, że wykonywane przez nas czynności w ciągu dnia uzależniona są od mediów. Multitasking jest zjawiskiem będącym przykładem ewolucji współczesnego człowieka; to współkorzystanie z różnych mediów w tym samym czasie. Niestety pojawiają się też ujemne strony nowych technologii, które są pogłębiane przez globalizację (Bielak, Ptaszek, 2016; Bliźnik, Nowak, 2005; Zorska, 2011). Do tych zjawisk możemy zaliczyć cyberterrorystykę, ataki hackerów komputerowych itp. W coraz większym zakresie widoczne są podziały

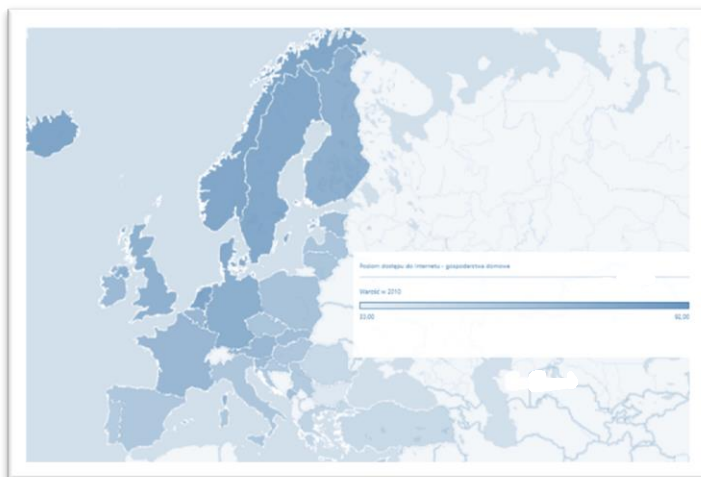
między bogatym społeczeństwem, mającym dostęp do komputera i Internetu, oraz biednym, pozbawionym możliwości użytkowania najnowszych technologii, co prowadzi do wykluczenia cyfrowego. Ostatnie lata przyniosły szereg niepewności i niepokoju za sprawą pandemii COVID-19. Pandemia i związane z nią w owym czasie lockdown oraz ograniczenia życia społecznego zmieniły w istotnym stopniu nasze codzienne funkcjonowanie. Uwzględniane przez państwa Unii Europejskiej środki w walce z pandemią, to znaczy między innymi: ograniczenia kontaktów społecznych, kwarantanna, zakaz przekraczania granicy między danymi państwami, zamknięcia obiektów handlowych, kulturalnych, ograniczenia w transporcie, miały istotny wpływ na nasze życie.

5.2. Zestaw cech diagnostycznych – społeczeństwo informacyjne w latach 2010-2020

Celem zaprezentowanego badania jest analiza społeczeństwa informacyjnego w wybranych krajach europejskich (w badaniu uwzględniono również dodatkowe kraje zaprezentowane na mapkach). Przeprowadzona analiza obejmuje lata od roku 2010 do 2020, ze szczególnym zwróceniem uwagi na okres pandemii COVID-19. Dane pozyskano ze strony Eurostat, Głównego Urzędu Statystycznego, przy uwzględnieniu zakresu tematycznego i dostępności danych. Przyjęto zmienne diagnostyczne o charakterze mierzalnym i takie, aby najlepiej opisywały poziom rozwoju badanego zjawiska. Zestaw zmiennych diagnostycznych, który został ustalony na podstawie analizy opisowej tych zmiennych, obejmował w ostateczności:

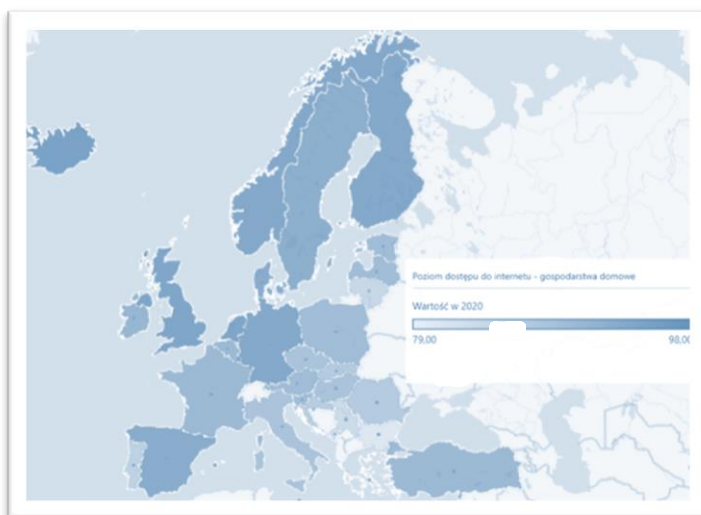
- x_1 – poziom dostępu do Internetu – gospodarstwa domowe,
- x_2 – osoby korzystające z Internetu celem dostępu do bankowości internetowej,
- x_3 – osoby korzystające z Internetu w celu uzyskania informacji związanych ze zdrowiem,
- x_4 – osoby, które nigdy nie korzystały z Internetu,
- x_5 – udział w obrotach przedsiębiorstw w e-commerce.

Dodatkowo dla wyodrębnionego zestawu danych uwzględniono dodatek Mapy – Excel w celu porównania lat 2010 i 2020 oraz próby wykrycia ewentualnych podobieństw bądź zróżnicowania w zjawisku (rysunki 5.1-5.10).



Rys. 5.1. Poziom dostępu do Internetu – gospodarstwa domowe (2010)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 5.2. Poziom dostępu do Internetu – gospodarstwa domowe (2020)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

W przypadku zmiennej x_1 – poziom dostępu do Internetu – gospodarstwa domowe, można zauważyć, że najwyższy poziom utrzymuje się zarówno w roku 2010, jak i 2020 w krajach nordyckich. W roku 2020 widzimy znaczący wzrost zmiennej x_1 między innymi w Niemczech, Wielkiej Brytanii i Hiszpanii. W następnej kolejności na rysunkach 5.3 i 5.4 zaprezentowano liczbę osób korzysta-

jących z Internetu celem dostępu do bankowości internetowej w rozpatrywanych latach i można zauważyć, że tu również głównie kraje nordyckie osiągnęły najwyższy poziom zjawiska.



Rys. 5.3. Osoby korzystające z Internetu celem dostępu do bankowości internetowej (2010)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 5.4. Osoby korzystające z Internetu celem dostępu do bankowości internetowej (2020)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

W następnym kroku analizy uwzględniono liczbę osób korzystających z Internetu w celu uzyskania informacji związanych ze zdrowiem. W czasie pandemii COVID-19 dostępność w tej formie usługi zdrowotnej była znacząco rozpowszechniona.



Rys. 5.5. Osoby korzystające z Internetu w celu uzyskania informacji związanych ze zdrowiem (2010)

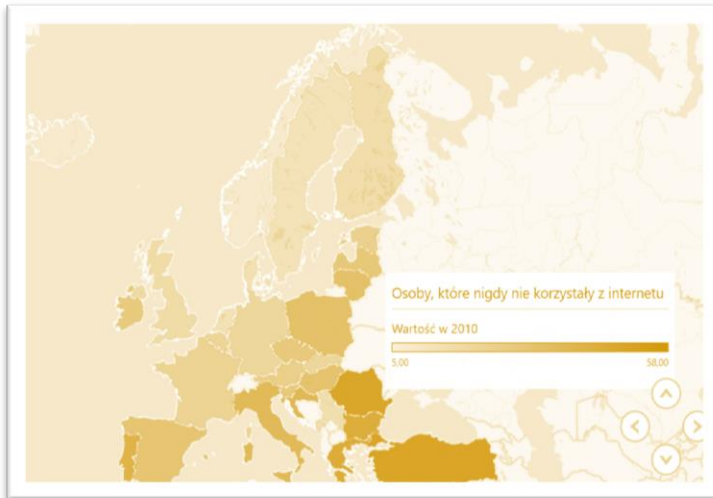
Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 5.6. Osoby korzystające z Internetu w celu uzyskania informacji związanych ze zdrowiem (2020)

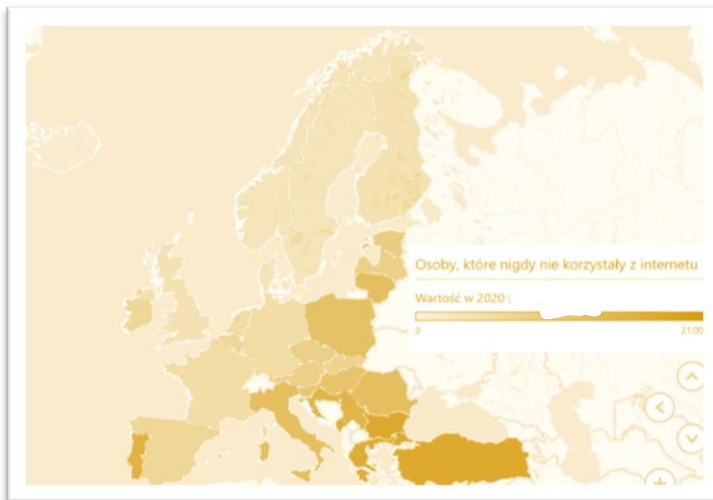
Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

Możemy zauważyć, że w widoczny sposób ilość osób korzystających z tego typu usługi wzrosła między innymi w Hiszpanii, Francji, Norwegii.



Rys. 5.7. Osoby, które nigdy nie korzystały z Internetu (2010)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 5.8. Osoby, które nigdy nie korzystały z Internetu (2020)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

W przypadku liczby osób, które nigdy nie korzystały z Internetu, nie widać natomiast zauważalnych korzystnych zmian na przestrzeni dziesięciu lat. Niestety pomimo szybkiego rozwoju nowych technologii, podobne kraje są nadal uwzględnione w roku 2010 i 2020 jako te z największą liczbą osób, które nie korzystają z Internetu.

W dalszej kolejności uwzględniono udział w obrotach przedsiębiorstw w e-commerce.



Rys. 5.9. Udział w obrotach przedsiębiorstw w e-commerce (2010)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.



Rys. 5.10. Udział w obrotach przedsiębiorstw w e-commerce (2020)

Źródło: Na podstawie danych statystycznych GUS zaczerpniętych ze strony <https://stat.gov.pl> oraz Eurostat – <https://ec.europa.eu/eurostat> (7.09.2021) z wykorzystaniem dodatku Microsoft 3D Mapy Excel.

W przypadku rozpatrywanej zmiennej widzimy, że na przestrzeni dziesięciu lat poziom znacząco się nie zwiększył.


5.3. Zastosowanie metody taksonomicznej do wyodrębnienia jednorodnych okresów w zmienności dynamiki analizowanego zjawiska – analiza empiryczna

Celem analizy jest wyznaczenie grup okresów czasowych charakteryzujących się jednorodnym rozwojem zjawiska. W tym celu jako narzędzie pomocnicze zastosowano metodę taksonomiczną Czekanowskiego. Punktem wyjścia metody Czekanowskiego jest macierz odległości między obiektami, zdefiniowana za pomocą dowolnej metryki. Mierniki odległości w macierzy D dzieli się na klasy podobieństwa obiektów. Odpowiednim klasom podobieństwa przyporządkowuje się symbole graficzne i tak wyznacza się nieuporządkowany diagram Czekanowskiego. W kolejnym kroku następuje porządkowanie diagramu, którego celem jest ułożenie symboli graficznych w ten sposób, by wzdłuż głównej przekątnej macierzy były symbole odpowiadające najmniejszym odległościom, a najdalej oddalone od głównej przekątnej te, które odpowiadają większym odległościom (Grabiński, Wydymus, Zeliaś, 1989, 71-100; Młodak, 2006; Panek, 2009, 58-114; Pocięcha i in., 1988).

W oparciu o zaprezentowany zestaw danych w pierwszym etapie analizy przeprowadzono standaryzację zmiennych, obliczono odległości taksonomiczne (posłużono się odległością euklidesową). Następnie wyznaczone zostały przedziały klasowe dla wartości odległości taksonomicznych na podstawie wyznaczonego empirycznego obszaru zmienności. Ostatni etap obejmował opracowanie nieuporządkowanego i uporządkowanego diagramu J. Czekanowskiego. Wszystkie obliczenia oraz wyznaczenie diagramu zostały przeprowadzone z wykorzystaniem programu Maczek¹. W badaniu w celach porównawczych uwzględniono Polskę, Szwecję, Hiszpanię oraz Niemcy.

Dla Polski otrzymano dwie grupy okresów charakteryzujące się podobnym poziomem rozwoju zjawiska. Na rysunku 5.11 zaprezentowano rezultaty otrzymane w oparciu o wykorzystanie programu MaCzek.

¹ <http://www.antropologia.uw.edu.pl/MaCzek/maczek.html> (2.06.2021).



Rys. 5.11. Diagram Czekanowskiego – Polska

Źródło: Opracowanie z wykorzystaniem programu MaCzek.

Otrzymane dwie grupy dla Polski obejmowały następujące lata:

$$G_1 = \{2010, 2011, 2013, 2014, 2015\}$$

$$G_2 = \{2016, 2017, 2018, 2019, 2020\}$$

Następnie analizę powtórzono w celu wyodrębnienia jednorodnych okresów w zmienności dynamiki analizowanego zjawiska dla Szwecji. Otrzymano trzy grupy jednorodnego rozwoju okresów:

$$G_1 = \{2010, 2011, 2012\}$$

$$G_2 = \{2013, 2014, 2015, 2016, 2017\}$$

$$G_3 = \{2018, 2019, 2020\}$$

W kolejnym kroku badania wyznaczono grupy okresów charakteryzujące się jednorodnym rozwojem dla Hiszpanii otrzymując trzy grupy okresów:

$$G_1 = \{2010, 2011, 2012\}$$

$$G_2 = \{2013, 2014, 2015, 2016, 2017, 2018\}$$

$$G_3 = \{2019, 2020\}$$

Grupy okresów charakteryzujące się jednorodnym rozwojem dla Niemiec:

$$G_1 = \{2010, 2011, 2012, 2013\}$$

$$G_2 = \{2014, 2015, 2016, 2017\}$$

$$G_3 = \{2018, 2019, 2020\}$$

W oparciu o uzyskane wyniki można zauważyć, że jedynie w przypadku Polski otrzymano dwie grupy okresów jednorodnego rozwoju zjawiska. Rozpatrywany przedział czasowy od 2010 do 2020 roku został rozbity na dwa podokresy o jednorodnej strukturze zjawiska, gdzie rok 2016 rozpoczyna drugi podokres, który uwzględnia rok 2020 związany z początkiem pandemii COVID-19. Dla Szwecji analizowany okres 2010-2020 został rozbity na trzy podokresy o jednakowej strukturze rozwoju zjawiska. Pierwszy podokres uwzględniał lata 2010-2012 o jednakowej strukturze zjawiska, następnie drugi podokres 2013-

2017 i trzeci 2018-2020. Dla Hiszpanii również otrzymano trzy podokresy, gdzie pierwszy obejmował lata 2010-2012, drugi lata 2013-2018, ostatni tylko lata 2019 i 2020. Podobnie było w przypadku Niemiec: pierwsza grupa obejmowała lata 2010-2013, druga lata 2014-2017, a ostatnia – 2018-2020. Rok 2020 stanowił początek pandemii COVID-19, co jest powiązane między innymi ze zwiększonym użytkowaniem Internetu i nowych technologii przez społeczeństwo w związku z wprowadzeniem pracy zdalnej, nauczania zdalnego, koniecznością zakupu sprzętu komputerowego, wprowadzenia przez firmy sprzedaży on-line. W przypadku Szwecji, Niemiec i Hiszpanii rok 2020 był uwzględniony w grupie obejmującej rok 2019 i ewentualnie 2018, czyli są to lata o jednorodnej strukturze rozwoju zjawiska (podokresy dwuletnie i trzyletnie). W przypadku Polski widzimy, że grupa obejmująca rok 2020 uwzględnia podokres 2016-2020 o jednorodnej strukturze zjawiska.

5.4. Zunifikowana metoda rozwiązywania równań różniczkowych liniowych

Teoria równań różniczkowych została zapoczątkowana i rozwijana w XVIII wieku i znalazła szerokie zastosowanie nie tylko w matematyce, ale również w wielu innych dziedzinach nauki. Wyznaczając odpowiednie równania możemy opisać między innymi zagadnienia ekonomiczne z życia codziennego, występujące w naukach przyrodniczych, fizyce. Równania różniczkowe dają możliwość opisu zależności występujących w dynamice rozwoju analizowanego zjawiska w rozpatrywanym przedziale czasowym.

Celem badania jest analiza dynamiki rozwoju użytkowania Internetu i nowych technologii w wybranym państwie z wykorzystaniem zaprezentowanej metody rozwiązań równań różnicowych i różniczkowych. Wykorzystane zostaną zagadnienia, wykorzystujące między innymi równania charakterystyczne i zagadnienia początkowe. Zastosowanie zaproponowanej metody rozwiązań równań liniowych o stałych współczynnikach daje możliwość wyznaczenia modeli w postaci równań różniczkowych z wykorzystaniem dodatkowych wybranych zagadnień analizy matematycznej i algebry liniowej.

W badaniu zostanie zastosowana metoda wyznaczenia równania różniczkowego o stałych współczynnikach zaproponowana w pracy J. Muszyńskiego (2004), mianowicie zunifikowana metoda rozwiązywania równań różniczkowych liniowych o stałych współczynnikach. Rozpatrujemy równanie różniczkowe p -tego rzędu o stałych współczynnikach (S rozważamy jako zbiór liczb rzeczywistych bądź zespolonych), postaci:

$$y^{(p)} + a_{p-1}y^{(p-1)} + \dots + a_1y' + a_0y = 0, \quad (1)$$

gdzie:

$$a_0, \dots, a_{p-1} \in \mathcal{S}.$$

Niech funkcja $y(x)$, $x \in R$ będzie jego rozwiązaniem ($y(x) \in \mathcal{S}$, dla $x \in R$). W związku z powyższym oznacza to, że funkcja y jest klasy $C^\infty(R)$ oraz:

$$y^{(p)}(x) + a_{p-1}y^{(p-1)}(x) + \dots + a_1y'(x) + a_0y(x) = 0 \text{ dla } x \in R. \quad (2)$$

Oznaczmy przez X przestrzeń $C^\infty(R)$, a przez X_0 zbiór rozwiązań rozpatrywanego równania, zatem $X_0 \subset X$ (Muszyński J, 2004). Niech D będzie operatorem różniczkowania w przestrzeni X postaci:

$$Dy = y'. \quad (3)$$

Wówczas na rozwiązaniach równania różniczkowego (w zbiorze X_0) spełnione jest równanie operatorowe:

$$D^p + a_{p-1}D^{p-1} + \dots + a_1D + a_0E = \theta, \quad (4)$$

gdzie θ jest operatorem zerowym. Odpowiadające równaniu (4) równanie algebraiczne (dla $\lambda \in \mathbb{C}$) możemy zapisać w postaci (Muszyński, 2004):

$$\lambda^p + a_{p-1}\lambda^{p-1} + \dots + a_0 = 0. \quad (5)$$

Równanie to nazywamy równaniem zerującym, a jego pierwiastki zerującymi.

Dodatkowo niech $\lambda_1, \dots, \lambda_s$ będą pierwiastkami zerującymi o krotnościach odpowiednio k_1, \dots, k_s , zatem:

$$\lambda^p + a_{p-1}\lambda^{p-1} + \dots + a_0 = (\lambda - \lambda_1)^{k_1} \cdot \dots \cdot (\lambda - \lambda_s)^{k_s}. \quad (6)$$

Natomiast rozwiązanie równania operatorowego znajdujemy w oparciu o wzór:

$$\det \begin{bmatrix} \lambda_1^{p-1} & \lambda_1^{p-2} & \dots & 1 & \lambda_1^n \\ (\lambda_1^{p-1})' & (\lambda_1^{p-2})' & \dots & 0 & (\lambda_1^n)' \\ \dots & \dots & \dots & \dots & \dots \\ (\lambda_1^{p-1})^{(k_1-1)} & (\lambda_1^{p-2})^{(k_1-1)} & \dots & 0 & (\lambda_1^n)^{(k_1-1)} \\ \dots & \dots & \dots & \dots & \dots \\ \lambda_s^{p-1} & \lambda_s^{p-2} & \dots & 1 & \lambda_s^n \\ (\lambda_s^{p-1})' & (\lambda_s^{p-2})' & \dots & 0 & (\lambda_s^n)' \\ \dots & \dots & \dots & \dots & \dots \\ (\lambda_s^{p-1})^{(k_s-1)} & (\lambda_s^{p-2})^{(k_s-1)} & \dots & 0 & (\lambda_s^n)^{(k_s-1)} \\ D^{p-1} & D^{p-2} & \dots & E & D^n \end{bmatrix}.$$

Przy czym, niech dane będzie równanie różniczkowe niejednorodne postaci:

$$y^{(p)} + a_{p-1}y^{(p-1)} + \dots + a_1y' + a_0y = b(x). \quad (7)$$

Przy warunkach początkowych: $y(x_0) = y'(x_0) = \dots = y^{(p-1)}(x_0) = 0$, wówczas rozwiązanie wyznaczamy zgodnie ze wzorem (Muszyński, 2004):

$$\det \begin{pmatrix} \lambda_1^{p-1} & \lambda_1^{p-2} & \dots & 1 & \int_{x_0}^x e^{\lambda_1(x-u)} b(u) du \\ (\lambda_1^{p-1})' & (\lambda_1^{p-2})' & \dots & 0 & \frac{\partial}{\partial \lambda} \int_{x_0}^x e^{\lambda_1(x-u)} b(u) du \\ \dots & \dots & \dots & \dots & \dots \\ (\lambda_1^{p-1})^{(k_1-1)} & (\lambda_1^{p-2})^{(k_1-1)} & \dots & 0 & \frac{\partial^{k_1-1}}{\partial \lambda^{k_1-1}} \int_{x_0}^x e^{\lambda_1(x-u)} b(u) du \\ \dots & \dots & \dots & \dots & \dots \\ \lambda_s^{p-1} & \lambda_s^{p-2} & \dots & 1 & \int_{x_0}^x e^{\lambda_s(x-u)} b(u) du \\ (\lambda_s^{p-1})' & (\lambda_s^{p-2})' & \dots & 0 & \dots \\ \dots & \dots & \dots & \dots & \dots \\ (\lambda_s^{p-1})^{(k_s-1)} & (\lambda_s^{p-2})^{(k_s-1)} & \dots & 0 & \frac{\partial^{k_s-1}}{\partial \lambda^{k_s-1}} \int_{x_0}^x e^{\lambda_s(x-u)} b(u) du \\ 1 & \dots & \dots & 0 & y(x) \end{pmatrix} = 0. \quad (8)$$

W ostatnim kroku metody otrzymujemy rozwiązanie ogólne równania jednorodnego przedstawiające opis wahań zjawiska wokół trendu i rozwiązanie szczególne będące funkcją trendu.

5.5. Analiza empiryczna – równanie różniczkowe liniowe rzędu drugiego o stałych współczynnikach

W pierwszym etapie analizy wyznaczono zmienną syntetyczną bezwzorcową, uwzględniając metody wyznaczania zmiennej zaproponowane w pracach Miki (1995) i Strahl (1998). Dla analizowanych krajów wyznaczono zmienną w okresie od roku 2010 do 2020. Wybrano Polskę, Niemcy, Hiszpanię oraz Szwecję i dla tych krajów w kolejnym kroku skonstruowano równania różniczkowe. Następnie w celu wyznaczenia rzędu równania różniczkowego wyliczono wartości bezwzględnych przyrostów zmiennej syntetycznej. Uwzględnione zostało równanie różniczkowe rzędu drugiego. W kolejnym kroku analizy został skonstruowany ekonometryczny model liniowy, który prezentował zależność funkcji trendu od wartości teoretycznych zmiennej syntetycznej, jej przyrostów rzędu pierwszego i jej przyrostów rzędu drugiego. Jako zmienną objaśnianą uwzględniono wartość najkorzystniejszego spośród wyznaczonych trendów w analizie. Do rozwiązania skonstruowanego równania różniczkowego zwyczajnego liniowego niejednorodnego rzędu drugiego z warunkami początkowymi została zastosowana metoda zaproponowana w pracy Muszyńskiego (2004). W ostatnim kroku metody otrzymujemy rozwiązanie ogólne równania jednorodnego, przedstawiające opis wahań zjawiska wokół trendu i rozwiązanie szczególne będące funkcją trendu.

Wyznaczono modele odpowiednio dla Polski, Hiszpanii, Niemiec i Szwecji:

$$\begin{aligned}y_P &= 0,0105e^{0,018t} \cos 0,0892t + 0,0199e^{0,018t} \sin 0,0892t + 3,071e^{0,025t} \\y_H &= 0,01975e^{0,029t} \cos 0,1054t + 0,0111e^{0,029t} \sin 0,1054t + 9,201e^{0,019t} \\y_S &= 0,1503e^{-0,122t} \cos 0,2601t + 0,12e^{-0,122t} \sin 0,2601t + 25,447e^{0,0112t} \\y_N &= 0,111e^{0,0671t} \cos 0,169t + 0,04e^{0,0671t} \sin 0,169t + 15,001e^{0,0241t}.\end{aligned}$$

Dla każdego z wyznaczonych modeli wartości ich współczynników są dodatnie. W przypadku Polski wartości współczynników są niższe w stosunku do wartości wyznaczonych dla pozostałych modeli. Dodatkowo widzimy, że dla wyznaczonych modeli obie funkcje układu fundamentalnego rozwiązań charakteryzują się znakiem dodatnim, co oznacza trend o kierunku rosnącym badanego zjawiska, a w związku z tym badane zjawisko podlega tendencji rosnącej.

5.6. Podsumowanie

Użytkowanie nowoczesnych technologii powoduje, że nasze życie społeczno-gospodarcze podlega ciągłym, nieustającym zmianom zarówno w ujęciu globalnym, jak i krajowym. Proces udoskonalenia, przetwarzania, gromadzenia i przesyłania informacji za pomocą technologii informatycznych jest procesem, który trwa nieprzerwanie. Pandemia koronawirusa spowodowała, że zostały wprowadzone zmiany dotyczące codziennego funkcjonowania, a sytuacja stała się wezwaniem dla nowych technologii. Umiejętność obsługi oraz dostęp do nowych technologii i Internetu znalazły istotne zastosowanie w celu szybkiego kontaktowania się, przekazywania dużych informacji. Dodatkowo stały się narzędziem funkcjonowania i osiągnięcia swoich celów biznesowych poprzez firmy, urzędy, szkolnictwo itp. Celem zaproponowanego badania była analiza rozwoju społeczeństwa informacyjnego w latach 2010-2020, uwzględniając tym samym okres pandemii COVID-19. Przeprowadzone badanie było uzależnione od dostępności danych empirycznych. W pierwszym etapie analizy dokonano porównania zmiennych w roku 2010 oraz 2020. Można stwierdzić, że kraje nordyckie na przestrzeni 10 lat charakteryzowały się najwyższym poziomem w zakresie użytkowania i wykorzystania Internetu. Przeprowadzono również analizę dla wybranych reprezentantów państw w celu wyznaczenia okresów jednorodnego rozwoju dla analizowanego przedziału czasowego obejmującego lata 2010-2020. W każdym z analizowanych przypadków oprócz Polski zostały wyodrębnione trzy grupy okresów. Dla Polski jedynie dwie grupy. Dla Szwecji i Niemiec ostatnia grupa obejmuje lata 2018-2020, a dla Hiszpanii jedynie 2019 i 2020. Grupa ta obejmuje lata związane już z okresem pandemii, który jest związany ze zwiększonym wykorzystaniem Internetu, zakupem nowego sprzętu komputerowego itd. Większość firm, sklepów i urzędów musiało poszerzyć swoje usługi poprzez zaoferowanie usługi

online. W dalszym etapie analizy dla wybranych czterech państw w oparciu o zebrane dane wyznaczono zmienną syntetyczną bezwzorcową, która stanowiła podstawę konstrukcji równań różniczkowych liniowych rzędu drugiego. Równanie rzędu drugiego dało możliwość sprecyzowania kierunku rozwoju analizowanego zjawiska w okresie rozpatrywanych dziesięciu lat. Dodatkowo mające miejsce wahania w rozwoju analizowanego zjawiska wymagało uwzględnienia modelu funkcji trygonometrycznych. W oparciu o wyznaczone wartości współczynników funkcji wykładniczych, które nie obejmują wahań, można zauważyć, że najwyższe wykorzystanie użytkownika Internetu oraz nowych technologii występują w Szwecji, a następnie w Niemczech. W dalszej kolejności można uwzględnić Hiszpanię, a najniższe wykorzystanie analizowanego zjawiska występuje w przypadku Polski. Uwzględniamy w tym celu wartości współczynników odpowiednio w modelu Szwecji (25,447), Niemiec (15,001), Hiszpanii (9,201) oraz Polski (3,071). W oparciu o otrzymane dodatnie wartości wszystkich współczynników w zaprezentowanych modelach oraz trendy badanych zjawisk będących funkcjami rosnącymi, możemy stwierdzić, że w przyszłości będziemy obserwowali wzrost użytkownika Internetu i wykorzystania nowych technologii w badanych krajach.

Literatura

- Bliźniuk, G., Nowak, J. S. (2005), *Spoleczeństwo informacyjne 2005*. Katowice: Polskie Towarzystwo Informatyczne – Oddział Górnośląski.
- Goban-Klas, T., Sienkiewicz, P. (1999). *Spoleczeństwo informacyjne. Szanse, zagrożenia, wyzwania*. Kraków: Fundacja Postępu Telekomunikacji.
- Grabiński, T., Wydymus, A., Zeliaś, A. (1989). *Metody taksonomii numerycznej w modelowaniu zjawisk społeczno-gospodarczych*. Warszawa: PWN.
- Miczka, T. (2016). Imperatyw: „im więcej, tym lepiej” jako zagrożenie dla rozwoju społeczeństwa informacyjnego. W T. Bielak, G.Ptaszek (red.). *Media.pl, Badania nad mediami w Polsce* (s. 130-143). Kraków: Wydawnictwo Libron – Filip Lohner. <https://depot.ceon.pl/bitstream/handle/123456789/11491/073e60a83196dc59e387a8aeefe572a31367dd59.pdf?sequence=1&isAllowed=y>
- Mika, J. (1995). *Analiza statystyczna Polski na tle krajów Unii Europejskiej*. Katowice: Wydawnictwo Naukowe Śląsk.
- Młodak, A. (2006). *Analiza taksonomiczna w statystyce regionalnej*. Warszawa: Difin.
- Muszyński, J. (2004). O pewnej zunifikowanej metodzie rozwiązywania równań liniowych o stałych współczynnikach. *Matematyka Stosowana. Matematyka dla społeczeństwa*, 32(5/46), 7-31. <https://wydawnictwa.ptm.org.pl/index.php/matematyka-stosowana/article/view/1235/1188>
- Panek, T. (2009). *Statystyczne metody wielowymiarowej analizy porównawczej*. Warszawa: Oficyna Wydawnicza Szkoły Głównej Handlowej.

- Pociecha, J., Podolec, B., Sokołowski, A., Zając, K. (1988). *Metody taksonomiczne w badaniach społeczno-ekonomicznych*. Warszawa: PWN.
- Strahl, D. (1998). *Taksonomia struktur w badaniach regionalnych*. Wrocław: Wydawnictwo Akademii Ekonomicznej.
- Zorska, A. (2011). *Chaos czy twórcza destrukcja? Ku nowym modelom w gospodarce i polityce*. Warszawa: Oficyna Wydawnicza SGH.
- <https://stat.gov.pl> (7.09.2021).
- <https://ec.europa.eu/eurostat> (7.09.2021).

6. Ocena podobieństwa rozwoju przedsiębiorstw sektora MMŚ oraz dużych przedsiębiorstw w wybranych krajach UE w latach 2010 i 2019 za pomocą diagramu Czekanowskiego

(Monika Miśkiewicz-Nawrocka)

6.1. Wprowadzenie

Sektor mikro-, małych i średnich przedsiębiorstw (MMŚP) odgrywa bardzo ważną rolę we współczesnej gospodarce, ponieważ w istotny sposób wpływa na jej wzrost i rozwój. Początkowo był on niedoceniany, a jego rola w kolejnych latach miała znacznie się zmniejszać (Kaplan, 1954), dziś jednak, według Organizacji Współpracy Gospodarczej i Rozwoju (OECD), stanowi ponad 90% wszystkich przedsiębiorstw działających na świecie oraz 63% ogółu pracujących znajduje zatrudnienie w tym sektorze (Munro, 2013). Rola, jaką obecnie pełni sektor mikro-, małych i średnich przedsiębiorstw, zmusza władze państw do stałego monitorowania i doskonalenia infrastruktury zarówno instytucjonalnej, jak i finansowej w celu poprawy warunków działania tych przedsiębiorstw (Mikołajczyk, Krawczyk, 2006). Kraje, w których podstawą jest gospodarka wolnorynkowa, charakteryzują się dużą swobodą przedsiębiorczości. Dominuje w nich własność prywatna, co pociąga za sobą istnienie sektora małych i średnich przedsiębiorstw jako narzędzia niezbędnego do prawidłowego rozwoju gospodarczego (Hozer, Markowicz, 2002). Liczne światowe badania nad sektorem MMŚP dowodzą, że przedsiębiorstwa te pełnią bardzo istotną rolę w gospodarce, wpływając na wzrost gospodarczy (Majewski, Kucharski, 2006; Mikołajczyk, Krawczyk, 2006).

Celem opracowania jest ocena kondycji finansowej przedsiębiorstw sektora mikro-, małych i średnich przedsiębiorstw oraz sektora dużych przedsiębiorstw w wybranych krajach UE. W opracowaniu dokonano uporządkowania wybranych krajów UE według wybranych cech przedsiębiorstw wykorzystując diagram Czekanowskiego (Czekanowski, 1913).

6.2. Definicja oraz rola mikro-, małych i średnich przedsiębiorstw

W literaturze brakuje jednej uniwersalnej definicji mikro-, małego i średniego przedsiębiorstwa. Definicje te różnią się od siebie w różnych krajach (Ardic i in., 2011). Według von Pobobsky'ego (1992) Międzynarodowa Organizacja Pracy wyróżniła ponad 50 definicji w 75 krajach.

Definicja małych i średnich przedsiębiorstw jest niezwykle istotna i użyteczna, ponieważ pozwala na oszacowanie odpowiednich statystyk i monitorowanie kondycji sektora MMŚP w czasie, międzynarodowe porównywanie gospodarek oraz porównania regionów w ramach jednej gospodarki, ustalenie progów podatkowych lub innych przepisów, zakwalifikowanie do poszczególnych form wsparcia publicznego (Berisha, Pula, 2015; OECD-Unido, 2004).

Pomimo braku jednoznacznej definicji MMŚP, podstawowym kryterium podziału przedsiębiorstw według OECD (2010) pozostaje wielkość zatrudnienia. Najczęściej górną granicą MMŚP jest 250 pracowników (UE, Meksyk, Japonia, Turcja), w niektórych krajach jednak wynosi ona 100 (Nowa Zelandia), 200 (Australia, Korea), a nawet 500 pracowników (USA, Canada).

Komisja Europejska również traktuje liczbę pracowników jako główne kryterium, ale niezbędnym uzupełnieniem definicji MMŚP jest kryterium finansowe, ponieważ pozwala uchwycić rzeczywistą skalę i wyniki przedsiębiorstwa oraz jego pozycję na tle konkurencji (European Commission, 2004). Komisja Europejska jako kryteria definiowania przedsiębiorstw podaje liczbę pracowników, roczny obrót lub roczny bilans (European Commission, 2005). Spełnienie kryterium liczby pracowników jest obowiązkowe, natomiast spełnienie kolejnego z dwóch kryteriów finansowych jest wyborem przedsiębiorstwa (Berisha, Pula, 2015). W tabeli 6.1 przedstawiono definicję MMŚP, która weszła w życie 1 stycznia 2005 roku.

Tabela 6.1. Definicja MMS przedsiębiorstw obowiązująca w UE

Kategoria przedsiębiorstwa	Liczba pracowników	Roczny obrót	lub	Roczny bilans
średnie	< 250	≤ 50 mln euro		≤ 50 mln euro
małe	< 50	≤ 10 mln euro		≤ 10 mln euro
mikro	< 10	≤ 2 mln euro		≤ 2 mln euro

Źródło: European Commission (2005).

Sektor MMŚP stanowi istotny element gospodarki, a poziom rozwoju gospodarczego w dużej mierze zależy zatem od zdolności do tworzenia dobrego środowiska dla rozwoju sektora MŚP. Przedsiębiorstwa tego sektora tworzą i wprowadzają nowe produkty, technologie, rozwiązania, które później mogą zostać przeniesione na inne przedsiębiorstwa (European Commission, 2004). Inwestycje zapewniają im dostęp do technologii i pomagają rozwijać biznes, zapewniając tym samym konkurencyjność przedsiębiorstwa. Małe i średnie przedsiębiorstwa mogą dostarczać wysokiej jakości usługi i konkurencyjne produkty po niskich kosztach i w ilościach dostosowanych do rynku). Przedsiębiorstwa MMŚ charakteryzują się dużą elastycznością oraz dynamicznym podejściem do otoczenia, ponieważ mogą bardzo szybko reagować na zmieniającą się

sytuację społeczną, gospodarczą oraz na potrzeby i preferencje potencjalnych klientów (Skowronek-Mielczarek, 2007). Ponadto przedsiębiorstwa sektora MMS są głównym czynnikiem dywersyfikacji rynku, przez co powodują wzrost produktywności całej gospodarki (Mikołajczyk, Krawczyk, 2006). Mikro- i małe przedsiębiorstwa prowadzą swoją działalność głównie w niszach rynkowych oraz na rynkach o stosunkowo niewielkim potencjale wzrostu, dlatego też stanowią ważny element rozwoju regionalnego (Skowronek-Mielczarek, 2003).

Trwałym elementem każdego systemu gospodarczego są jednak duże przedsiębiorstwa, które najczęściej spełniają wysokie wymagania rynkowe dotyczące niezbędnej koncentracji kapitału związanej z wielkością produkcji i względami technologicznymi (Ministerstwo Infrastruktury i Rozwoju, 2014). W UE mianem dużych przedsiębiorstw są określone przedsiębiorstwa spełniające jeden z warunków: zatrudnia przynajmniej 250 osób lub zatrudnia mniej niż 250 pracowników, ale suma bilansowa przekracza 43 mln euro i łączny obrót przekracza 50 mln euro, lub którego przynajmniej 25% kapitału lub praw do głosowania jest kontrolowane przez podmioty publiczne. Choć duże przedsiębiorstwa stanowią zaledwie 0,2% przedsiębiorstw działających w UE, zatrudniają 33% wszystkich pracujących.

6.3. Diagram Czekanowskiego

Tworzenie diagramu Czekanowskiego (Czekanowski, 1913) jest jedną z najstarszych metod taksonomicznych, która pozwala na określenie powiązań między obiektami i unaocznienie związków i podobieństw między nimi. Diagram jest wizualizacją macierzy odległości pomiędzy tymi obiektami. Obiekty najbardziej do siebie podobne znajdują się najbliżej głównej przekątnej macierzy odległości. Im dalej od głównej przekątnej tym obiekty są mniej podobne do siebie. (Jaskulski, Sołtysiak, 2004; Sołtysiak, Jaskulski, 1999). Wykreślenie diagramu przebiega według następujących etapów (Heffner, Gibas, 2007; Wójcik, 2013):

- zdefiniowanie macierzy danych,
- standaryzacja lub unitaryzacja zmiennych,
- wybór miary podobieństwa,
- oszacowanie macierzy odległości taksonomicznych,
- wyznaczenie wartości minimalnej i maksymalnej w macierzy odległości taksonomicznych,
- oszacowanie przedziałów klasowych dla odległości taksonomicznych na podstawie wyznaczonego empirycznego obszaru zmienności,
- opracowanie nieuporządkowanego diagramu Czekanowskiego,
- uporządkowanie diagramu Czekanowskiego,
- interpretacja uzyskanych wyników.

Standaryzację zmiennych można przeprowadzić zgodnie z formułą (Dziechciarz 2012):

$$z_{ij} = \frac{x_{ij} - \bar{x}_j}{S_j}, \quad (1)$$

gdzie:

z_{ij} – standaryzowana zmienna x_j dla i -tego obiektu,

x_{ij} – zmienna x_j dla i -tego obiektu,

\bar{x}_j – średnia arytmetyczna zmiennej x_j ,

S_j – odchylenie standardowe zmiennej x_j .

Macierz odległości podobieństwa wyznacza się za pomocą metryki euklidesowej.

6.4. Badanie empiryczne

Przedmiotem badania były wybrane kraje UE w latach 2010-2019 ze względu na kondycję finansową przedsiębiorstw. W badaniu pod uwagę wzięto kraje, które we wspomnianych latach były członkami wspólnoty UE z pominięciem Malty i Luksemburga z powodu braku danych.

W pierwszym etapie badań zdefiniowano zbiór zmiennych diagnostycznych, eliminując zmienne zbyt silnie ze sobą skorelowane. W tabeli 6.2 przedstawiono zestaw cech diagnostycznych wziętych pod uwagę uwzględniając podział na stymulanty (S) i destymulanty (D). Dobór poniższych miar wynikał z analizy czynników determinujących zachodzące zmiany.

Tabela 6.2. Zmienne diagnostyczne

Symbol	Nazwa zmiennej	Charakter zmiennej
X1	Odsetek przedsiębiorstw [%]	S
X2	Obrót lub składka przypisana brutto [%]	S
X3	Wartość dodana w kosztach czynników produkcji [%]	S
X4	Odsetek osób zatrudnionych [%]	S
X5	Obrót na osobę zatrudnioną [%]	S
X6	Pozorna wydajność pracy [%]	S
X7	Tempo wzrostu zatrudnienia [%]	S
X8	Liczba zatrudnionych na przedsiębiorstwo	S

W 2019 roku w krajach UE działało 6 118 667 przedsiębiorstw, z czego 90,81% stanowiły mikroprzedsiębiorstwa, 5,93% małe przedsiębiorstwa i 0,76% średnie przedsiębiorstwa. Duże przedsiębiorstwa w liczbie 8572 stanowiły 0,14%.

W kolejnym etapie badania pogrupowano państw pod względem podobieństwa sytuacji mikro-, małych, średnich i dużych przedsiębiorstw za pomocą diagramu Czekanowskiego. Na rysunkach 6.1-6.8 zaprezentowano diagramy Czekanowskiego dla badanych obiektów sporządzone w programie *Maczek* (<http://www.antropologia.uw.edu.pl/MaCzek/maczek.html>). Poszczególne wiersze i kolumny diagramu odpowiadają kolejnym krajom. Im większy symbol na przecięciu wiersza i kolumny, tym większe podobieństwo państw pod względem badanych cech. Najbardziej podobne obiekty znajdują się najbliżej głównej przekątnej, natomiast im dalej od głównej przekątnej tym obiekty są mniej podobne pod względem badanych cech.


Analizując poniższe diagramy (rysunki 6.1-6.8), można zauważyć, że państwa tworzą grupy obiektów najbardziej do siebie podobnych. Jednak w niektórych przypadkach podział nie jest jednoznaczny i niektóre państwa można przypisać do dwóch grup.

Rozpatrując podział państw ze względu na sytuację mikroprzedsiębiorstw w 2010 roku w krajach UE (rysunek 6.1), można wyróżnić pięć grup najbardziej podobnych obiektów:

- grupa I: Belgia, Węgry, Bułgaria, Hiszpania, Portugalia, Czechy, Francja,
- grupa II: Słowenia, Chorwacja, Rumunia, Litwa, Szwecja, Finlandia,
- grupa III: Austria, Niemcy, Dania,
- grupa IV: Łotwa, Estonia,
- grupa V: Słowacja, Cypr, Włochy, Grecja.

Polska, Irlandia, Wielka Brytania i Holandia nie tworzyły żadnych grup.

Państwa należące do grupy I charakteryzowały się największym odsetkiem mikroprzedsiębiorstw oraz liczbą zatrudnionych na przedsiębiorstwo. W grupie II znalazły się państwa, których mikroprzedsiębiorstwa osiągnęły obrót lub składkę przypisaną brutto poniżej wartości średniej. Grupę III stanowią państwa, w których mikroprzedsiębiorstwa osiągnęły najwyższy obrót na osobę zatrudnioną przy jednocześnie najniższym odsetku mikroprzedsiębiorstw oraz najniższym odsetku zatrudnionych. Do grupy IV należały państwa, których mikroprzedsiębiorstwa osiągnęły obrót lub składkę przypisaną brutto powyżej średniej. Państwa z grupy V charakteryzowały się najwyższymi wartościami wskaźnika liczby przedsiębiorstw, obrotu lub składki przypisanej brutto oraz wartości dodanej w kosztach czynników produkcji. W grupie V siła powiązań między państwami jest mniejsza (mniejsze kropki na diagramie – rysunek 6.1).


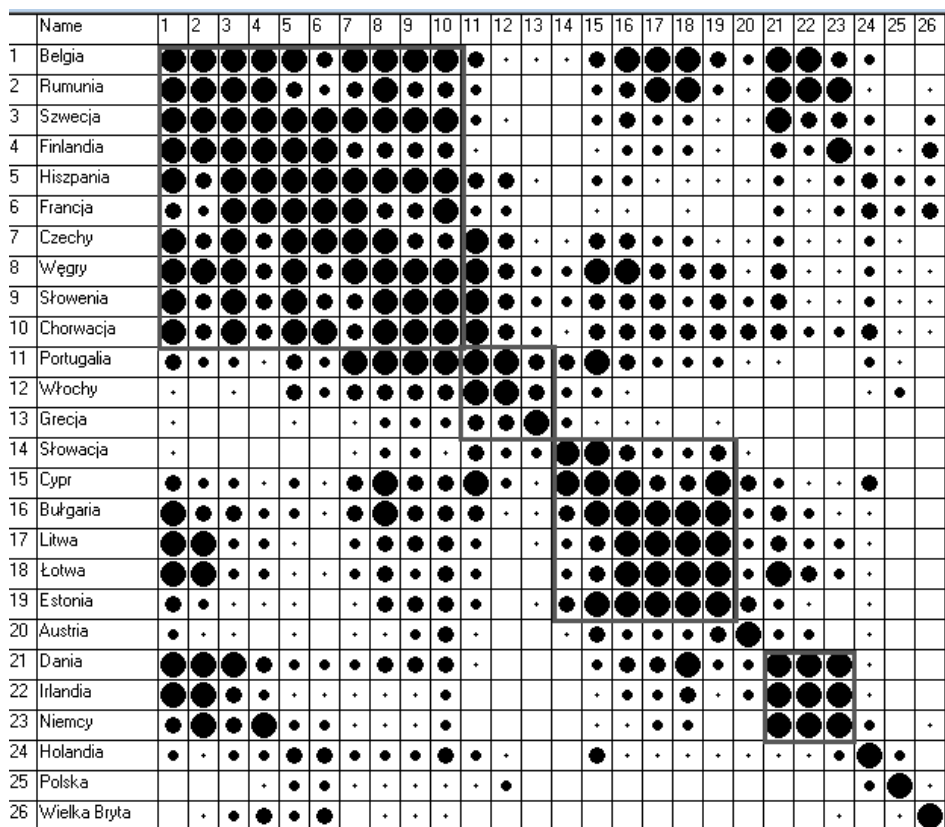


Rys. 6.1. Uporządkowany diagram Czekanowskiego dla mikroprzedsiębiorstw w 2010 roku

W sektorze małych przedsiębiorstw w 2010 r. (rysunek 6.2) można wyróżnić cztery grupy najbardziej podobnych państw. Są to:


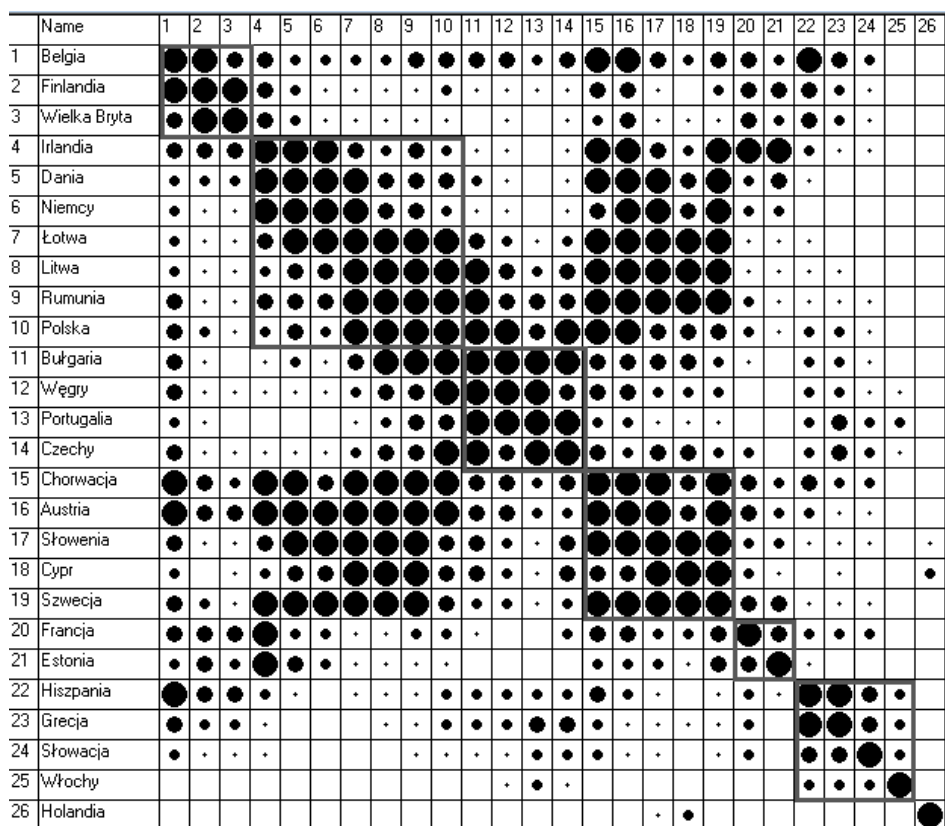
- grupa I: Belgia, Rumunia, Szwecja, Finlandia, Hiszpania, Francja, Czechy, Węgry, Słowenia, Chorwacja,
- grupa II: Portugalia, Włochy, Grecja,
- grupa III: Słowacja, Cypr, Bułgaria, Litwa, Łotwa, Estonia,
- grupa IV: Dania, Irlandia, Niemcy.

Austria, Holandia, Polska, Wielka Brytania nie należały do żadnej grupy.



Rys. 6.2. Uporządkowany diagram Czekanowskiego dla małych przedsiębiorstw w 2010 roku

Analizując sektor małych przedsiębiorstw w 2010 roku można zauważyć, że państwa należące do grupy I charakteryzowały się najniższym obrotem lub składką przypisaną brutto dla małych przedsiębiorstw. Do grupy II należały państwa, których małe przedsiębiorstwa osiągnęły największe wartości pozornej wydajności brutto. Wśród państw należących do grupy III znalazły się te, dla których obrót lub składka przypisana brutto oraz wartość dodana w kosztach czynników produkcji dla małych przedsiębiorstw osiągnęły najwyższe wartości. Natomiast w grupie IV znalazły się państwa, dla których pozorna wydajność pracy oraz liczba zatrudnionych na przedsiębiorstwo przyjmowały najmniejsze wartości.



Rys. 6.3. Uporządkowany diagram Czekanowskiego dla średnich przedsiębiorstw w 2010 roku

Na podstawie danych zawartych na rysunku 6.3 wyodrębniono trzy grupy najbardziej podobnych państw ze względu na sytuację średnich przedsiębiorstw w 2010 roku. Do kolejnych grup należą odpowiednio:

- grupa I: Belgia, Finlandia, Wielka Brytania,
- grupa II: Irlandia, Dania, Niemcy, Łotwa, Litwa, Rumunia, Polska,
- grupa III: Bułgaria, Węgry, Portugalia, Czechy,
- grupa IV: Chorwacja, Austria, Słowenia, Cypr, Szwecja,
- grupa V: Francja, Estonia,
- grupa VI: Hiszpania, Grecja, Słowacja, Włochy.

Holandia nie jest włączona do żadnej grupy.

Państwa należące do grupy I w sektorze średnich przedsiębiorstw charakteryzują się najmniejszym obrotem lub składką przypisaną brutto. W grupie III znalazły się kraje, dla których średnie przedsiębiorstwa osiągnęły największe wartości obrotu na osobę zatrudnioną, pozorną wydajność pracy i liczbie zatrud-

nionych na przedsiębiorstwo, przy najniższych odsetkach przedsiębiorstw. Do grupy V zaliczono państwa o najniższych wartościach obrotu na osobę zatrudnioną oraz pozorną wydajność pracy. Natomiast do grupy VI należały państwa o najmniejszym odsetku przedsiębiorstw, obrocie lub składce przypisanej brutto i odsetku osób zatrudnionych w średnich przedsiębiorstwach, przy jednocześnie najwyższym obrocie na osobę zatrudnioną i liczbie zatrudnionych na przedsiębiorstwo. Dla państw z grupy II i IV wartości rozważanych wskaźników przyjmują wartości z typowego przedziału zmienności.

W przypadku sektora dużych przedsiębiorstw w 2010 roku (rysunek 6.4) można wyróżnić cztery grupy najbardziej podobnych do siebie państw. Są to:

- grupa I: Belgia, Litwa, Węgry, Czechy, Hiszpania, Portugalia, Włochy, Grecja, Słowacja,
- grupa II: Łotwa, Estonia, Irlandia, Austria, Dania, Holandia, Słowenia,
- grupa III: Francja, Szwecja, Chorwacja, Niemcy, Finlandia,
- grupa IV: Polska, Rumunia.


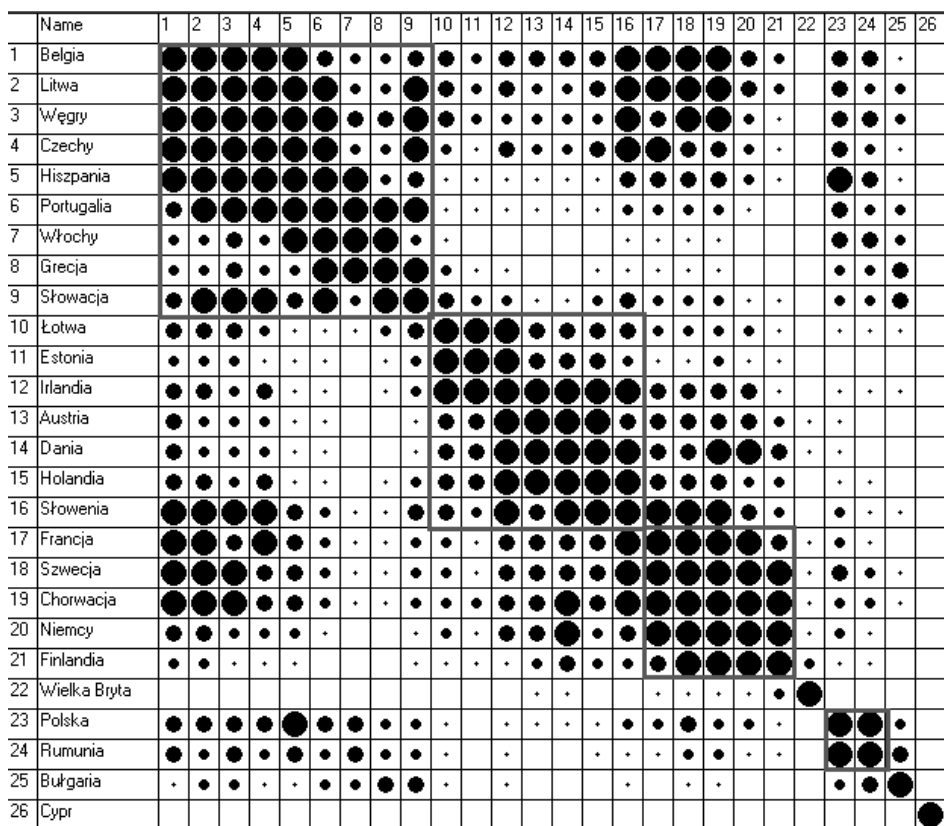
Wielka Brytania, Bułgaria i Cypr nie tworzyły żadnej grupy.

Analizując sektor dużych przedsiębiorstw (rysunek 6.4), można zauważyć, że państwa należące do grupy I charakteryzują się największą liczbą zatrudnionych na przedsiębiorstwo oraz odsetkiem zatrudnionych w dużych przedsiębiorstwach poniżej średniej. W grupie II znalazły się państwa, dla których duże przedsiębiorstwa osiągnęły najmniejsze obroty na osobę zatrudnioną, a w grupie III – te z największymi wartościami wskaźników obrotów lub składką przypisaną brutto oraz wartością dodaną w kosztach czynników produkcji. Natomiast grupę IV tworzyły kraje, dla których w dużych przedsiębiorstwach obrót na osobę zatrudnioną i pozorna wydajność pracy jest największy.

Dla mikroprzedsiębiorstw w 2019 roku (rysunek 6.5) można wyróżnić trzy grupy najbardziej podobnych państw:


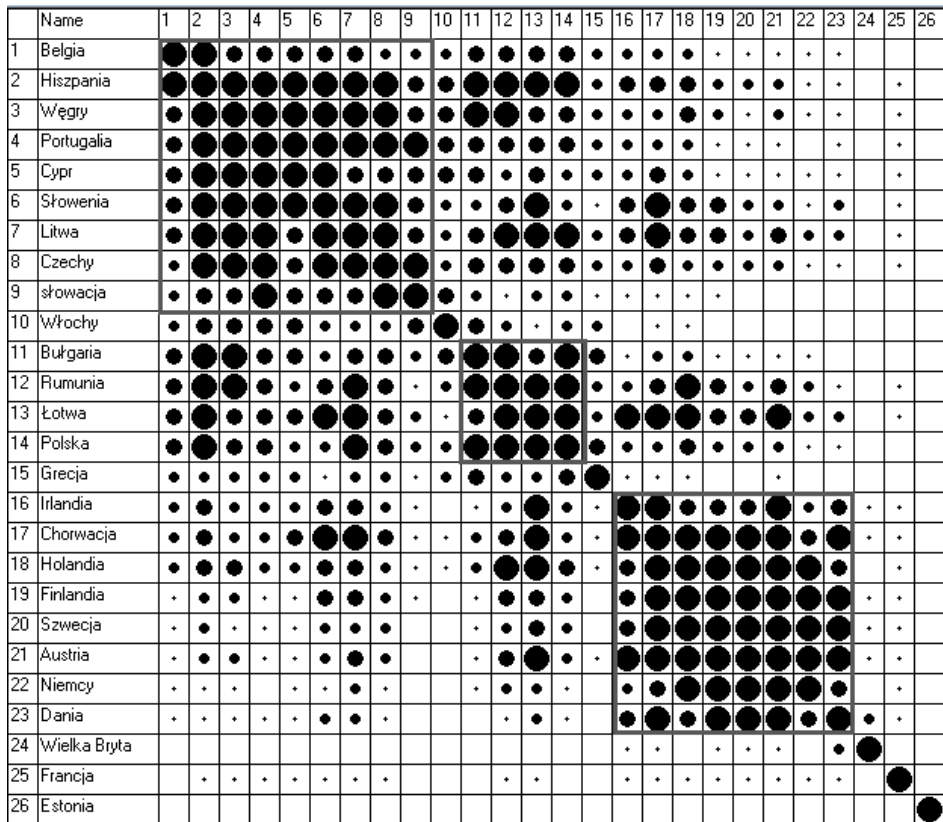
- grupa I: Belgia, Hiszpania, Węgry, Portugalia, Cypr, Słowenia, Litwa, Czechy, Słowacja,
- grupa II: Bułgaria, Rumunia, Łotwa, Polska,
- grupa III: Irlandia, Chorwacja, Holandia, Finlandia, Szwecja, Austria, Niemcy, Dania.

Włochy, Grecja, Wielka Brytania, Francja i Estonia nie zostały przyporządkowane do żadnej grupy.



Rys. 6.4. Uporządkowany diagram Czekanowskiego dla dużych przedsiębiorstw w 2010 roku

Na podstawie powyższego diagramu (rysunek 6.5) można zauważyć, że w 2019 roku zmieniło się pogrupowanie państw ze względu na sektor mikroprzedsiębiorstw. Do grupy I przypisano państwa, których przedsiębiorstwa charakteryzują się największą wartością dodaną w kosztach czynników produkcji. W grupie II znalazły się kraje, dla których mikroprzedsiębiorstwa osiągnęły największe tempo wzrostu zatrudnienia, przy najniższej pozornej wydajności pracy. Państwa należące do grupy III charakteryzują się najmniejszym odsetkiem przedsiębiorstw, obrotem lub składką przypisaną brutto, wartością dodaną w kosztach czynników produkcji oraz liczbą zatrudnionych na przedsiębiorstwo.

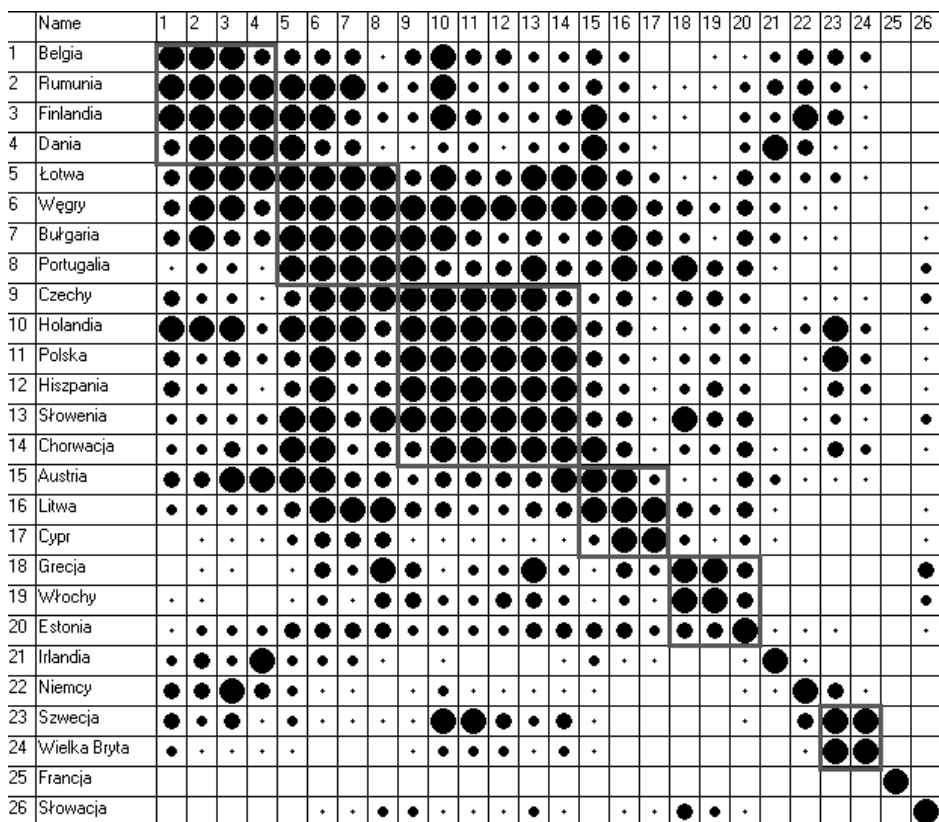


Rys. 6.5. Uporządkowany diagram Czekanowskiego dla mikroprzedsiębiorstw w 2019 roku

Analizując podział państw ze względu na małe przedsiębiorstwa w 2019 roku (rys. 6.6), wyróżniono sześć grup najbardziej podobnych obiektów:

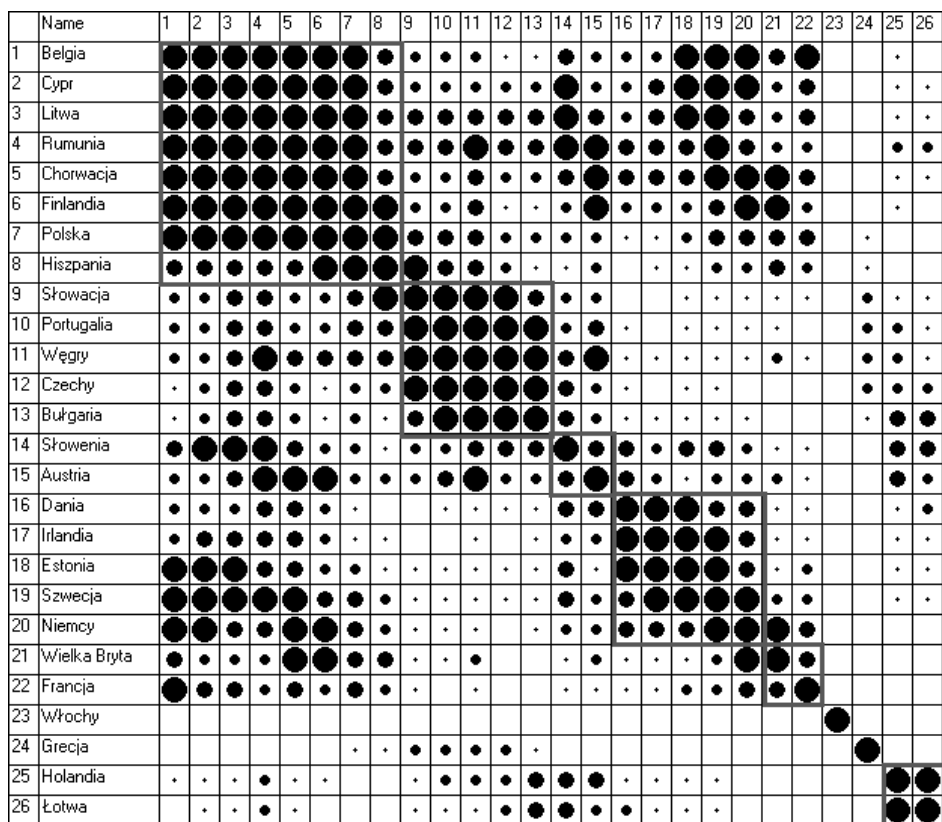
- grupa I: Belgia, Rumunia, Finlandia, Dania,
- grupa II: Łotwa, Węgry, Bułgaria, Portugalia,
- grupa III: Czechy, Holandia, Polska, Hiszpania, Słowenia, Chorwacja,
- grupa IV: Austria, Litwa, Cypr,
- grupa V: Grecja, Włochy, Estonia,
- grupa VI: Szwecja, Wielka Brytania.

Pozostałe kraje nie tworzą żadnych grup.



Rys. 6.6. Uporządkowany diagram Czekanowskiego dla małych przedsiębiorstw w 2019 roku

Wśród państw należących do grupy I znalazły się te, dla których obrót na osobę zatrudnioną w małych przedsiębiorstwach był poniżej średniej. W grupie II umieszczono państwa, dla których małe przedsiębiorstwa charakteryzują się wartością dodaną w kosztach produkcji oraz odsetkiem osób zatrudnionych powyżej średniej. W grupie III znalazły się państwa, dla których małe przedsiębiorstwa charakteryzują się wartością dodaną w kosztach produkcji oraz odsetkiem osób zatrudnionych poniżej średniej. Do grupy IV należały państwa o najwyższym obrocie lub składce przypisanej brutto. W grupie V znalazły się kraje o największym tempie wzrostu zatrudnienia w małych przedsiębiorstwach. Natomiast państwa z grupy VI charakteryzują się najmniejszym obrotem lub składką brutto oraz najmniejszą wartością dodaną w kosztach czynników produkcji.



Rys. 6.7. Uporządkowany diagram Czekanowskiego dla średnich przedsiębiorstw w 2019 roku


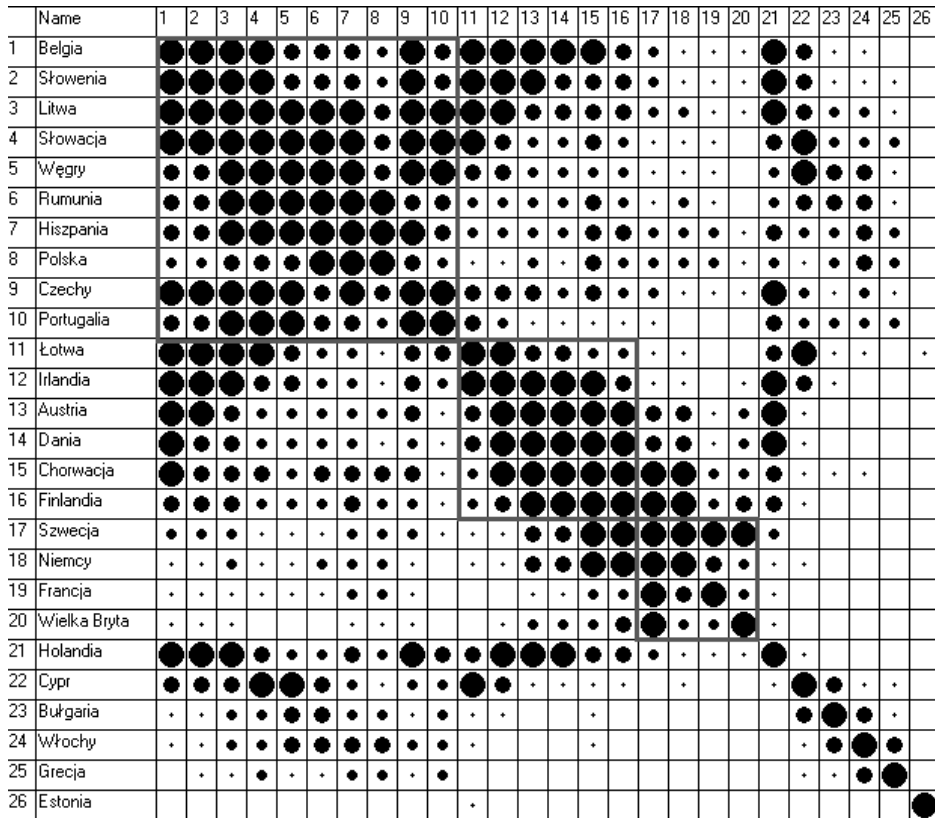
Na podstawie danych zawartych na rysunku 6.7 wyodrębniono grupy najbardziej podobnych państw ze względu na sektor średnich przedsiębiorstw w 2019 roku. Do wyróżnionych grup należą:

- grupa I: Belgia, Cypr, Litwa, Rumunia, Chorwacja, Finlandia, Polska, Hiszpania,
- grupa II: Słowacja, Portugalia, Węgry, Czechy, Bułgaria,
- grupa III: Słowenia, Austria,
- grupa IV: Dania, Irlandia, Estonia, Szwecja, Niemcy,
- grupa V: Wielka Brytania, Francja,
- grupa VI: Holandia, Łotwa.

Włochy i Grecja nie tworzą żadnych grup.

Państwa należące do grupy I charakteryzują się jednym z najniższych wskaźników tempa wzrostu zatrudnienia. W grupie II znalazły się kraje, dla których średnie przedsiębiorstwa osiągnęły największe wartości wskaźników:

pozorna wydajność pracy i liczba zatrudnionych na przedsiębiorstwo. Państwa z grupy III mają jedne z najwyższych wartości wskaźnika obrót lub składka przypisana brutto. Do grupy IV należały państwa o największym odsetku zatrudnionych w przedsiębiorstwach, przy jednocześnie najmniejszym obrocie na osobę zatrudnioną. W grupie V znalazły się kraje o najniższych obrocie lub składce przypisanej brutto oraz wartości dodanej w kosztach czynników produkcji oraz najwyższym tempie wzrostu zatrudnienia. Natomiast do grupy VI przypisano państwa o najwyższym obrocie lub składce przypisanej brutto.



Rys. 6.8. Uporządkowany diagram Czekanowskiego dla dużych przedsiębiorstw w 2019 roku

Dla dużych przedsiębiorstw w 2019 roku (rysunek 6.8) wyróżniono cztery grupy najbardziej podobnych państw:

- grupa I: Belgia, Słowenia, Litwa, Słowacja, Węgry, Rumunia, Hiszpania, Polska, Czechy , Portugalia,
- grupa II: Łotwa, Irlandia, Austria, Dania, Chorwacja, Finlandia,

- grupa III: Szwecja, Niemcy, Francja, Wielka Brytania,
- grupa IV: Bułgaria, Cypr, Włochy, Grecja.

Pozostałe państwa nie zakwalifikowano do żadnych grup.

Na podstawie powyższego diagramu (rysunek 6.8) można zauważyć, że państwa należące do grupy I charakteryzują się największą odsetkiem przedsiębiorstw. W grupie II znalazły się państwa, dla których duże przedsiębiorstwa osiągnęły wartości zmiennych obrót lub składka przypisana brutto oraz wartość dodana w kosztach czynników produkcji powyżej średniej. Państwa należące do grupy III charakteryzują się największymi wartościami wartości dodanej w kosztach czynników produkcji, przy minimalnym obrocie lub składce przypisanej brutto. Natomiast do grupy IV (o najsłabszych powiązaniach) przypisano państwa o największej pozornej wydajności pracy przy minimalnym odsetku osób zatrudnionych.

6.5. Podsumowanie

W badanym okresie wśród wybranych państw UE można wyróżnić kilka grup podobnych do siebie pod względem rozwoju sektora mikro-, małych i średnich przedsiębiorstw. Analizując wyniki przedsiębiorstw sektora MMS w 2010 roku do takich grup można zaliczyć: Niemcy i Dania oraz Włochy i Grecja, a w przypadku mikro- i małych przedsiębiorstw: Belgia, Węgry i Hiszpania oraz Łotwa i Estonia. W 2019 roku wśród państw, które należały do tej samej grupy dla mikro-, małych i średnich przedsiębiorstw znalazły się: Cypr i Litwa. W 2019 roku w sektorze mikro- i średnich przedsiębiorstw do tych samych grup trafiły: Słowacja, Czechy i Węgry, Rumunia i Polska, a także Irlandia, Szwecja, Niemcy i Dania, natomiast w sektorze małych i średnich przedsiębiorstw: Węgry i Bułgaria oraz Belgia i Rumunia. Analizując sektor mikroprzedsiębiorstw w latach 2010 i 2019 można zauważyć, że do tych samych grup w latach 2010 i 2019 należą: Austria, Dania i Niemcy, Belgia, Czechy, Hiszpania, Portugalia i Węgry, (Chorwacja, Finlandia i Szwecja oraz Cypr i Słowacja. Dla małych przedsiębiorstw w skład tych samych grup w latach 2010 i 2019 należą: Belgia, Finlandia i Rumunia, Bułgaria i Łotwa, Chorwacja, Czechy i Słowenia oraz Grecja i Włochy, natomiast dla sektora średnich przedsiębiorstw te same grupy tworzą: Austria i Słowenia, Belgia i Finlandia, Chorwacja i Cypr, Bułgaria, Czechy i Portugalia, Litwa, Polska i Rumunia oraz Dania, Irlandia i Niemcy.

Analizując wskaźniki opisujące sytuację przedsiębiorstw sektora MMSP w wybranych krajach UE w latach 2010 i 2019, można zauważyć, że zacierają się dysproporcje pomiędzy zachodnią a wschodnią częścią Europy. Utworzone grupy państw zmieniają się w czasie, a w skład danej grupy nie zawsze wchodzi kraje znajdujące się w bliskiej odległości geograficznej. Podobne wnioski można wyciągnąć analizując sektor dużych przedsiębiorstw.

Literatura

- Ardic, O. P., Mylenko, N., Saltane, V. (2011). *Small and medium enterprises: A cross-country analysis with a new date set* (Policy Research – Working Paper Series). Washington, DC: World Bank. <https://doi.org/10.1596/1813-9450-5538>
- Berisha, G., Pula, J. S. (2015). Defining small and medium enterprises: A critical review. *Academic Journal of Business Administration, Law and Social Sciences*, 1(1), 17-28. <https://iipcccl.org/wp-content/uploads/2015/03/Ajbals-17-28.pdf>
- Czekanowski, J. (1913). *Zarys metod statystycznych w zastosowaniu do antropologii* (Prace Naukowe, nr 5). Warszawa: Towarzystwo Naukowe Warszawskie.
- Dziechciarz, J. (2012). *Ekonometria. Metody, przykłady, zadania*. Wrocław: Wydawnictwo Uniwersytetu Ekonomicznego.
- European Commission. (2004). Observatory of the European SMEs (Highlights from the 2003 Observatory, No. 8). <http://www.cermlab.it/wp-content/uploads/cerm/Highlights%20from%20the%202003-Observatory.pdf>
- European Commission. (2005). *The new SME definition: User guide and model declaration section*. Brussels: Office for Official Publications of the European Communities. <https://op.europa.eu/en/publication-detail/-/publication/10abc892-251c-4d41-aa2b7fe1ad83818c>
- Heffner, K., Gibas, P. (2007). *Analiza ekonomiczno-przestrzenna*. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Hozer, J., Markowicz, I. (2002). *Małe firmy. Analizy i diagnozy*. Szczecin: Wydawnictwo Naukowe Uniwersytetu Szczecińskiego.
- Jaskulski, P., Sołtysiak, A. (2004). Diagram Czekanowskiego: pomysł, historia, zastosowania. *Taksonomia*, 11(1022: Klasyfikacja i analiza danych – teoria i zastosowania), 374-383.
- Kaplan, A. D. H. (1954). *Big enterprise in a competitive system*. Washington, DC: The Brookings Institution.
- Majewski, R., Kucharski, M. (2006). Sytuacja konkurencyjna polskiego sektora małych i średnich przedsiębiorstw po przystąpieniu Polski do Unii Europejskiej. *Studenckie Prace Prawnicze, Administracyjne i Ekonomiczne*, 4, 31-41. <https://wuwr.pl/sppae/article/view/8877>
- Mikołajczyk, B., Krawczyk, M. (2006). Sektor przedsiębiorstw mikro, małych i średnich w krajach Unii Europejskiej. *Studia Europejskie*, 2, 67-85. https://journalse.com/pliki/pw/2-2006_Mikolajczyk-Krawczyk.pdf
- Ministerstwo Infrastruktury i Rozwoju. (2014). *Ocena efektów wsparcia dużych przedsiębiorstw w ramach realizacji polityki spójności w Polsce. Ewaluacja*. Warszawa: Krajowa Jednostka Ewaluacji.
- Munro, D. (2013). *A guide to financing SMEs*. New York: Palgrave Macmillan.
- OECD. (2010). *SMEs, entrepreneurship, and innovation*. Paris.

- OECD-Unido. (2004). *Effective policies for small business*. Paris.
- Pobobsky, G. von (1992). Small and medium enterprises and labour law. *International Labour Review*, 131(6), 601-628.
- Skowronek-Mielczarek, A. (2007). *Małe i średnie przedsiębiorstwa, Źródła finansowania*. Warszawa: C.H. Beck.
- Sołtysiak, A., Jaskulski, P. (1999). Czekanowski's diagram. A method of multidimensional clustering. W J. A. Barceló, I. Briz, A. Vila (red.), *New techniques for old times* (BAR International Series, No. 757, s. 175-184). CAA 98. Computer Applications and Quantitative Methods in Archaeology. Proceedings of the 26th Conference, Barcelona, March 1998. Oxford.
- Wójcik, A. (2013). Zastosowanie diagramu Czekanowskiego do badania podobieństwa krajów Unii Europejskiej pod względem pozyskiwania energii ze źródeł odnawialnych. *Zarządzanie i Finanse*, 11(4/4), 353-365. <https://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.desklight-28bca778-25ec-4b16-b463-26c815fcca9f>
- <http://www.antropologia.uw.edu.pl/MaCzek/maczek.html> (20.09.2020).

Część II
Funkcjonowanie rynku kapitałowego
w pierwszym 20-leciu XXI wieku

7. Pomiar efektywności inwestowania w dobie kryzysów XXI wieku

(Adrianna Mastalerz-Kodzis)

7.1. Wprowadzenie

Efektywne lokowanie kapitału oraz inwestowanie to zagadnienia często omawiane w literaturze z zakresu ekonomii i finansów. Istnieje wiele różnych form lokowania kapitału. Różnią się one jednak oczekiwaną stopą zwrotu z inwestycji oraz poziomem ryzyka i niepewności. Inwestycja według W. Rogowskiego to długookresowa, obciążona ryzykiem alokacja środków finansowych w celu osiągnięcia korzyści w przyszłości (Rogowski, 2004). Bezpieczne i zyskowe lokowanie kapitału jest jednym z istotnych zagadnień ekonomicznych (Begg, Dornbusch, Fischer, 2007; Taylor, Mankiw, 2009).

Celem rozdziału jest porównanie różnych form inwestowania w latach 2000-2021. Wybrany przedział czasu, pierwsze 20-lecie XXI wieku, cechował się znaczącą niestabilnością ze względu na wiele charakterystyk gospodarczych. Ważnymi okresami są z pewnością kryzys finansowy z lat 2007-2009 oraz pandemia koronawirusa, przypadająca na okres 2020-2021. We wspomnianych okresach istotnie zmieniły się warunki gospodarcze, zwiększyła się amplituda wahań wielu wskaźników ekonomicznych. Inwestorzy niejednokrotnie poszukiwali sposobów na bezpieczne ulokowanie kapitału, tak, aby nie stracił on na wartości (Dorosz, 2014; Kołodko, 2010).

Analiza sposobu, efektywności oraz ryzyka inwestowania jest ważnym elementem działalności gospodarczej, przyczynia się bowiem do pomnażania majątku firm, instytucji oraz osób prywatnych. Wybór formy inwestowania nie jest łatwy, znacząco wpływa na rezultat inwestycyjny, na osiągniętą stopę zwrotu z inwestycji. Decydent ma do wyboru wiele wariantów, między innymi: założenie lokaty bankowej, kupno obligacji, inwestowanie na giełdzie papierów wartościach, zakup metali szlachetnych lub też ulokowanie swoich oszczędności na rynku nieruchomości. W niniejszej pracy skupiono się na trzech wybranych formach lokowania kapitału, a mianowicie na opłacalności zakładania lokaty bankowej, kupnie złota oraz na inwestowaniu w nieruchomości. Porównano różne warianty inwestycyjne wyznaczając efektywność inwestowania. Wykazano, że w pierwszym 20-leciu XXI wieku można inwestować, ociągając dodatni zysk, jednak proces inwestowania jest obciążony ryzykiem, niepewnością przyszłego stanu gospodarki oraz wysokim poziomem inflacji, który znacząco obniża zysk.

Wnioski mogą posłużyć inwestorom instytucjonalnym oraz indywidualnym w przyszłości, gdy sytuacja gospodarcza nie będzie stabilna, natomiast decydet będzie musiał rozwiązać problem lokacji zgromadzonego kapitału.

7.2. Metodyka badań

7.2.1. Ocena efektywności inwestycji – stopa zwrotu

Ocena opłacalności przedsięwzięcia inwestycyjnego może być przeprowadzona przy użyciu różnych metod obliczeniowych (Dobija, 1997; Marcinek, 2001; Nowak, 1997; Rogowski, 2004).

Najbardziej intuicyjną metodą jest obliczenie prostej stopy zwrotu. Stopa ta określa stosunek rocznego zysku do wartości kapitału początkowego:

$$R = (Z / K) 100\%, \quad (1)$$

gdzie:

R – roczna stopa zwrotu,

Z – zysk roczny (netto),

K – kapitał początkowy.

Powyższy wzór wykorzystuje wielkości roczne. Jednakże w przypadku działalności inwestycyjnej poszczególne lata mogą znacząco różnić się między sobą. Wówczas wskazane jest wyznaczanie przeciętnej stopy zwrotu według formuły:

$$R_p = (Z_n / K_n) 100\%, \quad (2)$$

gdzie:

R_p – przeciętna stopa zwrotu,

Z_n – średni roczny zysk netto,

K_n – średni roczny zaangażowany kapitał.

7.3. Uwzględnienie zmienności stóp procentowych oraz poziomu inflacji w ocenie efektywności inwestycji

Okres inwestycyjny często jest na tyle długi, że w czasie jego trwania zmieniają się stopy procentowe. Należy to uwzględnić podczas wyznaczania efektywności inwestycji. Jeśli zysk oznaczymy symbolem Z , zaś inwestowany kapitał za pomocą symbolu K , to można wówczas skorzystać z następujących wzorów:

Efektywna stopa procentowa

$$r_{ef}(n) = Z_n/K_{n-1} \quad (3)$$

- dla oprocentowania prostego:

$$r_{ef}(n) = r/(1+(n-1)r) \quad (4)$$

(r – nominalna stopa procentowa);

- dla oprocentowania złożonego:

$$r_{ef} = r \quad (5)$$

- dla oprocentowania złożonego z kapitalizacją w podokresach:

$$r_{ef} = (1 + (r^{(m)}/m))^m - 1 \quad (6)$$

($r^{(m)}$ – nominalna stopa procentowa kapitalizacji w podokresach,
 m – liczba podokresów w okresie bazowym);

- dla oprocentowania złożonego z kapitalizacją w nadokresach:

$$r_{ef} = (1 + mr_{(m)})^{1/m} - 1 \quad (7)$$

($r_{(m)}$ – nominalna stopa procentowa kapitalizacji w nadokresach).

Efektywna stopa dyskontowa

$$d_{ef}(n) = Z_n/K_n \quad (8)$$

- Dla oprocentowania prostego:

$$d_{ef}(n) = d/(1 - (n-1)d) \quad (9)$$

(d – nominalna stopa dyskontowa);

- dla oprocentowania złożonego:

$$d_{ef} = d \quad (10)$$

- dla oprocentowania złożonego z kapitalizacją w podokresach:

$$d_{ef} = 1 - (1 - (d^{(m)}/m))^m \quad (11)$$

($d^{(m)}$ – nominalna stopa dyskontowa kapitalizacji w podokresach);

- dla oprocentowania złożonego z kapitalizacją w nadokresach:

$$d_{ef} = 1 - (1 - md_{(m)})^{1/m} \quad (12)$$

($r_{(m)}$ – nominalna stopa dyskontowa kapitalizacji w nadokresach).

Przeciętna stopa procentowa

- Dla oprocentowania prostego:

$$\bar{r} = \frac{1}{n} \sum_{j=1}^m n_j r_j \quad (r_j \text{ to stopa procentowa w okresie } n_j) \quad (13)$$

(okres n_j to podokres n (np. miesiąc, kwartał, półrocze) lub nadokres (np. dwuletni), dla którego mamy stałe r_j);

- dla oprocentowania złożonego z dołu:

$$\bar{r} = \sqrt[n]{\prod_{j=1}^m (1 + r_j)^{n_j}} - 1; \quad (14)$$

- w podokresach:

$$\bar{r} = \sqrt[n]{\prod_{j=1}^m \left(1 + \frac{r_j}{m_j}\right)^{n_j m_j}} - 1; \quad (15)$$

- w nadokresach:

$$\bar{r} = \sqrt[n]{\prod_{j=1}^m (1 + m_j r_j)^{n_j / m_j}} - 1. \quad (16)$$

Przeciętna stopa dyskontowa

- Dla oprocentowania prostego

$$\bar{d} = \frac{1}{n} \sum_{j=1}^m n_j d_j \quad (17)$$

(d_j to stopa dyskontowa w okresie n_j);

- dla oprocentowania złożonego z góry:

$$\bar{d} = 1 - \sqrt[n]{\prod_{j=1}^m (1 - d_j)^{n_j}}; \quad (18)$$

- w podokresach:

$$\bar{d} = 1 - \sqrt[n]{\prod_{j=1}^m \left(1 - \frac{d_j}{m_j}\right)^{n_j m_j}}; \quad (19)$$

- w nadokresach:

$$\bar{d} = 1 - \sqrt[n]{\prod_{j=1}^m (1 - m_j d_j)^{n_j / m_j}}. \quad (20)$$

W rzeczywistości gospodarczej istotnym elementem jest spadek wartości kapitału będący skutkiem inflacji. Gdy nie uwzględnia się inflacji w wyznaczeniu zyskowności inwestycji, to otrzymany wynik nie jest prawidłową i dokładną miarą efektywności inwestycji.

W celu dodania do analizy poziomu inflacji można zastosować następujące formuły matematyki finansowej.

Rzeczywista stopa oprocentowania kapitału

$$r_i = (r - i)/(1 + i), \quad (21)$$

gdzie:

i – inflacja w okresie trwania inwestycji,

r – stopa oprocentowania kapitału.

Stopa inflacji

$$i = (r - r_i)/(1 + r_i) \quad (22)$$

- m -okresowa stopa inflacji:

$$i(m) = \prod_{k=1}^m (1 + i_k) - 1; \quad (23)$$

- przeciętna stopa inflacji:

$$\bar{i} = \sqrt[m]{\prod_{k=1}^m (1 + i_k)} - 1. \quad (24)$$

7.4. Deterministyczna metoda NPV

W finansach, wpływy i wypływy pieniędzy (tj. przychody lub wydatki, rozchody), które mają miejsce w jednakowych odstępach czasu, określane są nazwą strumieni (przepływów) pieniędzy (ang. *cash flows*). Oznaczmy przez CF_0 płatność (przychód lub wydatek) w chwili początkowej, a przez CF_i ($i = 1, 2, \dots, n$) płatność przypadającą na koniec i -tego okresu.

Chcąc obliczyć wartość bieżącą strumienia pieniędzy (CF_0, CF_1, \dots, CF_n), należy każdy element tego strumienia sprowadzić do chwili obecnej (czyli zdyskontować), a następnie zsumować otrzymane w ten sposób wielkości. Otrzymamy wtedy następujący wzór na wartość bieżącą strumienia pieniężnego:

$$PV = CF_0 + \frac{CF_1}{1+r} + \frac{CF_2}{(1+r)^2} + \dots + \frac{CF_n}{(1+r)^n} = \sum_{i=0}^n \frac{CF_i}{(1+r)^i}. \quad (25)$$

W powyższym wzorze r jest stopą procentową.

Wzór na przyszłą wartość strumienia ma postać:

$$FV = CF_0(1+r)^n + CF_1(1+r)^{n-1} + \dots + CF_{n-1}(1+r) + CF_n = \sum_{i=0}^n CF_i(1+r)^{n-i}. \quad (26)$$

Planując inwestycję, należy ocenić, czy jest ona opłacalna. Niech CF_0 oznacza nakłady, które musimy ponieść, aby uruchomić inwestycję (nakłady początkowe), a CF_1, CF_2, \dots, CF_n oznaczają przewidywane przychody z inwestycji lub związane z nią wydatki w kolejnych okresach czasu (np. miesiącach, kwartałach, latach).

Liczba n , czyli liczba rozważanych okresów czasu, nazywa się czasem życia ekonomicznego inwestycji. Załóżmy, że w rozważanym okresie czasu stopa procentowa jest stała i równa r .

Wartością bieżącą netto inwestycji nazywany wielkość:

$$NPV = \sum_{i=0}^n \frac{CF_i}{(1+r)^i}. \quad (27)$$

Oceniając opłacalność inwestycji przyjmujemy następującą zasadę:

- jeżeli $NPV > 0$, to inwestycja jest opłacalna i warto ją realizować, gdyż przewidywane przychody, zdyskontowane na moment rozpoczęcia inwestycji, przekraczają nakłady początkowe.
- jeżeli $NPV < 0$ – inwestycja nie jest opłacalna,
- gdy $NPV = 0$ – przewidywany zysk jest na zerowym poziomie.

Przy porównywaniu kilku wariantów inwestycji lub porównując wiele różnych inwestycji stosujemy zasadę maksymalizacji NPV, tzn. realizujemy projekt, dla którego NPV przyjmuje największą dodatnią wartość.

7.5. Probabilistyczna metoda NPV

Wartość zaktualizowana netto (NPV) jest łatwą oraz skuteczną metodą oceny efektywności projektu inwestycyjnego pod warunkiem, że wszystkie wyrazy ciągu $\{CF_i\}$ są precyzyjnie określone. Praktyka gospodarcza pokazuje jednak, że przyjęty warunek jest rzadko spełniony. Przewidywanie przyszłych przychodów oraz wydatków może okazać się trudne, czasem nawet niemożliwe. Można wówczas kolejne elementy strumienia przepływów pieniężnych traktować jako zmienne losowe o znanym rozkładzie prawdopodobieństwa $losCF_0, losCF_1, \dots, losCF_n$, ze skończoną wartością oczekiwaną i skończoną wariancją. Jednakże każdy projekt inwestycyjny jest specyficzny, jego powodzenie w dużej mierze zależy od sposobu zarządzania kolejnymi jego etapami oraz od skłonności bądź awersji do podejmowanego ryzyka. Zatem rozkład omawianej zmiennej losowej jest subiektywny, może być wyznaczany przez ekspertów.

Model, w którym strumień przepływów pieniężnych jest traktowany jako realizacja zmiennej losowej w literaturze przedmiotu, został nazwany probabilistycznym modelem wartości bieżącej netto z inwestycji – PNPV (Przybycin, 2011). PNPV jest wówczas zmienną losową. Probabilistyczny NPV określa się następująco:

$$PNPV = \sum_{i=0}^n \frac{losCF_i}{(1+r)^i}. \quad (28)$$

W przypadku probabilistycznego NPV istnieje możliwość kwantyfikacji ryzyka projektu inwestycyjnego.

Wartość oczekiwaną PNPV wyznaczamy zgodnie ze wzorem:

$$E(PNPV) = \sum_{i=0}^n \frac{E(losCF_i)}{(1+r)^i}, \quad (29)$$

zaś jej odchylenie standardowe jako:

$$S(PNPV) = \sqrt{\sum_{i=0}^n \frac{S^2(losCF_i)}{(1+r)^{2i}} + \sum_{i=0}^{n-1} \left(\sum_{j=i+1}^n r_{i,j} \frac{1}{(1+r)^i} \frac{1}{(1+r)^j} S(losCF_i)S(losCF_j) \right)}, \quad (30)$$

gdzie pod pierwiastkiem znajduje się wariancja zmiennej losowej PNPV, zaś symbolem r_{ij} , oznaczono współczynnik korelacji zmiennych losowych $losCF_i$ oraz $losCF_j$.

Gdy zmiennej losowe $losCF_i$ tworzą układ niezależnych zmiennych losowych, wówczas odchylenie standardowe redukuje się po poniższej postaci:

$$S(PNPV) = \sqrt{\sum_{i=0}^n \frac{S^2(losCF_i)}{(1+r)^{2i}}}. \quad (31)$$

Jako miarę ryzyka projektu inwestycyjnego możemy wówczas wyznaczać współczynnik zmienności określany następująco:

$$V_{PNPV} = S(PNPV)/E(PNPV). \quad (32)$$

Powyżej zdefiniowany współczynnik zmienności określa wielkość ryzyka projektu inwestycyjnego przypadającą na jednostkę wartości średniej zmiennej losowej PNPV. Znana wartość współczynnika zmienności V_{PNPV} pozwala na zarządzanie ryzykiem projektu inwestycyjnego. W zależności od skłonności, czy też awersji inwestora do ryzyka decydent będzie wybierał projekty o współczynniku zmienności przyjmującym większe lub mniejsze wartości. Im wyższa wartość współczynnika zmienności, tym większe potencjalne ryzyko projektu.

7.6. Analiza ryzyka inwestycyjnego

Poziom ryzyka przedsięwzięcia inwestycyjnego ma istotny wpływ na wynik finansowy tego przedsięwzięcia, stąd coraz większe zainteresowanie metodami zarządzania ryzykiem procesu inwestowania (Ostrowska, 2002).

W literaturze z zakresu inwestowania wyraźnie rozróżnia się pojęcia ryzyka i niepewności. Ryzyko można zmierzyć. Ryzyko to sytuacja, w której można rozważać prawdopodobieństwo osiągnięcia wyników większych lub mniejszych od przewidywanych oraz znany jest rozkład prawdopodobieństwa odchyłeń tych wyników od ich wartości oczekiwanych. Niepewności nie można zmierzyć. Niepewność to sytuacja, w której rozkład prawdopodobieństwa rozbieżności wyników od ich wartości oczekiwanych nie jest znany i nie jest możliwy do oszacowania. Zatem można zapisać, że ryzyko to dająca się zmierzyć niepewność.

Do skutecznych metod zarządzania ryzykiem inwestowania zalicza się modele oceny efektywności ekonomicznej projektów inwestycyjnych, na przykład model NPV lub PNPV.


W procesie inwestowania zauważa się, że im większa oczekiwana stopa zwrotu z inwestycji, tym większe ryzyko poniesienia straty. Zatem ryzykowna inwestycja może przynieść duże starty, ale z drugiej strony może dać inwestorowi ponadprzeciętne zyski. Wprowadza się wówczas pojęcie premii za ryzyko. W procesie inwestowania określamy oczekiwaną stopę zwrotu z inwestycji i podejmujemy ryzyko w takim rozmiarze, aby premia za ryzyko odpowiadała indywidualnym wymaganiom inwestora.

7.7. Analiza empiryczna

7.7.1. Inflacja oraz zmienność stóp procentowych w Polsce w latach 2000-2021

Efektywność inwestycji jest zależna od osiągniętego zysku jednak pomniejszonego o poziom inflacji. Na rysunku 7.1 przedstawiono poziom inflacji w Polsce oraz wysokość stóp referencyjnych NBP w latach 2002-2021.

Do obliczeń w kolejnych podrozdziałach niezbędnych do wyznaczenia efektywności inwestowania posłużono się danymi dotyczącymi inflacji oraz stóp procentowych zaczerpniętymi ze stron GUS oraz NBP.



Rys. 7.1. Inflacja roczna w Polsce oraz wysokość stóp referencyjnych NBP w latach 2002-2021

Źródło: Kolany (2021).

7.7.2. Efektywność inwestowania w złoto

Popularną formą inwestowania jest lokowanie kapitału w metale szlachetne, między innymi w złoto. Powszechnie uważa się, że jest to bezpieczna lokata kapitału.

Tabela 7.1. Efektywność inwestowania w złoto w porównaniu z zyskownością lokaty bankowej

Okres inwestycyjny	Styczeń 2000 – grudzień 2020	Styczeń 2010 – grudzień 2020	Styczeń 2020 – grudzień 2020
Forma inwestycji	Efektywność inwestowania – roczna stopa zysku w okresie inwestycyjnym (w %)		
Lokata z oprocentowaniem równym średniej stopie referencyjnej bez uwzględnienia inflacji	8,13065	2,6065	0,5
lokata z oprocentowaniem równym średniej stopie referencyjnej z uwzględnieniem inflacji	2,7732	0,5695	-0,0022
Inwestycja w złoto – sprzedaż złota w grudniu 2020 po cenie NBP bez uwzględnienia inflacji	25,1952	11,0194	19,1206
Inwestycja w złoto – sprzedaż złota w grudniu 2020 po cenie NBP z uwzględnieniem inflacji	20,3381	8,7013	18,6206

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://www.mennicakrajowa.pl>

Na podstawie danych zaczerpniętych ze strony Mennicy Polskiej dokonano zakupu złota w pierwszym możliwym terminie w styczniu – odpowiednio w latach 2000, 2010 oraz 2020. Wyniki efektywności inwestycji z uwzględnieniem oraz bez uwzględnienia średniego poziomu inflacji przedstawiono w tabeli 7.1. Porównano inwestowanie w złoto z założeniem lokaty bankowej na odpowiedni okres czasu.

Inwestowanie w złoto w każdym z rozważanych okresów czasu okazało się bardziej zyskowne niżeli trzymanie kapitału na lokacie bankowej. Wysoki poziom inflacji pochłania jednak część zysku.

7.7.3. Inwestowanie na rynku nieruchomości

W czasie globalnych kryzysów można zauważyć większe zainteresowanie lokowaniem kapitału na rynku nieruchomości. W Polsce ceny za metr kwadratowy lokalu użytkowego sukcesywnie wzrastają. Zakup nieruchomości może ochronić właściciela kapitału przed skutkami inflacji, zmniejszeniem się wartości posiadanego kapitału.

W tabeli 7.2 zamieszczono ceny w złotych za 1 m² powierzchni użytkowej budynku mieszkalnego oddanego do użytkowania w Polsce w latach 2000-2021. Można zauważyć, że ceny wzrastały z kwartału na kwartał. Warto także zwrócić uwagę, że analizując bardziej dokładne dane dotyczące cen w poszczególnych regionach, miastach i aglomeracjach Polski, w różnych miastach ceny były różne. Z reguły w metropoliach ceny za m² są znacząco wyższe aniżeli w małych miejscowościach.

Tabela 7.2. Cena 1 m² powierzchni użytkowej budynku mieszkalnego oddanego do użytkowania w Polsce w latach 2000-2021

Rok	Cena (w złotych) 1 m ² powierzchni użytkowej budynku mieszkalnego oddanego do użytkowania			
	1 kwartał	2 kwartał	3 kwartał	4 kwartał
<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>
2021	4 944	5 112	5 347	5 134
2020	4 567	5 000	4 987	5 012
2019	4 388	4 484	4 376	4 597
2018	4 132	4 294	4 385	4 139
2017	4 424	4 014	4 097	4 145
2016	4 177	4 063	3 976	4 000
2015	3 926	4 066	3 961	3 925
2014	4 129	4 141	3 880	3 984
2013	4 019	3 879	3 975	4 228
2012	4 130	4 103	3 915	3 837
2011	3 797	3 819	3 988	3 829
2010	4 372	4 433	4 657	3 979
2009	3 895	3 924	3 783	3 964

cd. tabeli 7.2

1	2	3	4	5
2008	2 970	3 186	3 478	3 631
2007	2 683	2 650	3 041	2 890
2006	2 560	2 445	2 557	2 619
2005	2 505	2 336	2 528	2 388
2004	2 412	2 562	2 386	2 195
2003	2 071	2 332	2 117	2 432
2002	2 400	2 400	2 484	2 330
2001	2 350	2 490	2 700	2 500
2000	2 245	2 280	2 300	2 300

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl/bdl/start>

W analizowanym okresie najniższą cenę odnotowano w I kwartale 2003 roku, zaś najwyższą w III kwartale 2021 roku. W tym czasie cena wzrosła o ponad 158%, co stanowi średni roczny wzrost o około 8,8%.

Gdyby zainwestować w mieszkania oddane do użytku odpowiednio w I kwartałach w latach 2000, 2010, 2020, to biorąc pod uwagę stopy procentowe oraz inflację wartość tych mieszkań w IV kwartale byłaby równa odpowiednio – tabela 7.3, wiersz 3 i 4. Jednakże ceny mieszkań w analizowanym okresie znacząco wzrosły. Warto porównać skapitalizowaną wartość kapitału początkowego z I kwartału z lat 2000, 2010 i 2020 oraz średnią cenę za m² w IV kwartale 2021 roku. Wówczas okaże się, że w okresie 2000-2021 średnia roczna stopa zysku jest dodatnia (bez uwzględnienia inflacji), na poziomie 2,2632%, zaś dla przedziałów czasowych 2010-2021 oraz 2020-2021 jest ona ujemna (tabela 7.3, wiersz 5, 6).

Tabela 7.3. Wzrost wartości kwoty zainwestowanej w nieruchomości

Okres inwestycyjny	Efektywność inwestowania – roczna stopa zysku w okresie inwestycyjnym (w %)		
	I kwartał 2000 – IV 2021	I kwartał 2010 – IV 2021	I kwartał 2020 – IV 2021
Forma inwestycji			
Zakup 1 m ² powierzchni użytkowej budynku mieszkalnego bez uwzględnienia inflacji	8,1307	2,6065	0,25
Zakup 1 m ² powierzchni użytkowej budynku mieszkalnego z uwzględnieniem inflacji	2,7732	0,5695	-0,0022
Inwestycja w nieruchomości – zakup nieruchomości w I kwartale odpowiednio roku 2000, 2010 i 2020 oraz jej sprzedaż w IV kwartale 2021 po cenie 5134 za m ² bez uwzględnienia inflacji	2,2632	-0,0324	-0,7158
Inwestycja w nieruchomości – zakup nieruchomości w I kwartale odpowiednio roku 2000, 2010 i 2020 oraz jej sprzedaż w IV kwartale 2021 po cenie 5134 za m ² z uwzględnieniem inflacji	-3,-943	-2,0693	-3,4055

Źródło: Na podstawie danych statystycznych Banku Danych Lokalnych GUS zaczerpniętych ze strony <https://bdl.stat.gov.pl/bdl/start>

Należy jednak podkreślić, że ceny rynkowe nieruchomości zarówno na rynku pierwotnym, jak i wtórnym różnią się znacząco w zależności od lokalizacji nieruchomości oraz jej standardu. Brane pod uwagę ceny za 1 m² powierzchni użytkowej budynku mieszkalnego oddanego do użytkowania podawane przez GUS jedynie pokazały pewne tendencje na rynku nieruchomości. Należy jednak pamiętać, że inwestowanie na tym rynku nie zawsze może się zakończyć dodatnim wynikiem finansowym.

7.8. Podsumowanie

W analizowanych przykładach dane dobrane do obliczeń zostały pobrane ze stron GUS, NBP oraz Mennicy Polskiej. Są to dane za okres historyczny. Jednakże należy pamiętać, że w procesie inwestycyjnym nie zawsze wszystkie wielkości są znane, zdeterminowane. W licznych przypadkach przyszłe przepływy pieniężne nie są znane, jednak można przewidzieć ich prawdopodobieństwa na podstawie danych historycznych. Wówczas warto zastosować, oprócz klasycznych metod, także metody probabilistyczne, na przykład PNPV.

Z procesem inwestycyjnym zawsze jest związane ryzyko. Nie ma zysku bez ryzyka. Inwestor podejmując ryzyko liczy się także z potencjalną możliwą stratą. Zarówno na rynku lokat, jak i na rynku metali szlachetnych można uzyskać dodatnią, ale także ujemną stopę zwrotu z inwestycji. W obecnych czasach, gdy poziom inflacji jest znaczący bardzo trudno o znalezienie inwestycji cechującej wysoką oczekiwaną stopą zwrotu oraz niewielkim poziomem ryzyka. Jednak, jak zostało to pokazane w pracy tego typu inwestycje nawet w okresie dużych wahań w gospodarce są możliwe.

Literatura

- Begg, D., Dornbusch, R., Fischer, S. (2007). *Makroekonomia*. Warszawa: Polskie Wydawnictwo Ekonomiczne.
- Dobjija, M. (1997). *Rachunkowość zarządcza i kontroling*. Warszawa: Wydawnictwo Naukowe PWN.
- Dorosz, A. (red.). (2014). *Wpływ globalnego kryzysu finansowego na działalność wybranych sfer gospodarki*. Warszawa: Akademia Finansów i Biznesu Vistula.
- Kolony, K. (2021), *Stopy procentowe w Polsce już rosą. Tracą inwestujący w funduszach dłużnych*. Bankier. <https://www.bankier.pl/wiadomosc/Stopy-procentowe-w-Polsce-juz-rosna-8190752.html>
- Kołodko, G. W. (2010). *Globalizacja, kryzys i co dalej?* Warszawa: Wydawnictwo Poltext.

- Marcinek, K. (2001). *Ryzyko projektów inwestycyjnych*. Katowice: Wydawnictwo Akademii Ekonomicznej.
- Nowak, E. (red.). (1997). *Matematyka i statystyka finansowa*. Warszawa: Fundacja Rozwoju Rachunkowości w Polsce.
- Ostrowska, E.(2002). *Ryzyko projektów inwestycyjnych*, PWE, Warszawa.
- Przybycin, Z. (2011). Zarządzanie ryzykiem projektów inwestycyjnych. *Zeszyty Naukowe Wyższej Szkoły Bankowej we Wrocławiu*, 11, 351-361. http://62.3.168.81/Content/433/PDF/zn20wr_Przybycin.pdf
- Rogowski, W. (2004). *Rachunek efektywności przedsięwzięć inwestycyjnych*. Kraków: Oficyna Ekonomiczna.
- Taylor, M., Mankiw, G. (2009). *Makroekonomia*. Warszawa: PWE.

8. Badanie przyczynowości między stopami zmian cen metali szlachetnych a ich determinantami w obliczu procesów zachodzących we współczesnej gospodarce

(Katarzyna Zeug-Żebro)

8.1. Wprowadzenie

Metale szlachetne są przedmiotem licznych transakcji rynkowych. Odgrywają dużą rolę w różnych strategiach inwestycyjnych, jak również znajdują szerokie zastosowanie w przemyśle. Fundamentalny wpływ na ich cen mają z jednej strony relacje pomiędzy popytem a podażą (w związku z ich zastosowaniem), a z drugiej – z popytu inwestycyjnego zgłaszanego na te aktywa. Początek XXI wieku przyniósł znaczące zmiany na rynku surowców. Inwestorzy zaczęli traktować je jako alternatywne i bezpieczne aktywa inwestycyjne. Skutkiem tego coraz częściej w celu dywersyfikacji portfeli inwestycyjnych wykorzystuje się surowce i produkty na nich bazujące.

Oprócz wzmożonego zainteresowania inwestorów surowcami, w tym metalami szlachetnymi, można obserwować wzrost liczby publikacji naukowych, gdzie podkreśla się, że stanowią one bardzo zróżnicowaną grupę aktywów, których ceny determinowane są wieloma czynnikami (Bukowski, 2016; Kasprzak-Czelej, 2018; Krężołek, 2020; Mamcarz, 2015). Zauważono między innymi, że zwiększająca się liczba transakcji o charakterze spekulacyjnym ma związek ze wzrostem zmienności cen towarów oraz występowaniem nowych istotnych zależności cenowych. Wśród determinant wpływających na przykład na ceny złota i srebra, wymienia się między innymi kurs dolara wobec euro, stopę zwrotu z indeksu S&P 500 czy ropę naftową (Bukowski, 2016). Badania wykazały, że również czynniki o charakterze demograficznym, makroekonomicznym i politycznym wpływają na kształtowanie się cen towarów. Przyczyn zmienności cen surowców jest jednak wiele i bardzo trudno określić, które z nich mają największe znaczenie. Dlatego ważne jest badanie relacji przyczynowych między zmianami cen surowców a czynnikami wpływającymi na te zmiany.

Przedmiotem opracowania było testowanie przyczynowości pomiędzy cenami złota i srebra, wybranymi indeksami giełdowymi oraz kursami par walutowych. W tym celu zastosowano liniowy test Grangera [Granger, 1969] oraz nieparametryczny test Diksa i Panchenki [Diks, Panchenko, 2006], który można stosować do wykrywania zależności przyczynowych niekoniecznie liniowych.

W badaniach wykorzystano szeregi czasowe utworzone z cen zamknięcia wybranych walorów finansowych pozyskanych z portalu inwestycyjnego stooq.pl. Dane obejmowały okres od 1 stycznia 2018 do 31 grudnia 2021. Wszystkie obliczenia wykonano przy użyciu programów Gretl i GC² oraz pakietu Microsoft Excel.

8.2. Przyczyny zmian cen wybranych metali szlachetnych

Złoto i srebro przez wieki były i nadal pozostają najpopularniejszymi metalami szlachetnym. Historia wydobycia i wykorzystania tych metali do pewnego momentu była podobna. Zmiana nastąpiła, gdy srebro znalazło szerokie zastosowanie w przemyśle i stało się ważniejsze dla gospodarki. Złoto, mimo że również znajduje zastosowanie w przemyśle, w dużej mierze pozostaje jednak instrumentem inwestycyjnym, który zyskuje w czasach kryzysu i złej koniunktury.

Determinanty cen złota i srebra można podzielić na krótko- i długoterminowe. Pierwsze w dużej mierze wynikają z przyczyn o charakterze finansowym i sposobami inwestowania, a drugie odnoszą się głównie do czynników wpływających na ich popyt. Ceny złota w krótkim okresie pozostają pod wpływem fluktuacji cen surowców, spekulacyjnych zachowań inwestorów oraz krótkoterminowych wahań kursu walutowego dolara, inflacji i indeksów giełdowych, zmian związanych z oceną obligacji rządowych oraz zdarzeń o globalnym znaczeniu (Bukowski, 2016). Do czynników wpływających na cenę tego metalu w krótkim okresie zaliczyć można również zachowanie sektora publicznego na rynku złota, stóp procentowych i sezonowości (Mamcarz, 2015).


Do długoterminowych determinant cen złota można zaliczyć przebieg i prognozę cyklu koniunkturalnego, perspektywy wzrostu gospodarczego, długookresowe oczekiwania inflacyjne i dotyczące kursu walutowego, długoterminowe trendy stóp zwrotu z indeksów giełdowych i rentowności bonów skarbowych (Bukowski, 2016). W przypadku złota sytuacja w zakresie jego wydobycia wpływa na ceny zarówno w krótkim, jak i długim okresie.

Do głównych czynników wpływających na cenę srebra zaliczyć można popyt ze strony przemysłu oraz zapasy srebra w sektorze prywatnym jak również poziom oczekiwanej inflacji. W przypadku krótkiego okresu cenę srebra determinują informacje dotyczące stopnia wykorzystania mocy wytwórczych i stopy bezrobocia, wartości USD oraz zachowania inwestorów (Kasprzak-Czelej, 2018).

² http://research.economics.unsw.edu.au/vpanchenko/software/2006_GC_JEDC_c_and_exe_code.zip

8.3. Inwestowanie w metale szlachetne w okresie pandemii

Rozwój gospodarczy i technologiczny na świecie w dużej mierze przełożył się na wzrost ceny srebra i złota. Jak wspomniano wcześniej zastosowanie srebra w przemyśle spowodowało zwiększenie popytu na ten surowiec. Niestety w ostatnich latach cena tego metalu gwałtownie zaczęła maleć. W okresie pandemii w wielu krajach wprowadzono obostrzenia, w tym czasowe zamknięcie wielu przedsiębiorstw wykorzystujących srebro. Brak dostaw zarówno surowców, jak i gotowych produktów spowodował spadek ceny srebra. Ponadto inwestorzy w obawie przed recesją coraz częściej wybierali złoto, co spowodowało wzrost wartości tego kruszcu (rysunek 8.1).



Rys. 8.1. Notowania cen złota i srebra (\$/uncja) w okresie od 1 stycznia 2018 do 31 grudnia 2021

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stoq.pl> (17.04.2022).

Panika na światowych giełdach wywołana pandemią COVID-19 pogłębiła dysproporcję pomiędzy ceną złota i srebra. Wskaźnik Gold/Silver Ratio (stosunek ceny złota do ceny srebra; rysunek 8.2) pod koniec marca 2020 roku osiągnął niespotykany wcześniej poziom, tj. 1:124 (przed pandemią wskaźnik ten szacowany był na poziomie 1:90).



Rys. 8.2. Wskaźnik Gold/Silver Ratio w okresie od 1 stycznia 2018 do 31 grudnia 2021

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (17.04.2022).

Dodatkowo niepewność związana z rozwojem wydarzeń spowodowała odwrócenie się inwestorów od tańszego metalu. Sytuacja ta jednak uległa zmianie w momencie ponownego otwarcia rynków i uruchomienia nowych inwestycji na podratowanie gospodarki. Od tej chwili ceny obu kruszców zaczęły rosnąć, jednak cena srebra wzrastała szybciej, co spowodowało, że stosunek ceny złota do srebra zmalał i na początku sierpnia 2020 roku osiągnął poziom 1:70. W tym okresie cena złota osiągnęła historyczny rekord, tj. 2075 dolarów za uncję.

8.4. Przyczynowości w sensie Grangera

Przyczynowość w sensie Grangera (1969) zachodzi, gdy zmienna X jest przyczyną zmiennej Y , tzn. jeśli bieżące wartości Y można prognozować z większą dokładnością przy użyciu historycznych wartości X , przy niezmienionej pozostałej informacji (Charemza, Deadman, 1997). Oznacza to, że błąd prognozy wyznaczony dla zmiennej Y będzie mniejszy, jeżeli w modelu zostanie zawarta zmienna X , niż wtedy, gdy zostanie ona pominięta.

Definicja przyczynowości sformułowana przez Grangera dotyczy występowania zależności przyczynowych między stacjonarnymi procesami X_t i Y_t w kategorii warunkowych rozkładów prawdopodobieństwa. Według tej definicji X_t nie jest przyczyną Y_t , jeśli:

$$F\left(Y_t | \left(X_{t-l_x}, \dots, X_{t-1}; Y_{t-l_y}, \dots, Y_{t-1}\right)\right) = F\left(Y_t | \left(Y_{t-l_y}, \dots, Y_{t-1}\right)\right), \quad (1)$$

dla dowolnych opóźnień czasowych $l_x, l_y \geq 1$.

W sytuacji, gdy równanie (1) nie zachodzi, wtedy X_t jest przyczyną Y_t , co w szczególności daje możliwość wykorzystania wartości przeszłych X_t do prognozowania Y_t .

Badanie występowania zależności przyczynowych polega na weryfikacji hipotezy zerowej, iż X_t nie jest przyczyną Y_t , co na mocy definicji równoważne jest warunkowi (1). Jednak w praktyce ekonometrycznej weryfikację trudnego do zastosowania warunku (1) zastępuje się bardziej operacyjnymi metodami (Orzeszko, Osińska, 2007). Jedną z nich jest ograniczenie zakresu badania do identyfikacji zależności przyczynowych jedynie o charakterze liniowym. W takiej sytuacji badanie polega na zbudowaniu i analizie modelu VAR o jednakowej liczbie opóźnień dla obu zmiennych, k , i zastosowanie testu łącznej istotności opóźnień danej zmiennej w równaniu objaśniającym drugą zmienną:

$$y_t = \alpha_{10} + \sum_{j=1}^k \alpha_{1j} y_{t-j} + \sum_{j=1}^k \beta_{1j} x_{t-j} + \varepsilon_{1t}, \quad (2)$$

$$x_t = \alpha_{20} + \sum_{j=1}^k \alpha_{2j} x_{t-j} + \sum_{j=1}^k \beta_{2j} y_{t-j} + \varepsilon_{2t}. \quad (3)$$

W równaniu (2) hipoteza zerowa:

$$H_0: \beta_{11} = \beta_{12} = \dots = \beta_{1k} = 0 \quad (4)$$

oznacza brak zależności przyczynowej w sensie Grangera zmiennej X do Y .

Natomiast w przypadku równości (3) hipoteza zerowa:

$$H_0: \beta_{21} = \beta_{22} = \dots = \beta_{2k} = 0 \quad (5)$$

oznacza brak (liniowej) przyczynowości zmiennej Y do X .

Przyczynowość w sensie Grangera umożliwia badanie transmisji informacji między zmiennymi i identyfikację kierunków przepływu przyczynowości obserwowanych zmian (Orzeszko, Osińska, 2007).

8.5. Test zależności o charakterze nieliniowym

W 2005 roku Diks i Panchenko (2005) przedstawili tezę, że test Hiemstrya–Jonesa (1994) może odrzucać hipotezę o braku przyczynowości, nawet gdy liniowy test Grangera zdecydowanie na nią wskazuje. Przeprowadzone przez nich dalsze badania doprowadziły do korekty tej hipotezy.

Niech (X, Y, Z) oznacza wektor losowy postaci $(X, Y, Z) = (X_{t-l_x}^{t-1}, Y_{t-l_y}^{t-1}, Y_t)$, natomiast f funkcję gęstości prawdopodobieństwa. Diks i Panchenko (2006) udowodnili, że hipoteza zerowa, według której X_t nie jest przyczyną Y_t , oznacza, że spełniona jest równość:

$$\frac{f_{X,Y,Z}(x,y,z)}{f_Y(y)} = \frac{f_{X,Y}(x,y)}{f_Y(y)} \frac{f_{Y,Z}(y,z)}{f_Y(y)}. \quad (6)$$

Wskazali również, że równoważna kluczowej formule Hiemstry i Jonesa (1994), będącej punktem wyjścia w analizie przyczynowości o charakterze nie-liniowym, jest następująca równość:

$$\frac{E[f_{X,Y,Z}(x,y,z)]}{E[f_Y(y)]} = \frac{E[f_{X,Y}(x,y)]}{E[f_Y(y)]} \frac{E[f_{Y,Z}(y,z)]}{E[f_Y(y)]}, \quad (7)$$

gdzie:

$$E[f_W(w)] = \int f_W^2(s) ds, \quad (8)$$

jest interpretowana jako miara koncentracji wektora losowego W .

W swym opracowaniu wykazali, że aby badać przyczynowość nie należy skupiać się na równości (7) a badać następującą formułę:

$$E \left[\frac{f_{X,Y,Z}(x,y,z)}{f_Y(y)} - \frac{f_{X,Y}(x,y)}{f_Y(y)} \frac{f_{Y,Z}(y,z)}{f_Y(y)} \right] = 0. \quad (9)$$

Implikacją hipotezy zerowej jest zatem:

$$E \left[\left(\frac{f_{X,Y,Z}(x,y,z)}{f_Y(y)} - \frac{f_{X,Y}(x,y)}{f_Y(y)} \frac{f_{Y,Z}(y,z)}{f_Y(y)} \right) g(X, Y, Z) \right] = 0, \quad (10)$$

gdzie $g(X, Y, Z)$ jest dodatnią funkcją wagową. Przy założeniu prawdziwości hipotezy zerowej wyrażenie to zeruje się, gdyż na mocy wzoru (9) wartość w nawiasie okrągłym jest równa zero. Hipotezę zerową odrzucamy, gdy obliczona wartość statystyki testu jest zbyt wysoka. Dla $g(X, Y, Z) = f_Y^2(Y)$ wzór (10) przyjmuje postać:

$$E[f_{X,Y,Z}(x, y, z)f_Y(y) - f_{X,Y}(x, y)f_{Y,Z}(y, z)] = 0. \quad (11)$$

Jego estymator jest oparty na funkcji wskaźnikowej i wyraża się wzorem:

$$T_n = \frac{(2\varepsilon)^{-l_x - l_y - 1}}{n(n-1)(n-2)} \sum_i [\sum_{k,k \neq i} \sum_{j,j \neq i} (I_{ik}^{XYZ} I_{ij}^Y - I_{ik}^{XY} I_{ij}^{YZ})], \quad (12)$$

gdzie n jest liczbą obserwacji, $I(\cdot)$ jest funkcją wskaźnikową:

$$I_{i,j}^W = I(\|W_i - W_j\| \leq \varepsilon) = \begin{cases} 1, & \|W_i - W_j\| \leq \varepsilon \\ 0, & \|W_i - W_j\| > \varepsilon \end{cases}, \quad (13)$$

$\|\cdot\|$ oznacza normę supremum.

8.6. Analiza empiryczna przyczynowości w sensie Grengera

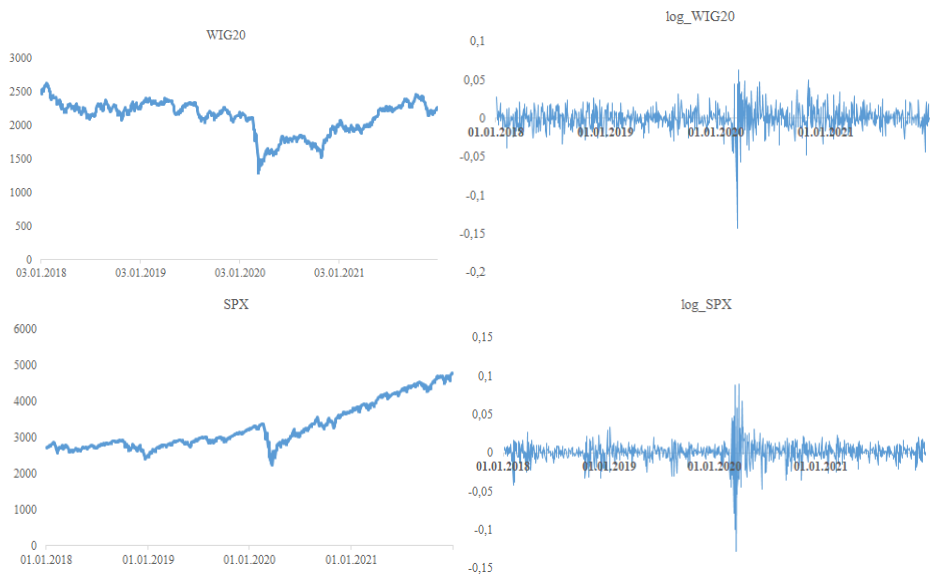
Wykorzystane w badaniach finansowe szeregi czasowe utworzono z cen zamknięcia:


- metali szlachetnych: złota (GC_F) i srebra (SI_F),
- indeksów giełdowych: WIG20 i S&P 500 (SPX),
- kursów par walutowych: EUR/USD i USD/PLN.

Dane obejmowały okres od stycznia 2018 do grudnia 2021 roku. Dni, dla których brakuje obserwacji jednej lub kilku zmiennych, zostały z próby usunięte. Źródłem danych był portal stooq.pl.

Wybór do analizy powyższych szeregów podyktowany był potwierdzonymi w literaturze przedmiotu powiązaniem przyczynowymi pomiędzy indeksami S&P500 a WIG20 oraz wybranymi funduszami surowcowymi (Krawiec, 2012; Misiuk, Zajkowska 2010). Nastroje inwestorów na rynkach kapitałowych, będące pochodną koniunktury gospodarczej, przyczyniają się do gwałtownych zmian na rynku złota. W tym przypadku chodzi o tzw. złoto przemysłowe, a nastroje inwestorów i stan gospodarki najlepiej odzwierciedlają indeksy giełdowe. Do analizy wybrano również kurs USD/EUR, gdyż jest zmienną oddziałującą na ceny metali szlachetnych, natomiast kurs USD/PLN jest wykorzystywany w formule wyznaczania wartości produktów strukturyzowanych. Kurs walutowy może służyć jako zmienna charakteryzująca otoczenie.

W pierwszym etapie badań, na podstawie wartości poszczególnych szeregów finansowych, wyznaczono ich logarytmiczne stopy zwrotu. Na rysunku 8.3 przedstawiono kształtowanie się cen analizowanych zmiennych i ich logarytmicznych przyrostów, dla których zostały wyznaczone wybrane statystyki opisowe.





Rys. 8.3. Kształtowanie się cen analizowanych walorów i ich logarytmicznych przyrostów w latach 2018-2021

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (8.04.2022).

Na podstawie charakterystyk przedstawionych w tabeli 8.1 można zauważyć, że dla czterech szeregów czasowych wartości kurtozy są wysokie, natomiast dla kursów par walutowych wartości te są zbliżone do 2. W pięciu przypadkach mamy do czynienia z asymetrią lewostronną (tylko szereg USD/PLN charakteryzuje się asymetrią prawostronną).

Tabela 8.1. Wybrane statystyki opisowe logarytmicznych przyrostów cen analizowanych walorów oszacowane dla całej próby

Szereg	Średnia	Mediana	Minimum	Maksimum	Odch.std	Skośność	Kurtoza
WIG20	-0,00009	-0,00030	-0,14246	0,06335	0,01425	-1,11690	12,48908
SPX	0,00058	0,00114	-0,12765	0,08968	0,01347	-1,06684	18,21546
GC_F	0,00033	0,00053	-0,05114	0,05775	0,00977	-0,24135	5,63480
SI_F	0,00030	0,00050	-0,12345	0,08896	0,01960	-0,81077	7,63552
USD/PLN	0,00017	0,00002	-0,02353	0,03463	0,00583	0,17667	1,99489
EUR/USD	-0,00006	-0,00006	-0,02484	0,01421	0,00411	-0,23991	1,77387

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (8.04.2022).

Następnie za pomocą testów Shapiro–Wilka i Jarque’a–Bery weryfikowano hipotezy dotyczące normalności rozkładu logarytmicznych przyrostów cen wszystkich analizowanych szeregów czasowych. Otrzymane wyniki zestawiono w tabeli 8.2, gdzie oprócz wartości statystyk podano wartości prawdopodobieństwa określanego jako krytyczny poziom istotności. We wszystkich przypadkach należy odrzucić hipotezę zerową, mówiącą, że rozpatrywane szeregi czasowe mogą być opisane rozkładem normalnym.

Tabela 8.2. Wyniki weryfikacji normalności rozkładu logarytmicznych przyrostów cen wybranych szeregów czasowych

Szereg	Statystyka			
	Shapiro–Wilka	wartość p	Jarque’a–Bery	wartość p
WIG20	0,9161	$8,62 \cdot 10^{-23}$	6454,31	0,00
SPX	0,8181	$9,15 \cdot 10^{-32}$	13489,1	0,00
GC_F	0,9258	$1,65 \cdot 10^{-21}$	1280,68	$8,02 \cdot 10^{-279}$
SI_F	0,8869	$4,58 \cdot 10^{-26}$	2441,91	0,00
USD/PLN	0,9846	$1,39 \cdot 10^{-8}$	163,745	$2,77 \cdot 10^{-36}$
EUR/USD	0,9875	$2,25 \cdot 10^{-18}$	134,687	$5,66 \cdot 10^{-3}$

Źródło Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (8.04.2022).

W kolejnym kroku weryfikowano stacjonarność badanych szeregów czasowych, wykorzystując rozszerzoną wersję testu Dickeya–Fullera – test ADF. Wyniki tego badania zamieszczono w tabeli 8.3. Na ich podstawie stwierdzono stacjonarność analizowanych szeregów czasowych. Wszystkie badane szeregi są I(1).

Tabela 8.3. Wyniki testu ADF dla logarytmicznych przyrostów cen wybranych szeregów czasowych

Szereg	Statystyka testu	Wartość p
WIG20	-1,20930	0,00
SPX	-5,95145	0,00
GC_F	-29,80200	0,00
SI_F	-20,83510	0,00
USD/PLN	-8,60898	0,00
EUR/USD	-9,41115	0,00

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (8.04.2022).

Następnie przeprowadzono test liniowy przyczynowości Grangera par zmiennych. W tym celu oszacowano równania modelu VAR o jednakowej liczbie opóźnień dla obu zmiennych i zastosowano test łącznej istotności opóźnień danej zmiennej w równaniu objaśniającym drugą zmienną.

W przypadku zmiennych niestacjonarnych wskazane jest wybranie optymalnej liczby k opóźnień modelu VAR, a następnie zwiększenie jej o liczbę równą rzędowi integracji zmiennych, d (Bauer, Maynard 2012; Toda, Yamamoto, 1995):

$$y_t = \alpha_{10} + \sum_{j=1}^{k+d} \alpha_{1j} y_{t-j} + \sum_{j=1}^{k+d} \beta_{1j} x_{t-j} + \varepsilon_{1t} \quad (14)$$

i weryfikowanie hipotezy zerowej (4) dla pierwotnej liczby opóźnień. Zgodnie z tą zasadą, wybiera się liczbę opóźnień na podstawie kryterium Akaikego (AIC), i zwiększa ją o 1 (czyli stopień integracji zmiennych).

Tabela 8.4 ilustruje wybór liczby opóźnień modelu VAR, dla całej próby, na podstawie kryterium Akaikego (AIC), bayesowskiego kryterium Schwarza (BIC), oraz Hannana–Quinna (HQC). Ich wartości wyznaczono dla 10 opóźnień, a optymalną liczbę opóźnienia dla każdego kryterium zapisano w nawiasie.

Tabela 8.4. Wybór liczby opóźnień modelu VAR dla par zmiennych

WIG20 i SPX			WIG20 i GC_F		
AIC	BIC	HQC	AIC	BIC	HQC
-11,98653 (9)	-11,82812 (2)	-11,91336 (9)	-12,10217 (6)	-12,03879 (1)	-12,06558 (2)
WIG20 i SI_F			WIG20 i USD/PLN		
AIC	BIC	HQC	AIC	BIC	HQC
-10,72813 (6)	-10,66374 (1)	-10,68969 (4)	-13,18616 (6)	-13,12969 (1)	-13,14848 (1)
WIG20 i EUR/USD			SPX i GC_F		
AIC	BIC	HQC	AIC	BIC	HQC
-13,83074 (1)	-13,80039 (1)	-13,81918 (1)	-12,36772 (9)	-12,22803 (2)	-12,22803 (7)
SPX i SI_F			SPX i USD/PLN		
AIC	BIC	HQC	AIC	BIC	HQC
-10,99987 (9)	-10,87151 (2)	-10,92669 (9)	-13,46989 (10)	-13,35236 (1)	-13,40501 (7)
SPX i EUR/USD			GC_F i SI_F		
AIC	BIC	HQC	AIC	BIC	HQC
-14,11709 (9)	-14,00938 (1)	-14,05273 (7)	-12,37922 (6)	-12,32199 (1)	-12,34078 (1)
GC_F i USD/PLN			GC_F i EUR/USD		
AIC	BIC	HQC	AIC	BIC	HQC
-13,99223 (3)	-13,94299 (1)	-13,96528 (3)	-14,71024 (6)	-14,67226 (1)	-14,69105 (1)
SI_F i USD/PLN			SI_F i EUR/USD		
AIC	BIC	HQC	AIC	BIC	HQC
-12,61007 (3)	-12,56416 (1)	-12,58639 (2)	-13,28105 (3)	-13,24918 (1)	-13,26797 (1)
USD/PLN i EUR/USD					
AIC	BIC	HQC			
-16,83266 (4)	-16,78207 (1)	-16,80872 (2)			

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (8.04.2022).

Analizując współzależności między zmianami stóp zwrotu na rynku akcji (indeksy giełdowe), na rynku walutowym (pary walutowe) i rynku surowców (metale szlachetne), przeprowadzono badania przy wykorzystaniu wszystkich wybranych zmiennych. Testy przyczynowości w sensie Grangera zrealizowano między parami tych zmiennych. Wyniki testu zawiera tabela 8.5, gdzie pogrubiona czcionka oznacza odrzucenie hipotezy o braku przyczynowości.

Tabela 8.5. Wyniki testu Grangera dla par zwrotów z instrumentów finansowych uzyskane dla całego analizowanego okresu

Przyczyna-skutek	Wartość testu	Przyczyna-skutek	Wartość testu
WIG20 SPX	6,3075 [0,0000]	SPX WIG20	7,3431 [0,0000]
WIG20 GC_F	1,2532 [0,2766]	GC_F WIG 20	5,5332 [0,0000]
WIG20 SI_F	0,49854 [0,8097]	SI_F WIG20	7,6209 [0,0000]
WIG20 USDPLN	1,9014 [0,0777]	USDPLN WIG20	5,8615 [0,0000]
WIG20 EURUSD	3,3426 [0,0678]	EURUSD WIG20	7,6714 [0,0057]
SPX GC_F	4,5285 [0,0000]	GC_F SPX	3,5832 [0,0002]
SPX SI_F	4,3291 [0,0000]	SI_F SPX	2,3888 [0,0112]
SPX USDPLN	3,2217 [0,0004]	USDPLN SPX	2,9121 [0,0013]
SPX EURUSD	3,5672 [0,0002]	EURUSD SPX	4,1008 [0,0000]
GC_F SI_F	3,5781 [0,0016]	SI_F GC_F	2,2272 [0,0385]
GC_F USDPLN	3,4102 [0,0171]	USDPLN GC_F	9,1989 [0,0000]
GC_F EURUSD	2,2905 [0,0335]	EURUSD GC_F	3,1218 [0,0049]
SI_F USDPLN	0,96282 [0,4096]	USDPLN SI_F	10,125 [0,0000]
SI_F EURUSD	0,83827 [0,4730]	EURUSD SI_F	7,6693 [0,0000]
USDPLN EURUSD	0,66604 [0,6157]	EURUSD USDPLN	6,4652 [0,0000]

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (8.04.2022).

W przeprowadzonej analizie wśród 30 par zmiennych, odnotowano dziewięć relacji dwukierunkowych oraz sześć relacji jednokierunkowych. Ponadto stwierdzono, że złoto jest w relacji dwukierunkowej z srebrem, indeksem S&P500 i kursami par walutowych oraz w relacji jednokierunkowej z indeksem giełdowym WIG20. Zauważono również, że zmiany cen wszystkich rozpatrywanych zmiennych są przyczyną zmian cen metali szlachetnych. Wynika z tego, że uwzględnienie w poszczególnych równaniach odpowiednich opóźnionych zmiennych pozwala lepiej wyjaśniać i przewidywać kształtowanie się badanych zjawisk.

8.7. Testowanie przyczynowości dla okresu przed pandemią i w okresie pandemii

Dla wszystkich zmiennych, w próbie obejmującej okres przed pandemią (1.01.2018-31.12.2019) oraz okres pandemii (1.01.2020-31.12.2021), zastosowano liniowy test Grangera oraz nieparametryczny test Diksa–Panchenko

(Syczewska, 2014). W obliczeniach związanych z testem Diksa–Panchenko przyjęto domyślną wartość 0,5. Otrzymane rezultaty przedstawiono w tabeli 8.6 (pogrubiona czcionka oznacza odrzucenie hipotezy o braku przyczynowości).

Tabela 8.6. Wyniki testu Grangera i Diksa–Panchenko dla par zwrotów z instrumentów finansowych dla okresu przed pandemią i w trakcie pandemii

Przyczyna- skutek	Granger		GC test	
	Wartość testu okres przed pandemią	Wartość testu okres pandemii	Wartość testu okres przed pandemią	Wartość testu okres pandemii
WIG20 SPX	14,223 [0,0000]	3,726 [0,0002]	0,632 [0,2636]	1,626 [0,1311]
SPX WIG20	2,108 [0,1226]	6,531 [0,0000]	0,688 [0,2456]	0,864 [0,0519]
WIG20 GC_F	2,622 [0,1060]	1,519 [0,1481]	-0,413 [0,6603]	0,496 [0,3100]
GC_F WIG 20	0,046 [0,8298]	5,189 [0,0000]	-0,447 [0,6727]	-0,015 [0,5058]
WIG20 SI_F	1,788 [0,1818]	1,155 [0,3299]	-0,081 [0,5321]	0,892 [0,1861]
SI_F WIG20	0,015 [0,9021]	9,439 [0,0000]	0,785 [0,2163]	0,546 [0,2926]
WIG20 USDPLN	18,119 [0,0000]	1,081 [0,3729]	-0,456 [0,6757]	1,122 [0,1309]
USDPLN WIG20	0,258 [0,6120]	5,983 [0,0000]	1,144 [0,1264]	1,053 [0,1461]
WIG20 EURUSD	12,300 [0,0005]	1,797 [0,0860]	-0,473 [0,6819]	0,312 [0,3775]
EURUSD WIG20	0,058 [0,8104]	2,893 [0,0057]	0,695 [0,2436]	-0,756 [0,7752]
SPX GC_F	4,865 [0,0279]	4,531 [0,0001]	0,851 [0,1973]	0,466 [0,3206]
GC_F SPX	1,077 [0,2999]	3,315 [0,0019]	0,088 [0,4649]	0,386 [0,3496]
SPX SI_F	5,731 [0,0035]	2,765 [0,0037]	0,387 [0,3492]	2,282 [0,0113]
SI_F SPX	0,809 [0,4458]	2,288 [0,0161]	-1,027 [0,8478]	1,307 [0,0957]
SPX USDPLN	3,936 [0,0478]	3,393 [0,0015]	-0,958 [0,8309]	-1,285 [0,9005]
USDPLN SPX	0,082 [0,7743]	4,150 [0,0002]	0,198 [0,4216]	0,321 [0,3739]
SPX EURUSD	1,751 [0,1863]	5,277 [0,0000]	-0,462 [0,6779]	-0,481 [0,6848]
EURUSD SPX	0,721 [0,3963]	5,636 [0,0000]	-0,030 [0,5121]	-0,077 [0,5307]
GC_F SI_F	0,660 [0,4168]	2,476 [0,0228]	0,109 [0,4568]	1,173 [0,1204]
SI_F GC_F	0,181 [0,6703]	1,955 [0,0707]	1,427 [0,0768]	1,881 [0,0300]
GC_F USDPLN	0,265 [0,6067]	4,922 [0,0022]	0,665 [0,2531]	-0,296 [0,6163]
USDPLN GC_F	3,483 [0,0626]	7,497 [0,0001]	-0,338 [0,6325]	0,686 [0,2463]
GC_F EURUSD	0,139 [0,7091]	4,685 [0,0010]	-0,877 [0,8098]	0,814 [0,2078]
EURUSD GC_F	2,758 [0,0974]	4,788 [0,0009]	-0,678 [0,7512]	0,735 [0,2312]
SI_F USDPLN	2,386 [0,1231]	1,657 [0,1754]	0,968 [0,1666]	1,480 [0,0694]
USDPLN SI_F	1,686 [0,1947]	9,095 [0,0000]	1,017 [0,1546]	1,616 [0,0531]
SI_F EURUSD	0,806 [0,3698]	1,651 [0,1769]	-0,018 [0,5071]	0,636 [0,2624]
EURUSD SI_F	0,696 [0,4048]	8,327 [0,0000]	-0,366 [0,6427]	0,355 [0,3613]
USDPLN EURUSD	0,025 [0,8741]	1,793 [0,1676]	0,535 [0,2963]	-0,609 [0,7288]
EURUSD USDPLN	1,278 [0,2588]	7,108 [0,0009]	0,103 [0,4588]	-1,005 [0,8427]

Źródło: Na podstawie danych statystycznych zaczerpniętych ze strony <https://stooq.pl> (8.04.2022).

Wyniki obu testów – liniowego testu Grangera oraz testu Diksa–Panchenko – okazały się bardziej zbliżone dla okresu przed pandemią niż w okresie pandemii. W okresie przed pandemią zależności przyczynowe były słabsze. Hipoteza zerowa o braku przyczynowości w tym czasie, dla testu Grangera została odrzucona tylko w przypadku sześciu par, natomiast dla testu Diksa–Panchenko nie

odnotowano żadnej relacji. W okresie pandemii (dla testu Grangera) dla większości przypadków odnotowano relacje przyczynowe, natomiast dla testu Diksa–Panchenko takie relacje obserwowano tylko w przypadku dwóch par, tj. indeksu S&P 500 i srebra oraz srebra i złota.

W przypadku metali szlachetnych (według testów Grangera), w okresie przed pandemią tylko zmiany ceny indeksu S&P 500 były przyczyną zmian ceny rozpatrywanych kruszców. Natomiast w okresie pandemii wpływ na zmianę cen złota i srebra miały ponownie zmiany ceny indeksu S&P 500 oraz pary walutowe USD/PL i EUR/USD.

8.8. Podsumowanie

Rynek złota i srebra jest wrażliwy na oddziaływanie wielu determinant rynkowych i pozarynkowych, które są krótko- lub długoterminowe. Jak wspomniano wcześniej można do nich zaliczyć popyt i podaż, koszty wydobycia, notowania niektórych surowców w tym ropy naftowej, wahania kursu walutowego dolara, kryzysy finansowe oraz te związane z globalnymi zdarzeniami (np. pandemia COVID-19). Do tych czynników można zaliczyć również nastroje inwestorów na rynkach kapitałowych i stan gospodarki, które najlepiej odzwierciedlają indeksy giełdowe. Ze względu na tak liczną grupę zmiennych mających wpływ na cenę złota i srebra, w opracowaniu skupiono się tylko na relacjach przyczynowych z indeksami giełdowymi WIG20 i S&P 500 oraz parami walutowymi USD/PL i EUR/USD. Badania przeprowadzono w pierwszej kolejności dla całego okresu tj. od stycznia 2018 do grudnia 2021, oraz w podziale na dwa podokresy tj. przed pandemią COVID-19 (01.2018-12.2019) i w trakcie pandemii (01.2020-12.2021). Dla całego przedziału czasowego zastosowano liniowy test Grangera, natomiast dla podokresów wykorzystano ponownie test Grangera oraz test Diksa–Panchenko.

Wyniki uzyskane w pierwszym badaniu, choć niejednoznaczne, ujawniły występowanie zależności przyczynowych w sensie Grangera. Oznacza to, że przyrosty cen poszczególnych metali mogą być lepiej prognozowane, gdy uwzględni się odpowiednio opóźnione przyrosty cen indeksów giełdowych WIG20 i S&P 500 oraz paramy walutowe USD/PL i EUR/USD

Ponowne przeprowadzenie analizy miało na celu zbadanie możliwości zmiany kierunku i siły powiązań przyczynowych w okresie przed pandemią COVID-19 oraz w trakcie pandemii. W okresie przed pandemią zależności przyczynowe wykazane przez test Grangera były słabsze, natomiast przeprowadzone testem Diksa–Panchenko nie wykazały żadnych relacji.

Literatura

- Bauer, D., Maynard, A. (2012). Persistence-robust surplus-lag Granger causality testing. *Journal of Econometrics*, 169, 293-300. <https://doi.org/10.1016/j.jeconom.2012.01.023>
- Bukowski, S. I. (2016). The main determinants of gold price in the international market. *International Business and Global Economy*, 35(1), 402-413.
- Charemza, W., Deadman, D. F. (1997). *Nowa ekonometria*. Warszawa: PWE.
- Diks, C., Panchenko, V. (2005). A note on Hiemstra-Jones test for Granger non-causality. *Studies in Nonlinear Dynamics and Econometrics*, 9(2), 4. http://research.economics.unsw.edu.au/vpanchenko/papers/2005_GC_SNDE.pdf
- Diks, C., Panchenko, V. (2006). A new statistics and practical guidelines for nonparametric Granger causality testing. *Journal of Economic Dynamics and Control*, 30(9/10), 1647-1669. <https://doi.org/10.1016/j.jedc.2005.08.008>
- Granger, C. W. J. (1969). Investigating casual relations by econometric models and cross-spectral methods. *Econometrica*, 37, 424-438. <https://www.jstor.org/stable/pdf/1912791.pdf>
- Hiemstra, C., Jones, J. D. (1994). Testing for linear and nonlinear Granger causality in the stock price volume relation. *Journal of Finance*, 49, 1639-1664. <https://doi.org/10.2307/2329266>
- Kasprzak-Czelej, A. (2018). Długookresowa zależność cen metali szlachetnych i ropy naftowej. *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, 370, 27-50. <https://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.cejsh-3fab8a20-41cb-461f-bedd-017640eab4ad>
- Krawiec, M. (2012). Testing the Granger causality for commodity mutual funds in Poland and commodity prices. *Quantitative Methods in Econometrics*, 13(2), 84-95. <https://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.desklight-cb0b94a2-93d6-43e8-b218-53df7fd65a99>
- Krężołek, D. (2020). *Modelowanie ryzyka na rynku metali*. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Mamcarz, K. (2015). Long-term determinants of the price of gold. *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, 252(4), 80-94. https://www.ue.katowice.pl/fileadmin/user_upload/wydawnictwo/SE_Artyku%C5%82y_251_270/SE_252/05.pdf
- Misiuk, A. B., Zająkowska, O. (2010). Does simultaneous investing on different stock markets allow to diversify risk? The cointegration analysis with main focus on Warsaw Stock Exchange. *Quantitative Methods of Economics*, 11, 118-127. <https://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.desklight-b62266ea-bcb6-4b3e-8e0c-0cf702cda143>
- Orzeszko, W., Osińska, M. (2007). Analiza przyczynowości w zakresie zależności nieliniowych. Implikacje finansowe. *Zeszyty Naukowe Uniwersytetu Szczecińskiego. Finanse, Rynki Finansowe, Ubezpieczenia*, 6(1): Rynek kapitałowy: skuteczne inwestowanie), 151-165. http://wneiz.umk.pl/_upload/1/Orzeszko_Osi%C5%84ska.pdf

- Syczewska, E. M. (2014). Przyczynowość w sensie Grangera – wybrane metody. *Metody ilościowe w badaniach ekonomicznych*, 15(4), 169-180. <https://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.desklight-3a34747c-1e49-4676-a683-3419fa3027cd>
- Toda, H. Y., Yamamoto, T. (1995). Statistical inference in vector autoregressions with possibly integrated processes. *Journal of Econometrics*, 66, 225-250. [https://doi.org/10.1016/0304-4076\(94\)01616-8](https://doi.org/10.1016/0304-4076(94)01616-8)

9. Analiza szeregów czasowych kontraktów terminowych na miedź przy wykorzystaniu modelu ARIMA i GARCH z uwzględnieniem wpływu pandemii COVID-19 na wycenę surowców

(Łukasz Sroka)

9.1. Wprowadzenie

Strach przed skutkami epidemii jest jednym z czynników wpływających na decyzje podejmowane na rynku zarówno od strony popytowej, jak i podażowej. Po stronie popytowej epidemia powoduje spadek wydatków konsumpcyjnych. Ludzie chorzy oraz przebywający na kwarantannie zostają w domach zamiast podróżować, odwiedzać centra handlowe, restauracje, kina czy teatry. Takie zachowanie konsumentów oznacza, że branża turystyczna, transportowa, produkcyjna oraz rozrywkowa bardzo silnie odczuwają brak popytu na swoje dobra i usługi (Jakóbiak, 2020). Choroba wywołana wirusem bądź bakterią wpływa również na gospodarkę światową ograniczając podaż. Dzieje się tak, ponieważ pandemia redukuje liczbę pracowników zdolnych do pracy, co znacząco wpływa na podaż siły roboczej. Ponadto wiele sektorów gospodarki światowej doświadcza zakłóceń w łańcuchach dostaw, co prowadzi do niedoborów surowców oraz materiałów na rynku (Sieroń, 2021).

Zakłócenia, które dotknęły światowe giełdy w 2020 roku wpłynęły również na wycenę surowców przemysłowych. Większość surowców zaczęło gwałtownie tanieć w okresie od stycznia do maja 2020. Za przykład może posłużyć cynk, którego cena pod koniec stycznia 2020 roku wynosiła 2428 dolarów za tonę, by już w marcu spaść do poziomu 1815 dolarów za tonę, czyli o ponad 25%. Po osiągnięciu marcowego minimum cenowego dla większości surowców przemysłowych rozpoczął się okres wzrostu cen. Na koniec grudnia 2020 roku za tonę cynku należało zapłacić 2700 dolarów, co stanowiło wzrost ceny o ponad 48% w porównaniu do marcowego dołka oraz wzrost o ponad 11% w porównaniu do stycznia 2020 roku.

Silne wahania cen surowców przemysłowych w znacznym stopniu wpływają na decyzje podejmowane przez przedsiębiorstwa dotyczące wielkości produkcji oraz zapasów. Aby móc podejmować skuteczne decyzje biznesowe, przedsiębiorstwo musi dokonać rewizji zarówno prognoz, jak również modeli ekonometrycznych wykorzystanych do ich stawiania. W związku z wyzwaniem, jakie stoją przed przedsiębiorstwem w obszarze prognostycznym, za cel

niniejszego rozdziału postawiono przygotowanie prognoz cen kontraktów terminowych na miedź na trzy okresy. Dane, które wybrano do analizy, podzielono na dwa podzbiór. Pierwszy podzbiór cen zawierał obserwacje, na które wpływ epidemii COVID-19 jest widoczny, natomiast w skład drugiego podzbioru wchodziły ceny bez istotnego wpływu pandemii. Analiza cen kontraktów terminowych została przygotowana przy użyciu modelu ARIMA oraz modelu GARCH.

Chcąc zrealizować postawiony cel, za metodę badawczą przyjęto analizę ekonometryczną wraz z weryfikacją hipotez statystycznych z wykorzystaniem danych dla dwóch szeregów czasowych kontraktów terminowych na miedź. Przyjęto, że w pierwszym szeregu czasowym obejmującym zakres dat od stycznia 2017 do marca 2020 wpływ pandemii na ceny kontraktów terminowych na miedź nie występuje, natomiast w drugim szeregu z zakresem danych od czerwca 2018 do czerwca 2021³ wpływ pandemii na ceny kontraktów jest widoczny. Modele ekonometryczne wykorzystane w rozdziale zostały przygotowane przy użyciu języka programowania Python wraz z następującymi bibliotekami: pandas, matplotlib, seaborn, numpy oraz statsmodels.

9.2. Model ARIMA

Model ARIMA należy do klasy efektywnych metod prognozowania szeregów czasowych. Model ten, tak samo jak modele autoregresji oraz średniej ruchomej, zapoczątkowany został przez Boxa i Jenkinsa (1983). Nazwa ARIMA to skrót od Auto Regressive Integrated Moving Average model, czyli autoregresyjny zintegrowany model średniej ruchomej. ARIMA składa się z trzech elementów składowych, do których zalicza się (Dąsał, Popławski, 2008; Ganczarek-Gamrot, 2014):

1. Proces autoregresyjny AR (ang. *autoregressive*).
2. Proces średniej ruchomej MA (ang. *moving averages*).
3. Stopień integracji I (ang. *integrated*).

Budowa modelu ARIMA opiera się na zjawisku autokorelacji, gdzie wartość parametru dotyczącego stopnia integracji większa od 0 wskazuje, że szereg czasowy został poddany operacji różnicowania (Chrabołowska, Nazarko, 2003). Do zapisu postaci modelu ARIMA stosuje się uniwersalne notacje określające rząd poszczególnych składowych modelu, czyli: p – rząd autoregresji, d – różnicowanie, q – rząd średniej ruchomej. Proces Y_t ARIMA (p,d,q) może zostać zapisany (Box, Jenkins, 1983):

³ Dane zaczerpnięte ze strony <https://www.investing.com/>

$$\nabla^d Y_t = \mu + \sum_{i=1}^p \phi_i \nabla^d Y_{t-1} + \varepsilon_t - \sum_{j=1}^q \theta_j \varepsilon_{t-j}, \quad (1)$$

gdzie:

μ, ϕ_i, θ_j – parametry modelu,

$\varepsilon_t \sim N(0, \sigma)$ – biały szum,

p – rząd modelu części autoregresyjnej,

q – rząd modelu części średniej ruchomej.

Analiza szeregu czasowego z wykorzystaniem modelu ARIMA składa się z trzech głównych etapów, do których zalicza się: identyfikację, estymację oraz diagnozę. Etap identyfikacji polega na rozpoznaniu liczby oraz typów parametrów modelu ARIMA, które następnie należy oszacować. W celu dokonania identyfikacji składowych modelu analizuje się wykres szeregu czasowego oraz oblicza rząd autokorelacji badanego szeregu. Jednym z warunków procesu identyfikacji modelu ARIMA jest stacjonarność wejściowego szeregu czasowego. Za stacjonarność szeregu czasowego w modelu odpowiada parametr d . Aby określić, czy dany szereg czasowy jest szeregiem stacjonarnym wykorzystuje się test pierwiastka jednostkowego Augmented Dickey–Fuller (ADF) bądź analizę korelogramów (Miłek, 2017).

Test ADF stosuje się, gdy szereg czasowy wykazuje trend oraz autokorelację reszt. W teście tym należy w odpowiedni sposób określić rząd r wykorzystując w tym celu funkcje ACF oraz PACF (Ganczarek-Gamrot, 2014).

Funkcja ACF (ang. *autocorrelation function*) zdefiniowana jest jako korelacja między wartościami szeregu czasowego oddalonymi o k przedziałów od siebie. Może być ona zapisana w następujący sposób: $ACF = \text{corr}(X_t, X_{t+k})$. Funkcja autokorelacji cząstkowej (ang. *Partial Auto-Correlation function* – PACF) określona jest natomiast jako korelacja między wartościami szeregu oddalonymi o k przedziałów od siebie, z jednoczesną rejestracją wartości z przedziałów znajdujących się pomiędzy (Guha, Bandyopadhyay, 2016).

Następnym etapem budowania modelu ARIMA jest estymacja jego parametrów. Aby oszacować parametr procesu AR należy wykorzystać metodę najmniejszych kwadratów. Metoda ta polega na znalezieniu najmniejszej sumy kwadratów reszt wartości parametrów modelu. Ze względu na nieobserwowalny charakter zmiennych objaśniających przy estymacji procesu MA zalecane jest wykorzystanie metody największej wiarygodności do określenia odpowiedniej wartości parametru q (Malska, Wachta, 2015).

Estymacja parametrów pozwala na wytypowanie kilku różnych modeli ARIMA o różnych wartościach parametrów p, d oraz q . W celu wyboru modelu najlepiej dostosowanego do danego szeregu czasowego wykorzystuje się kryterium informacyjne Akaikego (AIC). Kryterium to służy do wyselekcjonowania optymalnego modelu ARIMA. Celem wyboru modelu według kryterium AIC

jest oszacowanie straty informacji. Zgodnie z podejściem zaproponowanym przez Akaikego najlepszym modelem ze zbioru modeli-kandydatów jest ten, którego wartości kryterium AIC oznaczającego stratę informacji jest najmniejsza (Piłatowska, 2009). Kryterium informacyjne ma następującą postać (Piłatowska, 2011):

$$AIC = -2\ln L(\hat{\theta}) + 2K, \quad (2)$$

gdzie $L(\hat{\theta})$ oznacza funkcję wiarygodności dla danego modelu, która jest korygowana funkcją straty.

Wybrany model wraz z oszacowanymi parametrami zostaje w kolejnym kroku sprawdzony diagnostycznie. Podstawą diagnostyki jest analiza własności reszt modelu. Jeżeli reszty modelu są procesem białego szumu i nie występują znaczące odchylenia wartości funkcji ACF oraz PACF dla szeregu reszt modelu, to model może zostać zastosowany w celach prognostycznych. W przypadku występowania istotnych odchyżeń szeregu reszt należy wrócić do poprzedniego etapu związanego z wyborem parametrów modelu i przeanalizować model ARIMA o innej specyfikacji parametrów (Nazarko i in., 2004).

Ostatnim etapem jest wykorzystanie przygotowanego modelu do postawienia prognoz na n okresów wraz ze sprawdzeniem błędów otrzymanych predykcji. Do obliczenia błędów prognoz można wykorzystać błąd średniokwadratowy (ang. *Mean Squer Error* – MSE), lub jego pierwiastek, czyli średniej kwadratowej błędu (ang. *Root Mean Square Error* – RMSE).

Błąd MSE stosuje się w przypadku występowania wartości odstających prognoz. Statystyka ta w zadowalający sposób pozwala na określenie jakości postawionych przez model prognoz. Im mniejszy współczynnik MSE dla tym jakość prognoz jest lepsza.

Błąd RMSE jest definiowany jako pierwiastek błędu średniokwadratowego. Współczynnik ten pokazuje o ile prognozy wygłasze średnio rzecz biorąc różnią się od rzeczywistych wartości współczynnika RMSE.

9.3. Model GARCH

Model GARCH (ang. *Generalized Auto Regressive Conditional Heteroskedasticity Model*) jest uogólnioną wersją modelu ARCH. Ze względu na swoją prostotę jest jednym z najczęściej wykorzystywanych modeli do analizy szeregów czasowych (Doman, 2004).

Jednym z zastosowań modelu GARCH jest opis i prognozowanie zmienności rozumianej jako miara niepewności co do przyszłych stóp zwrotu instrumentu finansowego. W przypadku modelu GARCH za miarę niepewności przyjmuje się warunkową wariancję bądź warunkowe odchylenie standardowe. Model GARCH (p,q) szeregu ε_t można zapisać jako (Fiszeder, 2001):

$$\begin{aligned} \varepsilon_t | \psi_{t-1} &\sim N(0, h_t), \\ h_t &= \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}, \\ \varepsilon_t &= \sqrt{h_t} \xi_t \end{aligned} \tag{3}$$

gdzie:

ψ_{t-1} – zbiór wszystkich informacji dostępnych w okresie $t - 1$,
 $N(0, h_t)$ – rozkład normalny wartości oczekiwanej zero i wariancji h_t ,
 ξ_t – biały szum o standardowym rozkładzie normalnym,
 $\alpha_0, \alpha_i, \beta_j$ – parametry modelu.

Aby proces GARCH (p, q) był procesem stacjonarnym w szerszym sensie, następujące warunki muszą pozostać spełnione (Nelson, Cao, 1992; Fiszeder 2001):

$$\alpha_0 > 0, \alpha_i \geq 0 \text{ oraz } \beta_j \geq 0, \tag{4}$$

a także:

$$\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j < 1. \tag{5}$$

Badania empiryczne wykazują, że model GARCH znacznie lepiej wyjaśnia zmienność wariancji warunkowej niż inne modele. Wprowadzenie do modelu wariancji z poprzednich okresów umożliwia uzależnienie bieżącej zmienności procesu od całej jego przeszłości w sposób oszczędnie sparametryzowany (Fiszeder, 2001).

Model GARCH uwzględnia zarówno zjawisko skupiania się wariancja, jak i grube ogony empirycznych rozkładów. Jako wadę modelu można wymienić brak modelowania efektu dźwigni. Związane jest to z tym, że warunkowa wariancja uzależniona jest wyłącznie od modularnych wartości z okresów poprzednich, nie uwzględniając asymetrycznego wpływu dobrych i złych informacji na zakres realizacji stóp zwrotu (Krężolek, 2020).

Jednym z warunków wykorzystania modelu typu GARCH jest sprawdzenie występowania efektu ARCH, czyli heteroskedastyczności wariancji w analizowanym szeregu czasowym. Aby zweryfikować hipotezę zerową, mówiącą o tym, że efekt ARCH rzędu p dla danych nie występuje wykorzystuje się test Engela. Statystyka testująca, przy prawdziwości hipotezy zerowej, posiada rozkład χ^2 o p stopniach swobody (Krężolek, 2020). W przypadku odrzucenia hipotezy zerowej możliwe jest zastosowanie modelu GARCH do analizy danego szeregu czasowego.

9.4. Wyniki badania

Jak zaprezentowano w części teoretycznej, model ARIMA oraz model GARCH są modelami stosowanymi do analizy oraz prognozowania wartości szeregów czasowych. W celu przeprowadzenia badania porównawczego dwóch

szeregów czasowych pozyskano ceny zamknięcia kontraktów terminowych na miedź za okres od stycznia 2017 do marca 2020 roku (zwany dalej szeregiem I) oraz od czerwca 2018 do czerwca 2021 roku (zwany dalej szeregiem II). Ceny kontraktów terminowych wykorzystano do estymacji modelu ARIMA oraz do postawienia prognoz na trzy kolejne okresy. Przy wykorzystaniu obserwowanych cen obliczono również logarytmiczne stopy zwrotu, które użyte zostały do przygotowania modelu GARCH. Wartości kontraktów terminowych wyrażone są w dolarach za funt surowca. Podział szeregu czasowego cen kontraktów terminowych na dwa podszeregi wynika z celów postawionych w niniejszym opracowaniu. Aby dane były jak najbardziej aktualne, postanowiono, że najstarsze ceny kontraktów będą pochodzić z 2017 roku. Szereg czasowy podzielono na dwa podobnej długości podszeregi czasowe. Szereg I zawiera dane pozbawione wpływu pandemii na cenę surowca, natomiast w szeregu II wpływ światowej pandemii na ceny surowca jest obecny.

9.4.1. Analiza szeregów czasowych

Tabele 9.1 i 9.2 przedstawiają podstawowe statystyki opisowe dla analizowanych szeregów czasowych.

Tabela 9.1. Statystyki opisowe – dzienne ceny kontraktów terminowych na miedź (USD/funt)

Szereg czasowy	Średnia arytmetyczna	Odchylenie standardowe	Minimum	Maksimum	Skośność	Kurtoza
Szereg I	2,89	0,22	2,51	3,42	0,66	-0,78
Szereg II	3,03	0,55	2,31	4,76	1,47	1,45

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Tabela 9.2. Statystyki opisowe – dzienne stopy zwrotu dla kontraktów terminowych na miedź (USD/funt)


Szereg czasowy	Średnia arytmetyczna	Odchylenie standardowe	Minimum	Maksimum	Skośność	Kurtoza
Szereg I	0,0025%	1,10%	-4,54%	3,95%	-0,09	1,42
Szereg II	0,0036%	1,13%	-7,01%	4,25%	-0,41	2,24

Źródło: Opracowanie w programie Python. na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Analizując statystyki cen badanych szeregów czasowych można zauważyć, że szereg II cechuje się wyższą o 4,48% średnią wartością ceny w porównaniu do szeregu I. Ponadto szereg II charakteryzuje się większą zmiennością w badanym okresie. Analizując wartości maksymalne oraz minimalne cen, można stwierdzić, że najniższa i najwyższa cena za kontrakt terminowy na miedź wy-


stępuje dla szeregu II, przy czym cena maksymalna dla tego szeregu jest o 39,18% wyższa, a cena minimalna o 7,79% niższa niż dla szeregu I. Taka różnica może być wynikiem wpływu epidemii na ceny w szeregu II. Dodatkowo dla obu szeregów występuje prawostronnie skośny rozkład cen, a szereg I cechuje się ujemną kurtozą, a więc rozkładem platykurtycznym. Świadczy to o bardziej spłaszczonym rozkładzie cen względem rozkładu normalnego, a także o jego węższych ogonach. Z kolei szereg II posiada rozkład leptokurtyczny, czyli bardziej smukły niż rozkład normalny.

Średnia arytmetyczna dla logarytmicznych stóp zwrotu dla obu szeregów jest dodatnia. Tak samo jak w przypadku cen kontraktów terminowych, tak i w przypadku stóp zwrotu cen miedzi większa zmienność występowała dla szeregu II. W analizowanym okresie odchylenie standardowe stóp zwrotu było o 2,73% większe niż dla szeregu I. Minimalna stopa zwrotu dla obu szeregów jest ujemna, przy czym szereg II cechuje się najniższą osiągniętą stopą zwrotu. Najwyższą jednostkową stopę zwrotu, podobnie jak w przypadku cen na kontrakty terminowe, odnotowano w szeregu II. Oba szeregi charakteryzują się ujemną skośnością oraz dodatnią kurtozą. Oznacza to, że stopy zwrotu analizowanych cen posiadają asymetryczny (lewostronny) leptokurtyczny rozkład. Warto zauważyć, że takie wartości kurtozy oznaczają grubsze ogony rozkładu. Na rysunkach 9.1 oraz 9.2 przedstawiono empiryczne szeregi czasowe dla procesów cen i stóp zwrotu badanych okresów.



Rys. 9.1. Szereg czasowy cen (górnny) oraz stóp zwrotu (dolny) dla kontraktów terminowych na miedź dla szeregu I

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>



Rys. 9.2. Szereg czasowy cen (górny) oraz stóp zwrotu (dolny) dla kontraktów terminowych na miedź dla szeregu II

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Analizując powyższe wykresy można zauważyć, że wykres cen kontraktów terminowych na miedź szeregu I charakteryzuje się trendem wzrostowym między rokiem 2017 a drugą połową roku 2018, następnie ceny kontraktów terminowych zaczynają spadać. Z kolei szereg II do kwietnia 2020 roku wykazuje tendencje boczną, z wyraźnym nagłym spadkiem cen w okresie od stycznia do marca 2020 roku. Po zanotowaniu minimum cenowego w kwietniu 2020 roku zauważyć można wyraźny trend wzrostowy utrzymujący się do końca czerwca 2021 roku. Występowanie trendów w obu szeregach czasowych może świadczyć o braku ich stacjonarności.

Dla szeregów czasowych stóp zwrotu można zaobserwować skupienie się zmienności w pewnych okresach. Występują miesiące, kiedy stopy zwrotu dla obu szeregów są wyraźnie wyższe oraz miesiące, kiedy są na stosunkowo niskim poziomie. Taka zmienność może świadczyć o rozbieżności empirycznych rozkładów stóp zwrotu z rozkładem normalnym. Celem weryfikacji, czy dane szeregi czasowe charakteryzują się rozkładem normalnym, przeprowadzono weryfikację statystyczną zaprezentowaną w tabeli 9.3.

Tabela 9.3. Testy rozkładu normalnego cen oraz stóp zwrotu kontraktów na miedź

Analizowana zmienna	Kolmogorow–Smirnow		Jarque–Bera	
	KS	istotność	JB	istotność
Szereg I – cena	0,994	<0,000***	80,57	<0,000***
Szereg I – stopa zwrotu	0,484	<0,000***	67,98	<0,000***
Szereg II – cena	0,984	<0,000***	361,45	<0,000***
Szereg II – stopa zwrotu	0,483	<0,000***	188,36	<0,000***

*** Statystyczna istotność na poziomie 0,01.

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

W testach analizujących zgodność rozkładów zmiennych z rozkładem normalnym hipoteza zerowa mówi o tym, że empiryczne rozkłady prawdopodobieństwa realizacji cen/stóp zwrotu dla analizowanych okresów są zgodne z rozkładem normalnym o zadanych parametrach, wobec hipotezy alternatywnej według której rozkłady te różnią się istotnie, statystycznie od rozkładu normalnego. Wyniki przeprowadzonych testów wskazują, że na dowolnym poziomie istotności hipoteza zerowa zostaje odrzucona. Można więc stwierdzić, że empiryczne rozkłady cen oraz stóp zwrotu nie są zbieżne z rozkładem Gaussa. Potwierdzeniem tych wyników są także miary skośności oraz kurtozy dla analizowanych zmiennych.

Aby móc wykorzystać model ARIMA oraz model GARCH, należy w kolejnym kroku sprawdzić stacjonarność szeregów czasowych testem ADF. Tabela 9.4 przedstawia wyniki testu ADF dla cen i stóp zwrotu kontraktów terminowych na miedź dla obydwu okresów.

Tabela 9.4. Testy stacjonarności ADF cen oraz stóp zwrotu kontraktów na miedź

Analizowana zmienna	Test ADF	
	ADF	istotność
Szereg I – cena	-1,94	0,32
Szereg I – stopa zwrotu	-30,37	<0,000***
Szereg II – cena	0,05	0,96
Szereg II – stopa zwrotu	-30,45	<0,000***

*** Statystyczna istotność na poziomie 0,01.

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Hipoteza zerowa w teście ADF zakłada, że proces stochastyczny jest zintegrowany rzędu pierwszego wobec hipotezy alternatywnej, że proces ten nie jest zintegrowany. Jeżeli szereg jest zintegrowany, wówczas szereg określa się jako niestacjonarny. Analizując wyniki cen oraz stóp zwrotu dla obu okresów można zauważyć, że dla stóp zwrotu wartość statystyki ADF sugeruje odrzucenie hipotezy zerowej na rzecz hipotezy alternatywnej. Oznacza to, że proces stóp zwrotu dla analizowanych okresów jest stacjonarny. Przeciwne wnioski można wyciągnąć

analizując ceny kontraktów terminowych. Zgodnie z wynikami testu ADF nie ma podstaw do odrzucenia hipotezy zerowej na przyjętym poziomie istotności 0,01 – szeregi czasowe cen kontraktów terminowych na miedź nie są stacjonarne.

Wyniki testu oznaczają, że na przyjętym poziomie istotności możliwe jest wykorzystanie modeli szeregów czasowych z grupy modeli stacjonarnych dla analizowanych stóp zwrotu, natomiast dla cen kontraktów terminowych słuszne będzie wykorzystanie modelu ARIMA, czyli modelu uwzględniającego niestacjonarność szeregu czasowego.

9.4.2. Model ARIMA

Jak wykazano w poprzedniej części pracy, szeregi czasowe cen kontraktów terminowych na miedź obydwu podszeregów cechują się brakiem stacjonarności. Aby uzyskać stacjonarność i określić parametr d dla modelu, obliczono pierwsze różnice cen kontraktów na miedź dla analizowanych szeregów i ponownie przeprowadzono test ADF. Tabela 9.5 przedstawia wyniki testu ADF dla pierwszych różnic cen.

Tabela 9.5. Testy stacjonarności ADF pierwszych różnic cen kontraktów na miedź

Analizowana zmienna	Test ADF	
	ADF	istotność
Szereg I – cena	-11,66	<0,000***
Szereg II – cena	-10,15	<0,000***

*** Statystyczna istotność na poziomie 0,01.

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Analizując wyniki ponownego testu ADF dla pierwszych różnic cen kontraktów terminowych na miedź zauważyć można, że zarówno szereg I, jak i szereg II okazały się szeregami stacjonarnymi. Oznacza to, że parametr d modelu ARIMA powinien zostać ustawiony na 1.

W celu sprawdzenia parametrów modelu ARIMA dla szeregu I oraz szeregu II wykorzystano kryterium informacyjne Akaikego oraz informacje pozyskane z testu stacjonarności. Do wybrania optymalnych parametrów p i q wykorzystano algorytm z biblioteki `auto.arima` dostępnej w Pythonie. Biblioteka ta pozwoliła na automatyczne porównanie modelu ARIMA pod kątem kryterium Akaikego z różnymi kombinacjami parametru p oraz q . W badaniu przyjęto, że maksymalna wartość parametrów p i q może wynieść 10. Tabela 9.6 przedstawia wyniki kryterium informacyjnego AIC dla najlepszych kombinacji parametrów modelu ARIMA ze względu na kryterium informacyjne Akaikego.

Tabela 9.6. Kryterium informacyjne warunkujące wybór modelu ARIMA dla cen kontraktów terminowych na miedź

Model	AIC	
	szereg I	szereg II
ARIMA(1,1,1)	-3305,63	-2887,37
ARIMA(2,1,1)	-3304,72	-2887,35
ARIMA(1,1,0)	-3307,56	-2888,90
ARIMA(0,1,1)	-3307,61	-2888,98
ARIMA(1,1,2)	-3304,42	-2885,85
ARIMA(0,1,0)	-3306,71	-2890,06

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>


Analizując tabelę 9.6 można zauważyć, że dla szeregu I najlepszym modelem jest model ARIMA(0,1,1), natomiast dla szeregu II model ARIMA(0,1,0). Dla takich parametrów modelu utrata informacyjna mierzona kryterium Akaikego jest najmniejsza. Oszacowane wagi dla modelu ARIMA(0,1,1) szeregu I oraz ARIMA(0,1,0) szeregu II znajdują się w tabeli 9.7.

Tabela 9.7. Oszacowania parametrów modelu ARIMA dla cen kontraktów terminowych na miedź

Model	Parametr	Współczynnik	Błąd standardowy	Istotność
ARIMA(0,1,1) szereg I	MA	-0,06	0,04	0,087**
ARIMA(0,1,0) szereg II	sigma	0,001	0,000	0,005***


Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Jak zaprezentowano w tabeli 9.7 oszacowane, parametry modelu ARIMA(0,1,1) oraz ARIMA(0,1,0) są statystycznie istotne. Na rysunkach 9.3 i 9.4 przedstawiono graficzną prezentację reszt modeli dla szeregu I i II.



Rys. 9.3. Reszty dla modelu ARIMA(0,1,1) (wykres po lewej) wraz z ich rozkładem empirycznym (wykres po prawej) dla szeregu I


Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>



Rys. 9.4. Reszty dla modelu ARIMA(0,1,0) (wykres po lewej) wraz z ich rozkładem empirycznym (wykres po prawej) dla szeregu II


Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Reszty modelu ARIMA(0,1,1) oraz ARIMA(0,1,0) oscylują wokół średniej równej zero oraz mają stałą wariancję. Ponadto histogram reszt zbliżony jest do rozkładu normalnego. Sprawdzono również korelogram funkcji ACF i PACF dla dziesięciu opóźnień. Wykres dla szeregu I oraz szeregu II przedstawiają rysunki 9.5 oraz 9.6.



Rys. 9.5. Funkcja ACF i PACF reszt modelu ARIMA(0,1,1) dla szeregu I

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>



Rys. 9.6. Funkcja ACF i PACF reszt modelu ARIMA(0,1,0) dla okresu II

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Korelogram ACF oraz PACF modelu ARIMA(0,1,1) oraz ARIMA(0,1,0) przedstawiają, że nie występuje korelacja reszt modelu. Na podstawie powyższych analiz można stwierdzić, że model ARIMA(0,1,1) oraz ARIMA(0,1,0) są modelami prawidłowymi dla szeregu I oraz II i mogą zostać wykorzystane do celów prognostycznych.

Ostatnim etapem analizy jest postawienie prognoz dla trzech kolejnych okresów oraz sprawdzenie błędów uzyskanych predykcji. Tabela 9.8 przedstawia prognozy dla trzech kolejnych dni dla szeregu I oraz szeregu II wraz z ich rzeczywistymi realizacjami oraz błędami.

Tabela 9.8. Prognozy wraz z ich realizacjami oraz błędami modelu ARIMA (0,1,1) oraz ARIMA(0,1,0) dla szeregu I oraz szeregu II

Modele	Nr	Prognoza USD/funt	Realizacja USD/funt	Błąd %
ARIMA(0,1,1) szereg I	1	2,583	2,646	-2,38%
	2	2,584	2,613	-1,11%
	3	2,584	2,625	-1,56%
ARIMA(0,1,0) szereg II	4	4,298	4,529	-5,10%
	2	4,299	4,522	-4,93%
	3	4,300	4,524	-4,95%


Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Dla szeregu I błąd MSE wyniósł 0,001, natomiast błąd RMSE 0,032. Dla szeregu II błąd MSE wynosi 0,002, a błąd RMSE 0,041.

9.4.3. GARCH


W badaniach, poza poszukiwaniem modeli opisujących szereg czasowy cen danego instrumentu, bardzo często istotna jest również ocena stopnia zmienności analizowanych danych.

W poprzednim podrozdziale test ADF wykazał stacjonarność stóp zwrotu obydwu szeregów stóp zwrotu. Rysunki 9.7 oraz 9.8 prezentują funkcje korelacji ACF oraz PACF dla szeregu I oraz szeregu II prezentowanych stóp zwrotu.



Rys. 9.7. Korelogram funkcji ACF i PACF stóp zwrotu kontraktów terminowych na miedź dla szeregu I

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>



Rys. 9.8. Korelogram funkcji ACF i PACF stóp zwrotu kontraktów terminowych na miedź dla szeregu II

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Analizując powyższe korelogramy podjęto decyzje o wykorzystaniu modelu MA(1) do dalszej analizy procesu ARCH oraz przygotowania modelu GARCH analizowanych szeregów czasowych.

Kolejnym krokiem estymacji parametrów modelu GARCH jest sprawdzenie występowania efektu ARCH procesu MA(1) dla analizowanych szeregów czasowych. W celu weryfikacji hipotezy zerowej mówiącej o heteroskedastyczności wariancji wykorzystano test efektu ARCH zaproponowany przez Engle'a. Wyniki testu zaprezentowano w tabeli 9.9.

Tabela 9.9. Test efektu ARCH dla 10 opóźnień

Szereg czasowy	Model	Statystyka testowa	Istotność
Szereg I	MA(1)	5,58	0,85
Szereg II	MA(1)	24,23	0,007***

*** Statystyczna istotność na poziomie 0,01.

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Wyniki testu wskazują, że dla szeregu I efekt ARCH nie występuje i na poziomie istotności 0,01 nie ma podstaw do odrzucenia hipotezy zerowej mówiącej o braku występowania heteroskedastyczności. Natomiast dla szeregu II hipotezę zerową na poziomie 0,01 można odrzucić. Oznacza to, że dla szeregu II wariancja jest zmienna w czasie i do jej analizy możliwe jest wykorzystanie modelu GARCH.

W tabeli 9.10 zaprezentowano kryterium informacyjne Akaikiego szeregu II, obliczone dla modeli GARCH z różnymi współczynnikami p i q . Modele te powstały przy wykorzystaniu warunkowego rozkładu reszt modelu MA(1).

Tabela 9.10. Kryterium informacyjne warunkujące wybór modelu GARCH dla cen kontraktów terminowych na miedź

Model GARCH	Kryterium AIC
GARCH(1,1)	-4776,90
GARCH(1,2)	-4776,51
GARCH(2,2)	-4774,84
GARCH(2,3)	-4768,01
GARCH(1,3)	-4775,79

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Wyniki w tabeli 9.10 pokazują, że na podstawie kryterium informacyjnego AIC najlepszym modelem jest model GARCH(1,1). Taki też model został wybrany do oszacowania i prognozowania zmienności stóp zwrotu kontraktów terminowych na miedź. W tabeli 9.11 zaprezentowano parametry oszacowanego modelu.


Tabela 9.11. Oszacowanie modelu GARCH(1,1) dla szeregu II

Parametr	Współczynnik	Błąd standardowy	Statystyka t	Istotność
Ω	0,0005	0,00002	20,38	0,00***
$\alpha(1)$	0,10	0,042	2,37	0,00***
$\beta(1)$	0,60	0,044	13,51	0,00***

*** Statystyczna istotność na poziomie 0,01.


Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Parametry oszacowanego modelu GARCH(1,1) okazały się statystycznie istotne. Można więc uznać, że model dobrze opisuje szereg II. Kolejnym krokiem analizy oszacowanego modelu jest sprawdzenie jego reszt. Rysunek 9.9 przedstawia rozkład oraz wariancję reszt, natomiast rysunek 9.10 funkcję ACF i PACF reszt.



Rys. 9.9. Reszty modelu GARCH(1,1) (wykres po lewej) wraz z ich rozkładem empirycznym (wykres po prawej) dla szeregu II

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>



Rys. 9.10. Funkcja ACF i PACF modelu ARIMA(0,1,0) dla okresu II

Źródło: Opracowanie w programie Python na podstawie danych zaczerpniętych ze strony <https://pl.investing.com/>

Jak widać na powyższych wykresach, reszty modelu cechują się wariancją bliską zera oraz rozkładem zbliżonym do rozkładu normalnego. Ponadto funkcja ACF oraz PACF nie pokazują występowania korelacji reszt modelu. Można więc uznać, że model GARCH(1,1) jest modelem dobrze opisującym stopień zmienności stóp zwrotu cen kontraktów na miedź dla szeregu II.

9.5. Podsumowanie

Celem niniejszego artykułu było przygotowanie trzykresowej prognozy cen kontraktów terminowych na miedź na podstawie danych, dla których wpływ epidemii COVID-19 na wartość kontraktów terminowych był widoczny oraz dla kontraktów bez tego wpływu z wykorzystaniem modelu ARIMA wraz z użyciem modelu GARCH do oceny zmienności obu badanych szeregów czasowych.

Pierwszy cel zakładający postawienie prognoz za pomocą modelu ARIMA, został zrealizowany przy wykorzystaniu dwóch różnych modeli w zależności od analizowanego szeregu czasowego. Dla szeregu czasowego, którego skutki pandemii były niewidoczne (szereg I), najlepszym modelem pod względem kryterium Akaikego był model ARIMA(0,1,1), natomiast dla szeregu czasowego, w którym skutki pandemii COVID-19 występowały, najlepszym pod względem kryterium informacyjnego Akaikego okazał się model ARIMA(0,1,0), czyli model błędzenia losowego bez dryfu. Przy wykorzystaniu otrzymanych modeli zaprognozowano przyszłe ceny kontraktów terminowych na miedź.

Analizując błędy prognoz MSE oraz RMSE wraz z porównaniem prognoz do ich rzeczywistych realizacji, można zauważyć, że model szeregu I cechował się niższym obciążeniem prognoz niż model szeregu II. Dla modelu ARIMA(0,1,1) błąd procentowy prognoz do ich realizacji nie przekraczał $-2,4\%$, natomiast dla modelu błędzenia losowego błąd ten osiągnął wartość pomiędzy $-4,95\%$ a $-5,10\%$. Również błąd MSE oraz RMSE były mniejsze dla szeregu bez wpływu pandemii na ceny. Takie wyniki mogą oznaczać, że w analizowanych okresach pandemia ma wpływ na modele ARIMA cen kontraktów terminowych na miedź.

Poza analizą cen, badaniu poddano również logarytmiczne stopy zwrotu kontraktów terminowych na miedź w celu sprawdzenia możliwości wykorzystania modelu GARCH do oceny zmienności analizowanych szeregów czasowych. Aby móc zbadać, czy efekt ARCH decydujący o możliwości wykorzystania modelu GARCH występuje, dokonano estymacji modelu MA(1). Model ten jest najlepiej dopasowanym pod kątem kryterium Akaikego modelem dla logarytmicznych stóp zwrotu szeregu I oraz szeregu II. Wyniki testu Engle'a wykazały, że dla szeregu I efekt ARCH jest nieistotny statystycznie, natomiast dla szeregu II potwierdzono jego występowanie. Kolejnym krokiem była estymacja modelu GARCH szeregu II. Najlepszym modelem pod kątem kryterium AIC był model GARCH(1,1), którego wszystkie parametry były statystycznie istotne. Również analiza reszt wykazała, że taki model jest modelem prawidłowym do oceny stopnia zmienności wariancji.

Analizując powyższe rezultaty, można zauważyć, że oba badane szeregi czasowe różnią się od siebie pod kątem parametrów modeli ARIMA, jakości stawianych prognoz oraz występowaniem efektu ARCH. Jedną z przyczyn ta-

kiego stanu rzeczy może być pandemia, która w trakcie jej trwania, wywarła istotny wpływ na ceny surowców notowane na giełdzie. Dalsze badania dotyczące wpływu pandemii na szeregi czasowe powinny się skupić na poszukiwaniu takich modeli szeregów czasowych, które będą starały się w sposób bardziej elastyczny dopasowywać się do nagłych zmian na rynkach.

Literatura

- Box, G. E. P., Jenkins, G. M. (1983). *Analiza szeregów czasowych*. Warszawa: PWN.
- Chrałołowska, J., Nazarko, J. (2003). Modele ARIMA w prognozowaniu sprzedaży. *Zagadnienia Techniczno-Ekonomiczne*, 48, 791-804. <http://www.nazarko.pl/public/data/resource/upload/00003/2426/file/modele-arima2003.pdf>
- Dąsał, K., Popławski, T. (2008). Problemy związane z prognozowaniem zużycia energii elektrycznej w Polsce. *Polityka Energetyczna*, 11(1), 101-115. <https://min-pan.krakow.pl/wp-content/uploads/sites/4/2018/02/06-D%C4%85sal-Pop%C5%82awski.pdf>
- Doman, M. (2004). Prognozowanie zmienności polskich indeksów giełdowych za pomocą modeli GARCH przy użyciu danych wysokiej częstotliwości. *Acta Universitatis Lodzianensis*, 177, 291-309. <https://dSPACE.uni.lodz.pl/xmlui/bitstream/handle/11089/7202/277-295.pdf?sequence=1&isAllowed=y>
- Fiszeder, P. (2001). Zastosowanie modeli GARCH w analizie krótkookresowych zależności pomiędzy Warszawską Giełdą Papierów Wartościowych a międzynarodowymi rynkami akcji. *Przegląd Statystyczny*, 48(3/4), 345-364.
- Ganczarek-Gamrot, A. (2014). *Analiza szeregów czasowych*. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Guha, B., Bandyopadhyay, G. (2016). Gold price forecasting using ARIMA model. *Journal of Advanced Management Science*, 4(2), 117-121. <http://doi.org/10.12720/joams.4.2.117-121>
- Jakóbiak, W. (2020). *Ujemna cena ropy, czyli taka, jaką wycenił koronawirus*. Biznes Alert. <https://biznesalert.pl/ujemne-ceny-ropy-kryzys-gospodarczy-odbicie-energetyka-ropa-wojciech-jakobik/>
- Krężolek, D. (2020). *Modelowanie ryzyka na rynku metali*. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Malska, W., Wachta, H. (2015). Wykorzystanie modelu ARIMA do analizy szeregu czasowego. *Zeszyty Naukowe Politechniki Rzeszowskiej*, 34(292/3), 23-30. <https://doi.org/10.7862/re.2015.27>
- Milek, M. (2017). Wykrywanie pierwiastków jednostkowych z wykorzystaniem testów permutacyjnych. *Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, 335, 27-38. <https://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.cejsh-0131cdf0-52e5-4d5e-bdaa-7e2461f42187>

- Nazarko, J., Chraślowska, J., Rybaczuk, M. (2004). Zastosowanie wielosezonowego modelu ARIMA w prognozowaniu obciążeń mocą elektryczną. *Taksonomia. Prace Naukowe Akademii Ekonomicznej we Wrocławiu*, 11(1022), 173-182. <http://www.nazarko.pl/public/data/resource/upload/00003/2426/file/zastosowanie-wielosezonowego-modelu-arima.pdf>
- Nelson, D. B., Cao, C. Q. (1992). Inequality constraints in the univariate GARCH model. *Journal of Business and Economic Statistics*, 10, 229-235. <https://doi.org/10.2307/1391681>
- Piłatowska, M. (2009). Prognozowanie kombinowane z wykorzystaniem wag Akaike'a. *Acta Universitatis Nicolai Copernici*, 389, 51-62. https://doi.org/10.12775/AUNC_ECON.2009.025
- Piłatowska, M. (2011). Porównanie kryteriów informacyjnych i predykcyjnych w wyborze modelu. *Prace i Materiały Wydziału Zarządzania Uniwersytetu Gdańskiego*, 4(8), 499-512. <https://docplayer.pl/45410930-Porownanie-kryteriow-informacyjnych-i-predykcyjnych-w-wyborze-modelu.html>
- Sieroń, A. (2020). *Czy pandemia COVID-19 spowoduje zapaść globalnej gospodarki?* Instytut Misesa. <https://mises.pl/blog/2020/03/14/sieron-czy-pandemia-covid-19-spowoduje-zapasc-globalnej-gospodarki/>

10. Inwestowanie w akcje w okresie pandemii COVID-19

(Ewa Pośpiech)

10.1. Wprowadzenie

Inwestowanie w akcje to proces wymagający wiedzy i doświadczenia. Znajomość mechanizmów rządzących giełdą oraz umiejętność podejmowania decyzji stanowią kluczowy aspekt w tym procesie. Istotnym elementem jest także wykorzystanie narzędzi, które będą wspomagały proces decyzyjny. Często stosowane są narzędzia ilościowe, które w metodyczny sposób pozwalają przeprowadzić selekcję walorów. Kolejnym ważnym elementem jest horyzont czasowy inwestycji. W przypadku inwestycji długoterminowych zaleca się dokonanie analizy fundamentalnej spółek w celu zbadania ich kondycji ekonomiczno-finansowej. Oznacza to analizę otoczenia makroekonomicznego oraz ocenę sytuacji spółki, którą można przeprowadzić za pomocą wskaźników fundamentalnych i rynkowych. Przedsiębiorstwo o stabilnej pozycji i dobrych perspektywach stanowi zachętę dla potencjalnych inwestorów chcących ulokować swoje środki w akcje spółek.

Proces selekcji walorów może być realizowany na różne sposoby. Jedną z możliwości, uwzględniającą aspekt ilościowy, dają metody wielokryterialne, które na podstawie kryteriów oceny determinują postrzeganie danego waloru. Taka ocena pozwala na wybór tych spółek, które zdaniem decydenta spełniają jego oczekiwania co do stabilności i perspektyw danego przedsiębiorstwa.

W zagadnieniu wyboru portfela akcji często wykorzystywane są także narzędzia analizy portfelowej, w ramach której wyznaczane są portfele efektywne – portfele o najniższym ryzyku przy zadanej stopie zwrotu lub portfele o maksymalnej stopie zwrotu przy założonym poziomie akceptowalnego ryzyka (Jajuga, Jajuga, 2015).

Na skutek występowania różnych rodzajów ryzyka, które towarzyszy inwestycjom, nawet w sytuacji względnej stabilizacji na rynku, żadne ze stosowanych narzędzi wspomagających budowanie portfela nie daje gwarancji zysku. W przypadku zaś wystąpienia zjawisk ekstremalnych, takich jak: klęski żywiołowe, pandemie, kryzysy finansowe itp., niemal natychmiast odbija się to negatywnie na rynkach kapitałowych. Te specyficzne okoliczności generują wiele wyzwań dotyczących ważnych kwestii związanych z życiem społeczno-gospodarczym, a u inwestora pojawiają się dodatkowe obawy i pytania, czy inwestowanie w czasie występowania zjawisk ekstremalnych zawsze musi pociągać za sobą duże straty, czy może jednak istnieje szansa na zyskowne inwestowanie w takich wa-

runkach, zwłaszcza w akcje. Zagadnienia te determinują cel tej części pracy, którym jest ocena możliwości uzyskania zyskowych portfeli efektywnych w trudnym czasie pandemii COVID-19. W analizach wykorzystano akcje notowane na Rynku Głównym GPW w Warszawie. Portfele konstruowano na podstawie wyselekcjonowanych grup spółek, które uzyskano przy użyciu wielokryterialnych metod TOPSIS (standardowej i rozmytej) na podstawie wskaźników fundamentalnych i rynkowych z lat 2017-2019 oraz 2018-2020. Porównanie i ocena wyników uzyskanych portfeli zostały dokonane na przestrzeni lat 2020-2021, podczas których cały świat zmagął się z pandemią. Hipoteza badawcza, którą postawiono, brzmi: Mimo negatywnych reakcji rynków związanych z występującą pandemią, istnieje możliwość skonstruowania zyskowych długoterminowych portfeli efektywnych. Ponadto proponowane podejścia pozwalają zarekomendować metodę TOPSIS, zwłaszcza w ujęciu rozmytym, jako skuteczne narzędzie stosowane do wspomagania wyboru portfela akcji.

10.2. Metodyka i przedmiot analiz

Na podstawie studiów literaturowych oraz uprzednio prowadzonych badań (Chen, Hung, 2009; Ece, Uludag, 2017; Kazemi i in., 2014; Liu, i in., 2012; Nguyen, Gordon-Brown, 2012; Pośpiech, 2017a, 2017b, 2018, 2020a, 2020b, 2020c; Pośpiech, Mastalerz-Kodzis, 2015, 2016; Raei, Bahrani Jahromi, 2012), zastosowano narzędzia i metody, które w zagadnieniu wspomagania wyboru portfela dawały możliwość uzyskania interesujących wyników. W analizach wykorzystano wielokryterialne metody TOPSIS (standardową i w ujęciu rozmytym – FTOPSIS) oraz narzędzia analizy portfelowej wykorzystywane do konstruowania portfeli efektywnych (portfele o najmniejszym ryzyku przy zadanej stopie zwrotu).

Procedura budowania rankingu obiektów za pomocą metod TOPSIS oraz FTOPSIS przedstawiona jest w wielu opracowaniach (Hwang, Yoon, 1981; Jahanshahloo i in., 2006; Lai, i in., 1994; Roszkowska, Wachowicz, 2013; Trzaskalik, 2014), a jej rezultatem jest ranking wariantów.

Przedmiotem badań (obiektami) były spółki giełdowe notowane na GPW w Warszawie, a dane wykorzystane w badaniach to dane dla walorów tworzących indeks WIG20 w grudniu 2019 roku. W skład tego indeksu wchodziły spółki reprezentujące dziewięć sektorów (tabela 10.1).

Tabela 10.1. Spółki objęte badaniem

Spółka	Skrót	Sektor
ALIOR	ALR	banki komercyjne
CCC	CCC	odzież i obuwie
CDPROJEKT	CDR	gry
CYFRPLSAT	CPS	telekomunikacja
DINOPL	DNP	artykuły codziennego użytku
JSW	JSW	górnictwo węgla
KGHM	KGH	górnictwo metali
LOTOS	LTS	wydobycie i produkcja
LPP	LPP	odzież i obuwie
MBANK	MBK	banki komercyjne
ORANGEPL	OPL	telekomunikacja
PEKAO	PEO	banki komercyjne
PGE	PGE	energetyka
PGNIG	PGN	wydobycie i produkcja
PKNORLEN	PKN	wydobycie i produkcja
PKOBP	PKO	banki komercyjne
PLAY	PLY	telekomunikacja
PZU	PZU	firmy ubezpieczeniowe
SANPL	SPL	banki komercyjne
TAURONPE	TPE	energetyka

Źródło: Pośpiech (2020c).

W procedurze wielokryterialnej, mającej wyłonić grupy spółek, z których budowano następnie portfele, jako kryteria oceny przyjęto wybrane wskaźniki fundamentalne i rynkowe. Do oceny kondycji ekonomiczno-finansowej spółki wykorzystano cztery wskaźniki (Leszczyński, 2004; Tarczyński, 2001, 2002; Trzaskalik, 2006; Tyran, 2001):

- wskaźnik rentowności aktywów ROA,
- wskaźnik rentowności kapitału własnego ROE,
- cena do wartości księgowej P/BV,
- cena do zysku na 1 akcję P/E.

Okres, z którego zaczerpnięto dane, obejmował trzy lata (Tarczyński, 2002). W standardowym ujęciu metody TOPSIS jako oceny kryterialne uwzględniono średnie wartości badanych wskaźników z uwzględnionych trzech lat, natomiast w ujęciu rozmytym dane z trzech lat potraktowano jako parametry trójkątnej liczby rozmytej: $\tilde{a}_i^{(k)} = (l_{ik}, m_{ik}, u_{ik})$, gdzie k określa numer kryterium, l_k to najmniejsza wartość spośród trzyletnich ocen kryterialnych, m_k oznacza środkową wartość z uwzględnionego trzyletniego okresu, a u_k reprezentuje najwyższą wartość z badanego okresu.

Stwierdzono, że pożądaną są jak najwyższe wartości wskaźników, dlatego każde z kryteriów było maksymalizowane. Ponadto przyjęto taką samą wagę dla każdego z uwzględnianych kryteriów.

Ranking, zbudowany za pomocą metod TOPSIS, umożliwił wyznaczenie zbiorów spółek, które były podstawą konstrukcji portfela. Zbudowano portfele efektywne (portfele o minimalnym ryzyku przy zadanej stopie zwrotu portfela), w którym wykorzystano klasyczne podejście Markowitza (Markowitz, 1952). Zbudowano portfele efektywne na bazie zbiorów zawierających od 10 do 15 spółek – wybierano te spółki, które znajdowały się najwyżej w rankingu. We wcześniej prowadzonych badaniach (Pośpiech, 2017b, 2018, 2020a, 2020c) wyniki uzyskanych portfeli konfrontowano z portfelem rynkowym reprezentowanym przez indeks WIG20, który niemal w całym badanym okresie notował duże straty. W obecnym ujęciu wyniki zbudowanych portfeli efektywnych porównano z wynikami portfela rynkowego reprezentowanego przez indeks dochodowy WIG.

10.3. Wyniki badań

Okres badań obejmował lata 2017-2021. Dane dla wskaźników fundamentalnych i rynkowych pochodziły z lat 2017-2020, natomiast przy budowie portfeli efektywnych wykorzystano roczne dane obejmujące lata 2019-2021. Tabela 10.2 zawiera wartości wskaźnika, na podstawie którego zbudowano ranking spółek, natomiast tabela 10.3 prezentuje zbiory spółek stanowiących podstawę budowy portfeli efektywnych. Konstruowano portfele o minimalnej wariancji przy zadanej wartości stopy zwrotu – przyjęto średnią z roku 2019 dodatnich stóp zwrotu spółek tworzących indeks WIG20 w grudniu 2019 roku, a w przypadku portfeli zmodyfikowanych uwzględniono średnią dodatnich stóp zwrotu tych spółek z roku 2020.

Tabela 10.2. Wartości wskaźnika S_i oraz ranking spółek według metod

Spółka	TOPSIS (TOP)		Rozmyta TOPSIS (FTOP)	
	S_i	ranking	S_i	ranking
<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>
ALR	0,568	19	0,492	17
CCC	0,608	6	0,529	9
CDR	0,669	2	0,686	1
CPS	0,583	11	0,517	11
DNP	0,623	3	0,594	3
JSW	0,610	5	0,617	2
KGH	0,586	10	0,526	10
LTS	0,597	8	0,551	7

cd. tabeli 10.2

1	2	3	4	5
LPP	0,619	4	0,579	4
MBK	0,574	17	0,496	16
OPL	0,770	1	0,562	6
PEO	0,576	15	0,500	14
PGE	0,576	14	0,481	18
PGN	0,591	9	0,531	8
PKN	0,605	7	0,573	5
PKO	0,575	16	0,499	15
PLY	0,120	20	0,396	20
PZU	0,580	12	0,505	12
SPL	0,577	13	0,501	13
TPE	0,572	18	0,461	19

Źródło: Pośpiech (2020c).

Na podstawie powyższego rankingu wyznaczono zbiory spółek (tabela 10.3) – wybrano te walory, które zajmowały najwyższe pozycje w rankingu.

Tabela 10.3. Zbiory spółek 1 – podstawa wyboru portfela

Metoda porządkowania	Zbiory spółek					
	n = 10	dołączone spółki w celu uzyskania zbioru o podanej liczebności				
		n = 11	n = 12	n = 13	n = 14	n = 15
TOPSIS	OPL, CDR, DNP, LPP, JSW, CCC, PKN, LTS, PGN, KGH	CPS	PZU	SPL	PGE	PEO
FTOPSIS					PEO	PKO

Źródło: Pośpiech (2020c).


Selekcja walorów za pomocą wielokryterialnych metod TOPSIS i FTOPSIS doprowadziła do wyszczególnienia tych samych zbiorów o liczebności 10-13 oraz różne zbiory czternasto- oraz piętnastoelementowe. Zbiory te stanowiły podstawę wyboru ośmiu portfeli efektywnych, których oznaczenia zaprezentowano w tabeli 10.4.

Tabela 10.4. Oznaczenia uzyskanych portfeli efektywnych

Metody	Oznaczenia portfeli w zależności od liczebności oraz metody preselekcji zbiorów					
	n = 10	n = 11	n = 12	n = 13	n = 14	n = 15
TOPSIS	P1	P2	P3	P4	P5	P7
FTOPSIS					P6	P8

Źródło: Pośpiech (2020c).

Wyniki teoretycznych portfeli, zbudowanych na dzień 3 stycznia 2020 roku zaprezentowano na rysunkach 10.1-10.4. Porównano je z wynikami portfela rynkowego PR, reprezentowanego przez indeks dochodowy WIG.



Rys. 10.1. Zyski/straty portfeli P1, P2, P3, P4 ($n = 10, 11, 12, 13$) i PR w roku 2020


Źródło: Na podstawie: Pośpiech (2020c).

Wyniki portfeli omawiane były w pracy Pośpiech (2020c), wówczas jednak zestawiono ich wyniki z portfelem rynkowym reprezentowanym przez indeks WIG20. W szczególności: na początku roku 2020 wyniki badanych portfeli były podobne – charakteryzowały się niewielkimi zyskami bądź nieznacznymi stratami. W początkowych dwóch dekadach lutego portfele P1, P2, P3, P4 cechowały się trendem wzrostowym zysków, natomiast portfel rynkowy (WIG20) notował kilkuprocentowe straty. Wyniki indeksu WIG oscylowały wokół 0. Od końca lutego do 12 marca 2020 roku obserwowano coraz mniejsze zyski lub coraz większe straty portfeli P1-P4, co było skutkiem rozwoju epidemii koronawirusa na świecie i w Europie (w Polsce pierwszego pacjenta chorego na COVID-19 zdiagnozowano na początku marca). W tym okresie portfel rynkowy (indeks WIG) notował głównie straty, po czym w następnych miesiącach jego wyniki ponownie oscylowały wokół 0. Portfel rynkowy reprezentowany przez indeks WIG, notował zdecydowanie lepsze wyniki niż indeks WIG20, ale z wyjątkiem przełomu października i listopada, uzyskał gorsze wyniki niż portfele P1-P4, które po coraz mniejszych stratach notowanych do połowy kwietnia, cechowały się sukcesywnymi zyskami. Portfele P1-P3 notowały kilku/kilkunasto-procentowe wzrosty, osiągając najwyższy wynik w dniu 28 sierpnia

nia 2020 roku (ponad 18%). Od tego momentu widoczne były coraz mniejsze zyski aż do końca października, kiedy ponownie zaobserwowano kilkuprocentowe straty. Do końca roku prawie każdy portfel notował dodatnie wyniki. Najlepsze rezultaty uzyskiwał portfel P4, który od 8 kwietnia 2020 roku charakteryzował się zyskami, a najwyższy zysk (ok. 35%) zanotował 27 sierpnia 2020 roku. Do końca roku portfel ten osiągał dodatnie, chociaż na zmiennym poziomie, wyniki.

Uzyskane rezultaty ukazują, że wyniki wygenerowanych (teoretycznych) portfeli efektywnych są dużo korzystniejsze niż portfela rynkowego, nawet po zmianie benchmarku. Jak zauważono w trakcie poprzednich badań (Pośpiech, 2020c), w składzie tych portfeli nie ma spółek z sektora bankowego, energetycznego czy górniczego.

Dysponując danymi za rok 2021, zbadano dalsze notowania wygenerowanych portfeli. Ich kształtowanie się przedstawiono na rysunku 10.2.




Rys. 10.2. Zyski/straty portfeli P1, P2, P3, P4 ($n = 10, 11, 12, 13$) i PR w roku 2021

Źródło: Obliczenia własne na podstawie danych zaczerpniętych ze stron: www.bankier.pl i www.gpw.pl (15.11.2021).

Wyniki portfela rynkowego przez cały rok 2021 oscylowały wokół zera, natomiast notowania pozostałych portfeli kształtowały się następująco: od zróżnicowanych wyników w okresie styczeń-luty (od kilkuprocentowych strat portfela P1 do kilkunastoprocentowych zysków portfela P4), przez straty wszystkich portfeli w okresie marzec-czerwiec, i wreszcie wzrosty od kilku do nawet ponad 20% w okresie: koniec czerwca do końca października 2021 roku.

Na rysunku 10.3 przedstawiono zyski/straty portfela rynkowego PR oraz portfeli efektywnych P5, P6, P7, P8 wyłonionych ze zbiorów czternasto- i piętnastoelementowych.




Rys. 10.3. Zyski/straty portfeli P5, P6, P7, P8 ($n = 14, 15$) i PR w roku 2020

Źródło: Na podstawie: Pośpiech (2020c).

Wyniki portfeli P5-P8 przedstawiono w artykule Pośpiech (2020c). Podkreślono, że portfele te jeszcze lepiej prezentują się na tle portfela rynkowego (także po zmianie WIG20 na WIG) oraz na tle wcześniej rozważanych portfeli. Kształtowanie się zysków/strat jest analogiczne, jak w przypadku portfeli P1-P4, przy czym dla tych portfeli notowane są jeszcze wyższe zyski (szczególnie P5 i P7, uzyskanych po wstępnej selekcji metodą TOPSIS). Jednak portfele te cechowały się większym ryzykiem. Zatem to decydent musiałby stwierdzić, czy preferuje inwestycje o nieznacznie niższych zyskach obciążonych mniejszym ryzykiem, czy jest gotów na większe ryzyko i potencjalnie wyższe zyski.

Na rysunku 10.4 pokazano wyniki tych portfeli w roku 2021.



Rys. 10.4. Zyski/straty portfeli P5, P6, P7, P8 ($n = 14, 15$) i PR w roku 2021

Źródło: Na podstawie danych zaczerpniętych ze stron: www.gpw.pl i <http://infostrefa.com/infostrefa/pl/archiwum> (15.11.2021).

Wyniki portfeli P5, P6, P7, P8 w 2021 roku kształtują się podobnie jak P1-P4 w tym samym okresie. Tym razem jednak nieznacznie niższe notowania, w drugiej połowie roku, mają portfele P5 i P7 (preselekcja metodą TOPSIS).

Rysunki 10.1-10.4 ukazują zatem kształtowanie się teoretycznych dwudziestodwumiesięcznych portfeli, których wyniki odzwierciedlają wpływ pandemii na notowania akcji na giełdzie: rok 2020 – istotne straty w początkowej fazie pandemii (sukcesywne wprowadzane obostrzeń), powolne „zdejmowanie” obostrzeń oraz stabilizacja liczby zachorowań (czerwiec-sierpień), spadki związane m.in. z tzw. drugą falą pandemii oraz innymi wydarzeniami w kraju i na świecie, i wreszcie odbudowa portfeli, które na końcu roku notują zyski na poziomie kilku, a nawet kilkudziesięciu procent – wygasanie drugiej fali i rozpoczęcie podawania szczepionki przeciw COVID-19.

Można także zauważyć, że w roku 2021 rozwój pandemii ma wpływ na wyniki uzyskanych portfeli: zróżnicowanie wyników w początkowych dwóch miesiącach (chwilowe zmniejszenie liczby zachorowań), straty portfeli w okresie od marca do końca maja (nasilenie pandemii – tzw. trzecia fala), stabilizacja w I połowie czerwca, po czym osiąganie dodatnich wyników do końca badanego okresu (poprawa sytuacji pandemicznej).

W dotychczasowych rozważaniach badano wyniki teoretycznych portfeli w latach 2020-2021, przy czym portfele zbudowano na początku roku 2020. Postanowiono również zbadać wyniki portfeli zmodyfikowanych na początku

roku 2021. Uwzględniono 19 spółek indeksu WIG20 (usunięto z rozważań spółkę PLAY ze względu na to, że spółka w listopadzie 2020 roku została przejęta przez Grupę Iliad, a wycofanie akcji z obrotu na GPW nastąpiło w kwietniu 2021 roku⁴) i wyznaczono nowe zbiory zawierające od 10 do 15 walorów. Rezultat grupowania przedstawiono w tabeli 10.5.

Tabela 10.5. Zbiory spółek 2 – podstawa wyboru portfela

Metoda porządkowania	Zbiory spółek					
	n = 10	dołączone spółki w celu uzyskania zbioru o podanej liczebności				
		n = 11	n = 12	n = 13	n = 14	n = 15
TOPSIS	OPL, CDR, DNP, LPP, PGN, PKN, KGH, CPS, LTS, PKO	JSW	PZU	SPL	PEO	MBK
FTOPSIS	CDR, DNP, OPL, LPP, PGN, PKN, KGH, CPS, PZU, MBK	SPL	PEO	LTS	JSW	PKO

Źródło: Na podstawie danych zaczerpniętych ze strony www.bankier.pl (15.11.2021).

Oznaczenia portfeli efektywnych zmodyfikowanych po roku 2020, których podstawą były zbiory spółek 2 (tabela 10.5), przedstawione zostały w tabeli 10.6.


Tabela 10.6. Oznaczenia zmodyfikowanych portfeli efektywnych w 2021 roku

Metody	Oznaczenia portfeli w zależności od liczebności oraz metody preselekcji zbiorów					
	n = 10	n = 11	n = 12	n = 13	n = 14	n = 15
TOPSIS	P1T_m	P2T_m	P3T_m	P4TF_m	P5T_m	P7TF_m
FTOPSIS	P1F_m	P2F_m	P3F_m		P6F_m	

Wyniki uzyskanych portfeli ukazano na rysunkach 10.5-10.6.


Zmodyfikowane po roku 2020 portfele efektywne cechują się bardzo dużymi zyskami, nawet w okresie trzeciej fali pandemii (co najmniej ok. 20%). Najbardziej opłacalny byłby portfel P4TF_m, którego najniższy dochód był na poziomie 60%, a w szczytowych okresach przekraczał nawet 100%.

⁴ Dane zaczerpnięte ze strony <https://inwestycje.pl/gielda/akcje-play-communications-zostana-wycofane-z-obrotu-na-gpw/> (15.02.2022).



Rys. 10.5. Zyski/straty zmodyfikowanych portfeli ($n = 10, 11, 12, 13$) i PR w roku 2021

Źródło: Na podstawie danych zaczerpniętych ze stron: www.gpw.pl i <http://infostrefa.com/infostrefa/pl/archiwum> (15.11.2021).



Rys. 10.6. Zyski/straty zmodyfikowanych portfeli ($n = 14, 15$) i PR w roku 2021

Źródło: Na podstawie danych zaczerpniętych ze stron: www.gpw.pl oraz <http://infostrefa.com/infostrefa/pl/archiwum> (11.11.2021).

Kolejne portfele także charakteryzowały się dużymi zyskami – najgorszy z nich w okresie szczytu trzeciej fali pandemii nie przynosił zysków, ale po tym czasie jego zyski rosły, w najlepszym momencie osiągając poziom ok. 35%. Drugi co do wysokości zysków portfel notował wyniki na poziomach od prawie 40% do 80%, zyski zaś najlepszego z portfeli obejmowały zakres od 60% do 115%.

Ryzyko zmodyfikowanych portfeli przedstawiono w tabeli 10.7.

Tabela 10.7. Ryzyko zmodyfikowanych portfeli efektywnych

Metody	Ryzyko portfeli					
	<i>n</i> = 10	<i>n</i> = 11	<i>n</i> = 12	<i>n</i> = 13	<i>n</i> = 14	<i>n</i> = 15
TOPSIS	P1T_m 1,771	P2T_m 2,074	P3T_m 1,771	P4TF_m 2,381	P5T_m 1,699	P7TF_m 1,885
FTOPSIS	P1F_m 1,771	P2F_m 2,101	P3F_m 1,772		P6F_m 2,498	

Źródło: Na podstawie danych zaczerpniętych ze stron: www.gpw.pl i <http://infostrefa.com/infostrefa/pl/archiwum> (15.11.2021).

Ryzyko portfeli jest zróżnicowane. Można zauważyć, że portfelom o najmniejszym ryzyku towarzyszą niższe zyski, zaś te najbardziej zyskowe (P4TF_m, P6F_m) cechuje wysoki poziom ryzyka.

10.4. Podsumowanie

Celem przeprowadzonych analiz była ocena możliwości wygenerowania atrakcyjnych dla inwestora portfeli w trudnym czasie pandemii koronawirusa, która pojawiła się na świecie pod koniec 2019 roku. Przedmiotem badań były spółki indeksu WIG20 z grudnia 2019 roku. Badania przeprowadzono etapami. W pierwszym etapie, w celu poznania kondycji uwzględnionych spółek, zebrano dane dla najczęściej stosowanych wskaźników fundamentalnych i rynkowych. Przeprowadzono analizę wielokryterialną (metodą TOPSIS i FTOPSIS), w której wybrane wskaźniki stanowiły kryteria oceny spółek. Na podstawie uzyskanego rankingu spółek wyznaczono zbiory zawierające od dziesięciu do piętnastu walorów, które stanowiły bazę wyznaczania portfeli efektywnych (minimalizowano ryzyko przy zadanej stopie zwrotu).

Wyznaczono najpierw kilka portfeli, których wyniki były zdecydowanie lepsze niż portfela rynkowego, reprezentowanego przez indeks dochodowy WIG. Oceniono zyski portfeli na przestrzeni roku 2020 oraz 2021. Zauważono, że portfele efektywne wyznaczone na początku roku 2020 składały się głównie ze spółek należących do sektorów: Telekomunikacja, Paliwa i Gaz oraz Sieci handlowe, co wskazuje na te gałęzie, które w dobie pandemii odgrywają istotną rolę.

Porównując wyniki portfeli w 2020 roku wyznaczonych ze zbiorów uzyskanych przez selekcję standardową lub rozmytą metodą TOPSIS (P5, P7), identyczne lub nieco lepsze wyniki uzyskano przy użyciu metody TOPSIS – portfele te cechowały się jednak wyższym ryzykiem. Na przestrzeni roku 2021 sytuacja portfeli uległa zmianie: po nieznaczącej dominacji portfeli, do preselekcji których wykorzystano metodę TOPSIS, w I kwartale 2021 roku, nastąpiła zmiana – porównywalnymi bądź lepszymi wynikami charakteryzowały się portfele pochodzące z preselekcji metodą FTOPSIS (P6, P8).

Badając zyskowność portfeli w 2021 roku opierano się na danych fundamentalno-rynkowych z lat 2017-2019. Jak się okazało, atrakcyjne pod względem dochodów portfele były do osiągnięcia. Dodatkowo zbadano także inne ujęcie zagadnienia: oceniono zyskowność portfeli w roku 2021, ale po uwzględnieniu danych fundamentalno-rynkowych z lat 2018-2020 i wygenerowaniu zmodyfikowanych (efektywnych) portfeli na początku 2021 roku. Nastąpiły zmiany w składzie portfela, w dalszym ciągu jednak dominującą rolę w portfelach odgrywały spółki z sektorów: Telekomunikacja, Artykuły codziennego użytku, a także Wydobywanie i produkcja. Te zmodyfikowane portfele cechowały się w znakomitej większości ponadprzeciętnymi zyskami. W porównaniu portfeli, których selekcja odbywała się metodą TOPSIS lub FTOPSIS, lepiej (bądź porównywalnie) wypadły te drugie.

Analizując kształtowanie się wyników wyznaczonych portfeli zauważa się zbieżność z sytuacją, jaka w danym okresie wystąpiła w związku z rozwojem pandemii. Wyniki te wskazują jednak na możliwość skonstruowania atrakcyjnych (zyskowych) portfeli w sytuacji, gdy cały świat zmaga się z pandemią COVID-19 oraz z jej społecznymi i ekonomicznymi skutkami. Tak korzystne rezultaty wynikają z co najmniej dwóch powodów: po pierwsze, przeprowadzonej analizy fundamentalnej spółek, która wskazała te o najlepszej kondycji, po drugie, zasadność inwestowania w te dziedziny, które w zaistniałych warunkach są najbardziej opłacalne.

Analiza przeprowadzona za pomocą wybranych wskaźników fundamentalnych i rynkowych pozwala ocenić daną spółkę, a jeśli ta ocena jest pozytywna, szansa na dobre wyniki portfeli, w których skład wchodzi akcje takiego przedsiębiorstwa są większe.

Podsumowując, analiza kondycji fundamentalno-rynkowej spółek, cierpliwość, obserwacja zjawisk i aktualnie występujących trendów oraz rozważne zarządzanie portfelem umożliwi konstrukcję zyskowych portfeli, a także minimalizowanie ryzyka inwestycyjnego, nawet w specyficznym czasie pandemii, w którym zaburzone zostają liczne procesy społeczne, gospodarcze i finansowe.

Literatura

- Chen, C.-T., Hung, W.-Z. (2009). A new decision-making method for stock portfolio selection based on computing with linguistic assessment. *Journal of Applied Mathematics and Decision Science*, 2009, 897024. <https://doi.org/10.1155/2009/897024>
- Ece, O., Uludag, A. S. (2017). Applicability of fuzzy TOPSIS method in optimal portfolio selection and an application in BIST. *International Journal of Economics and Finance*, 9(10), 107-127. <https://doi.org/10.5539/ijef.v9n10p107>
- Hwang, C. L., Yoon, K. (1981). *Multiple attribute decision making: Methods and application*. Berlin: Springer Verlag.
- Jahanshahloo, G. R., Hosseinzadeh Lotfi, F., Izadikhah, M. (2006). Extension of the TOPSIS method for decision-making problems with fuzzy data. *Applied Mathematics and Computation*, 185, 1544-1551. <https://doi.org/10.1016/j.amc.2006.02.057>
- Jajuga K., Jajuga T. (2015). *Inwestycje. Instrumenty finansowe, aktywa niefinansowe, ryzyko finansowe, inżynieria finansowa*. Warszawa: Wydawnictwo Naukowe PWN.
- Kazemi, A., Sarrafha, K., Beedel, M. (2014). A hybrid fuzzy decision making method for a portfolio selection: A case study of Tehran Stock Exchange. *International Journal of Industrial and Systems Engineering*, 18(3), 335-354. <https://doi.org/10.1504/IJISE.2014.065537>
- Lai, Y.-J., Liu, T.-Y., Hwang, C.-L. (1994). TOPSIS for MODM. *European Journal of Operational Research*, 76(3), 486-500. [https://doi.org/10.1016/0377-2217\(94\)90282-8](https://doi.org/10.1016/0377-2217(94)90282-8)
- Leszczyński, Z. (2004). *Analiza ekonomiczno-finansowa spółki*. Warszawa; PWE.
- Liu, Y. J., Zhang, W. G., Xu, W. J. (2012). Fuzzy multi-period portfolio selection optimization models using multiple criteria. *Automatica*, 48(12), 3042-3053. <https://doi.org/10.1016/j.automatica.2012.08.036>
- Markowitz, H. (1952). Portfolio selection. *Journal of Finance*, 7(1), 77-91. <https://doi.org/10.2307/2975974>
- Nguyen, T. T., Gordon-Brown, L. N. (2012). Fuzzy numbers and MCDM methods for portfolio optimization. *International Journal of Computer, Electrical, Automation, Control and Information Engineering*, 6(12), 1593-1605. <https://doi.org/10.5281/zenodo.1334303>
- Pośpiech, E. (2017a). Multi-criteria fuzzy modelling in the issue of portfolio selection. W M. Čulík (red.), *Proceedings (Part III.) – 11th International Scientific Conference on Financial Management of Firms and Financial Institutions* (s. 700-707). Ostrava: VŠB – TU.
- Pośpiech, E. (2017b). Rozmyte modelowanie we wspomaganiu decyzji inwestycyjnych. *Organizacja i Zarządzanie*, 113, 375-384.
- Pośpiech, E. (2018). The risk of multi-criteria portfolios taking into account the fuzzy approach. W M. Čulík (red.), *Managing and Modelling of Financial Risks. 9th International Scientific Conference – Proceedings (Part 2)* (s. 411-418). Ostrava: VŠB – TU.

- Pośpiech, E. (2020a). *Modelowanie nieostre w wielokryterialnym wspomaganiu decyzji inwestycyjnych*. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Pośpiech, E. (2020b). The multi-criteria fuzzy approach to building and evaluating effective portfolios. *Organizacja i Zarządzanie*, 144, 397-407.
- Pośpiech, E. (2020c). The use of fuzzy modelling to invest in the Polish capital market in the pandemic era. W L. Burilovic, T. Rados, N. Recker (red.), *Economic and social development. 63rd International Scientific Conference on Economic and Social Development Development – "Building Resilient Society"* (Book of Proceedings, s. 151-158). Varaždin: Varazdin Development and Entrepreneurship Agency and University North. https://www.esd-conference.com/upload/book_of_proceedings/Book_of_Proceedings_esdZagreb2020_Online.pdf
- Pośpiech, E., Mastalerz-Kodzis, A. (2015). Wybór metody wielokryterialnej do wspomagania decyzji inwestycyjnych. *Organizacja i Zarządzanie*, 86, 379-388.
- Pośpiech, E., Mastalerz-Kodzis, A. (2016). Zastosowanie metody TOPSIS w ujęciu rozmytym do selekcji walorów giełdowych. *Organizacja i Zarządzanie*, 96, 395-404.
- Raei, R., Bahrani Jahromi, M. (2012). Portfolio optimization using a hybrid of fuzzy ANP, VIKOR and TOPSIS. *Management Science Letters*, 2, 2473-2484.
- Roszkowska, E., Wachowicz, T. (2013). Metoda TOPSIS i jej rozszerzenia – stadium metodologiczne. W T. Trzaskalik (red.), *Analiza wielokryterialna. Wybrane zagadnienia* (s. 11-40). Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Tarczyński, W. (2001). *Rynki kapitałowe. Metody ilościowe*. Warszawa: Wydawnictwo Placet.
- Tarczyński, W. (2002). *Fundamentalny portfel papierów wartościowych*. Warszawa: PWE.
- Trzaskalik, T. (red.). (2006). *Metody wielokryterialne na polskim rynku finansowym*. Warszawa: PWE.
- Trzaskalik, T. (red.). (2014). *Wielokryterialne wspomaganie decyzji*. Warszawa: PWE.
- Tyran, M. R. (2001). *Wskaźniki finansowe*. Kraków: Oficyna Ekonomiczna.

11. Wpływ epidemii COVID-19 na wybór modelu regresji wielorakiej stóp zwrotu kontraktów terminowych na aluminium i ropę naftową WTI

(Łukasz Sroka)

11.1. Wprowadzenie

Pandemia COVID-19 w istotny sposób wpłynęła zarówno na globalne rynki, jak i na pojedyncze przedsiębiorstwa. Decyzje dotyczące zamknięcia wielu sektorów gospodarki na okres zmorzonej zachorowalności oraz same skutki koronawirusa spowodowały zmiany w otoczeniu wewnętrznym oraz zewnętrznym przedsiębiorstw. Zmiany te zaczęły kreować nowe uwarunkowania działalności gospodarczej, do których przedsiębiorstwa musiały się przygotować, aby przetrwać na dynamicznie zmieniającym się rynku.

Jednym z głównych skutków pandemii było przerwanie światowych łańcuchów dostaw. Zamrożenie gospodarki w Azji, w Ameryce, czy też w Europie w znacznym stopniu przyczyniło się do powstania zastoju produkcyjnych, co z kolei wiązało się ze spadkiem cen surowców produkcyjnych notowanych na giełdach.

Zawirowania związane z nagłymi wahaniami cen na rynku spowodowały, że wiele modeli ekonometrycznych służących do opisu procesów gospodarczych musiało zostać przekształconych, aby dalej mogły w sposób zadowalający opisywać analizowane zjawiska. Główne zmiany dotyczyły postaci modelu oraz zmiennych wchodzących w jego skład.

Ponieważ wiedza na temat optymalnej postaci modelu ekonomicznego wraz ze zmiennymi wchodzącymi w jego skład jest w sferze zainteresowania zarówno przedsiębiorstw, jak i inwestorów za cel niniejszego rozdziału postawiono przygotowanie analizy porównawczej modeli regresji wielorakiej. Pierwszy model regresji wielorakiej został estymowany metodą najmniejszych kwadratów, natomiast drugi model – ważoną metodą najmniejszych kwadratów. Do badania wykorzystano stopy zwrotu kontraktów terminowych na aluminium i ropę naftową WTI. Zbiór stóp zwrotu analizowanych surowców został podzielony na dwa podzbiory. Pierwszy podzbiór zawierał stopy zwrotu dla cen, w których wpływ pandemii na ceny występuje, natomiast drugi podzbiór cechował się stopami zwrotu bez widocznego oddziaływania epidemii na ceny.

Pierwszym badanym modelem jest model regresji wielorakiej, w którym parametry zostaną oszacowane metodą najmniejszych kwadratów (MNK). Dla drugiego modelu parametry zostały oszacowane z wykorzystaniem ważonej metody najmniejszych kwadratów (WMNK). Ponadto, aby sprawdzić, w jaki sposób pandemia wpłynęła na modelowanie procesów gospodarczych analizie zostaną podane dane za okres, w którym efekt pandemii na gospodarkę nie występował (dane od 2.01.2019 do 28.02.2020) oraz z okresu, w którym skutki COVID-19 były widoczne (dane od 2.03.2020 do 30.06.2021). Aby móc zrealizować postawiony w pracy cel, za metodę badawczą przyjęto analizę ekonometryczną wraz z weryfikacją hipotez statystycznych. Analiza zostanie przygotowana w programie Python, przy wykorzystaniu następujących bibliotek: pandas, numpy, matplotlib, seaborn oraz statsmodels.

Pierwsza część pracy opisuje wpływ pandemii na rynek analizowanych surowców przemysłowych. Druga część zawiera wyniki przeprowadzonych badań. Na końcu rozdziału dokonano podsumowania wyników badań.

11.2. Rynek surowców przemysłowych w dobie pandemii

Pierwsza fala pandemii z marca i kwietnia 2020 roku wpłynęła negatywnie na wycenę surowców na światowych giełdach. Przedsiębiorstwa ograniczyły popyt na surowce przemysłowe w związku z zamknięciem gospodarki oraz niemożnością kontynuowania produkcji na poziomie sprzed pandemii. Załamanie rynku wiosną 2020 roku, a następnie gwałtowne ożywienie gospodarcze w drugiej połowie 2020 roku połączone z dużym popytem na dobra konsumpcyjne trwałego użytku przy jednoczesnym trwaniu pandemii doprowadziło do problemów z łańcuchami dostaw zarówno w transporcie morskim, jak i lądowym, co skutkowało niedoborem materiałów produkcyjnych.

W związku z zamrożeniem gospodarki i ograniczeniem światowego popytu indeksy surowców spadł o 16% na początku 2020 roku. Zmniejszanie ograniczeń wraz z przywracaniem działalności wytwórczej w kolejnych miesiącach 2020 roku skutkowało powrotem cen do stanów sprzed pandemii, a z czasem nawet ich przebicciem. W lipcu 2020 roku ceny indeksów surowców odrobiły stratę spowodowaną epidemią, osiągając porównywalne ceny ze stycznia 2020, natomiast w kwietniu 2021 roku ceny indeksów metali przemysłowych wzrosły o 48% w stosunku do cen z okresu przedpandemicznego, w którym najbardziej zdrożały rudy żelaza, miedzi oraz cynku (Wąsiński, 2021, s. 2).

Nagle wahania cen surowców stały się istotnym problemem w popandemicznym świecie. Skokowe zmiany cen na giełdach wraz z załamaniem się łańcuchów dostaw skutkowały nie tylko wzrostem cen dóbr i usług, ale przyczyniły się także do pogorszenia warunków biznesowych wielu przedsiębiorstw. Do

grupy surowców przemysłowych których ceny istotnie zmieniły się w wyniku pandemii, a które mają wpływ na funkcjonowanie gospodarki zaliczyć można aluminium oraz ropę naftową.

W kwietniu 2020 roku cena kontraktów terminowych na aluminium notowana na londyńskiej giełdzie surowcowej spadła o ponad 20% w porównaniu do stycznia tego samego roku. W ciągu kolejnych 12 miesięcy nastąpił wzrost ceny kontraktów terminowych na aluminium wynoszący 67%. Za ten wzrost w dużej mierze odpowiadały oczekiwania przedsiębiorstw, że popandemiczne ożywienie gospodarcze, zapoczątkowane przez luzowanie polityki monetarnej, napędzać będzie popyt na towary, który załamał się w wyniku epidemii. Ponadto wzrost cen kontraktów na aluminium znajdowały także wsparcie w zwiększających kosztach transportu drogą morską oraz w obawie, że ograniczenie emisji dwutlenku węgla w Chinach doprowadzi do zmniejszenia produkcji tego surowca w tamtejszych hutach (Wierciszewski, 2021).

Rok 2020 zapisał się negatywnie w historii rynku ropy naftowej. Mimo że ropa naftowa ma szerokie zastosowanie w przemyśle i wykorzystywana jest do produkcji paliw płynnych oraz innych surowców niezbędnych do gospodarczego funkcjonowania świata, takich jak np.: smary, woski, asfalt drogowy oraz inne specyfiki naftowe, to ograniczenie mobilności ludzi w połączeniu z zablokowaniem działalności gospodarczej przedsiębiorstw spowodowały spadek popytu na ropę na niespotykaną wcześniej skalę (Ptak, Jakóbiec, 2016). Według danych podanych przez Agencję Informacyjną Departamentu Energii w USA globalny popyt na ropę naftową z powodu pandemii spadł w II kwartale 2020 roku o 15,82 mln baryłek dziennie i był to najgorszy kwartał w czasie pandemii COVID-19. Cena kontraktów na ropę WTI z 20 kwietnia 2020 roku osiągnęła wartość -40 USD za baryłkę. Powodów ujemnej ceny było kilka, a jednym z nich była niechęć inwestorów posiadających kontrakty terminowe na ropę do fizycznego odbioru surowca. Inwestorzy woleli dopłacić, niż ponosić koszty odbioru i magazynowania ropy naftowej w okresie, w którym konsumpcja tego surowca była na rekordowo niskim poziomie (Kolany, 2020).

Podjęte działania w postaci silnego ograniczenia wydobycia ropy przez kraje zrzeszone w kartelu OPEC wraz z wynalezieniem szczepionki przy stopniowej poprawie sytuacji pandemicznej na świecie korzystnie wpłynęły na notowania kontraktów na ten surowiec. Prognozuje się, że globalne zużycie paliw ciekłych wzrośnie o 5,6 mln baryłek dziennie w 2021 roku oraz o 3,3 mln baryłek dziennie w 2022 roku (Suder, 2021). W powyższych analizach należy jednak wziąć pod uwagę fakt, że na wycenę kontraktów terminowych na ropę naftową wpływ mają również inne czynniki, których przewidywanie obarczone jest dużym błędem takie jak: stabilność polityczna, koniunktura gospodarcza, struktura dostaw oraz groźby przerwania dostaw (Kowalik i Herczakowska, 2006).

11.3. Wyniki badań

Chcąc wykorzystać model regresji wielorakiej do modelowania stóp zwrotu analizowanych surowców w pierwszej kolejności określono zestaw regresorów, które w istotny sposób mogą opisywać zmienną objaśnianą.

W przypadku stóp zwrotu dla aluminium oraz ropy naftowej WTI zaproponowano szereg predyktorów opisanych w pracy Krężolek (2020), które zaprezentowano w tabeli 11.1.

Tabela 11.1. Zbiór predyktorów proponowanych do opisu stóp zwrotu analizowanych surowców przemysłowych

Pary walutowe	AUD/USD	dolar australijski do dolara amerykańskiego
	USD/CHF	dolar amerykański do franka szwajcarskiego
	USD/JPY	dolar amerykański do jena japońskiego
Giełdowe indeksy (akcje/surowce)	CAC40	CAC 40 Index – Francja
	China A50*	China A 50 index – Chiny
	DAX	DAX index – Niemcy
	Nikkei 225	Nikkei 225 index – Japonia
	DJI	Dow Jones Industrial – USA
	S&P500	S&P500 – USA
	DJM*	Dow Jones Mining – USA
LMEI*	London Metal Exchange Index – W. Brytania	
Fundusze ETF (Exchange Traded Fund)	MSC World*	iShares MSCI World ETF
	VMI*	Vangard Material Index
	VREI*	Vangard Real Estate Index

* Dodatkowe predyktory, które nie występują w pracy Krężolek (2020).

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>

Otrzymane dane zostały podzielone na dwa zbiory. Pierwszy zbiór zawierał zmienne z okresu od 2.01.2019 do 28.02.2020 (zwane dalej zbiorem I). Przyjęto, że na te dane wpływ pandemii nie występował. Drugi zbiór, za okres od 2.03.2020 do 30.06.2021 (zwany dalej zbiorem II), zawierał dane z widocznym wpływem skutków epidemii na rynek. Pozyskane dane zostały przekształcone na dzienne logarytmiczne stopy zwrotu, a następnie poddano je analizie.

Analizę przeprowadzono osobno dla kontraktów terminowych na aluminium i ropę naftową. Na początku dokonano analizy korelacji między zmiennymi objaśnianymi a zmiennymi objaśniającymi. W tym celu wykorzystano współczynnik korelacji liniowej Pearsona. W przeprowadzonych obliczeniach przyjęto poziom istotności 0,05.

Badanie wykazało umiarkowanie silną istotnie statystyczną zależność dla kontraktów terminowych na aluminium z indeksem LEMI dla zbioru I, natomiast dla zbioru II umiarkowanie silnie istotna korelacja surowca występuje zarówno z indeksem LEMI, jak i parami walutowymi EUR/USD oraz

AUD/USD. Analizując współczynniki korelacji ropy naftowej, zauważono, że jest ona umiarkowanie silnie statystycznie istotnie skorelowana z indeksami CAC40, China A50, DAX, DJI, LMEI, S&P500, z ETF-ami: MSC World, VMI oraz VREI oraz parą walutową USD/JPY zarówno dla zbioru I, jak i zbioru II. Zależność liniowa między ropą naftową WTI a indeksami giełdowymi może wynikać z szerokiego wykorzystania tego surowca w produkcji oraz transporcie. Oznacza to, że zmiana ceny ropy naftowej ma duży wpływ na zyski osiągane przez największe spółki, co przekłada się na ich wyniki giełdowe.

Analizując korelacje między zmiennymi objaśniającymi, można zauważyć występowanie silnego, istotnie statystycznego związku między indeksami giełdowymi. Dodatkowo występuje silna istotnie statystyczna korelacja między parami walutowymi EUR/USD, USD/CHF oraz USD/JPY. Takie wyniki mogą wskazywać, że zmienne te będą wykluczane w trakcie budowy modelu z racji na ich współliniowy charakter. Pozostałe zmienne objaśniające nie wykazują silnej istotnie statystycznej zależności między sobą.

Kolejnym etapem badania była estymacja modelu regresji wielorakiej przy wykorzystaniu metody najmniejszych kwadratów oraz ważonej metody najmniejszych kwadratów dla każdego z analizowanych surowców w podziale na dwa zbiory: przedpandemiczny i pandemiczny. Do budowy modelu przyjęto wartość 0,05 jako poziom istotności. Analizę przeprowadzono metodą krokową polegającą na estymacji modelu przy wykorzystaniu pełnego zestawu zmiennych objaśniających, następnie sprawdzono istotność statystyczną i wykluczono zmienną statystycznie nieistotną o największej wartości p-value testu t-Studenta. Proces kontynuowano do momentu, w którym wszystkie zmienne okazywały się być istotnymi statystycznie.

11.3.1. Modelowanie stóp zwrotu kontraktów na aluminium

Tabela 11.2 prezentuje podsumowanie modelu regresji wielorakiej estymowanego metodą najmniejszych kwadratów.

Tabela 11.2. Podsumowanie modelu regresji wielorakiej MNK dla stóp zwrotu kontraktów na aluminium

Zbiór danych	Predyktory	R^2	R^2 – skorygowany	Błąd standardowy
Zbiór I	China A50, LMEI, VMI	0,374	0,367	0,007
Zbiór II	EUR/USD, GBP/USD, LMEI	0,409	0,403	0,009

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Analizując powyższą tabelę można zauważyć, że modele regresji wielorakiej estymowane metodą najmniejszych kwadratów dla każdego ze zbiorów wskazują umiarkowane dopasowanie zmiennych objaśniających do zmiennej zależnej. Współczynnik determinacji jest na poziomie 37-41%, jednakże zważywszy na charakter danych, wartość ta jest zadowalająca.

Tabela 11.3 przedstawia estymację predyktorów wchodzących w skład modelu estymowanego metodą najmniejszych kwadratów dla zbioru I oraz zbioru II.

Tabela 11.3. Oszacowanie współczynników regresji wielorakiej MNK dla stóp zwrotów kontraktów na aluminium

Zbiór danych	Predyktor	Współczynniki niestandardyzowana		Statystyka współliniowości	Istotność parametrów	
		β	Błąd standardowy	VIF	t	p-value
Zbiór I	China A50	-0,071	0,035	1,135	-2,025	0,004***
	LMEI	0,865	0,067	1,325	12,986	0,000***
	VMI	-0,176	0,046	1,274	-3,817	0,000***
	Stała	<0,001	0,000	1,001	0,131	0,896
Zbiór II	EUR/USD	0,412	0,141	1,676	2,929	0,004***
	GBP/USD	-0,341	0,103	1,753	-3,300	0,001***
	LMEI	0,542	0,050	1,193	12,897	0,000***
	Stała	<0,001	0,000	1,022	0,254	0,800

*** Statystyczna istotność na poziomie 0,01.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Wszystkie współczynniki modelu stóp zwrotu kontraktów terminowych na aluminium estymowane MNK są statystycznie istotne. Również statystyka współliniowości VIF jest na zadowalającym poziomie (poniżej 5), co świadczy o braku zależności liniowej pomiędzy predyktorami. Współczynniki modelu dla obydwu zbiorów wskazują na różnokierunkową i zróżnicowaną siłę wpływu na wartości stóp zwrotu kontraktów terminowych na aluminium.

Badając modele dla zbioru I oraz zbioru II można zauważyć, że dla zbioru przedpandemicznego na zmienność kontraktów terminowych na aluminium wpływ mają wyłącznie indeksy oraz ETF-y, natomiast na zbiór II zarówno indeks, jak i pary walutowe.

Na zmienność kontraktów na aluminium dla zbioru I najsilniej dodatnio wpływa indeks LMEI, wpływ pozostałych zmiennych jest ujemny. Na zmienność kontraktów terminowych na aluminium dla zbioru II również najsilniejszy dodatni wpływ ma indeks LMEI, natomiast także pary walutowe umiarkowanie silnie wpływają na zmienność w analizowanym okresie. Warto zauważyć, że wpływ pary walutowej EUR/USD jest dodatni, natomiast pary walutowej GBP/USD ujemny.

W celu pełnej weryfikacji zaprezentowanych modeli dokonano analizy składnika losowego, którego realizacją są reszty. W tabeli 11.4 zaprezentowano wyniki testu normalności rozkładu reszt.

Tabela 11.4. Test normalności składnika losowego modelu regresji wielorakiej MNK – stopy zwrotu kontraktów na aluminium

Zbiór danych	Test Shapiro–Wilka		Test Jarque’a–Bery	
	SW	p-value	JB	p-value
Zbiór I	0,995	0,556	4,086	0,129
Zbiór II	0,995	0,400	2,638	0,267

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Wyniki testów oznaczają, że nie ma podstaw do odrzucenia hipotezy mówiącej, że reszty mają rozkład normalny. Dokonano również oceny autokorelacji oraz heteroskedastyczności składnika losowego. Wyniki testu autokorelacji rzędu 1 Breuscha–Godfrey’a oraz testu na heteroskedastyczność Breuscha–Pagana zaprezentowano w tabeli 11.5.

Tabela 11.5. Test autokorelacji rzędu 1. oraz heteroskedastyczności modelu regresji wielorakiej MNK – stopy zwrotu kontraktów na aluminium

Zbiór danych	Test Breuscha–Godfrey’a		Test Breuscha–Pagana	
	BG	p-value	BP	p-value
Zbiór I	0,803	0,372	6,960	0,072*
Zbiór II	0,479	0,488	3,854	0,277

* Statystyczna istotność na poziomie 0,1.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Wyniki testu autokorelacji wykazują, że nie ma podstaw do odrzucenia hipotezy o braku autokorelacji dla obydwu zbiorów. Oznacza to, że w analizowanych modelach składnik losowy jest niezależny. Test na heteroskedastyczność wykazuje, że dla zbioru I na poziomie istotności 0,1 należy odrzucić hipotezę mówiącą o tym, że składnik losowy jest jednorodny. Dla zbioru II nie ma podstaw do odrzucenia tej hipotezy i można uznać, że składnik losowy jest jednorodny.

Tabela 11.6 zawiera podsumowanie współczynnika determinacji oraz błędów standardowych modelu regresji wielorakiej estymowanych ważoną metodą najmniejszych kwadratów stóp zwrotu kontraktów na aluminium.

Tabela 11.6. Podsumowanie modelu regresji wielorakiej WMNK dla stóp zwrotu kontraktów na aluminium

Zbiór danych	Predyktory	R^2	R^2 – skorygowany	Błąd standardowy
Zbiór I	LMEI, VMI	0,424	0,420	0,007
Zbiór II	DAX, EUR/USD, GBP/USD, LMEI, MSC World ETF	0,462	0,453	0,009

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Analizując powyższą tabelę można zauważyć, że R^2 jest na wyższym poziomie (42-46%) niż miało to miejsce w modelu regresji wielorakiej estymowanego MNK. Błędy standardowe są za to na tym samym poziomie. Dodatkowo zaobserwowano, że inny zestaw predyktorów okazał się statystycznie istotny w porównaniu do modelu estymowanego MNK.

Oszacowane parametry modelu zaprezentowano w tabeli 11.7.

Tabela 11.7. Oszacowanie współczynników modelu regresji wielorakiej WMNK dla stóp zwrotów kontraktów na aluminium

Zbiór danych	Predyktor	Współczynniki niestandardyzowana		Statystyka współliniowości	Istotność parametrów	
		β	Błąd standardowy	VIF	t	p-value
Zbiór I	LMEI	0,872	0,062	1,251	14,083	0,000***
	VMI	-0,168	0,046	1,251	-3,648	0,000***
	Stała	<0,001	0,000	1,000	-0,073	0,942
Zbiór II	DAX	-0,095	0,037	2,205	-2,556	0,011**
	EUR/USD	0,441	0,136	1,763	3,035	0,003***
	GBP/USD	-0,318	0,096	1,888	-3,330	0,001***
	LMEI	0,650	0,047	1,373	13,751	0,000***
	MSC World	0,082	0,033	2,101	2,469	0,014**
	Stała	<0,001	0,001	1,022	0,197	0,844

*** Statystyczna istotność na poziomie 0,01.

** Statystyczna istotność na poziomie 0,05.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Wszystkie współczynniki modelu regresji wielorakiej dla stóp zwrotu kontraktów terminowych na aluminium okazały się statystycznie istotne. Statystyka współliniowości VIF jest na zadowalającym poziomie, co świadczy o braku zależności liniowej pomiędzy predyktorami. Podobnie jak dla modelu regresji wielorakiej MNK również dla modelu estymowanego WMNK występują różnokierunkowe zależności między predyktorami, a stopą zwrotu kontraktów terminowych na aluminium. Na zmienność kontraktów terminowych na aluminium dla zbioru I najsilniej dodatnio wpływa indeks LMEI, wpływ VMI jest umiar-

kowanie ujemnie silny. Na zmienność kontraktów terminowych dla zbioru II również najsilniejszy dodatni wpływ ma indeks LMEI, wraz z parami walutowymi EUR/USD oraz GBP/USD. Wpływ pary walutowej EUR/USD jest dodatni, natomiast pary walutowej GBP/USD ujemny. Dodatkowo ETF MSC World ma słaby dodatni wpływ na zmienność stóp zwrotu kontraktów na aluminium.

Podobnie jak w poprzednim modelu, można zauważyć, że dla zbioru przedpandemicznego największy wpływ na stopy zwrotu kontraktów terminowych na aluminium mają indeksy, natomiast dla zbioru II, w którym wpływ pandemii występuje, oddziałują nie tylko indeksy, ale również ETF-y oraz pary walutowe.

W tabeli 11.8 zaprezentowano test rozkładu normalnego reszt, natomiast w tabeli 11.9 testy autokorelacji rzędu 1 oraz heteroskedastyczności dla modeli estymowanych WMNK.

Tabela 11.8. Test normalności składnika losowego modelu regresji wielorakiej WMNK – stopy zwrotu kontraktów na aluminium

Zbiór danych	Test Shapiro–Wilka		Test Jarque’a–Bery	
	SW	p-value	JB	p-value
Zbiór I	0,996	0,717	3,097	0,213
Zbiór II	0,991	0,083*	5,551	0,062*

* Statystyczna istotność na poziomie 0,1.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Analizując powyższe wyniki można stwierdzić, że dla zbioru I nie ma podstaw do odrzucenia hipotezy o zgodności reszt z rozkładem normalnym. Natomiast dla zbioru II ta hipotezę należy odrzucić na poziomie istotności 0,1.

Tabela 11.9. Test autokorelacji rzędu 1, oraz heteroskedastyczności modelu regresji wielorakiej WMNK – stopy zwrotu kontraktów na aluminium

Zbiór danych	Test Breuscha–Godfrey’a		Test Breuscha–Pagana	
	BG	p-value	BP	p-value
Zbiór I	2,273	0,132	9,577	0,008***
Zbiór II	0,553	0,457	9,312	0,095*

*** Statystyczna istotność na poziomie 0,01.

* Statystyczna istotność na poziomie 0,1.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Wyniki testu autokorelacji wykazują, że nie ma podstaw do odrzucenia hipotezy zerowej. Można więc stwierdzić, że dla analizowanych modeli składnik losowy jest niezależny. Wyniki oceny heteroskedastyczności reszt wskazują, że dla zbioru I na poziomie 0,01 należy odrzucić hipotezę zerową mówiącą o tym, że składnik losowy jest jednorodny, natomiast dla zbioru II hipoteza ta jest odrzucona na poziomie istotności 0,1.

11.3.2. Modelowanie stóp zwrotu kontraktów na ropę naftową

Tabela 11.10 zawiera informacje na temat modelu regresji wielorakiej estymowanej metodą najmniejszych kwadratów dla stóp zwrotu kontraktów terminowych na ropę naftową.

Tabela 11.10. Podsumowanie modelu regresji wielorakiej MNK dla stóp zwrotu kontraktów na ropę naftową WTI

Zbiór danych	Predyktory	R ²	R ² – skorygowany	Błąd standardowy
Zbiór I	China A50, MSC World	0,126	0,120	0,020
Zbiór II	DJM, LMEI, USD/JPY	0,238	0,230	0,041

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Wartość współczynnika determinacji R^2 dla zbioru I jest na niskim poziomie wynoszącym ok. 13%, natomiast wartość tego współczynnika równa 24% dla zbioru II jest na umiarkowanie wysokim poziomie. Analizując zmienne objaśniające wchodzące w skład obu modeli można zauważyć, że model dla zbioru I zawiera dwa predyktory: indeks China A50 oraz ETF MSC World, gdzie w skład modelu zbioru II wchodzi większa liczba zmiennych: indeksy DJM i LMEI oraz para walutowa USD/JPY.

Tabela 11.11 przedstawia oszacowanie współczynników regresji wielorakiej cen kontraktów na ropę dla zbioru I oraz zbioru II.

Tabela 11.11. Oszacowanie współczynników regresji wielorakiej MNK dla stóp zwrotów kontraktów na ropę naftową WTI

Zbiór danych	Predyktor	Współczynniki niestandardyzowana		Statystyka współliniowości	Istotność parametrów	
		B	Błąd standardowy	VIF	t	p-value
Zbiór I	China A50	0,196	0,091	1,098	2,151	0,032**
	MSC World	0,775	0,150	1,098	5,182	0,000***
	Stała	<0,001	0,001	1,005	-0,555	0,597
Zbiór II	DJM	0,334	0,090	1,048	3,725	0,000***
	LMEI	1,101	0,219	1,038	5,021	0,000***
	USD/JPY	3,263	0,446	1,019	7,323	0,000***
	Stała	<0,001	0,002	1,022	-0,071	0,943

*** Statystyczna istotność na poziomie 0,01.

** Statystyczna istotność na poziomie 0,05.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Współczynniki modelu regresji wielorakiej są statystycznie istotne dla wszystkich zmiennych ponadto VIF również jest na zadowalająco niskim poziomie.

Dla zbioru I najsilniej na stopy zwrotu kontraktów terminowych na ropę naftową oddziałuje index China A50. Wpływ indeksu China A50, jak i ETF MSC World, jest dodatni. Na stopy zwrotu kontraktów na ropę naftową zbioru pandemicznego wpływ ma więcej zmiennych, wśród których najsilniej na stopy oddziałuje para walutowa USD/JPY oraz indeks LMEI. Dla obydwu zmiennych objaśniających wpływ na stopy zwrotu kontraktów na ropę naftową jest dodatni.

Tabele 11.12 oraz 11.13 prezentują testy weryfikacyjne dla modelu regresji wielorakiej dla stóp zwrotu ropy naftowej.

Tabela 11.12. Test normalności składnika losowego – stopy zwrotu kontraktów na ropę naftową WTI

Zbiór danych	Test Shapiro–Wilka		Test Jarque’a–Bera	
	SW	p-value	JB	p-value
Zbiór I	0,916	0,000	980,367	0,000
Zbiór II	0,851	0,000	929,598	0,000

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Analizując powyższe testy można stwierdzić, że zarówno dla zbioru I, jak i zbioru II należy odrzucić hipotezę zerową mówiącą o zgodności reszt z rozkładem normalnym.

Tabela 11.13. Test autokorelacji rzędu 1 oraz heteroskedastyczności – stopy zwrotu kontraktów na ropę naftową WTI

Zbiór danych	Test Breuscha–Godfrey’a		Test Breuscha–Pagana	
	BG	p-value	BP	p-value
Zbiór I	0,521	0,471	1,475	0,478
Zbiór II	0,021	0,884	4,629	0,201

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Wyniki testów autokorelacji wykazują, że należy odrzucić hipotezę zerową o braku autokorelacji rzędu pierwszego. Oznacza to, że dla analizowanych modeli składnik losowy nie jest niezależny. Wyniki oceny heteroskedastyczności reszt przedstawiają, że dla obydwu zbiorów nie ma podstaw do odrzucenia hipotezy o jednorodności wariancji.

W tabeli 11.14 zaprezentowano ogólne podsumowanie modelu regresji wielorakiej estymowanego ważoną metodą najmniejszych kwadratów kontraktów na ropę naftową.

Tabela 11.14. Podsumowanie modelu regresji wielorakiej WMNK dla stóp zwrotu kontraktów na ropę naftową

Zbiór danych	Predyktory	R^2	R^2 – skorygowany	Błąd standardowy
Zbiór I	LMEI, MSC World, USD/CHF, USD/JPY	0,250	0,240	0,020
Zbiór II	LMEI, MSC World, USD/JPY	0,215	0,207	0,042

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Współczynnik determinacji zbioru I estymowanego metodą WMNK poprawił się znacząco w porównaniu do modelu regresji wielorakiej MNK, natomiast dla zbioru II nieznacznie się pogorszył. Dodatkowo można zauważyć, że w modelu estymowanego metodą ważoną występuje większa liczba zmiennych objaśniających zarówno dla zbioru I, jak i II.

Tabela 11.15. Oszacowanie współczynników regresji wielorakiej WMNK dla stóp zwrotów kontraktów na ropę naftową WTI

Zbiór danych	Predyktor	Współczynniki niestandardyzowana		Statystyka współliniowości	Istotność parametrów	
		β	błąd standardowy	VIF	t	p-value
Zbiór I	LMEI	0,316	0,159	1,300	1,987	0,048**
	MSC World	0,627	0,151	1,693	4,149	0,000***
	USD/CHF	-0,755	0,353	1,472	-2,139	0,033***
	USD/JPY	1,178	0,341	1,980	3,453	0,001***
	Stała	-0,001	0,001	1,001	-0,445	0,657
Zbiór II	LMEI	0,615	0,243	1,212	2,532	0,012**
	MSC World	0,322	0,151	1,383	2,139	0,033**
	USD/JPY	3,323	0,494	1,211	6,735	0,000***
	Stała	0,001	0,003	1,022	0,414	0,414

*** Statystyczna istotność na poziomie 0,01.

** Statystyczna istotność na poziomie 0,05.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Analizując zmienne wchodzące w skład modeli ekonometrycznych prezentowanych zbiorów można zauważyć, że para walutowa USD/JPY oddziałuje najsilniej dodatnio na stopy zwrotu kontraktów terminowych na ropę naftową w obydwu zbiorach. Warto zauważyć, że dla zbioru I para walutowa USD/CHF ma silną ujemną zależność. Biorąc pod uwagę indeksy oraz ETF-y, to dla zbioru I najsilniej oddziałuje indeks LMEI, natomiast dla zbioru II jest to ETF MSC World.

W tabeli 11.16 zaprezentowano wyniki testu Shapiro–Wilka oraz Jarque’a–Bery regresji wielorakiej WMNK dla stóp zwrotu kontraktów terminowych na ropę naftową.

Tabela 11.16. Test normalności składnika losowego regresji wielorakiej WMNK – stopy zwrotu kontraktów na ropę naftową

Zbiór danych	Test Shapiro–Wilka		Test Jarque’a–Bery	
	SW	p-value	JB	p-value
Zbiór I	0,912	0,000***	1172,716	0,000***
Zbiór II	0,821	0,000***	1331,445	0,000***

*** Statystyczna istotność na poziomie 0,01.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Dla modelu estymowanego metodą WMNK, należy odrzucić hipotezę zerową mówiącą o zgodności reszt z rozkładem normalnym dla zarówno dla zbioru I, jak i zbioru II.

Tabela 11.17. Test autokorelacji rzędu 1 oraz heteroskedastyczności – stopy zwrotu kontraktów na ropę naftową

Zbiór danych	Test Breuscha–Godfrey’a		Test Breuscha–Pagana	
	BG	p-value	BP	p-value
Zbiór I	2,069	0,150	6,670	0,154
Zbiór II	6,671	0,095*	8,687	0,003***

*** Statystyczna istotność na poziomie 0,01.

** Statystyczna istotność na poziomie 0,05.

Źródło: Na podstawie danych zaczerpniętych ze strony <https://www.investing.com>, z wykorzystaniem języka Python.

Test Breuscha–Godfrey’a wykazuje, że nie ma podstaw do odrzucenia hipotezy zerowej o braku autokorelacji rzędu pierwszego. Oznacza to, że dla analizowanych modeli składnik losowy jest niezależny. Wyniki oceny heteroskedastyczności reszt wskazują, że należy odrzucić hipotezę zerową o jednorodności składnika losowego, na rzecz hipotezy alternatywnej mówiącej o jej braku (tabela 11.17).

11.4. Podsumowanie

Celem niniejszej pracy było przygotowanie analizy porównawczej dwóch modeli regresji wielorakiej pierwszego estymowanego MNK oraz drugiego estymowanego WMNK stóp zwrotu dwóch surowców przemysłowych – aluminium oraz ropy naftowej WTI.

Cel pracy został zrealizowany poprzez przeanalizowanie dwóch zestawów danych dla każdego z badanych surowców – jednego z okresu sprzed pandemii, drugiego z okresu oddziaływania epidemii na ceny.

Wyniki badań modelu regresji wielorakiej estymowanego metodą najmniejszych kwadratów stóp zwrotu kontraktów terminowych na aluminium pokazały, że na stopy zwrotu dla zbioru I najsilniej oddziałują indeks LMEI. Wpływ tego indeksu na zmienną objaśnianą jest silnie dodatni. Dla zbioru II dwa predyktory bardzo silnie dodatnio wpływają na stopy zwrotu kontraktów na aluminium – indeks LMEI oraz para walutowa EUR/USD. Warto zauważyć, że w tym modelu para walutowa GBP/USD miała umiarkowanie silny ujemny wpływ na analizowane stopy zwrotu.

Model regresji wielorakiej estymowany ważoną metodą najmniejszych kwadratów cechował się większą wartością współczynnika determinacji w porównaniu do modelu estymowanego metodą MNK. W modelu estymowanym WMNK, tak samo jak w modelu estymowanym MNK te same zmienne objaśniające najsilniej oddziaływały na stopy zwrotu kontraktów terminowych na aluminium.

Analizując wyniki modelu regresji wielorakiej MNK dla ropy naftowej można zauważyć, że dla zbioru przedpandemicznego największy wpływ na stopy zwrotu kontraktów terminowych na ropę naftową miał indeks China A50 oraz ETF MSC World. Wpływ tych zmiennych był umiarkowanie silnie dodatni. Dla danych z odczuwalnymi skutkami pandemii najsilniej na stopy zwrotu oddziaływały para walutowa USD/JPY oraz indeks LMEI. Ich wpływ był dodatni.

W modelu regresji wielorakiej estymowanego metodą WMNK na zbiór I największy dodatni wpływ miały para walutowa USD/JPY oraz ETF MSC World. Wpływ pary walutowej USD/CHF był umiarkowanie silnie ujemny. W zbiorze II podobnie jak w przypadku modelu MNK najsilniej na stopy zwrotu wpływała para walutowa USD/JPY. Wpływ pozostałych zmiennych był słabszy. Warto nadmienić, że dla zbioru I współczynnik determinacji modelu WMNK ma wyższą wartość niż w modelu MNK, natomiast odwrotna sytuacja ma miejsce dla zbioru pandemicznego.

Kontynuacja badań może dotyczyć sprawdzenia, czy modele estymowane innymi metodami dają lepsze rezultaty pod względem dopasowania modelu do danych rzeczywistych. Dodatkowo przyszłe analizy mogą skupić się nad wyborem innego zestawu predyktorów, dzięki czemu obraz zmiennych wpływających na stopy zwrotu analizowanych surowców mógłby być pełniejszy.

Literatura

- Kolany, K. (2020). *Co oznacza ropa za mniej niż zero*. Puls Biznesu. <https://www.pb.pl/co-oznacza-ropa-za-mniej-niz-zero-989039>
- Kowalik, S., Herczakowska, J. (2010). Analiza i prognoza cen ropy naftowej na rynkach międzynarodowych. *Polityka Energetyczna. Energy Policy Journal*, 13(2), 253-262. <https://epj.min-pan.krakow.pl/Analysis-and-forecast-of-oil-prices-on-the-international-market,95816,0,2.html>
- Krężolek, D. (2020). *Modelowanie ryzyka na rynku metali*. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego.
- Ptak, S., Jakóbiec, J. (2016). Ropa naftowa jako główny surowiec energetyczno-przemysłowy. *Nafta-Gaz*, 72(6), 451-460. <https://doi.org/10.18668/NG.2016.06.09>
- Suder, J. (2021). *Pandemia nadal wpływa na rynek ropy naftowej*. Forsal. <https://forsal.pl/gospodarka/artykuly/8095944,pandemia-nadal-wplywa-na-rynek-ropy-naftowej.html>
- Wąsiński, M. (2021). Wstęp. *Tygodnik Gospodarczy PIE*, 21, 2. https://pie.net.pl/wp-content/uploads/2021/05/Tygodnik-Gospodarczy-PIE_21-2021.pdf
- Wierciszewski, M. (oprac.). (2021). *10 surowców, które w pandemii podróżowały, co najmniej o kilkadziesiąt procent. Używasz każdego z nich*. Business Insider. <https://businessinsider.com.pl/finanse/ktore-surowce-najmocniej-podrozaly-w-pandemii-uzywasz-kazdego-z-nich/gvgj8e3>

Tabela A1.1. Pozycja państw UE w rankingu indeksu LEI

Państwo	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019			
Austria	11	11	10	10	10	10	9	9	9	8	7	7	7	7	7	6	6	6	7	7	7	7	9	9	9	11	12	12	13	13			
Belgia	9	9	9	9	9	9	10	10	11	11	11	10	10	10	10	11	12	13	14	14	14	13	14	14	14	14	14	13	13	12	12		
Bulgaria	21	22	22	23	23	23	23	23	23	24	24	24	24	24	24	24	25	25	25	25	26	26	26	26	27	28	28	28	28	28			
Chorwacja	19	19	19	19	19	19	19	19	19	19	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20	22	22	22	22		
Cypr	7	8	8	8	8	8	8	8	8	9	9	10	12	14	14	15	15	16	16	16	16	16	18	18	18	18	18	18	18	17	17		
Czechy	20	20	20	20	20	20	20	20	20	20	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19		
Dania	15	15	15	16	16	15	15	15	15	16	16	17	17	17	17	17	17	17	17	17	17	17	17	17	17	17	17	17	17	18	18		
Estonia	26	27	27	27	27	27	27	27	27	27	26	26	26	25	25	24	24	23	23	23	23	23	22	22	22	22	22	20	20	20	20		
Finlandia	13	13	13	13	13	13	13	13	13	12	12	11	10	10	10	11	11	12	13	13	13	12	11	11	12	11	11	11	11	11	11	11	
Francja	6	6	5	5	5	5	5	5	5	5	4	4	4	4	4	4	4	4	4	4	4	4	3	3	3	3	4	4	4	4	4		
Niemcy	12	12	12	12	12	12	11	11	10	10	9	9	9	9	9	9	9	9	9	10	11	12	13	15	15	15	15	15	15	15	15	14	
Grecja	7	7	7	6	6	6	6	6	6	6	6	6	6	6	6	6	7	7	7	8	8	8	7	7	8	8	8	8	8	7	7		
Węgry	27	26	26	25	24	24	24	24	24	24	23	23	23	23	23	23	23	23	24	24	24	24	24	24	24	24	24	24	24	24	24	24	
Irlandia	16	16	15	15	15	15	15	15	15	15	15	15	15	15	15	14	13	11	11	11	11	11	11	11	11	11	9	9	8	7	6		
Włochy	4	4	4	4	4	4	3	2	2	2	2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	2	2	2	2	2	2	
Łotwa	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	27	27	27	27	27	27	27	27	27	27	
Litwa	24	24	24	24	25	25	25	25	25	25	25	25	25	25	26	27	27	27	27	27	27	27	27	28	28	27	26	26	26	26	26	26	
Luksemburg	14	14	14	14	14	14	14	14	14	14	14	14	14	14	13	13	13	13	12	11	10	9	9	7	7	7	7	7	7	7	7	7	
Malta	4	3	3	2	2	2	3	4	4	4	4	4	4	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	
Holandia	3	5	5	7	7	7	7	7	7	7	8	8	8	8	8	8	8	7	7	6	6	6	6	6	6	6	6	6	6	6	6	6	6
Polska	23	23	23	22	22	22	22	22	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	21	20	20	
Portugalia	17	17	17	17	17	17	17	17	17	17	16	16	16	16	16	16	15	15	15	15	15	15	13	13	12	12	10	10	10	10	10	10	
Rumunia	25	25	25	26	26	26	26	26	26	26	26	26	26	26	26	26	26	26	26	26	25	25	25	25	25	25	25	25	25	25	25	25	25
Słowacja	22	21	21	21	21	21	21	21	22	22	22	22	22	22	22	22	22	22	22	22	22	22	22	22	22	23	23	23	23	23	23	23	23
Słowenia	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	17	16	16	16	16	16	16	16	16	15	15	15	15
Hiszpania	2	2	2	2	2	2	2	3	3	3	3	3	3	3	3	3	2	2	2	2	2	2	1	1	1	1	1	1	1	1	1	1	1
Szwecja	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Wielka Brytania	10	10	10	10	11	11	11	12	12	12	12	13	12	10	10	10	10	10	9	9	9	9	10	10	10	12	13	14	14	14	14	14	15

Tabela A2. Pozycja państw UE w rankingu indeksu EI

Państwo	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019		
Austria	8	8	10	9	12	13	14	13	13	14	16	14	19	20	20	20	19	15	15	16	14	14	14	16	14	14	15	15	14	15		
Belgia	3	3	2	1	3	3	3	2	2	3	3	5	4	5	8	6	4	4	9	7	7	7	7	10	9	9	8	8	8	9		
Bulgaria	15	16	16	19	21	20	22	21	22	22	24	24	24	24	24	26	26	25	25	25	26	26	26	23	23	23	25	25	26	26		
Chorwacja	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28		
Cypr	26	26	27	18	21	20	21	20	21	23	24	23	23	23	23	24	23	23	23	23	25	25	23	23	22	24	22	21	18	18		
Czechy	18	21	24	21	20	18	17	17	18	16	14	13	13	14	14	13	13	13	13	12	9	9	9	8	8	8	8	9	10	10	11	
Dania	6	5	6	6	6	6	6	6	7	6	7	2	2	2	3	1	3	3	2	3	4	2	2	2	2	2	3	4	3	3	5	
Estonia	8	10	11	14	14	10	8	9	10	8	8	8	8	8	9	9	10	10	10	9	6	6	5	11	12	11	12	11	12	13	13	
Finlandia	10	9	8	7	7	7	7	7	8	9	9	10	10	10	2	1	2	2	2	2	2	2	3	3	3	2	2	2	2	2	3	
Francja	17	15	14	13	8	8	8	10	12	12	13	16	16	16	16	16	17	18	20	21	19	20	20	20	20	20	20	21	22	22	22	
Niemcy	5	4	4	4	5	5	5	5	6	5	4	3	3	3	3	1	3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	
Grecja	19	17	18	23	23	24	24	25	25	24	24	22	22	21	18	17	16	21	18	18	18	18	18	18	18	16	16	17	17	17	16	
Węgry	24	21	18	15	15	15	15	15	16	14	15	15	15	15	15	15	16	16	16	14	16	17	16	15	17	18	19	19	21	21		
Irlandia	12	13	13	12	13	12	12	12	5	6	6	7	6	4	4	4	5	5	4	5	10	10	5	7	5	6	3	4	4	4	4	
Włochy	23	21	20	20	19	19	19	19	19	20	21	20	18	18	19	21	21	20	21	20	22	23	20	21	23	25	26	26	25	25	25	
Łotwa	21	18	23	25	26	26	25	24	23	21	20	17	14	13	12	12	12	12	11	10	13	13	13	14	13	13	13	13	13	12	12	
Litwa	13	14	15	17	17	17	18	17	14	13	12	12	12	10	11	10	6	6	5	10	11	11	11	12	10	10	10	10	10	10	10	
Luksemburg	22	18	21	22	22	22	22	20	20	18	17	17	17	17	17	19	19	19	23	22	22	22	22	26	26	25	24	23	24	23	23	
Malta	20	18	22	24	25	25	26	26	26	27	28	27	28	28	27	23	25	26	27	27	24	27	23	21	21	21	21	21	19	20		
Holandia	1	1	1	3	1	1	1	3	4	4	5	6	9	9	10	11	7	8	8	7	4	4	4	6	7	7	7	7	7	7	7	
Polska	11	12	12	11	10	11	11	11	11	11	11	11	11	11	12	13	14	14	14	15	15	15	17	13	15	15	14	14	14	14	14	
Portugalia	27	27	26	26	24	23	23	23	24	25	25	26	26	27	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	
Rumunia	15	21	25	27	27	27	27	27	27	27	26	27	26	27	26	25	24	22	19	19	19	19	23	27	27	27	27	27	27	27	27	27
Słowacja	7	7	9	9	11	10	13	14	15	17	19	21	20	19	20	18	18	17	17	17	17	16	15	17	17	18	18	18	19	19	19	
Słowenia	4	6	5	8	9	9	9	9	10	8	10	9	7	7	6	7	6	7	7	6	5	5	9	9	11	12	11	9	9	8	8	
Hiszpania	25	21	17	16	16	16	16	16	17	19	18	19	21	22	22	22	22	24	24	24	21	18	19	19	19	17	16	16	16	16	17	
Szwecja	2	2	3	1	2	2	2	1	1	1	1	1	1	1	1	6	8	9	11	12	13	12	12	5	6	4	5	5	6	6	6	
Wielka Brytania	14	11	7	5	4	4	4	4	3	2	2	3	4	6	5	5	8	9	6	4	3	8	8	4	4	5	6	6	6	6	4	

Tabela A3. Pozycja państw UE w rankingu indeksu GNII

Państwo	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019									
Austria	3	2	4	3	3	3	4	4	4	4	4	4	4	4	4	4	5	4	2	3	2	2	2	2	2	2	2	2	2	2	2								
Belgia	7	7	7	7	6	6	7	5	5	5	5	5	5	6	6	6	6	7	7	6	5	6	7	7	7	7	8	8	8	8	8								
Bulgaria	27	27	27	27	26	26	26	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28	28							
Chorwacja	24	24	24	25	23	21	21	20	21	21	21	21	21	22	22	22	22	22	21	23	23	24	25	26	26	26	26	27	27	27	27	27							
Cypr	13	16	13	14	14	14	14	16	14	14	14	14	14	14	15	14	14	14	14	13	13	13	13	14	14	16	15	15	15	15	15	15							
Czechy	16	18	18	18	18	18	18	18	19	19	19	19	19	19	19	19	18	18	17	17	17	17	16	16	17	17	16	16	16	17	16	17	16						
Dania	2	4	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	3	4	4	4	4	3	2	2	3	3	3	3	3						
Estonia	23	22	22	22	22	22	23	23	23	22	22	22	22	22	20	20	20	20	20	20	20	21	20	20	19	19	18	18	18	18	18	18	18	18					
Finlandia	10	11	11	11	11	11	11	12	12	11	11	11	10	10	9	8	8	8	7	8	8	8	8	8	8	8	9	9	9	9	9	9	9	9					
Francja	8	8	8	8	8	8	8	8	8	8	10	10	11	12	12	12	12	12	11	11	10	10	9	9	10	10	10	10	10	10	10	10	10	10	10				
Niemcy	4	3	3	4	5	5	5	7	7	7	7	7	8	9	10	10	9	9	9	9	9	7	5	5	5	5	5	5	5	5	5	5	5	5	5	5			
Grecja	14	13	14	15	15	16	16	16	16	16	16	16	15	15	15	14	15	15	15	15	15	15	19	19	19	20	21	22	22	22	22	22	22	22	22	22			
Węgry	22	23	20	20	20	20	20	21	21	20	20	20	20	20	20	22	21	21	21	25	25	24	23	24	25	25	25	24	25	25	25	24	25	24	25	23	23		
Irlandia	15	14	15	13	13	12	12	11	10	10	8	8	7	5	5	3	4	5	8	9	9	10	10	9	8	3	2	2	2	2	2	2	2	2	2	2			
Włochy	6	6	6	6	6	7	6	6	6	6	6	6	6	6	8	8	9	10	10	10	10	11	11	12	12	12	12	12	12	12	12	12	12	12	12	12	12		
Łotwa	20	21	25	28	28	28	28	27	26	26	26	26	26	26	26	26	25	24	23	24	25	26	26	24	24	24	24	24	24	24	24	24	24	24	24	24	24	24	
Litwa	21	20	21	23	27	27	27	25	25	25	25	25	25	23	23	23	23	23	22	21	22	22	22	22	21	20	20	20	20	20	20	20	20	20	20	20	20	20	
Luksemburg	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	
Malta	19	17	17	17	17	17	17	17	17	17	17	17	17	17	18	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	19	
Holandia	5	5	5	5	4	4	3	3	3	3	3	3	3	3	3	3	3	3	3	4	2	3	3	3	3	4	4	4	4	4	4	4	4	4	4	4	4	4	
Polska	28	28	28	26	24	24	24	24	24	24	24	24	24	24	24	25	25	26	26	26	26	26	25	23	23	23	23	23	23	23	23	23	23	23	23	23	23	23	23
Portugalia	17	15	16	16	16	15	15	14	15	15	15	16	16	16	16	16	17	17	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18	18
Rumunia	26	26	26	24	25	25	25	26	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27	27
Słowacja	25	25	23	21	21	22	22	22	23	23	24	23	23	23	24	24	24	25	24	22	21	20	21	21	21	22	22	22	21	21	21	21	21	21	21	21	21	21	21
Słowenia	18	19	19	19	19	19	19	19	18	18	18	18	18	18	18	17	16	16	16	16	16	16	15	15	16	15	15	17	17	17	17	17	17	17	17	17	17	17	
Hiszpania	12	12	12	12	12	13	13	13	13	13	13	13	13	13	13	13	13	13	13	14	14	14	14	14	13	13	13	13	13	13	13	13	13	13	13	13	13	13	13
Szwecja	9	9	9	10	9	9	9	9	9	9	9	9	9	7	7	7	7	6	6	5	6	5	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	
Wielka Brytania	11	10	10	9	10	10	10	10	11	12	12	12	12	12	11	11	11	11	11	12	12	12	12	11	11	11	11	11	11	11	11	11	11	11	11	11	11	11	11

Gospodarka światowa w XXI wieku zmienia się bardzo dynamicznie, a zmiany te mają charakter stochastyczny. Na obserwowane wielkości w gospodarce ma wpływ wiele czynników społecznych, ekonomicznych, ale także politycznych. Celem pracy jest pokazanie skali oraz kierunku zmian zachodzących w otaczającym świecie w aspekcie społecznym i ekonomicznym w pierwszym 20-leciu XXI wieku. Metodykę badań stanowią wybrane narzędzia statystyczne i ekonometryczne.

Monografia składa się z dwóch części zasadniczych. W pierwszej z nich omówiono zmiany zachodzące w sferze społeczno-gospodarczej w Polsce i na świecie. Druga część zawiera analizy dotyczące rynku kapitałowego.

Zaprezentowane wnioski wynikające z badań empirycznych pozwoliły na zapisanie nowych spostrzeżeń dotyczących funkcjonowania gospodarki Polski i wybranych gospodarek światowych, w tym także rynków kapitałowych. Autorzy mają nadzieję, że pokazane w pracy relacje będą pomocne w procesie podejmowania decyzji na różnych poziomach zarządzania gospodarką.

Adrianna Mastalerz-Kodzis
Katarzyna Zeug-Żebro

ISBN 978-83-7875-829-7



Uniwersytet
Ekonomiczny
w Katowicach