

dr Marek KOŁATKA

Uniwersytet Gdański
e-mail: marek.kolatka@ug.edu.pl
ORCID: 0000-0002-7037-3457

DOI: 10.15290/oes.2023.02.112.09

WARUNKI RYNKOWE A KRÓTKOOKRESOWE MOŻLIWOŚCI PROGNOSTYCZNE NA POLSKIEJ GIEŁDZIE PAPIERÓW WARTOŚCIOWYCH¹

Streszczenie

Cel – Weryfikacja, czy warunki rynkowe są powiązane z możliwościami wyznaczenia skutecznych prognoz w krótkim okresie na polskiej giełdzie papierów wartościowych.

Metoda badań – Zastosowano test autokorelacji Quenouille’a w celu weryfikacji wystąpienia korelacji między stopami zwrotu w podokresach. Wyznaczono warunki rynkowe: rynek hossy/bessy, okres: byka, niedźwiedzia i normalny, wystąpienie kryzysu oraz poziom zmienności. Wykorzystano test χ^2 oraz współczynnik korelacji rho-Spearmana, aby ocenić siłę, kierunek i istotność powiązań między warunkami rynkowymi a możliwościami prognozy przyszłej stopy zwrotu.

Wnioski – Stwierdzono występowanie w podokresach istotnych powiązań między stopami zwrotu z indeksu WIG. Możliwości prognostyczne wzrastały w okresach hossy, rynku byka i w okres większej zmienności na rynkach. Możliwości prognostyczne malały w okresach bessy, normalnych i kryzysów.

Oryginalność/wartość/implikacje/rekomendacje – Opisano, w jaki sposób można określić warunki rynkowe oraz wskazano, podczas których warunków rynkowych wzrastają lub maleją szanse na wyznaczenie skutecznych prognoz inwestycyjnych na polskiej giełdzie.

Słowa kluczowe: polska giełda papierów wartościowych, prognozy inwestycyjne, warunki rynkowe.

¹ Artykuł finansowany ze środków Katedry Mikroekonomii Uniwersytetu Gdańskiego. Artykuł wpłynął 22.12.2022, zaakceptowano 15.05.2023.

MARKET CONDITIONS AND SHORT-TERM FORECASTING OPPORTUNITIES ON THE POLISH STOCK EXCHANGE

Summary

Purpose – Verifying that market conditions are related to the ability to provide effective forecasts on the Polish stock exchange in the short-term.

Research method – A Quenouille autocorrelation test was applied to verify the occurrence of correlations between returns in sub-periods. Market conditions were determined: boom/bust market, bull, bear and normal periods, the occurrence of a crisis and the level of volatility. The χ^2 test and the rho-Spearman correlation coefficient were used to assess the strength, direction and significance of the relationship between market conditions and the ability to forecast future returns.

Results – Sub-periods of significant correlations between WIG returns were found. Forecasting opportunities increased during boom periods, bull markets and periods of higher market volatility. Prognostic possibilities decreased during bust, normal and crisis periods.

Originality/value/implications/recommendations – A description of how market conditions can be determined and an indication during which market conditions the chances of determining successful investment forecasts on the Polish stock market increase or decrease are provided.

Keywords: Polish stock exchange, investment forecasts, market conditions.

JEL Classification: G11, G14

1. Wstęp

Możliwość skutecznego prognozowania cen instrumentów finansowych to aspekt, który od dziesięcioleci jest weryfikowany w świecie naukowym. W niniejszej pracy postanowiono zweryfikować, czy na polskiej giełdzie papierów wartościowych występują okresy możliwości predykcji przyszłych zmian oraz czy okresy te są powiązane z warunkami rynkowymi. W związku z tym sformułowano dwie hipotezy badawcze: 1) na polskiej giełdzie papierów wartościowych występują okresy współzależności stóp zwrotu, 2) okresy występowania współzależności stóp zwrotu są powiązane z warunkami rynkowymi.

Wartością dodaną dla odbiorców będzie wskazanie, czy polska giełda papierów wartościowych cechuje się losowością czy może występują okresy ze związk-

szonym prawdopodobieństwem prognozy przyszłych stóp zwrotu. Dodatkowo zostaną wskazane warunki rynkowe, które sprzyjają możliwości prawidłowego oszacowania przyszłych zmian.

2. Wybrane prace naukowe w kontekście kształtowania się cen na rynkach

Już w 1900 roku Louis Bachelier w swojej pracy doktorskiej opisał naukowo, w jaki sposób dochodzi do ustalania cen aktywów na giełdzie w Paryżu [Smith, 2004, s. 98–99]. Od tego momentu powstało wiele rozpraw, które potwierdzają lub negują możliwość predykcji zmian na rynkach finansowych.

Przełomową pracą była również rozprawa doktorska Eugena Famy z 1970 roku, w której przedstawił spójną teorię odnośnie do efektywności informacyjnej rynków [Fama, 1970, s. 383]. Zgodnie z tą teorią zmiany na rynkach dokonują się w sposób losowy, więc opierając się na danych historycznych, w długim okresie nie ma możliwości osiągnięcia dodatkowej stopy zwrotu (słaba forma efektywności). Z kolei w latach 1979 i 1980 ukazały się prace Daniela Kahnemana, Amosa Tverskiego oraz Richarda Thaler. Autorzy w swoich publikacjach uzupełnili teorie ekonomiczne o aspekty psychologiczne i społeczne. Prace te przyczyniły się do szybkiego rozwoju nowego nurtu nazwanego ekonomią behawioralną. Nurt ten w swoich założeniach odbiegał od restrykcyjnych podstaw ekonomii neoklasycznej i wznosił stosowanie przez ludzi heurystyk, czyli skłonności do intuicyjnego oceniania rzeczywistości [Solek, 2010, s. 24–25]. Przedstawiciele ekonomii behawioralnej wyjaśnili wiele anomalii, chociażby te dotyczące skuteczności strategii inwestycyjnych stosowanych na rynkach finansowych [Guerrien, Gun, 2011, s. 27].

W najnowszych opracowaniach coraz częściej można znaleźć wskazania, które potwierdzają możliwość prognozowania zmian aktywów – m.in. przy pomocy systemów uczących się (ang. *machine learning*) [Akyildirim i in., 2021], analizy nastrojów [Khedr i in., 2017], trendów w wyszukiwarkach internetowych [Fan i in., 2021] czy wykorzystując sieci neuronowe [Pang i in., 2020].

Przeprowadzając badania literatury, znajdzie się również rozważania z niejednoznacznymi rezultatami [Dias i in., 2020], z sugestiami, że poziom skuteczności predykcji zależy od przyjętego okresu [Karasiński, 2020] lub, że nieefektywność rynku rośnie podczas nietypowych wydarzeń, takich jak np. pojawienie się pandemii COVID-19 [Evangelos, 2021].

3. Prognozowanie przyszłych stóp zwrotu na polskiej giełdzie papierów wartościowych

Do przeprowadzenia badania przygotowano szereg czasowy składający się z dziennych kursów zamknięcia indeksu WIG. Pierwsza wartość szeregu pochodziła z 3.10.1994 roku (wprowadzenie dziennych notowań na polskiej giełdzie), a ostatnia z 28.04.2023 roku. Na podstawie tych danych oszacowano dzienne logarytmiczne stopy zwrotu. Charakterystyki opisowe dla szeregu wyjściowego i szeregu logarytmicznych stóp zwrotu zaprezentowano w tabeli 1, natomiast wartości szeregu pierwotnego zaprezentowano na wykresie 1.

TABELA 1

Statystyki opisowe dziennych kursów zamknięcia i logarytmicznych stóp zwrotu dla indeksu WIG

Zmienna	Kurs zamknięcia	Logarytmiczna stopa zwrotu
Liczba obserwacji	7 148	7 148
Średnia	37 175	0,00026927
Odchylenie standardowe	18 526	0,014307
Współczynnik zmienności	0,49836	53,134
Skośność	-0,094852	-0,39074
Kurtoza	-1,4016	5,3547
Test Jarque-Bera	595,828*	8 721,59*
Test KPSS (wart. kryt. 5%)	2,19664 > 0,148	0,0834253 < 0,462

* = 1% poziom istotności

Źródło: opracowanie własne.

W celu weryfikacji możliwości występowania jedynie podokresów, w których indeks WIG charakteryzuje się brakiem losowości stóp zwrotu, wyjściowy szereg podzielono na 24-miesięczne nachodzące na siebie podokresy. I tak pierwszy podokres rozpoczynał się 3.10.1994 roku, a kończył 30.09.1996 roku. Kolejny podokres rozpoczynał się 2.11.1994 roku, a kończył 31.10.1996 roku itd. (przesunięcie o jeden miesiąc). Ostatni podokres rozpoczynał się 4.05.2021, a kończył się 28.04.2023 roku. W ten sposób uzyskano 320 podokresów z liczebnością około 500 dziennych logarytmicznych stóp zwrotu.

WYKRES 1

Kurs zamknięcia na koniec dnia indeksu WIG od 3.10.1994 do 28.04.2023



Źródło: opracowanie własne.

Aby sprawdzić, czy na polskiej giełdzie występują zależności pomiędzy kolejnymi stopami zwrotu, a co za tym idzie, czy można wykorzystać wartość stopy zwrotu do prognozy na kolejny dzień, postanowiono wykorzystać test autokorelacji Quenouille'a. Test ten służy m.in. do oceny, czy wartość aktualnej stopy zwrotu zależy od wartości stopy zwrotu z okresu wcześniejszego. Hipoteza zerowa testu wskazuje na brak korelacji między analizowanymi stopami zwrotu, natomiast hipoteza alternatywna zwraca uwagę na występowanie powiązań między obserwacjami. Innymi słowy, odrzucając hipotezę zerową, stwierdza się zależność między stopami zwrotu, więc można z pewnym prawdopodobieństwem oszacować wartość z przyszłości, korzystając z wartości dzisiejszej. Do weryfikacji hipotezy zerowej w teście Quenouille'a stosuje się współczynnik autokorelacji stóp zwrotu dany wzorem [Ku, Seneta, 1996, s. 621–623]:

$$\hat{\rho}(k) = \frac{\sum_{t=1}^{T-k} (R_t - \bar{R}_T)(R_{t-k} - \bar{R}_T)}{\sum_{t=1}^T (R_t - \bar{R}_T)^2},$$

gdzie:

 $\hat{\rho}(k)$ – współczynnik autokorelacji stopnia k ,

T – liczba obserwacji,

R_t – stopa zwrotu w chwili t ,

\bar{R}_T – średnia stopa zwrotu liczona za pomocą formuły: $\bar{R}_T = \frac{1}{T} \sum_{t=1}^T R_t$,


R_{t-k} – stopa zwrotu oddalona wstecz od chwili t o k chwil.

Zakładając prawdziwość hipotezy zerowej w opisywanym teście, statystyka $S = \sqrt{T} \hat{\rho}(k)$ ma asymptotyczny rozkład normalny o parametrach $N(0,1)$. Hipotezę zerową, przy poziomie istotności 5%, dla testu Quenouille'a odrzuca się, gdy wartość bezwzględna statystyki S jest większa od 1,96 (zgodnie z wartością krytyczną odczytaną ze standaryzowanego rozkładu normalnego dla danego poziomu istotności) [Górska, Krawiec, 2017, s. 87].

W opracowaniu zweryfikowano występowanie powiązań pierwszego rzędu (autokorelacja pierwszego rzędu) dla każdego podokresu osobno. Sprawdzone więc, czy wartości sąsiednich stóp zwrotu w danym podokresie są od siebie zależne, czyli czy można na podstawie wartości z danego dnia dokonać istotnej prognozy na kolejny dzień. Wartość bezwzględna statystyki S powyżej 1,96 nakazywała odrzucenie hipotezy zerowej w danym podokresie, co oznaczało, że można było wówczas skutecznie prognozować kolejną stopę zwrotu, korzystając z wartości wcześniejszej. Wartość poniżej 1,96 oznaczała losowy charakter zmian i brak możliwości przewidywania na podstawie opisanej reguły. Otrzymane wyniki dla każdego podokresu przedstawiono na wykresie 2.

WYKRES 2

Wyniki testu autokorelacji 1. rzędu dla poszczególnych podokresów indeksu WIG



Źródło: opracowanie własne.

Analizując wyniki przedstawione na wykresie 2, można stwierdzić, że w początkowych latach przyjętego okresu występowała autokorelacja między dziennymi logarytmicznymi stopami zwrotu (do podokresu zakończony w maju 2000 roku), która z czasem była coraz mniej istotna, aż do sytuacji, gdy zmiany między sąsiednimi obserwacjami zachodziły w sposób losowy. W tym okresie można było skutecznie prognozować przyszłe stopy zwrotu, opierając się na danych z dnia poprzedniego. Przez kolejne lata okresy braku korelacji i stwierdzonych korelacji występowały naprzemiennie. W ostatnich latach (od 2018 roku z jednym wyjątkowym podokresem) zmiany na indeksie WIG zachodzą w sposób losowy, więc nie ma możliwości przewidywania kolejnej stopy zwrotu na podstawie stopy zwrotu z dnia poprzedniego.

Ostatecznie stwierdzono 145 podokresów z istotnymi korelacjami między sąsiednimi stopami zwrotu. Daje to wynik na poziomie 45%. Na tej podstawie pozytywnie zweryfikowano pierwszą hipotezę badawczą: na polskiej giełdzie papierów wartościowych występują okresy współzależności stóp zwrotu.

4. Metody określenia warunków rynkowych

Weryfikacja drugiej hipotezy badawczej wymaga sprawdzenia, czy podokresy stwierdzonych zależności między stopami zwrotu są powiązane z konkretnymi warunkami rynkowymi.

Pierwsza metoda określenia warunków rynkowych polegała na podziale danego szeregu czasowego na okresy wzrostów (hossa) i na okresy spadków (bessa), zgodnie z podejściem zaproponowanym przez Franka Fabozziego i Jacka Clarka Francisa [Fabozzi, Francis, 1977]. Według tych badaczy dany okres należy do hossy, gdy stopa zwrotu w nim osiągnięta jest nieujemna, a do okresu bessy, gdy stopa zwrotu w nim osiągnięta jest ujemna. Takie podejście zapewnia wzajemnie wykluczający się i wyczerpujący podział całej próby na dwa podzbiory. Zalety takiego określenia czynników zewnętrznych to intuicyjność i przejrzystość podziału szeregu czasowego. Wadą natomiast jest ignorowanie występowanie trendów na rynku. W wyniku takiego określenia sytuacji rynkowej otrzymano jeden szereg czasowy zmiennej WIG, w którym okresom wzrostów przypisano wartość 1, a okresom spadków – wartość 0. Liczebność poszczególnych okresów dla takiego podziału przedstawiono w tabeli 2.

TABELA 2

Liczebność podokresów scharakteryzowanych jako poszczególne warunki rynkowe dla zmiennej WIG

Zmienna	Hossa	Bessa	Byk	Niedźwiedź	Normalny
WIG	201	119	82	9	229

Źródło: opracowanie własne.

Aby uwzględnić zjawisko trendów występujących na rynkach finansowych, w pracy przyjęto również drugi rodzaj podziału, zaproponowany przez Aprila Kleina i Jamesa Rosenfelda [Klein, Rosenfeld, 1987]. Dany podokres szeregu wyjściowego został tu przyporządkowany do okresu byka, niedźwiedzia lub okresu normalnego. Zgodnie z tym podejściem konieczne jest wyznaczenie „znaczących ruchów na rynku”. Sytuacja taka występuje, kiedy wartość bezwzględna stopy zwrotu dla danego podokresu jest większa od połowy odchylenia standardowego stóp zwrotu wszystkich podokresów. Jeżeli nierówność taka nie zachodzi, to dany okres zakwalifikowany jest jako okres normalny. W przeciwnym razie, gdy uzyskana stopa zwrotu jest dodatnia, mowa o rynku byka, a gdy jest ujemna – o rynku niedźwiedzia.

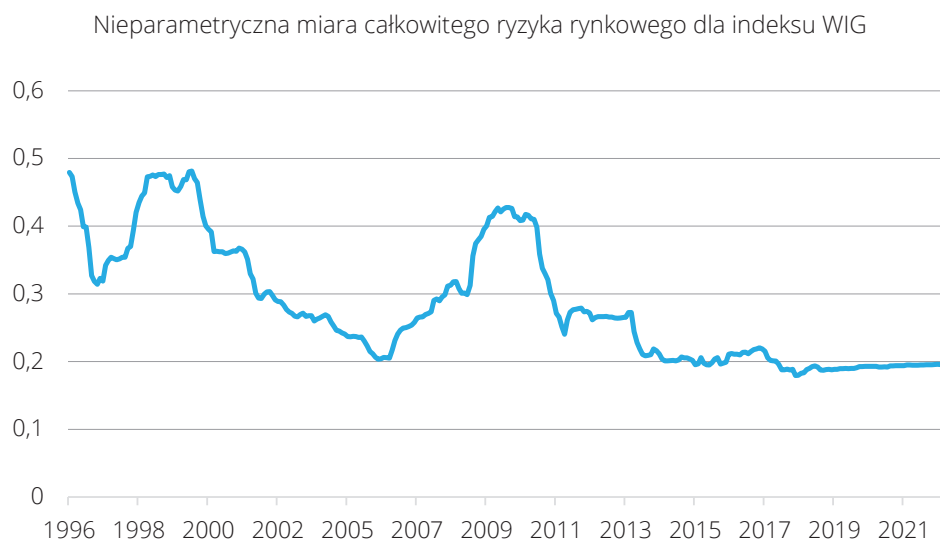
Uwzględniając trendy rynkowe, zauważyć można było podokresy, dla których wyniki trzeba było zmodyfikować. Na przykład jeżeli w jednym okresie rynek znacząco wzrastał, podczas gdy sąsiednie okresy były sklasyfikowane jako normalne, to okres ten został ostatecznie sklasyfikowany jako normalny. Podobnie robiono, jeżeli dany okres wskazywał na występowanie rynku byka lub okresu normalnego, natomiast sąsiednie okresy wskazywały na wystąpienie rynku niedźwiedzia – okres ten również został uznany za okres niedźwiedzia. Z kolei w sytuacji, gdy wyznaczony został okres normalny, a okresy sąsiednie należały do dwóch różnych przyporządkowań, sprawdzono uzyskaną stopę zwrotu i, jeżeli była ona ujemna, zmieniano taki okres na okres niedźwiedzia, a jeżeli dodatnia – na okres byka. Identycznych modyfikacji dokonywali April Klein i James Rosenfeld w swoich badaniach. Ostatecznie każdy wyznaczony trend zgodnie z tą metodą musiał składać się z co najmniej dwóch nieoddzielonych podokresów.

W ten sposób uzyskano trzy szeregi czasowe dla wybranej zmiennej. W pierwszym szeregu wartość 1 przypisano okresom byka, a pozostałym – 0. W drugim szeregu wartość 1 otrzymały okresy niedźwiedzia, a pozostałe – 0. Analogicznie, w ostatnim szeregu wartości 1 otrzymały wyłącznie okresy normalne. Liczebności

poszczególnych podokresów zakwalifikowanych do poszczególnych kategorii, w podziale na zmienne, umieszczono we wcześniej wspomnianej tabeli 2.

Dodatkowo w badaniu postanowiono uwzględnić okresy dynamicznych zmian zachodzących w notowaniach indeksu WIG. Poziom zmienności obliczono jako pierwiastek kwadratowy sumy dziennych stóp zwrotu podniesionych do kwadratu w danym okresie. W literaturze wynik takiego działania określa się jako nieparametryczną miarę całkowitego ryzyka rynkowego [Anderson i in., 2003]. Dla każdego podokresu otrzymano konkretną wartość poziomu zmienności. W odróżnieniu do wcześniej scharakteryzowanych jest to zmienna ciągła. Test Jarque-Bera dla otrzymanej zmiennej nie potwierdził jej rozkładu normalnego (statystyka testowa = 21,91, brak rozkładu normalnego dla 1% poziomu istotności). Przebieg zmiennej przedstawiono na wykresie 3. Na podstawie wykresu można stwierdzić, że całkowite ryzyko rynkowe dla indeksu WIG cechuje się ogólną tendencją malejącą z okresowymi wzrostami.

WYKRES 3



Źródło: opracowanie własne.

Wyznaczając warunki rynkowe, uwzględniono również kryzysy, które wystąpiły w badanym okresie i które miały bezpośredni wpływ na sytuację gospodarczą w Polsce: kryzys rosyjski (08.1998–11.2000) [Chiodo, Owyang, 2002], kryzys finansowy 2007–2009 (09.2007–06.2009) [www 1] oraz kryzys pandemiczno-energetyczny (02.2020–04.2023) [Cheema i in., 2022, s. 3]. Dany podokres

został zakwalifikowany jako kryzysowy, jeżeli co najmniej połowa jego składowych miesięcy była tożsama z wymienionymi wcześniej okresami trwania kryzysu. Taki podział (w przybliżony sposób) pozwoli zweryfikować korelację poziomów statystyki między wystąpieniem dekonjunkury. W ten sposób otrzymano szereg czasowy ze zmiennymi dyskretnymi: 1 – podokres dekonjunkury, 0 – brak dekonjunkury.

Ostatecznie dla zmiennej WIG dla każdego podokresu osobno przypisano rynek hossy lub bessy oraz rynek byka, niedźwiedzia lub rynek normalny. Dodatkowo określono poziom zmienności i występowanie (lub nie) w danym podokresie kryzysu gospodarczego.

5. Metodyka badania i otrzymane wyniki

Określenie warunków rynkowych panujących dla danego podokresu w większości przypadków doprowadziło do uzyskania zmiennych dyskretnych (dany podokres przyporządkowano do zbioru (1) lub nie (0)). Dlatego postanowiono zweryfikować zależność występowania autokorelacji między stopami zwrotu a warunkami rynkowymi, również używając zmiennej dyskretniej. Dla poszczególnych wyników statystyki S przypisano następujące wartości:

- $\langle 0 ; 0,98 \rangle$ przypisano 0,
- $\langle 0,98 ; 1,96 \rangle$ przypisano 1,
- $\langle 1,96 ; 2,94 \rangle$ przypisano 2,
- $\langle 2,94 ; 3,92 \rangle$ przypisano 3,
- $\langle 3,92 ; 4,9 \rangle$ przypisano 4,
- $\langle 4,9 ; 5,88 \rangle$ przypisano 5,
- $\langle 5,88 ; 6,86 \rangle$ przypisano 6,
- $\langle 6,86 ; \infty \rangle$ przypisano 7.

Taki podział stanowi kolejne wielokrotności wartości 1,96, która w przybliżeniu oddziela występowanie powiązań stóp zwrotu od ich braku dla 5% poziomu ufności.

Ze względu na brak normalnego rozkładu obserwacji w dyskretnych szeregach czasowych wykorzystanych w badaniu do sprawdzenia powiązań między nimi zdecydowano się wykorzystać test niezależności χ^2 . Hipotezy w tym teście brzmią następująco:

H0: analizowane cechy są niezależne,

H1: analizowane cechy nie są niezależne.

Statystykę χ^2 oblicza się za pomocą poniższego wzoru, wyznaczając wcześniej tablicę korelacyjną:

$$\chi^2 = \sum_{i=1}^k \sum_{j=1}^l \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}} ij,$$

gdzie:

k – liczba poziomów pierwszej zmiennej,

l – liczba poziomów drugiej zmiennej,

n_{ij} – liczebności rozkładu rzeczywistego,

\hat{n}_{ij} – liczebności rozkładu hipotetycznego.

Zmienna χ^2 ma asymptotyczny rozkład chi-kwadrat o $(k-1)(l-1)$ stopniach swobody i jest miarą rozbieżności między rozkładem hipotetycznym a zaobserwowanym. Co oznacza, że im większa oszacowana wartość χ^2 , tym większe prawdopodobieństwo zależności dwóch cech. Dla przyjętego poziomu istotności α hipotezę zerową odrzuca się, gdy $\chi_{obl.}^2 \geq \chi_{\alpha, (k-1)(l-1)}^2$. Inaczej mówiąc, istnieje wówczas związek między badanymi cechami. Do wykonania testu niezależności wykorzystano program GRETL2017b.

Test niezależności χ^2 wskazuje tylko na ewentualne występowanie związku między cechami. Nie mówi natomiast nic o stopniu wykazanej współzależności. Dlatego też powstało kilka miar, które informują, czy dana korelacja jest silna czy słaba. Najczęściej używanym narzędziem w przypadku tablic wielodzielnych jest współczynnik V Craméra, wyrażany następującym wzorem [Sulewski, 2013, s. 30]:

$$V = \sqrt{\frac{\chi^2}{n(m-1)}},$$

gdzie:

n – liczba obserwacji,

m – mniejsza z wartości k i l .

Wskaźnik ten przyjmuje wartości od 0 (cechy niezależne) do 1 (zależność funkcyjna). Za Piotrem Sulewskim [2013] postanowiono przyjąć następujące przedziały i odpowiadające im poziomy współzależności cech:

- (0 ; 0,33) – niski stopień,
- (0,33 ; 0,66) – średni stopień,
- (0,66 ; 1) – wysoki stopień.

Przy określaniu warunków rynkowych uzyskano również jedną zmienną ciągłą: poziom zmienności, określane również jako całkowite ryzyko rynkowe. W związku z tym do weryfikacji powiązań dla tej zmiennej wykorzystano również zmienną ciągłą, tj. wartości bezwzględne poszczególnych statystyk S dla odpowiednich podokresów. Jako że zmienne te nie charakteryzowały się rozkładem normalnym, do zbadania istotności i siły zależności wykorzystano współczynnik korelacji rho-Spearmana zgodnie z regułą [Jóźwiak, Podgórski, 2012, s. 352–353]:

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)},$$

gdzie:

d_i^2 – różnica między rangami przyporządkowanymi i -tej jednostce w obu ciągach.

Współczynnik ρ przyjmuje wartości od -1 (maksymalna niezgodność rang) do 1 (idealna zgodność rang). Uzyskana wartość 0 oznacza niezależność rang w obu szeregach. Do oceny poziomu współzależności między cechami wykorzystano to samo kryterium co w przypadku testu niezależności χ^2 . W tym celu również wykorzystano program GRETL2017b. Wszystkie wyniki przedstawiono w tabeli 3.

TABELA 3

Liczebność podokresów scharakteryzowanych jako poszczególne warunki rynkowe dla zmiennej WIG

Zmienna	Hossa/ bessa	Byk	Niedźwiedź	Normalny	Kryzys	Zmienność
WIG	0,249 (+) ***	0,327 (+) ***	0,129 (+)	0,321 (-) ***	0,467 (-) ***	0,194 (+) ***

Źródło: opracowanie własne.

Wartość w danej komórce odzwierciedla poziom współzależności cech. Jeżeli pod wartością tą znajdują się co najmniej 3 gwiazdki (***) , to oznacza to istotność statystyczną dla poziomu ufności co najmniej 1%. Plus (+) wskazuje na wzrost wartości bezwzględnej statystyk S w danej sytuacji rynkowej (wzrost skuteczności prognoz), a minus (-) wskazuje na spadek skuteczności prognozowania dziennych stóp zwrotu w danej sytuacji rynkowej. Warto zwrócić jeszcze uwagę na wynik w kolumnie „hossa/bessa”. Wynik tam umieszczony obowiązuje dla podokresów z nieujemną stopą zwrotu. Jednak, jako że szereg uzyskany w wyniku tego podziału

jest wykluczający się, interpretację uzyskuje się również dla okresów z ujemnymi stopami zwrotu (dla rynku bessy). Siła powiązania i istotność statystyczna pozostają wówczas na tym samym poziomie, zmienia się wyłącznie kierunek powiązania na przeciwny.

Interpretując wyniki dla zmiennej WIG można stwierdzić, że dla testu autokorelacji istotna statystycznie zależność między warunkami rynkowymi a poziomami statystyki S występuje dla rynku hossy/bessy, okresu byka i normalnego, dla okresów zmienności oraz w czasie kryzysu. Nieistotne statystycznie powiązania wystąpiły tylko dla okresu niedźwiedzia. Oznacza to, że wyłącznie w okresie niedźwiedzia nie wystąpiło powiązanie między możliwością prognozowania przyszłych stóp zwrotu a warunkiem rynkowym. Dla prawie wszystkich statystycznie istotnych warunków rynkowych stwierdzono niski stopień współzależności między danym warunkiem rynkowym a wartościami statystyki S (wartości z przedziału 0 a 0,33). Wyjątek stanowią jedynie okresy kryzysów – ze średnim stopniem powiązań (0,467). Najniższy istotnie statystyczny stopień powiązań stwierdzono dla okresów zmienności (0,194). Skuteczność prognoz wzrasta w okresach hossy, byka, niedźwiedzia i większej zmienności (znak + w komórce), maleje natomiast w okresach bessy, normalnym i kryzysu (znak - w komórce). Po podsumowaniu otrzymanych wyników w tej części badania hipotezę drugą (okresy występowania współzależności stóp zwrotu są powiązane z warunkami rynkowymi) uznaje się za zweryfikowaną pozytywnie.

6. Podsumowanie

Utworzenie skutecznej strategii inwestycyjnej na rynkach finansowych stanowi przedmiot dociekań, nie tylko świata naukowego, ale również osób, które w sposób bezpośredni kierują swój majątek w zakup aktywów finansowych. Powstało wiele badań, które potwierdzają, negują lub nie dają jednoznacznej odpowiedzi w tej kwestii.

W pierwszej części niniejszego badania wykazano, że na polskiej giełdzie występowały w przeszłości okresy, w których można było skutecznie prognozować następną wartość stopy zwrotu, posługując się wyłącznie wartościami z dnia bieżącego. Największe szanse były na to pod koniec XX wieku, z czasem możliwości te były coraz rzadsze, a w ostatnich latach praktycznie znikły. Z jednej strony, może to świadczyć o rosnącej efektywności polskiej giełdy, a z drugiej – może oznaczać, że potrzeba bardziej wyszukanych metod prognozowania, aby osiągać satysfakcjonujące wyniki inwestycyjne.

Należy podkreślić, że przedstawione badanie ma charakter wstępny, które może posłużyć jako podstawa do kolejnych rozważań. W przyszłości można po-

wtórzyć podobne studia dla wyższych rzędów autokorelacji oraz podzielić przyjęty okres na mniejsze części, gdyż od 1994 roku na polski rynek kapitałowy wpływ miało wiele czynników, jak chociażby przystąpienie do Unii Europejskiej, co wiąże się z różnymi etapami polskiej giełdy.

Wkład pracy to wykazanie różnych metod pozwalających na określenie warunków rynkowych, które później można wykorzystać do oceny skuteczności prognoz, wskazania specyfiki poszczególnych sytuacji czy do podejmowania decyzji inwestycyjnych.

Wszystkie przeprowadzone badania wykonane w ramach tego artykułu pozwoliły wytypować, które warunki rynkowe w przeszłości przyczyniały się do wyznaczania bardziej skutecznych prognoz na polskiej giełdzie. Wartością dodaną opracowania jest wskazanie metod wyznaczania warunków rynkowych oraz określenie ich powiązania z możliwościami prognostycznymi następujących po sobie stóp zwrotu. Obie hipotezy badawcze zostały zweryfikowane pozytywnie. Analiza otrzymanych wyników prowadzi do następujących wskazań: w przeszłości najsukcesowniej decyzje na podstawie bieżącej stopy zwrotu można było podejmować w trakcie hossy, rynku byka i w okres większej zmienności na rynkach (jednak powiązania między autokorelacją a warunkami rynkowymi była niska). Natomiast okresy bessy, normalne i kryzysów nie sprzyjały wyznaczaniu skutecznych prognoz. Zwłaszcza podczas występowania kryzysów wyznaczanie krótkookresowych prognoz było zadaniem trudnym.

Literatura

- Akyildirim E., Goncu A., Sensoy A., 2021, *Prediction of Cryptocurrency Returns Using Machine Learning*, "Ann Oper Res", Vol. 297, pp. 3–36, DOI: 10.1007/s10479-020-03575-y.
- Anderson T.G., Bollerslev T., Diebold F.X., Labys P., 2003, *Modeling and Forecasting Realized Volatility*, "Econometrica", Vol. 71(2), pp. 579–625, DOI: 10.2139/ssrn.267792.
- Cheema M.A., Faff R., Szulczyk K.R., 2022, *The 2008 Global Financial Crisis and COVID-19 Pandemic: How Safe Are the Safe Haven Assets?*, "International Review of Financial Analysis", Vol. 83, pp. 1–13, DOI: 10.1016/j.irfa.2022.102316.
- Chiodo A.J., Owyang M.T., 2002, *A Case Study of a Currency Crisis: The Russian Default of 1998*, "The Federal Reserve Bank of St. Louis", Vol. 84(6), pp. 7–17, DOI: 10.20955/r.84.7-18.
- Dias R., Teixeira N., Machova V., Pardal P., Horak J., Vochozka M., 2020, *Random Walks and Market Efficiency Tests: Evidence on US, Chinese and European Capital Markets Within the Context of the Global COVID-19 Pandemic*, "Oeconomia Copernicana", Vol. 11(4), pp. 585–608, DOI: 10.24136/oc.2020.024.

- Evangelos V., 2021, *Efficient Markets Hypothesis in the Time of COVID-19*, "Review of Economic Analysis", Vol. 13(1), pp. 45–62, DOI: 10.15353/rea.v13i1.1799.
- Fabozzi F.J., Francis J.C., 1977, *Stability Tests for Alphas and Betas Over Bull and Bear Market Conditions*, "The Journal of Finance", Vol. 32(4), pp. 1093–1099, DOI: 10.2307/2326515.
- Fama E.F., 1970, *Efficient Capital Markets: A Review of Theory and Empirical Work*, "The Journal of Finance", Vol. 25(2), pp. 383–417, DOI: 10.2307/2325486.
- Fan M. H., Chen M.Y., Liao E.C., 2021, *A Deep Learning Approach for Financial Market Prediction: Utilization of Google Trends and Keywords*, "Granular Computing", Vol. 6, pp. 207–216, DOI: 10.1007/s41066-019-00181-7.
- Górska A., Krawiec M., 2017, *Analiza efektywności informacyjnej w formie słabej na rynkach „soft commodities” z wykorzystaniem wybranych testów statystycznych*, „Problemy Rolnictwa Światowego”, nr 17(3), s. 81–92, DOI: 10.22630/PRS.2017.17.3.55.
- Guerrien B., Gun O., 2011, *Efficient Market Hypothesis: What Are We Talking About?*, "Real-World Economic Review", Vol. 56, pp. 19–30.
- Jóźwiak J., Podgórski J., 2012, *Statystyka od podstaw*, wyd. VII, Polskie Wydawnictwo Ekonomiczne, Warszawa.
- Karasiński J., 2020, *The Changing Efficiency of the European Stock Markets*, "Annales Universitatis Mariae Curie-Skłodowska, sectio H – Oeconomia", Vol. 54(1), pp. 41–51, DOI:10.17951/h.2020.54.1.41-51.
- Khedr A.E., Salama S.E., Hegazy N.Y., 2017, *Predicting Stock Market Behavior using Data Mining Technique and News Sentiment Analysis*, "International Journal of Intelligent Systems and Applications", Vol. 9(7), pp. 22–30, DOI: 10.5815/ijisa.2017.07.03.
- Klein A., Rosenfeld J., 1987, *The Influence of Market Conditions on Event-Study Residuals*, "The Journal of Financial and Quantitative Analysis", Vol. 22(3), pp. 345–351, DOI: 10.2307/2330968.
- Ku S., Seneta E., 1996, *Quenouille-Type Theorem on Autocorrelation*, "Annals of the Institute of Statistical Mathematics", Vol. 48(4), pp. 621–630, DOI: 10.1007/BF00052323.
- Pang X., Zhou Y., Wang P., Lin W., Chang V., 2020, *An Innovative Neural Network Approach for Stock Market Prediction*, "The Journal Supercomputing", Vol. 76, pp. 2098–2118, DOI: 10.1007/s11227-017-2228-y.
- Smith B.M., 2004, *A History of the Global Stock Market: From Ancient Rome to Silicon Valley*, The University of Chicago Press, Chicago.
- Solek A., 2010, *Ekonomia behawioralna a ekonomia neoklasyczna*, „Zeszyty Naukowe Polskiego Towarzystwa Ekonomicznego”, nr 8, s. 21–34.
- Sulewski P., 2013, *Wielowymiarowe uogólnienie testu niezależności*, „Wiadomości Statystyczne”, nr 58(12), s. 27–41.