

FINANSE, RYNKI FINANSOWE, UBEZPIECZENIA
nr 4/2018 (94), cz. 2
(Zeszyty Naukowe Uniwersytetu Szczecińskiego,
Finanse, Rynki Finansowe, Ubezpieczenia)

RACHUNKOWOŚĆ W ZARZĄDZANIU JEDNOSTKAMI GOSPODARCZYMI

CZĘŚĆ 2

SZCZECIN 2018

Rada naukowa

prof. dr hab. Aldona Kamela-Sowińska – Uniwersytet Ekonomiczny w Poznaniu
prof. dr hab. Zbigniew Luty – Uniwersytet Ekonomiczny we Wrocławiu
prof. dr hab. Sławomir Sojak – Uniwersytet Mikołaja Kopernika w Toruniu
prof. Vasyl Stolyarov – Bukovinian University in Chernivtsi (Ukraina)
prof. Rodica Zaharia – Academy of Economic Studies in Bucharest (Rumunia)
dr hab. Krystyna Żołądkiewicz prof. UG – Uniwersytet Gdański

Lista recenzentów znajduje się na stronie internetowej czasopisma:
www.wneiz.pl/frfu

Redaktor naczelny | prof. dr hab. Waldemar Gos

Redaktorzy naukowci | dr hab. Sebastian Majewski prof. US, dr Urszula Gierałtowska

Redaktor statystyczny | dr Anna Gdakowicz

Korekta | Medium Art

Skład komputerowy | Marcin Kaczyński

Projekt okładki | Joanna Dubois-Mosora

Wersja papierowa jest wersją pierwotną

Wszystkie numery czasopisma dostępne są w internecie
www.wneiz.pl/frfu/numery

Czasopismo jest indeksowane w: BazEkon (www.kangur.uek.krakow.pl/bazy_ae/bazekon/nowy/index.php)
BazHum, The Central and Eastern European Online Library (CEEOL)

© Copyright by Uniwersytet Szczeciński, Szczecin 2018

ISSN 2450-7741

(ISSN 1640-6818; 1733-2842)

WYDAWNICTWO NAUKOWE UNIwersYTETU SZCZecińskiego

Wydanie I. Ark. wyd. 8,5. Ark. druk. 9,7. Format B5. Nakład 126 egz.

Spis treści

Krzysztof Borowski – Wykorzystanie barometru stycznia i grudnia na przykładzie 88 spółek notowanych na GPW Warszawie	5
Leszek Czapiewski – Efekt <i>momentum</i> na GPW w Warszawie w latach 1995–2015	19
Urszula Gierałtowska – Inwestycje kolekcjonerskie. Analiza inwestycji na rynku win	37
Ireneusz Miciuła, Monika Różycka – Stan rynku kryptowalut w Polsce na tle światowego rozwoju	49
Artur Paździor, Grzegorz Kłosowski – Prognozowanie kursu bitcoina z wykorzystaniem sztucznej sieci neuronowej	61
Grzegorz Przekota, Jerzy Rembeza – Powiązania długookresowych stóp procentowych w krajach Unii Europejskiej	75
Anna Rapacewicz – Analiza związków między datą rozegrania spotkania a stopą zwrotu z akcji spółek giełdowych zaangażowanych w sponsoring sportowy	91
Maciej Stradomski, Mateusz Mikutowski – Efekty kalendarzowe polskich rodzinnych spółek giełdowych	103
Anna Szczepańska-Przekota – Ocena zastosowania zagranicznych kontraktów terminowych w zarządzaniu ryzykiem cenowym na rynku pszenicy w Polsce	113
Ryszard Węgrzyn – Analiza porównawcza kształtowania się indeksów akcji na świecie po kryzysie finansowym	125
Ilona Żelazowska – Efekt barometru stycznia w funduszach inwestycyjnych akcji jako przykład anomalii sezonowych na rynkach kapitałowych	143

Wykorzystanie barometru stycznia i grudnia na przykładzie 88 spółek notowanych na GPW Warszawie

Krzysztof Borowski*

Streszczenie: *Cel* – Celem badania jest przeprowadzenie weryfikacji skuteczności stosowania tzw. barometru miesiąca (grudnia i stycznia) na przykładzie miesięcznych stóp zwrotu 88 cen akcji notowanych na GPW w Warszawie.

Metoda badania – Metoda została zaproponowana przez Dzhabarova i Ziembę i opiera się na analizie zależności występujących między miesięcznymi stopami zwrotu w miesiącu grudniu (i styczniu) a skumulowaną miesięczną stopą zwrotu w ciągu 11 miesięcy następujących po nim. Zależność tę wyraża się za pomocą regresji liniowej. Analizę przeprowadzono dla arytmetycznych i logarytmicznych stóp zwrotu w miesiącu grudniu i styczniu w trzech grupach: dla wszystkich stop zwrotu (dodatnich, ujemnych i równych zero), dla dodatnich i równych zero miesięcznych stóp zwrotu i dla ujemnych miesięcznych stóp zwrotu.

Wynik – Uzyskane wyniki wskazują na niską skuteczność tej metody na GPW w Warszawie poza przypadkami kilku spółek.

Oryginalność/wartość – Jest to jedno z nielicznych znanych autorowi badań na rynku polskim.

Słowa kluczowe: rynek finansowy, anomalie kalendarzowe, efektywność rynku

Wprowadzenie

Zagadnienie efektywności rynków finansowych wciąż cieszy się dużym zainteresowaniem badaczy, zwłaszcza kwestia występowania tzw. anomalii, tj. zachowań rynku, które przeczyłyby teorii efektywności rynków finansowych. Szczególnie często podejmowanym tematem są anomalie kalendarzowe, wśród których najbardziej popularne jest występowanie tzw. efektu stycznia i efektu grudnia, zgodnie z którymi w styczniu (lub grudniu) średnia miesięczna stopa zwrotu jest statystycznie różna od średniej miesięcznej stopy zwrotu w pozostałych miesiącach roku. Udowodnienie występowania efektu stycznia pozwala na stworzenie stosunkowo prostej strategii inwestycyjnej, dzięki której możliwe jest uzyskiwanie nadwyżkowych stóp zwrotu. Do tzw. efektów kalendarzowych zalicza się także tzw. barometr stycznia. W tym wypadku bada się zależności między miesięcznymi stopami zwrotu, jakie występują w miesiącu styczniu, a skumulowaną stopą zwrotu w ciągu

* dr hab. K. Borowski, Szkoła Główna Handlowa, Instytut Ryzyka i Rynków Finansowych, e-mail: Krzysztof.borowski@sgh.waw.pl.

11 miesięcy następujących po danym miesiącu. Podejście to można zapisać w uproszczonej wersji w formie: jaki styczeń, taki cały rok.

Celem artykułu jest zbadanie zależności między miesięcznymi stopami zwrotu w miesiącu styczniu i grudniu oraz miesięcznymi stopami zwrotu występującymi w ciągu 11 miesięcy następującymi po każdym z tych miesięcy, na przykładzie 88 cen akcji notowanych na GPW w Warszawie, przy założeniu, że pierwsze notowanie analizowanej spółki miało miejsce przed 1 stycznia 2000 roku i że w chwili przeprowadzenia badania (maj 2018 r.) akcje tej firmy wciąż znajdowały się w obrocie giełdowym. W badaniu wykorzystano ceny zamknięcia analizowanych spółek na ostatniej sesji w poszczególnych miesiącach – dane pochodzą ze strony internetowej Domu Maklerskiego BOŚ (<http://bossa.pl>). Zestawienie analizowanych akcji zamieszczono w tabeli 4; znajduje się w niej również data ostatniego dnia miesiąca, w którym akcje spółki zadebiutowały na giełdzie. Ostatnią sesją uwzględnioną w badaniu jest sesja z 31 stycznia 2018 roku.

1. Literatura przedmiotu

Opublikowanie przez Famę (1965) teorii efektywności rynków finansowych zapoczątkowało proces prowadzenia badań nad występowaniem anomalii kalendarzowych. Do pierwszych tego typu prac zaliczyć można prace Lakonishoka i Smidta (1988), Thaler (1992, s. 23–25) oraz Ziemby (1994) czy też bardziej współczesne: Keima i Ziemby (2000, s. 1–13), Hirscha i Hirscha (2011, 33–49) oraz Verheydena, De Moora i Van den Bossche’a (2013). Z kolei Dimson i Mussavian (1998) zamieścili przegląd badań oraz stosowanych metod, zaś Malkiel (2003, 2005) dokonał krytyki hipotezy rynku efektywnego. Badania poświęcone występowaniu efektu stycznia prowadzone były również na rynku polskim, m.in. przez Marianowską, Szerszyńską i Szymańskiego (2016, s. 35–48).

Rozeff i Kinney (1976) wykazali, że miesięczne stopy zwrotu indeksów giełdowych publikowanych przez New York Stock Exchange w latach 1904–1974, obliczone dla stycznia, były dodatnie, przy czym różnica ta w stosunku do innych miesięcy była statystycznie istotna. Keim (1983) udowodnił, że około połowa wartości rocznych stóp zwrotu cen akcji na giełdzie amerykańskiej w okresie 1963–1974 była udziałem stóp zwrotu w miesiącu styczniu. Hensel i Ziemba (1995) wykazali, że w okresie 1940–1993, kiedy stopa zwrotu indeksu S&P 500 w miesiącu styczniu była ujemna, skumulowana stopa zwrotu w ciągu pozostałych 11 miesięcy roku była również ujemna. Zależność ta była jeszcze silniejsza, kiedy stopa zwrotu w styczniu była dodatnia. Podobne wyniki zostały przedstawione wcześniej przez Ziembę (1994). Haug i Hirschey (2006) udowodnili, że w wypadku spółek o małej kapitalizacji średnia przeciętna stopa zwrotu w miesiącu styczniu zmienia się wraz z upływem czasu, przybierając lub też tracąc na sile. Zdaniem Rendona i Ziemby (2007) efekt stycznia wciąż jest obecny na rynkach kapitałowych, jednak znaczna część zwwyżek cen akcji dawniej obserwowanych w styczniu ma miejsce w grudniu (efekt grudnia). Z kolei Easterday, Sen i Stephan (2008), na podstawie analizy stóp zwrotu w okresie 1963–1979, wcześniejszym niż rok 1963 i późniejszym niż 1979 (kończąc na 2007 r.), doszli do wniosku, że występo-

wanie efektu stycznia nie słabnie na przestrzeni lat, a w wypadku spółek o małej i średniej kapitalizacji przybiera na sile. Bronson (2012) udowodnił, że w sześciu przypadkach, mimo dodatniej stopy zwrotu w miesiącu styczniu, stopa zwrotu w ciągu następnych 11 miesięcy była ujemna (w okresie 1940–2010). Taka sytuacja miała miejsce w następujących latach: 1946, 1947, 1966, 1987, 1994 i 2001. Z kolei ujemna stopa zwrotu w styczniu poprzedziła w 11 przypadkach dodatnie stopy zwrotu w pozostałych miesiącach roku.

W pracach niektórych autorów mówi się o tzw. barometrze stycznia. Według nich znak stopy zwrotu w styczniu (dodatnia lub ujemna) stanowi wyznacznik kierunku trendu na rynku akcji w kolejnych jedenastu miesiącach (Hirsch, 1986, s. 23–43). Kiedy stopa zwrotu w styczniu była dodatnia, skumulowana stopa zwrotu liczona dla pozostałych miesięcy również będzie dodatnia, a gdy stopa zwrotu w pierwszym miesiącu roku jest ujemna, wtedy stopa zwrotu dla pozostałych miesięcy jest ujemna lub bliska zera. W 2011 roku Hirsch i Hirsch (2011, s. 23–39) zaproponowali, aby w kalkulacjach uwzględniać nie stopę zwrotu w ciągu kolejnych 11 miesięcy, ale w ciągu 12 miesięcy, po styczniu.

Brown i Luo (2006) zaprezentowali użyteczność stosowania metody barometru styczniowego w USA w latach 1941–2003. Autorzy analizowali stopy zwrotu dla każdego miesiąca roku i kolejnych jedenastu po nim następujących. Ich zdaniem barometr stycznia sprawdzał się lepiej, kiedy stopa zwrotu w styczniu była ujemna, co doprowadziło do wypracowania przez autorów strategii, zgodnie z którą, jeśli miesięczna stopa zwrotu w styczniu jest ujemna, inwestorzy powinni pozostawać poza rynkiem, a w wypadku gdy miesięczna stopa zwrotu w styczniu jest dodatnia, nie powinni na tej podstawie prognozować wzrostów w ciągu następnych jedenastu miesięcy. Jednak zadaniem Stiversa, Suna i Suna (2009) znaczenie tej metody w wypadku indeksów giełd amerykańskich zmniejsza się wraz z upływem czasu, głównie od 1970 roku. Badanie Sturma (2009), obejmujące stopy zwrotu cen akcji z okresu 1940–2006, dowiodło, że metoda barometru styczniowego jest szczególnie efektywna w pierwszym i ostatnim roku cyklu prezydenckiego w USA, podczas gdy w roku drugim i trzecim cyklu efekt barometru stycznia nie został odnotowany. Cooper, McConnel i Ovtchinnikov (2006), analizując indeks CRSP w okresie 1940–2003, udowodnili, że gdy styczniowa stopa zwrotu jest dodatnia (ujemna), wtedy średnia stopa zwrotu w ciągu kolejnych jedenastu miesięcy wynosi 14,8% (2,92%), co pozwoliło im wyciągnąć wniosek, że stopa zwrotu w styczniu jest dobrym prognostykiem stóp zwrotu w kolejnych jedenastu miesiącach. Prawidłowość ta dotyczy zarówno spółek o dużej, jak i średniej kapitalizacji, a także spółek typu *growth* i *value*.

Występowanie efektu barometru stycznia zostało udowodnione również na giełdach europejskich, na których, podobnie jak zostało to wcześniej wykazane w USA, wartość prognostyczna dodatnich stóp zwrotu w styczniu była zdecydowanie silniejsza niż ujemnych (Hensel, Ziemba, 1995; Easton, Pinder, 2007). Imhof i Brusa dokonali analizy stóp zwrotu cen akcji w USA, Australii, Niemczech, Hongkongu, Japonii i Szwajcarii, dochodząc do wniosku, że gdy styczniowe stopy zwrotu w styczniu są dodatnie na wszystkich rynkach z wyłączeniem USA, wówczas skumulowana stopa zwrotu w ciągu pozostałych jedenastu miesięcy jest również dodatnia. Ujemne stopy zwrotu w styczniu zapowiadały skumulowaną stopę zwrotu równą w przybliżeniu zero w ciągu pozostałych jedenastu miesięcy na ana-

lizowanych rynkach (Imhof, Brusa, 2008). Brusa dokonał analizy stóp zwrotu wybranych indeksów giełdowych USA oraz 30 spółek przemysłowych w okresie 1940–2008, dowodząc, że efekt barometru stycznia obecny jest zarówno dla indeksów szerokiego rynku, jak i dla indeksów branżowych. Jednak występowanie tego efektu stało się słabsze dla pewnej grupy indeksów branżowych (Brusa, 2009). Tymczasem Bohl i Salm (2010), którzy przeanalizowali występowanie efektu barometru na giełdach w 19 krajach, dowiedli, że o ile był on dobrze widoczny w USA, Norwegii i Szwajcarii, o tyle w pozostałych 16 krajach (w tym w Japonii, Francji, Hiszpanii i Niemczech) nie stanowił dobrego narzędzia prognostycznego. System transakcyjny oparty na wskazaniach barometru stycznia został zaproponowany przez Kaepfela (2009, s. 38–42).

Easton i Pinder (2007), na podstawie analizy stóp zwrotu akcji w USA i 38 innych rynków akcji z okresu 1940–2003, doszli do wniosku, że możliwość prognozowania stóp zwrotu w ciągu jedenastu miesięcy występujących po styczniu ograniczała się głównie do nadwyżkowych stóp zwrotu, a dla okresu 1973–2003 była mocno ograniczona. Autorzy zakwestionowali sprawdzalność barometru stycznia na innych rynkach niż amerykański. Z kolei Marshall i Visaltanachoti (2010) podważyli przydatność barometru stycznia na podstawie badania stóp zwrotu na 22 rynkach akcji, w tym na rynku amerykańskim. Zastosowanie strategii inwestycyjnej bazującej na barometrze stycznia generowało podobne stopy zwrotu, co wykorzystanie strategii opartej na barometrze listopada i grudnia, jednak niższe stopy zwrotu niż strategia „kup i trzymaj”. W swoich rozważaniach autorzy ci koncentrowali się na stopie zwrotu skorygowanej o czynnik ryzyka. Występowanie barometru stycznia dla indeksu giełdy indyjskiej NSE CNX 500 w okresie od 7.06.1999 do 30.06.2012 zostało zakwestionowane przez Patela (2014).

Dzhabarov i Ziemba (2011) udowodnili, że o ile dodatnia stopa zwrotu w styczniu może być dobrym prognostykiem, o tyle przy ujemnej stopie zwrotu w wielu wypadkach skumulowana stopa zwrotu w pozostałych miesiącach nie musi być negatywna. Autorzy badali model regresji liniowej, w którym zmienną niezależną była stopa zwrotu w styczniu, a zmienną zależną – stopa zwrotu w pozostałych miesiącach roku dla indeksu S&P 500 w okresie 1940–2010. Autorzy badali wartość współczynnika R^2 dla wszystkich otrzymanych stóp zwrotu w styczniu (dodatnich i ujemnych) oraz oddzielnie dla dodatnich i ujemnych stóp zwrotu w pierwszym miesiącu roku. Współczynniki R^2 dla przedstawionych modeli były równe odpowiednio: 6,7%, 0,5% i 7,2%.

2. Metodyka badania

Zależność między miesięczną stopą zwrotu w grudniu (i styczniu) a skumulowaną stopą zwrotu w ciągu jedenastu miesięcy następujących po nim wyrażona jest za pomocą regresji liniowej (Dzhabarov, Ziemba, 2011, s. 216):

$$ROY = \alpha + \beta \cdot R_j + \varepsilon,$$

gdzie:

R_j – miesięczna stopa zwrotu w analizowanym miesiącu (grudniu lub styczniu),

ROY – skumulowana stopa zwrotu dla 11 miesięcy następujących po analizowanym miesiącu,

α, β – współczynniki regresji,

ε – błąd dopasowania.

Analizę przeprowadzono dla arytmetycznych i logarytmicznych stóp zwrotu dla następujących przypadków:

- łącznie dla wszystkich stop zwrotu (dodatnich, ujemnych i równych zero R_j) w grudniu (styczniu),
- dla dodatnich i równych zero miesięcznych stóp zwrotu w grudniu (styczniu), tj. $R_j \geq 0$,
- dla ujemnych miesięcznych stóp zwrotu w grudniu (styczniu), tj. $R_j < 0$.

3. Analiza wyników

Otrzymane wyniki zaprezentowano z podziałem na dwie arytmetyczne i logarytmiczne stopy zwrotu.

3.1. Arytmetyczne stopy zwrotu

Uzyskane wyniki dla analizowanych akcji zamieszczono w tabeli 4. W grudniu najniższą wartość współczynnika R^2 (dodatnie, ujemne i równe zero stopy zwrotu R_j) odnotowano dla następujących akcji (w nawiasie podano jego wartość): CD Projekt, INGBS, Kruszwica i Żywiec (dla wszystkich spółek wartość współczynnika R^2 była równa 0), a najwyższą dla Alty (0,5071), TIM (0,3402) i Pekao (0,2852). Z kolei dla stycznia najniższą wartość współczynnika R^2 była udziałem następujących spółek: Kompa, PKN Orlen i TIM (dla wszystkich indeksów równa 0,0000), a najwyższą dla Polnordu (0,4227), Kopexu (0,3563) i Instal Kraków (0,2989).

Dla ujemnych stóp zwrotu w grudniu najniższe wartości współczynników R^2 uzyskano dla spółek: BBI Development, Amica, Impexmetal i Cognor (we wszystkich przypadkach wartość R^2 była równa 0), a najwyższe dla: Ulmy (0,9602), Comarcha (0,8484) i Rafako (0,7393). Dla dodatnich stóp zwrotu w grudniu wartości współczynników dopasowania R^2 były najniższe dla: Tritonu (0,0000), Polimexu Mostostal (0,0000) i Orange (0,0001), a najwyższe dla Alty (0,8059), Muzy (0,5602) i Protektora (0,5166).

Dla ujemnych stóp zwrotu w styczniu najniższe wartości współczynników R^2 uzyskano dla spółek: Pfeiderer (0,0001), Forte (0,0003) i Novita (0,0004), a najwyższe dla Sanwilu (0,7622), Orange (0,6728) i Enapu (0,5128). Dla dodatnich stóp zwrotu w styczniu wartości współczynników dopasowania R^2 były najniższe dla Efektu (0,0000), Dębicy (0,0000) i Rafako (0,0002), a najwyższe dla Instal Kraków (0,6742), Polnordu (0,6077) i Krezusa (0,4726).

3.2. Logarytmiczne stopy zwrotu

W grudniu najniższą wartość współczynnika R^2 (dodatnie, ujemne i równe zero stopy zwrotu R_j) otrzymano dla następujących akcji: Impexmetal, Żywiec i CD Projekt (dla wszystkich spółek wartość współczynnika R^2 była równa 0), a najwyższą dla Alty (0,3669), BOS (0,2815) i Pekao (0,2501). W styczniu najniższą wartość współczynnika R^2 obliczono dla spółek: PolimexMS (0,0000), Odlewnie (0,0002) i TIM (0,0002), a najwyższą dla KCI (0,5343), Kopexu (0,3382) i Tritona (0,2570).

Dla ujemnych stóp zwrotu w grudniu najniższe wartości współczynników R^2 otrzymano dla spółek: Suwary (0,0000), Best (0,0002) i Impexmetal (0,0002), a najwyższe dla Ulmy (0,9229), Comarcha (0,8514) i CNT (0,5685). Dla dodatnich stóp zwrotu w grudniu wartości współczynników dopasowania R^2 były najniższe dla Ulmy, Atlantisu i Polimexu MS (dla wszystkich spółek wartość współczynnika R^2 była równa 0), a najwyższe dla Alty (0,7016), TIM-u (0,5376) i PMPG (0,4541).

Dla ujemnych stóp zwrotu w styczniu najniższe wartości współczynników R^2 uzyskano dla spółek: MDI Energia (0,0000), Imperia (0,0001) i Ropczyce (0,0002), a najwyższe dla KCI (0,8927), Impexmetal (0,7514) i Orange (0,7256). Dla dodatnich stóp zwrotu w styczniu wartości współczynników dopasowania R^2 były najniższe dla następujących spółek: Colian, Assecopol i Mostostal Zabrze (dla wszystkich spółek wartość współczynnika R^2 była równa 0), a najwyższe dla spółek Instal Kraków (0,5863), Orbis (0,5223) i Efekt (0,4376).

Tabela 1

Częstości współczynników R^2 przy wykorzystywaniu wszystkich stóp zwrotu, jedynie dodatnich i jedynie ujemnych stóp zwrotu w grudniu i styczniu

Przedział	Wszystkie stopy zwrotu		Grudzień		Styczeń	
	grudzień (%)	styczeń (%)	ujemne (%)	dodatnie (%)	ujemne (%)	dodatnie (%)
0–0,1	71,59	71,59	61,36	57,95	43,18	60,23
0,1–0,2	20,45	20,45	19,32	21,59	26,14	17,05
0,2–0,3	6,82	6,82	6,82	12,50	15,91	11,36
0,3–0,4	1,14	1,14	5,68	2,27	3,41	6,82
0,4–0,5	0,00	0,00	1,14	3,41	5,68	2,27
0,5–0,6	0,00	0,00	3,41	1,14	1,14	2,27
0,6–0,7	0,00	0,00	0,00	0,00	1,14	0,00
0,7–0,8	0,00	0,00	0,00	1,14	2,27	0,00
0,8–0,9	0,00	0,00	1,14	0,00	1,14	0,00
0,9–1,0	0,00	0,00	1,14	0,00	0,00	0,00

Źródło: opracowanie własne.

W wypadku posługiwania się zarówno dodatnimi, jak i ujemnymi stopami zwrotu, przeważający odsetek współczynników R^2 należy do przedziału od 0–0,5. Liczbę przypadków i odsetek występowania współczynników R^2 większych niż 0,5 zamieszczono w tabeli 3.

Przy arytmetycznych stopach zwrotu najwyższy odsetek odnotowano, gdy analizowane były ujemne stopy zwrotu w tym miesiącu (4,55%). Z kolei dla logarytmicznych stóp zwrotu, gdy brane były pod uwagę ujemne stopy zwrotu w grudniu i styczniu, odsetek ten wyniósł 5,68%. Zarówno dla grudnia jak i stycznia odsetek wartości R^2 większych niż 0,5 był wyższy dla ujemnych niż dla dodatnich stóp zwrotu. Wartości współczynników R^2 większe niż 0,6 należą do rzadkości: grudzień – jedynie ujemne stopy zwrotu (łącznie 2,28%), grudzień – jedynie dodatnie stopy zwrotu (1,14%) oraz styczeń – jedynie ujemne stopy zwrotu (łącznie 4,55%). W styczniowych, wyłącznie dodatnich stopach zwrotu, nie odnotowano żadnego przypadku, kiedy współczynnik R^2 był wyższy od 0,6.

Tabela 2

Ilość i odsetek przypadków gdy R^2 jest większe niż 0,5

Arytmetyczne stopy zwrotu						
	grudzień łącznie	styczeń łącznie	grudzień – ujemne stopy zwrotu	grudzień – dodatnie stopy zwrotu	styczeń – ujemne stopy zwrotu	styczeń – dodatnie stopy zwrotu
Ilość przypadków gdy $R^2 > 0,5$	1	0	4	3	3	2
Odsetek przypadków gdy $R^2 > 0,5$	1,14%	0,00%	4,55%	3,41%	3,41%	2,27%
Logarytmiczne stopy zwrotu						
Ilość przypadków gdy $R^2 > 0,5$	0	1	5	2	5	2
Odsetek przypadków gdy $R^2 > 0,5$	0,00%	1,14%	5,68%	2,27%	5,68%	2,27%

Źródło: opracowanie własne.

Tabela 3

Mediana współczynników R^2 w stosowanym modelu

Arytmetyczne stopy zwrotu						
	grudzień łącznie	styczeń łącznie	grudzień – ujemne stopy zwrotu	grudzień – dodatnie stopy zwrotu	styczeń – ujemne stopy zwrotu	styczeń – dodatnie stopy zwrotu
Mediana	0,0306	0,0236	0,0521	0,0663	0,1063	0,0690
Logarytmiczne stopy zwrotu						
Mediana	0,0429	0,0360	0,0594	0,0668	0,1289	0,0700

Źródło: opracowanie własne.

Analiza median dla obliczonych współczynników R^2 wskazuje, że w czterech przypadkach były one większe dla miesiąca stycznia niż grudnia – dotyczy to analizowania oddzielnie ujemnych i dodatnich stóp zwrotu w każdym z tych miesięcy. Z kolei gdy stopy zwrotu były analizowane razem, wartości median współczynników R^2 były wyższe dla grudnia niż dla stycznia.

Tabela 4

Wartości współczynników R^2 , alfa i beta dla analizowanych spółek – barometr grudnia, arytmetyczne stopy zwrotu

Spółka	Data pierwszego miesiaca	Współczynnik beta	Wyraz wolny (alfa)	Błąd wyrazu współczynniku beta	Błąd wyrazu wolnego	Współczynnik R^2	Średni błąd	Statystyka F	SS regresja	SS składnik losowy
1	2	3	4	5	6	7	8	9	10	11
Agora	1999-05-31	0,7484	0,0226	0,7006	0,0867	0,0629	0,3776	1,1411	0,1627	2,4239
Alchemia	1998-05-29	0,5257	0,0620	0,9854	0,2139	0,0165	0,8343	0,2846	0,1981	11,8337
Alta	1999-01-29	3,2227	0,1607	0,7707	0,1656	0,5071	0,7168	17,4868	8,9857	8,7355
Amica	1997-09-30	2,1808	0,1126	1,4604	0,1373	0,1102	0,5886	2,2299	0,7725	6,2362
Aparator	1997-04-30	-0,5549	0,2459	1,2635	0,1216	0,0106	0,5286	0,1929	0,0539	5,0287
Asseccopol	1998-06-30	0,6414	0,0305	1,2593	0,1058	0,0150	0,4228	0,2594	0,0464	3,0387
Atlantis	1997-06-30	0,7081	0,0263	1,0132	0,1390	0,0264	0,5846	0,4884	0,1669	6,1507
Awbud	1998-06-30	2,2374	0,1692	1,2822	0,1443	0,1519	0,5839	3,0448	1,0380	5,7953
BBi Development	1997-06-30	0,6516	-0,1114	0,6984	0,0887	0,0461	0,3964	0,8705	0,1368	2,8290
Będzin	1998-12-31	-2,3680	0,2692	1,6607	0,2444	0,1128	0,9852	2,0333	1,9735	15,5297
Best	1997-05-30	-1,0870	0,6225	2,5261	0,3058	0,0114	1,1521	0,1852	0,2458	21,2364
Boryszew	1996-05-31	4,0293	0,5238	2,4036	0,3214	0,1289	1,4699	2,8103	6,0715	41,0488
BOS	1997-02-28	1,3626	-0,0445	0,6226	0,0577	0,2102	0,2573	4,7897	0,3172	1,1919
Budimex	1995-05-31	-0,1658	0,1564	0,8155	0,0775	0,0021	0,3635	0,0413	0,0055	2,6424
Bytom	1994-12-22	-1,5015	0,3584	1,5315	0,2508	0,0459	1,1715	0,9613	1,3193	27,4493
BZW BK	1993-06-29	-1,5262	0,2688	1,1056	0,1350	0,0797	0,5692	1,9057	0,6174	7,1275
CD Projekt	1994-08-31	0,0350	0,2726	1,1489	0,1473	0,0000	0,6800	0,0009	0,0004	9,2489
CNT	1998-11-30	7,0854	1,6285	7,3451	1,3896	0,0519	5,9707	0,9305	33,1725	606,0352
Cognor	1997-03-27	1,3180	0,2236	1,6370	0,2521	0,0348	1,1238	0,6482	0,8186	22,7328

1	2	3	4	5	6	7	8	9	10	11
Colian	1995-05-31	1,1484	0,1822	1,4470	0,1340	0,0305	0,6147	0,6298	0,2379	7,5559
Comarch	1999-03-31	-1,6906	0,2406	1,4419	0,1677	0,0791	0,6367	1,3746	0,5572	6,4860
Dębica	1994-11-30	-2,0684	0,2223	1,5526	0,1231	0,0779	0,5130	1,7747	0,4671	5,5273
Echo	1996-03-29	-0,4153	0,1668	1,1614	0,1219	0,0067	0,5375	0,1279	0,0370	5,4897
Efekt	1993-04-29	-0,4006	0,0738	0,6783	0,0858	0,0156	0,4200	0,3488	0,0615	3,8812
Elbudowa	1996-02-29	-0,7780	0,1310	1,6865	0,1258	0,0111	0,5746	0,2128	0,0702	6,2723
Elzab	1998-05-29	2,5621	0,3856	2,3309	0,2150	0,0664	0,9062	1,2082	0,9921	13,9595
ENAP	1997-08-29	1,0952	0,0464	0,5999	0,1171	0,1562	0,5173	3,3326	0,8917	4,8163
Ferrum	1997-06-30	-1,9624	0,3385	2,1877	0,2929	0,0428	1,2805	0,8046	1,3193	29,5128
Forte	1996-07-31	0,8613	0,2520	1,9454	0,1693	0,0102	0,7752	0,1960	0,1178	11,4180
Groclin	1998-11-30	-0,3186	0,3567	2,5322	0,3069	0,0009	1,2525	0,0158	0,0248	26,6705
Handlowy	1997-06-30	0,4772	0,0159	0,9397	0,0684	0,0141	0,2690	0,2579	0,0187	1,3025
Hydrotor	1998-03-31	2,0468	0,1948	1,2945	0,1245	0,1282	0,5428	2,5002	0,7366	5,0085
Imperia	1997-06-30	-0,7999	0,0071	2,4352	0,1807	0,0060	0,8070	0,1079	0,0703	11,7221
Impexmetal	1997-06-30	-0,1689	0,3378	2,5763	0,2343	0,0002	1,0455	0,0043	0,0047	19,6749
Indykpol	1994-10-28	-1,5677	0,2501	1,1592	0,1493	0,0801	0,7140	1,8288	0,9322	10,7044
ING BS	1994-01-31	-0,0248	0,1404	0,9475	0,0745	0,0000	0,3278	0,0007	0,0001	2,2571
Instal Kraków	1999-04-30	-0,3703	0,2561	2,3702	0,2318	0,0016	0,9220	0,0244	0,0208	12,7525
KCI	1998-01-30	-2,1749	0,2913	3,5354	0,4770	0,0231	1,9317	0,3785	1,4123	59,7063
Kety	1996-01-31	-1,7742	0,2187	0,8725	0,0995	0,1787	0,4036	4,1353	0,6735	3,0942
KGHM	1997-07-31	-0,7279	0,2765	1,5271	0,1695	0,0125	0,7582	0,2272	0,1306	10,3480
Kompap	1996-11-29	-1,0734	0,0076	0,7423	0,0851	0,0991	0,3794	2,0907	0,3009	2,7347
Kopex	1998-06-30	1,9402	0,3613	2,6421	0,3372	0,0307	1,4672	0,5392	1,1608	36,5957
Krezus	1997-06-30	0,6085	0,1598	0,9513	0,1712	0,0222	0,7594	0,4091	0,2360	10,3814
Kruszwica	1997-01-31	0,0138	0,3017	2,0390	0,2348	0,0000	1,0477	0,0000	0,0001	19,7594
Lentex	1997-05-30	-3,1656	0,2699	1,6913	0,1701	0,1629	0,6678	3,5032	1,5624	8,0278

1	2	3	4	5	6	7	8	9	10	11
Lubawa	1996-11-29	1,5752	0,2677	1,6525	0,1659	0,0456	0,7287	0,9086	0,4825	10,0891
mBank	1992-10-29	-1,0136	0,4640	2,0827	0,2960	0,0102	1,3897	0,2369	0,4575	44,4220
MDI Energia	1997-06-30	0,0758	-0,0288	0,9043	0,1975	0,0004	0,8713	0,0070	0,0053	13,6641
Mennica	1998-04-30	2,0146	0,1158	1,3702	0,1216	0,1128	0,4735	2,1617	0,4846	3,8110
Millennium	1992-08-27	0,4296	0,3311	2,0660	0,2181	0,0019	1,0567	0,0432	0,0483	25,6798
Mostostal Plock	1998-09-30	-0,5802	0,0796	1,0798	0,1209	0,0167	0,5260	0,2887	0,0799	4,7037
Mostostal Warszawa	1993-10-28	1,9403	0,1331	1,5506	0,1756	0,0664	0,8497	1,5657	1,1304	15,8830
Mostostal Zabrze	1994-10-28	2,2095	-0,0194	1,3089	0,1186	0,1195	0,5384	2,8497	0,8261	6,0876
Muza	1998-04-30	2,6078	0,1348	1,1944	0,0959	0,2190	0,3943	4,7667	0,7410	2,6428
Novita	1994-12-29	-0,0259	0,3629	1,0218	0,3091	0,0001	0,7338	0,0006	0,0003	4,3071
Odlownie	1998-03-31	0,6517	0,2582	1,2983	0,1882	0,0146	0,7658	0,2520	0,1478	9,9701
Orange	1998-11-30	0,4184	-0,0547	0,5511	0,0450	0,0328	0,1923	0,5763	0,0213	0,6286
Orbis	1997-11-28	-1,5973	0,1592	0,9904	0,0787	0,1263	0,2900	2,6013	0,2188	1,5139
Pekao	1998-06-30	1,6303	0,0187	0,6260	0,0457	0,2852	0,1841	6,7812	0,2298	0,5762
Pepees	1997-05-30	1,1524	0,2883	2,1770	0,2240	0,0153	0,9890	0,2802	0,2741	17,6047
Pfleiderer	1997-05-30	-2,9830	0,4114	1,3178	0,1691	0,2216	0,6802	5,1236	2,3704	8,3276
PKN Orlen	1999-11-30	-0,6456	0,1263	0,7603	0,0700	0,0431	0,2863	0,7211	0,0591	1,3111
PMGP	1995-12-29	0,2940	-0,0654	0,5274	0,1309	0,0170	0,5761	0,3107	0,1031	5,9746
Polimex	1997-10-31	0,4729	0,1218	1,4673	0,1865	0,0057	0,8322	0,1039	0,0719	12,4648
Mostostal										
Polnord	1998-12-31	4,4219	-0,0135	2,1103	0,3323	0,2153	1,3084	4,3907	7,5161	27,3890
Prochem	1994-06-30	1,6796	0,2295	1,3645	0,1238	0,0673	0,5588	1,5152	0,4731	6,5566
Próchnik	1991-04-30	-5,4044	0,3681	3,7831	0,5547	0,0784	2,7900	2,0408	15,8863	186,8247
Projprzem	1999-08-31	-0,2848	0,1348	0,7846	0,1435	0,0082	0,5725	0,1318	0,0432	5,2442

1	2	3	4	5	6	7	8	9	10	11
Protektor	1998-07-31	-0,6126	0,5282	3,2095	0,3682	0,0023	1,5510	0,0364	0,0876	38,4874
Rafako	1994-03-31	-1,6297	0,1175	1,1589	0,1352	0,0861	0,6428	1,9774	0,8172	8,6784
Relpol	1996-02-29	0,4276	0,0715	0,9008	0,1137	0,0117	0,5202	0,2253	0,0610	5,1420
Remak	1994-11-30	0,1165	0,1396	0,7126	0,1206	0,0013	0,5741	0,0267	0,0088	6,9214
Ropczyce	1997-12-31	-1,8039	0,2033	0,7555	0,1023	0,2512	0,4459	5,7016	1,1336	3,3798
Rubicon	1997-06-30	0,5821	-0,0765	0,7832	0,1240	0,0298	0,5391	0,5523	0,1605	5,2314
Sanok	1997-01-31	1,1352	0,2324	1,6895	0,1650	0,0245	0,7244	0,4515	0,2369	9,4446
Sanwil	1998-02-27	0,4753	0,0075	0,9454	0,1789	0,0147	0,7569	0,2528	0,1448	9,7399
Sohodev	1997-06-30	0,4625	0,0228	0,8236	0,0935	0,0172	0,4181	0,3154	0,0551	3,1466
Stalexport	1994-10-28	1,9625	-0,0152	1,0546	0,0884	0,1416	0,4176	3,4628	0,6040	3,6628
Stalprodukt	1997-08-29	2,1585	0,5238	2,9108	0,3564	0,0296	1,5914	0,5499	1,3927	45,5847
Suway	1998-10-30	2,0339	0,1459	1,5871	0,1693	0,0931	0,6940	1,6424	0,7909	7,7054
Sygnity	1995-10-31	0,9205	-0,0015	1,4119	0,1671	0,0208	0,7334	0,4250	0,2286	10,7575
TIM	1998-02-27	6,4203	0,2944	2,1686	0,2246	0,3402	0,9779	8,7651	8,3824	16,2578
Triton	1998-11-30	0,1109	0,1968	0,8513	0,2259	0,0010	0,9574	0,0170	0,0156	15,5827
Ulma	1997-05-30	-0,1483	0,3580	1,9896	0,2815	0,0003	1,0730	0,0056	0,0064	19,5726
Vistula	1993-09-30	3,8920	0,3786	2,0815	0,2457	0,1371	1,1966	3,4962	5,0065	31,5031
Wawel	1998-03-31	-1,0612	0,3139	1,2752	0,1115	0,0391	0,4513	0,6925	0,1411	3,4628
Wikana	1997-02-28	3,3335	0,1749	1,7310	0,3095	0,1791	1,3489	3,7086	6,7478	30,9318
Żywiec	1991-09-24	0,0053	0,3798	2,3393	0,3524	0,0000	1,7319	0,0000	0,0000	71,9910

Źródło: opracowanie własne.

Uwagi końcowe

Zaproponowana przez Dzhabarova i Ziembę (2011, s. 216) metoda badania zależności między miesięcznymi stopami zwrotu w miesiącu grudniu (i styczniu) a skumulowaną miesięczną stopą zwrotu w ciągu jedenastu miesięcy następujących po nim, wyrażona za pomocą regresji liniowej, wykazała niskie wartości współczynników R^2 w przypadku analizowanych spółek notowanych na GPW w określonych interwałach czasowych. Spośród analizowanych przypadków: wszystkich stóp zwrotu, dodatnich i ujemnych stóp zwrotu wartość współczynnika R^2 większa niż 0,6 nie została odnotowana jedynie dla grudniowych i styczniowych stóp zwrotu obliczonych dla wszystkich stóp zwrotu. W pozostałych przypadkach były to sporadyczne wystąpienia:

- grudzień, ujemna arytmetyczna stopa zwrotu: Ulma, Comarch i Rafako,
- grudzień, dodatnia arytmetyczna stopa zwrotu: Alta,
- styczeń, ujemna arytmetyczna stopa zwrotu: Sanwil i Orange,
- grudzień, dodatnia arytmetyczna stopa zwrotu: Alta,
- grudzień, ujemna logarytmiczna stopa zwrotu: Ulma i Comarch,
- grudzień, dodatnia logarytmiczna stopa zwrotu: Alta,
- styczeń, ujemna logarytmiczna stopa zwrotu: KCI, Impexmetal, Sanwil, Orange.

Pewnym ograniczeniem badania jest wielkość bazy danych – polski rynek kapitałowy jest jeszcze stosunkowo młody, obserwowane są na nim wciąż procesy włączania i wyłączania z notowań akcji spółek, jak również fuzji i przejęć, zachodzące w stopniu bardziej intensywnym niż na rynkach rozwiniętych. Innym ograniczeniem przeprowadzonego badania jest różna długość wziętych pod uwagę horyzontów inwestycyjnych, co nierozzerwalnie wiąże się z wcześniej opisanymi uwarunkowaniami badania. Dla podziału na dodatnie i ujemne stopy zwrotu w grudniu (i styczniu) i kalkulacji współczynnika R^2 w wielu wypadkach liczba stopni swobody ograniczała się do 5 lub 6 danych, co wpływało na uzyskiwane wyniki.

W literaturze przedmiotu rzadko można znaleźć opracowania dotyczące tzw. barometru grudnia czy też analizę arytmetycznych i logarytmicznych stóp zwrotu, dlatego też uzyskane w artykule wyniki są swoistym *novum*.

Podobne badania mogą zostać prowadzone również dla rynku surowców i indeksów giełdowych. Pojawia się również możliwość modyfikacji zastosowanej metody, aby zamiast miesięcznych stóp zwrotu badać zależność kwartalnej stopy zwrotu (w pierwszym lub ostatnim kwartale roku) i skumulowanej stopy zwrotu w trzech lub czterech kwartałach po nim następujących.

Literatura

- Bohl, M., Salm, C. (2010). The Other January Effect: International Evidence. *European Journal of Finance*, 2 (16), 173–182. DOI:10.1080/13518470903037953.
- Bronson, R. (2012). *What January Effect?* Pobrano z: <http://ritholz.com/blog/2011/02/what-January-effect-2/9>, 2011 (12.01.2018).

- Brown, L., Luo, L. (2006). The January Barometer: Further Evidence. *Journal of Investing*, 1 (15), 25–31. DOI: 10.3905/joi.2006.616841.
- Brusa, J. (2009). An Industry Analysis of the Other January Effect. *Journal of International Finance and Economics*, 4 (8), 74–81.
- Cooper, M., McConnel, J., Ovtchinnikov, A. (2006). The Other January Effect. *Journal of Financial Economics*, 2 (82), 315–341. DOI: 10.1016/j.jfineco.2006.03.001.
- Dimson, E., Mussavian, M. (1998). A Brief History of Market Efficiency. *European Financial Management*, 1 (4), 91–193. DOI:10.1111/1468-036X.00056.
- Dzhabarov, C., Ziemba, W. (2011). Seasonal Anomalies. W: L. Zacks (red.), *The Handbook of Equity Market Anomalies* (s. 213–217). Hoboken: Wiley & Sons.
- Easterday, K., Sen, P., Stephan, J. (2008). The Persistence of the Small Firm/January Effect: Is It Consistent with Investors' Learning and Arbitrage Efforts? *Quarterly Review of Economics and Finance*, 3 (49), 1172–1193. DOI:10.1016/j.qref.2008.07.001.
- Easton, S., Pinder, S. (2007). A Refutation of the Existence of the Other January Effect. *International Review of Finance*, 3–4 (7), 89–104. DOI:10.1111/j.1468-2443.2007.00069.x.
- Fama, E. (1965). The Behavior of Market Prices. *Journal of Business*, 1 (38), 34–105.
- Fama, E. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, 2 (25), 383–417. DOI:10.2307/2325486.
- Fama, E. (1991). Efficient Capital Markets II. *Journal of Finance*, 5 (46), 1575–1617. DOI:10.1111/j.1540-6261.1991.tb04636.x.
- Haug, M., Hirschey, M. (2006). The January Effect. *Financial Analyst Journal*, 5 (65), 78–88. DOI:10.2469/faj.v62.n5.4284.
- Hensel, C., Ziemba, W. (1995). The January Barometer. *Journal of Investing*, 2 (4), 67–70. DOI:10.3905/joi.4.2.67.
- Hirsch, Y. (1986). *Don't Sell Stocks on Monday*. New York: Facts on File Publications.
- Hirsch, J., Hirsch, Y. (2011). *Stock Trader's Almanac*. Hoboken: Wiley & Sons.
- Imhof, M., Brusa J. (2008). The Other January Effect: International Evidence. *International Journal of Business Research*, 5 (8), 48–52.
- Kaepfel, J. (2009). *Seasonal Stock Market Trends: The Definitive Guide to Calendar-based Stock Market Trading*. Hoboken: Wiley & Sons.
- Keim, D. (1983). Size Related Anomalies and Stock Returns Seasonality: Further Empirical Evidence. *Journal of Financial Economics*, 1 (12), 3–32. DOI: 10.1016/0304-405X(83)90025-9.
- Keim, D., Ziemba, W. (2000). *Security Market Imperfections in Worldwide Equity Markets*. Cambridge: Cambridge University Press.
- Lakonishok, J., Smidt, S. (1988). Are Seasonal Anomalies Real? A Ninety-year Perspective. *Review of Financial Studies*, 1 (4), 403–425. DOI:dx.doi.org/10.1093/rfs/1.4.403.
- Malkiel, B. (2003). The Efficient Market Hypothesis and Its Critics. *Journal of Economic Perspectives*, 1 (17), 59–82. DOI:10.1257/089533003321164958.
- Malkiel, B. (2005). Reflections on the Efficient Market Hypothesis: 30 Years Later. *Financial Review*, 1 (40), 1–9. DOI: 10.1111/j.0732-8516.2005.00090.x.
- Marianowska, M., Szerszyńska, E., Szymański, M. (2016). Anomalie sezonowe na rynkach kapitałowych: efekt stycznia i barometr stycznia na Giełdzie Papierów Wartościowych w Warszawie. *Journal of Capital Market and Behavioral Finance*, 1 (3), 35–48.
- Marshall, B., Visaltanachoti, N. (2010). The Other January Effect: Evidence against Market Efficiency. *Journal of Banking & Finance*, 10 (34), 2413–2424. DOI:10.1016/j.jbankfin.2010.03.019.
- Patel, J. (2014). The Monthly Barometer of the Indian Stock Market. *International Business & Economic Research Journal*, 1 (13), 85–92. DOI:10.19030/iber.v13i1.8358.
- Rendon, J., Ziemba, W. (2007). Is the January Effect Still Alive in the Futures Markets? *Financial Market and Portfolio Management*, 3 (21), 381–396. DOI: 10.1007/s11408-007-0049-3.

- Rozeff, M., Kinney, W. (1976). Capital Market Seasonality: The Case of Stock Returns. *Journal of Financial Economics*, 3 (4), 379–402. DOI:10.1016/0304-405X(76)90028-3.
- Stivers, C., Sun, L., Sun, Y. (2009). The Other January Effect: International, Style, and Subperiod Evidence. *Journal of Financial Markets*, 3 (12), 521–546. DOI:10.1016/j.finmar.2009.01.001.
- Sturm, R. (2009). The „Other” January Effect and the Presidential Election Cycle. *Applied Financial Economics*, 17 (19), 1–9. DOI:10.1080/09603100802599589.
- Thaler, R. (1992). *The Winner Curse*. New York: The Free Press.
- Verheyden, T., De Moor, L., Van den Bossche, F. (2013). A Tale of Market Efficiency. *Review of Economics and Business Literature*, 2 (58), 139–156.
- Ziemba, W. (1994). Investing in the Turn-of-the-year Effect in the Futures Markets. *Interfaces*, 3 (24), 46–61. DOI: 10.1287/inte.24.3.46.

THE JANUARY (DECEMBER) BAROMETER EFFECT ON THE EXAMPLE OF 88 EQUITIES LISTED ON THE WARSAW STOCK EXCHANGE

Abstract: *Purpose* – The aim of the research is to verify the effectiveness of the so-called January (December) barometer on the example of monthly rates of return 88 equity prices listed on the Warsaw Stock Exchange.

Design/methodology/approach – The method was proposed by Dzhaharov and Ziemba and is based on an analysis of the relationships between the monthly rates of return in the month of December (or January) and the cumulative monthly rates of return during the following 11 months. This dependence is expressed by linear regression. The monthly arithmetic and logarithmic rates of return registered in December and January were divided into three groups: (1) all rates of return (positive, negative and equal to zero), (2) positive and equal to zero and (3) negative rates of return.

Originality/value – This is the one of the first study known regarding Polish equity market.

Findings – In the case of 88 shares listed on the Warsaw Stock Exchange, except a few companies, low effectiveness of the January (December) barometer was found.

Keywords: financial market, calendar anomalies, financial market effectiveness.

Cytowanie

Borowski, K. (2018). Wykorzystanie barometru stycznia i grudnia na przykładzie 88 spółek notowanych na GPW Warszawie. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), s. 5–18. DOI: 10.18276/frfu.2018.94/2-01.

Efekt *momentum* na GPW w Warszawie w latach 1995–2015

Leszek Czapiewski*

Streszczenie: *Cel* – Celem artykułu jest weryfikacja istnienia efektu *momentum* na GPW w Warszawie w latach 1995–2015.

Metodologia badania – Jako metodę badawczą wykorzystano metodę weryfikacji wyników inwestycji opartych na strategii *momentum*. Zbadano rezultaty strategii inwestycyjnych utrzymywanych w okresie K -miesięcy ($K = 1, \dots, 36$). W tym celu skonstruowano portfele złożone zarówno z akcji najbardziej „wzrostowych”, jak i „spadkowych” w ciągu poprzedzających J -miesięcy ($J = 1, \dots, 36$). Równolegle testowano strategię inwestycyjną dla portfeli tylko „wzrostowych” oraz tylko „spadkowych”.

Wynik – Przeprowadzone w okresie 1995–2015 badania potwierdzają istnienie efektu *momentum* i są zbieżne z wcześniej uzyskanymi wynikami badań dla polskiego rynku kapitałowego. Wyniki pogłębionych testów wskazują jednak na duże zróżnicowanie wyników strategii *momentum* zarówno dla portfeli „wzrostowych” i „spadkowych”, jak i dla poszczególnych podokresów badawczych.

Oryginalność/wartość – Przeprowadzone w artykule badania są jak dotąd najobszerniejszymi badaniami na temat zjawiska *momentum* na polskim rynku kapitałowym. Bazują na analizie 1296 strategii inwestycyjnych z uwzględnieniem wszystkich 649 spółek notowanych na rynku głównym GPW w Warszawie w latach 1995–2015.

Słowa kluczowe: anomalie rynkowe, efektywność rynku kapitałowego, efekt *momentum*, strategię *momentum*

Wprowadzenie

Jeśli rynki kapitałowe są efektywne, to akcje i inne instrumenty finansowe są wyceniane prawidłowo, a ich cena odpowiednio odzwierciedla wartość aktywów im odpowiadających. Bardzo wiele badań jednak dowodzi, że wycena instrumentów finansowych zawiera często systematyczne i wykrywalne błędy. Jeżeli tak jest, to inwestor potrafiący zaobserwować te odchylenia może osiągnąć ponadprzeciętne zyski.

Błędy wyceny związane z nieefektywnością rynków finansowych nazywane są anomaliami. Najczęściej dotyczą efektów kalendarzowych, strategii *momentum*, strategii kontrariańskiej, korelacji stóp zwrotu w krótkim i długim okresie czasu, efektów związanych z cechami spółek czy efektów łączonych z upublicznieniem informacji.

* dr Leszek Czapiewski, Uniwersytet Ekonomiczny w Poznaniu, e-mail: leszek.czapiewski@ue.poznan.pl.

Strategia kontrariańska (odwrócenia) bezpośrednio łączy się ze strategią *momentum*, ale koncepcja w niej zawarta stanowi przeciwieństwo strategii *momentum* (strategia *momentum* związana jest z kontynuacją przeszłego zachowania się stóp zwrotu w przyszłości, a strategia kontrariańska – z jego odwróceniem). Strategia *momentum* polega więc na zakupie akcji o najwyższej stopie zwrotu, realizowanej w ostatnich n -okresach i jednoczesnej sprzedaży akcji, które osiągnęły historycznie najniższą stopę zwrotu.

Celem artykułu jest weryfikacja istnienia zjawiska *momentum* (na podstawie wyznaczenia zyskowności strategii *momentum*) i określenie jego charakteru na Gieldzie Papierów Wartościowych w Warszawie w latach 1995–2015. Badania zostały sfinansowane ze środków projektu badawczego przyznanego przez Narodowe Centrum Nauki (2015/19/D/HS4/01950).

1. Strategia *momentum* w świetle dotychczasowych badań

Sformułowanie zasad strategii *momentum* i strategii kontrariańskiej było efektem debaty nad racjonalnością zachowania inwestorów na rynku kapitałowym. Strategie te związane są ze spółkami, które w określonym horyzoncie inwestycyjnym przyniosły najwyższe stopy zwrotu (spółki „wzrostowe”, tzw. zwycięzcy) oraz spółkami, które przyniosły najniższe stopy zwrotu (spółki „spadkowe”, tzw. przegrani). Strategia *momentum* polega na kupowaniu akcji spółek „zwycięzców” i jednoczesnym sprzedawaniu akcji spółek „przegranych”, natomiast strategia kontrariańska polega na kupowaniu akcji spółek „przegranych” i sprzedawaniu akcji spółek „zwycięzców”.

Takie zachowanie się stóp zwrotu akcji spółek w krótkim i długim okresie, które przyczynia się do wystąpienia zjawiska *momentum* i zjawiska odwrócenia, często wyjaśniane jest poprzez dwie przeciwne reakcje uczestników rynku na napływające informacje. Z efektem *momentum* związana jest niedostateczna reakcja inwestorów na pojawiające się informacje dotyczące spółki (*underreaction*), co powoduje przesunięcie czasowe uwzględniania ich w wycenie. Dostosowanie cen nie następuje natychmiast i możliwe jest osiągnięcie ponadprzeciętnych stóp zwrotu z inwestycji w akcje „wzrostowe” i przez krótką sprzedaż akcji „spadkowych”. Efekt odwrócenia, będący podstawą strategii kontrariańskiej, tłumaczony jest nadreaktywnością uczestników rynku (*overreaction*). Wówczas silna dodatnia (pozytywne informacje) lub ujemna (negatywne informacje) reakcja cen w krótkim okresie była następnie odwracana w długim okresie, pozwalając powrócić do długookresowej równowagi.

Pracą, która zainicjowała dyskusję naukową w tym obszarze, był artykuł De Bondta i Thaler (1985). Na podstawie spółek z NYSE z okresu 1926–1982 autorzy wykazali, że spółki charakteryzujące się w przeszłości najniższymi miesięcznymi stopami zwrotu uzyskiwały w okresie do trzech lat lepsze wyniki niż spółki wykazujące w przeszłości najwyższe stopy zwrotu. Na podobne zachowanie, występujące w krótkim okresie, wskazali Jegadeesh (1990) i Lehmann (1990), którzy na przykładzie tygodniowych i miesięcznych stóp zwrotu wykazali zyskowność strategii kontrariańskich.

Jedno z ważniejszych badań związanych ze zjawiskiem *momentum* przeprowadzili Jegadeesh i Titman (1993). Wykorzystując analizę miesięcznych stóp zwrotu spółek noto-

wanych na NYSE i AMEX w latach 1965–1989, wykazali występowanie efektu *momentum* w średnim okresie. Zbadali w tym celu zachowanie się portfeli konstruowanych na podstawie czterech wariantów historycznych stóp zwrotu z okresów o długości J -miesięcy ($J = 3, 6, 9, 12$). Te portfele, budowane co miesiąc, przetrzymywane były w czterech wariantach przez K kolejnych miesięcy ($K = 3, 6, 9, 12$). Przy różnych kombinacjach okresów formacji portfeli (J) oraz okresów ich utrzymywania (K) zweryfikowano 16 różnych strategii polegających na kupnie spółek „wzrostowych” o najwyższych historycznych stopach zwrotu i sprzedaży spółek „spadkowych” o najniższych historycznych stopach zwrotu.

Zyskowność tak określonej strategii stanowi potwierdzenie występowania zjawiska *momentum* w średnim okresie. Wszystkie zweryfikowane strategie przyniosły dodatnie średnie miesięczne stopy zwrotu, a najlepszą strategią (średnio 1,49% w skali miesiąca) okazała się ta, w której spółki do portfeli dobierane były na podstawie stóp zwrotu z minionych 12 miesięcy ($J = 12$), a utworzony portfel był utrzymywany przez następne trzy miesiące ($K = 3$).

Kolejne badania również potwierdziły występowanie zjawiska kontynuacji stóp zwrotu dla rynku amerykańskiego (m.in. Chan, Jegadeesh, Lakonishok, 1996, 1999; Jegadeesh, Titman, 2001) i innych rozwiniętych rynków kapitałowych (m.in. Rouwenhorst, 1998; Liu, Lee, 2001; Li, Brooks, Miffre, 2009).

Na polskim rynku kapitałowym również potwierdzono występowanie efektu *momentum* w krótkim i średnim okresie inwestycyjnym. Badania w tym obszarze prowadzili m.in. Grotowski (2003a, 2003b), Czajkowska (2004), Merło i Konarzewski (2015), a także Pałowska (2015). Jednak najbardziej obszerne i zbliżone do podejścia Jegadeesha i Titmana (1993) badania nad efektywnością strategii *momentum* przeprowadził dla polskiej giełdy Szyszka (2006) i Wójtowicz (2011). Ich zbiorcze wyniki, w przeliczeniu na średniomiesięczne stopy zwrotu, zaprezentowano w tabeli 1.

Tabela 1

Wybrane wyniki strategii *momentum* na polskim rynku kapitałowym (średniomiesięcznie, %)

A. Szyszka okres badawczy: 1994–2005					T. Wójtowicz okres badawczy: 2003–2010				
	$K = 3$	$K = 6$	$K = 9$	$K = 12$		$K = 1$	$K = 3$	$K = 9$	$K = 12$
$J = 3$	2,28	1,38	1,28	1,14	$J = 1$	2,53	1,16	0,74	0,58
$J = 6$	2,26	2,17	1,84	1,52	$J = 3$	1,61	1,00	0,88	0,75
$J = 9$	3,08	2,00	1,70	1,22	$J = 9$	1,22	0,70	0,55	0,54
$J = 12$	2,82	1,97	1,06	–0,28	$J = 12$	0,77	0,31	0,12	–0,09

Wytłuszczeniem wyszczególniono wyniki istotne statystycznie na poziomie $\alpha \leq 0,1$.

Źródło: opracowanie własne na podstawie Szyszka (2006); Wójtowicz (2011).

W badaniach Szyszki (2006) na podstawie danych z GPW w Warszawie z lat 1994–2005 skonstruowano 16 strategii inwestycyjnych (4 możliwe okresy formacji portfeli $J = 3, 6, 9, 12$ miesięcy oraz 4 okresy ich utrzymywania $K = 3, 6, 9, 12$ miesięcy). Najlepsze rezultaty (3,08% średniomiesięcznie) przyniosła strategia łącząca kupno akcji „wzrostowych” i krótką sprzedaż

akcji „spadkowych” w przypadku portfela zbudowanego na podstawie dziewięciomiesięcznej historii ($J = 9$) i utrzymywanego przez trzy miesiące ($K = 3$). Na osiągnięte wyniki wpływały głównie rezultaty osiągnięte z „krótkiej” sprzedaży akcji „przegranych”.

Wójtowicz (2011) w swoich badaniach posłużył się danymi z GPW w Warszawie z okresu 2003–2010. Skonstruował również 16 strategii inwestycyjnych, przy czym bazowały one na czterech możliwych okresach formacji portfeli ($J = 1, 3, 6, 9$ miesięcy) oraz na czterech okresach ich utrzymania ($K = 3, 6, 9, 12$ miesięcy). Z badań wynika, że w porównaniu do wcześniejszych badań Szyszkowski zyskowność strategii *momentum* ulegała obniżeniu. Mogło to być rezultatem wystąpienia w okresie 2007–2009 kryzysu finansowego. Największą średniomiesięczną stopę zwrotu (2,53%) przyniosła strategia na podstawie stóp zwrotu z ostatniego miesiąca ($J = 1$) i utrzymywana także w okresie jednego miesiąca ($K = 1$). Również w tym badaniu na osiągnięte wyniki głównie wpływały rezultaty osiągnięte z „krótkiej” sprzedaży akcji „przegranych”.

2. Opis próby badawczej i zastosowanej metody badań


Badania strategii *momentum* przeprowadzono na podstawie wszystkich akcji spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie w okresie od lipca 1995 do czerwca 2015 z uwzględnieniem papierów, które zostały wycofane z obrotu w badanym okresie. Łącznie wzięto pod uwagę akcje 649 spółek, przy czym liczba badanych akcji zmieniała się w czasie w miarę przybywania nowych walorów i wycofywania innych. Wykorzystano logarytmiczne miesięczne stopy zwrotu wyznaczone na podstawie skorygowanych notowań z ostatnich sesji w poszczególnych miesiącach (w odróżnieniu od większości wcześniej realizowanych badań, korekta notowań uwzględniła wszystkie operacje na papierach, takie jak wypłata dywidendy, prawa poboru i objęcia, splity, scalenia itp.).

Przetestowano wszystkie warianty strategii *momentum* dla inwestycji o długości $K = 1, \dots, 60$ miesięcy, wykorzystując dane z $J = 1, \dots, 60$ miesięcy. W odróżnieniu od wcześniejszych badań (gdzie testowano najczęściej tylko 16 strategii) pozwoliło to na zweryfikowanie aż 1296 strategii *momentum*. Podobnie jak w innych badaniach, ocenie podlegała hipotetyczna efektywność strategii inwestycyjnej (brak kosztów transakcyjnych, nieograniczona krótka sprzedaż). Testowano ją zarówno łącznie dla strategii wykorzystującej zakup akcji „wzrostowych” oraz krótką sprzedaż akcji „spadkowych”, jak i oddzielnie dla poszczególnych składowych (tylko zakup lub tylko sprzedaż). W doborze spółek wchodzących w skład portfeli inwestycyjnych wykorzystano (jak u większości innych badaczy) odsetek 10% spółek „zwycięzców” i „przegranych”.

3. Wyniki badań empirycznych

Wyniki (w postaci stóp zwrotu z inwestycji) wszystkich 1296 przeanalizowanych strategii *momentum* przedstawiono na wykresach w postaci dwuwymiarowej mapy wyników (rys. 1–2). Pokazano wszystkie kombinacje dla 36 wariantów dla $J = 1, \dots, 36$ (w kolumnach) i 36 wariantów dla $K = 1, \dots, 36$ (w wierszach). Warianty strategii rentownych i istotnych statystycznie oznaczono znakiem „+”. Warianty strategii nierentownych i istotnych statystycznie oznaczono znakiem „-”. Pozostałe komórki (brak oznaczenia) to wariant strategii z wynikami nieistotnymi statystycznie (istotność statystyczna dla $p\text{-value} \leq 0,1$). Czarna linia rozdziela strategie rentowne od nierentownych. Skala zysku lub straty w poszczególnych wariantach reprezentowana jest przez różne odcienie szarości w wypełnieniu komórek. W postaci tabelarycznej przedstawiono natomiast wyniki kombinacji wariantów dla $J=1, \dots, 18$ oraz $K = 1, \dots, 9$ (tab. 2–4).

W pierwszej kolejności, na rysunku 1 oraz w tabeli 2 ukazano wyniki dla połączonej strategii *momentum* (zakup akcji „zwycięzców” i jednoczesna sprzedaż akcji „przegranych”).



Rysunek 1. Wyniki połączonej strategii *momentum* – zakup akcji „zwycięzców” i jednoczesna sprzedaż akcji „przegranych”

Źródło: opracowanie własne.

Tabela 2


Wyniki połączonej strategii *momentum*– zakup akcji „zwycięzców” i jednoczesna sprzedaż akcji „przegranych” (%)

	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9
J = 1	1,15 **	1,45 ***	1,69 ***	1,54 ***	1,40 ***	1,38 ***	1,30 ***	1,14 ***	1,07 ***
J = 2	1,72 ***	2,20 ***	2,28 ***	2,09 ***	1,97 ***	1,91 ***	1,77 ***	1,61 ***	1,53 ***
J = 3	2,70 ***	2,73 ***	2,61 ***	2,45 ***	2,28 ***	2,10 ***	1,89 ***	1,75 ***	1,69 ***
J = 4	2,33 ***	2,50 ***	2,45 ***	2,39 ***	2,28 ***	2,09 ***	1,95 ***	1,84 ***	1,74 ***
J = 5	2,45 ***	2,58 ***	2,71 ***	2,50 ***	2,33 ***	2,17 ***	2,07 ***	1,95 ***	1,84 ***
J = 6	2,85 ***	2,78 ***	2,76 ***	2,58 ***	2,51 ***	2,36 ***	2,19 ***	2,05 ***	1,89 ***
J = 7	2,73 ***	2,65 ***	2,67 ***	2,55 ***	2,44 ***	2,24 ***	2,06 ***	1,89 ***	1,73 ***
J = 8	2,81 ***	2,81 ***	2,73 ***	2,65 ***	2,51 ***	2,31 ***	2,11 ***	1,95 ***	1,76 ***
J = 9	2,78 ***	2,99 ***	2,95 ***	2,75 ***	2,52 ***	2,29 ***	2,12 ***	1,88 ***	1,73 ***
J = 10	2,98 ***	3,22 ***	2,97 ***	2,71 ***	2,44 ***	2,21 ***	1,97 ***	1,77 ***	1,60 ***
J = 11	3,06 ***	3,02 ***	2,72 ***	2,45 ***	2,25 ***	2,03 ***	1,85 ***	1,68 ***	1,52 ***
J = 12	2,97 ***	2,90 ***	2,60 ***	2,34 ***	2,19 ***	1,97 ***	1,81 ***	1,62 ***	1,41 ***
J = 13	2,84 ***	2,59 ***	2,37 ***	2,18 ***	2,04 ***	1,81 ***	1,62 ***	1,40 ***	1,22 ***
J = 14	2,48 ***	2,44 ***	2,24 ***	2,11 ***	1,97 ***	1,72 ***	1,50 ***	1,31 ***	1,18 ***
J = 15	2,49 ***	2,38 ***	2,22 ***	2,07 ***	1,90 ***	1,64 ***	1,44 ***	1,31 ***	1,17 ***
J = 16	2,43 ***	2,28 ***	2,15 ***	1,99 ***	1,81 ***	1,55 ***	1,40 ***	1,25 ***	1,09 ***
J = 17	2,51 ***	2,30 ***	2,13 ***	1,88 ***	1,68 ***	1,49 ***	1,31 ***	1,15 ***	1,00 ***
J = 18	2,24 ***	2,08 ***	1,85 ***	1,63 ***	1,52 ***	1,36 ***	1,22 ***	1,08 ***	0,94 ***

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

Źródło: opracowanie własne.

Uzyskane rezultaty potwierdzają istnienie zjawiska *momentum* w całym okresie 1995–2015 i są najbardziej zbliżone do wyników dla okresu 1994–2005 uzyskanych wcześniej przez Szyszkę (2006). Największą zyskownością (średniomiesięcznie 3,22%) charakteryzuje się wariant strategii budowany na okresie $J = 10$ miesięcy i przetrzymywany przez okres $K = 2$ miesięcy.



Rysunek 2. Wyniki strategii *momentum* rozdzielone z podziałem na zakup akcji „zwycięzców” i sprzedaż akcji „przegranych”

Źródło: opracowanie własne.

Podobnie jak we wcześniejszych badaniach, wyniki połączonych strategii są w większości wynikiem realizacji sprzedaży akcji „przegranych”, a w bardzo małym stopniu realizacji kupna akcji „zwycięzców” (rys. 2 i tab. 3–4).

Tabela 3

Wyniki rozdzielonej strategii *momentum* – tylko zakup akcji „zwycięzców” (%)

	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9
J = 1	-0,31	-0,09	0,06	0,04	-0,01	0,01	-0,03	-0,09	-0,10
J = 2	0,06	0,47	0,52	0,42	0,34	0,28	0,20	0,10	0,08
J = 3	0,80	0,79 *	0,70 *	0,63 *	0,52	0,39	0,30	0,22	0,21
J = 4	0,55	0,52	0,56	0,44	0,38	0,30	0,22	0,16	0,13
J = 5	0,52	0,66 *	0,65 *	0,51	0,44	0,35	0,29	0,23	0,19
J = 6	0,73	0,71 *	0,65 *	0,53	0,45	0,39	0,31	0,24	0,18
J = 7	0,43	0,48	0,51	0,43	0,39	0,33	0,23	0,14	0,08
J = 8	0,52	0,58	0,56	0,49	0,43	0,35	0,22	0,15	0,07
J = 9	0,61	0,74 *	0,74 **	0,60 *	0,51	0,38	0,28	0,16	0,12
J = 10	0,59	0,85 **	0,72 **	0,59 *	0,42	0,30	0,16	0,06	-0,01
J = 11	0,67	0,67 *	0,58	0,42	0,32	0,21	0,12	0,03	-0,02
J = 12	0,59	0,64	0,48	0,35	0,26	0,16	0,06	-0,04	-0,10
J = 13	0,70	0,56	0,41	0,30	0,21	0,08	-0,04	-0,12	-0,18
J = 14	0,37	0,38	0,29	0,20	0,10	-0,03	-0,15	-0,20	-0,23
J = 15	0,45	0,45	0,29	0,19	0,07	-0,06	-0,14	-0,18	-0,19
J = 16	0,44	0,37	0,23	0,10	-0,02	-0,13	-0,20	-0,23	-0,26
J = 17	0,44	0,30	0,16	0,01	-0,07	-0,16	-0,23	-0,26	-0,27
J = 18	0,11	0,06	-0,05	-0,14	-0,19	-0,24	-0,30	-0,32	-0,36

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

Źródło: opracowanie własne.

Tabela 4

Wyniki rozdzielonej strategii *momentum* – tylko sprzedaż akcji „przegranych” (%)

	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9
J = 1	1,46 **	1,54 **	1,63 ***	1,49 ***	1,41 ***	1,37 ***	1,32 ***	1,23 ***	1,17 ***
J = 2	1,66 **	1,73 **	1,76 ***	1,67 ***	1,63 ***	1,63 ***	1,58 ***	1,51 ***	1,45 ***
J = 3	1,89 ***	1,94 ***	1,91 ***	1,83 ***	1,76 ***	1,71 ***	1,59 ***	1,53 ***	1,49 ***
J = 4	1,78 **	1,98 **	1,89 ***	1,95 ***	1,90 ***	1,80 ***	1,73 ***	1,68 ***	1,61 ***
J = 5	1,93 ***	1,92 ***	2,05 ***	1,99 ***	1,89 ***	1,82 ***	1,78 ***	1,72 ***	1,65 ***
J = 6	2,12 ***	2,07 ***	2,10 ***	2,06 ***	2,06 ***	1,96 ***	1,88 ***	1,80 ***	1,71 ***
J = 7	2,31 ***	2,17 ***	2,16 ***	2,12 ***	2,05 ***	1,92 ***	1,83 ***	1,75 ***	1,65 ***
J = 8	2,29 ***	2,23 ***	2,17 ***	2,16 ***	2,08 ***	1,96 ***	1,89 ***	1,80 ***	1,69 ***
J = 9	2,17 ***	2,24 ***	2,21 ***	2,15 ***	2,01 ***	1,91 ***	1,84 ***	1,72 ***	1,61 ***
J = 10	2,39 ***	2,37 ***	2,25 ***	2,13 ***	2,02 ***	1,92 ***	1,81 ***	1,70 ***	1,60 ***
J = 11	2,40 ***	2,35 ***	2,14 ***	2,03 ***	1,94 ***	1,83 ***	1,74 ***	1,64 ***	1,54 ***
J = 12	2,38 ***	2,27 ***	2,12 ***	1,99 ***	1,93 ***	1,81 ***	1,75 ***	1,65 ***	1,52 ***
J = 13	2,14 ***	2,03 ***	1,96 ***	1,87 ***	1,83 ***	1,72 ***	1,66 ***	1,53 ***	1,40 ***
J = 14	2,11 ***	2,07 ***	1,96 ***	1,91 ***	1,87 ***	1,75 ***	1,64 ***	1,51 ***	1,41 ***
J = 15	2,03 ***	1,94 ***	1,93 ***	1,89 ***	1,83 ***	1,70 ***	1,58 ***	1,49 ***	1,36 ***
J = 16	1,99 ***	1,91 ***	1,92 ***	1,90 ***	1,83 ***	1,68 ***	1,61 ***	1,48 ***	1,35 ***
J = 17	2,07 ***	2,00 ***	1,97 ***	1,87 ***	1,75 ***	1,65 ***	1,54 ***	1,41 ***	1,28 ***
J = 18	2,13 ***	2,02 ***	1,90 ***	1,77 ***	1,72 ***	1,60 ***	1,52 ***	1,40 ***	1,29 ***

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

Źródło: opracowanie własne.

Źródło: opracowanie własne.

Tabela 5

Wyniki połączonej strategii *momentum* – zakup akcji „zwycięzców” i jednoczesna sprzedaż akcji „przegrywanych” (%)

	<i>K</i> = 1	<i>K</i> = 2	<i>K</i> = 3	<i>K</i> = 4	<i>K</i> = 5	<i>K</i> = 6	<i>K</i> = 7	<i>K</i> = 8	<i>K</i> = 9									
<i>J</i> = 1	1,00	1,15	**	1,74	***	1,55	***	1,47	***	1,48	***	1,39	***	1,11	***	1,06	***	
<i>J</i> = 2	1,56	*	2,44	***	2,61	***	2,39	***	2,22	***	2,08	***	1,89	***	1,71	***	1,65	***
<i>J</i> = 3	3,08	***	3,13	***	3,07	***	2,89	***	2,61	***	2,31	***	2,03	***	1,88	***	1,82	***
<i>J</i> = 4	2,43	***	2,72	***	2,68	***	2,55	***	2,40	***	2,09	***	1,92	***	1,76	***	1,69	***
<i>J</i> = 5	2,53	***	2,87	**	2,98	***	2,66	***	2,42	***	2,22	***	2,07	***	1,93	***	1,84	***
<i>J</i> = 6	3,09	***	3,06	***	3,01	***	2,82	***	2,67	***	2,39	***	2,17	***	2,02	***	1,88	***
<i>J</i> = 7	2,88	***	2,80	***	2,89	***	2,70	***	2,49	***	2,20	***	2,00	***	1,83	***	1,69	***
<i>J</i> = 8	3,06	***	3,14	***	3,02	***	2,79	***	2,57	***	2,30	***	2,07	***	1,89	***	1,69	***
<i>J</i> = 9	2,89	***	3,28	***	3,17	***	2,80	***	2,48	***	2,19	***	2,02	***	1,70	***	1,56	***
<i>J</i> = 10	3,21	***	3,33	***	2,92	***	2,58	***	2,25	***	2,00	***	1,65	***	1,42	***	1,26	***
<i>J</i> = 11	2,77	***	2,83	***	2,40	***	2,10	***	1,91	***	1,66	***	1,44	***	1,26	***	1,13	***
<i>J</i> = 12	2,80	***	2,70	***	2,26	***	2,02	***	1,84	***	1,59	***	1,42	***	1,20	***	1,04	***
<i>J</i> = 13	2,78	***	2,30	***	1,98	***	1,74	***	1,61	***	1,38	***	1,16	***	0,96	***	0,84	***
<i>J</i> = 14	2,13	**	2,01	***	1,71	***	1,62	***	1,49	***	1,22	***	1,01	***	0,85	***	0,73	***
<i>J</i> = 15	1,96	**	1,72	***	1,51	***	1,42	***	1,30	***	1,11	***	0,91	***	0,79	***	0,65	**
<i>J</i> = 16	1,91	**	1,73	***	1,55	***	1,45	***	1,33	***	1,00	***	0,83	***	0,66	**	0,49	*
<i>J</i> = 17	2,09	**	1,80	***	1,59	***	1,39	***	1,18	***	0,96	***	0,72	**	0,53	*	0,34	
<i>J</i> = 18	1,91	**	1,60	***	1,37	***	1,07	***	0,94	**	0,71	**	0,51	*	0,33		0,18	

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

Źródło: opracowanie własne.

Tabela 6


Wyniki połączonej strategii *momentum* w okresie 2005–2015 – zakup akcji „zwycięzców” i jednoczesna sprzedaż akcji „przegranych” (%)

	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9
J = 1	1,25 **	1,72 ***	1,69 ***	1,54 ***	1,32 ***	1,30 ***	1,24 ***	1,20 ***	1,13 ***
J = 2	1,80 ***	1,94 ***	1,99 ***	1,77 ***	1,70 ***	1,75 ***	1,70 ***	1,61 ***	1,47 ***
J = 3	2,30 ***	2,36 ***	2,16 ***	1,98 ***	1,92 ***	1,90 ***	1,79 ***	1,64 ***	1,54 ***
J = 4	2,09 ***	2,20 ***	2,15 ***	2,14 ***	2,11 ***	2,11 ***	1,97 ***	1,89 ***	1,75 ***
J = 5	2,13 ***	2,12 ***	2,31 ***	2,26 ***	2,21 ***	2,09 ***	2,02 ***	1,91 ***	1,80 ***
J = 6	2,28 ***	2,35 ***	2,44 ***	2,30 ***	2,26 ***	2,26 ***	2,15 ***	2,05 ***	1,87 ***
J = 7	2,33 ***	2,41 ***	2,41 ***	2,31 ***	2,29 ***	2,23 ***	2,10 ***	1,94 ***	1,78 ***
J = 8	2,52 ***	2,55 ***	2,46 ***	2,52 ***	2,46 ***	2,36 ***	2,20 ***	2,05 ***	1,85 ***
J = 9	2,46 ***	2,55 ***	2,64 ***	2,64 ***	2,50 ***	2,36 ***	2,21 ***	2,05 ***	1,86 ***
J = 10	2,44 ***	2,93 ***	2,93 ***	2,78 ***	2,58 ***	2,42 ***	2,26 ***	2,07 ***	1,89 ***
J = 11	3,15 ***	3,10 ***	3,03 ***	2,83 ***	2,61 ***	2,43 ***	2,27 ***	2,08 ***	1,88 ***
J = 12	2,97 ***	2,97 ***	2,84 ***	2,61 ***	2,45 ***	2,31 ***	2,16 ***	1,98 ***	1,72 ***
J = 13	2,80 ***	2,75 ***	2,66 ***	2,53 ***	2,40 ***	2,21 ***	2,05 ***	1,81 ***	1,56 ***
J = 14	2,51 ***	2,72 ***	2,62 ***	2,48 ***	2,34 ***	2,13 ***	1,91 ***	1,66 ***	1,49 ***
J = 15	2,77 ***	2,81 ***	2,72 ***	2,57 ***	2,36 ***	2,11 ***	1,86 ***	1,70 ***	1,53 ***
J = 16	2,53 ***	2,46 ***	2,46 ***	2,33 ***	2,13 ***	1,90 ***	1,76 ***	1,60 ***	1,44 ***
J = 17	2,53 ***	2,43 ***	2,37 ***	2,14 ***	1,90 ***	1,71 ***	1,58 ***	1,47 ***	1,37 ***
J = 18	2,41 ***	2,34 ***	2,18 ***	1,99 ***	1,84 ***	1,73 ***	1,66 ***	1,56 ***	1,45 ***

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

Źródło: opracowanie własne.

Dodatkowo w badaniu przeanalizowano, jaki wpływ na wyniki ma wybór odsetka spółek wchodzących w skład portfeli inwestycyjnych. Badania zostały powtórzone dla odsetka 5% i 20% spółek „zwycięzców” i „przegranych”. Wyniki te zaprezentowano na rysunku 4 i w tabelach 7–8. Również w tych wariantach potwierdza się istnienie zjawiska *momentum*, przy czym im mniejszy odsetek wybieranych spółek, tym większa zyskowność realizowanych inwestycji.



Rysunek 4. Wyniki połączonej strategii *momentum* – dla 5% najlepszych i najgorszych spółek (strona lewa) oraz 20% najlepszych i najgorszych spółek (strona prawa)

Źródło: opracowanie własne.

Tabela 7

Wyniki połączonej strategii *momentum* dla 5% najlepszych i najgorszych spółek (%)

	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9
J = 1	0,43	0,98 **	1,58 ***	1,54 ***	1,42 ***	1,38 ***	1,32 ***	1,14 ***	1,06 ***
J = 2	1,60 **	2,21 ***	2,35 ***	2,19 ***	2,10 ***	2,03 ***	1,81 ***	1,60 ***	1,58 ***
J = 3	2,66 ***	2,78 ***	2,65 ***	2,44 ***	2,27 ***	2,10 ***	1,88 ***	1,73 ***	1,67 ***
J = 4	2,55 ***	2,69 ***	2,75 ***	2,71 ***	2,53 ***	2,27 ***	2,10 ***	2,00 ***	1,89 ***
J = 5	2,22 ***	2,65 ***	2,79 ***	2,65 ***	2,46 ***	2,35 ***	2,26 ***	2,15 ***	2,07 ***
J = 6	2,48 ***	2,93 ***	2,78 ***	2,55 ***	2,43 ***	2,39 ***	2,21 ***	2,05 ***	1,87 ***
J = 7	2,87 ***	2,71 ***	2,81 ***	2,76 ***	2,55 ***	2,44 ***	2,28 ***	2,07 ***	1,97 ***
J = 8	2,84 ***	2,79 ***	2,78 ***	2,65 ***	2,55 ***	2,39 ***	2,20 ***	2,00 ***	1,80 ***
J = 9	2,90 ***	3,15 ***	3,01 ***	2,81 ***	2,72 ***	2,47 ***	2,27 ***	2,05 ***	1,84 ***
J = 10	2,93 ***	3,02 ***	3,02 ***	2,91 ***	2,68 ***	2,42 ***	2,22 ***	1,96 ***	1,79 ***
J = 11	3,49 ***	3,36 ***	3,24 ***	2,90 ***	2,68 ***	2,38 ***	2,11 ***	1,87 ***	1,70 ***
J = 12	3,85 ***	3,67 ***	3,25 ***	2,93 ***	2,62 ***	2,30 ***	2,07 ***	1,88 ***	1,68 ***
J = 13	3,73 ***	3,43 ***	2,94 ***	2,72 ***	2,45 ***	2,20 ***	2,04 ***	1,88 ***	1,61 ***
J = 14	3,35 ***	3,14 ***	2,89 ***	2,51 ***	2,31 ***	2,03 ***	1,77 ***	1,56 ***	1,39 ***
J = 15	3,08 ***	2,87 ***	2,52 ***	2,31 ***	2,10 ***	1,81 ***	1,55 ***	1,44 ***	1,27 ***
J = 16	2,98 ***	2,67 ***	2,50 ***	2,28 ***	2,04 ***	1,78 ***	1,63 ***	1,51 ***	1,36 ***
J = 17	2,71 ***	2,57 ***	2,39 ***	2,09 ***	1,85 ***	1,68 ***	1,52 ***	1,37 ***	1,21 ***
J = 18	2,84 ***	2,69 ***	2,31 ***	2,01 ***	1,93 ***	1,68 ***	1,55 ***	1,40 ***	1,26 ***

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

Źródło: opracowanie własne.

Tabela 8

Wyniki połączonej strategii *momentum* dla 20% najlepszych i najgorszych spółek (%)

	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9
J = 1	1,09 ***	1,19 ***	1,42 ***	1,31 ***	1,23 ***	1,19 ***	1,09 ***	1,00 ***	0,93 ***
J = 2	1,58 ***	1,77 ***	1,82 ***	1,65 ***	1,56 ***	1,47 ***	1,34 ***	1,23 ***	1,19 ***
J = 3	2,22 ***	2,19 ***	2,09 ***	1,97 ***	1,89 ***	1,74 ***	1,59 ***	1,49 ***	1,42 ***
J = 4	2,30 ***	2,27 ***	2,25 ***	2,07 ***	1,93 ***	1,76 ***	1,62 ***	1,52 ***	1,44 ***
J = 5	2,45 ***	2,42 ***	2,29 ***	2,12 ***	1,99 ***	1,86 ***	1,75 ***	1,63 ***	1,52 ***
J = 6	2,47 ***	2,46 ***	2,31 ***	2,17 ***	2,07 ***	1,94 ***	1,81 ***	1,68 ***	1,53 ***
J = 7	2,55 ***	2,48 ***	2,39 ***	2,23 ***	2,11 ***	1,97 ***	1,83 ***	1,68 ***	1,53 ***
J = 8	2,43 ***	2,45 ***	2,41 ***	2,29 ***	2,15 ***	1,98 ***	1,80 ***	1,63 ***	1,47 ***
J = 9	2,53 ***	2,54 ***	2,47 ***	2,30 ***	2,13 ***	1,93 ***	1,77 ***	1,59 ***	1,45 ***
J = 10	2,37 ***	2,43 ***	2,33 ***	2,16 ***	2,00 ***	1,80 ***	1,63 ***	1,46 ***	1,33 ***
J = 11	2,24 ***	2,28 ***	2,16 ***	1,98 ***	1,81 ***	1,65 ***	1,51 ***	1,36 ***	1,23 ***
J = 12	2,25 ***	2,23 ***	2,06 ***	1,89 ***	1,73 ***	1,60 ***	1,45 ***	1,30 ***	1,16 ***
J = 13	2,12 ***	2,04 ***	1,91 ***	1,72 ***	1,59 ***	1,46 ***	1,30 ***	1,13 ***	0,99 ***
J = 14	1,90 ***	1,93 ***	1,82 ***	1,70 ***	1,56 ***	1,42 ***	1,25 ***	1,09 ***	0,98 ***
J = 15	1,97 ***	1,94 ***	1,78 ***	1,66 ***	1,53 ***	1,32 ***	1,15 ***	1,02 ***	0,94 ***
J = 16	1,91 ***	1,93 ***	1,76 ***	1,62 ***	1,41 ***	1,25 ***	1,13 ***	1,02 ***	0,91 ***
J = 17	1,85 ***	1,79 ***	1,65 ***	1,47 ***	1,33 ***	1,20 ***	1,11 ***	0,98 ***	0,87 ***
J = 18	1,81 ***	1,69 ***	1,54 ***	1,36 ***	1,28 ***	1,18 ***	1,07 ***	0,95 ***	0,83 ***

*, **, *** – istotność wyników na poziomie 0,1; 0,05; 0,01.

Źródło: opracowanie własne.

Uwagi końcowe

Badania, których rezultaty przedstawiono w niniejszym artykule, po raz pierwszy zostały przeprowadzone na taką skalę dla Giełdy Papierów Wartościowych w Warszawie. Również w tak wielowariantowym ujęciu potwierdzono występowanie efektu *momentum*. Zaobserwowana na polskim rynku kapitałowym skala tego zjawiska wydaje się nawet większa niż na dojrzałych rynkach.

Warto jednak wspomnieć o ograniczeniach praktycznych możliwości wykorzystania zjawiska *momentum* w procesie inwestowania na rynku kapitałowym. Wiąże się to z brakiem możliwości realizacji krótkiej sprzedaży dla większości spółek. Być może, wraz z rozwojem polskiej giełdy, ograniczenie to zniknie.

Interesujące wydają się wyniki świadczące o zanikaniu zjawiska *momentum* w dłuższym okresie. Może to być przesłanką aplikacji strategii kontrariańskich opartych na zjawisku „odwrócenia”. Kwestia ta wymaga jednak dalszych szczegółowych badań.

Literatura

- Chan, L.K.C., Jegadeesh, N., Lakonishok, J. (1996). Momentum Strategies. *The Journal of Finance*, 5 (51), 1681–1713.
- Chan, L.K.C., Jegadeesh, N., Lakonishok, J. (1999). The Profitability of Momentum Strategies. *Financial Analysts Journal*, 6 (55), 80–90.
- Czajkowska, M. (2004). Zjawisko kontynuacji krótko- i średnioterminowych stóp zwrotu – momentum. *Studia i Prace Kolegium Zarządzania i Finansów SGH*, 52, 24–32.
- De Bondt, W., Thaler, R. (1985). Does the Stock Market Overreact? *Journal of Finance*, 3 (40), 793–805.
- Grotowski, M. (2003a). Momentum (1). *Nasz Rynek Kapitałowy*, 2, 133–139.
- Grotowski, M. (2003b). Momentum (2). *Nasz Rynek Kapitałowy*, 4, 103–108.
- Jegadeesh, N. (1990). Evidence of Predictable Behavior of Security Returns. *Journal of Finance*, 3 (45), 881–898.
- Jegadeesh, N., Titman (1993). Returns to buying winners and selling losers: implications for stock market efficiency. *Journal of Finance*, 1 (48), 65–89.
- Jegadeesh, N., Titman (2001). Profitability of momentum strategies: an evaluation of alternative explanations. *Journal of Finance*, 2 (56), 699–720.
- Lehmann, B. (1990). Fads, Martingales, and Market Efficiency. *Quarterly Journal of Economics*, 1 (105), 1–28.
- Li, X., Brooks, C., Miffre, J. (2009). Low-cost momentum strategies. *Journal of Asset Management*, 6 (9), 366–379.
- Liu, C., Lee, Y. (2001). Does the momentum strategy work universally? Evidence from the Japanese stock market. *Asia-Pacific Financial Markets*, 4 (8), 321–339.
- Merlo, P., Konarzewski, P. (2015). The Momentum Effect Exemplifies The Influence of Investors' Irrational Behaviour on Changing Prices of Shares and Stocks: An Analysis of The Momentum Effect on The Warsaw Stock Exchange. *e-Finanse*, 1 (11), 56–64.
- Pawłowska, J. (2015). Efektywność strategii momentum w inwestowaniu na Giełdzie Papierów Wartościowych w Warszawie. *Zeszyty Naukowe Uniwersytetu Szczecińskiego*, 855. *Finanse, Rynki Finansowe, Ubezpieczenia*, 74 (t. 1), 447–454.
- Rouwenhorst, K. G. (1998). International Momentum Strategies. *Journal of Finance*, 53, 267–284.
- Szyska, A. (2006). Zjawisko kontynuacji stóp zwrotu na Giełdzie Papierów Wartościowych w Warszawie. *Bank i Kredyt*, 8, 37–49.
- Wójtowicz, T. (2011). Efekt momentum na GPW w Warszawie w latach 2003–2010. *Ekonomia Menedżerska*, 9, 143–154.

MOMENTUM STRATEGY ON THE WARSAW STOCK EXCHANGE IN THE PERIOD 1995–2015

Abstract: *Purpose* – The aim of the research is to verify the existence of the momentum effect on the Warsaw Stock Exchange in Poland in the period 1995–2015.

Design/methodology/approach – Different portfolios were built according to the momentum strategy for investments for K months (where $K = 1, \dots, 36$). Such portfolios included both most growing and most declining equities during J -months ($J = 1, \dots, 36$). In the next step, portfolios of exclusively most growing companies were constructed. Simultaneously, it was repeated for most declining companies only.

Findings – The results provide evidence for the existence of the momentum effect during the period 1995–2015. Hence, they are in line with findings of the previous studies for earlier stages of the WSE development. However, detailed analysis proves for large differences of results in robustness tests.

Originality/value – The research was based on 1.296 investment strategies for 649 companies listed on the main equity market in Poland in the period 1995–2015. Hence, it is the most comprehensive study on the momentum effect for Polish equities.

Keywords: market anomalies, equity market efficiency, momentum effect, momentum strategy

Cytowanie

Czapiewski, L. (2018). Efekt *momentum* na GPW w Warszawie w latach 1995–2015. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 19–35. DOI: 10.18276/frfu.2018.94/2-02.

Inwestycje kolekcjonerskie. Analiza inwestycji na rynku win

Urszula Gierałtowska*

Streszczenie: *Cel* – Zasadniczym celem artykułu jest przybliżenie możliwości inwestowania na rynku przedmiotów kolekcjonerskich ze szczególnym uwzględnieniem oceny rentowności inwestycji na rynku win inwestycyjnych.

Metodologia badania – Inwestycje w przedmioty kolekcjonerskie są jedną z form inwestycji alternatywnych, które inwestorzy wykorzystują do dywersyfikacji portfela i ochrony przed inflacją. W sposób szczególny przedstawiono analizę inwestycji na rynku win inwestycyjnych. Omówiono główne cechy tego rynku oraz indeksy, które opisują sytuację na rynku i stanowią benchmark dla tej nowej grupy instrumentów alternatywnych. Dokonano również analizy rentowności inwestycji w wino na tle wybranych instrumentów klasycznych i alternatywnych.

Wynik – W artykule wskazano, że dla inwestorów nie zawsze najważniejszy jest zysk z inwestycji, ale również satysfakcjonujące są względy pozaeconomiczne: rozwój pasji, doznania zmysłowe, prestiż i uznanie otoczenia. Inwestycje na rynku inwestycji emocjonalnych należy traktować jako ciekawą alternatywę dla instrumentów klasycznych, chociaż niestety wciąż dostępną jedynie dla ludzi zamożnych.

Oryginalność/wartość – Artykuł stanowi wkład do badań i debaty na temat sytuacji na globalnym rynku kapitałowym oraz możliwości inwestowania na tym rynku.

Słowa kluczowe: inwestycje kolekcjonerskie, wino, sztuka, Liv-ex, indeksy rynku wina

Wprowadzenie

Inwestycje w przedmioty kolekcjonerskie są jedną z form inwestycji alternatywnych, które w ostatnim czasie cieszą się dużym zainteresowaniem inwestorów wykorzystujących te instrumenty do dywersyfikacji portfela i ochrony przed inflacją. Należy jednak pamiętać, że rynek ten charakteryzuje się własnymi prawami – przede wszystkim jest to rynek nieuregulowany prawnie, a inwestowanie na nim powinno mieć charakter długoterminowy. W przeciwieństwie do klasycznych instrumentów finansowych rynek ten jest mało płynny, ponieważ transakcje odbywają się rzadko, zazwyczaj w systemie aukcyjnym lub prywatnych umów. Natomiast ceny instrumentów uzależnione są przede wszystkim od zainteresowania kupującego.

Wśród najbardziej popularnych inwestycji emocjonalnych należy wymienić inwestycje w sztukę, klasyczne samochody, instrumenty muzyczne, rzadkie książki, biżuterię, alkohole czy ludzi. Wartość aktywów emocjonalnych jest niezależna od wydarzeń na rynkach giełdowych,

* Urszula Gierałtowska, doktor/adiunkt, Uniwersytet Szczeciński, Wydział Nauk Ekonomicznych i Zarządzania, Instytut Finansów, Katedra Ubezpieczeń i Rynków Kapitałowych, e-mail: urszula.gieraltowska@usz.edu.pl.

od decyzji banków centralnych czy trendów ekonomicznych. Kiedyś inwestycje takie były traktowane jako hobby przez snobistyczne elity bogaczy, obecnie są bardziej dostępne dla szerszego grona inwestorów i coraz bardziej popularne, nadal jednak wymagają specjalistycznej wiedzy.

Zasadniczym celem artykułu jest próba przybliżenia możliwości inwestowania na rynku przedmiotów kolekcjonerskich, gdzie nie zawsze liczy się zwrot finansowy, a zamożni inwestorzy często czerpią korzyści z rozwoju osobistych zainteresowań czy relacji międzyludzkich. W sposób szczególny analizie poddano rynek win, który uległ zasadniczym zmianom w końcu XX wieku, kiedy od 1999 roku w Londynie rozpoczęła działalność międzynarodowa giełda win. Wino stało się nową grupą aktywów – giełda umożliwiła obrót wyrafinowanymi markami win, których ceny notowane są w systemie ciągłym. Wpłynęło to na wzrost zainteresowania winem ze strony inwestorów indywidualnych, jak i instytucjonalnych, a to przełożyło się bezpośrednio na wzrost cen.

1. Inwestycje kolekcjonerskie jako alternatywna forma lokowania kapitału

W ostatnich latach na rynkach finansowych występowały zawirowania, co skłoniło inwestorów do poszukiwania nowych sfer lokowania środków i dywersyfikacji portfeli inwestycyjnych. Wiele osób nie jest świadomych możliwości inwestowania na rynku przedmiotów kolekcjonerskich, aczkolwiek instytucje rynku finansowego ułatwiają inwestowanie w tego typu walory (w sposób bezpośredni lub pośredni). Istnieje wiele powodów, dla których ludzie inwestują w przedmioty kolekcjonerskie. Inwestycje kolekcjonerskie łączą walor ekonomiczny z emocjonalnym, ponieważ poza kuszącymi potencjalnymi zyskami i faktem posiadania konkretnego, namacalnego dobra, inwestorzy mogą osiągnąć korzyści pozaekonomiczne (rozwój osobistych zainteresowań, doznania zmysłowe, prestiż i uznanie otoczenia, szeroka gama emocji) (Carey, 2008; Adamska, 2015). Carey zwraca dodatkowo uwagę, że pełna kolekcja ma większą wartość na rynku niż całkowita wartość poszczególnych jej pozycji. Dimson i Spaenjers (2014b), badając wybrane aktywa emocjonalne od 1900 roku, podkreślają, że mimo iż długoterminowe zyski nie są zbyt wysokie, to jednak aktywa emocjonalne zapewniają „psychiczną dywidendę”, jakiej nie dają aktywa finansowe.

Zakup przedmiotów kolekcjonerskich wiąże się jednak bardzo często z posiadaniem znacznych zasobów pieniężnych i specjalistycznej wiedzy. Inwestycje kolekcjonerskie postrzegane są jako element dywersyfikacji całego portfela osób zamożnych, ponieważ nie są związane z rynkiem giełdowym i są odporne na koniunkturę.

Jak wspomniano, oferta artykułów kolekcjonerskich, które mogą być przedmiotem inwestowania, jest bardzo szeroka. Są to przede wszystkim: biżuteria i kamienie szlachetne (diamenty, rubiny), dzieła sztuki, luksusowe samochody, alkohole kolekcjonerskie (wino, whisky), stare książki, instrumenty muzyczne, monety, znaczki pocztowe, konie, komiksy, zegarki, antyczne meble, chińska porcelana, autografy znanych ludzi, zabawki czy maskotki (Pruchnicka-Grabias, 2008, s. 217 i n.). Inwestowanie w przedmioty kolekcjonerskie wiąże się jednak z większym ryzykiem w porównaniu do instrumentów klasycznych, ale w długim horyzoncie inwestycyjnym może przynosić wyższe zyski (Dimson, Spaenjers, 2014a).

Inwestując w aktywa emocjonalne, należy uwzględnić m.in. ryzyko związane ze zmianą cen aktywów, ryzyko kursów walutowych, ryzyko błędnego wyboru aktywa, ryzyko utraty, uszkodzenia lub kradzieży dobra, możliwość fałszerstwa lub oszustwa. Obrót przedmiotami kolekcjonerskimi odbywa się na rynku nieregulowanym, co wiąże się z brakiem transparentności i rzetelnej oceny zagrożeń oraz realnej oceny osiągniętych wyników, jak również wysokimi kosztami transakcyjnymi. Rynek przedmiotów kolekcjonerskich charakteryzuje się małą płynnością, co oznacza, że wielu kolekcjonerów może mieć problem z zamknięciem inwestycji w określonym momencie po oczekiwanej cenie. Większość inwestorów oczekuje wzrostu ceny przedmiotów kolekcjonerskich w perspektywie długookresowej, ale w wypadku wielu dóbr potrzeba bardzo długiego horyzontu czasowego i korzystnych warunków rynkowych, by inwestycje te generowały zyski (Grable, Xuan, 2015, s. 78).

Jednak jak wskazują badania prowadzone przez firmę doradcą Knight Frank (por. tab. 1), w dłuższym czasie aktywa kolekcjonerskie przynoszą w większości wypadków dość wysokie stopy zwrotu. W ciągu ostatnich 10 lat najwięcej można było zarobić na klasycznych samochodach, winie i monetach. O dobrej kondycji inwestycji emocjonalnych świadczy również wysoka stopa zwrotu indeksu luksusowych inwestycji (KFLII), który w ciągu 10 lat wzrósł o 126%.

Tabela 1

Wybrane średnie stopy zwrotu różnych aktywów kolekcjonerskich (stan na koniec 2017 r.) (%)

Aktywa	1 rok	10 lat
Bizuteria	4	138
Chińska ceramika	-5	-3
Dzieła sztuki	21	78
KFLII*	7	126
Klasyczne samochody	2	334
Monety	4	182
Wino	11	192
Znaczki pocztowe	1	103

* KFLII – Knight Frank Luxury Investments Index – indeks luksusowych inwestycji.

Źródło: opracowanie własne na podstawie The Wealth Report (2018).

O dobrej kondycji rynku alternatywnego mogą świadczyć np. wyniki osiągnięte przez rynek dzieł sztuki. W 2017 roku trzy największe domy aukcyjne na świecie – Christie's, Sotheby's i Philips – zanotowały sprzedaż na poziomie 11,21 mld dolarów, co stanowiło wzrost o 25% w porównaniu do roku 2016¹. W tym roku doszło m.in. do sprzedaży obrazu *Salvator Mundi* Leonarda da Vinci za 450,3 mln dolarów, co jest absolutnym rekordem na rynku dzieł sztuki.

¹ Należy zwrócić uwagę, że największy udział w zysku domów aukcyjnych (29,3 %) miała sztuka powojenna i współczesna (TEFAF Art Market Report, 2018).

Inwestor na polskim rynku dzieł sztuki również może osiągać wysokie stopy zwrotu. W 2017 roku padł rekord sprzedażowy – obraz Wyspiańskiego *Macierzyństwo* został sprzedany za 4336 tys. zł, przy cenie wywoławczej 800 tys. zł. W tym samym roku na polskim rynku sztuki odbyły się 284 aukcje, które przyniosły łączny obrót 214,1 mln zł, co w porównaniu z rokiem 2016 oznaczało wzrost o 28% (obroty 167,1 mln zł na 269 aukcjach) (*Wyjątkowy i rekordowy rok 2017!*).

Rynki kolekcjonerskie na świecie są coraz lepiej zorganizowane: skupiają coraz więcej profesjonalistów, mają również swoje indeksy, które mogą być pomocne dla inwestorów. W przypadku luksusowych samochodów inwestorzy mogą posilkować się indeksami z rodziny Hagerty (Blue Chip, 1950s American, British Cars Index, Ferrari, Muscle Cars, Affordable Classic) lub HAGI (Historic Automobile Group International 50 Index Classic Car), natomiast w przypadku dzieł sztuki do określania cen i tendencji na rynku można wykorzystać m.in. indeks Mei Moses czy SASI (Skate's Art Stockes Index).

2. Rynek win kolekcjonerskich

Wino jako inwestycja ma długą historię w Europie, ale jest również znaczną klasą aktywów w USA. Z roku na rok zyskuje ono na popularności wśród inwestorów (Masset, Weisskopf, 2010) ze względu na coraz lepsze wyniki finansowe, jak również z uwagi na przyjemność posiadania rzadkiego i kosztownego produktu, co przynosi emocjonalną satysfakcję. Jednak większość win oferowanych na rynku nie nadaje się do długoterminowego inwestowania, ponieważ nie spełnia niezbędnych kryteriów.

Wino o wartości inwestycyjnej stanowi mniej niż 1% światowego rynku wina, z czego ok. 80% pochodzi z Bordeaux (Ricardo, 2013). Wino inwestycyjne musi charakteryzować się stałą oraz wysoką jakością, co potwierdzają opinie znanych krytyków winiarskich, np. Roberta Parkera, Jamesa Sucklinga czy Jancis Robinson. Podstawą klasyfikacji win jest ranking winnic oraz skala oceny Roberta Parkera², która uwzględnia potencjał sezonu, liczbę dni słonecznych, datę rozpoczęcia winobrania, pogłoski o szkodnikach, jak również rekomendowany czas do osiągnięcia pełnego bukietu smaku (ok. 20 lat). Roma, Di Martino i Perrone (2013) wskazują, że na cenę wina mają wpływ również czynniki takie, jak: rocznik, zawartość alkoholu, pochodzenie geograficzne, odmiana winorośli, wielkość producenta i potencjał piwniczny.

Starzenie się ma pozytywny wpływ na ceny wina, ponieważ z jednej strony staje się ono dojrzałe w smaku, a z drugiej – staje się produktem coraz rzadszym, co potencjalnie skutkuje wzrostem jego ceny (każda sprzedana butelka podnosi cenę pozostałych). Doskonałe wino osiągnie dojrzałość po 5–7 latach, choć według znawców optymalne walory smaku i najwyższą jakość ma wino leżakujące od 12 do 18 lat. Wina inwestycyjne mają trwałość

² Na podstawie przeprowadzonych badań statystycznych wykazano, że istnieje istotna zależność między oceną przyznaną przez Roberta Parkera a ceną wina (za: Hay, 2007).

40–50 lat, choć niektóre mogą przetrwać jeszcze dłużej³. Rekomendowany okres inwestycji w wino to minimum 5 lat.

Doradcy inwestycyjni, krytycy czy domy aukcyjne powinni być w stanie określić rodzaj wina na podstawie ratingu, sposobu przechowywania i transportowania, aby zidentyfikować cenionych dostawców i wyeliminować wina kiepskiej jakości. Inwestorzy nie wybierają win, tak jak wybierane są inne aktywa tradycyjne, a biorą pod uwagę przede wszystkim rocznik wina, region produkcji czy warunki przechowywania (Coffman, Nance, 2009).

Rynek win inwestycyjnych jest rynkiem zorganizowanym, ponieważ na świecie funkcjonuje kilka giełd, na których zawierane są transakcje kupna i sprzedaży wina. Najważniejszą i cieszącą się największym zaufaniem inwestorów giełdą wina jest londyńska Liv-ex, czyli London International Vintners Exchange, która funkcjonuje od 1999 roku, a jej powstanie miało ogromne znaczenie dla rynku win inwestycyjnych. Dzięki specjalnej platformie transakcyjnej Liv-ex podniosła standardy efektywności i przejrzystości na rynku, który wcześniej nie był transparentny. Liv-ex nie tylko umożliwia handel winem, ale również oferuje jego transport i przechowywanie w odpowiednich warunkach.


Spśród indeksów londyńskiej giełdy należy zwrócić uwagę na⁴: Liv-ex Fine Wine 50 Index, Liv-ex Fine Wine 100 Index, Liv-ex Fine Wine Investables Index oraz Liv-ex Fine Wine 500 Index. W większości indeksy te zdominowane są w swojej strukturze przez wina Bordeaux (ponad 95%), ale znaleźć tam można również wysoko ocenione wina burgundzkie, reńskie i włoskie.

Na rysunku 1 przedstawiono, jak zmieniały się ceny win notowanych na londyńskiej giełdzie. Rozpoczęta w styczniu 2004 roku inwestycja w wino przyniosła najwyższą stopę zwrotu w czerwcu 2011 roku – w przypadku indeksu Liv-ex Fine Wine 50 Index – 334,5%. Dla porównania na koniec 2017 roku inwestycja przyniosła 253,5% zysku (w porównaniu do 2004 r.). Jak wynika z danych zawartych w tabeli 2, ostatnie lata były dość optymistyczne dla inwestorów – przy rosnącym popycie na wina wzrastały również ich ceny oraz indeksy. Najbardziej zyskowne marki win w ciągu ostatnich pięciu lat to m.in. Petit Mouton 2011 (stopa zwrotu 165%), Krug Vintage Brut 1990 (162%) czy Domaine de la Romanee Grands Echezeaux 2006 (152 %) (Connington, 2017).

Największą barierą wejścia dla inwestorów są oczywiście pieniądze. Oprócz ceny zakupu wina inwestorzy muszą również ponieść koszty transakcyjne, opłaty za zarządzanie, przechowywanie i ubezpieczenie. Inwestorzy mogą lokować kapitał w sposób bezpośredni poprzez zakup skrzynek wina, które zostało już zabutelkowane i sklasyfikowane lub zakup wina na rynku pierwotnym (*en primeur* – zakup leżakującego w beczkach wina na kilkanaście miesięcy przed zabutelkowaniem) oraz za pośrednictwem domów aukcyjnych lub internetowych platform dedykowanych winom. Możliwe jest również inwestowanie pośrednie (co jest relatywnie mniej kosztowne): inwestowanie w indeks, w fundusze inwestycyjne zajmujące się obrotem wina czy zakup udziałów w winnicach.

³ Więcej na stronie www.premiercru.com.

⁴ Szczegółowe omówienie indeksów oraz ich komponentów jest dostępne na stronie www.liv-ex.com.



Rysunek 1. Wartość wybranych indeksów win w latach 2004–2017

Źródło: opracowanie własne na podstawie danych Liv-ex.

Tabela 2

Roczne zmiany indeksów win w latach 2010–2017 (%)

Rok	Liv-ex Fine Wine 100 Index		Liv-ex Fine Wine Investables Index		Liv-ex Fine Wine 50 Index		Liv-ex Bordeaux 500	
	t/t-1	t/0 (04 = 1)	t/t-1	t/0 (04 = 1)	t/t-1	t/0 (04 = 1)	t/t-1	t/0 (04 = 1)
2010	40,49	236,28	42,33	233,82	56,92	301,11	28,98	165,57
2011	-14,85	186,33	-10,03	200,35	-16,62	234,45	-1,70	162,04
2012	-8,92	160,78	-8,13	175,92	-9,64	202,22	-5,11	148,66
2013	-1,39	157,15	0,07	176,12	-3,02	193,09	0,77	150,57
2014	-7,25	138,50	-7,14	156,40	-8,96	166,83	-4,81	138,53
2015	-0,10	138,26	1,42	160,04	-0,73	164,88	-0,16	138,15
2016	24,79	197,33	24,35	223,35	26,70	235,61	23,09	193,15
2017	5,17	212,69	5,55	241,28	5,34	253,54	7,80	216,03

Źródło: opracowanie własne na podstawie danych Liv-ex.

3. Rynek win inwestycyjnych a rynek akcji i metali szlachetnych

Jak zauważono na wstępie, instrumenty alternatywne wykorzystywane są coraz częściej do dywersyfikacji portfela oraz ochrony przed inflacją i niebezpieczeństwami wahań koniunktury. Dzieje się tak, ponieważ instrumenty te wykazują niską korelację z tradycyjnymi klasami aktywów. W badaniach empirycznych, oprócz wymienionych wcześniej indeksów win, wykorzystano podstawowe indeksy giełd światowych⁵: FTSE 100 (uwzględniony z powodu lokalizacji największej giełdy win – pozwoli określić, czy stan brytyjskiej gospodarki wpływa na ceny win inwestycyjnych), indeksy amerykańskie S&P 500, DJ oraz niemiecki DAX (ze względu na znaczenie gospodarki amerykańskiej i niemieckiej dla Europy i świata). Pod uwagę zostały wzięte również główne indeksy Warszawskiej Giełdy Papierów Wartościowych – WIG i WIG 20. Do analiz wykorzystano również inne skuteczne dywersyfikatory portfela, które często wykorzystywane są przez inwestorów: złoto i srebro.

W tabelach 3–4 przedstawiono rentowność inwestycji w wino, w surowce (złoto i srebro) oraz rynek akcji. W sposób subiektywny dokonano wyodrębnienia kilku podokresów w latach 2004–2018. Najpierw podjęto próbę oceny sytuacji w okresie przed kryzysem (datowanym na upadek Lehman Brothers – lipiec 2008), w dalszej kolejności wyodrębniono okres największych cen wina (do czerwca 2011) oraz okres spadku cen (do czerwca 2014), a następnie przedstawiono sytuację bieżącą.

Tabela 3

Rentowność inwestycji w wybrane instrumenty klasyczne i alternatywne w wybranych okresach w latach 2004–2018 (%)

	01.2004– 03.2018	01.2004– 07.2008	07.2008– 06.2011	06.2011– 06.2014	06.2014– 03.2018
DAX	205,08	63,41	13,84	33,31	23,02
S&P 500	137,51	13,98	4,20	48,43	34,72
DJ	130,57	8,84	9,11	35,54	43,24
FTSE 250	235,39	52,64	34,75	31,75	23,77
WIG	180,39	103,68	14,17	7,27	12,40
WIG 20	40,43	74,87	1,80	–14,03	–8,24
Złoto	218,04	120,54	64,00	–12,65	0,67
Srebro	172,93	193,04	100,34	–40,41	–21,99
Liv-ex Fine Wine 100 Index	210,69	165,05	37,59	–35,28	31,64
Liv-ex Fine Wine Investables Index	240,18	147,09	49,67	–30,98	33,28
Liv-ex Fine Wine 50 Index	252,00	166,81	66,94	–40,24	32,24
Liv-ex Bordeaux 500	216,59	115,03	38,67	–21,07	34,51

Źródło: obliczenia własne.

⁵ Z uwagi na specyfikę indeksów win, wszelkie obliczenia przeprowadzone zostały dla miesięcznych stóp zwrotu.

Tabela 4

Przeciętne miesięczne stopy zwrotu i ryzyko dla wybranych instrumentów klasycznych i alternatywnych w latach 2004–2018 (%)

	01.2004– 03.2018		01.2004– 07.2008		07.2008– 06.2011		06.2011– 06.2014		06.2014– 03.2018	
	średnia	s(x)	średnia	s(x)	średnia	s(x)	średnia	s(x)	średnia	s(x)
DAX	0,782	5,013	0,982	4,054	0,576	6,384	0,944	5,210	0,570	6,674
S&P500	0,583	3,852	0,274	2,653	0,312	6,125	1,164	3,493	0,706	2,895
DJ	0,558	3,686	0,192	2,748	0,405	5,514	0,902	3,286	0,850	3,120
FTSE 250	0,808	4,386	0,842	3,738	1,094	6,793	0,850	4,023	0,510	2,649
WIG	0,765	5,623	1,463	5,646	0,687	7,751	0,317	4,938	0,330	3,743
WIG 20	0,376	5,915	1,195	5,857	0,364	7,793	–0,279	5,275	–0,091	4,488
Złoto	0,812	5,161	1,552	4,587	1,609	6,030	–0,185	6,167	0,087	3,807
Srebro	1,040	9,439	2,338	8,491	2,788	12,377	–0,862	10,515	–0,385	5,789
Liv-ex Fine Wine 100 Index	0,703	2,731	1,825	2,784	0,982	3,535	–1,179	2,082	0,619	1,111
Liv-ex Fine Wine Investables Index	0,747	2,401	1,685	2,340	1,211	3,176	–1,008	1,798	0,646	1,033
Liv-ex Fine Wine 50 Index	0,786	3,082	1,848	3,158	1,557	3,945	–1,392	2,342	0,632	1,331
Liv-ex Bordeaux 500	0,693	1,860	1,419	1,872	0,965	2,266	–0,645	1,430	0,666	1,045

Źródło: obliczenia własne.

Biorąc pod uwagę cały okres badawczy, należy zwrócić uwagę, że rentowność inwestycji w wino należy do jednych z najwyższych. Równie wysoką stopę zwrotu osiągnąłby inwestor, który zainwestował w złoto oraz indeksy DAX i FTSE 250. Równocześnie trzeba zauważyć, że poziom ryzyka mierzony odchyleniem standardowym jest w przypadku inwestycji w wino dużo niższy niż w wypadku innych analizowanych inwestycji, co oznacza, że inwestycje w wino były mniej ryzykowne od pozostałych.

W okresie hossy na rynku finansowym (do lipca 2008) badane inwestycje w instrumenty alternatywne przynosiły wyższą stopę zwrotu niż instrumenty klasyczne (indeksy giełdowe). W wypadku wina ryzyko było w większości niższe niż instrumentów klasycznych, natomiast inwestycje w surowce (zwłaszcza w srebro) charakteryzowały się większą zmiennością.

Okres bezpośrednio po kryzysie gospodarczym był korzystny zwłaszcza dla inwestorów, którzy inwestowali w metale szlachetne. Szczególnie wysokie stopy zwrotu inwestorzy osiągnęli w 2010 roku, kiedy rynek metali szlachetnych przeżywał rozkwit. Na świecie otwarto wiele funduszy skupiających się na rynku metali szlachetnych. Jednak szybko rosnąca cena metali doprowadziła do pęknięcia bańki spekulacyjnej, czego wynikiem były wyraźne spadki ich cen w późniejszym okresie (zwłaszcza w 2013 i 2015 r.). Również rentowność inwestycji w wino była dość wysoka, aczkolwiek rynek wina podupadł na skutek słabych zniw i ubogich roczników, jakie pojawiały się na rynku.

Szczególnie słabym okresem dla rynku win inwestycyjnych były lata 2011–2014. Wszystkie indeksy win zanotowały wyraźne straty, choć podobna sytuacja miała miejsce również na rynku surowców. Dużo lepszymi aktywami okazały się wówczas indeksy giełdowe, dla których stopa zwrotu była w większości dodatnia.

Od czerwca 2014 do marca 2018 roku sytuacja na rynku wina się ustabilizowała. Zyski wówczas osiągnęły porównywalne z zyskami z indeksów giełdowych, przy znacznie niższym ryzyku. Najgorsza sytuacja była na rynku metali szlachetnych, a w szczególności srebra, które zanotowało bardzo duże straty⁶.

Zaprezentowana analiza nie uwzględnia wysokich kosztów transakcyjnych, które są ponoszone w odniesieniu do większości instrumentów alternatywnych. Zarówno inwestycje w surowce, jak i inwestycje w wino obciążone są dodatkowymi kosztami transakcyjnymi, jak również kosztami związanymi z przechowywaniem, transportem i ubezpieczeniem dóbr. Dodatkowo należy pamiętać, że rynek win charakteryzuje się niewielką płynnością, co dodatkowo może zwiększyć ryzyko inwestycyjne.

Tabela 5

Korelacja między stopami zwrotu pomiędzy indeksami wina a pozostałymi aktywami w latach 2004–2018

	DAX	S&P 500	DJ	FTSE 250	WIG	WIG 20	Złoto	Srebro
Liv-ex Fine Wine 100 Index	0,2348	0,2198	0,2157	0,3103	0,3300	0,2685	0,1709	0,2242
Liv-ex Fine Wine Investables Index	0,2332	0,2101	0,2019	0,2963	0,3209	0,2532	0,1479	0,2286
Liv-ex Fine Wine 50 Index	0,2021	0,1885	0,1818	0,2927	0,3110	0,2608	0,1617	0,2079
Liv-ex Bordeaux 500	0,1599	0,1550	0,1592	0,2445	0,2826	0,2507	0,1828	0,2141

Źródło: obliczenia własne.

Baldi, Vandone i Peri (2010) dowodzą, że wino jest doceniane przez inwestorów z uwagi na słabą korelację z rynkiem akcji. W tabeli 5 przedstawiono współczynniki korelacji liniowej Pearsona między miesięcznymi stopami zwrotu w okresie od stycznia 2004 do marca 2018 roku. Korelacja liniowa kształtowała się na dość niskim, dodatnim poziomie, co oznacza, że między badanymi zmiennymi istniały dość słabe zależności. Z punktu widzenia inwestycyjnego jest to oczywiście dobra informacja, która pozwala inwestorowi na odpowiednią dywersyfikację portfela, a co za tym idzie, osiąganie zysków zarówno w okresie hossy, jak i bessy z uwagi na niewielką wzajemną zależność stóp zwrotu.

⁶ Z badań wynika, że ceny srebra rosną szybciej w czasie wzrostów cen złota, ale jednocześnie odnotowują głębsze spadki w okresie spadków cen złota.

Uwagi końcowe

Rynek inwestycji emocjonalnych nieustannie ewoluuje, co ma przede wszystkim związek z celami, jakie mogą realizować inwestorzy. Z jednej strony aktywa te są podstawą wielu kolekcji, które pozwalają inwestorom nie tylko osiągać zyski, ale również realizować marzenia z dzieciństwa. Sam fakt posiadania aktywów emocjonalnych wyzwala w wielu inwestorach emocje i doznania, które są bardziej satysfakcjonujące niż realizowane zyski. Z drugiej strony inwestorzy poszukują jednak instrumentów, które pozwolą zabezpieczyć ich portfel przed fluktuacjami, jakie mogą pojawiać się na rynku finansowym, a nawet niewielki udział w portfelu inwestycji o charakterze alternatywnym może znacznie zmniejszyć jego wrażliwość na zmiany kursów giełdowych. Zagadnienia związane z instrumentami emocjonalnymi są z pewnością niezmiernie interesujące, choć niestety trudno obiektywnie ocenić rentowność tych aktywów, w przeciwieństwie do klasycznych inwestycji. Czynniki, które sprzyjają rozwojowi rynku inwestycji emocjonalnych, są poprawa warunków życia i zdolność nabywania dóbr luksusowych nie tylko ze względu na zysk finansowy, ale również ze względu na prestiż i osobiste doznania estetyczne.

Powstanie londyńskiej giełdy wina Liv-ex spowodowało nie tylko wzrost zainteresowania rynkiem win inwestycyjnych, ale pozwoliło również analitykom na szersze zastosowanie metod ilościowych do badania tego wciąż mało popularnego rynku. Można zaryzykować stwierdzenie, że wino jest nie tylko dobrym uzupełnieniem naszego menu, lecz również portfela. Stanowi doskonały dywersyfikator portfela inwestycyjnego z uwagi na słabe skorelowanie z podstawowymi indeksami giełdowymi. Inwestycje na rynku inwestycji emocjonalnych należy zatem traktować jako ciekawą alternatywę dla instrumentów klasycznych, choć niestety wciąż jeszcze dostępną jedynie dla ludzi zamożnych.

Literatura

- Adamska, A. (2015). Inwestowanie w aktywa emocjonalne. *Zeszyty Naukowe Uniwersytetu Szczecińskiego*, 854. *Finanse, Rynki Finansowe, Ubezpieczenia*, 73, 295–302.
- Baldi, L., Vandone, D., Peri, M. (2010). Is Wine a Financial Parachute? W: Proceedings of the 4th International European Forum on System Dynamics and Innovation in Foods Networks (s. 472–487). Germany: University of Bonn.
- Carey, C. (2008). Modeling Collecting Behavior: The Role of Set Completion. *Journal of Economic Psychology*, 29, 336–347.
- Coffman, B.A., Nance, R.J. (2009). Wine: The Illiquid Investment Asset. *Journal of Financial Planning*, 22, 61–70.
- Connington, J. (2017). The top 10 Investment Wines That Returned 150pc in Five Years. *The Telegraph*. Pobrano z: www.telegraph.co.uk/investing/news/top-10-investment-wines-returned-150pc-five-years/ (kwiecień 2018).
- Dimson, E., Spaeniers, Ch. (2014a). Investing in Emotional Assets. *Financial Analysts Journal*, 70, 20–25.
- Dimson, E., Spaeniers, Ch. (2014b). The Investment Performance of Art and Other Collectibles. W: A. Dempster (red), *Risk and Uncertainty in the Art World* (s. 219–238). London: Bloomsbury Publishing.
- Grable, J.E., Xuan Chen (2015). Collectible, Investment, or Both: Evaluating the Attractiveness of Collectible Stamps. *Journal of Financial Service Professionals*, 69, 78–87.

- Hay, C. (2007). Globalisation and the Institutional Re-embedding of Markets: The Political Economy of Price Formation in the Bordeaux en primeur Market. *New Political Economy* 2 (12), 185–209.
- Masset, P., Weisskopf, J. (2010). *Raise your Glass: Wine Investment and the Financial Crisis*. Pobrano z: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1457906 (kwiecień 2018).
- Pruchnicka-Grabias, I. (red) (2008). *Inwestycje alternatywne*. Warszawa: CeDeWu.
- Ricardo, E.M. (2013). Investment Grade Wine – An Alternative Asset Class. *Wealth Society*, 6. Pobrano z: <http://www.trelliswineinvestments.com/wp-content/uploads/2011/10/Wealth-Society-Wine-Investment-Article2.pdf> (kwiecień 2018).
- Roma, P., Di Martino, G., Perrone, G. (2013). What to Show on the Wine Labels: A Hedonic Analysis of Price Drivers of Sicilian Wines. *Applied Economics*, 19 (45), 2765–2778.
- TEFAF Art Market Report (2018). The European Fine Art Foundation. Pobrano z: www.tefaf.com (kwiecień 2018).
- The Wealth Report (2018). *The Global Perspective on Prime Property and Investment*. Pobrano z: www.knightfrank.com/resources/wealthreport2018/the-wealth-report-2018.pdf (kwiecień 2018).
- Wyjątkowy i rekordowy rok 2017!.* Pobrano z: <http://www.artinfo.pl/pl/publikacje/artinformacje/wyjatkowy-i-rekordowy-rok-2017/?syear=2017&page=9> (kwiecień 2018).
- www.premiercru.com (kwiecień 2018).
- www.liv-ex.com (kwiecień 2018).

INVESTING IN LUXURY COLLECTIBLES. ANALYSIS OF INVESTMENTS ON WINE MARKET

Abstract: *Purpose* – The main aim of this paper is to present the possibilities of investing in collectibles market more closely.

Design/methodology/approach – The investments in collectibles market are one of the forms of the alternative investments. Collectibles are seen as a store of value due to their permanence, portability and rarity value. Collectibles can be used to diversify portfolios and protect against inflation. The analysis of investments on the “investment wine” market is presented in a special way. The author discuss the main features of this market and present indexes describing the market situation and creating a benchmark for this new group of alternative instruments. An analysis of wine investments profitability against the background of selected classical and alternative instruments was also made.

Findings – The author point out that investor profits are not always the most important, but non-economic reasons such as the development of passion, sensory experience, prestige and recognition of the environment are equally rewarding (collectibles are often referred to as emotional assets). The investments in collectibles market are as an interesting alternative to classical instruments, but still only for wealth people.

Originality/value – The article constitutes a contribution to research and debate on the situation in the global capital market and on the possibilities of investing in collectibles market.

Keywords: collectible investments, wine, art, Liv-ex, wine market indexes

Cytowanie

Gierałtowska, U. (2018). Inwestycje kolekcjonerskie. Analiza inwestycji na rynku win. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 37–47. DOI: 10.18276/frfu.2018.94/2-03.

Stan rynku kryptowalut w Polsce na tle światowego rozwoju

Ireneusz Miciuła, Monika Różycka*

Streszczenie: *Cel* – Celem artykułu jest ocena stanu polskiego rynku kryptowalut na tle rozwoju tego rynku na świecie oraz przedstawienie możliwych perspektyw rozwoju.

Metodologia badania – W ramach oceny rynku kryptowalut wykorzystano dane ilościowe i jakościowe, zawarte w badaniach statystycznych i raportach ilościowych, krajową i zagraniczną literaturę przedmiotu oraz studia przypadków dla konkretnych rozwiązań wprowadzanych na omawianym rynku.

Wynik – Przedstawiono rozwój globalnego rynku kryptowalut i historię najpopularniejszej kryptowaluty, bitcoina. Oceniono stan oraz strukturę polskiego rynku kryptowalut na tle globalnego rynku kryptowalut. Przedstawiono także możliwe ścieżki rozwoju rynku kryptowalut w Polsce i na świecie.

Oryginalność/wartość – Omówiono funkcjonowanie systemu finansowego opartego na kryptowalutach i jego znaczenie dla gospodarek oraz wskazano możliwe perspektywy rozwoju rynku kryptowalut w Polsce i na świecie.

Słowa kluczowe: kryptowaluty, innowacje finansowe, polski rynek kryptowalut, giełdy kryptowalut

Wprowadzenie

Rozwój rynku kryptowalut i jego implikacje dla gospodarki światowej wywołują duże zainteresowanie tym tematem. W artykule zaprezentowano analizę i ocenę rozwoju rynku kryptowalut w Polsce wraz z próbą przedstawienia perspektyw rozwoju, dokonane na tle rynku kryptowalut na świecie. Waluta kryptograficzna, popularnie zwana kryptowalutą, jest w definicji rozproszonym systemem księgowym opartym na kryptografii, który przechowuje informacje o stanie własności w konwencjonalnych jednostkach. Stan własności jest powiązany z poszczególnymi węzłami systemu (portfelami) w taki sposób, że tylko posiadacz odpowiedniego klucza prywatnego ma kontrolę nad danym portfelem i nie ma możliwości dwukrotnego wydania tej samej jednostki (Satoshi, 2008).

Handel internetowy wymaga występowania instytucji, które pełnią rolę zaufanych stron trzecich do przetwarzania płatności elektronicznych. Wprowadzany system płatności elektronicznych, oparty na dowodzie kryptograficznym, umożliwi dowolnym dwóm zainteresowanym stronom dokonywanie transakcji bezpośrednio ze sobą, bez potrzeby korzystania

* dr Ireneusz Miciuła, Uniwersytet Szczeciński, Wydział Nauk Ekonomicznych i Zarządzania, e-mail: ireneusz.miciula@usz.edu.pl; mgr Monika Różycka, Zachodniopomorska Szkoła Biznesu w Szczecinie, e-mail: moniwo@o2.pl.

z zaufanej strony trzeciej (Investopedia, 2018). *Peer-to-peer*, czyli model komunikacji internetowej, pozwala na przesyłanie płatności online bezpośrednio z jednej strony do drugiej bez pośrednictwa instytucji trzeciej. Podpisy cyfrowe stanowią część rozwiązania, ale główne korzyści są tracone, jeśli zaufana strona trzecia nadal jest zobowiązana do zapobiegania podwójnemu wydatkowaniu (Satoshi, 2008). System kryptowalut od strony operacyjnej zależy od rozwiązań w kryptologii, czyli dziedziny wiedzy o transmisji informacji zabezpieczonych przed nieuprawnionym dostępem (Christin, 2013). Jednak system ten oparty jest również na zaufaniu wobec instytucji potwierdzającej autentyczność kluczy kryptograficznych. Szuka rozwiązań, które mogłyby funkcjonować bez potrzeby zaufania stron trzecich. Może być jednak także źródłem kryzysów finansowych i „miejscem” ukrywania przestępstw, co powoduje zagrożenia i możliwe straty gospodarcze na świecie.

1. Rozwój rynku kryptowalut na świecie

Zainteresowanie kryptowalutami wynika z dwóch powodów. Przede wszystkim z idei wolności i niezależności od stron trzecich, takich jak państwo lub instytucje finansowe. Po drugie – z możliwych zysków inwestycyjnych, zarówno legalnych, jak i nielegalnych. Jedną z głównych cech kryptowalut jest to, że działa jak wirtualna waluta. Posiadacz takiej kryptowaluty przechowuje ją na swoim komputerze lub w aplikacji na smartfonach w tak zwanym portfelu, do którego dostęp ma tylko on. Jeśli chce dokonać transakcji, odbywa się ona elektronicznie, bezpośrednio między nim a wykonawcą. Każda jednostka kryptowalut ma unikalny kod, który zawiera informacje uniemożliwiające jej kopiowanie lub ponowne wydawanie. Kluczem do koncepcji kryptowalut jest to, że w obiegu nie ma regulatora. W związku z tym nie istnieje „Centralny Bank Kryptowalut”, który może zdecydować o zwiększeniu podaży kryptowaluty, a tym samym zmniejszeniu jej wartości. Twórca decyduje o tym, ile danej kryptowaluty znajduje się w obiegu na etapie tworzenia systemu. Dopóki nie nastąpi ponowna ingerencja w sposób funkcjonowania lub ilość kryptowaluty na rynku, jej wartość leży w rękach wolnego rynku. Handel kryptowalutami odbywa się drogą elektroniczną, bez udziału jakiegokolwiek systemu bankowego, bezpośrednio między użytkownikami kryptowaluty, tj. w technologii *peer-to-peer*. Oznacza to, że transakcja nie jest w żaden sposób nadzorowana (Moneycontrol, 2018).

Aktualnie najpopularniejszą kryptowalutą na świecie jest bitcoin. Ma on najwyższą kapitalizację rynkową oraz najwyższy kurs i często w ramach omawiania tematu kryptowalut jest flagowym przykładem. Powstał w 2009 roku. Nie wiadomo, kto jest jego twórcą. Prawie jednocześnie trzech informatycy (King, Oksman, Bry) opatentowali rozwiązania zbliżone do tych, na których opierał się system bitcoin, a to tylko jedni z wielu kandydatów na twórcę bitcoina (Rosic, 2018). Dzięki obserwacji rozwoju bitcoina można zauważyć charakterystyczne fazy dla całego rynku kryptowalut. Pierwsza faza, która jest zauważalna na wykresach wszystkich nowych kryptowalut, to tzw. faza zdobywania zaufania. Kolejne etapy rozwoju są widoczne na wykresach kryptowalut, które przeszły do kolejnych faz: drugiej (zainteresowania, wzrostu) i trzeciej (ustalenia wartości maksymalnej dla okresu). Czas między

kolejnymi fazami jest różny dla konkretnych kryptowalut i zależy od wielu czynników. Wiele jest przykładów kryptowalut, które powstały i upadły już w pierwszej fazie cyklu życia. Równie dużo jest przykładów kryptowalut, które przeszły do fazy trzeciej, osiągnęły wartość maksymalną, po czym nastąpił bardzo szybki spadek wartości lub momentalny upadek i kryptowaluta przestała funkcjonować. Często zdarza się także, że nie ma tak dużego zainteresowania ze strony inwestorów i dofinansowania jak w przypadku bitcoina, co prowadzi do bankructwa i upadku funkcjonowania tych kryptowalut. Powoduje to wiele szkód dla zaufania systemowi kryptowalut i daje argumenty ich przeciwnikom, że system może być wykorzystywany do tworzenia piramid finansowych i innych oszustw. Te same negatywne skutki dla systemu wywołują upadki giełd i platform wymiany kryptowalut, chociaż w tym wypadku często zdarza się, że odpowiedzialność za te wydarzenia ponoszą również obrońcy obecnego systemu, czyli państwa i instytucje finansowe. Przykładowo w Polsce nakładane są dodatkowe podatki, a instytucje finansowe, takie jak banki, odmawiają świadczenia usług na rzecz takich podmiotów. Analizując historię najpopularniejszej kryptowaluty, widzimy, że państwa mają różne podejście do systemu kryptowalut, od całkowitego zakazu i ustanawiania kar do pełnej uznawalności. Część państw często korzysta z nałożonych obciążeń podatkowych nałożonych na kryptowaluty, ale nie zamierza ustanawiać konkretnych przepisów prawa w tej kwestii, choć uznaje tę działalność za legalną.

Bitcoin jest flagowym przykładem systemu kryptowalut, z których większość powtarza prawidłowości zachowań tego systemu. Obecnie notowanych jest ponad 1500 kryptowalut na ponad 7000 specjalnych giełdach (tak zwanych kryptogiełdach). Duża liczba, szczególnie lokalnych kryptowalut, ma krótką historię funkcjonowania, po czym znika z rynku. Powoduje to negatywne skutki dla odbierania systemu kryptowalut jako całości, ponieważ z tego powodu istnieje wiele przykładów na wykorzystanie go dla celów oszustw finansowych. Niewątpliwie jednak istnieją również zalety, których uwypuklenie wymagałoby pewnych rozwiązań prawnych i technologicznych. Kryptowaluta jest pierwszym wynalazkiem w systemie finansowym, który został opracowany poza instytucjami finansowymi i bez współpracy z nimi. Jest nowatorska i nie wykorzystuje istniejących systemów finansowych. Co więcej, stanowi zagrożenie dla *status quo* systemu finansowego. Niewątpliwie ta cecha niezależności i braku konieczności zaufania trzeciej stronie (instytucjom tworzącym i regulującym system finansowy) byłaby rewolucją w świecie finansów, w którym wymagane byłyby jedynie dwie strony transakcji. Jest to główny argument za tworzeniem systemu, który nie jest zależny i poddany wpływom regulatorów finansowych. Niestety w praktyce, mimo wizji rozproszenia systemu i zależności tylko od stron transakcji, nie funkcjonuje to w ten sposób. W rzeczywistości system oparty na technologii również ma regulatorów i bazuje na zaufaniu, ale jest to naturalna cecha systemów społecznych, które muszą być oparte o uznawalność społeczną. Wiele kryptowalut i giełd wymiany zależy niestety od grupy osób lub wręcz jednej osoby, która może mieć niegodziwe zamiary, czego przykładem jest wiele oszustw związanych z rynkiem kryptowalut. Z jednej strony manipulacji dokonują twórcy lub regulatorzy zasad funkcjonowania, łącznie ze zmianami w samym algorytmie, a z drugiej – gracze, mający olbrzymi wpływ na cały rynek. Doskonałym przykładem jest najpopularniejsza kryptowaluta, której 97% jest w rękach zaledwie 4% wszystkich portfeli (Chaparro, 2018). Dlatego też coraz więcej osób i instytucji

ze świata finansów przestrzega przed inwestowaniem w kryptowaluty, mówiąc o piramidzie finansowej, bańce spekulacyjnej czy zwykłych oszustwach. Obecnie, gdy kryptowaluty nie funkcjonują jako prawne środki płatnicze, jest to forma spekulacji lub tezauryzacji wartości. Niewątpliwie jednak technologia ta ma wielkie możliwości, dlatego też tak trudno zdefiniować system, który funkcjonowałby w bezpieczny sposób (Miciuła, Miciuła, 2015). Ustanowienie takiego systemu w rzeczywistości nie jest zadaniem łatwym i niewątpliwie wymaga strony zaufanej, która będzie czuwać nad bezpieczeństwem obrotów. Wydaje się, że finansowy system na bazie omawianej technologii powinien zmierzać w tę stronę. Aktualnie, pomimo wielkiego zainteresowania, sam problem nie jest do końca rozpoznany, o czym świadczą chociażby różne podejścia krajów świata do odpowiedniego stosowania tej technologii.

2. Stan polskiego rynku kryptowalut

Rozwój rynku kryptowalut w danym państwie zależy od decyzji prawnych rządów w stosunku do tego rynku. Jak już wspomniano, możliwości jest dużo, od całkowitego zakazu kryptowalut do pełnego przyjęcia jako pełnoprawnego środka płatniczego, a pomiędzy jest jeszcze wiele innych możliwości i rozwiązań. Obecnie na liście państw, przez które przechodzą największe kryptowalutowe transakcje, Polska zajmuje 24. miejsce. Ma to oczywiście związek z decyzjami państwa w stosunku do rynku kryptowalut. W Polsce kryptowaluty nie są uznawane za jednostkę walutową, środek płatniczy czy też pieniądz elektroniczny, mimo to tworzenie jednostek w ramach wbudowanego w system algorytmu według prawa jest legalne, dlatego posiadacze kryptowalut nie mogą korzystać z ulg podatkowych przewidzianych dla handlu walutą. Zresztą odnosi się wrażenie, że, tak jak w Polsce, państwa celowo nakładają obciążenia podatkowe, by zasilić budżet państwa. Dodatkowo w wielu państwach występuje dezinformacja i brak regulacji, dlatego opodatkowanie obrotu kryptowalutami wywołuje wiele kontrowersji. Można śmiało powiedzieć, że jest to jeden z tych przykładów, gdzie regulacje prawne nie nadążają za rzeczywistością gospodarczą. 20 kwietnia 2018 roku w Polsce miał miejsce protest przeciwko niejasnemu wprowadzaniu obowiązków podatkowych w stosunku do obrotu kryptowalutami. Aktualnie w zakresie podatku dochodowego od osób fizycznych uzyskany przychód z tytułu sprzedaży zakupionych kryptowalut będzie stanowił przychód z praw majątkowych, o których mowa w art. 18 ustawy o podatku dochodowym od osób fizycznych (Ratajczak, 2018). Konsekwencją uzyskiwania przychodu z praw majątkowych jest spoczywający na sprzedającym obowiązek wykazania tegoż przychodu i obliczenia podatku należnego od sumy uzyskanych dochodów według skali podatkowej. Natomiast w trakcie roku podatkowego nie ciąży obowiązek wpłacania zaliczek na podatek dochodowy od osób fizycznych. W ramach podatku VAT punktem zwrotnym w podejściu organów podatkowych do kwestii opodatkowania był wyrok Trybunału Sprawiedliwości Unii Europejskiej w sprawie *Skatteverket/David Hedqvist*, w którym TSUE stwierdził, że zwolnienie z VAT jest przewidziane art. 135 ust. 1 lit. e ustawy o podatku dochodowym (Tabaka, 2018). Powyższe stanowisko TSUE jest stosowane obecnie przez organy podatkowe, które wcześniej odmawiały zastosowania zwolnienia do tego typu usług. W obecnych interpretacjach organy podatkowe

stoją na stanowisku, że do obrotu kryptowalutami ma zastosowanie zwolnienie z art. 43 ust. 1 pkt 7 ustawy o podatku od towarów i usług, odnoszące się do transakcji dotyczących walut, banknotów i monet używanych jako prawny środek płatniczy (Piech, Kacwin, 2017).

Rynek kryptowalut to wciąż rynek nieuregulowany, więc nie ma narzędzi, by chronić konsumentów. W momencie gdy taki podmiot zakończyłby działalność z dnia na dzień, instytucje nie są w stanie pomóc klientom odzyskać ich środki. Niewątpliwie jednak w Polsce występuje niesprzyjający klimat regulacyjno-podatkowy oraz chaos informacyjny, co powoduje ograniczenie stosowania kryptowalut. Dodatkowo cztery banki (BZ WBK, mBank, PKO BP i Alior Bank) wypowiedziały umowy firmom, które prowadziły platformy umożliwiające inwestowanie w kryptowaluty. W wyniku takich działań największe giełdy wymiany kryptowalut w Polsce ogłosiły, że rozważają przeniesienie swojej działalności poza granice kraju. W tabeli 1 przedstawiono największe giełdy wymiany kryptowalut działające w Polsce.

Tabela 1

Największe giełdy wymiany kryptowalut w Polsce

	BitBay	BitMaszyna	Coinroom	NevBit	BitMarket.pl
	1	2	3	4	5
Siedziba firmy (adres)	BitBay Sp. z o.o., ul. Zacisze 2/6, 40-025 Katowice	Androbayt Sp. z o.o., ul. Słowackiego 12, 87-800 Włocławek	Coinroom Sp. z o.o., ul. Janka Muzykanta 60, 02-188 Warszawa	Nevonet Sp. z o.o., ul. Kołłątaja 47/43, 81-333 Gdynia	Michau Enterprises Limited Chytron 26, 1075 Nikozja Cypr
Kapitał zakładowy (PLN)	100 000	50 000	100 000	10 000	–
Dostępne kryptowaluty	BTC, LTC, ETH, XRP, XBC, DASH, LSK, BTG	BTC, LTC, LSK, DOGE, KBM	BTC, LTC, ETH, DASH, XMR, BCC, PIVX, ZCOIN, LSK, ZEC, ETC, VTC ZOI, HUSH	BTC, LTC	BTC, LTC, PPC, DOGE, XRP, BTG
Dostępne waluty	PLN, USD, EUR	PLN	PLN, USD, EUR, GBP, NOK, CHF, CZK, DKK	PLN	PLN, EUR
Prowizje od transakcji	0,43–0,25%	0%	0,39–0,15%	0%	0,00–0,45%
Prowizje od wpłat / wypłat w PLN	Brak / 1 PLN (przelew zwykły), 10 PLN – (wypłata ekspresowa), 10–20 PLN (z bankomatu)	0 (zwykły przelew), 1,9% (Pay By Link) / 1 PLN (zwykły przelew), 10 PLN (wypłata ekspresowa)	0 (zwykły przelew), 2% (Dotpay) / 1 PLN (dla PLN, USD, EUR – zwykły przelew)	0/1 PLN	brak/1 PLN (zwykły przelew), 0,95% kwoty wypłaty (ekspresowo), 10–20 PLN (z bankomatu)

	1	2	3	4	5
Prowizje od wpłat / wypłat w BTC	0 BTC/0.0002 BTC	brak/0,0001 BTC	brak/0,0001 BTC	brak 0,0001 BTC	brak/0,0001 BTC
Minimalna ilość potwierdzeń BTC	3	3	3	6	3
Minimalna wartość oferty (zakupu/sprzedaży) BTC	5 PLN	10 PLN	dłużne: 1 krypto: 0,001	0.01 BTC	0,01 / 0,01
Minimalna kwota wypłaty (PLN/BTC)	5 PLN/ 0.001 BTC	większa od opłat / BTC bez ograniczeń	większa od opłat / BTC bez ograniczeń	10 PLN / 0,0002 BTC	10 / 0,01
Dźwignia	–	–	–	–	dźwignia + Swap
Metody wypłat	przelew zwykły, ekspresowy, wypłata przekazem pieniężnym InPost, wypłata w bankomacie	zwykły przelew, przelew ekspresowy	zwykły przelew, przelew ekspresowy	zwykły przelew	zwykły przelew, BlueCash
Uwierzytelnianie dwuskładnikowe	token SMS, Rublon lub Google Authenticator	TAK (2FA)	Google Authenticator	–	TAK (2FA)
Wymóg weryfikacji	po przekroczeniu 15 000 euro wpłat na konto	handel	wypłata fiatów	wypłata fiatów	po przekroczeniu 1000 euro wpłat na konto
Sposób weryfikacji	skan/zdjęcie dokumentu tożsamości	wykonanie przelewu bankowego na wskazane konto	zasilenie z konta bankowego dowolną kwotą lub skan dokumentu tożsamości	zasilenie z konta bankowego dowolną kwotą	przelew z polskiego konta bankowego oraz wysłanie kodu pod adres rejestrującego się lub skan dowodu
Ograniczenia niezweryfikowanego użytkownika	brak do czasu przekroczenia sumy wpłat / powyżej 15 000 EUR w skali roku	zablokowane: wpłata / wypłata środków – handel	Zablokowane: wypłaty klasycznych walut	Zablokowane: wypłaty klasycznych walut	Zablokowane: wypłaty z konta – zamknięcie konta
Czas trwania procesu weryfikacji	do 12 godzin	do 24 godzin	do 48 godzin	–	do 48 godzin

Źródło: opracowanie własne na podstawie Piech, Kacwin (2017); Bitcoin.pl (2018).

Udział procentowy przedstawionych giełd wymiany kryptowalut w Polsce w 2017 roku wyglądał następująco: BitBay (49%), Bitmarket.pl (28%), Coinroom (16%), Nevbit (4%) i Bitmaszyna (3%), a dzienne obroty na rynku kryptowalut w Polsce sięgały 50 mln zł. Według Morgan Stanley najwięcej zarejestrowanych giełd kryptowalutowych znajduje się w Wielkiej Brytanii (Polskie radio, 2018).

Biorąc pod uwagę obecnie istniejące kryptowaluty, do trzech pierwszych kryptowalut polskich, które powstały na początku roku 2014, zaliczamy:

1. PolCoin (PLC) – jest pierwszą polską wirtualną walutą. Powstała w styczniu 2014 roku jako klon zyskującego na popularności bitcoina. Oparty jest na tym samym algorytmie SHA256d. Obecnie jest to całkowicie polski projekt, w który zaangażowany jest wyłącznie polski zespół twórców oraz polski kapitał. Używany jest jako środek płatniczy. PolCoinami obecnie można płacić m.in. w jednym sklepie stacjonarnym oraz kilku sklepach internetowych (PolCoin, 2014).
2. PolishCoin (PCC) – stworzony, by pomóc ludziom z Polski w „zrobieniu pierwszego kroku” w świecie cyfrowych pieniędzy, bowiem pod względem nowych technologii, dostępu do nich, ale też świadomości ich istnienia, Polska jest „na tyłach” świata i Europy. Eksperci uważają, że do tej pory jest to najlepiej przygotowana kryptowaluta z Polski i jest dostępna na jednej z giełd wymiany kryptowalut. Docelowo twórcy chcą na tyle rozpowszechnić PCC, aby trafił na światowe giełdy kryptowalut.
3. PLNcoin (PLNc) – zadebiutował 17 marca 2014 roku. Twórcy, jeszcze przed oficjalnym otwarciem, wydobyli 2 mln monet. Rozdawali je za darmo w zamian za założenie konta na ich stronie, na której powstało 16 tysięcy profili. Waluta pojawiła się na kilku giełdach, a firma organizująca podróże zagraniczne zadeklarowała, że respektuje wpłaty w PLNc obok bitcoina i litecoina.

Twórcy tych polskich kryptowalut deklarują: „Stworzyliśmy je po to, żeby mieć możliwość płacenia w wirtualnym świecie za co chcemy i komu chcemy bez kontroli instytucji bankowych czy rządu” (Woźnicki, 2018). Jest to najczęściej wymieniany argument podkreślający zalety rozwoju nowego systemu finansowego opartego na kryptowalutach. Niestety możliwe są także niekontrolowane zagrożenia. Sceptycy wskazują, że wielu twórców kryptowalut stara się wykorzystać panujący klimat społeczno-gospodarczy, aby zarobić dzięki *pump and dump* („pompuj i rzuć”) – sztucznie windują ceny, aby sprzedać monety lub akcje, gdy tylko inni się nimi zainteresują. Następuje krótkotrwały wzrost wartości kryptowaluty bez intencji budowania nowej infrastruktury gospodarczej. Twórcom marzy się, że pewnego dnia właśnie ich monety staną się środkiem płatniczym. Natomiast użytkownicy, którzy decydują się kopać i gromadzić monety, w większym stopniu traktują to jako szansę inwestycyjną niż system finansowy. Jednak wiele tworzonych kryptowalut przestaje funkcjonować (Jagielowicz, 2018).

Na polskim rynku kryptowalut jak do tej pory mamy do czynienia niestety głównie z chaosem. Jedyna pozytywna decyzja w stosunku do rynku kryptowalut to wydany komunikat organów państwowych, że obrót kryptowalutami nie narusza prawa krajowego i unijnego, ale ich posiadanie wiąże się z dużym ryzykiem. Jest to stanowczo zbyt mała aktywność organów ustawodawczych. Natomiast na kanwie wydarzeń globalnych w Polsce również zmierza się w kierunku wprowadzenia na rynku kryptowalut pewnych regulacji prawnych.

Przykładem będą nowe obowiązki informacyjne. Ministerstwo Finansów chce objąć obowiązkiem informacyjnym firmy handlujące kryptowalutami. Niewątpliwie należy analizować historię kryptowalut w państwach, które w tym sektorze mają doświadczenia i rozwiązania funkcjonujące od lat. Upadek giełdy wymiany kryptowalut w Japonii miał miejsce już w 2014 roku i na tych doświadczeniach wprowadzono regulacje, które będą wdrażane także w Polsce. Szkoda, że nie zrobiono tego wcześniej, ucząc się na doświadczeniach innych, funkcjonujących już rynków. W Polsce historia się powtórzyła i wprowadzane regulacje są pokłosiem upadku giełdy kryptowalut Bitcurex w październiku 2016 roku. Giełdę zamknięto, a ponad 2 tysiące bitcoinów należących do użytkowników zdefraudowano. W związku z brakiem regulacji żadne instytucje ochrony inwestorów czy konsumentów nie mają prawnych możliwości pomocy. Do najważniejszych czynników, które wpływają na kursy kryptowalut, zaliczamy:

1. Zaufanie użytkowników oraz inwestorów – kryptowaluty to wirtualne pieniądze, które nie mają żadnej formy fizycznej. Ich wartość w głównej mierze jest uzasadniona ofertą i popytem użytkowników (Miciuła, 2014). Jeżeli popyt na kryptowaluty wzrasta, podwyższa się również ich kurs. I odwrotnie – jeśli ludzie pozbywają się kryptowalut, ich kurs maleje.
2. Używalność kryptowalut – kryptowaluty powstały jako waluta wirtualna dla szybkich i tanich transakcji internetowych. Im więcej sprzedawców wspiera i przyjmuje kryptowaluty, tym bardziej poszerza się ich wykorzystanie w praktyce. W państwach o niestabilnej gospodarce waluty wirtualne są kupowane w celu zachowania wartości własnych pieniędzy. Kryptowaluty bez praktycznego wykorzystania wcześniej lub później przestaną istnieć.
3. Interwencja organów regulacyjnych i nadzorczych – jeżeli rząd zacznie wspierać kryptowaluty, zaufanie użytkowników wzrośnie, a to spowoduje również wzrost wartości kryptowaluty. Przykładowo kiedy w kwietniu 2017 roku Japonia uznała bitcoina za walutę legalną, jego wartość znacznie wzrosła. Działa to jednak również odwrotnie. Ograniczenia lub zakazy kryptowalut ze strony urzędów państwowych mogą rozpocząć gwałtowny spadek rynku. Na przykład we wrześniu 2017 roku Chiny zakazały kryptowalut, co spowodowało spadek ich kursu.
4. Uwaga mediów – informacje o wzrastającej wartości kryptowalut przyciągają nowych inwestorów, co powoduje podwyższenie popytu i wzrost kursu kryptowalut. Również poglądy znanych osobistości i firm wpływają na wzrost lub spadek cen. Przykładem była opinia dyrektora generalnego JPMorgan, Jamiego Dimona, z września 2017 roku, który określił bitcoin jako oszustwo, na co rynek zareagował spadkiem (Investplus, 2018).
5. Manipulowanie kursami – inwestorzy wykorzystują technikę manipulacyjną zwaną *pump and dump*, polegającą na zakupie kryptowaluty za niską cenę i jej późniejszej medialnej propagacji w celu przyciągnięcia nowych inwestorów, którzy spowodują wzrost kursu (Miciuła, 2015). Mechanizm ten dotyczy często samych twórców lub organizatorów i zarządzających wieloma kryptowalutami, które powstają w celach stworzenia swoistej piramidy finansowej, tylko i wyłącznie dla własnego zarobku. Metoda ta (kupić tanio – przekonać innych do zakupu – drogo sprzedać) nie sprzyja niestety naturalnemu rozwojowi kryptowalut.

6. Czynniki technologiczne (twórcy, zarządcy, regulatorzy) – zmianą kursu można również manipulować przez zmiany w kodzie źródłowym, np. przez implementację ulepszeń lub zmian w liczbie monet dostępnych na rynku.
7. Czynniki organizacyjne – np. czynniki wpływające na wydobywanie kryptowaluty (trudności wydobycia czy cena energii, która, jak wynika z analiz w literaturze przedmiotu, dochodzi do wartości porównywalnych z ceną energii, która zaspokaja zwyczajowe funkcjonowanie tysięcy gospodarstw domowych) (Luther, 2016).
8. Substytuty – również aktywa na giełdzie wpływają na siebie wzajemnie, rosnące zainteresowanie bitcoinem niektórzy uważają np. za przyczynę spadku złota itp. Natomiast wartość bitcoina ma wpływ na kursy innych walut kryptograficznych, które stają się alternatywą dla innych inwestycji czy spekulacji.

Uwagi końcowe

Kryptowaluty nie są kontrolowane przez rządy ani banki centralne, w związku z tym państwa stosują wobec nich najczęściej dwie taktyki. Część przyjęła strategię strusia, mając nadzieję, że moda na kryptowaluty sama przeminie, i nie wprowadza specjalnych regulacji, jedynie te, które wynikają z prawa krajów zrzeszonych, czyli dotyczą na przykład państw członkowskich Unii Europejskiej, jak w przypadku Polski. Inne próbują choć w części przejąć kontrolę nad rynkiem kryptowalut i zarabiać na nim. Na przykład w Japonii bitcoin stał się pełnoprawnym środkiem płatniczym. Jednak ze względu na doświadczenie (upadek w 2014 roku giełdy Mt. Gox i zniknięcie 850 tysięcy bitcoinów) rząd Japonii wprowadza jasno określone uregulowania. Podmioty, które chcą prowadzić usługi wymiany kryptowalut, muszą widnieć w rejestrze Agencji Usług Finansowych Japonii, która prowadzi dodatkowy nadzór. Takie kraje, jak Rosja, Ukraina, Białoruś i Litwa opowiadają się za chęcią zarabiania. Kraje te, leżące w pobliżu Polski, ze względu na wprowadzone ograniczenia i niejasne działania organów państwowych po prostu przejmą uczestników rynku kryptowalut i to oni będą zarabiać. Natomiast rząd Polski w ramach realnej aktywności robi niewiele. Co prawda częściowo rozwiązano chaos związany z interpretacją podatkową dotyczącą rynku kryptowalut, ale nie rozwiano ostatecznie wszystkich wątpliwości, co wpływa negatywnie na inwestorów. Polski rząd stwierdził, że nie zamierza w tej sprawie wydawać ogólnej interpretacji podatkowej. Jak twierdzą analitycy, zaniedbania te (brak regulacji prawnych) powodują, że jako kraj tracimy szansę na jeszcze większe środki pieniężne dla budżetu państwa (np. za 2016 r. omawiana branża w Polsce zapłaciła ponad 100 mln zł podatków).

Najczęstsze opinie dotyczące kryptowalut są takie, że wirtualne waluty będą nowym etapem rozwoju lub rajem dla oszustów. Należy wprowadzić pewne rozwiązania i regulacje, niewykluczone, że oparte na zaufaniu do instytucji międzynarodowych, które spowodują przesunięcie prawdopodobieństwa wykorzystania możliwości stosowania kryptowalut w stronę rozwoju społeczeństwa informacyjnego, ograniczając tym samym możliwości oszustom i innym przestępstwom.

Literatura

- Abram, G., Szymura, T. (2017). *Bitcoin – Still Cryptocurrency or Currency?* Pobrano z: <http://www.infor.pl/Bitcoin-jeszcze-kryptowaluta-czy-juz-waluta.html#ftn16> (22.04.2018).
- Bitcoin.pl. (2018) *The Review of Polish Stock Exchanges for Cryptocurrencies*. Pobrano z: <http://bitcoin.pl/zestawienie-gield> (2.05.2018).
- Coindesk (2018). *Bitcoin (USD) Price*. Pobrano z: <https://www.coindesk.com/price/> (5.05.2018).
- Polskie radio (2018). *Cryptocurrencies – Whether Investing in Them Is Safe?* Pobrano z: <https://www.polskieradio.pl/Artykul/2068287,Jak-uregulowac-obrot-kryptowalutami> (30.04.2018).
- Chaparro, F. (2018). *97 Percent Bitcoin Are Kept in Only 4 Percent All Portfolios*. Pobrano z: <https://businessinsider.com.pl/finance/kryptowaluty/analiza-credit-suisse/6g9r9zg> (22.04.2018).
- Christin, N. (2013). *Traveling the Silk Road: A Measurement Analysis of a Large Anonymous Online Marketplace*. W: *Proceedings of the 22nd International World Wide Web Conference* (s. 213–224). Rio de Janeiro.
- Investopedia (2018). *What Is a Cryptocurrency*. Pobrano z: <https://www.investopedia.com/terms/c/cryptocurrency.asp> (28.04.2018).
- Investplus (2018). *Cryptocurrencies – Courses*. Pobrano z: <https://investplus.cz/pl/kryptowaluty-kursy-pln-usd-ranking-kryptowalut/> (20.06.2018).
- Jagielowicz, M. (2018). *Cryptocurrencies – To Invest or Not?* Pobrano z: <https://www.polskieradio.pl/42/273/Artykul/2107569,Kryptowaluty-czy-inwestowanie-w-nie-jest-bezpieczne> (21.06.2018).
- Luther, W.J. (2016). *Cryptocurrencies, Network Effects and Switching Costs*. *Contemporary Economic Policy*, 34, 553–571.
- Miciuła, I. (2014). *The Concept of FTS Analysis in Forecasting Trends of Exchange Rate Changes*. *Economics & Sociology*, 2 (7), 172–182.
- Miciuła, I. (2015). *Financial Innovations on the Currency Market as New Instruments to Risk Management*. *Journal of International Studiem*, 1 (8), 138–149.
- Miciuła, I., Miciuła, K. (2015). *Kluczowe trendy dla budowania biznesu w branży big data*. *Zeszyty Naukowe Uniwersytetu Szczecińskiego*, 863. *Studia Informatica*, 36, 51–63.
- Money. (2018). *BitCoin*. Pobrano z: <https://www.money.pl/pieniadze/bitcoin/> (14.07.2018).
- Moneycontrol (2018). *Philippines Boxer to Launch His Own Cryptocurrency*. Pobrano z: <https://www.moneycontrol.com/news/business/cryptocurrency/philippines-boxer-to-launch-his-own-cryptocurrency-2553257.html> (21.07.2018).
- Piech, K., Kacwin, M. (2017). *Stan rynku kryptowalut w Polsce oraz możliwe przychody podatkowe państwa*. Pobrano z: <https://www.gov.pl/documents/31305/436699/Stan+rynku+kryptowalut+w+Polsce.pdf/ceb489cf-aaf5-fdef-fb04-62724e1b62b9> (3.08.2018).
- PolCoin (2014). *What is PolCoin?* Pobrano z: <https://polcoin.pl/> (12.07.2018).
- Ratajczak, M. (2018). *Niecodzienny protest inwestujących w kryptowaluty*. Pobrano z: <https://www.money.pl/gospodarka/artykul/rozliczenie-kryptowalut-podatki,185,0,2403001.html> (18.07.2018).
- Rosic, A. (2018). *What is Cryptocurrency? Everything You Need to Know*. Pobrano z: <https://blockgeeks.com/what-is-cryptocurrency/> (2.08.2018).
- Satoshi, N. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. Pobrano z: <http://bitcoin.org/bitcoin.pdf> (4.08.2018).
- Tabaka, M. (2018). *Polish Investors Are Plunged into the Chaos of Tax Interpretations Regarding Cryptocurrencies*. Pobrano z: <https://www.spidersweb.pl/2018/04/chaos-w-rozliczeniach-podatkowych-z-kryptowalut.html> (26.07.2018).
- Ustawa z dnia 26 lipca 1991 r. o podatku dochodowym od osób fizycznych.
- Ustawa z dnia 11 marca 2004 r. o podatku od towarów i usług.
- Woźnicki, Ł. (2018). *PolishCoin, PolCoin i PLNc – w Polsce są już aż trzy narodowe kryptowaluty. Dlaczego?* Pobrano z: http://wyborcza.pl/1,76842,15707096,PolishCoin__PolCoin_i_PLNc_.html (15.07.2018).

THE STATE OF THE CRYPTOCURRENCY MARKET IN POLAND ON THE BACKGROUND OF GLOBAL DEVELOPMENT

Abstract: *Purpose* – The aim of the article is to assess the condition of the Polish cryptocurrency market on the background of the development of this market in the world and to present possible development perspectives.

Research methodology – As part of the cryptocurrency market evaluation, quantitative and qualitative data included in statistical surveys and quantitative reports, national and foreign literature on the subject and case studies for specific solutions implemented on the discussed market.

Findings – The development of the global cryptocurrency market and the history of the most popular cryptocurrency Bitcoin is presented. Assessment of the condition and structure of the Polish cryptocurrency market against the background of the global cryptocurrency market. The possible paths of cryptocurrency market development in Poland and in the world were also presented.

Originality/value – An overview of the functioning of the financial system based on cryptocurrencies and its importance for economies. Indication of possible development prospects for the crypto market in Poland and in the world.

Keywords: cryptocurrencies, financial innovations, Polish cryptocurrency market, cryptocurrency exchanges

Cytowanie

Miciuła, I., Różycka, M. (2018). Stan rynku kryptowalut w Polsce na tle światowego rozwoju. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 49–59. DOI: 10.18276/frfu.2018.94/2-04.

Prognozowanie kursu bitcoina z wykorzystaniem sztucznej sieci neuronowej

Artur Paździor, Grzegorz Kłosowski*

Streszczenie: *Cel* – Celem artykułu jest prezentacja koncepcji systemu informatycznego umożliwiającego prognozowanie kursu kryptowaluty bitcoin (BTC) w odniesieniu do waluty euro.

Metodologia badania – Na potrzeby realizacji tak sformułowanego celu opracowano model sztucznej sieci neuronowej – perceptronu wielowarstwowego. W ramach badań dobrano zmienne wejściowe, od których uzależniono kurs BTC. Pozyskano także odpowiednie dane, pochodzące z dziennych notowań kursów wybranych walut i metali. Dane poddano stosownej obróbce matematycznej w celu ich dostosowania do wykorzystania podczas uczenia, walidacji i testowania sztucznej sieci neuronowej.

Oryginalność/wartość – Oryginalny był dobór wektora zmiennych wejściowych, umożliwiających prognozowanie kursu BTC. Wyniki przeprowadzonych eksperymentów potwierdziły wysoką skuteczność prognozowania w perspektywie jedno- i dwudniowej. Wysokie wartości współczynnika regresji (R) i mały błąd średniokwadratowy (MSE) świadczą o tym, że opracowany system predykcyjny prawidłowo przewiduje kursy analizowanej kryptowaluty nie tylko w odniesieniu do danych historycznych, lecz także dla wartości bieżących i przyszłych.

Słowa kluczowe: rynek kapitałowy, kryptowaluty, prognozowanie zmian kursów, sztuczna sieć neuronowa

Wprowadzenie

Struktura, charakter, specyfika funkcjonowania, rodzaj instrumentów oraz rodzaje analiz wykorzystywanych w procesach inwestycyjnych na rynku finansowym w ostatnich dekadach uległy znaczącym przeobrażeniom. Jeszcze na przełomie XX i XXI wieku wydawało się, że wektor zmian na światowych rynkach finansowych jest klarowny i zmierza w kierunku popularyzacji instrumentów pochodnych (derywatów)¹. Na popularyzację instrumentów pochodnych nie miały wpływu także zjawisko globalizacji rynków finansowych, które doprowadziło do znacznego wzrostu wolumenu i dywersyfikacji transakcji finansowych (Stankovska,

* dr hab. inż. Artur Paździor prof. PL, Politechnika Lubelska, Wydział Zarządzania, Katedra Finansów i Rachunkowości, e-mail: a.pazdzior@pollub.pl; dr inż. Grzegorz Kłosowski, Politechnika Lubelska, Wydział Zarządzania, Katedra Organizacji Przedsiębiorstwa, e-mail: g.klosowski@pollub.pl.

¹ Rynek terminowy w Polsce upowszechnił się w drugiej połowie lat 90. XX wieku, kiedy to 16 stycznia 1998 r. po raz pierwszy uruchomiono rynek terminowy poprzez wprowadzenie do obrotu kontraktów terminowych na indeks WIG20. Obecnie (wg stanu na 10.09.2018 r.) na Gieldzie Papierów Wartościowych w Warszawie notowane są zarówno kontrakty terminowe (indeksowe, akcyjne, walutowe, obligacyjne, na stopy procentowe), jak i opcje na indeks WIG20 (*Instrumenty pochodne...*).

2017, s. 81–82). Zdaniem przedstawicieli największych korporacji świata (85% spośród 500) instrumenty pochodne są bardzo ważne lub ważne dla ich strategii zarządzania ryzykiem. Średni dzienny obrót instrumentami pochodnymi OTC (będącymi przedmiotem obrotu poza rynkiem regulowanym) wynosi około 2,3 biliona USD, zaś szacunkowa ich wartość rynkowa kształtuje się na poziomie około 25 bilionów USD (*The Value of Derivatives...*).

Instrumenty pochodne z jednej strony odgrywają ważną rolę w zabezpieczaniu i zarządzaniu ryzykiem, z drugiej są jednak także zagrożeniem dla stabilności rynków finansowych oraz gospodarki (przykłady firm bankrutujących z powodu inwestycji w opcje walutowe). Mimo wielu korzyści wynikających chociażby z hedgingu, arbitrażu oraz wykorzystania dźwigni finansowej, w ostatniej dekadzie wolumen i wartość obrotu instrumentami pochodnymi na rynkach światowych i w Polsce uległy ograniczeniu (*Statistical Release...*).

W odniesieniu do kontraktów indeksowych oraz akcyjnych ich umiarkowana popularność w ostatniej dekadzie mogła być następstwem korzystnych tendencji na rynku kapitałowym, widocznych od września 2011 roku. Niemalą wpływ na wymienione tendencje mogły mieć również nowe regulacje dotyczące nieregulowanego rynku instrumentów pochodnych, które wprowadzono w wielu krajach po globalnym kryzysie finansowym (Pyka, Muszyński, 2015, s. 118). Przyczyn spadku dynamiki zainteresowania derywatami szukać zatem należy także w innych obszarach, spośród których kluczowym wydaje się alternatywna możliwość generowania wyraźnie wyższych niż dla rynków akcyjnych oczekiwanych dochodów. Do takich przyczyn należy niewątpliwie powstanie i upowszechnienie rynku walut szyfrowanych (tzw. kryptowalut).

Celem artykułu jest prezentacja koncepcji systemu informatycznego umożliwiającego prognozowanie kursu kryptowaluty bitcoin (BTC) w odniesieniu do waluty euro (EUR). Na potrzeby realizacji tak sformułowanego celu opracowano model sztucznej sieci neuronowej – perceptronu wielowarstwowego (Kłosowski, Klepka, Nowacka, 2018). W ramach badań dokonano doboru zmiennych wejściowych, od których uzależniono kurs BTC. Pozyskano także odpowiednie dane, pochodzące z dziennych notowań kursów wybranych walut i metali. Dane poddano stosownej obróbce matematycznej w celu ich dostosowania do wykorzystania podczas uczenia, walidacji i testowania sztucznej sieci neuronowej (Huang, Lai, Nakamori, Wang, 2004).

Do realizacji celu wykorzystano badania literaturowe, dane finansowe dostępne na portalach finansowych oraz narzędzia statystyczne i ekonometryczne.

1. Geneza i istota rynku kryptowalut


Handel bitcoinem został zainicjowany w 2009 roku, a więc w okresie tuż po kryzysie finansowym. Koncepcja tej kryptowaluty została opracowana w latach 2007–2009 m.in. przez autora dokumentu *Bitcoin: Peer-to-Peer Electronic Cash System*, kryjącego się pod pseudonimem Satoshi Nakamoto.

Bitcoin jest walutą niepaństwową, która korzysta z niepaństwowego systemu płatniczego. System transakcyjny oparty jest na zasobach internetowych i dlatego jest zdecentralizo-

wany, w przeciwieństwie do tradycyjnych systemów płatności. Znaczącą różnicą między konwencjonalnymi walutami a bitcoinem jest to, że kryptowaluty mogą być „emitowane”, a raczej tworzone na całym świecie przez tzw. górników. Osoby te analizują historyczne transakcje bitcoinowe, tworząc tzw. łańcuch bloków *blockchain*, określane także mianem księgi systemu bitcoin, stanowiący swego rodzaju szkielet infrastruktury systemu bitcoin (Möbert, 2018, s. 3). W celu ograniczenia inflacji bitcoinów jego autorzy przewidzieli w algorytmie skończoną ich liczbę, która kiedykolwiek zostanie wygenerowana. Zapobieżono w ten sposób ich nadmiarowi, zapewniając rzadkość tej kryptowaluty (DeVries, 2016, s. 1).

Bitcoin jest zatem wirtualną jednostką pieniężną i dlatego nie ma fizycznej reprezentacji. Jednostka tej kryptowaluty jest podzielna i można ją podzielić na 100 milionów „satoshis”, będących najmniejszą częścią bitcoina. W systemie kryptowalut nie występuje centralny organ z wyłącznym prawem do prowadzenia rachunków. Istnieje za to zdefiniowany zestaw reguł i możliwość indywidualnego monitorowania innych uczestników, którzy zwykle pozostają anonimowi dzięki użyciu pseudonimów (Berentsen, Schär, 2018, s. 4–5). Użytkownicy mogą zatem realizować transakcje bez nadzoru stron trzecich. Pomimo tego, że bitcoin, w odróżnieniu od obiektów fizycznych oraz pierwotnych środków płatności (np. surowców i towarów), nie ma wartości wewnętrznej, jego wartość opiera się głównie na zaufaniu i akceptacji (por. DeVries, 2016, s. 1, 6).

Mimo tego system walut szyfrowanych zyskuje coraz większą popularność. W ciągu dziewięciu lat od rynkowego debiutu bitcoina, liczba kryptowalut notowanych na całym świecie ukształtowała się na poziomie 1501 szt. (Investing.com). Realnym odzwierciedleniem popularności bitcoina jest zmienność jego ceny. W perspektywie ostatnich kilku lat kurs tej kryptowaluty odznaczał się wyjątkowo dużą zmiennością, co umożliwiało inwestorom zrealizowanie wyraźnie wyższej niż w przypadku konwencjonalnych walut, czy też alternatywnych instrumentów finansowych, stopy zwrotu z zaangażowanego kapitału (por. rys. 1).



Rysunek 1. Kurs bitcoina w okresie od września 2016 r. do września 2018 r.


Źródło: Market Price (USD).

Zwiększenie zainteresowania bitcoinem i innymi kryptowalutami wynika bezpośrednio ze wzrostu poziomu zaufania użytkowników, rozwoju technologii IT, upowszechniania Internetu, większych możliwości generowania dochodu, globalnej mobilności itp. (DeVries, 2016, s. 2). Można także postawić hipotezę, że popularność ta jest także efektem spadającego

zaufania do tradycyjnych systemów walutowych oraz polityki monetarnej banków centralnych, szczególnie w kontekście realizacji tzw. luzowania ilościowego (Corbet, McHugh, Meegan, 2017, s. 61). Istotnym motywem może być także fakt nieuregulowania podatkowego w wielu krajach transakcji kryptowalutami, co stwarza możliwość obrotu tymi instrumentami bez konieczności regulowania wysokich zobowiązań wobec organów skarbowych.

Biorąc pod uwagę dynamicznie rosnącą popularność oraz zagrożenia wynikające z handlu kryptowalutami, handel walutami szyfrowanymi porównuje się niekiedy do pierwszej piramidy finansowej, nazywanej schematem Ponziego (*Ponzi Schemes...*). Różnica polega jednak na tym, że o ile schemat i autor pierwszej udokumentowanej piramidy finansowej był w miarę klarowny, o tyle w wypadku rynku kryptowalut autor procesu jest anonimowy, a schemat, a raczej algorytm, ma charakter zdecentralizowany i niezinstytucjonalizowany. Sami zaś uczestnicy tego rynku, w przeciwieństwie do typowej piramidy, nie są biernymi dawcami kapitału, ale realnie kształtują poziom kursu kryptowalut (Kmita, 2017).

Stwierdzić jednak należy, że formułowanie tezy o tzw. spekulacyjnej bańce kryptowalutowej wydaje się nieoparte rzetelną analizą. W zestawieniu największych tego typu wydarzeń w nowożytnej historii rynków kapitałowych wartość rynku walut szyfrowanych, mimo dynamicznego rozwoju tego rynku, w dalszym ciągu pozostaje znikoma (por. rys. 2).



Rysunek 2. Rozmiar największych baniek spekulacyjnych w nowożytnej historii (z uwzględnieniem inflacji)

Źródło: Baumann, Lesoismier (2017), s. 9.

Mimo tego, że obecnie notowanych jest ponad 1,5 tys. różnego rodzaju kryptowalut, rynek ten jest mocno scentralizowany. Dowodem na to jest fakt, że 50% kapitalizacji rynkowej walut szyfrowanych stanowi bitcoin (Baumann, Lesoismier, 2017, s. 13). Na kolejnych miejscach znajdują się następujące kryptowaluty (Baumann, Lesoismier, 2017, s. 14–18):

- ethereum (13% ogólnej kapitalizacji),
- ripple (5%),
- litecoin (poniżej 1%),
- gnosis (ok. 0,4%),
- omisego (ok. 0,3%).

2. Model systemu prognozowania

Z uwagi na to, że pozyskanie danych w postaci dziennych kursów otwarcia walut i metali z poszczególnych dni na przestrzeni ostatnich lat nie nastręcza trudności, zdecydowano się na zastosowanie modelu predykcyjnego opartego na sztucznych sieciach neuronowych typu perceptron wielowarstwowy. Innym argumentem świadczącym na korzyść tego rozwiązania był dostęp do szerokiej wiedzy eksperckiej w zakresie teoretycznej i praktycznej znajomości rynków finansowych i giełd towarowych. Obserwacje i analizy zjawisk zachodzących na powyższych rynkach pozwoliły w szczególności dostrzec korelacje zachodzące między kursami pewnych par walutowych (w tym także bitcoina) oraz cenami miedzi i złota. W sytuacji, kiedy z dużą dozą prawdopodobieństwa można stwierdzić istnienie prawidłowości w zakresie zmian kursów walut i wybranych metali, lecz jednocześnie nie sposób przedstawić skutecznej zależności jednych kursów walut lub cen metali od kursów i cen innych walorów w postaci odpowiedniej formuły matematycznej, odpowiednim rozwiązaniem są heurystyki oraz sztuczne sieci neuronowe.

Na rysunku 3 przedstawiono model neuronowego systemu prognozowania kursu bitcoina. Model zawiera cztery wejścia. Są nimi dzienne kursy otwarcia dwóch par walutowych: EUR/USD, USD/CNH oraz kursy miedzi (USD) i złota (USD). Sieć neuronowa ma jedną warstwę ukrytą, składającą się z 10 neuronów. Wyściem prezentowanego modelu jest kurs waluty bitcoin (BTC) wyrażony w euro. Zarówno w warstwie ukrytej, jak i w warstwie wyjściowej zastosowano hiperboliczną, stycznie sigmoidalną funkcję przejścia.


Dane wejściowe:

1. EUR/USD
2. USD/CNH
3. Miedź [USD]
4. Złoto [USD]

Wartość

prognozowana:

1. BTC/EUR



Rysunek 3. Model neuronowego systemu prognozowania kursu bitcoina

Źródło: opracowanie własne.

Zauważono, że waluty chińskie, zarówno juan pozakontynentalny CNH, jak i kontynentalny CNY, są silnie skorelowane z bitcoinem. W modelu zastosowano CNH, ponieważ korelacja tej waluty z bitcoinem jest większa ($R \approx +0,72$) niż CNY ($R \approx +0,68$). Ponadto można zauważyć, że wraz z osłabianiem kursu juana od sierpnia 2015 roku ma miejsce wzrost kursu bitcoina. Analogia ta nie jest oczywista, kiedy porównuje się wykresy kursów obu walut w krótkich okresach gwałtownych fluktuacji (np. w sierpniu 2015 r., gdy nastąpiła dramatyczna dewaluacja juana). Sytuacja wydaje się bardziej klarowna, kiedy analizowane są okresy roczne lub dłuższe.

3. Cel badań i metoda badawcza

Celem badań było rozwiązanie problemu związanego z procesem inwestowania na rynku walutowym. Prace badawcze dotyczyły w szczególności opracowania metody prognozowania kursu kryptowaluty BTC na podstawie bieżących danych z rynku walutowego i giełdy towarowej (metali). Ostatecznie powstały dwa modele decyzyjne, z których pierwszy prognozował kurs BTC w horyzoncie czasu wynoszącym jeden dzień, natomiast zadaniem modelu drugiego była analogiczna predykcja w perspektywie dwóch dni.

Jak już wcześniej wspomniano, w badaniach zastosowano metodę symulacji komputerowej z wykorzystaniem sztucznej sieci neuronowej. Opracowano model systemu decyzyjnego, opartego na sztucznej inteligencji. Z uwagi na dostęp do danych historycznych zastosowano perceptron wielowarstwowy z dziesięcioma neuronami w jednej warstwie ukrytej.

Przeprowadzono dwie serie eksperymentów symulacyjnych. Pierwsza miała na celu zweryfikowanie jakości systemu prognozującego kwotowania pary walutowej BTC/EUR z jednodniowym wyprzedzeniem. Seria druga weryfikowała jakość systemu predykcyjnego, przewidującego kurs BTC z wyprzedzeniem dwudniowym.


Zbiór danych wykorzystanych w obu modelach zawierał dzienne notowania (kursy otwarcia) czterech wejść i jednego wyjścia. Liczność zbiorów danych wykorzystanych w eksperymencie pierwszym wynosiła 270 przypadków, natomiast w drugim 269 przypadków.

4. Sposób opracowania danych

Dane zostały przygotowane z wykorzystaniem oprogramowania Excel i Access. Utrudnieniem był fakt, że notowania kursów walut fiducjarnych (np. USD, EUR) nie obejmują weekendów i świąt, podczas gdy kryptowaluta bitcoin jest notowana bez przerwy. Prócz tego kalendarz dziennych notowań metali różni się od kalendarza notowań par walutowych. Z tego powodu należało odrzucić dane zawierające niepełne notowania, czyli te, które nie obejmowały wszystkich wartości wejściowych i wyjściowych w danym dniu.

W celu ujednolicenia wielkości wejściowych i wyjściowych wszystkie liczby sprowadzono do wartości z przedziału od 0 do 1. We wszystkich przypadkach zastosowano przeliczenie, w którym wartość rzeczywistą podzielono przez wartość maksymalną spośród wszystkich wartości z całego zbioru danych. Jest to sprawdzona praktyka, zalecana podczas projektowania sztucznych sieci neuronowych. W ten sposób uzyskano metadane, które zaprezentowano w tabeli 2.

Na rysunku 4 przedstawiono relacje typu „jeden do jednego”, łączące wszystkie notowania. Kluczem indeksowania wszystkich macierzy danych jest data. Taki sposób powiązania tabel jest gwarancją spójności danych.



Rysunek 4. Relacje tabel z danymi indeksowanymi według dat notowań

Źródło: opracowanie własne.

W tabeli 1 przedstawiono wstępnie uporządkowane dane. Z uwagi na duże różnice nominalów dane w postaci bezpośredniej mogłyby powodować dodatkowe trudności w wytrenowaniu sieci neuronowej. Należało je poddać dalszej obróbce matematycznej.

Tabela 1

Fragment zbioru danych rzeczywistych

Data notowania	Wejścia				Wyjście
	EUR–USD [USD]	USD–CNH [CNH]	Miedź* [USD]	Złoto** [USD]	BTC/EUR + 1 [EUR]
4.01.2016	1,0856	6,5687	2,071	1063,4	397,2
5.01.2016	1,0829	6,6274	2,074	1075,6	399,86
6.01.2016	1,0746	6,6419	2,079	1081,6	400,38
7.01.2016	1,0778	6,6953	2,06	1091,6	399,49
8.01.2016	1,0931	6,6808	2,018	1111,1	420,03
11.01.2016	1,0922	6,6814	1,976	1105,7	410,67

* Cena za jeden funt.

** Cena za jedną uncję trojańską (jubilerską).

Źródło: opracowanie własne.

W tabeli 2 przedstawiono odpowiednio zredukowane i zagregowane metadane, gotowe do użycia w celu wytrenowania sieci neuronowej prognozującej kurs BTC/EUR z jednodniowym wyprzedzeniem.

Tabela 2

Fragment zbioru metadanych

Data notowania	Wejścia				Wyjście
	EUR–USD	USD–CNH	Miedź	Złoto	BTC/EUR + 1
4.01.2016	0,9415	0,9421	0,7656	0,7752	0,3681
5.01.2016	0,9391	0,9505	0,7667	0,7841	0,3686
6.01.2016	0,9319	0,9526	0,7686	0,7885	0,3678
7.01.2016	0,9347	0,9602	0,7616	0,7958	0,3867
8.01.2016	0,9480	0,9582	0,7460	0,8100	0,3781
11.01.2016	0,9472	0,9582	0,7305	0,8061	0,3814

Źródło: opracowanie własne.

W ramach przeprowadzonych badań przetestowano trzy metody uczenia sieci neuronowej, wykorzystujące algorytmy:

- Levenberga-Marquardta, algorytm wyposażony w funkcję redukcji pamięci przy dużych zbiorach uczących,
- regularyzacji bayesowskiej, zmodyfikowany algorytm Levenberga-Marquardta, opracowany w celu budowania sieci o lepszych własnościach uogólniania, posiadający procedury optymalizacji liczby parametrów sieci (Foresee, Hagan, 1997),
- skalowalny algorytm gradientów sprzężonych, który nie wykorzystuje metody liniowego przeszukiwania w każdej iteracji, ale używa kombinowanej metody algorytmu Levenberga-Marquardta i zbieżności gradientów sprzężonych.

5. Rezultaty eksperymentów z sieciami neuronowymi do prognozowania kursów BTC

Zarówno w przypadku sieci prognozującej kursy CTC w perspektywie jednodniowej, jak i dwudniowej najlepsze efekty uzyskano, stosując algorytm regularyzacji bayesowskiej. Ten typ algorytmu angażuje nieco więcej czasu niż pozostałe algorytmy uczenia sieci, lecz oferuje wysokie wskaźniki generalizacji. Dobre wskaźniki sieci osiągnęte są nawet wtedy, gdy zbiór uczący jest zaszumiony i zawiera niewielką liczbę przypadków uczących. Zatrzymanie procesu uczenia następowało w sytuacji, kiedy w kolejnych sześciu iteracjach błąd walidacji nie malał. Ta technika ustalania momentu zakończenia procesu trenowania sieci znana jest pod nazwą wczesnego zatrzymania (*early stopping*). Dzięki jej zastosowaniu, trenowana sieć nie ulega przeuczeniu (*overfitting*) i uzyskuje zdolność generalizacji.

Na rysunku 5 przedstawiono wskaźniki świadczące o jakości uzyskanej sieci. Na uwagę zasługuje zwłaszcza wysoki współczynnik regresji (R) i mały błąd średniokwadratowy (MSE) w obu przypadkach.

Results			
	Samples	MSE	R
Training:	188	3.71119e-4	9.90138e-1
Validation:	41	0.00000e-0	0.00000e-0
Testing:	41	5.66711e-4	9.91067e-1


Results			
	Samples	MSE	R
Training:	189	4.49489e-4	9.88426e-1
Validation:	40	0.00000e-0	0.00000e-0
Testing:	40	5.43413e-4	9.88589e-1

Rysunek 5. Rezultaty uczenia sieci do prognozowania BTC w horyzoncie jednodniowym (u góry) i dwudniowym (u dołu)

Źródło: opracowanie własne.

Duże znaczenie mają niski błąd MSE i wysoki (bliski 1) współczynnik R w odniesieniu do zbioru testowego. Przypadki z tego zbioru nie uczestniczą w procesie uczenia sieci, w związku z tym prawidłowe prognozy w odniesieniu do zbioru testowego świadczą o tym, że sieć nie została „przeuczona”. Innymi słowy, niskie wartości MSE i wysokie R świadczą o tym, że opracowany system predykcyjny prawidłowo przewiduje kursy bitcoina nie tylko w odniesieniu do danych historycznych, lecz także dla wartości bieżących i przyszłych.


Na rysunku 6 zaprezentowano wykres wartości błędu średniokwadratowego w trakcie procesu uczenia sieci. Zarówno w przypadku predykcji jednodniowej, jak i dwudniowej wartości MSE są niskie. Ponadto kształty wykresów (brak fluktuacji, hiperbola) wskazują na wysoką jakość otrzymanych systemów predykcyjnych.



Rysunek 6. Wykres błędu średniokwadratowego w trakcie uczenia sieci w horyzoncie jednodniowym (po lewej) i dwudniowym (po prawej)

Źródło: opracowanie własne.


Na rysunku 7 zaprezentowano histogramy błędów MSE. Każdy pionowy słupek wskazuje ilość błędów o określonej wartości. Jak widać, największe ilości błędów występują blisko zera. Oba histogramy odpowiadają krzywej Gaussa, odzwierciedlającej rozkład normalny. Fakt ten również potwierdza wysoką jakość otrzymanych sterowników predykcyjnych.




Rysunek 7. Histogram błędów uczenia sieci w horyzoncie jednodniowym (po lewej) i dwudniowym (po prawej)

Źródło: opracowanie własne.

Na rysunku 8 zaprezentowano wykresy rozrzutu odzwierciedlające korelację odpowiedzi udzielanych przez sieć neuronową z odpowiedziami prawidłowymi. Dwa górne rysunki odpowiadają sterownikowi prognozującemu kurs BTC z wyprzedzeniem jednodniowym. Dwa dolne dotyczą prognozowania dwudniowego. Wykresy po lewej stronie obrazują rozkład przypadków dla zbioru uczącego, natomiast lewa strona wykresów odpowiada zbiorowi testowemu. Można zauważyć, że skupienie odpowiedzi jest bliskie linii odpowiadającej odpowiedziom prawidłowym. Ma to szczególne znaczenie w przypadku zbioru testowego, o czym już wcześniej wspomniano.





Rysunek 8. Diagramy korelacyjne uczenia sieci do prognozowania BTC w horyzoncie jednodniowym (u góry) i dwudniowym (u dołu)

Źródło: opracowanie własne.

Uwagi końcowe

Przeprowadzona analiza dowodzi, że zastosowanie sztucznych sieci neuronowych do prognozowania kursu bitcoina znajduje swoje uzasadnienie w otrzymanych wynikach. Wysokie wartości współczynnika regresji (R) i mały błąd średniokwadratowy (MSE) świadczą o tym, że opracowany system predykcyjny prawidłowo przewiduje kursy analizowanej kryptowaluty nie tylko w odniesieniu do danych historycznych, lecz także dla wartości bieżących i przyszłych. Świadczy to o wysokiej zdolności uzyskanej sieci do generalizacji.

Otrzymane wyniki upoważniają do stwierdzenia, że mimo wysokiej zmienności kursów kryptowalut można znaleźć zmienne niezależne (predyktory), których poziomy cenowe są wyraźnie dodatnio skorelowane z poziomem cen walut szyfrowanych. Podkreślić należy, że rezultaty przeprowadzonej analizy są miarodajne w odniesieniu do kursu bitcoina, na podstawie analiz konkretnego szeregu czasowego. Uwzględnienie innego horyzontu czasowego lub też zastosowanie w modelu innej kryptowaluty prawdopodobnie skłoniłyby do odmiennej konkluzji. Niemniej poszukiwanie determinant zmian poziomów cenowych kryptowalut stanowi swego rodzaju koncepcję próby algorytmizacji z pozoru nieprzewidywalnych zachowań graczy giełdowych. Odszukanie w przyszłości sieci powiązań kursu walut szyfrowanych z takimi zmiennymi jak ceny surowców, kursy walut tradycyjnych czy koniunktura na rynku akcji, umożliwiłoby pośrednie wkomponowanie elementów analizy fundamentalnej do rynku, który został stworzony po to, by dla tradycyjnych wzorców giełdowych stanowić alternatywę. Dowiodłoby to jednak tezy o globalnym systemie finansowym jako układzie naczyń połączonych, nawet w odniesieniu do rynku, który miał ten system zrewolucjonizować.

Literatura

- Baumann, J., Lesoismier, A. (2017). *Cryptocurrencies Outlook 2018. Stairway to Heaven*. SwissBorg.
- Berentsen, A., Schär, F. (2018). A Short Introduction to the World of Cryptocurrencies. *Federal Reserve Bank of St. Louis Review*, First Quarter.
- Bitcoin Correlations to Macro Environment: Gold and Yuan Standouts*. TradeBlock. Pobrano z: <https://tradeblock.com/blog/bitcoin-correlations-to-macro-environment-gold-and-yuan-standouts> (31.11.2017).
- Corbet, S., McHugh, G., Meegan, A. (2017). The Influence of Central Bank Monetary Policy Announcements on Cryptocurrency Return Volatility. *Investment Management and Financial Innovations*, 4 (14), 60–72.
- DeVries, P.D. (2016). An Analysis of Cryptocurrency, Bitcoin, and the Future. *International Journal of Business Management and Commerce*, 1 (2), 1–9.
- Foresee, F.D. Hagan, M.T. (1997). Gauss-Newton Approximation to Bayesian Learning. W: *Proceedings of the International Joint Conference on Neural Networks* (s. 1930–1935). Houston: IEEE.
- Huang, W., Lai, K.K., Nakamori, Y., Wang, S. (2004). *Forecasting Foreign Exchange Rates with Artificial Neural Networks: A Review*. *International Journal of Information Technology & Decision Making*, 3 (01), 145–165.
- Instrumenty pochodne*. GPW. Pobrano z: <https://www.gpw.pl/instrumenty-pochodne> (10.09.2018).
- Investing.com. Zakładka: Kryptowaluty. Pobrano z: <https://m.pl.investing.com/> (10.09.2018).
- Kłosowski, G., Klepka, T., Nowacka, A. (2018). Neural Controller for the Selection of Recycled Components in Polymer-gypsy Mortars. *Applied Computer Science*, 2 (14), 48–59.
- Kmita, M. (2017). *Dlaczego Bitcoin nie jest piramidą finansową*. BitHub.pl. Pobrano z: <https://bithub.pl/opinie/dlaczego-bitcoin-piramida-finansowa/> (13.09.2018).
- Market Price (USD)*. Blockchain. Pobrano z: <https://www.blockchain.com/charts/market-price?timespan=2years> (13.09.2018).
- Möbert, J. (2018). *Bitcoin Myths, Misconceptions and Misunderstandings*. EU Monitor Global Financial Markets. Deutsche Bank Research.
- Ponzi Schemes Using Virtual Currencies*. SEC Investor Alert. Pobrano z: https://www.sec.gov/investor/alerts/ia_virtualcurrencies.pdf (13.09.2018).
- Pyka, I., Muszyński, M. (2015). Nowe regulacje bezpiecznego obrotu instrumentami pochodnymi na rynku pozagiełdowym w Polsce. *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, 238, 117–131.
- Stankovska, A. (2017). Global Derivatives Market. *SEEU Review*. Pobrano z: <https://www.degruyter.com/downloadpdf/j/seeur.2016.12.issue-1/seeur-2017-0006/seeur-2017-0006.pdf> (10.09.2018 r).
- Statistical Release: OTC Derivatives Statistics at End – June 2017* (2017). Bank of International Settlements. Pobrano z: https://www.bis.org/publ/otc_hy1711.pdf (11.09.2018).
- The Value of Derivatives*. Pobrano z: <https://www.isda.org/a/qJEDE/isda-final-2014.pdf> (12.09.2018).

FORECASTING THE BITCOIN RATE USING AN ARTIFICIAL NEURAL NETWORK

Abstract: *Purpose* – The aim of the article is to present the concept of an IT system that allows forecasting of the bitcoin cryptocurrency rate in relation to the euro.

Design/methodology/approach – For the needs of pursuing such a formulated goal, an artificial neural network model – a multi-layer perceptron was developed. As part of the research, the input variables on which the BTC exchange rate was based were selected. Relevant data from daily quotations of exchange rates of selected currencies and metals were also obtained. The data was subjected to appropriate mathematical processing in order to adapt them for use during teaching, validation and testing of the artificial neural network.

Originality/value – The results of the conducted experiments confirmed the high effectiveness of forecasting in one and two days perspective. High values of the regression coefficient (R) and small mean square error (MSE) indicate that the developed prediction system correctly predicts the rates of the analyzed cryptocurrency not only in relation to historical data, but also for current and future values.

Keywords: stock market, cryptocurrencies, forecasting of exchange rates, artificial neural network

Cytowanie

Paździor, A., Kłosowski, G. (2018). Prognostowanie kursu bitcoina z wykorzystaniem sztucznej sieci neuronowej. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 61–73. DOI: 10.18276/frfu.2018.94/2-05.

Powiązania długookresowych stóp procentowych w krajach Unii Europejskiej

Grzegorz Przekota, Jerzy Rembeza*

Streszczenie: *Cel* – Określenie poziomu i zróżnicowania stóp procentowych w krajach Unii Europejskiej ze względu na przynależność kraju do strefy euro oraz rating. Określenie powiązań między stopami procentowymi w krajach Unii Europejskiej wraz z oceną wpływu niemieckich stóp procentowych na krajowe stopy procentowe.

Metodologia badania – Badaniu poddano stopy procentowe wyliczone na bazie 10-letnich obligacji skarbowych na podstawie danych udostępnionych przez Europejski Bank Centralny. W ocenie poziomu i zróżnicowania stóp procentowych korzystano z metod statystyki opisowej oraz analizy wariancji. Powiązania między stopami procentowymi badano przy użyciu współczynnika korelacji oraz testów punktów przełamań szeregów czasowych. Wpływ niemieckich stóp procentowych na stopy krajowe badano przy użyciu modeli ARDL, testów powiązań długookresowych oraz modeli ECM.

Wynik – Ustalono silne powiązania korelacyjne między stopami procentowymi w krajach Unii Europejskiej, jednak nie można mówić o długookresowej równowadze. Wpływ niemieckich stóp procentowych na stopy procentowe w pozostałych krajach jest ograniczony. Długookresowa równowaga ze stopami niemieckimi charakteryzowała tylko kilka krajów.

Oryginalność/wartość – Skonfrontowano wyniki powiązań korelacyjnych z testami przełamań, co pozwala lepiej interpretować wyniki korelacji. Ustalono ograniczony wpływ stóp procentowych w Niemczech na stopy procentowe większości państw Unii Europejskiej. Oznacza to, że mimo daleko posuniętej integracji państw polityka fiskalna wciąż prowadzona jest bardziej niezależnie.

Słowa kluczowe: obligacje, strefa euro, rating, kointegracja

Wprowadzenie

Rynek obligacji, z uwagi na jego znaczenie dla kosztów obsługi zadłużenia państwa oraz rynku inwestycji prywatnych, jest obecnie jednym z najistotniejszych elementów krajowych oraz światowych rynków finansowych (Georgoutsos, Migiakis, 2013). Stąd też koniunktura na tym rynku, przejawiająca się w cenie obligacji, ma znaczenie dla polityki makroekonomicznej państwa oraz funkcjonowania przedsiębiorstw.

Krajowe rynki obligacji skarbowych oraz – ogólniej – rynki stóp procentowych, nie funkcjonują w sposób niezależny od siebie. Teorią tłumaczącą ruchy cen na tym rynku jest

* dr hab. Grzegorz Przekota prof. PK, Politechnika Koszalińska, Wydział Nauk Ekonomicznych, e-mail: grzegorz.przekota@tu.koszalin.pl; dr hab. Jerzy Rembeza prof. PK, Politechnika Koszalińska, Wydział Nauk Ekonomicznych, e-mail: jerzy.rembeza@tu.koszalin.pl.

teoria parytetu stopy procentowej. Zgodnie z nią stopy procentowe na rynku krajowym są równe zagranicznym stopom procentowym skorygowanym o oczekiwaną zmianę waluty krajowej. Badania empiryczne pokazują jednak zawodność tej teorii (Baldacci, Gupta, Mati, 2008). Okazuje się, że ryzyko związane ze zmianami cen obligacji łączy się z sytuacją makroekonomiczną danej gospodarki oraz postrzeganiem jej przez światowe rynki finansowe. W sytuacji niepokoju na rynkach finansowych można oczekiwać wzrostu wysokości spreadów na niekorzyść państw o gorszych ratingach (Beber, Brandt, Kavajecz, 2009; Ferrucci, 2003; Barrios, Iversen, Lewandowska, Setzer, 2009).

Rynki finansowe, wyceniając obligacje, kierują się wskaźnikami obiektywnymi (wzrost długu publicznego, wielkość deficytu budżetowego, dynamika wzrostu produktu i inne), ale także subiektywną oceną gospodarki. Na rynku europejskim taka sytuacja dotyczy chociażby krajów Europy Środkowo-Wschodniej (EŚW), które mimo stabilnej sytuacji gospodarczej postrzegane są wciąż jako kraje rozwijające się, co skutkuje wyższymi stopami procentowymi w porównaniu z krajami Europy Zachodniej.

W analizach empirycznych często dokonuje się porównania stóp procentowych w danym kraju ze stopami innego kraju. Na rynku europejskim punktem odniesienia są z reguły obligacje niemieckie. Takie podejście zastosowano także w niniejszym opracowaniu, w którym wykorzystano dane Europejskiego Banku Centralnego dotyczące długookresowych stóp procentowych o miesięcznej częstotliwości, wyznaczonych na podstawie cen 10-letnich obligacji skarbowych w latach 2001–2018. Analizą objęto 22 kraje: Austrię, Belgię, Czechy, Danię, Finlandię, Francję, Grecję, Hiszpanię, Holandię, Irlandię, Litwę, Luksemburg, Łotwę, Niemcy, Polskę, Portugalię, Słowację, Słowenię, Szwecję, Węgry, Wielką Brytanię i Włochy.

Analizowane kraje różnią się ze względu na obowiązującą walutę: euro lub też walutę krajową oraz ratingiem. W pracy korzystano z ratingu agencji Fitch. Celem opracowania było określenie poziomu i zróżnicowania stóp procentowych w zależności od przynależności do strefy euro oraz ratingu. Ponadto, przyjmując, że stopy niemieckie stanowią benchmark dla stóp procentowych pozostałych państw Unii Europejskiej, określono długookresowe i krótkookresowe powiązania między stopami procentowymi w tych krajach a stopami niemieckimi. Na tej podstawie starano się odpowiedzieć na pytanie, czy obecność danego kraju w strefie euro wpływa na powiązania z niemieckim rynkiem stóp procentowych.

1. Badania nad wyceną obligacji skarbowych

Badania empiryczne pozwalają na uznanie sytuacji finansów publicznych w zakresie obsługi bieżącego zadłużenia oraz zdolności kredytowej, zadłużenia zagranicznego, aktualnego wzrostu gospodarczego oraz jego perspektywy, poziomu stóp procentowych i inflacji, a także kursu walutowego za kluczowe czynniki warunkujące koniunkturę na rynku obligacji (Edwards, 1984; Baldacci, Gupta, Mati, 2008). Z kolei prowadzona przez rządy państw polityka fiskalna wpływa na rating, który interpretuje się jako poziom ryzyka, co ma odzwierciedlenie w stopach zwrotu z obligacji rządowych (Azreki, Candelon, Sy, 2011). Na podstawie badań wybranych państw OECD wykazano występowanie między nimi in-

tegracji finansowej, przejawiającej się długoterminowymi zgodnymi ruchami cen obligacji. Natomiast różnice między cenami kształtowane były przez makroekonomiczne czynniki indywidualne (Afonso, Rault, 2012). Słabszy okazuje się wpływ zmiennych finansowych. Słaby wpływ indeksu S&P 500 na rentowność obligacji wykazano w szczególności w Stanach Zjednoczonych (Ludvigson, Ng, 2009).

Na długookresową rentowność obligacji słaby wpływ wywiera nominalna inflacja (Goldberg, Leonard, 2003). Z inflacją skorelowane są stopy nominalne (Chionis, Pragidis, Schizas, 2014; Gómez-Puig, Sosvilla-Rivero, Ramos-Herrera, 2014). W okresach kryzysowych na wadze zyskuje prognoza salda budżetowego i związane z nią programy naprawy finansów publicznych oraz sytuacja sektora finansowego (Assman, Boysen-Hogrefe, 2011; Weber, Jaramillo, 2013; Beirne, Fratzcher, 2013). Wzrost nominalnych stóp procentowych może być powodowany rosnącym deficytem budżetowym, gdyż ten ostatni zwiększa nacisk na wzrost inflacji. Z drugiej strony globalizacja rynków finansowych osłabia wpływ długu na stopy procentowe (Clayes, Moreno, Surinach, 2012). Istotne znaczenie ma też, na ile otwarta jest gospodarka. Im większy udział długu zewnętrznego, tym mniejszy wpływ deficytu na stopy procentowe (Baldacci, Kumar, 2010).

Dla uczestników rynku obligacji jedną z istotnych informacji jest ocena ratingowa, choć sam system ocen wywołuje kontrowersje. Z jednej strony rating w sposób syntetyczny opisuje sytuację gospodarczą oraz wiarygodność danego kraju, jednak z drugiej pojawiają się zarzuty dotyczące upolitycznienia decyzji o przyznaniu ratingu bądź jego spekulacyjnego charakteru. Niezależnie od tych zastrzeżeń ocena ratingowa, będąca syntetycznym podsumowaniem wielu szczegółowych informacji, ma duży wpływ na rentowność obligacji (Afonso, Gomes, Taamouti, 2014).

Polski rynek obligacji był przedmiotem badań porównawczych z innymi krajami Europy Środkowo-Wschodniej oraz Europy Zachodniej, z których wynika, że także w jego wypadku istotne znaczenie mają takie czynniki, jak ryzyko kredytowe oraz niewypłacalności i płynności (Alexopoulou, Bunda, Ferrado, 2009; Nickel, Rother, Rülke, 2011; Ebner, 2009). W przypadku krajów regionu determinanty rentowności obligacji mogą być podzielone na dwie duże grupy. Pierwsza obejmuje zmienne pochodzące z rynku euro, takie jak stopa referencyjna Europejskiego Banku Centralnego, stopa EURIBOR, zmienność rynku mierzona indeksem VDAX-NEW oraz inflacja. Stanowią one grupę zmiennych egzogenicznych. Druga grupa obejmuje zmienne endogeniczne, w tym wielkość produkcji, stan budżetu państwa, zadłużenie, inflację i kurs walutowy (Csonto, Ivaschenko, 2013).

2. Metodyka badań

Badania podzielono na trzy części: ocenę kształtowania się stóp procentowych, badanie różnicy między stopami procentowymi w zależności od przynależności bądź nie do strefy euro i ratingu oraz modelowanie zależności krajowych stóp procentowych od niemieckich stóp procentowych.

We wstępnej ocenie korzystano z oceny powiązań korelacyjnych między poszczególnymi szeregami czasowymi stóp procentowych. Interesowano się także przełamaniami w szeregach czasowych. Uwzględnienie przełamań zaleca się także w ocenie stacjonarności szeregów czasowych (Hansen, 2001), do której wykorzystano rozszerzony test Dickeya-Fullera z uwzględnieniem przełamań (Vogelsang, Perron, 1998).

Badanie znaczenia przynależności do strefy euro oraz ratingu oparto na analizie wariancji. W tej części badań analizie poddano wysokości spreadu krajowych stóp procentowych w stosunku do stóp procentowych obowiązujących w Niemczech.

W związku z tym, że jednym z celów opracowania było określenie wpływu stóp procentowych w Niemczech na stopy procentowe w innych krajach, zastosowano model ARDL (Autoregressive Distributed Lag), czyli model autoregresyjny z rozkładem opóźnień w postaci:

$$R_{H,t} = \alpha_0 + \alpha_1 R_{H,t-1} + \dots + \alpha_i R_{H,t-i} + \beta_0 R_{D,t} + \beta_1 R_{D,t-1} + \dots + \beta_j R_{D,t-j} + \varepsilon_t,$$

gdzie $R_{H,t}$ to stopa procentowa w danym kraju w terminie t , a $R_{D,t}$ to stopa procentowa w Niemczech w terminie t . W porównaniu z modelami typu VAR zaletą modeli ARDL jest możliwość stosowania w odniesieniu do zmiennych zintegrowanych w różnym stopniu, a także stosowania różnej liczby opóźnień dla poszczególnych zmiennych (Greene, 2008).

W analizach empirycznych szczególnie przydatne są narzędzia dodatkowe, związane z modelem ARDL, w tym w szczególności testy powiązań długookresowych, pozwalające na ocenę kointegracji zmiennych, a więc rozróżnienie zależności pozornych od niepozornych. W testowaniu związków długookresowych posłużono się testem granic (Pesaran, Shin, Smith, 2001). Stosowanie tego testu wymaga przekształcenia modelu ARDL do postaci warunkowego ECM (Error Correction Model), czyli modelu korekty błędem:

$$R_{H,t} = \alpha_0 + \sum_{i=1}^k \alpha_i \Delta R_{H,t-i} + \sum_{j=1}^p \beta_j \Delta R_{D,t-j} + \theta_1 R_{H,t-1} + \theta_2 R_{D,t-1} + \varepsilon_t.$$

W przypadku potwierdzenia związków długookresowych między analizowanymi stopami procentowymi przeprowadzono analizę związków o charakterze krótkookresowym. Wykorzystano w tym celu konwencjonalną postać modelu ECM bez restrykcji, będącą przekształceniem modelu ARDL do postaci:

$$\Delta R_{X,t} = \alpha_0 + \sum_{i=1}^k \alpha_i \Delta R_{X,t-i} + \sum_{j=1}^p \beta_j \Delta R_{D,t-j} + \gamma z_{t-1} + \varepsilon_t,$$

gdzie z jest składnikiem resztowym z regresji kointegrującej:

$$R_{X,t} = \alpha_0 + \alpha_1 R_{D,t} + z_t.$$

Zgodnie z teorią, jeżeli istnieje związek długookresowy pomiędzy zmiennymi, to współczynnik γ powinien być istotnie ujemny.

Ostatnim etapem badań był wybór szeregów krajowych stóp procentowych powiązanych kointegracyjnie ze stopami niemieckimi i przedstawienie zależności między przyrostami wybranych zmiennych przy użyciu modeli ECM (Engle, Granger, 1987).

3. Kształtowanie stóp procentowych obligacji w krajach Unii Europejskiej

W ocenianym okresie 2001–2017 stopy procentowe we wszystkich krajach Unii Europejskiej wyraźnie spadły, np. w Niemczech z poziomu około 5% w roku 2001 do około 0,5% w 2018 roku, a w Polsce z poziomu 10–12% w roku 2001 do poziomu około 3% w roku 2018. W niektórych gospodarkach lata 2009–2012 przyniosły dość znaczący wzrost stóp procentowych, będący pochodną kryzysu lat 2008–2009. Dotyczy to Grecji, Litwy, Łotwy, Węgier, Irlandii czy Portugalii, np. w Grecji w roku 2012 stopy procentowe przekroczyły 20%, na Litwie w 2009 roku wynosiły 14,5%. Jednak kraje te poradziły sobie z wysokimi stopami procentowymi i ostatnie lata we wszystkich krajach charakteryzowały się niższymi ich wartościami.

Powiązania korelacyjne stóp procentowych w analizowanych krajach (tab. 1) są z reguły bardzo silne, np. dla Niemiec i Austrii jest to 0,9848, a dla Polski i Niemiec 0,8291. Generalnie stopy procentowe prawie wszystkich krajów silnie powiązane są korelacyjnie ze stopami niemieckimi, ale także między sobą. Nie dotyczy to Grecji, której stopy procentowe powiązane były z reguły ujemnie ze stopami procentowymi w pozostałych krajach. Jednak spowodowane było to perturbacjami, jakie kraj ten przeżywał w latach 2010–2014. Można zauważyć także, że mimo silnych powiązań korelacyjnych z Niemcami, tworzą się jednak pewne koszyki państw, np. polskie stopy procentowe najsilniej skorelowane są z czeskimi i słowackimi.

Mimo silnych zależności korelacyjnych trudno jest wskazać kraje, dla których terminy przełamań byłyby w pełni zgodne (tab. 2). Można mówić jedynie o pewnych podobieństwach. Stawiając niemieckie stopy procentowe jako benchmark dla pozostałych, zauważyć można, że nie ma takiego kraju, dla którego terminy przełamań byłyby w pełni zgodne z niemieckimi. Zatem z jednej strony mamy tutaj do czynienia z silną korelacją szeregów czasowych stóp procentowych, ale jednocześnie słabą zgodnością terminów przełamań. Taka sytuacja oznacza, że stopy procentowe w badanej grupie państw podążają w podobnych kierunkach, ale punkty zwrotne i siła trendów między punktami zwrotnymi jest różna.

Interesujący jest przypadek Austrii i Czech, gdyż przełamanie w Austrii zawsze wyprzedzało przełamanie w Czechach. Można wskazać także pary państw o silnie powiązanych terminach powiązań, np. wysoka zgodność dotyczy Austrii i Belgii.

Uzyskane wyniki testu przełamań mogą dowodzić, że powiązania korelacyjne analizowanych szeregów czasowych nie świadczą o długoterminowym powiązaniu, a są wynikiem sił oddziałujących jednocześnie na cały oceniany system.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22
Irlandia	0,62	0,73	0,63	0,52	0,51	0,87	0,56	0,62	0,39	0,42	0,76											
Włochy	0,79	0,87	0,79	0,70	0,69	0,97	0,74	0,81	0,57	0,27	0,86	0,85										
Litwa	0,68	0,68	0,73	0,60	0,62	0,58	0,65	0,65	0,47	-0,07	0,79	0,57	0,62									
Luksemburg	0,96	0,94	0,94	0,93	0,94	0,70	0,96	0,95	0,86	-0,30	0,80	0,60	0,76	0,73								
Łotwa	0,68	0,69	0,74	0,60	0,62	0,59	0,65	0,66	0,50	-0,05	0,78	0,64	0,62	0,89	0,74							
Holandia	0,99	0,97	0,95	1,00	0,99	0,70	1,00	0,99	0,95	-0,35	0,80	0,57	0,75	0,65	0,95	0,65						
Polska	0,86	0,86	0,92	0,83	0,83	0,68	0,85	0,85	0,75	-0,17	0,72	0,57	0,73	0,64	0,82	0,63	0,84					
Portugalia	0,22	0,37	0,23	0,09	0,06	0,74	0,14	0,24	-0,06	0,81	0,50	0,80	0,71	0,24	0,18	0,28	0,15	0,26				
Szwecja	0,96	0,92	0,91	0,99	0,99	0,64	0,98	0,97	0,96	-0,43	0,71	0,48	0,67	0,57	0,91	0,56	0,98	0,83	0,06			
Słowenia	0,74	0,79	0,68	0,69	0,68	0,84	0,72	0,76	0,56	0,14	0,69	0,63	0,84	0,51	0,69	0,44	0,73	0,72	0,51	0,72		
Słowacja	0,93	0,94	0,93	0,89	0,88	0,83	0,91	0,93	0,79	-0,08	0,82	0,66	0,86	0,68	0,88	0,65	0,91	0,92	0,38	0,88	0,87	

Źródło: obliczenia własne na podstawie danych ECB.

Tabela 2

Terminy przełamań w szeregach stóp procentowych

Kraj	Termin (rok/miesiąc)
Austria	2004/08, 2007/03, 2009/10, 2012/05, 2014/12
Belgia	2004/07, 2007/02, 2009/09, 2012/05, 2014/12
Czechy	2004/10, 2007/05, 2009/12, 2012/07, 2015/02
Dania	2004/10, 2008/12, 2011/09 , 2014/08
Finlandia	2004/01, 2007/01, 2009/08, 2012/03, 2014/10
Francja	2004/07, 2007/02, 2009/09, 2012/05, 2014/12
Grecja	2010/07, 2013/07, 2015/11
Hiszpania	2004/01, 2007/01, 2010/12, 2014/03
Holandia	2003/12, 2006/07 , 2009/02, 2011/09 , 2014/08
Irlandia	2004/08, 2007/05, 2010/06, 2013/01, 2015/08
Litwa	2003/08 , 2008/06, 2011/01, 2014/08
Luksemburg	2003/08 , 2006/09 , 2009/09, 2012/04, 2014/11
Łotwa	2003/08 , 2008/06, 2011/01, 2014/06
Niemcy	2003/08 , 2006/05 , 2008/12 , 2011/08 , 2014/08
Polska	2003/08 , 2012/10
Portugalia	2011/01, 2013/11
Słowacja	2003/08 , 2013/04, 2015/11
Słowenia	2004/08, 2011/10, 2014/04
Szwecja	2004/09, 2008/11 , 2011/08 , 2014/11
Węgry	2005/02, 2008/02, 2012/07, 2015/02
Wielka Brytania	2004/11, 2008/12, 2011/08 , 2015/12
Włochy	2003/08 , 2007/01, 2011/01, 2014/03

Objaśnienia: wyłuszczone terminy różniące się od terminów przełamań w Niemczech nie więcej niż 4 miesiące.
Źródło: obliczenia własne na podstawie danych ECB.

4. Znaczenie przynależności do strefy euro i ratingu dla wysokości spreadu

Dokonano podziału gospodarek na należące do strefy EURO/ERMII oraz będące poza nią oraz określono wysokość ratingu kraju w danym miesiącu. Dla takiego układu zmiennych grupujących wyznaczono charakterystyki opisowe wysokości spreadu względem Niemiec (tab. 2). Wartość średnia w tabeli 2 jest średnią ze spreadów względem Niemiec wszystkich krajów i miesięcy przy danym ratingu. Z analogicznych danych wyznaczano odchylnie standardowe. Wartość n dotyczy liczby przypadków (wypadkowa krajów i miesięcy), kiedy stwierdzano dany wynik ratingu.

Tabela 3

Charakterystyki opisowe wysokości spreadu względem Niemiec państw będących przedmiotem analizy

Kraje EURO/ERMII				Kraje poza EURO/ERMII			
rating	średnia	odch. stand.	n ob.	rating	średnia	odch. stand.	n ob.
AAA	0,20	0,34	1307	AAA	0,35	0,32	358
AA+	0,50	0,63	258	AA+	1,03	0,33	37
AA	0,48	0,45	375	AA	1,67	1,28	59
AA–	1,29	1,15	110	AA–	0,78	0,56	109
A+	1,21	1,20	184	A+	1,68	1,67	198
A	0,86	1,09	97	A	1,58	1,15	334
A–	1,18	1,25	183	A–	2,72	1,87	99
BBB+	2,26	1,61	205	BBB+	3,81	2,47	121
BBB	2,64	1,16	54	BBB	4,78	1,59	28
BBB–	7,93	1,63	17	BBB–	4,67	2,40	101
BB+	4,65	3,16	78	BB+	–	–	–
B	5,58	1,99	15	B	–	–	–
B–	7,83	3,91	23	B–	–	–	–
CCC	11,70	5,91	45	CCC	–	–	–
C	27,39	–	1	C	–	–	–
Razem	1,07	2,26	2952	Razem	1,76	1,94	1444

Źródło: obliczenia własne na podstawie danych ECB.

Na podstawie testu istotności *t*-Studenta różnicy średnich ustalono, że średni poziom spreadu (1,07 p.p.) w krajach strefy EURO/ERMII był istotnie statystycznie (przy poziomie istotności $p < 0,01$) niższy niż w krajach poza strefą (1,76 p.p.). Ponadto, zgodnie z przewidywaniem, wysokość spreadu związana jest istotnie statystycznie z ratingiem. Gorszy rating oznacza średnio wyższe wartości spreadu. Związek ten jest również statystycznie istotny (przy poziomie istotności $p < 0,01$) i dotyczy krajów będących w strefie euro oraz poza tą strefą. I tak dla krajów strefy euro i ratingu AAA średni spread wyniósł 0,20, ale już przy ratingu BBB+ było to 2,26. Podobnie dla krajów spoza strefy euro, przy ratingu AAA średni spread wyniósł 0,35, ale już przy ratingu BBB+ było to 3,81.

Badanie istotności różnicy w średnich spreadach krajów ze strefy EURO/ERMII i spoza strefy (tab. 4) pozwala stwierdzić, że przy nieistotnie różnych średnich poziomach spreadów ocena ratingowa krajów spoza strefy EURO/ERMII jest z reguły wyższa niż ocena ratingowa

krajów strefy, np. kraje spoza strefy EURO/ERMII – ocena AAA, tymczasem kraje należące do strefy przy nieistotnie różnym spreadzie – ocena AAA, AA+ lub AA; kraje spoza strefy AA+, a tymczasem kraje należące do strefy: AA–, A+, A, A– itd.

Tabela 4

Test istotności różnicy w średnich spreadach krajów ze strefy EURO/ERMII i spoza strefy

Rating AAA	Kraje poza EURO/ERMII									
	AA+	AA	AA–	A+	A	A–	BBB+	BBB	BBB–	
Kraje EURO/ERMII	AAA	0,07	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	AA+	0,16	0,02	0,00	0,05	0,00	0,00	0,00	0,00	0,00
	AA	0,16	0,01	0,00	0,03	0,00	0,00	0,00	0,00	0,00
	AA–	0,00	0,29	0,07	0,00	0,01	0,04	0,00	0,00	0,00
	A+	0,00	0,44	0,02	0,01	0,00	0,00	0,00	0,00	0,00
	A	0,00	0,50	0,00	0,68	0,00	0,00	0,00	0,00	0,00
	A–	0,00	0,51	0,01	0,01	0,00	0,00	0,00	0,00	0,00
	BBB+	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	BBB	0,00	0,00	0,00	0,00	0,00	0,00	0,75	0,00	0,00
	BBB–	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	BB+	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,64	0,92
	B	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,05	0,01
	B–	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	CCC	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	C	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Objaśnienia: w tabeli zawarto poziomy istotności testu; zaciemniono pary nieróżniące się istotnie.

Źródło: obliczenia własne na podstawie danych ECB.

5. Powiązania między stopami procentowymi w poszczególnych krajach

Na podstawie testu powiązań długookresowych (tab. 5), związanego z modelem ARDL, zidentyfikowano kraje, których stopy procentowe są istotnie statystycznie długoterminowo powiązane ze stopami niemieckimi.

Okazuje się, że dla większości krajów Unii Europejskiej nie można mówić o statystycznie istotnym powiązaniu ich stóp procentowych ze stopami niemieckimi. Rezultaty takie są potwierdzeniem spostrzeżeń dotyczących terminów przełamań. Na 21 krajów długoterminowe powiązanie krajowych stóp procentowych ze stopami niemieckimi dotyczy

dziwięciu (Austria, Belgia, Dania, Finlandia, Litwa, Luksemburg, Portugalia, Szwecja i Wielka Brytania), z czego trzy (Dania, Szwecja i Wielka Brytania) pozostają poza strefą euro. Okazuje się, że pozostawanie w strefie euro nie jest warunkiem długoterminowego powiązania stóp procentowych obligacji skarbowych.

Tabela 5

Długookresowe powiązania stóp ze stopami w Niemczech – wyniki testu granic

Kraj	Statystyka empiryczna testu	Kraj	Statystyka empiryczna testu
Austria	7,2880*	Luksemburg	5,7920*
Belgia	5,1114*	Łotwa	2,0572
Czechy	3,8955	Polska	3,3684
Dania	6,4216*	Portugalia	5,3051*
Finlandia	8,9715*	Słowacja	2,8597
Francja	3,6212	Słowenia	4,3864
Grecja	2,7431	Szwecja	4,8509*
Hiszpania	3,1179	Węgry	4,1777
Holandia	4,4538	Wlk. Brytania	6,0823*
Irlandia	4,4802	Włochy	2,9997
Litwa	5,1694*		

Objaśnienia: gwiazdką (*) oznaczono wyniki statystycznie istotne na poziomie $p < 0,05$.

Źródło: obliczenia własne na podstawie danych ECB.

Dla grupy krajów wyróżnionych zbudowano modele ECM (tab. 6). Na ich podstawie można powiedzieć, że bieżące zmiany stóp procentowych w Niemczech ($\Delta(R_p)$) najsilniej oddziałują na bieżące zmiany stóp procentowych w Szwecji (wsp. regresji 0,994) i Danii (wsp. regresji 0,967). Silnie reagują także stop procentowe w Wielkiej Brytanii, Finlandii oraz Austrii. Najsłabsza reakcja stóp procentowych występuje na Litwie, co zresztą jest zgodne z oceną korelacji. We wszystkich przypadkach jednak reakcja krajowych stóp procentowych jest silniejsza na bieżące zmiany stóp niemieckich niż na własne opóźnienia.

Mechanizm dochodzenia krajowych stóp procentowych do długookresowej równowagi ze stopami niemieckimi we wszystkich gospodarkach działa prawidłowo (ujemne współczynniki regresji przy parametrze ECT i istotne na poziomie $p < 0,001$). Natomiast najszybciej do poziomu równowagi ze stopami niemieckimi dostosowują się stopy procentowe w Danii (ECT = -0,158), Finlandii (ECT = -0,110), na Litwie (ECT = -0,094) oraz w Austrii (ECT = -0,093).

Tabela 6

Powiązania stóp procentowych w krajach UE ze stopami procentowymi w Niemczech – modele ECM bez restrykcji

Zmienne	Austria	Belgia	Dania	Finlandia	Litwa	Luksem.	Portugalia	Szwecja	Wlk. Brytania
C	-0,172 ^c	0,227 ^c	-0,067 ^c	-0,127 ^c	-0,606 ^c	-0,046 ^c	0,161 ^b	0,104 ^c	0,154 ^c
$\Delta(R_H(-1))$	-0,038	0,155 ^a		0,097	0,222 ^b	0,155 ^a	0,083	0,258 ^c	0,295 ^c
$\Delta(R_H(-2))$	0,147 ^a			0,090	0,243 ^c	-0,010	0,140 ^a		
$\Delta(R_H(-3))$	0,109			-0,041	0,121	0,144 ^a	0,215		
$\Delta(R_H(-4))$						-0,097 ^c	0,010 ^b		
$\Delta(R_H(-5))$							0,156 ^a		
$\Delta(R_D)$	0,866 ^c	0,820 ^c	0,967 ^c	0,937 ^c	0,412	0,783 ^c	0,735 ^c	0,994 ^c	0,923 ^c
$\Delta(R_D(-1))$	0,071	-0,062	0,064	-0,094	-0,506	0,030		-0,221 ^b	-0,226 ^b
$\Delta(R_D(-2))$	-0,234 ^c	-0,160 ^b	-0,053	-0,128		-0,057			
$\Delta(R_D(-3))$	-0,162 ^a	-0,073				-0,191 ^b			
$\Delta(R_D(-4))$	-0,071								
ECT	-0,093 ^c	-0,049 ^c	-0,158 ^c	-0,110 ^c	-0,094 ^c	-0,071 ^c	-0,034 ^b	-0,063 ^c	-0,090 ^c
Dummy					0,449 ^b		0,241 ^b	0,044 ^c	-0,052 ^a
Adj.R ²	0,773	0,627	0,837	0,908	0,166	0,634	0,234	0,858	0,701

Objaśnienia: R_H – stopy krajowe, R_D – stopy niemieckie, Dummy – rok 2009, ^{a, b, c} – istotne na poziomie 0,05, 0,01, 0,001.

Źródło: obliczenia własne na podstawie danych ECB.

Uwagi końcowe

W pracy analizowano stopy procentowe wyznaczone na podstawie cen 10-letnich obligacji skarbowych państw należących do Unii Europejskiej. Cechą charakterystyczną gospodarek tworzących Unię Europejską jest bliskość geograficzna, swobodny przepływ kapitałów oraz ścisła współpraca. Biorąc pod uwagę te elementy, można byłoby oczekiwać silnych powiązań zmiennych ekonomicznych charakteryzujących te gospodarki, w szczególności stóp procentowych. Tymczasem, mimo zaawansowanych procesów integracyjnych, polityka fiskalna krajów UE prowadzona jest jeszcze w dużej mierze niezależnie, co ma dla przedmiotu analizy duże znaczenie. Chociaż na przestrzeni badanego okresu we wszystkich gospodarkach stopy procentowe spadły, uzyskane silne zależności korelacyjne nie mogą świadczyć o wpływie zagranicznych obligacji na krajowe. Problem powiązania długookresowych stóp procentowych wykracza poza prostą korelację.

Badania wykazały, że spośród krajów Unii Europejskiej najniższe stopy procentowe mają państwa pozostające w strefie euro. Kraje te jednak muszą utrzymywać dość wysoką dyscyplinę budżetową, gdyż są bardziej krytycznie oceniane przez agencje ratingowe. Kraje pozostające poza strefą euro i posiadające taki sam rating, jak kraje strefy euro, charakteryzują się wyższymi stopami procentowymi, albo – inaczej mówiąc – przy nieistotnie różnych średnich poziomach stóp procentowych kraje spoza strefy mają lepszy rating niż kraje strefy euro.

Analiza przełamań pozwala na wysunięcie wniosków, że siła trendów, jakie w tym samym czasie dotyczą szeregów czasowych stóp procentowych poszczególnych krajów, nie jest jednakowa. Silne powiązania korelacyjne pokazują podobieństwo punktów zwrotnych cykli, z kolei różnice w terminach przełamań oznaczają, że podążanie od jednego punktu zwrotnego do kolejnego odbywa się z różną siłą, specyficzną dla każdego z krajów. Sugeruje to możliwość występowania wspólnych czynników sprawczych dla kształtowania wartości analizowanych szeregów czasowych, a nie podążania jednych obligacji za drugimi. Można wskazać gospodarki, które charakteryzują się nie tylko silną korelacją, ale i podobieństwem terminów przełamań. Dotyczy to przede wszystkim Austrii i Belgii oraz Austrii i Czech, ale są to tylko jednostkowe przypadki.

Modelowanie i testowanie zależności długoterminowej krajowych stóp procentowych od stóp procentowych w Niemczech pozwala na wyciągnięcie wniosku, że choć stopy procentowe wykazywały zbliżone kierunki zmian, w znacznej części krajów Unii Europejskiej stopy procentowe nie są powiązane długookresowymi związkami ze stopami w Niemczech. Dotyczy to zarówno krajów spoza strefy euro, jak i krajów należących do strefy euro. Badania pokazują, że państwa mogą tworzyć pewne koszyki gospodarcze i geograficzne. Takim przykładem są chociażby Niemcy i Dania. Z kolei np. przykład Słowenii pokazuje, że samo przyjęcie euro nie prowadzi do powiązania stóp z traktowanymi jako benchmark stopami niemieckimi.

Literatura

- Afonso, A., Gomes, P., Taamouti, A. (2014). Sovereign Credit Ratings, Market Volatility and Financial Gains. *Computational Statistics and Data Analysis*, 76, 20–33.
- Afonso, A., Rault, Ch. (2012). Short- and Long-run Behaviour of Long-term Sovereign Bond Yields. *Journal Applied Economics*, 47, 3971–3993.
- Alexopoulou, I., Bunda, I., Ferrado, A. (2009). Determinants of Government Bond Spreads in New EU Countries. *Eastern European Economics*, 5 (48), 5–37.
- Assman, Ch., Boysen-Hogrefe, J. (2011). Determinants of Government Bond Spreads in the Euro Area: In Good Times as in Bad. *Empirica*, 39, 341–356.
- Azreki, R., Candelon, B., Sy, A. (2011). Sovereign Rating News and Financial Markets Spillovers: Evidence from the European Debt Crisis. *CESifo Working Paper*, 3411, 1–28.
- Baldacci, E., Gupta, S., Mati, A. (2008). Is It (Still) Mostly Fiscal? Determinants of Sovereign Spreads in Emerging Markets. *IMF Working Paper*, 08/259.
- Baldacci, E., Kumar, M.S. (2010). Fiscal Deficits, Public Debt, and Sovereign Bond Yields. *IMF Working Paper*, 10/184.
- Barrios, S., Iversen, P., Lewandowska, M., Setzer, R. (2009). Determinants of Intra-euro Area Government Bond Spreads during the Financial Crisis. *European Economy, Economic Papers*, 388.
- Beber, A., Brandt, M.W., Kavajecz, K. A. (2009). Flight to Quality or Flight to Liquidity? Evidence from the Euro are Bond Market. *Review of Financial Studies*, 22, 925–957.
- Beirne, J., Fratzcher, M. (2013). The Pricing of Sovereign Risk and Contagion During the European Sovereign Debt Crisis. *Journal of Money and Finance*, 38, 60–82.
- Chionis, D., Pragidis, I., Schizas, P. (2014). Long-term Government Bond Yields and Macroeconomic Fundamentals: Evidence for Greece during the Crisis-era. *Finance Research Letters*, 11, 254–258.
- Clayes, P., Moreno, R., Surinach, J. (2012). Debt, Interest Rates and Integration of Financial Markets. *Economic Modelling*, 29, 48–59.
- Csonto, B., Ivaschenko, I. (2013). Determinants of Sovereign Bond Spreads in Emerging Markets: Local Fundamentals and Global Factors vs. Ever-changing Misalignments. *IMF Working Paper*, 13/164.
- Ebner, A. (2009). An Empirical Analysis on the Determinants of CEE Government Bond Spreads. *Emerging Markets Review*, 10, 97–121.
- Edwards, S. (1984). LDC Foreign Borrowing and Default Risk: An Empirical Investigation. *American Economic Review*, 74, 726–734.
- Engle, R.F., Granger, C.W.J. (1987). Cointegration and Error Correction: Representation, Estimation and testing. *Econometrica*, 55, 251–276.
- Ferrucci, P. (2003). Empirical Determinants of Emerging Market Economies' Sovereign Bond Spreads. *Bank of England Working Paper*, 205. Pobrano z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.839.6499-&rep=rep1&type=pdf>.
- Georgoutsos, D.A., Migiakis, P.M. (2013). Heterogeneity of the Determinants of Euro-area Sovereign Bond Spreads: What Does It Tell Us About Financial Stability? *Journal of Banking & Finance*, 37, 4650–4664.
- Goldberg, L., Leonard, D. (2003). What Moves Sovereign Bond Markets? The Effects of Economic News on US and German Yields. *Federal Reserve Bank of New York. Current Issues in Economics and Finance*, 9 (9), 1–7.
- Gómez-Puig, M., Sosvilla-Rivero, S., Ramos-Herrera, M. del C. (2014). An Update on EMU Sovereign Yield Spread Drivers in Times of Crisis: A Panel Data Analysis. *The North American Journal of Economics and Finance*, 30, 133–153.
- Greene, W.H. (2008). *Econometric Analysis*. New York: Pearson.
- Hansen, B.E. (2001). The New Econometrics of Structural Change: Dating Breaks in U.S. Labor Productivity. *Journal of Economic Perspectives*, 15, 117–128.
- Ludvigson, S.C., Ng, S. (2009). Macro Factors in Bond Risk Premia. *Review of Financial Studies*, 22, 5027–5067.

- Nickel, Ch, Rother, P.C., Rülke, J.C. (2011). Fiscal Variables and Bond Spreads. Evidence from Eastern European Countries and Turkey. *Applied Financial Economics*, 21, 1291–1307.
- Perron, P. (1989). The Great Crash, the Oil Price Shock, and the Unit Root Hypothesis. *Econometrica*, 57, 1361–1401.
- Pesaran, M.H., Shin, Y., Smith, R.J. (2001). Bounds Testing Approaches to the Analysis of Level Relationships. *Journal of Applied Econometrics*, 3 (16), 289–326.
- Weber, A., Jaramillo, L. (2013). Bond Yields in Emerging Economies: It Matters What State You Are in. *Emerging Markets Review*, 17, 169–185.

RELATIONSHIPS OF LONG-TERM INTEREST RATES IN EUROPEAN UNION COUNTRIES

Abstract: *Purpose* – Determination of the level and differentiation of interest rates in the European Union countries due to the country's membership in the euro area and the rating. Determination of links between interest rates in European Union countries together with an assessment of the impact of German interest rates on domestic interest rates.

Design/methodology/approach – The interest rates calculated on the basis of 10-year treasury bonds were subject to the study. Data provided by the European Central Bank. In the assessment of the level and differentiation of interest rates, methods of descriptive statistics and analysis of variance were used. Relationships between interest rates were examined using a correlation coefficient and breakpoint tests of time series. The impact of German interest rates on domestic rates was examined using ARDL models, long-term link tests and ECM models. *Findings* – Strong correlation relations between interest rates in the European Union countries have been established, but one can not talk about long-term equilibrium. The influence of German interest rates on interest rates in other countries is limited. Only a few countries were characterized by long-term equilibrium with German rates.

Originality/value – The results of correlation relationships with break tests were compared, which allows better interpretation of correlation results. A limited influence of interest rates in Germany on interest rates in most of the European Union countries was established. This means that despite the far-reaching integration of countries, fiscal policy is still being pursued more independent.

Keywords: bonds, euro area, rating, cointegration

Cytowanie

Przekota, G., Rembeza, J. (2018). Powiązania długookresowych stóp procentowych w krajach Unii Europejskiej. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 75–89. DOI: 10.18276/frfu.2018.94/2-06.

Analiza związków między datą rozegrania spotkania a stopą zwrotu z akcji spółek giełdowych zaangażowanych w sponsoring sportowy

Anna Rapacewicz*

Streszczenie: *Cel* – W artykule ukazano badanie wpływu czynników nieekonomicznych na stopy zwrotu z akcji spółek sponsorskich notowanych na Giełdzie Papierów Wartościowych w Warszawie. Zanalizowano związki między dniami rozgrywania meczów przez kluby piłkarskie występujące w Ekstraklasie a stopami zwrotu spółek giełdowych, które je sponsorują.

Metodologia badań – Na podstawie literatury odnoszącej się do poruszanego problemu wybrano dynamiczne modele typu (G)ARCH wykazujące największą wartość poznawczą w badaniu tego typu związków.

Wynik – Wykazanie, że dzień rozgrywania meczu piłkarskiego przez drużynę Ekstraklasy wpływa na stopę zwrotu z akcji sponsora danej drużyny.

Oryginalność/wartość – W pracy podjęto jedną z pierwszych prób zidentyfikowania związków między informacjami sportowymi a kursami akcji na rynku polskim.

Słowa kluczowe: akcje, modele (G)ARCH, piłka nożna

Wprowadzenie

Współczesny sport ściśle powiązany jest z działalnością sponsorów, którzy niejednokrotnie stanowią ważne źródło finansowania organizacji sportowych. W szczególności widoczne jest to w najpopularniejszej na świecie dyscyplinie sportowej – piłce nożnej. W związku z tym można spodziewać się, że między sportem a finansującymi go przedsiębiorstwami mogą występować silne związki.

Celem artykułu jest wykazanie występowania związków między stopami zwrotu spółek sponsorów a faktem rozegrania meczów przez sponsorowane przez nie drużyny. W artykule postawiono hipotezę, że rozgrywanie meczów przez drużyny polskiej Ekstraklasy ma istotny statystycznie wpływ na wielkości stóp zwrotu z akcji zaangażowanych w sponsoring spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie.

W badaniu posłużono się kursami akcji spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie w okresie od 1 lipca 2010 do 30 czerwca 2017 roku oraz datami

* mgr Anna Rapacewicz, Uniwersytet Szczeciński, Wydział Nauk Ekonomicznych i Zarządzania, e-mail: anna.rapacewicz@gmail.com.

rozgrywania meczów przez wybrane zespoły występujące w Ekstraklasie¹ w sezonach 2010/2011 – 2016/2017. Weryfikację oparto na dynamicznych modelach ekonometrycznych typu (G)ARCH.

1. Przemysł piłkarski

Piłka nożna traktowana jest jako przemysł już od wielu lat (Sloane, 1971), jednakże od czasów, gdy zyskała to miano, dochodziło do wielu przemian. Jednym z przełomowych momentów w świecie piłki nożnej było wprowadzenie tak zwanego prawa Bosmana. Nazwę prawo to zawdzięcza piłkarzowi, któremu w 1990 roku skończył się kontrakt z FC Liege, w związku z czym chciał przejść do innej drużyny. Władze klubu nie zgodziły się na to bez kwoty odstępnego. Jean-Marc Bosman oskarżył wówczas klub i belgijską federację o złamanie zasady wolnego przepływu osób. Proces zakończył się jego zwycięstwem i zapoczątkował od 1995 roku funkcjonowanie prawa Bosmana, które pozwala na wolny transfer zawodnika po wygaśnięciu kontraktu. Co więcej, uznano, że skoro pracownicy państw członkowskich mają być traktowani bez różnicy obywatelstwa, to kluby i federacje piłkarskie nie powinny wprowadzać klauzul ograniczających liczbę obcokrajowców w klubach europejskich. Powyższy przypadek miał kolosalny wpływ na sposób pozyskiwania zawodników przez kluby, co wpływało nie tylko na prezentowany przez nie poziom sportowy, ale także na ich pozycję rynkową. Stało się oczywiste, że najbogatsze europejskie kluby zaczęły pozyskiwać najlepszych zawodników, przez co innym, biedniejszym zespołom było coraz trudniej z nimi rywalizować w europejskich rozgrywkach. Często podawany jest tu przykład Ajaksu Amsterdam, który w 1995 roku wygrał Ligę Mistrzów zespołem opartym na wychowankach. W ciągu kolejnych lat z klubu, korzystając z prawa Bosmana, odeszli czołowi piłkarze, a Ligę Mistrzów wygrywać zaczęły zespoły tylko z lig uznawanych za najbogatsze.

Oprócz powyższych zmian postępująca internacjonalizacja i coraz większa komercjalizacja związana z widowiskami sportowymi sprawiła, że największe kluby piłkarskie, które biorą udział w najwyższych klasach rozgrywek w Europie, zaczęły działać już nie tylko jako kluby sportowe, ale także jako duże przedsiębiorstwa o zasięgu międzynarodowym. Modele biznesowe tego typu klubów-przedsiębiorstw są zorientowane nie tylko na wynik sportowy drużyny, ale także na zysk, satysfakcję zarządzających klubem czy rozwój młodzieży, co sprawia, że przedsiębiorstwo sportowe stoi przed wyzwaniem odpowiedniego uhierarchizowania tych celów (Sznajder, 2007). Z kolei, by osiągnąć zamierzone cele, kluby potrzebują środków na swoją podstawową działalność. Warto w tym miejscu wspomnieć o opinii Szymanskiego i Kupera, która stawia zespoły w uprzywilejowanej sytuacji w porównaniu do przedsiębiorstw tradycyjnych: „No big soccer club disappears under its debts. (...) No matter how much money clubs waste, someone will always bail them out” (Szymanski, Kuper, 2009,

¹ W celu uzupełnienia szeregu czasowego dla niektórych zespołów, które w wymienionych latach awansowały do Ekstraklasy, wykorzystano także wyniki spotkań tych drużyn z I ligi.

s. 90). Świadczy to o tym, że nawet te kluby, które są zadłużone, a obecnie, według Raportu UEFA (UEFA, 2017), na każdy z Top20 klubów europejskich przypada przeciętnie 231 mln długu netto, są w stanie dobrze radzić sobie na rynku i pozyskiwać środki od bogatych inwestorów, sponsorów, a nawet zdobywać je na rynku kapitałowym. Sznajder zwraca uwagę na kilka uwarunkowań, którym podlegają spółki sportowe notowane na giełdzie, a należą do nich: działalność na rynku regulowanym nie tylko przepisami dotyczącymi klasycznych przedsiębiorstw, ale także przepisami sportowymi; dualność rynku, czyli działanie spółek sportowych na rynku pierwotnym, jakim jest rynek sportu, i wtórnym rynku reklamowo-sponsoringowym, pozwalającym organizacjom sportowym stosować równocześnie modele biznesowe B2B i B2C; charakterystyczni odbiorcy, którzy niejednokrotnie wykazują związki emocjonalne z daną drużyną czy też – najbardziej istotna w kontekście niniejszego opracowania – wrażliwość na szybko pojawiające się doniesienia medialne, w tym także wyniki spotkań (Sznajder, 2007, s. 48–49). Ponadto przemysł sportowy charakteryzuje się cechami nazwanymi przez Forta kotwicami ekonomiki sportu, z których za najważniejsze w kontekście niniejszego artykułu można uznać monopolistyczny charakter produktu sportu oraz niepewność rezultatu produktu sportu (meczu), który uznawany jest za produkt udany wówczas, gdy strony rywalizujące prezentują podobny poziom (Fort, 2005).

Raport Delloite (2018a) podaje, że rynek piłkarski w Europie osiągnął rozmiar 25,5 miliarda euro w sezonie 2016/2017. Rynek polskiej piłki nożnej w tym samym okresie uzyskał jedynie 129 milionów euro przychodów, co jest kwotą niższą niż wpływy ostatniego klubu zaliczanego do Top20 klubów europejskich – Evertonu (2016/2017 – 199,2 mln przychodów). Klasyfikuje to Polskę wśród średnich lig europejskich.

2. Sponsoring piłki nożnej w Polsce

Sponsoring sportowy to nowoczesna forma promocji przedsiębiorstw wykorzystująca do tego sportowe wydarzenia, przyciągające na obiekty sportowe i przed telewizory rzesze kibiców. Fakt ten wykorzystywany jest przez przedsiębiorstwa do celów promocyjnych i marketingowych, w zamian za oferowany przez nie sponsoring w postaci finansowej lub/i rzeczowej. Dzięki sponsoringowi korzyści odnoszą obydwie strony kontraktu: sponsor, który zyskuje większą rozpoznawalność oraz sponsorowany (czyli w tym przypadku klub), który otrzymuje środki finansowe na prowadzenie działalności.

Źródła przychodów w obrębie rozwiniętych lig zagranicznych pochodzą w głównej mierze z transmisji spotkań i źródeł komercyjnych, w tym także ze sponsoringu (Delloite, 2018b). Podobną sytuację można zaobserwować także na polskim rynku piłkarskim. Jak podaje Delloite, sponsoring komercyjny jest ważnym źródłem finansowania polskiej ligi. Jednakże biorąc pod uwagę ogół przychodów polskich klubów piłkarskich, zauważyć można, że Polska na tle największych lig europejskich nie wypada najkorzystniej. Wspomniane wcześniej 129 milionów euro przychodów to niewielka kwota w porównaniu z angielskim (5,30 mld euro) czy niemieckim (2,79 mld euro) rynkiem piłkarskim, a co za tym idzie, kwoty pochodzące od sponsorów są stosunkowo mniejsze.

Biorąc po uwagę polski rynek piłkarski, można zauważyć kilka jego charakterystycznych cech. Pierwsza z nich to duże rozdrobnienie branżowe sponsorów (Delloite, 2017). Raport Delloite wskazuje, że sponsorzy w Polsce pochodzą co najmniej z 30 branż, z czego większość to przeważnie firmy budowlane, transportowe czy motoryzacyjne. Taki stan rzeczy znacznie odróżnia nas od rozwiniętego pod względem biznesu piłkarskiego Zachodu, gdyż tam piłkę nożną sponsorują przede wszystkim instytucje finansowe, bukmacherskie czy branża lotnicza, które w polską piłkę zaangażowane są w niewielkim stopniu. Co więcej, na Zachodzie w sponsoring angażują się przede wszystkim duże międzynarodowe korporacje, natomiast w Polsce aż połowa sponsorów reprezentowana jest przez prywatne firmy lokalne (Delloite, 2018). Kolejnym istotnym aspektem występującym na rynku polskiego sportu jest także fakt, że w sponsoring zaangażowane są często spółki należące do Skarbu Państwa, czego nie obserwuje się na taką skalę w rozwiniętych ligach zagranicznych. Co więcej, na krajowym rynku piłkarskim często stadiony, na których rozgrywane są mecze Ekstraklasy, budowane są przez miasta, gdyż kluby nie są w stanie sfinansować budowy tego typu obiektów. W rozwiniętej pod względem piłkarskim części Europy, jak pokazuje raport Delloite, wśród stadionów generujących największą liczbę zysków aż dziewięć na dziesięć należy do właścicieli prywatnych, których na rynku polskiej piłki wciąż brakuje.

Uwzględniając powyższe rozważania, można zauważyć, że sponsoring piłki nożnej w Polsce, mimo regularnego wzrostu wartości rynku sponsoringu, jest wciąż niewielki w porównaniu z innymi państwami europejskimi. Porównując działalność klubów i strukturę ich przychodów, można zauważyć znaczne podobieństwo, jednak skala działalności jest znacznie mniejsza. Biorąc pod uwagę niską rozpoznawalność Ekstraklasy na świecie i jej niedofinansowanie, nie może dziwić brak zainteresowania większych inwestorów. To z kolei przekłada się na wielkość zainwestowanych przez sponsorów środków, która jest dostosowana do firm działających na polskim rynku, a oczekiwania sponsorujących odzwierciedlają w większości lokalne polityki firm.

3. Badanie związków między sportem a biznesem z wykorzystaniem modeli autoregresyjnych

W ciągu ostatnich 20 lat badania nad zależnościami wyników sportowych i stóp zwrotu spółek giełdowych związanych ze światową piłką nożną obejmują w znacznej większości modele typu (G)ARCH (Majewska, Majewski, 2017). Z badań tych wynika, że to właśnie te modele ukazują statystycznie istotne związki między stopami zwrotu spółek sponsorów a wynikami sportowymi wspieranych przez nich klubów, dlatego też metodologię badań w niniejszym artykule oparto na modelach z wyżej wymienionej grupy.

Podstawowa postać modelu z grupy ARCH(q) zaproponowana przez R. Engle'a (1982) wygląda następująco:

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2,$$

gdzie:

h_t – wariancja warunkowa,

$\varepsilon_t | I_{t-1} \sim N(0, h_t)$,

I_t – zbiór informacji w okresie t ;

$\alpha_0 > 0, \alpha_i \geq 0, i = 1, \dots, q$ i $\sum_{i=1}^q \alpha_i < 1$.

Kolejnym modelem z powyższej grupy jest uogólniona postać modelu ARCH(q) – model GARCH(p, q) powstały poprzez włączenie do równania modelu ARCH(q) opóźnień w realizacji wariancji, co można zapisać następująco (Bollerslev, 1986):

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j},$$

gdzie:

$\alpha_0 > 0, \alpha_i \geq 0, \beta_j \geq 0, i = 1, \dots, q, j = 1, \dots, p$.

W artykule posłużono się także uogólnioną formą modelu wykładniczego – EGARCH(p, q). Postać modelu oraz wzór opisujący funkcję wariancji warunkowej zapisać można w następujący sposób (Majewski, 2015; zob. Nelson, 1991; Shi, Kobayashi, 2009):

$$y_t = \sqrt{h_t} e_t, \\ \log(h_t) = \alpha_0 + \beta \log(h_{t-1}) + \gamma \left| \frac{y_{t-1}}{h_{t-1}} \right| + \left| \frac{\theta y_{t-1}}{h_{t-1}} \right|,$$

gdzie: $-1 < \beta < 1$.

Zaprezentowane modele charakteryzuje nieliniowość procesów, co sprawia, że ich estymacja przeprowadzana jest z wykorzystaniem metody największej wiarygodności (L), gdzie logarytm funkcji L wyznaczany jest następująco:

$$\ln L = -\frac{N}{2} \ln 2\pi - \frac{1}{2} \sum_{t=1}^N \ln h_t(\theta) - \frac{1}{2} \sum_{t=1}^N \frac{R_t^2}{h_t(\theta)},$$

gdzie:

N – długość serii,

$h_t(\theta)$ – funkcja wariancji obliczona za pomocą wzoru: $h_t(\theta) = e^{\alpha_1 + \alpha_2 \cdot \ln \varepsilon_t}$

R_t – wartości teoretyczne otrzymane z funkcji regresji.

Wskaźnikiem ułatwiającym porównywanie dopasowania modeli jest wskaźnik wykorzystujący powyższą próbę wiarygodności modelu – kryterium informacyjne Akaikego (AIC), pozwalające dokonać wyboru między modelami o różnej liczbie zmiennych objaśniających. Kryterium AIC obliczyć można z wykorzystaniem następującego wzoru (Rosienkiewicz, Detyna, 2013; zob. Akaike, 1974):

$$AIC(\hat{\theta}) = -2 \ln \hat{L} + 2p,$$

gdzie:

p – liczba zmiennych egzogenicznych wraz z wyrazem wolnym,

$\hat{L} = L(\hat{\theta}) = \max \{L(\theta_i, D)\}$ – maksimum funkcji wiarygodności szacowanego modelu.

4. Badanie empiryczne – Ekstraklasa SA

Estymacja zaprezentowanych modeli ekonometrycznych ma na celu zbadanie występowania oraz analizę związków między faktem rozegrania meczu przez daną drużynę Ekstraklasa a stopą zwrotu z akcji spółki zaangażowanej w jej sponsorowanie. W artykule analizie poddano pięć spółek sponsorujących zespoły Ekstraklasa oraz jedną spółkę sportową notowaną na Giełdzie Papierów Wartościowych w Warszawie.

Pierwsza spółka to Lubelski Węgiel „Bogdanka” SA, jeden z liderów polskiego rynku producentów węgla kamiennego. „Bogdanka” realizuje swoje działania marketingowe poprzez wspieranie działań w zakresie sportu realizowanych przez głównego beneficjenta budżetu – Górnik Łęczna. Wspiera drużynę grającą w Ekstraklasie oraz dba o zachęcanie młodzieży do zdrowego trybu życia, czego celem jest osiągnięcie korzyści społecznych poprzez zaangażowanie lokalnej młodzieży w przedsięwzięcia sportowe, a także osiągnięcie celów marketingowych, takich jak budowa wizerunku firmy. Następną spółką to Comarch SA, która jest jedną z największych informatycznych spółek w Polsce. Angażuje się ona w sponsoring klubu Cracovia, wydzielając, jako jedną ze swoich rodzajów działalności, działalność sportową związaną z prowadzeniem klubu. Głównym celem inwestycji w drużynę jest promocja marki Comarch. Kolejną spółką to KGHM Polska Miedź SA, jeden z czołowych producentów miedzi na świecie. Jest ona właścicielem drużyny Zagłębie Lubin, a do jej zadań należy między innymi organizacja profesjonalnych zawodów sportowych oraz Akademii Piłkarskiej KGHM Zagłębie. Zaangażowanie KGHM w sponsoring ma na celu realizowanie długofalowej strategii odpowiedzialności społecznej. W dalszej kolejności analizie poddane zostały Zakłady Chemiczne Police SA, polskie przedsiębiorstwo branży chemicznej należące do Grupy Azoty. Spółka jest głównym sponsorem Pogoni Szczecin. Kolejne przedsiębiorstwo to Polnord SA, zajmujące się świadczeniem usług deweloperskich na terenie kraju. Polnord do 2016 roku był sponsorem strategicznym Arki Gdynia, która przez pewien okres występowała pod nazwą Polnord Arka Gdynia. Od roku 2017 Polnord zrezygnował ze współpracy strategicznej z klubem, natomiast nawiązał współpracę z zespołem jako jego partner. Ostatnią spółką to Ruch Chorzów SA, jedyna w tym zestawieniu spółka notowana na Giełdzie Papierów Wartościowych (na rynku NewConnect od grudnia 2008 r.). Podstawowym przedmiotem działalności klubu jest sport. Ruch wiąże z tym rodzajem działalności swoje plany strategiczne, dotyczące między innymi uzyskiwania licencji na kolejne sezony, podnoszenia poziomu drużyny piłkarskiej czy zwiększania frekwencji podczas meczów.

Pierwszy z etapów badania polegał na zebraniu niezbędnych danych do przeprowadzenia badania. Drugi obejmował estymację modeli z wykorzystaniem wcześniej zgromadzonych informacji. Ostatni etap to wybór najlepiej oszacowanych modeli i opis uzyskanych wyników.

Badanie przeprowadzono na podstawie notowań akcji przedstawionych spółek w okresie od 1 lipca 2010 do 30 czerwca 2017 roku oraz informacji o datach rozgrywania spotkań wybranych zespołów Ekstraklasa w sezonach 2010/2011 – 2016/2017. W pracy wykorzystano następujące zmienne:

- R_t – logarytmiczna stopa zwrotu z akcji spółki-sponsora,
- MD – dzień rozegrania spotkania.

Zastosowano także opóźnienia zmiennej objaśniającej (MD) do trzech okresów. Jako zmienną endogeniczną zastosowano dzienną logarytmiczną stopę zwrotu, obliczoną zgodnie z poniższym wzorem:

$$R_t = \ln \frac{P_t}{P_{t-1}},$$

gdzie:

P_t – kurs zamknięcia akcji w okresie t ,

P_{t-1} – kurs zamknięcia akcji w okresie $t-1$.

Ze względu na jakościowy charakter zmiennej egzogenicznej zamieniono ją na zmienną zerojedynkową, gdzie: 1 – dany dzień był dniem sesji giełdowej, na którą powinien mieć wpływ dzień meczowy; 0 – sesje giełdowe, które nie były poprzedzone meczem.

Obliczone stopy zwrotu zestawiono następnie ze stworzoną bazą wyników spotkań wybranych drużyn Ekstraklasy i wykorzystano do przeprowadzenia modelowania ekonometrycznego w ogólnodostępnym programie GRET. W wyniku estymacji prawie stu modeli wyselekcjonowano te, które charakteryzowały się najlepszym dopasowaniem, zgodnie z kryterium maksymalizacji funkcji największej wiarygodności i minimalizacji kryterium informacyjnego Akaikiego. Wśród wyselekcjonowanych modeli znalazły się modele GARCH i EGARCH. Wyniki estymacji powyższych modeli dla stóp zwrotu spółek giełdowych przedstawiono w tabelach 1–6.

Na podstawie przeprowadzonej analizy ekonometrycznej stwierdzono, że we wszystkich przypadkach występują ujemne związki między wystąpieniem dnia meczowego a stopami zwrotu spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie zaangażowanych w sponsoring klubów najwyższej klasy rozgrywkowej w piłce nożnej – Ekstraklasy.

Tabela 1

Wyniki estymacji modeli dla spółki Bogdanka SA

Spółka	Model			
Estymacja GARCH, wykorzystane obserwacje 2010–07–01:2017–06–30 (N = 1751)				
		<i>Współczynnik</i>	<i>wartość p</i>	
Bogdanka (Górnik Łączna)	Const	0,000408289	0,4593	
	MD	−0,00423351	0,0043	***
	alpha(0)	0,000409861	<0,0001	***
	alpha(1)	0,260792	<0,0001	***
Logarytm wiarygodności		4183,289	AIC −8356,578	

Źródło: obliczenia własne.

Przypadek Bogdanki SA, w oszacowanym modelu GARCH(0,1), wykazuje, że fakt rozegrania meczu w najwyższej piłkarskiej klasie rozgrywkowej w Polsce przez drużynę Górnik Łączna opóźniony o dwa okresy wpływa o –0,42 punktu procentowego na stopy zwrotu z akcji spółki notowanej na Giełdzie Papierów Wartościowych w Warszawie *ceteris paribus*.

Tabela 2

Wyniki estymacji modeli dla spółki Comarch SA

Spółka	Model			
Estymacja GARCH, wykorzystane obserwacje 2010-07-05:2017-06-30 (N = 1747)				
		<i>Współczynnik</i>	<i>wartość p</i>	
Comarch (Cracovia)	const	0,00100124	0,0392	**
	MD_2	−0,0026976	0,0447	**
	alpha(0)	0,000183057	0,0004	***
	alpha(1)	0,122644	<0,0001	***
	beta(1)	0,394823	0,0089	***
	Logarytm wiarygodności	4430,535	AIC	−8849,071

Źródło: obliczenia własne.

W przypadku spółki Comarch SA wyselekcjonowano model GARCH(1,1), z którego można wyciągnąć podobny wniosek o wpływie rozegrania meczu ligowego przez Cracovię, opóźnionego o dwa okresy na stopy zwrotu z akcji spółki notowanej na Giełdzie Papierów Wartościowych w Warszawie o -0,27 punktu procentowego *ceteris paribus*.

Tabela 3

Wyniki estymacji modeli dla spółki KGHM Polska Miedź SA

Spółka	Model			
Estymacja EGARCH(1,1), wykorzystane obserwacje: 2010-07-02:2017-06-30 (N = 1750)				
		<i>Współczynnik</i>	<i>wartość p</i>	
KGHM (Zagłębie Lubin)	const	0,000940463	0,0763	*
	MD_1	−0,00407280	0,0102	**
	omega	−0,233441	0,0011	***
	alpha	0,124965	1,72e ^{−06}	***
	gamma	−0,0377029	0,0187	**
	beta	0,981486	0,0000	***
Logarytm wiarygodności		4144,12931	AIC:	−8276,25862

Źródło: obliczenia własne.

W przypadku spółki KGHM Polska Miedź SA w wyselekcjonowanym modelu EGARCH(1,1) można zauważyć, że fakt rozegrania spotkania w najwyższej klasie rozgrywkowej w Polsce przez drużynę Zagłębie Lubin opóźniony o jeden okres wpływa o -0,41 punktu procentowego na stopy zwrotu z akcji spółki notowanej na Giełdzie Papierów Wartościowych w Warszawie *ceteris paribus*.

Tabela 4

Wyniki estymacji modeli dla spółki Zakłady Chemiczne Police SA

Spółka	Model			
Estymacja GARCH, wykorzystane obserwacje 2012-07-04:2017-06-30 (N = 1230)				
		<i>Współczynnik</i>	<i>wartość p</i>	
Zakłady Chemiczne Police (Pogoń Szczecin)	const	4,62127e ⁻⁰⁵	0,9289	
	MD_2	−0,00253141	0,0144	**
	alpha(0)	0,000234437	<0,0001	***
	alpha(1)	0,230836	<0,0001	***
	alpha(2)	0,202734	<0,0001	***
	Logarytm wiarygodności	3172,120	AIC	−6332,241

Źródło: obliczenia własne.

W przypadku należących do Grupy Azoty Zakładów Chemicznych Police SA najlepsze dopasowanie wykazywał model GARCH(1,2). Wskazuje on na występowanie ujemnego wpływu rozegrania spotkania w najwyższej piłkarskiej klasie rozgrywkowej przez Pogoń Szczecin opóźnionego o dwa okresy o -0,25 punktu procentowego na kursy akcji spółki notowanej na Giełdzie Papierów Wartościowych w Warszawie *ceteris paribus*.

Tabela 5

Wyniki estymacji modeli dla spółki Polnord SA

Spółka	Model			
	Estymacja GARCH, wykorzystane obserwacje 2010-07-01:2017-06-30 (N = 1751)			
		<i>Współczynnik</i>	<i>wartość p</i>	
Polnord (Arka Gdynia)	const	0,000310984	0,6203	
	MD	−0,00367886	0,0340	**
	alpha(0)	3,99464e ⁻⁰⁵	0,0026	***
	alpha(1)	0,136497	<0,0001	***
	beta(1)	0,826857	<0,0001	***
	Logarytm wiarygodności	3893,550	AIC	−7775,100

Źródło: obliczenia własne.

W przypadku spółki Polnord SA najlepszym dopasowaniem charakteryzował się model GARCH(1,1). Na jego podstawie można wywnioskować, że nieopóźniony dzień rozegrania spotkania ligowego w Ekstraklasie przez zespół Arka Gdynia wpływa o -0,37 punktu procentowego na zmienność stopy zwrotu z akcji spółki notowanej na Giełdzie Papierów Wartościowych w Warszawie *ceteris paribus*.

Tabela 6

Wyniki estymacji modeli dla spółki Ruch Chorzów SA

Spółka	Model			
Estymacja EGARCH(0,1), wykorzystane obserwacje: 2010-07-06 – 2017-06-30 (N = 1551)				
		<i>Współczynnik</i>	<i>wartość p</i>	
Ruch Chorzów (spółka giełdowa)	const	−1,46988e ^{−013}	1,0000	
	MD	−0,0246846	0,0001	***
	MD_1	−0,0348415	7,12e ^{−012}	***
	MD_2	−0,0248909	0,0002	***
	MD_3	−0,0166183	0,0097	***
	omega	−5,78081	0,0000	***
	alpha	2,50222	1,15e ^{−05}	***
	gamma	−2,00326	0,0002	***
Logarytm wiarygodności		1434,96911	AIC: −2853,93823	

Źródło: obliczenia własne.

Ostatni, wyselekcjonowany dla Ruchu Chorzów SA model EGARCH(0,1) pokazuje, że zarówno nieopóźniony fakt rozegrania meczu przez drużynę Ruchu, jak i opóźniony o jeden, dwa lub trzy okresy wpływa na kurs akcji spółki notowanej na NewConnect odpowiednio o -2,47, -3,48, -2,49 i -1,66 punktu procentowego *ceteris paribus*.

Uwagi końcowe

Na podstawie przeprowadzonego badania udało się potwierdzić założoną na początku hipotezę o istnieniu związków między stopami zwrotu a faktem rozgrywania spotkań przez kluby Ekstraklasy. We wszystkich przeanalizowanych przypadkach wykryto ujemne związki między stopą zwrotu z akcji spółki a datą rozegrania meczu przez drużynę przez nią sponsorowaną.

Dalsze badania powinno się rozszerzyć na przykład o analizę kursów bukmacherskich, która pozwoliłaby wykazać, czy można mówić o emocjonalnym charakterze związków, bądź o zmienne określające konkretny dzień tygodnia, umożliwiające bardziej precyzyjne zbadanie analizowanego zjawiska.

Literatura

- Akaike, H. (1974). A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 6 (19), 716–723.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 3 (31), s. 307–327.

- Club Licensing Benchmarking Report Financial Year 2016 (2018). The European Club Footballing Landscape.
- Delloite (2017). Badanie: Zaangażowanie firm w sektor piłki nożnej w Polsce.
- Delloite (2018a). Annual Review of Football Finance.
- Delloite (2018b). Football Money League.
- Engle, R. (1982). Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of UK Inflation. *Econometrica*, 4 (50), 987–1007.
- Fort, R. (2005). The Golden Anniversary of the Baseball Players' Labor Market. *Journal of Sports Economics*, 4 (6), 347–358.
- Majewska, A., Majewski, S. (2018). Econometric Modelling of Market Prices of Football Clubs. *Aestimatio. The IEB International Journal of Finance*, 17, 2–17.
- Majewski, S. (2015). Is it a Business Feeding on Emotions or an Act of Altruism? The Case of Financing Football in Poland. *Folia Oeconomica Lodziensis*, 1 (310), 71–85.
- Nelson, D.B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*, 2 (59), 347–370.
- Rosienkiewicz, M., Detyna, J. (2013). Analiza efektywności metod wyboru zmiennych objaśniających do budowy modelu regresyjnego. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*, 309, 214–235.
- Shi, X., Kobayashi, M. (2009). Testing for Jumps in the EGARCH Process. *Mathematics and Computers in Simulation*, 9 (79), 2797–2808.
- Sloane, P.J. (1971). The Economics of Professional Football: The Football Club as a Utility Maximiser. *Scottish Journal of Political Economy*, 2 (18), 121–146.
- Sznajder, A. (2007). Charakterystyka rynku sportu profesjonalnego. *Gospodarka Narodowa*, 10, 45–65.
- UEFA (2017). The European Club Footballing Landscape.

THE ANALYSIS OF THE RELATIONSHIP BETWEEN MATCHDAY AND RATE OF RETURN OF PUBLICLY-TRADED COMPANIES INVOLVED IN SPORT SPONSORING

Abstract: *Purpose* – Article shows study on the influence of noneconomic factors in the fluctuation of rates of return of companies involved in sponsoring listed on the Warsaw Stock Exchange. The author is focused on the correlations between polish Ekstraklasa football clubs matchday and rates of return of companies involved in sponsoring.

Methodology – This article were used previous literature methodology which demonstrate the highest cognitive value in researches of this type of relationship which are GARCH-type models.

Findings – the result of the study is to indicate the relationship between polish club matchday and rate of return of its sponsor.

Originality/value – The value of the work is one of the first attempts to identify the relationship between sport information and stock prices in Poland.

Keywords: stocks, (G)ARCH models, football

Cytowanie

Rapacewicz, A. (2018). Analiza związków między datą rozegrania spotkania a stopą zwrotu z akcji spółek giełdowych zaangażowanych w sponsoring sportowy. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 91–101.

Efekty kalendarzowe polskich rodzinnych spółek giełdowych

Maciej Stradomski, Mateusz Mikutowski*

Streszczenie: *Cel* – Celem artykułu jest zidentyfikowanie, czy przedsiębiorstwa rodzinne obecne na giełdzie charakteryzują się odmienną podatnością cen ich walorów na wpływ efektów kalendarzowych względem cen spółek nierodzinnych.

Metodologia badania – Przeanalizowano logarytmiczne i arytmetyczne miesięczne stopy zwrotu z akcji prawie 400 przedsiębiorstw z GPW w latach 2006–2016, następnie, za pomocą analizy wariancji jednoczynnikowej, zweryfikowano potencjalne różnice między wydzielonymi grupami.

Wynik – Badanie nie wykazało istotnych różnic między stopami zwrotu przedsiębiorstw rodzinnych i nierodzinnych w perspektywie efektów kalendarzowych.

Oryginalność/wartość – Przedsiębiorstwa rodzinne są istotną grupą w polskiej gospodarce, a jednocześnie mają wiele cech, które odróżniają je od innych przedsiębiorstw. Analiza ma za zadanie dostarczyć środowisku naukowemu i biznesowemu informacji o potencjalnym obszarze odmienności przedsiębiorstw rodzinnych, czyli zachowaniu cen ich walorów oraz postrzeganiu ich przez inwestorów giełdowych.

Słowa kluczowe: przedsiębiorstwa rodzinne, finanse behawioralne, stopy zwrotu, GPW, akcje

Wprowadzenie

Pomimo tego, że przedsiębiorstwa rodzinne nie kojarzą się *stricto* z publicznym rynkiem kapitałowym, w wielu krajach, a także w Polsce, stają się jego istotnym elementem. Spośród spółek obecnych na podstawowym rynku GPW, według różnych badań, ok. 25–35% stanowią przedsiębiorstwa rodzinne (Grant Thornton, 2018; Stradomski, Mikutowski, 2018). Przedsiębiorstwa rodzinne charakteryzują się odmiennym podejściem do zarządzania. Rodzinni właściciele mają o wiele większą awersję do ryzyka niż inni akcjonariusze, a także mniej zdywersyfikowany portfel inwestycyjny niż średnia rynkowa (Chung, 2013; González, Guzmán, Pombo, Trujillo, 2015). Wskazane cechy determinują występowanie relatywnie wysokiej asymetrii informacyjnej na linii właściciel mniejszościowy – właściciel większościowy (rodzina). W artykule zbadano zachowanie cen walorów przedsiębiorstw rodzinnych oraz ich podatność na zidentyfikowane przez innych badaczy efekty kalendarzowe.

* dr. hab. Maciej Stradomski prof. UEP, Uniwersytet Ekonomiczny w Poznaniu, Wydział Zarządzania, e-mail: maciej.stradomski@ue.poznan.pl; mgr Mateusz Mikutowski, Uniwersytet Ekonomiczny w Poznaniu, Wydział Zarządzania, e-mail: mateusz.mikutowski@ue.poznan.pl.

Przeprowadzono także analizę porównawczą tychże zachowań do notowań przedsiębiorstw nierodzinnych.

1. Metodyka badania

Do badania wyselekcjonowano spółki, które według stanu na 30.11.2017 roku notowane były na głównym parkiecie GPW. Z badania, ze względu na specyfikę właścicielską lub operacyjną, wyłączono:

- 17 spółek, w których udziałowcem był Skarb Państwa,
- 67 spółek reprezentujących sektor finansowy (banki, zakłady ubezpieczeniowe, przedsiębiorstwa inwestycyjne etc.).

W poniższej tabeli przedstawiono uproszczony schemat selekcji.

Tabela 1

Uproszczony proces selekcji podmiotów wykorzystanych do badania

Przyjęte kryterium selekcji	Przedsiębiorstwa spełniające warunek	Liczba podmiotów po selekcji
Przedsiębiorstwa notowane na głównym parkiecie GPW na 31.10.2017	478	478
Przedsiębiorstwa nie posiadające w akcjonariacie Skarbu Państwa	459	459
Przedsiębiorstwa pochodzące z branży niefinansowych	411	396

Źródło: opracowanie własne.

Dalsza analiza obejmowała zatem 396 podmiotów, z których wybrano dwie grupy przedsiębiorstw: podmioty charakteryzujące się rodzinnością (przedsiębiorstwa rodzinne) i pozostałe. W tym celu posłużono się wieloczynnikową definicją przedsiębiorstwa rodzinnego, uwzględniającą zarówno cechy o charakterze właścicielsko-zarządczym, jak i analizę kontekstową, weryfikującą samoidentyfikację przedsiębiorstwa jako spółkę rodzinną. Dla celów dalszego badania za spółkę rodzinną uznano podmioty, w których:

- przynajmniej jedna osoba z rodziny lub rodzina łącznie posiada co najmniej 33% głosów w spółce,
- przynajmniej jedna osoba z rodziny zasiada w zarządzie lub radzie nadzorczej spółki,
- spółka nosi znamiona rodzinności.

Dane dotyczące struktury akcjonariatu oraz członków zarządów i rady nadzorczej spółek pobrano z bazy danych Notoria – specjalistycznej bazy danych konsolidującej informacje finansowe i niefinansowe, dotyczące spółek notowanych na publicznych rynkach finansowych w Polsce (GPW, NewConnect, Catalyst). W wypadku braku informacji dotyczącej dokładnej struktury akcjonariatu (np. gdy akcjonariuszem była spółka kapitałowa) informacje uzupełniono z innych publicznie dostępnych źródeł oraz raportów spółek.

By zweryfikować znamiona rodzinności spółek, posłużono się analizą publicznie dostępnych źródeł internetowych, pozwalających stwierdzić, czy spółka sama przedstawia się jako rodzinna lub jest tak postrzegana przez inne podmioty (np. przyznane nagrody, plebiscyty, wystąpienia na konferencjach). Przy zastosowaniu takiej definicji rodzinności z 396 spółek wyselekcjonowano 89 spółek, które spełniały wymienione kryteria.

Dane dotyczące notowań spółek giełdowych pobrano z bazy Thomson – profesjonalnej bazy danych, która zawiera zagregowane informacje dotyczące transakcji zawieranych na rynkach kapitałowych. Wybrany zakres czasowy badania to okres od ostatniej sesji w 2005 roku do ostatniej sesji w 2016 roku. W badaniu przeanalizowano zarówno arytmetyczne, jak i logarytmiczne miesięczne stopy zwrotu. Ceny walorów zostały skorygowane o zdarzenia mające wpływ na nominalną cenę akcji (np. splity i re-splity akcji).

Podstawowym celem badania było przeanalizowanie różnic między występowaniem efektów kalendarzowych oraz osiąganymi stopami zwrotu przedsiębiorstw rodzinnych i nierodzinnych, a nie faktem występowania samych efektów kalendarzowych, gdyż w tym obszarze powstało już wiele analiz, także na polskim rynku giełdowym.

Analizowane efekty kalendarzowe, zwane również anomaliami kalendarzowymi, są zjawiskiem pozwalającym przynajmniej teoretycznie na osiągnięcie ponadprzeciętnych stóp zwrotu przez inwestora. W świetle teorii rynków kapitałowych wyróżniane są generalnie dwie definicje anomalii rynkowych. Anomalia jako sytuacja umożliwiająca osiągnięcie dodatnich, wyższych niż średnio-rynkowe stopy zwrotu, oraz anomalia jako strategia, która nie jest zgodna z zasadami rynku efektywnego (Keller, 2015). Pierwsza koncepcja oparta jest na definicji Edgara Petersa i mówi o tym, że anomalie powinniśmy odbierać jako „sytuację umożliwiającą osiąganie dodatnich, ponadprzeciętnych stóp zwrotu” (Peters, 1997, s. 36). Druga, stworzona przez Monikę Czerwonkę i Bartłomieja Gorlewskiego (2008, s. 51), przedstawia anomalię jako „technikę lub strategię będącą sprzeczną z założeniami teorii rynków efektywnych”.

Wyniki przedstawiono dla lat 2006–2016, obejmując wszystkie miesiące kalendarzowe. W wypadku danych dla poszczególnych miesięcy przeprowadzono analizę wariancji jedno-czynnikowej (ANOVA), która pozwoliła odpowiedzieć na pytanie, czy obydwie grupy różnią się od siebie w sposób statystycznie istotny.

2. Przedsiębiorstwa rodzinne jako przedmiot inwestycji kapitałowej

Ewentualna odrębność przedsiębiorstw rodzinnych, wydzielonych jako subpopulacja przedsiębiorstw prywatnych, staje się w ostatnich latach tematem gorącej dyskusji, nie tylko akademickiej, ale i praktycznej. Fakt istnienia populacji przedsiębiorstw rodzinnych, mających określoną, unikatową charakterystykę, mógłby wpływać nie tylko na istniejące regulacje prawno-podatkowe, lecz również spowodować konieczność modyfikacji niektórych teorii z obszaru finansów przedsiębiorstw. Jedną z metod weryfikacji hipotezy o odrębności przedsiębiorstw rodzinnych jest badanie reakcji inwestorów względem dwóch wyodrębnionych prób badawczych – przedsiębiorstw rodzinnych i przedsiębiorstw o odmiennych formach

własności. Badania tego typu są już mocno rozpowszechnione i dotyczą ewentualnych różnic w postrzeganiu przedsiębiorstw rodzinnych z perspektywy ich struktury finansowania, struktury zadłużenia, polityki inwestycyjnej czy też polityki dywidendowej.

Przedsiębiorstwa rodzinne stanowią od wielu już lat, także na polskim rynku, wdzięczny przedmiot analiz teoretycznych i praktycznych. Znaczenie tejże populacji podmiotów dla gospodarki *per se* nie jest już kwestionowane, m.in. przez potwierdzone badania ukazujące wpływ przedsiębiorstw rodzinnych na poziom PKB, wielkość i strukturę zatrudnienia czy też udział w eksporcie (Lewandowska, Więcek-Janka, Hardyś-Nowak, Wojewoda, Tyleczyński, 2016). Przedsiębiorstwa rodzinne są też obecne na polskim rynku kapitałowym jako emitenci obligacji, jak również akcji dopuszczonych do obrotu publicznego (Filipczak, 2018).

Cechą charakterystyczną przedsiębiorstw rodzinnych jest ich silne zróżnicowanie. Występują bowiem niemalże we wszystkich sektorach gospodarki, różnią się istotnie między sobą formami prawnymi, wielkością obrotów, zatrudnienia etc., co zostało potwierdzone wieloma badaniami na różnych rynkach (Anderson, Reeb, 2003; Caprio, Croci, Del Giudice, 2011; Feldman, Amit, Villalonga, 2016). Stanowią zatem populację bardzo heterogeniczną. Fakt ten nie pomaga w prowadzeniu badań odnośnie do potrzeb tejże populacji. Od strony naukowej zróżnicowanie populacji przedsiębiorstw rodzinnych potwierdza istnienie kilkudziesięciu definicji przedsiębiorstwa rodzinnego, z których żadna nie zdobyła dotychczas dominującego charakteru (Rau, Astrachan, Smyrniotou, 2018).

Jedną z alternatywnych metod potwierdzenia istnienia wyodrębnionej populacji przedsiębiorstw rodzinnych mogłoby być ukazanie zróżnicowanego podejścia inwestorów kapitałowych do przedsiębiorstw rodzinnych.

3. Wyniki badań

Istnieją przykłady badań, gdzie miesięczne efekty kalendarzowe (stycznia, maja, grudnia) analizowane były z perspektywy średnich dziennych stóp zwrotu w danym miesiącu (Bogdański, 2017), jednak najczęściej są one rozważane w ujęciu miesięcznej lub kilkutygodniowej stopy zwrotu w danym miesiącu (Ziemba, 2012; Harasim, 2016; Schabek, Castro, 2017). Z tego powodu także w tym badaniu postanowiono przeanalizować miesięczne stopy zwrotu (zarówno arytmetyczne, jak i logarytmiczne). Na początku zaprezentowano wyniki badań dla arytmetycznych miesięcznych stóp zwrotu. W tabeli 2 przedstawiono arytmetyczne, miesięczne stopy zwrotu wygenerowane przez walory przedsiębiorstw rodzinnych i nierodzinnych w poszczególnych miesiącach kalendarzowych w latach 2006–2016.

Podczas analizy danych zawartych w tabeli 2 widoczne jest, że występowanie efektów kalendarzowych, zarówno dla spółek rodzinnych, jak i nierodzinnych, nie jest silnie zauważalne, co potwierdza wnioski z dokonanych wcześniej na polskim rynku badań (Harasim, 2016; Bogdański, 2017). Podsumowanie wyników z tabeli 2 oraz analizę istotności statystycznej przedstawiono w tabeli 3.

Tabela 2

Arytmetyczne, miesięczne stopy zwrotu dla przedsiębiorstw rodzinnych i nierodzinnych w latach 2006–2016 (%)

Wyszcz.	2006		2007		2008		2009		2010		2011	
	NR	R	NR	R	NR	R	NR	R	NR	R	NR	R
Styczeń	8,97	7,44	-0,60	0,33	-2,07	-5,21	-1,10	0,09	0,16	0,89	1,84	0,25
Luty	24,76	9,23	12,65	12,21	-9,78	-9,64	-6,60	-13,51	0,81	3,06	0,34	-2,46
Marzec	6,02	5,00	0,18	-2,07	-4,47	-5,61	-6,39	-4,01	1,73	3,70	0,41	0,81
Kwiecień	12,82	15,71	23,68	26,29	2,24	3,78	22,76	20,32	10,77	12,31	1,14	0,59
Maj	12,43	7,92	9,78	6,50	-5,80	-7,28	25,29	19,97	0,78	2,48	0,64	-0,09
Czerwiec	-7,39	-8,77	6,40	12,56	-5,11	-4,85	1,27	5,62	-4,47	-3,20	-3,23	-2,77
Lipiec	-2,65	1,22	4,54	1,09	-15,29	-13,48	2,44	4,90	-2,28	-5,04	-4,80	-4,27
Sierpień	10,12	9,71	-10,70	-6,37	-1,26	-1,73	15,89	11,71	7,42	8,85	-6,68	-9,20
Wrzesień	5,50	5,93	-4,39	-6,95	-1,04	-4,64	9,53	7,91	1,67	3,86	-13,27	-14,74
Październik	7,90	8,02	0,75	-5,65	-9,43	-5,83	1,03	-1,11	4,85	3,45	-10,55	-9,27
Listopad	14,19	12,10	1,73	-1,18	-21,70	-18,93	-0,83	0,00	1,05	0,99	6,13	5,00
Grudzień	15,02	15,83	-13,86	-12,59	-10,15	-6,87	0,23	3,70	0,30	0,89	-3,24	-3,52
Śr. Roczna	9,00	7,59	2,21	1,33	-7,09	-6,79	5,27	4,65	1,90	2,64	-2,68	-3,37
Wyszcz.	2012		2013		2014		2015		2016			
	NR	R	NR	R	NR	R	NR	R	NR	R		
Styczeń	-2,22	-2,76	2,77	1,25	-2,31	-2,20	-3,23	-2,43	-3,36	-4,66		
Luty	12,35	13,21	4,97	5,21	2,73	0,79	4,42	2,50	-3,29	-3,44		
Marzec	8,77	7,44	0,35	1,58	-2,25	-1,99	6,08	5,82	3,78	3,75		
Kwiecień	0,11	2,02	-2,48	1,97	2,25	0,96	0,54	1,93	7,00	9,57		
Maj	-4,74	-7,31	-5,69	-5,28	-2,72	-5,08	3,76	4,89	5,86	6,10		
Czerwiec	-8,49	-9,68	6,58	9,96	-1,34	-0,24	0,51	2,09	-2,44	-0,05		
Lipiec	0,81	-1,44	0,76	-0,72	-1,82	-1,27	-3,42	-2,08	-1,10	-1,09		
Sierpień	-6,06	-4,95	2,92	0,60	-4,24	-7,00	2,65	4,10	2,99	4,06		
Wrzesień	1,35	-2,37	5,38	8,45	-0,63	-0,89	-3,22	-1,68	2,25	-0,25		
Październik	3,97	3,81	6,83	5,48	4,02	2,95	0,26	-0,27	3,13	5,53		
Listopad	3,43	4,68	12,02	10,75	-1,11	0,14	5,83	4,29	0,34	0,47		
Grudzień	1,03	-1,11	-0,67	1,18	0,61	-3,57	-3,40	-3,07	-2,05	-0,43		
Śr. roczna	0,86	0,10	2,83	3,38	-0,56	-1,45	0,91	1,33	1,10	1,62		

NR – przedsiębiorstwa nierodzinne, R – przedsiębiorstwa rodzinne.

Źródło: opracowanie własne na podstawie notowań spółek giełdowych.

Tabela 3

Podsumowanie analizy arytmetycznych stóp zwrotu

Wyszczególnienie	Zwrot miesięczny niższy niż średnia roczna		Zwrot miesięczny wyższy niż średnia roczna		ANOVA (p = 5,0%)	
	NR	R	NR	R	F	F. kryt
Styczeń	10	10	2	2	0,13	4,35
Luty	5	4	7	8	0,37	4,35
Marzec	7	6	5	6	0,00	4,35
Kwiecień	4	2	8	10	0,12	4,35
Maj	5	6	7	6	0,16	4,35
Czerwiec	9	5	3	7	0,41	4,35
Lipiec	11	10	1	2	0,00	4,35
Sierpień	5	6	7	6	0,01	4,35
Wrzesień	7	7	5	5	0,08	4,35
Październik	7	5	5	7	0,04	4,35
Listopad	7	6	5	6	0,00	4,35
Grudzień	9	11	3	1	0,04	4,35

NR – przedsiębiorstwa nierodzinne, R – przedsiębiorstwa rodzinne, F – statystyka Fishera.

Źródło: opracowanie własne na podstawie notowań spółek giełdowych.

Analizując dane z tabeli 3, widoczne jest, że efekty kalendarzowe w szeroko przyjętej postaci w analizowanych spółkach nie występują. W wypadku efektu stycznia potwierdzone zostały wnioski z badań na polskim rynku, gdzie wykazano, że efekt stycznia wykazuje przeciwnie tendencje niż na rynkach rozwiniętych (Harasim, 2016; Bogdański, 2017; Budka, Kosiński, Sobczak, 2017). Miesięczne stopy zwrotu w maju wykazują charakter całkowicie losowy. W wypadku efektu grudnia analizowane spółki także radziły sobie w większości przypadków gorzej niż w całym roku – jest to także tendencja przeciwna do tendencji zazwyczaj obserwowanych na rynkach zagranicznych (Ziembra, 2012).

Ważniejsze dla niniejszego badania jest jednak poszukiwanie różnic między spółkami rodzinnymi i nierodzinnymi. Po przeanalizowaniu wartości, jakie wykazywały miesięczne stopy zwrotu w porównaniu do średniej rocznej, widoczne jest, że nie występują istotne różnice między przedsiębiorstwami rodzinnymi oraz nierodzinnymi.

W celu potwierdzenia tych spostrzeżeń dokonano także analizy wariancji jednoczynnikowej, gdzie porównano stopy zwrotu w poszczególnych miesiącach odnotowane przez przedsiębiorstwa rodzinne i nierodzinne we wszystkich analizowanych latach. Z wyliczeń wynika, że wartość F w żadnym z analizowanych miesięcy nie przekroczyła wartości F krytycznego. Z tego powodu nie można odrzucić hipotezy zerowej, co oznacza, że miesięczne stopy zwrotu obydwu analizowanych grup nie różnią się od siebie w stopniu statystycznie istotnym.

Dokonano także analogicznej analizy przy wykorzystaniu logarytmicznych stóp zwrotu. Wyniki przedstawiono w tabeli 4.

Tabela 4

Logarytmiczne, miesięczne stopy zwrotu dla przedsiębiorstw rodzinnych i nierodzinnych w latach 2006–2016 (%)

Wyszcz.	2006		2007		2008		2009		2010		2011	
	NR	R	NR	R	NR	R	NR	R	NR	R	NR	R
Styczeń	6,43	6,08	-2,27	-0,16	-2,84	-5,71	-2,87	-0,98	-0,40	0,06	1,42	-0,14
Luty	17,34	8,03	10,45	9,74	-10,96	-11,08	-8,41	-16,75	0,20	1,73	-0,34	-2,91
Marzec	4,13	4,09	-0,75	-2,80	-5,22	-6,70	-8,57	-6,14	1,29	3,26	0,06	0,52
Kwiecień	10,41	13,27	18,34	20,35	1,52	2,91	16,54	15,59	9,51	10,70	0,53	0,04
Maj	9,41	6,71	8,03	4,87	-6,85	-8,34	20,49	16,92	0,38	1,54	0,31	-0,41
Czerwiec	-9,05	-9,79	4,82	8,71	-5,95	-5,46	0,12	3,87	-4,90	-3,76	-3,81	-3,41
Lipiec	-3,25	0,81	3,14	0,28	-17,58	-15,05	1,61	3,63	-3,30	-5,66	-5,27	-4,93
Sierpień	8,91	9,07	-12,12	-7,23	-2,48	-2,59	11,55	10,02	6,64	8,04	-7,38	-10,07
Wrzesień	4,12	4,23	-5,44	-8,00	-1,85	-5,19	7,70	6,15	0,82	2,29	-15,26	-16,51
Październik	6,59	7,16	-2,39	-6,29	-10,84	-6,78	0,11	-1,72	4,01	2,46	-12,14	-11,39
Listopad	10,21	10,57	1,02	-1,90	-26,14	-22,19	-1,86	-0,70	0,34	0,37	5,07	4,02
Grudzień	11,95	12,75	-15,93	-14,59	-12,90	-9,03	-0,34	2,69	-0,69	0,39	-4,00	-4,40
Śr. Roczna	6,48	6,21	0,28	-0,39	-8,64	-8,05	3,00	2,75	1,16	1,75	-3,49	-4,20
Wyszcz.	2012		2013		2014		2015		2016			
	NR	R	NR	R	NR	R	NR	R	NR	R		
Styczeń	-3,36	-3,24	2,00	0,40	-3,07	-2,73	-4,16	-3,22	-3,96	-5,88		
Luty	10,77	11,29	4,17	3,76	1,75	-0,17	3,19	1,94	4,11	-3,99		
Marzec	7,01	6,49	-0,55	0,33	-3,43	-2,65	4,87	5,00	2,72	2,97		
Kwiecień	-1,89	0,88	-4,01	0,44	0,96	0,50	-0,69	1,24	5,41	7,75		
Maj	-5,33	-8,08	-6,92	-6,30	-3,66	-5,61	2,57	4,27	4,70	5,37		
Czerwiec	-10,07	-11,02	5,33	7,82	-2,23	-0,78	-0,28	0,99	-3,55	-1,27		
Lipiec	0,11	-2,98	-0,26	-1,26	-2,52	-1,77	-3,94	-3,14	-1,80	-1,56		
Sierpień	-7,03	-6,42	1,48	-0,46	-5,00	-7,81	1,80	2,89	1,82	3,64		
Wrzesień	-0,22	-3,48	4,41	7,16	-1,74	-1,53	-4,05	-2,14	1,33	-1,04		
Październik	3,12	2,87	5,52	4,31	3,04	2,03	-1,06	-0,67	1,85	3,71		
Listopad	2,04	3,14	9,90	9,18	-1,74	-0,55	4,47	3,60	-0,53	-0,32		
Grudzień	-0,12	-1,91	-1,86	-0,27	-3,24	-4,45	-4,09	-3,69	-2,86	-1,38		
Śr. Roczna	-0,41	-1,07	1,62	2,10	-1,74	-2,12	-0,10	0,58	0,09	0,66		

NR – przedsiębiorstwa nierodzinne, R – przedsiębiorstwa rodzinne.

Źródło: opracowanie własne na podstawie notowań spółek giełdowych.

Analiza logarytmicznych stóp zwrotu przynosi podobne wnioski, jak w wypadku stóp arytmetycznych. Widoczne jest to także w podsumowaniu przedstawionym w tabeli 5.

Tabela 5

Podsumowanie analizy logarytmicznych stóp zwrotu

Wyszczególnienie	Ogółem niższa niż średnia		Ogółem niższa niż średnia		ANOVA	
	NR	R	NR	R	F	F. kryt
Styczeń	9	9	3	3	0,02	4,35
Luty	5	5	7	7	0,32	4,35
Marzec	6	6	6	6	0,02	4,35
Kwiecień	4	2	8	10	0,24	4,35
Maj	5	6	7	6	0,10	4,35
Czerwiec	9	5	3	7	0,33	4,35
Lipiec	10	9	2	3	0,00	4,35
Sierpień	6	6	6	6	0,00	4,35
Wrzesień	6	7	6	5	0,07	4,35
Październik	6	5	6	7	0,01	4,35
Listopad	5	6	7	6	0,00	4,35
Grudzień	10	11	2	1	0,10	4,35

NR – przedsiębiorstwa nierodzinne, R – przedsiębiorstwa rodzinne.

Źródło: opracowanie własne na podstawie notowań spółek giełdowych.

Analiza logarytmicznych stóp zwrotu jeszcze mocniej zaciera występowanie jakichkolwiek efektów kalendarzowych, jednak ogólne tendencje pozostają takie same, jak w przypadku analizy arytmetycznych stóp zwrotu. Dla logarytmicznych stóp zwrotu także w żadnym z miesięcy wartość F nie przekroczyła wartości F krytycznego – oznacza to, że stopy zwrotu nie były od siebie istotnie różne.

Uwagi końcowe

Przeprowadzone przez autorów badania wykazują, że na polskim rynku publicznym nie są widoczne statystycznie istotne różnice w występowaniu efektów kalendarzowych dla dwóch wyodrębnionych populacji – przedsiębiorstw rodzinnych i przedsiębiorstw nierodzinnych. Przyczyn tego należy upatrywać w kilku czynnikach.

Po pierwsze siła oddziaływania samych efektów kalendarzowych jest – zgodnie z wieloma badaniami (Harasim, 2016; Bogdański, 2017) – malejąca, co z kolei jest efektem dojrzewania polskiego rynku kapitałowego, a także rosnącej roli tradingu wolumenowego. Brak różnic

w postrzeganiu przedsiębiorstw rodzinnych w kontekście efektów kalendarzowych jest zdaniem autorów spowodowany z kolei następującymi faktami:

- a) przedsiębiorstwa rodzinne są traktowane przez inwestorów jako długoterminowa inwestycja, stabilizująca ze względu na swą charakterystykę portfel papierów wartościowych;
- b) ewentualne występowanie efektów kalendarzowych ma swoje źródło w nieracjonalności zachowań inwestycyjnych na rynku, trudno zatem uznać, że inwestorzy w jednym obszarze (timingu decyzji) będą zachowywać się irracjonalnie, a w innym (doboru spółek do portfela) wykażą racjonalną, uzasadnioną selektywność;
- c) w przypadku występowania preferencji względem którejś z analizowanych populacji inwestorzy mieliby nadal problem z obiektywnym ich wyodrębnieniem; póki co spółki rodzinne nie są objęte wyodrębnionym indeksem giełdowym (Grant Thornton, 2018), a ich dobór nawet na potrzeby badań naukowych ma często zróżnicowany lub nawet przypadkowy charakter; co więcej, populacja przedsiębiorstw rodzinnych na GPW może nie być reprezentatywna, a także przedsiębiorstwa notowane mogą, zdaniem niektórych autorów, poprzez wejście do obrotu publicznego, tracić swoją unikatową rodzinną specyfikę.

Przeprowadzone badania nie są z pewnością wyczerpujące i dają podstawy do dalszych analiz porównawczych weryfikujących występowanie efektów kalendarzowych w odniesieniu do różnych subpopulacji przedsiębiorstw, różniących się m.in. strukturą właścicielską.

Literatura

- Anderson, C., Reeb, D. (2003). Founding-Family Ownership and Firm Performance: Evidence from the S&P 500. *The Journal of Finance*, 3 (58), 1301–1328.
- Bogdański, M. (2017). Występowanie efektów kalendarzowych na Gieldzie Papierów Wartościowych w Warszawie. *Journal of Capital Market and Behavioral Finance*, 2 (6), 35–46.
- Budka, K., Kosiński, D., Sobczak, A. (2017). Występowanie anomalii kalendarzowych na przykładzie wybranego sektora GPW w Warszawie. *Journal of Capital Market and Behavioral Finance*, 3 (7), 7–16.
- Caprio, L., Croci, E., Del Giudice, A. (2011). Ownership Structure, Family Control, and Acquisition Decisions. *Journal of Corporate Finance*, 5 (17), 1636–1657.
- Chung, H.M. (2013). The Role of Family Management and Family Ownership in Diversification: The Case of Family Business Groups. *Asia Pacific Journal of Management*, 3 (30), 871–891. DOI:10.1007/s10490-012-9284-x.
- Czerwonka, M., Gorlewski, B. (2012). *Finanse behawioralne. Zachowania inwestorów i rynku*. Warszawa: Oficyna Wydawnicza SGH.
- Feldman, E.R., Amit, R.R., Villalonga, B. (2016). Corporate Divestitures and Family Control. *Strategic Management Journal*, 37, 429–446.
- Filipczak, S. (2018). *Gielda dla firm rodzinnych. Pozyskiwanie kapitału i zarządzanie majątkiem*. Warszawa: Wydawnictwo Naukowe PWN.
- Grant Thornton Frackowiak Sp. z o.o. Sp. k. (2018). *Rodzinny biznes na Gieldzie*. Pobrano z: <http://granthornton.pl/wp-content/uploads/2018/02/Rodzinny-biznes-na-Gie%C5%82dzie-Wersja-rozszerzona.pdf> (25.09.2018).
- González, M., Guzmán, A., Pombo, C., Trujillo, M.A. (2015) Family Firms and Debt: Risk Aversion Versus Risk of Losing Control. *Journal of Business Research*, 11 (66), 2308–2320. DOI: <https://doi.org/10.1016/j.jbusres.2012.03.014>.

- Harasim, K. (2016). Efekty kalendarzowe a stopa zwrotu z indeksu WIG. *Journal of Capital Market and Behavioral Finance*, 2 (4), 17–25.
- Keller, J., (2015). Efekt dni tygodnia w różnych segmentach rynku głównego GPW. *Finanse, Rynki Finansowe, Ubezpieczenia*, 74/1, 69–79.
- Lewandowska, A., Więcek-Janka, E., Hardyś-Nowak, A., Wojewoda, M., Tylczyński, Ł. (2016). *Firma rodzinna to marka*. Poznań: Instytut Biznesu Rodzinnego.
- Peters, E. (1997). *Teoria chaosu a rynki kapitałowe*. Warszawa: Wydawnictwo WIG-Press.
- Rau, S., Astrachan, J., Smyrnios, K. (2018). The F-PEC Revisited: From the Family Business Definition Dilemma to Foundation of Theory. *Family Business Review*, 2 (31), 200–213.
- Schabek, T., Castro, H. (2017). “Sell not only in May” Seasonal Effects on Stock Markets. *Dynamic Econometric Models*, 17, 5–18. DOI: <http://dx.doi.org/10.12775/DEM.2017.001>.
- Stradomski, M., Mikutowski, M. (2018). Aktywność firm rodzinnych na rynku fuzji i przejęć. *Przedsiębiorczość i Zarządzanie*, 7 (19/1), 163–176.
- Ziemba, W.T. (2012) *Calendar Anomalies and Arbitrage*. World Scientific Publishing Company.

CALENDAR ANOMALIES AMONG POLISH PUBLIC FAMILY COMPANIES

Abstract: *Purpose* – The purpose of this paper is to identify whether family businesses are different to non-family enterprises in terms of their stocks returns on the stock exchange in view of the calendar anomalies occurrence.

Design/methodology/approach – Logarithmic and arithmetic, monthly returns on shares of almost 400 companies from the WSE in 2006–2016 were analyzed, then the potential differences between the separated groups were verified by the ANOVA analysis.

Findings – The study did not show any significant differences between returns of family and non-family enterprises in the perspective of calendar effects.

Originality/value – Family businesses are an important group in the Polish economy, at the same time they have many features that diverse them from other types of enterprises. The analysis is designed to provide to scientific and business communities the information about the potential area of diversity of family businesses, that is, their stocks returns and perceiving of family businesses by investors.

Keywords: family business, behavioral finance, stocks, returns, WSE

Cytowanie

Stradomski, M., Mikutowski, M. (2018). Efekty kalendarzowe polskich rodzinnych spółek giełdowych. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 103–112. DOI: 10.18276/frfu.2018.94/2-08.

Ocena zastosowania zagranicznych kontraktów terminowych w zarządzaniu ryzykiem cenowym na rynku pszenicy w Polsce

Anna Szczepańska-Przekota*

Streszczenie *Cel* – Celem pracy jest rozpoznanie możliwości redukcji zmienności cen gotówkowych pszenicy przez producenta krajowego, przy wykorzystaniu kontraktów terminowych *futures* z giełd MATIF i CBOT.

Metoda badania – Porównano wynik finansowy ze strategii bez użycia kontraktów z wynikiem finansowym ze strategii z użyciem kontraktów. Wykorzystano do tego statystyki opisowe. Ceny kontraktów *futures* przeliczano na PLN według kursu zmiennego oraz według kursu stałego, co umożliwiło ocenę ryzyka walutowego.

Wynik – Istotnym wnioskiem płynącym z analiz jest stwierdzenie, że polski producent rolny nie może w sposób bezpieczny wykonywać operacji hedgingowych na zagranicznych rynkach terminowych. Zauważono, że na rynku pszenicy możliwe jest wykorzystywanie zagranicznych rynków terminowych do budowania strategii nie o charakterze hedgingowym, a o charakterze spekulacyjnym, mimo że jest to narażanie się na świadome ryzyko.

Oryginalność/wartość – W pracy poruszono problem wykorzystania zagranicznych rynków terminowych do zarządzania ryzykiem cenowym na krajowym rynku pszenicy. Biorąc pod uwagę, że w Polsce nie istnieje rynek kontraktów *futures* na produkty rolne, badania zamieszone w pracy mają wymiar aplikacyjny.

Słowa kluczowe: kontrakty *futures*, *hedging*, spekulacja, ryzyko walutowe

Wprowadzenie

Funkcjonowanie rynku rolnego zależy od rozmaitych czynników, których natura powoduje nieprzewidywalny efekt działalności. Współczesne gospodarstwo rolne podlega bardzo silnym wpływom globalnej sytuacji ekonomicznej. Niestabilność otoczenia ekonomicznego i przyrodniczego implikuje wzrost ryzyka cenowego i trudności w prognozowaniu przyszłego dochodu (Just, 2003). Zmienność cenowa rynków towarowych powodowana jest rynkowymi czynnikami makro- i mikroekonomicznymi oraz niestabilnymi uwarunkowaniami przyrodniczymi (Jerzak, 2014). Rynki rolne wykazują zależność od innych rynków, czego przejawem są transmisje cenowe między różnymi produktami (Hayesc, Xiaodong, Yub, 2011). Ponadto na rolnych rynkach terminowych obserwuje się coraz większe zainteresowanie ze strony inwestorów obecnych do tej pory tylko na rynku kapitałowym (Sanders, Irwin, 2012). Wszystko to powoduje, że ceny na rynkach rolnych podlegają znacznym wahaniom, które utrudniają funkcjonowanie i rozwój gospodarstw rolnych (Jerzak, 2013). Powstaje zatem pytanie, czy producent rolny jest w stanie tak zarządzać ryzykiem, aby ustabilizować zmienność ceny, czy też musi narażać się na dodatkowe czynniki ryzyka.

Jednym z rozwiązań w zakresie stabilizacji dochodów z produkcji rolnej, jakie oferuje rynek finansowy, jest skorzystanie z instrumentów pochodnych, w szczególności kontraktów terminowych. Współczesny światowy rynek kontraktów terminowych jest na tyle rozwinięty, że możliwy jest obrót kontraktami terminowymi także na giełdach zagranicznych. Transakcje zabezpieczające przyciągają producentów i przetwórców rolnych pragnących zabezpieczyć sobie przyszłą cenę produktów, z kolei transakcje spekulacyjne przyciągają inwestorów, którzy chcą zyskiwać na zmianach notowań instrumentów giełdowych. Ważną funkcją giełd terminowych jest odkrywanie przyszłych cen na rynku gotówkowym. Aktualna cena terminowa produktu zawiera w sobie oczekiwania uczestników rynku o kształtowaniu przyszłej ceny gotówkowej (Easwarana, Ramasundaram, 2008).

W Polsce nie funkcjonuje żadna giełda oferująca kontrakty *futures* na produkty rolne. Nasuwają się zatem pytania, czy polski producent może skorzystać z oferty giełd zagranicznych, jaka będzie efektywność takiego postępowania, czy przeprowadzane transakcje będą miały wymiar hedgingowy czy spekulacyjny. Problemy te stanowią przedmiot badań niniejszej pracy. Badania wykonano na podstawie danych tygodniowych dotyczących cen gotówkowych pszenicy publikowanych przez MRiRW za lata 2010–2016 oraz notowań kontraktów na pszenicę na giełdach MATIF i CBOT.

1. Rynek kontraktów *futures* na produkty rolne

W zależności od rzeczywistych potrzeb inwestor może wykorzystać kontrakty terminowe *forward* i *futures* na różne sposoby, np. jeżeli planuje zakupy produktu bazowego w przyszłości, a chce się zabezpieczyć przed jego wzrostem – kupuje kontrakt (zajmuje długą pozycję), z kolei jeżeli planuje sprzedaż produktu bazowego w przyszłości, a obawia się spadku jego ceny – sprzedaje kontrakt (zajmuje krótką pozycję). Wykorzystanie kontraktów daje pewność przyszłej ceny, natomiast nie pozwala na zdyskontowanie korzystnych zmian cen gotówkowych, gdyż jeżeli ceny gotówkowe wzrosną powyżej kwoty zabezpieczenia, dostawca nie skorzysta z tego wzrostu, ponieważ obowiązuje go cena z kontraktu. Stąd też, w zależności od skłonności inwestora do ryzyka, będzie on w większym lub mniejszym stopniu zainteresowany transakcjami zabezpieczającymi (Parcell, Pierce, 2000).

Rynek kontraktów *futures* może zostać także wykorzystany w celach spekulacyjnych. Należy tutaj wyróżnić spekulacje polegające na wykorzystaniu zmienności cen, które traktować można także jako inwestycje krótkoterminowe, od spekulacji polegających na oddziaływaniu na cenę. Te drugie są szczególnie niebezpieczne na rynku produktów rolnych, gdzie nawet niewielki wzrost cen dokonany na skutek działań spekulacyjnych przekłada się na dodatkowe problemy związane z zaopatrzeniem w żywność (Malik, 2013). Badania dotyczące identyfikacji podmiotów odpowiedzialnych za spekulacje nie należą od najłatwiejszych, często okazuje się, że brakuje dostatecznie silnych dowodów na potwierdzenie tezy, że dana instytucja odpowiedzialna jest za działania spekulacyjne (Irwin, Sanders, Merrin, 2009), a niekiedy te dowody są wątpliwe (Gilbert, 2010). Mimo wszystko możliwości, jakie daje rynek *futures*, zarówno w zakresie zabezpieczenia, jak i spekulacji, przyciągają dużą

liczbę kupujących i sprzedających na tych giełdach, co gwarantuje ich płynność (Jones, Kaul, Lipson, 1994).

Cena *futures* jest wypadkową wszystkich oczekiwań uczestników rynku. W danym dniu cena kontraktu będzie odzwierciedlać konsensus opinii kupujących i sprzedających co do przyszłej wartości dobra. Ceny *futures* zwiększają się lub zmniejszają z powodu niezliczonych czynników, które wpływają na oczekiwania kupujących i sprzedających co do tego, ile dany towar będzie wart w określonym czasie w przyszłości. Jeśli pojawią się nowe informacje, wystąpią zmiany w podaży i popycie, to oczekiwania również ulegną zmianie, a cena danego kontraktu będzie wahać się w górę lub w dół. Ten proces kształtowania cen wykazuje pewną ciągłość (Garbade, Silber, 1983). Kształtowanie cen przez rynki *futures* jest jedną z ważniejszych funkcji gospodarczych, a nawet głównych korzyści ekonomicznych tych rynków. Dzięki temu dostępne są informacje na temat przyszłej wartości towaru i każdy z uczestników w tym samym czasie ma pełen dostęp do tych samych informacji (Hazell, Jaramillo, Williamson, 1990). Rynki *futures* będą w stanie skutecznie pełnić funkcję zabezpieczającą tylko wtedy, gdy będą efektywne w zakresie kształtowania cen (Tomek, Peterson, 2001).

Zapotrzebowanie na produkty rynku terminowego wynika z faktu, że produkcja rolna charakteryzuje się nieredukowalnym poziomem nieprzewidywalności (Spratt, 2013). W rezultacie ceny produktów rolnych są bardziej niestabilne niż większości produktów w sektorze pozarolniczym (Schnepf, 2006). Efektywne rynki terminowe pozwalają producentom rolnym na stabilizację dochodu, jednak nie funkcjonują one w każdym kraju, a korzystanie z rynków zagranicznych wymaga ponoszenia dodatkowego ryzyka walutowego (Chen, Rogof, Rossi, 2010). Producenci rolni w takich krajach, jak Polska, gdzie nie funkcjonuje rynek *futures* produktów rolnych, mogą korzystać z rynków zagranicznych. W zakresie inwestycji na rynku pszenicy mogą być to np. należąca do grupy CME amerykańska giełda CBOT lub należąca do grupy NYSE Euronext francuska giełda MATIF. Kontrakty notowane na tych rynkach są przedmiotem analizy w niniejszym opracowaniu.

2. Metodyka badań


W wielu krajach nie funkcjonują giełdowe rynki terminowe, tymczasem gdy ceny gotówkowe wykazują wysoką korelację z cenami tych samych dóbr notowanych na innych zagranicznych rynkach (cena got_k a cena got_z na rysunku 1), gdzie funkcjonują efektywne rynki terminowe (wyrównanie cen gotówkowych i terminowych w momencie wygaśnięcia kontraktu), to możliwe jest wykorzystanie takich rynków do zabezpieczenia ceny na rynku krajowym. W tym wypadku wysoka korelacja nie musi oznaczać zbliżonych cen, lecz podążanie cen w tych samych kierunkach. Różnica w cenach wynika z kosztów transportu, systemu podatkowego obowiązującego w danym kraju, kosztów produkcji, kursu walutowego i innych czynników.

Na rysunku 1 pokazano, jak powinno wyglądać zachowanie krajowego rynku gotówkowego oraz zagranicznego rynku *futures*, aby dostawca dobra mógł zabezpieczyć przyszłą

cenę. Przy pełnej korelacji krajowych i zagranicznych cen gotówkowych oraz efektywnego zagranicznego rynku terminowego zabezpieczenie ceny na rynku krajowym możliwe jest na poziomie:

$$F_k = S_{k0} + (F_{z0} - S_{z0}),$$

gdzie $F_{z0} - S_{z0}$ jest bazą rynku zagranicznego.



Rysunek 1. Wykorzystanie zagranicznych rynków *futures* do zabezpieczenia ceny gotówkowej na rynku krajowym

Źródło: opracowanie własne.

Każde odstępstwo od pełnej korelacji między cenami gotówkowymi rynku krajowego i zagranicznego bądź efektywności zagranicznego rynku terminowego (a tak zachowuje się rzeczywisty rynek) powoduje niepewność co do zabezpieczenia przyszłej ceny na rynku krajowym za pomocą kontraktów zagranicznych.

Badania wykonane w pracy dotyczą wykorzystania kontraktów na pszenicę z giełd MATIF i CBOT do zabezpieczenia ceny gotówkowej na rynku polskim. Bazują one na danych tygodniowych dotyczących cen gotówkowych pszenicy publikowanych przez MRiRW za lata 2010–2016 oraz notowań kontraktów na pszenicę na giełdach MATIF i CBOT. Porównywano wynik finansowy ze strategii bez użycia kontraktów:

$$S_{k1} - S_{k0},$$

gdzie:

S_{k0} – cena gotówkowa na początku okresu analizy,

S_{k1} – cena gotówkowa na koniec okresu analizy,

z wynikiem finansowym ze strategii z użyciem kontraktów:

$$S_{k1} - S_{k0} + F_{z0} - F_{z1},$$

gdzie:

F_{z0} – cena terminowa na początku okresu analizy (cena sprzedaży kontraktów),

F_{z1} – cena terminowa na koniec okresu analizy (cena odkupu kontraktów).

Analizie poddano trzy momenty wejścia na rynek terminowy:

- pierwsze notowania kontraktu,
- rok przed wygaśnięciem kontraktu,
- ostatnie notowanie poprzedniego kontraktu.


Okres końcowy zawsze stanowiło ostatnie notowanie analizowanego kontraktu. Obliczenia przeprowadzano w zł/tonę, przeliczając notowania kontraktów według kursu walutowego obowiązującego w dniu przeprowadzenia transakcji (z narażeniem na ryzyko walutowe) oraz według kursu stałego, obowiązującego w dniu wejścia na rynek terminowy (bez narażenia na ryzyko walutowe).

3. Wyniki badań

Na giełdzie MATIF w latach 2010–2012 wygasły kontrakty styczeniowe, marcowe, majowe, sierpniowe i listopadowe. W kolejnych dwóch latach (2013–2014) nie notowano kontraktów sierpniowych, a w latach 2015–2016 miejsce kontraktów sierpniowych i listopadowych zajęły kontrakty wrześniowe i grudniowe.

Zgodnie z ustaloną metodologią badano trzy momenty wejścia na rynek terminowy (rys. 2): pierwszy w terminie pierwszego notowania kontraktu, w tym wypadku do terminu wygaśnięcia pozostawało od 79 tygodni dla kontraktów majowych z lat 2010–2013 do 152 tygodni dla kontraktu na grudzień 2016 roku. Drugi testowany moment wejścia na rynek terminowy to rok przed terminem wygaśnięcia danego kontraktu, w tym wypadku do terminu wygaśnięcia pozostawały zawsze 52 tygodnie dla każdego z kontraktów. Trzeci moment wejścia to ostatnie notowanie poprzedniego kontraktu, w tym wypadku czas utrzymywania kolejnych kontraktów był zmienny i wynosił od 8–9 tygodni dla kontraktów styczeniowych, marcowych, majowych i listopadowych za lata 2010–2012 do 26 tygodni dla kontraktów listopadowych za lata 2013–2014. Notowania kontraktów z giełdy MATIF pierwotnie wyrażone w euro przeliczono na złotówki.

Wyniki badania pierwszego (wejście na rynek terminowy w momencie pierwszego notowania kontraktu) zależą od zachowania cen gotówkowych. W okresie ich wzrostu (lata 2012–2013 w stosunku do 2010–2011) korzystanie z kontraktów znacząco pogarszało wyniki finansowe, ale w okresie malejących cen gotówkowych (lata 2015–2016) zabezpieczenie cen dawało już lepsze wyniki. Średni wynik dla strategii bez zabezpieczenia w całym ocenianym okresie, który wyniósł 2,24 zł, jest wyraźnie lepszy od wykorzystania kontraktów przy zmiennym kursie walutowym (–59,50 zł) oraz przy stałym kursie (–36,54 zł). Korzyścią ze stosowania kontraktów była jedynie znaczna redukcja zmienności (mierzonej odchyleniem standardowym) z poziomu 171,55 zł przy braku zabezpieczenia do około 100 zł przy zabezpieczeniu kontraktami według zmiennego bądź stałego kursu walutowego.




Rysunek 2. Wyniki transakcji zabezpieczających ceny pszenicy na rynku polskim za pomocą kontraktów z giełdy MATIF: (a) – wejście na rynek terminowy w terminie pierwszego notowania kontraktu; (b) – wejście na rynek terminowy rok przed wygaśnięciem kontraktu; (c) – wejście na rynek terminowy w momencie ostatniego notowania poprzedniego kontraktu

Źródło: obliczenia i wykonanie własne.

Wnioski z badania rocznego okresu zabezpieczenia ceny gotówkowej za pomocą kontraktów z giełdy MATIF zbliżone są do badania poprzedniego. Także tutaj widoczny jest lepszy wynik ekonomiczny bez zabezpieczenia ceny w sytuacji rosnących cen gotówkowych, a tylko nieznacznie korzystniejszy ze strategii z wykorzystaniem kontraktów terminowych w sytuacji malejących cen gotówkowych. W przedmiotowym badaniu uzyskano dla strategii bez zabezpieczania średni wynik na poziomie 24,39 zł, co jest wynikiem znacząco lepszym niż dla strategii z wykorzystaniem kontraktów przy zmiennym kursie walutowym –31,70 zł, oraz dla strategii z wykorzystaniem kontraktów przy stałym kursie walutowym –21,23 zł. Natomiast korzyścią z wykorzystania kontraktów była znaczna redukcja zmienności wyników. Dla strategii bez zabezpieczenia uzyskano odchylenie standardowe na poziomie 209,12 zł, tymczasem przy wykorzystaniu kontraktów spadło ono do poziomu poniżej 120 zł zarówno przy zmiennym, jak i stałym kursie walutowym.

Stosowanie kontraktów terminowych na giełdzie MATIF okazało się także mało skuteczne w krótkim okresie czasu, gdzie momentem wejścia na rynek terminowy były ostatnie notowania poprzednich kontraktów. Okazuje się, że przy znacznie gorszym średnim wyniku (dla strategii bez zabezpieczenia kontraktami uzyskano 6,43 zł, tymczasem dla strategii z wykorzystaniem kontraktów –11,82 zł dla kursu zmiennego i –10,71 zł dla kursu stałego), kontrakty nie oferowały wyraźnej redukcji ryzyka. Odchylenie standardowe różnicy cen dla strategii bez zabezpieczenia kontraktami wyniosło 88,65 zł, a dla strategii z zabezpieczeniem kontraktami liczonymi według kursu zmiennego niewiele mniej, bo 86,21 zł, z kolei dla strategii z zabezpieczeniem kontraktami liczonymi według kursu stałego wynik był prawie identyczny jak dla strategii bez zabezpieczenia kontraktami i wyniósł 88,39 zł.

Porównanie cen gotówkowych pszenicy z notowaniami kontraktów na giełdzie CBOT wymagało przeliczenia kursu walutowego z USD na PLN oraz zamiany jednostki metrycznej z buszli na tonę. Na giełdzie CBOT notowane są kontrakty na pszenicę o terminie wygaśnięcia w miesiącach: marzec, maj, lipiec, wrzesień i grudzień. Pierwsze badanie skuteczności zabezpieczenia cen gotówkowych za pomocą kontraktów terminowych odbywało się na odcinkach o zmiennej długości od 74 tygodni dla kontraktu na maj 2010 roku do 159 tygodni dla kontraktu na lipiec 2013 roku, z reguły było to około 140–150 tygodni, a więc okres około trzech lat. Drugie badanie przeprowadzono dla odcinków o długości 52 tygodni (jednego roku). Badanie trzecie przeprowadzono dla odcinków o długości od 8–9 tygodni dla kontraktów majowych, lipcowych i wrześniowych do 13 tygodni dla kontraktów marcowych i grudniowych. Wyniki zamieszczono na rysunku 3.



Rysunek 3. Wyniki transakcji zabezpieczających ceny pszenicy na rynku polskim za pomocą kontraktów z giełdy CBOT: (a) – wejście na rynek terminowy w terminie pierwszego notowania kontraktu; (b) – wejście na rynek terminowy rok przed wygaśnięciem kontraktu; (c) – wejście na rynek terminowy w momencie ostatniego notowania poprzedniego kontraktu

Źródło: obliczenia i wykonanie własne.

Transakcje zabezpieczające cenę pszenicy na polskim rynku gotówkowym za pomocą kontraktów z giełdy CBOT w badaniu pierwszym okazały się skuteczne. Nawet przy rosnących cenach gotówkowych użycie kontraktów nie pogarszało znacząco wyników (rozliczenie kontraktów w 2012 i 2013 r.), a w sytuacji malejących cen gotówkowych wyniki z użyciem kontraktów były zawsze lepsze. Generalnie dla strategii bez użycia kontraktów uzyskano średni wynik na poziomie $-35,04$ zł z odchyleniem standardowym $254,67$ zł. Użycie kontraktów przy zmiennym kursie walutowym pozwoliło na uzyskanie wyraźnie lepszego wyniku ekonomicznego przy znacznie mniejszym ryzyku, gdyż uzyskano średni wynik na poziomie $104,88$ zł z odchyleniem standardowym $154,71$ zł. Dodatkowe zabezpieczenie kursu walutowego na stałym poziomie pozwalało na dalszą poprawę wyniku, do średniego poziomu $151,99$ zł przy jeszcze mniejszym odchyleniu standardowym $124,74$ zł. Z uwagi na zmienny okres inwestycyjny trudno jest wyniki te w sposób w pełni wiarygodny porównywać z analogicznymi wynikami dla giełdy MATIF.

Badanie drugie dotyczyło zabezpieczenia ceny pszenicy na rok przed terminem wygaśnięcia kontraktu. Dzięki stałemu okresowi uzyskane wyniki są porównywalne z wynikami dla giełdy MATIF; chociaż terminy wygasania poszczególnych kontraktów są różne, jednak w każdym przypadku okres zainteresowania wynosił 1 rok. Dla strategii bez użycia kontraktów uzyskano średni wynik na poziomie $3,98$ zł z odchyleniem standardowym $189,79$ zł. Użycie kontraktów przy zmiennym kursie walutowym pozwoliło na uzyskanie lepszego wyniku ekonomicznego przy mniejszym ryzyku, gdyż uzyskano średnią $78,48$ zł z odchyleniem standardowym $154,08$ zł. Zabezpieczenie kursu walutowego na stałym poziomie pozwalało na dalszą poprawę wyniku, do średniego poziomu $102,91$ zł przy jeszcze mniejszym odchyleniu standardowym $127,75$ zł. Jednoznacznie można powiedzieć, że zabezpieczenie cen gotówkowych pszenicy przy użyciu kontraktów na giełdzie CBOT dawało lepsze średnie wyniki. Gorzej wypadła zmienność, która kształtowała się na poziomie nieco wyższym niż zmienność na giełdzie MATIF.

O ile wyniki zabezpieczenia ceny gotówkowej na rok przed terminem wykupu kontraktu (badanie drugie) albo na dłuższy termin (badanie pierwsze) dawały bardzo obiecujące wyniki zarówno w zakresie średniego wyniku ekonomicznego, jak i ryzyka, to zabezpieczenie ceny gotówkowej na poziomie ceny z terminu ostatniego notowania poprzedniego kontraktu, a więc dla krótkiego terminu, jest już słabsze. Wprawdzie uzyskano dobry wynik ekonomiczny, szczególnie jeśli weźmie się pod uwagę, że badaniu podlegały krótkie okresy, ale obarczony był on wyższą zmiennością. Dla strategii bez użycia kontraktów terminowych uzyskano średni wynik na poziomie $5,43$ zł z odchyleniem standardowym $72,95$ zł. Użycie kontraktów przy zmiennym kursie walutowym pozwoliło na uzyskanie lepszego wyniku ekonomicznego, gdyż uzyskano średnią na poziomie $14,61$ zł, ale już przy odchyleniu standardowym $100,17$ zł. Zabezpieczenie kursu walutowego na stałym poziomie pozwalało na dalszą poprawę średniego wyniku, do poziomu $19,91$ zł, ale także przy większym niż dla strategii bez zabezpieczenia odchyleniu standardowym wynoszącym $95,24$ zł.

Uwagi końcowe

Korzystanie przez polskich producentów rolnych z zagranicznych rynków terminowych wymaga od nich znajomości wielu danych, takich jak bieżące ceny gotówkowe w Polsce, ceny terminowe i bieżące ceny gotówkowe na rynkach zagranicznych, kurs walutowy i oczekiwania odnośnie do tych cen w przyszłości. Wszystko to powoduje, że ryzyko niewłaściwej transakcji jest dość duże, a inwestowanie na zagranicznych rynkach bardziej przypomina działania spekulacyjne niż hedgingowe.

Z przeprowadzonych analiz wyłania się obraz rynku terminowego, któremu bliżej do charakteru spekulacyjnego niż hedgingowego, chociaż zauważa się możliwości ograniczenia zmienności wyniku ekonomicznego. Dodatkowym demotywatorem dla producentów rolnych może być niepewny dochód, a nawet więcej, często dochód średnio gorszy niż w przypadku strategii bez zabezpieczenia.

Generalnie wykorzystanie kontraktów terminowych powoduje stabilizację wyników, co jest sytuacją oczekiwaną i wskazywałoby na sens takiego postępowania. Jednak producent rolny bierze pod uwagę nie tylko ryzyko, ale również dochód, a tutaj wyniki są już słabsze. Zgodnie z ogólnymi prawidłowościami rynkowymi mniejszemu ryzyku odpowiada średnio mniejszy dochód. Oczekiwanie większego dochodu wiąże się z podjęciem większego ryzyka. Taka jest natura zabezpieczania cen gotówkowych pszenicy na rynku krajowym przy użyciu kontraktów z giełdy MATIF.

Inaczej przedstawiają się wyniki dla rynku CBOT. Należy stwierdzić, że ukształtowanie cen gotówkowych pszenicy w Polsce w stosunku do cen terminowych na tym rynku jest korzystne z punktu widzenia polskiego producenta rolnego. Pozostaje do rozstrzygnięcia kwestia stabilności uzyskanych wyników, tj. pytanie, czy uzyskane relacje mają charakter trwały, czy jedynie są wynikiem przyjętego horyzontu czasowego analizy. Z obserwacji sytuacji w latach 2010–2016 wynika raczej stabilny charakter tej relacji, co sugerowałoby zasadność podejmowania ryzyka zabezpieczania cen przy użyciu tego rynku.

W związku z uzyskanymi rezultatami należy negatywnie ustosunkować się do waloru aplikacyjnego przeprowadzonych badań, tj. należy stwierdzić, że nie jest możliwe stosowanie strategii hedgingowej dla zabezpieczenia się przed ryzykiem zmian cen produktów rolnych na polskim rynku gotówkowym przy wykorzystaniu kontraktów terminowych *futures* z rynków zagranicznych. Strategie inwestycyjne z wykorzystaniem zagranicznych rynków terminowych mają wymiar spekulacyjny, a ryzyko walutowe działa tutaj negatywnie. Strategie zabezpieczone stałym kursem walutowym z reguły przynosiły lepsze wyniki. Instrumentarium możliwości redukcji ryzyka zmian cen polskiego producenta rolnego, w porównaniu do producentów z krajów, w których funkcjonują rynki terminowe, jest ograniczone. Narażając się na świadome ryzyko, polscy producenci rolni mogą wykorzystać zagraniczne rynki terminowe do budowania strategii o charakterze spekulacyjnym, które przy odpowiednim układzie cen mogą przynosić dodatkowe dochody.

Literatura

- Chen, Y.C., Rogof, K., Rossi, B. (2010). Can Exchange Rates Forecast Commodity Prices? *Quarterly Journal of Economics*, 3 (125), 1145–1194.
- Easwarana, R.S. Ramasundaram, P. (2008). Whether Commodity Futures Market in Agriculture is Efficient in Price Discovery? – An Econometric Analysis. *Agricultural Economics Research Review*, 21 (Conference Number), 337–344.
- Garbade, K.D., Silber, W.L. (1983). Price Movements and Price Discovery in Futures and Cash Markets. *Review of Economics and Statistics*, 2 (65), 289–297.
- Gilbert, Ch.L. (2010). *Speculative Influences on Commodity Futures Prices 2006–2008*. UNCTAD Discussion Paper.
- Hayesc, D.J. Xiaodong, D. Yub, C.L. (2011). Speculation and Volatility Spillover in the Crude Oil and Agricultural Commodity Markets: A Bayesian Analysis. *Energy Economics*, 3 (33), 497–503.
- Hazell, P.B.R., Jaramillo, M., Williamson, A. (1990). The Relationship between the World Price Instability and the Prices Farmers Receive in Developing Countries. *Journal of Agricultural Economics*, 41, 227–243.
- Irwin, S.H., Sanders, D.R. (2010). A Speculative Bubble in Commodity Futures Prices? Cross-sectional Evidence. *Agricultural Economics*, 1 (41), 25–32.
- Irwin, S.H., Sanders, D.R., Merrin, R.P. (2009). Devil or Angel? The Role of Speculation in the Recent Commodity Price Boom (and Bust). *Journal of Agricultural and Applied Economics*, 2 (41), 377–391.
- Jerzak, M. (2014). Towarowe instrumenty pochodne w zarządzaniu ryzykiem cenowym w rolnictwie. *Roczniki Naukowe Ekonomii Rolnictwa i Rozwoju Obszarów Wiejskich*, 4 (101), 78–84.
- Jerzak, M. (2013). *Towarowy rynek terminowy w rolnictwie – determinanty tworzenia i rozwoju w Polsce*. Poznań: Wydawnictwo Uniwersytetu Przyrodniczego w Poznaniu.
- Jones, C.M., Kaul, G., Lipson, M.L. (1994). Transactions, Volume and Volatility. *Review of Financial Studies*, 7, 631–651.
- Just, R.E. (2003). Risk Research in Agricultural Economics: Opportunities and Challenges for the Next Twenty-five Years. *Agricultural Systems*, 75, 123–159.
- Malik, G. (2013). Identyfikacja spekulacji na rynkach terminowych towarów rolnych. *Econometrics* 4 (42), 140–148.
- Parcell, J. Pierce, V. (2000). *Introduction to Hedging Agricultural Commodities with Futures*. University of Missouri Extension.
- Sanders, D.R., Irwin, S.H. (2012). Reappraisal of Investing in Commodity Futures Markets. *Applied Economic Perspectives and Policy*, 3 (34), 515–530.
- Schnepf, R. (2006). *Price Determination in Agricultural Commodity Markets: A Primer*. United States Department of Agriculture. Congressional Research Services – Report for Congress.
- Spratt, S. (2013). *Food Price Volatility and Financial Speculation*. United Kingdom Futures Agriculture Consortium. Institute of Development. Working Paper 047.
- Tomek, W.G., Peterson, H.H. (2001). Risk Management in Agricultural Markets: A Review. *The Journal of Futures Markets*, 10 (21), 953–985.
- Working, H. (1953). Futures Trading and Hedging. *American Economic Review*, 43, 314–343.

ASSESSMENT OF THE USE OF FOREIGN FUTURES CONTRACTS IN PRICE RISK MANAGEMENT IN THE WHEAT MARKET IN POLAND

Abstract Purpose – The aim of the work is to recognize the possibility of reducing the volatility of cash prices on the Polish wheat market by using futures contracts from the MATIF and CBOT markets.

Design/methodology/approach – The financial result from the strategy was compared without the use of contracts with the financial result from the strategy with the use of contracts. Descriptive statistics were used here. The prices of futures contracts were converted into PLN according to the floating exchange rate and according to the fixed exchange rate, which made it possible to assess the currency risk.

Findings – An important issue from the analysis is the statement that the Polish agricultural producer can't safely perform hedging operations on foreign futures markets. It was noticed that on the wheat market, exposing itself to conscious risk, it is possible to use foreign futures markets to build non-hedging but speculative strategies.

Originality/value – The paper discusses the problem of using foreign futures markets to manage price risk on the domestic wheat market. Considering that there is no market for futures contracts for agricultural products in Poland, research undertaken at work has an application dimension.

Keywords: futures contracts, hedging, speculation, currency risk

Cytowanie

Szczepańska-Przekota, A. (2018). Ocena zastosowania zagranicznych kontraktów terminowych w zarządzaniu ryzykiem cenowym na rynku pszenicy w Polsce. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 113–124. DOI: 10.18276/frfu.2018.94/2-09.

Analiza porównawcza kształtowania się indeksów akcji na świecie po kryzysie finansowym¹

Ryszard Węgrzyn*

Streszczenie: *Cel* – Po bessie związanej z ostatnim kryzysem finansowym w pierwszych miesiącach 2009 roku można było obserwować odwrócenie trendów i początek kształtowania się długotrwałej hossy. Celem artykułu jest przeprowadzenie i zaprezentowanie analizy porównawczej stóp zwrotu i ryzyka (zmienności stóp zwrotu) wybranych giełdowych indeksów akcji w tym pokryzysowym okresie, zwłaszcza wskazanie różnic dotyczących indeksów akcji z różnych regionów geograficznych i krajów.

Metodologia badania – Indeksy giełdowe przeanalizowano pod kątem długookresowych zmian, podstawowych charakterystyk stóp zwrotu oraz zróżnicowania ich zmienności z zastosowaniem modeli GARCH. W części końcowej dokonano porównania oczekiwanych stóp zwrotu i ryzyka indeksów. Szczegółowej analizie poddano łącznie 15 indeksów.

Wynik – Na podstawie przeprowadzonej analizy dokonano oceny kształtowania się wybranych indeksów giełdowych oraz zwrócono uwagę na występujące różnice w zakresie ich stóp zwrotu i ryzyka.

Oryginalność/wartość – Wyniki badań dają możliwość szerszego spojrzenia na zróżnicowaną sytuację rynku kapitałowego po kryzysie finansowym i mogą być wykorzystane przez inwestorów lokujących środki finansowe na przykład w funduszach indeksowych.

Słowa kluczowe: indeks giełdowy, zmienność, model GARCH

Wprowadzenie

Ostatni kryzys finansowy objawił się na giełdach światowych szczególnie w październiku 2008 roku. Początek miesiąca przyniósł znaczne spadki najbardziej znanego na świecie indeksu giełdy nowojorskiej DJIA. Po kolejnych spadkach, łącznie od 1 do 27 października 2008 roku, indeks ten obniżył się o 24,5%². Podobnie jednak jak w wypadku DJIA, tak i w wypadku wielu innych indeksów, początek bessy nastąpił znacznie wcześniej. Bessa ta na większości giełd światowych rozpoczęła się już w drugiej połowie 2007 roku i trwała do pierwszych miesięcy 2009 roku. Zwłaszcza w marcu 2009 roku można było obserwować odwrócenie trendów i początek kształtowania się nowej hossy (szerzej: Węgrzyn, 2010). Od tamtego czasu minęło już ponad dziewięć lat, co skłania do bliższego zainteresowania

* dr hab. Ryszard Węgrzyn prof. UEK, Uniwersytet Ekonomiczny w Krakowie, e-mail: wegrzyn@uek.krakow.pl.

¹ Publikacja została sfinansowana ze środków przyznanych Wydziałowi Zarządzania Uniwersytetu Ekonomicznego w Krakowie w ramach dotacji na utrzymanie potencjału badawczego.

² Obliczenia własne na podstawie danych Serwisu Informacyjnego Stooq, stooq.co.kr (10.07.2009).

kształtowaniem się indeksów w tym pokryzysowym okresie, zwłaszcza w zakresie zróżnicowania pod względem geograficznym.

Celem artykułu jest przeprowadzenie i zaprezentowanie analizy porównawczej stóp zwrotu i ryzyka (zmienności stóp zwrotu) wybranych giełdowych indeksów akcji, a w szczególności wskazanie różnic w kształtowaniu indeksów reprezentujących akcje spółek z różnych regionów geograficznych i krajów.

Indeksy giełdowe przeanalizowano pod kątem długookresowych zmian, podstawowych statystyk stóp zwrotu oraz zróżnicowania ich zmienności z zastosowaniem modeli GARCH. W części końcowej zaprezentowano także porównanie oczekiwanych stóp zwrotu i ryzyka indeksów giełdowych. Szczegółowej analizie poddano łącznie 15 wybranych indeksów giełdowych, reprezentujących największe giełdy światowe oraz poszczególne regiony geograficzne, w okresie od 1 kwietnia 2009 do 30 kwietnia 2018 roku.

1. Przegląd literatury

Analizę indeksów giełdowych akcji skupiono w szczególności na ocenie ich zmienności za pomocą modelu GARCH, który jest jednym z podstawowych i najpopularniejszych podejść w analizie szeregów czasowych, zwłaszcza na rynkach akcji. Model GARCH został pierwotnie opracowany przez Bollersleva (1986) i Taylora (1986) oraz szeroko rozwinięty przez kolejnych autorów, którzy zaproponowali różnorodne jego modyfikacje. Przegląd tych modeli można znaleźć na przykład w pracach Stawickiego (2004), Osińskiej (2006), Doman i Domana (2009), Fiszедера (2009) oraz Bauwensa, Hafnera i Laurenta (2012).

Badania związane z zastosowaniem modeli GARCH skupiały się w większości na indeksach giełdowych i kursach walutowych. W jednej z pierwszych na ten temat prac V. Akgiray (1989) stwierdził, że model GARCH, porównany ze średnią ruchomą ważoną wykładniczo i innymi modelami zmienności historycznej, radzi sobie lepiej. Pagan i Schwert (1990) w swoich badaniach uznali model EGARCH za najlepszy w prognozowaniu. Cumby, Figlewski i Hasbrouck (1993) również wykazali, że EGARCH jest lepszy od modeli zmienności historycznej. Figlewski (1997) natomiast wyciągnął wniosek, że GARCH jest lepszy od modeli zmienności historycznej tylko na rynkach akcji przy wykorzystaniu danych dziennych. Heynen i Kat (1994) polecali model EGARCH zarówno dla zmienności indeksów akcyjnych, jak i kursów walutowych.

W nowszych badaniach Erginbay, Eleftherios i Yusuf (2014) przeanalizowali zastosowanie modeli GARCH, GJR-GARCH i EGARCH do modelowania zmienności stóp zwrotów indeksów giełdowych dla czterech europejskich rynków wschodzących i Turcji. Na podstawie obserwacji dziennych z rynków Bułgarii (indeks SOFIX), Czech (PX), Polski (WIG), Węgier (BUX) i Turcji (XU100) pozytywnie ocenili modele GARCH dla zwrotów z indeksów PX, BUX, WIG i XU100, natomiast w wypadku indeksu SOFIX stwierdzili, że nie ma znaczącego efektu GARCH.

Z kolei Farhan, Samia i Raza (2017) przeanalizowali zmienność stóp zwrotu akcji na czterech azjatyckich rynkach kapitałowych, stosując modele ARCH, GARCH, EGARCH,

TGARCH i PARCH. Na podstawie kryterium informacyjnego Akaike (AIC) i kryterium informacyjnego Schwarz (SIC) ocenili, że model TGARCH przewyższał inne modele w wypadku indeksów SSE Composite i BSE SENSEX, natomiast model PARCH okazał się lepszy w wypadku indeksów KSE100 i DSE20.

Zawsze istniało duże zainteresowanie poznawaniem zmian w zmienności stóp zwrotów z akcji i innych szeregów czasowych z powodu szoków (wstrząsów) egzogennych. Badacze i inwestorzy badali również wpływ nieprzewidywanych szoków na kształtowanie się zmienności w czasie. Hassan (2017) w swoim artykule zastosował różne narzędzia w celu uchwycenia okresów nagłych zmian w zmienności indeksów DJIA, DAX i FTSE. Uzyskane wyniki wskazały, że persistencja szoków w zakresie zmienności nie jest tak duża, jak powszechnie się uważa.

Jeżeli chodzi o szczegółowe postaci modeli GARCH, to Engle (2001) podzielił pogląd, że GARCH(1,1) jest najprostszym i najbardziej odpornym modelem spośród całej rodziny modeli zmienności. Ng i McAleer (2004) zastosowali modele zmienności GARCH(1,1) i TARCH(1,1), aby oszacować i prognozować zmienność dziennych stóp zwrotu z indeksów Nikkei225 i S&P 500. Wyniki wskazały, że ocena tych modeli była zależna od użytych danych. Model GARCH(1,1) wydawał się lepszy w odniesieniu do indeksu Nikkei225, podczas gdy TGARCH (1,1) był lepiej oceniany dla indeksu S&P 500.

W odniesieniu do wybranych polskich szeregów finansowych Fiszedler i Orzeszko (2012) zastosowali różne jedno- i wielowymiarowe modele klasy GARCH. Wyniki wskazały, że modele ARMA-GARCH są ogólnie w stanie uchwycić zależności w analizowanych szeregach czasowych. Nie oznacza to jednak, że każdy określony model ARMA-GARCH wystarczająco dobrze opisuje istniejące zależności. Badanie pokazało, że różne parametryzacje analizowanych modeli klasy GARCH mają różne zdolności opisywania dynamiki procesów finansowych, a zastosowanie wyższych opóźnień w modelu GARCH może mieć decydujący wpływ na usunięcie efektu ARCH, a w konsekwencji na identyfikację nieliniowości.

Modele ARMA-GARCH zostały przeanalizowane także przez Węgrzyna (2013) w odniesieniu do indeksu WIG20. Autor przedstawił wyniki zastosowania modeli ARMA, służących do eliminacji zależności liniowych, oraz modeli GARCH, APARCH oraz EGARCH zarówno z normalnym warunkowym rozkładem, jak i rozkładem t -Studenta oraz skośnym rozkładem t -Studenta. Analiza obejmowała okres od 3 października 1994 do 31 października 2012 roku o łącznej liczbie obserwacji 4529. Występowanie związków liniowych w stopach zwrotów wskazuje na potrzebę zastosowania odpowiedniej specyfikacji równania średniej warunkowej. W przeprowadzonej analizie w każdym przypadku wykorzystano model ARMA, dobrany na podstawie wstępnych oszacowań. Po przetestowaniu reszt z dopasowanego modelu liniowego na obecność heteroskedastyczności warunkowej typu autoregresyjnego przeprowadzono próby dopasowania modeli zmienności GARCH, APARCH oraz EGARCH. W wypadku analizy dziennych stóp zwrotu indeksu WIG20 dwa spośród analizowanych modeli zasługiwały na szczególną uwagę: model AR(1)-GARCH(1,1) z rozkładem t -Studenta oraz AR(1)-APARCH(1,1) z rozkładem t -Studenta. Kryteria informacyjne w obu przypadkach były bardzo zbliżone, co może skłaniać do wyboru prostszego modelu AR(1)-GARCH(1,1). Wybór taki były zgodny z wynikami badań spotykanymi w literaturze (Doman, Doman, 2009, s. 96 i n.; Osiewalski, Pajor, Pipień, 2004, s. 17–39).

2. Zastosowane metody badawcze oraz charakterystyka danych

W pierwszej kolejności wybrane indeksy giełdowe oceniono pod kątem długookresowych zmian na podstawie sporządzonych wykresów, a także podstawowych charakterystyk stóp zwrotu. Następnie oszacowano długookresowe odchylenia standardowe stóp zwrotu indeksów za pomocą wybranego modelu GARCH oraz dokonano porównania oczekiwanych stóp zwrotu indeksów i ich zmienności.

W związku z analizą zmienności stóp zwrotu zastosowano, ze względu na ich własności, logarytmiczne stopy zwrotu określane jako (Doman, Doman, 2009, s. 20):

$$r_t = (\ln P_t - \ln P_{t-1}) \cdot 100 \quad (1)$$

gdzie:

P_t – poziom określonego indeksu w momencie t .

Stopy te podaje się często w takiej postaci, aby uniknąć wielkości bardzo bliskich zeru.

W literaturze finansowej występuje wiele różnego typu rozwiązań stosowanych w modelowaniu i prognozowaniu zmienności stóp zwrotu. Ogólną reprezentacją liniowych modeli gaussowskich jest model ARMA(p,q) (*autoregressive moving average*) o postaci:

$$r_t = a_0 + \sum_{j=1}^p a_j r_{t-j} + \varepsilon_t - \sum_{j=1}^q b_j \varepsilon_{t-j} \quad (2)$$

gdzie:

r_t – logarytmiczna stopa zwrotu,

a_0 , a_j i b_j – parametry modelu,

ε_t – niezależne i o tym samym rozkładzie zmienne losowe ze średnią zero i skończoną wariancją.

Model ARMA(0,q) jest określany jako model średniej ruchomej rzędu q i oznaczany przez MA(q), natomiast model ARMA(p,0) jest modelem autoregresyjnym rzędu p , oznaczanym przez AR(p).

Dla modelowania zmian w wariancji podstawowym było określenie stopy zwrotu r_t jako sumy o postaci (Doman, Doman 2009, s. 77):

$$r_t = \mu_t + \varepsilon_t \quad (3)$$

gdzie:

μ_t – średnia warunkowa, opisywana zazwyczaj za pomocą modelu ARMA(p,q),

ε_t – innowacja w średniej, określana jako ciąg niezależnych i o tym samym rozkładzie (IID – *independent and identically distributed*) zmiennych losowych z_t ze średnią zero i wariancją jeden, pomnożonych przez odchylenie standardowe σ_t :

$$\varepsilon_t = \sigma_t z_t. \quad (4)$$

Engle (1982) zaproponował, aby wariancja była w tym wypadku modelowana jako warunkowa względem przeszłych obserwacji przy użyciu modelu autoregresyjnej heteroskedastyczności warunkowej (ARCH – *autoregressive conditional heteroscedasticity*). Włączając opóźnione wartości σ_t^2 , otrzymujemy tak zwany uogólniony model ARCH:

$$\sigma_t^2 = \alpha + \beta_1 \varepsilon_{t-1}^2 + \dots + \beta_p \varepsilon_{t-p}^2 + \gamma_1 \sigma_{t-1}^2 + \dots + \gamma_q \sigma_{t-q}^2, \alpha > 0, \beta \geq 0, \gamma_i \geq 0. \quad (5)$$

Model ten został zaproponowany przez Bollersleva (1986) i Taylora (1986) i określony jako GARCH(p,q) (*generalized autoregressive conditional heteroscedasticity*). Modyfikacja ta doprowadziła do redukcji liczby koniecznych do estymowania parametrów. W większości empirycznych zastosowań wartości ($p \leq 2$, $q \leq 2$) są wystarczające, aby modelować zmienność.

Literatura dotycząca modeli GARCH jest niezwykle bogata, a pojawiające się liczne modyfikacje powodują, że znalezienie modelu, który najlepiej opisuje badany szereg czasowy, jest zadaniem bardzo trudnym i nie zawsze celowym. W przeprowadzonym badaniu chodziło o oszacowanie wariancji (odchylenia standardowego) procesu ε_t dla badanego okresu. Na podstawie przeglądu literatury zdecydowano się na wybór modelu o postaci AR(1)-GARCH(1,1) z warunkowym rozkładem t -Studenta.

Po wyliczeniu logarytmicznych dziennych stóp zwrotu dla poszczególnych indeksów oszacowano parametry modelu metodą największej wiarygodności za pomocą programu komputerowego Time Series Modelling dla badanego okresu od 1 kwietnia 2009 do 30 kwietnia 2018 roku. Liczba obserwacji różniła się w zależności od kraju funkcjonowania danej giełdy ze względu na różną liczbę dni bez handlu. Dla chińskiego indeksu SSE zanotowano w tym okresie 2203 obserwacje, a dla indeksu CAC z giełdy paryskiej – 2408 obserwacji.

Wybór indeksów giełdowych do analizy uwzględniał głównie kryterium wielkości kapitalizacji giełdy³, którą dany indeks reprezentuje, oraz kryterium zapewniające reprezentację poszczególnych regionów geograficznych. W związku z tym Amerykę Północną reprezentują giełdy New York Stock Exchange z indeksem DJIA (Dow Jones Industrial Average) oraz NASDAQ z indeksem NASDAQ, a także Toronto Stock Exchange z indeksem TSX. Europę reprezentują z kolei Giełda Paryska z indeksem CAC40 (Cotation Assistée en Continu), London Stock Exchange z indeksem FTSE250 (Financial Times Stock Exchange 250), Giełda Niemiecka z indeksem DAX (Deutscher Aktienindex), a także Giełda Moskiewska z indeksem RTS (Russian Trading System) i Giełda Warszawska z indeksem WIG20 (Warszawski Indeks Giełdowy 20). W przypadku Azji wybrano natomiast giełdy: w Tokio z indeksem Nikkei 225 (Nikkei heikin kabuka), Szanghaju z indeksem SSE (Shanghai Stock Exchange Composite), Hongkongu z indeksem Hang Seng, Bombaju z indeksem SENSEX (Bombay Stock Exchange Sensitive Index) oraz Australian Securities Exchange z indeksem All Ordinaries. W Ameryce Łacińskiej wybrano dwie największe giełdy tego regionu: São


³ Uwzględniono dane dotyczące krajowej kapitalizacji giełd podane przez World Federation of Exchange, www.world-exchanges.org (25.05.2018).

Paulo Stock Exchange z indeksem Bovespa (Bolsa de Valores de São Paulo) oraz Mexican Stock Exchange z indeksem IPC (Índice de Precios y Cotizaciones).

3. Wyniki analizy długookresowych zmian wybranych indeksów giełdowych

Przed przystąpieniem do oceny kształtowania się wybranych indeksów w okresie ostatnich dziewięciu lat warto zwrócić uwagę na historię ich kształtowania się. Otóż w 2003 roku na wielu rynkach rozpoczął się okres hossy, który trwał do około połowy 2007 roku. W drugiej połowie natomiast większość analizowanych indeksów przeszła z fazy hossy w bessę, która pogłębiała się w 2008 roku, zwłaszcza w styczniu i październiku. Bessa ta przyniosła łączne spadki indeksów rzędu 50–70%. Do ponownego odwrócenia trendów i rozpoczęcia kolejnej hossy dochodziło najczęściej w lutym i marcu 2009 roku.

Na rysunkach 1–2 przedstawiono przykładowe kształtowanie się indeksów od 2 stycznia 2009 do 30 kwietnia 2018 roku. Przed sporządzeniem rysunków zsynchronizowano odpowiednio daty obserwacji. Na rysunku 1 zaprezentowano indeksy Dow Jones, TSX, CAC, FTSE250 oraz DAX. Indeks DJIA, który w tym wypadku jest pewnym punktem odniesienia, został wyróżniony pogrubioną linią i prezentuje najsilniejszą tendencję wzrostową. Na podstawie rysunku można stwierdzić, że indeks TSX w początkowym okresie przewyższał indeks DJIA, lecz z czasem jego tempo wzrostu osłabło. Indeksy FTSE250 i DAX kształtowały się w sposób zbliżony do DJIA, ale w przeciwieństwie do niego nie wykazały tak przyspieszonego wzrostu pod koniec 2017 roku. Indeks CAC natomiast prezentuje znacznie słabszą tendencję wzrostową.




Rysunek 1. Kształtowanie się indeksów w okresie 2.01.2009 r. – 30.04.2018 r. (1)

Źródło: opracowanie własne na podstawie danych Serwisu Informacyjnego Stooq, www.stooq.pl (25.05.2018).

Na rysunku 2 ujęto natomiast indeksy NASDAQ, RTS, WIG20 oraz SSE. W tym wypadku punktem odniesienia jest NASDAQ, wyróżniony linią pogrubioną. W początkowym okresie wszystkie indeksy wykazały silny wzrost, zwłaszcza SSE, ale w późniejszym okresie, z wyjątkiem indeksu NASDAQ, pojawiła się tendencja spadkowa i pewna stagnacja. Indeks SSE w 2015 roku zanotował silny wzrost, ale też mocny spadek. Dopiero w ostatnich latach indeksy WIG20, RTS oraz SSE wykazały stabilną łagodną tendencję wzrostową.

Tokijski index Nikkei225 kształtował się w sposób zbliżony do DJIA, chociaż zdecydowanie bardziej dynamicznie. Indeksy Hang Seng i SENSEX natomiast w początkowym okresie bardzo mocno wzrosły, ale w późniejszym okresie ich tendencja wzrostowa była podobna do DJIA. Znacznie słabszą tendencję wzrostową zaobserwowano w przypadku indeksu giełdy australijskiej. Indeks IPC kształtował się w sposób zbliżony do DJIA, natomiast indeks Bovespa po szybkim wzroście w 2009 roku zaprezentował tendencję spadkową w latach 2001–2015 oraz silną tendencję wzrostową zapoczątkowaną w 2016 roku. Reasumując, można stwierdzić, że w badanym okresie w większości przypadków analizowane indeksy giełdowe wykazywały wyraźną tendencję wzrostową.



Rysunek 2. Kształtowanie się indeksów w okresie 2.01.2009 r. – 30.04.2018 r. (2)

Źródło: opracowanie własne na podstawie danych Serwisu Informacyjnego Stooq, www.stooq.pl (25.05.2018).

W celu precyzyjniejszego porównania zmian indeksów giełdowych wyliczono podstawowe statystyki stóp zwrotu, które zaprezentowano w tabeli 1. Na podstawie danych zawartych w tabeli można stwierdzić, że najwyższymi średnimi stopami zwrotu w badanym okresie charakteryzują się indeksy: NASDAQ, SENSEX, DJIA, FTSE250 i DAX, najniższymi natomiast SSE, WIG20, RTS, All Ordinaries i TSX. Z wyjątkiem indeksu SENSEX wszystkie indeksy wykazały ujemną skośność rozkładu stóp zwrotu, natomiast obliczona kurtoza w każdym przypadku była dodatnia, wskazując na dużą koncentrację obserwacji

wokół średniej. Odchylenie standardowe jako miara zmienności wskazuje na zróżnicowanie pod tym względem poszczególnych indeksów. W tym wypadku jednak przeprowadzono dodatkowo pogłębioną analizę zmienności stóp zwrotu indeksów giełdowych, opartą na wybranym modelu GARCH.

Tabela 1

Podstawowe statystyki kształtowania się stóp zwrotu indeksów giełdowych w okresie 1.04.2009 r. – 30.04.2018 r.

Indeks	Średnia	Odchylenie standardowe	Skośność	Kurtoza
Dow Jones	0,049700	0,909355	−0,439853	3,62106
Nasdaq	0,066319	1,089659	−0,423538	3,12122
TSX	0,024464	0,852941	−0,340436	2,49189
CAC	0,028606	1,292210	−0,138335	3,61852
FTSE250	0,049380	0,980703	−0,591901	4,84592
DAX	0,048422	1,263099	−0,218833	2,35225
RTS	0,022862	1,890149	−0,346883	5,96328
WIG20	0,017965	1,261864	−0,126563	3,11346
Nikkei225	0,044476	1,369416	−0,492912	4,89519
SSE	0,011185	1,432917	−0,958076	5,55265
Hang Seng	0,036787	1,223617	−0,102678	2,61094
SENSEX	0,056723	1,109072	1,269695	20,61342
All Ordinaries	0,023665	0,894900	−0,266561	1,52743
Bovespa	0,032022	1,453822	−0,108069	1,86183
IPC	0,038953	0,952122	−0,140309	3,45296

Źródło: obliczenia własne za pomocą programu Time Series Modelling 4.31.

4. Wyniki analizy zmienności stóp zwrotu indeksów giełdowych

Wyniki oszacowań parametrów modeli dla badanego okresu przedstawiono w tabelach 2–3. Na ich podstawie można zauważyć, że, z wyjątkiem parametru modelu $AR(1) - a_1$, parametry wykazały istotność statystyczną w przypadku każdego z analizowanych indeksów. Parametr a_1 był istotny statystycznie tylko w pięciu przypadkach. Mimo to pozostawiono ten składnik w modelu ze względu na występowanie związków liniowych w stopach zwrotów.

Na podstawie oszacowanych parametrów modeli GARCH(1,1) stwierdzono, że w każdym wypadku suma parametrów β_1 i γ_1 była mniejsza od jeden, co oznacza, że proces ε_t generowany przez GARCH(1,1) jest kowariancyjnie stacjonarny. W takiej sytuacji wariancja procesu ε_t jest równa (Doman, Doman, 2009, s. 83):

$$E(\varepsilon_t^2) = \frac{\alpha}{1 - \beta_1 - \gamma_1} \quad (6)$$

Posługując się tą formułą, obliczono wariancje procesu dla poszczególnych indeksów w okresie od 1 kwietnia 2009 do 30 kwietnia 2018 roku, a następnie przedstawiono je wraz z przeliczonymi odchyleniami standardowymi w ujęciu rocznym w tabeli 4. Zdecydowanie najwyższy poziom zmienności cechuje stopy zwrotu indeksów chińskiego SSE i rosyjskiego RTS, najniższą zmienność natomiast wykazały indeksy FTSE250, TSX i DJIA (zob. tab. 4).

Tabela 2

Wyniki oszacowania parametrów modeli dla okresu 1.04.2009 – 30.04.2018 r. (1)

Parametry	Oceny parametrów	Błędy standardowe	Poziomy t	Poziomy p
1	2	3	4	5
Parametry modelu dla indeksu DJIA				
a_t	-0,03167	0,02115	-1,498	0,134
$\sqrt{a}$	0,35789	0,0351	–	–
β_t	0,15021	0,02514	5,975	0,000
γ_t	0,83521	0,02383	35,049	0,000
$\sqrt{DF}$	2,32812	0,1332	–	–
Parametry modelu dla indeksu NASDAQ				
a_t	-0,00646	0,02058	-0,314	0,754
$\sqrt{a}$	0,48767	0,0537	–	–
β_t	0,10503	0,01925	5,456	0,000
γ_t	0,87302	0,02259	38,646	0,000
$\sqrt{DF}$	2,43502	0,1487	–	–
Parametry modelu dla indeksu TSX				
a_t	0,05217	0,02055	2,538	0,011
$\sqrt{a}$	0,27307	0,0397	–	–
β_t	0,08462	0,01581	5,352	0,000
γ_t	0,90659	0,01726	52,526	0,000
$\sqrt{DF}$	3,07698	0,2705	–	–
Parametry modelu dla indeksu CAC40				
a_t	-0,0148	0,02057	-0,72	0,472
$\sqrt{a}$	0,45637	0,0724	–	–
β_t	0,10462	0,01883	5,556	0,000
γ_t	0,88689	0,01957	45,319	0,000
$\sqrt{DF}$	2,51354	0,1593	–	–
Parametry modelu dla indeksu FTSE250				
a_t	0,07912	0,02168	3,649	0,000
$\sqrt{a}$	0,40698	0,042	–	–
β_t	0,11137	0,01929	5,774	0,000
γ_t	0,86401	0,0236	36,611	0,000
$\sqrt{DF}$	2,94333	0,2404	–	–

1	2	3	4	5
Parametry modelu dla indeksu DAX				
a_t	0,0168	0,01999	0,84	0,401
$\sqrt{\alpha}$	0,44553	0,0764	–	–
β_t	0,08969	0,0143	6,272	0,000
γ_t	0,90237	0,0151	59,76	0,000
$\sqrt{DF}$	2,5401	0,1846	–	–
Parametry modelu dla indeksu RTS				
a_t	0,06732	0,01983	3,395	0,001
$\sqrt{\alpha}$	0,65524	0,0967	–	–
β_t	0,05076	0,00881	5,762	0,000
γ_t	0,94158	0,00859	109,613	0,000
$\sqrt{DF}$	2,44468	0,169	–	–
Parametry modelu dla indeksu WIG20				
a_t	0,01933	0,02044	0,946	0,344
$\sqrt{\alpha}$	0,63826	0,0577	–	–
β_t	0,06006	0,0105	5,72	0,000
γ_t	0,91514	0,01429	64,041	0,000
$\sqrt{DF}$	2,67678	0,1938	–	–

$\sqrt{DF}$ – oznacza pierwiastek oszacowanej liczby stopni swobody (*degree of freedom*) dla rozkładu *t*-Studenta.

Źródło: obliczenia własne za pomocą programu Time Series Modelling 4,31.

Tabela 3

Wyniki oszacowania parametrów modeli dla okresu 1.04.2009 – 30.04.2018 r. (2)

Parametry	Oceny parametrów	Błędy standardowe	Poziomy t	Poziomy p
1	2	3	4	5
Parametry modelu dla indeksu Nikkei225				
a_t	–0,01967	0,02132	–0,923	0,356
$\sqrt{\alpha}$	0,65055	0,0787	–	–
β_t	0,11095	0,02451	4,527	0,000
γ_t	0,86077	0,03086	27,893	0,000
$\sqrt{DF}$	2,58325	0,1919	–	–
Parametry modelu dla indeksu SSE				
a_t	0,01896	0,0187	1,014	0,311
$\sqrt{\alpha}$	0,37504	0,0729	–	–
β_t	0,05815	0,00966	6,045	0,000
γ_t	0,94144	0,00888	106,044	0,000
$\sqrt{DF}$	2,13573	0,1048	–	–

1	2	3	4	5
Parametry modelu dla indeksu Hang Seng				
a_i	0,02403	0,01952	1,231	0,218
$\sqrt{\alpha}$	0,53669	0,0711	–	–
β_i	0,05885	0,00965	6,098	0,000
γ_i	0,92554	0,01229	75,308	0,000
$\sqrt{DF}$	2,7426	0,2206	–	–
Parametry modelu dla indeksu SENSEX				
a_i	0,07545	0,01968	3,834	0,000
$\sqrt{\alpha}$	0,44127	0,0621	–	–
β_i	0,0487	0,00866	5,624	0,000
γ_i	0,93905	0,0106	88,59	0,000
$\sqrt{DF}$	2,69851	0,2164	–	–
Parametry modelu dla indeksu All Ordinaries				
a_i	0,01622	0,0212	0,765	0,444
$\sqrt{\alpha}$	0,33075	0,051	–	–
β_i	0,07063	0,0147	4,805	0,000
γ_i	0,91832	0,01697	54,114	0,000
$\sqrt{DF}$	3,29986	0,3347	–	–
Parametry modelu dla indeksu Bovespa				
a_i	–0,00713	0,02067	–0,345	0,730
$\sqrt{\alpha}$	0,86014	0,074	–	–
β_i	0,05785	0,01165	4,966	0,000
γ_i	0,90822	0,01771	51,283	0,000
$\sqrt{DF}$	3,15222	0,3556	–	–
Parametry modelu dla indeksu IPC				
a_i	0,0476	0,02134	2,231	0,026
$\sqrt{\alpha}$	0,40768	0,0511	–	–
β_i	0,06392	0,01314	4,865	0,000
γ_i	0,92004	0,0153	60,133	0,000
$\sqrt{DF}$	2,74953	0,1978	–	–

$\sqrt{DF}$ – oznacza pierwiastek oszacowanej liczby stopni swobody (*degree of freedom*) dla rozkładu *t*-Studenta.

Źródło: obliczenia własne za pomocą programu Time Series Modelling 4.31.

Tabela 4

Wyniki oszacowania wariancji (odchylenia standardowego) procesu ε_t dla okresu 1.04.2009 – 30.04.2018 r.

Indeks	$\alpha^{0,5}$	β_t	γ_t	Wariancja procesu	Odchylenie standardowe procesu w ujęciu rocznym
DJIA	0,35789	0,15021	0,83521	8,78500	46,86416
NASDAQ	0,48767	0,10503	0,87302	10,83472	52,04497
TSX	0,27307	0,08462	0,90659	8,48319	46,05211
CAC40	0,45637	0,10462	0,88689	24,53163	78,31289
FTSE250	0,40698	0,11137	0,86401	6,72757	41,01088
DAX	0,44553	0,08969	0,90237	24,99962	79,05634
RTS	0,65524	0,05076	0,94158	56,04954	118,37392
WIG20	0,63826	0,06006	0,91514	16,42644	64,08285
Nikkei225	0,65055	0,11095	0,86077	14,96518	61,16613
SSE	0,37504	0,05815	0,94144	343,06098	292,85704
Hang Seng	0,53669	0,05885	0,92554	18,45203	67,91912
SENSEX	0,44127	0,0487	0,93905	15,89545	63,03857
All Ordinaries	0,33075	0,07063	0,91832	9,90005	49,74950
Bovespa	0,86014	0,05785	0,90822	21,80492	73,83244
IPC	0,40768	0,06392	0,92004	10,36178	50,89642

Źródło: obliczenia własne.

5. Porównanie oczekiwanych stóp zwrotu i ryzyka wybranych indeksów

W dalszej kolejności, na podstawie oszacowanych za pomocą modelu GARCH odchyłeń standardowych w ujęciu rocznym oraz średnich arytmetycznych stóp zwrotu, obliczono współczynniki zmienności w postaci ilorazu odchylenia standardowego i średniej, stanowiące względną miarę zmienności (zob. tab. 5).

W tabeli 5 przedstawiono wyniki obliczeń w skali roku, natomiast na rysunku 3 zaprezentowano poszczególne indeksy – na osi Y podano oczekiwaną stopę zwrotu (średnią) indeksu, a na osi X miarę ryzyka (odchylenie standardowe). Na podstawie danych zebranych w tabeli można stwierdzić, że największe ryzyko na jednostkę stopy zwrotu występuje w przypadku indeksów: chińskiego SSE i rosyjskiego RTS, a także polskiego WIG20, francuskiego CAC i australijskiego All Ordinaries. Najmniejsze ryzyko natomiast dotyczy: amerykańskiego NASDAQ, brytyjskiego FTSE250, amerykańskiego DJIA, indyjskiego SENSEX oraz japońskiego Nikkei225.


Tabela 5

Podstawowe statystyki kształtowania się stóp zmian indeksów giełdowych w okresie 1.04.2009 r. – 30.04.2018 r. (w skali roku)

Indeksy	Średnia (%)	Odchylenie Standardowe (%)	Współczynnik Zmienności (%)
Dow Jones	13,46	46,86	348,16
Nasdaq	18,07	52,04	288,06
TSX	7,03	46,05	655,54
CAC	9,24	78,31	847,69
FTSE250	13,55	41,01	302,71
DAX	14,10	79,06	560,64
RTS	10,17	118,37	1163,67
WIG20	6,48	64,08	988,85
Nikkei225	13,46	61,17	454,41
SSE	5,35	292,86	5473,26
Hang Seng	11,07	67,92	613,59
SENSEX	15,73	63,04	400,75
All Ordinaries	6,92	49,75	719,22
Bovespa	10,65	73,83	693,43
IPC	10,87	50,90	468,11

Źródło: obliczenia własne.

Na podstawie rysunku 3 można ocenić, które z indeksów okazały się najlepszą inwestycją dla inwestorów działających na poszczególnych rynkach pod względem oczekiwanej stopy zwrotu i ryzyka. Oczywiście chodzi o inwestorów inwestujących na tych rynkach w poszczególnych krajach, a nie inwestorów zagranicznych, w przypadku których ważną składową wyniku inwestycji jest także kształtowanie się kursów walutowych. Na rysunku tym pominięto indeks SSE jako przypadek zdecydowanie odstający – o najniższej oczekiwanej stopie zwrotu i najwyższym poziomie ryzyka. Dzięki temu rysunek stał się bardziej przejrzysty.



Rysunek 3. Kształtowanie się oczekiwanej stopy zwrotu i ryzyka indeksów giełdowych

Źródło: opracowanie własne na podstawie danych Serwisu Informacyjnego Stooq, www.stooq.pl (9.05.2018).

Uwagi końcowe

Na podstawie przeprowadzonych badań można stwierdzić, że zdecydowanie najwyższą oczekiwaną stopą zwrotu i jednocześnie stosunkowo niskim ryzykiem charakteryzuje się indeks NASDAQ. W porównaniu do indeksów SENSEX, DAX, Nikkei225, Hang Seng, Bovespa, RTS, CAC, WIG20 i SSE ma on znacząco wyższą oczekiwaną stopę zwrotu, a ryzyko na niższym poziomie. Na uwagę zasługuje także indeks FTSE250, który wykazuje najniższy poziom ryzyka, a pod względem oczekiwanej stopy zwrotu przewyższają go tylko indeksy NASDAQ, SENSEX i DAX. Z drugiej strony, pomijając wspomniany już indeks SSE, zwraca uwagę indeks RTS o wysokim ryzyku i stosunkowo niskiej oczekiwanej stopie zwrotu oraz indeks WIG20 o niskiej oczekiwanej stopie i stosunkowo wysokim ryzyku. Niską oczekiwaną stopę zwrotu wykazują także indeksy All Ordinaries i TSX, chociaż ich ryzyko jest nieco niższe.

Kształtowanie się światowych indeksów giełdowych w badanym okresie było zatem różnicowane, a istotnym czynnikiem różnicującym było zapewne to, w jaki sposób poszczególne kraje radziły sobie z kryzysem finansowym i w jakim stopniu go odczuwały. Poza tym można wskazać wiele innych czynników różnicujących poszczególne kraje i mających

istotny wpływ na sytuację na rynku papierów wartościowych (zob. np. Wojtyna, 2009, s. 46, 58, 68; Nawrot, 2009, s. 18–19).

Uzyskane w ten sposób wyniki mogą być wykorzystane przez inwestorów lokujących środki finansowe zwłaszcza w funduszach indeksowych, których zadaniem jest odwzorowywanie wyników określonych indeksów, a także przez podmioty oferujące tego typu produkty finansowe. Mogą również być inspiracją do dalszych badań w kierunku uwzględnienia kursów walutowych oraz zastosowania podejścia portfelowego z punktu widzenia inwestorów międzynarodowych.

Pomimo stwierdzonych różnic należy podkreślić, że kształtowanie się analizowanych indeksów w długim okresie było w większości bardzo podobne. Na początku 2009 roku na wszystkich indeksach nastąpiło odbicie po kryzysowych spadkach, a następnie, z nielicznymi wyjątkami, miała miejsce długotrwała hossa. Takie podobne kształtowanie się większości indeksów wynika z procesów globalizacji gospodarczej i integracji rynków finansowych. Wzajemne powiązania gospodarek i szybki proces przepływu informacji powodują, że w prognozach rynkowych są uwzględniane nawet pojedyncze i odległe zdarzenia o charakterze gospodarczym.

Należy także zaznaczyć, że uzyskane wyniki mogą być obarczone błędem wynikającym z przyjętego okresu badawczego, jak również z zastosowanych narzędzi, np. przyjętego modelu zmienności. W omawianym okresie można stwierdzić ogólną tendencję wzrostową, która w każdej chwili może się odwrócić. Warto zauważyć, że obserwacje z ostatniego roku w kilku przypadkach mogą wskazywać na początek odwrócenia tego długookresowego trendu i rozpoczęcie bessy. W dodatku niektórzy autorzy ostrzegają, że w najbliższych latach może wystąpić kolejna fala kryzysu, związana z nierozwiązanymi nadal problemami, które stały się źródłem ostatniego kryzysu. W takim wypadku należałoby oczekiwać radykalnego obniżenia stóp zwrotu, a także wzrostu ich zmienności.

Literatura

- Akgiray, V. (1989). Conditional Heteroscedasticity in Time Series of Stock Returns: Evidence and Forecasts. *Journal of Business*, 62, 55–80.
- Bauwens, L., Hafner, Ch.M., Laurent, S. (2012). *Handbook of Volatility Models and Their Applications*. Hoboken: J. Wiley & Sons.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroscedasticity. *Journal of Econometrics*, 31, 307–327.
- Cumby, R., Figlewski, S., Hasbrouck, J. (1993). Forecasting Volatilities and Correlations with EGARCH Models. *Journal of Derivatives*, 1, 51–63.
- Doman, M., Doman, R. (2009). *Modelowanie zmienności i ryzyka. Metody ekonometrii finansowej*. Kraków: Wolters Kluwer.
- Engle, R. (2001). GARCH 101: The Use of ARCH/GARCH Models in Applied Econometrics. *The Journal of Economic Perspectives*, 4 (15), 157–168.
- Engle, R.F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of Variance of UK Inflation. *Econometrica*, 50, 987–1007.

- Erginbay, U., Eleftherios, T., Yusuf, M. (2014). Modeling Volatility in the Stock Markets using GARCH Models: European Emerging Economies and Turkey. *International Journal in Economics and Business Administration*, 2 (3), 72–87.
- Farhan, A., Samia, M.U., Raza, A. (2017). Modelling Stock Indexes Volatility of Emerging Markets. Pobrano z: <https://www.researchgate.net/publication/319954309>.
- Figlewski, S. (1997). *Forecasting Volatility*. Oxford, UK: Blackwell.
- Fiszeder, P. (2009). *Modele klasy GARCH w empirycznych badaniach finansowych*. Toruń: Wydawnictwo Naukowe Uniwersytetu Mikołaja Kopernika.
- Fiszeder, P., Orzeszko, W. (2012). Nonparametric Verification of GARCH-Class Models for Selected Polish Exchange Rates and Stock Indices. *Czech Journal of Economics and Finance*, 5 (62), 430–449.
- Hassan, S.A. (2017). A Time Series Analysis of Major Indexes Using GARCH Model with Regime Shifts. *International Journal of Financial Research*, 4 (8), 127–133.
- Heynen, R.C., Kat, H.M. (1994). Volatility Prediction: a Comparison of Stochastic Volatility, GARCH(1,1) and EGARCH(1,1) Models. *Journal of Derivatives*, 2 (2), 50–65.
- Nawrot, W. (2009). *Globalny kryzys finansowy XXI wieku. Przyczyny, przebieg, skutki, prognozy*. Warszawa: CeDeWu.
- Ng, H.G., McAleer, M.J. (2004). Recursive Modelling of Symmetric and Asymmetric Volatility in the Presence of Extreme Observations. *International Journal of Forecasting*, 1 (20), 115–129.
- Osiewalski, J., Pajor, A., Pipień, M. (2004). Bayesowskie modelowanie i prognozowanie indeksu WIG z wykorzystaniem procesów GARCH i SV. W: A. Zeliaś (red.), *XX Seminarium Ekonometryczne im. Prof. Zbigniewa Pawłowskiego* (s. 17–39). Kraków: Akademia Ekonomiczna w Krakowie.
- Osińska, M. (2006). *Ekonometria finansowa*. Warszawa: PWE.
- Pagan, A.R., Schwert, G.W. (1990). Alternative Models for Conditional Stock Volatility. *Journal of Econometrics*, 45, 267–290.
- Stawicki, J. (2004). *Wykorzystanie łańcuchów Markowa w analizie rynku kapitałowego*. Toruń: Uniwersytet Mikołaja Kopernika.
- Taylor, S.J. (1986). *Modelling Financial Time Series*. Chichester: Wiley.
- Węgrzyn, R. (2010). The Global Financial Crisis versus the Shaping of Stock Market Indices. W: R. Borowiecki, T. Rojek (red.), *Challenges for the Contemporary Enterprise under Globalization* (s. 23–32). Cracow: Cracow University of Economics.
- Węgrzyn, R. (2013). Zastosowanie wybranych modeli zmienności w analizie ryzyka cen akcji. *Zeszyty Naukowe Uniwersytetu Szczecińskiego*, 760. *Finanse, Rynki Finansowe, Ubezpieczenia*, 60, 551–562.
- Wojtyna, A. (red.) (2009). *Dostosowania makroekonomiczne i mikroekonomiczne w krajach na średnim poziomie rozwoju po kryzysach finansowych*. Warszawa: PWE.

COMPARATIVE ANALYSIS OF THE SHAPING OF SHARE INDEXES IN THE WORLD AFTER THE FINANCIAL CRISIS

Abstract: Purpose – After the bear market associated with the recent financial crisis, it was possible to observe the reversal of trends and the beginning of the long-term bull market in the first months of 2009. The purpose of the article is to conduct and present a comparative analysis of the rates of return and risk (volatility of the rates of return) of the selected stock exchange indices in this post-crisis period, in particular to indicate differences in share indices from different geographic regions and countries.

Design/methodology/approach – The stock indexes have been analyzed in terms of long-term changes, basic statistics of the rates of return and differences in their volatility using GARCH models. In the final part, the expected rates of return and the risk of indices were compared. A total of 15 indexes were analyzed in detail.

Findings – On the basis of the conducted analysis, the assessment of selected stock exchange indices was made and the differences in their rates of return and risk were noted.

Originality/value – The research results give the opportunity to look more broadly at the diverse situation of the capital market after the financial crisis and can be used by investors investing financial resources, for example, in index funds.

Keywords: stock market index, volatility, GARCH model

Cytowanie

Węgrzyn, R. (2018). Analiza porównawcza kształtowania się indeksów akcji na świecie po kryzysie finansowym. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 125–141. DOI: 10.18276/frfu.2018.94/2-10.

Efekt barometru stycznia w funduszach inwestycyjnych akcji jako przykład anomalii sezonowych na rynkach kapitałowych

Ilona Żelazowska*

Streszczenie: *Cel* – Celem artykułu było przyjęcie lub odrzucenie hipotezy o występowaniu efektu barometru stycznia na podstawie stóp zwrotu z badanych funduszy inwestycyjnych w latach 2003–2017.

Metodologia badania – W badaniu wykorzystano miesięczne stopy zwrotu funduszy inwestycyjnych. Wyznaczono skumulowane stopy zwrotu, wykorzystano również model regresji liniowej, a badania poddano testowi dla dwóch wariancji bez powtórzeń.

Wynik – Różnice w stopach zwrotu wykazały występowanie barometru stycznia w 10 na 15 badanych przypadków. Wyniki są jednak nieistotne statystycznie, a model regresji liniowej jest słabo dopasowany do rzeczywistości, co może wskazywać na małą przydatność modelu do budowania skutecznych strategii inwestycyjnych opartych na barometrze stycznia.

Oryginalność/wartość – Badanie przeprowadzono na podstawie stóp zwrotu z funduszy inwestycyjnych. Wcześniejsze badania przeprowadzane w Polsce nie wskazywały jednoznacznych wyników i dotyczyły głównie indeksów giełdowych, pojedynczych spółek i surowców.

Słowa kluczowe: anomalie sezonowe, barometr stycznia, efekt stycznia, hipoteza efektywności rynku

Wprowadzenie

Efektywność rynku może być rozpatrywana w ujęciu transakcyjnym, alokacyjnym i informacyjnym. W sensie transakcyjnym charakteryzuje się niskimi kosztami transakcyjnymi, dzięki wysokiej konkurencji na rynku finansowym. Efektywność alokacyjna przejawia się przepływami kapitału od kapitałodawców do przedsięwzięć, które dadzą najwyższą możliwą stopę zwrotu. Natomiast efektywność w sensie informacyjnym zakłada, że wszystkie dostępne informacje o akcji są natychmiast odzwierciedlane w cenie tej akcji. Informacje powinny docierać do wszystkich inwestorów w tym samym czasie, a oni analizować informacje i podejmować na ich podstawie racjonalne decyzje (Fama, 1970). W publikacjach naukowych badacze od prawie pół wieku próbują z jednej strony określić, czy rynek jest efektywny w sensie informacyjnym, oraz zidentyfikować w jakiej formie (silnej, półsilnej, słabej), natomiast z drugiej strony badać anomalie, które są odstępstwami od hipotezy efek-

* Ilona Żelazowska, Uniwersytet Szczeciński, Wydział Nauk Ekonomicznych i Zarządzania, e-mail: zela-zowska_ilona@o2.pl.

tywności rynku i mogą być skutecznie wykorzystane w budowaniu strategii inwestycyjnych pozwalających na osiągnięcie ponadprzeciętnych stóp zwrotu.

W ramach badanych anomalii wyróżniono anomalie: sezonowe, fundamentalne oraz związane z nadreaktywnością i subreaktywnością. Szeroko rozpatrywaną anomalią sezonową, pierwszy raz zauważoną i nazwaną w 1942 roku, jest efekt stycznia, po raz pierwszy zbadany przez Wachtela, który zwrócił uwagę na nienaturalnie wysokie styczniowe stopy zwrotu dla indeksu Dow Jones Industrial Average (Wachtel, 1942).

Efekt stycznia charakteryzuje się szybką hossą na rynkach kapitałowych na skutek nowych, realizowanych przez inwestorów instytucjonalnych, inwestycji. Najczęściej ma to powiązanie z optymalizacją podatkową. Inwestorzy pod koniec roku decydują się na zamknięcie stratnych pozycji i tym samym obniżają swoje wykazywane zyski. Dopiero na początku stycznia akcje są ponownie odkupowane i tym samym zyskują na wartości (Reinganum, 1983).

Anomalią odwrotną do efektu stycznia jest barometr stycznia, nazywany również „innym efektem stycznia” (*other january effect*). Zakłada on, że wraz z dodatnią (ujemną) stopą w zwrotu w styczniu można przewidywać występowanie dodatniej (ujemnej) skumulowanej stopy zwrotu w pozostałych jedenastu miesiącach w roku. Oznacza to, że styczeń jest barometrem, zgodnie z którym podąża skumulowana stopa zwrotu w pozostałych miesiącach.

1. Przegląd literatury i dotychczasowych badań

Efekt barometru stycznia sprowadza się do jednej zasadniczej kwestii. Przed wszystkim charakteryzuje się tym, że dodatnia stopa zwrotu w styczniu ma być swego rodzaju „barometrem” wskazującym kształtowanie się dodatnich stóp zwrotu w pozostałych miesiącach roku, natomiast ujemna stopa zwrotu w styczniu ma wskazywać na ujemne stopy zwrotu w pozostałych miesiącach w roku. Zatem szeroko opisywany w światowej i polskiej literaturze przedmiotu efekt stycznia może być przydatny do przewidywania stóp zwrotu w pozostałej części roku. Warto jednak zauważyć, że zdaniem badaczy sprawdzalność barometru stycznia nie oznacza, że będzie on skutecznym narzędziem w podejmowaniu inwestycji (Keller, 2014).

Jednym z pierwszych badaczy, który, badając efekt stycznia, zauważył występowanie zależności charakteryzującej się stopami zwrotu od lutego do grudnia, podążającymi za styczniowymi stopami zwrotu, był Kaeppl (1990). Następnie badania zostały przeprowadzone przez Coopera, McConnella i Ovtchinnikova (2006). Autorzy sporządzili raport o sezonowości na podstawie amerykańskich stóp zwrotu akcji. Średni zwrot z 11-miesięcznego okresu od lutego do grudnia był znacznie wyższy w roku z dodatnimi stopami zwrotu ze stycznia niż w roku z ujemnymi stopami zwrotu ze stycznia. Dane obejmowały okres 1940–2006.

Bohl i Salm (2010) badali siły predykcyjne w styczniu i dla jedenastu pozostałych miesięcy w roku (od lutego do grudnia) dla stóp zwrotu w 19 różnych krajach, wnioskując, że jedynie w dwóch z 19 przebadanych krajów występuje efekt barometru stycznia, co zdaniem autorów

może świadczyć o tym, że barometr stycznia nie jest zjawiskiem międzynarodowym. Wzięto pod uwagę okresy kilkudziesięcioletnie, różne dla każdego z krajów poddanych badaniu.

Z kolei w innym artykule naukowym zaproponowano, by w celu zbadania barometru stycznia wziąć pod uwagę stopy zwrotu ze stycznia oraz skumulowane stopy zwrotu nie z jedenastu, lecz dwunastu miesięcy po okresie styczniowym (Hirsch, Hirsch, 2011). Natomiast w badanym okresie 1940–1993 Hensel i Ziembra (1995) dowiedli, że stopy zwrotu z jedenastu miesięcy od lutego do grudnia mają związek ze stopami zwrotu w styczniu, jeżeli w styczniu występuje ujemna stopa zwrotu; wówczas skumulowana stopa zwrotu z pozostałych miesięcy będzie również ujemna.

W polskich publikacjach naukowych temat barometru stycznia nie był tak szeroko omawianym zagadnieniem, jak w przypadku publikacji anglojęzycznych. W Polsce badano zazwyczaj indeksy giełdowe i surowcowe, występujące na Giełdzie Papierów Wartościowych. Jednym z pierwszych polskich badań poruszających problem barometru stycznia była praca Łona (2006). Autor oparł swoje badania na indeksach giełdowych Stanów Zjednoczonych w okresie 1988–2005 oraz wyznaczył korelację między stopami zwrotu ze stycznia a stopami zwrotu od lutego do grudnia. W badaniu wykazał, że wystąpiła silna korelacja o charakterze dodatnim. Autor badał również inne efekty sezonowe na rynkach akcji. W artykule z 2014 roku zbadał stopy zwrotu z indeksu giełdowego krajów wschodzących w latach 1995–2013, w celu przetestowania efektu stycznia i barometru stycznia na tych rynkach. W drugiej części badania skupił się na indeksach branżowych na Giełdzie Papierów Wartościowych. W badaniu dowiódł występowania barometru stycznia, zarówno dla rynków dojrzałych, rynków wschodzących, jak i w dla polskiego rynku akcji (Łon, 2014).

W swojej pracy Borowski (2018) dowodził występowania barometru stycznia i grudnia dla 50 giełd światowych i 32 cen surowców. Okres badawczy obejmował datę pierwszego notowania indeksu lub ceny surowców (na podstawie bazy danych portalu stooq.pl), a ostatnia sesja uwzględniona w tymże badaniu przypadła na koniec 2017 roku. W badaniu wykorzystano model regresji liniowej. Autor wykazał niskie wartości współczynników R^2 w przypadku analizowanych indeksów giełdowych i cen surowców w badanym okresie, co świadczy o małej przydatności zastosowania barometru stycznia w podejmowaniu decyzji inwestycyjnych.

Marianowska, Szerszyńska i Szymański (2016) przebadali miesięczne stopy zwrotu dla indeksów WIG, WIG20, mWIG40 i sWIG80. Dowiedli, że w większości z badanych lat (okres badawczy obejmował lata 1992–2016) występuje efekt barometru stycznia, który osłabił się od 2013 roku, jednak nie nadmieniono, czy uzyskane wyniki są istotne statystycznie.

Istnieją ponadto badania oparte na indeksie sWIG80, które dowiodły, że w okresie 9-letnim, przypadającym na lata 2007–2015, barometr stycznia nie wystąpił w żadnym przypadku, a korelacja dotycząca badanych miesięcy okazała się nieistotna statystycznie (Karaszkievicz, Staniec, 2017).

2. Metodologia badań empirycznych

W artykule przyjęto określone zakresy badawcze. Ze względu na zakres czasowy przyjmuje się ograniczenia, skupiając się danych z lat 2003–2017. W badaniach oparto się na miesięcznych stopach zwrotu. Badaniu poddano fundusze inwestycyjne, które w swoim portfelu miały przewagę spółek notowanych na warszawskiej Giełdzie Papierów Wartościowych i których aktywa alokowane były przede wszystkim w instrumenty finansowe o charakterze udziałowym (nie mniej niż 50%, do 100% wartości aktywów funduszu w swojej polityce inwestycyjnej). Portfele funduszy opierają się na akcjach polskich i należą do grup akcji polskich uniwersalnych oraz akcji polskich małych i średnich spółek. Do badania wybrano fundusze, które spełniały powyższe kryteria i działały nieprzerwanie co najmniej od 2003 do końca 2017 roku. Badanie objęło 13 funduszy inwestycyjnych, które spełniły założone kryteria. Celem artykułu było zweryfikowanie hipotezy o występowaniu efektu barometru stycznia na podstawie miesięcznych stóp zwrotu z badanych funduszy inwestycyjnych w latach 2003–2017.

Materiałami empirycznymi były informacje uzyskane za pośrednictwem literatury krajowej i zagranicznej oraz dane surowe pozyskane z serwisów www.analizy.pl i www.stooq.pl.

W pierwszym etapie badań wyznaczono miesięczne logarytmiczne stopy zwrotu dla badanych 13 funduszy, zgodnie ze wzorem:

$$R_t = \ln \left(\frac{P_t}{P_{t-1}} \right),$$

gdzie:

P_t – cena akcji na koniec badanego okresu,

P_{t-1} – cena akcji na początku badanego okresu.

Następnie badanie, w celu weryfikacji zjawiska, jakim jest barometr stycznia, podzielono na dwie części. W pierwszej kolejności wyznaczono nadwyżkę stóp zwrotu z funduszy inwestycyjnych nad stopą zwrotu z indeksu WIG w badanym okresie, a następnie wyznaczono skumulowaną stopę zwrotu dla stóp zwrotu ze stycznia oraz z pozostałych jedenastu miesięcy. Druga część badania objęła analizę regresji w celu określenia zależności między miesięczną stopą zwrotu w styczniu a skorelowaną stopą zwrotu z jedenastu miesięcy następujących po styczniu. Analiza regresji linowej wyrażona została następująco:

$$R_{i,t} = \alpha_i + \beta_i * d_{i,t} + \varepsilon_{i,t},$$

gdzie:

$R_{i,t}$ – skumulowana stopa zwrotu dla jedenastu miesięcy, od lutego do grudnia dla badanych funduszy,

$d_{i,t}$ – miesięczna stopa zwrotu w styczniu dla badanych funduszy,

α_p, β_p – współczynniki regresji linowej.

W celu potwierdzenia lub odrzucenia hipotezy o występowaniu efektu barometru stycznia w wybranych funduszach inwestycyjnych zastosowano test statystyczny F dla dwóch wariancji dla prób niezależnych postaci:

$$F = \frac{S_x^2}{S_y^2}.$$

Test statystyczny ma rozkład F z $v_1 = n-1$ i $v_2 = m-1$ stopniami swobody. W celu weryfikacji hipotezy o istotnej liniowej relacji między stopami zwrotu w styczniu oraz z jedenastu miesięcy następujących po styczniu, przeprowadzono analizę dwuczynnikową wariancji bez powtórzeń dla średnich miesięcznych stóp zwrotu badanych 13 funduszy.

3. Wyniki przeprowadzonych badań

W badaniu przeanalizowano miesięczne stopy zwrotu 13 funduszy inwestycyjnych w latach 2003–2017. W badanym okresie wyznaczono miesięczne stopy zwrotu, a następnie wyznaczono nadwyżkową stopę zwrotu funduszy inwestycyjnych nad indeksem WIG, po czym obliczono skumulowaną stopę zwrotu dla nadwyżkowych stóp zwrotu dla każdego z miesięcy (tab. 1).

Wyniki pokazują, że w większości badanych funduszy inwestycyjnych skumulowana stopa zwrotu w styczniu nie jest najwyższą stopą zwrotu, a jedynie w przypadku funduszu Investor Top 25 Małych Spółek, który należy do grupy akcji polskich małych i średnich spółek, styczniowa stopa zwrotu jest najwyższą stopą zwrotu we wszystkich miesiącach.

W tabeli 2 wzięto pod uwagę stopy zwrotu ze stycznia dla wszystkich badanych funduszy inwestycyjnych oraz skumulowane stopy zwrotu z pozostałych jedenastu miesięcy dla badanych funduszy. Efekt barometru stycznia wystąpił wówczas, gdy dodatnia stopa zwrotu w styczniu prognozowała dodatnią skumulowaną stopę zwrotu z pozostałych miesięcy, natomiast ujemne stopy zwrotu występujące w styczniu prognozowały ujemną skumulowaną stopę zwrotu w przypadku pozostałych miesięcy.

Zgodnie z wynikami przedstawionymi w tabeli 2 efekt barometru stycznia mógł wystąpić w badanym okresie w 60% przypadków, czyli w dziewięciu latach w badanym 15-letnim okresie. Barometr stycznia nie występował przede wszystkim w okresie bezpośrednio przed i w trakcie kryzysu gospodarczego, czyli w latach 2007–2010, ale również we wcześniejszych latach: 2003, 2005 oraz w 2014.

Tabela 1

Skumulowana miesięczna stopa zwrotu funduszy inwestycyjnych w miesiącu w badanym okresie (%)

	Styczeń	Luty	Marzec	Kwiecień	Maj	Czerwiec	Lipiec	Sierpień	Wrzesień	Październik	Listopad	Grudzień
Aviva Investors Polskich Akcji	0,38	-1,44	2,08	5,75	10,07	-4,65	-4,43	-3,52%	5,15	-3,55	12,57	-2,37
Investor Akcji Spółek Dywidendowych	-5,03	-11,69	-6,18	-10,76	8,46	-1,79	-2,73	-12,72	4,30	-10,81	13,38	-0,51
Investor Top 25 Małych Spółek	28,03	15,45	2,01	-14,47	12,26	-7,46	-28,23	-6,05	9,88	-7,60	-7,88	-9,20
Millennium Akcji	-5,31	-2,35	-3,64	-6,58	3,11	-1,61	-15,42	-4,30	0,43	-8,92	2,48	-8,18
NN Akcji	-0,30	-8,46	-6,92	0,10	0,51	-2,33	-0,21	-3,24	2,84	-1,72	5,39	-10,51
NN FIO Akcji 2 A	2,96	-4,34	-8,95	0,90	2,89	2,97	-3,07	0,96	7,94	-0,09	9,10	-6,91
Arka BZ WBK Akcji Polskich	2,99	-2,07	-3,91	1,69	0,84	-6,80	-1,30	8,23	5,13	-6,56	2,76	3,47
PZU Akcji KRAKOWIAK	-7,62	-2,72	-6,56	-10,83	2,08	-5,45	-13,74	-9,11	4,11	-5,21	0,46	-5,48
Rockbridge Akcji	-1,64	-7,82	0,71	-7,56	-1,97	-8,84	-11,64	-5,93	9,26	-1,36	1,34	-6,00
Skarbiec Akcja	-2,88	3,95	-11,37	3,53	4,32	2,57	-2,13	-7,47	8,12	-9,33	11,10	-3,63
UniKorona Akcje	-5,85	-6,78	-3,14	4,55	10,02	-0,03	-0,54	-5,67	10,78	3,59	5,56	-5,50
AEGON UFK ESALIENS Akcji	-4,43	-6,56	-2,12	1,37	13,81	3,24	-17,77	2,42	6,61	-12,38	11,65	-4,85
Novo Akcji	-0,35	-4,70	-1,83	3,59	2,71	1,63	-14,07	-11,32	5,96	-9,07	-1,49	-11,37

Źródło: opracowanie własne.


Tabela 2

Występowanie barometru stycznia dla badanych funduszy inwestycyjnych (%)

Rok	Styczeń	Pozostałe miesiące	Barometr stycznia
2003	35,52	-8,81	NIE
2004	-8,70	-8,55	TAK
2005	7,91	-135,76	NIE
2006	-40,78	-3,39	TAK
2007	-8,27	38,50	NIE
2008	-5,00	66,06	NIE
2009	7,79	-155,77	NIE
2010	-8,13	-7,34	TAK
2011	3,02	15,28	TAK
2012	-13,24	-54,72	TAK
2013	7,42	28,98	TAK
2014	9,56	-13,57	NIE
2015	12,74	33,88	TAK
2016	4,59	29,93	TAK
2017	-3,49	-72,29	TAK

Źródło: opracowanie własne.

Na rysunku 1 ukazano podążanie za stopą zwrotu ze stycznia ze stopami zwrotu w miesiącach od lutego do grudnia każdego analizowanego roku. Wyznaczono stopy zwrotu ze stycznia każdego analizowanego roku oraz średnią ze skumulowanej stopy zwrotu dla pozostałych jedenastu miesięcy.

**Rysunek 1.** Barometr stycznia dla badanych funduszy inwestycyjnych w latach 2003–2017

Źródło: opracowanie własne.

W celu sprawdzenia istotności statystycznej danych zawartych w tabeli 2, z której można wyciągnąć jednoznaczne wnioski, że w większości badanych lat wystąpił efekt barometru stycznia w odniesieniu do wybranych funduszy inwestycyjnych, przeprowadzono test F dla dwóch wariancji bez powtórzeń. Sformułowano hipotezę zerową oraz hipotezę alternatywną.

$$H_0: \sigma_1^2 = \sigma_2^2,$$

$$H_1: \sigma_1^2 > \sigma_2^2 \text{ lub } \sigma_1^2 < \sigma_2^2,$$

gdzie:

H_0 oznacza, że w badanych funduszach inwestycyjnych istnieją podstawy do potwierdzenia występowania efektu barometru stycznia na podstawie stóp zwrotu w badanym okresie.

H_1 zakłada, że w badanych funduszach inwestycyjnych nie występuje efekt barometru stycznia w badanym okresie.

Tabela 3

Wyniki i obszary krytyczne dla testu F dla dwóch wariancji

Rok	Test F
2003	0,04909
2004	0,102585
2005	0,017876
2006	0,046356
2007	0,144405
2008	0,012227
2009	0,041696
2010	0,108824
2011	0,043551
2012	0,321742
2013	0,048306
2014	0,051464
2015	0,004211
2016	0,146838
2017	0,046515

Źródło: opracowanie własne.

Wartości dla testu F przedstawiono w tabeli 3, natomiast obszar krytyczny dla każdego z testów jest obszarem jednostronnym $(0,372213; +\infty)$, obliczonym dla 12 stopni swobody i poziomu istotności 0,05.

W związku z powyższym należy dla badanych lat odrzucić hipotezę zerową na korzyść hipotezy alternatywnej, mówiącej o tym, że w badanych funduszach inwestycyjnych nie występuje efekt barometru stycznia w omawianym okresie. Otrzymane w tabeli 2 wyniki

nie zostały potwierdzone za pomocą testu statystycznego i założenie, według którego stopy zwrotu wskazywałyby na występowanie barometru stycznia, nie może zostać uznane za prawdziwe.

Drugą część badania stanowił zbudowany dla każdego z funduszy inwestycyjnych model regresji liniowej. Dane dla modelu przedstawiono w tabeli 4.

Tabela 4

Parametry regresji liniowej dla funduszy inwestycyjnych w latach 2003–2017

Rok	Alfa	Beta	R ²	DW
2003	0,0384	0,5559	0,01517	2,805355**
2004	–0,0047	0,9687	0,09626	1,259937**
2005	0,1546*	0,6934	0,00859	2,242038
2006	0,1260	1,5727	0,11466	2,813258**
2007	0,0875*	0,0168	0,00004	1,049483**
2008	0,0332	4,1901	0,21467	1,8584
2009	0,3051	–0,7403	0,02285	1,539657
2010	0,0617*	0,2365	0,00609	2,281276
2011	–0,3089*	–1,1727	0,05989	1,939381
2012	0,1027*	–0,0580	0,00108	2,265165
2013	0,0658*	3,5109*	0,59545	1,713747
2014	–0,0103	–3,1582*	0,51331	1,893412
2015	0,2452*	–1,9439	0,01591	2,065523
2016	0,0744	–1,4363	0,30291	2,081107
2017	–0,1459*	2,5859*	0,31104	1,667361

* Wyniki estymacji parametrów α i β uznane za istotne statystycznie; ** brak konkluzji na temat autokorelacji składnika losowego.

Źródło: opracowanie własne.

Modele regresji charakteryzowały się niskim współczynnikiem dopasowania do rzeczywistości. Najwyższym wskaźnikiem R² charakteryzowały się lata 2013 (0,59545) i 2014 (0,51331), w których nie zaobserwowano barometru stycznia (tab. 2). Z kolei najniższy współczynnik determinacji R² zaobserwować można w latach 2004, 2005, 2007, 2010 i 2012, gdzie – zgodnie z informacjami w tabeli 2 – badając jedynie skumulowane stopy zwrotu, można było zaobserwować potencjalnie występujący barometr stycznia (z wyjątkiem 2010 r.). Niski współczynnik determinacji świadczy o tym, że ewentualne różnice w stopach zwrotu nie będą przydatne do budowania skutecznych strategii inwestycyjnych, opartych na efekcie barometru stycznia.

Przy badaniu autokorelacji składnika losowego postawiono dwie hipotezy: H_0 : $\rho_1 = 0$, H_1 : $\rho_1 > 0$ lub $\rho_1 < 0$. Wartość statystyki DW wynosi od 1,049483 do 2,813258, natomiast wartości krytyczne statystyki DW wynoszą odpowiednio: $d_l = 1,01$; $d_g = 1,34$, co oznacza, że w roku 2005 oraz latach 2008–2017 nie wystąpiła autokorelacja składnika losowego, natomiast

w latach 2003–2004 oraz 2006–2007 nie można podjąć decyzji co do wystąpienia autokorelacji składnika losowego i należy wykorzystać wzór $\rho = \frac{|2-DW|}{2}$. Stwierdzono, że w żadnym z modeli w latach 2003–2004 i 2006–2007 nie występuje autokorelacja składnika losowego.

W odniesieniu do lat 2005, 2007, 2010–2013, 2015, 2017 warto zauważyć, że parametr α_1 jest istotny statystycznie, natomiast w przypadku lat 2013–2014 i 2017 dodatkowo istotny statystycznie jest również parametr β_1 . Oznacza to, że w powyższych przypadkach p-value < 0,05.

Uwagi końcowe

Badając jedynie skumulowane stopy zwrotu dla wybranych funduszy inwestycyjnych w okresie od 2003 do 2017 roku, można byłoby potwierdzić występowanie barometru stycznia w dziewięciu z piętnastu badanych lat. Jednak test statystyczny nie jest w stanie potwierdzić istotności statystycznej wyników.

W pojedynczych badanych funduszach, po wyznaczeniu 13 modeli regresji liniowej, zauważono, że modele były niedopasowane do rzeczywistości ze względu na niski współczynnik determinacji R^2 , co może sugerować niską przydatność zastosowania modelu w wykorzystaniu barometru stycznia do podejmowania decyzji inwestycyjnych.

Przeprowadzone badania są zbieżne z badaniami anglojęzycznymi i polskimi, które mówią o słabym dopasowaniu danych do rzeczywistości i tym samym braku możliwości wykorzystania zależności w stopach zwrotu przy podejmowaniu decyzji inwestycyjnych. Warto też zwrócić uwagę na analizę stóp zwrotu dla poszczególnych lat. Pomimo występowania zależności wskazujących, że dodatnie stopy zwrotu w styczniu przewidują dodatnią skumulowaną stopę zwrotu w pozostałych jedenastu miesiącach, natomiast ujemne stopy zwrotu w styczniu będą przewidywały ujemną skumulowaną stopę zwrotu w pozostałych jedenastu miesiącach w roku, nie można z całą pewnością stwierdzić występowania efektu barometru stycznia, gdyż nie ma on potwierdzenia w teście statystycznym. Warto zaznaczyć, że w badaniach anglojęzycznych analizie poddawane były okresy kilkudziesięcioletnie. Na tle anglojęzycznych badań przytoczonych w przeglądzie literaturowym należy zaznaczyć, że 15 lat to dość krótki okres, aby można było wysnuć jednoznaczne wnioski, dlatego badania dotyczące anomalii występujących w funduszach inwestycyjnych warto powtórzyć w kolejnych latach ich działalności, gdy możliwe będzie wzięcie pod uwagę dłuższego okresu badawczego.

Literatura

- Bohl, M., Salm, C. (2010). The Other January Effect: International Evidence. *European Journal of Finance*, 16, 173–182.
- Borowski, K. (2018). Analiza barometru stycznia i grudnia na przykładzie 50 indeksów giełd światowych i 32 cen surowców. W: J. Ostaszewski, M. Wrzesiński (red.), *Etyka, sprawiedliwość i racjonalność w dorobku nauki o finansach w latach 1918–2018* (s. 177–192). Warszawa: Oficyna Wydawnicza SGH.
- Cooper, M., McConnell, J., Ovtchinnikov, A. (2006). The Other January Effect. *Journal of Financial Economics*, 82, 315–341.

- Czerwonka, M., Gorlewski, B. (2012). *Finanse behawioralne*. Warszawa: Oficyna Wydawnicza SGH.
- Fama, E. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, 25, 383–417.
- Hensel, C., Ziemba, W. (1995). The January Barometer: Swiss, European and Global Results. *Financial Market and Portfolio Management*, 2 (9), 187–196.
- Hirsch, J., Hirsch, Y. (2011). *Stock Trader's Almanac*. Hoboken: Wiley & Sons.
- Jajuga, K., Jajuga, T. (2006). *Inwestycje, instrumenty finansowe, aktywa niefinansowe, ryzyko finansowe, inżynieria finansowa*. Warszawa: Wydawnictwo Naukowe PWN.
- Kaepfel, J. (1990). The January Barometer: Myth and Reality. *Technical Analysis of Stock and Commodities*, 8, 252–254.
- Karaszewicz, B., Staniec, I. (2017). Wpływ efektu stycznia na WIG20. *Zeszyty Naukowe. Organizacja i Zarządzanie*, 67 (1214), 87–96.
- Keller, J. (2014). Efekt stycznia na polskim rynku akcji – występowanie i cykliczność. W: P. Urbanek, E. Walińska (red.), *Ekonomia, finanse i nauki o zarządzaniu wobec wyzwań współczesnych gospodarek* (s. 103–114). Łódź: Wydawnictwo Uniwersytetu Łódzkiego.
- Łon, E. (2006). Barometr stycznia. *Gazeta Bankowa*, 8, 30–33.
- Łon, E. (2014). Efekty sezonowe na rynkach akcji. *Pieniądze i Wiedza*, 3 (64), 69–77.
- Marianowska, M., Szerszyńska, E., Szymański, M. (2016). Anomalie sezonowe na rynkach kapitałowych: efekt stycznia i barometr stycznia na Giełdzie Papierów Wartościowych w Warszawie. *Journal of Capital Market and Behavioral Finance*, 1 (3), 35–48.
- Reinganum, M.R. (1983). The Anomalous Stock Market Behavior of Small Firms in January: Empirical Tests for Tax-Loss Selling Effects. *Journal of Financial Economics*, 1 (12), 89–104.
- Stivers, C., Sun, L., Sun, Y. (2009). The Other January Effect: International, Style, and Subperiod Evidence. *Journal of Financial Markets*, 3 (12), 521–546.
- Wachtel, S. (1942). Certain Observations on Seasonal Movements in Stock Prices. *Journal of Business*, 2 (15), 184–193.

OTHER JANUARY EFFECT IN STOCK MUTUAL FUNDS AS AN EXAMPLE OF SEASONAL ANOMALIES IN THE CAPITAL MARKETS

Abstract: *Purpose* – The article presents the other January effect. The purpose of the article was to accept or reject the hypothesis about the occurrence of the other January effect, based on the rates of return from the mutual funds in 2003–2017.

Methodology/approach – The study uses the monthly rates of return of mutual funds. Accumulated rates of return have been determined. The linear regression model was also used, and the results were tested for two variances without repetition.

Findings – Differences in the rates of return have been demonstrated the presence of the other January effect in 10 out of the 15 cases studied. However, the results are statistically insignificant, and the linear regression model is poorly suited to reality, which may indicate the low usefulness of the model for building effective investment strategies based on the other January effect.

Originality/value – The study was conducted based on rates of return from mutual funds. Earlier research carried out in Poland did not indicate unequivocal results, and stock market indices and focused on individual companies and raw materials.

Keywords: seasonal anomalies, other January effect, January effect, capital market efficiency hypothesis

Cytowanie

Żelazowska, I. (2018). Efekt barometru stycznia w funduszach inwestycyjnych akcji jako przykład anomalii sezonowych na rynkach kapitałowych. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 143–153. DOI: 10.18276/frfu.2018.94/2-11.

