



Mateusz Skwarek

Czynniki behawioralne a efektywność
informacyjna rynku Bitcoina

Behavioural factors and informational efficiency of
the Bitcoin market

Praca doktorska

Promotor: dr hab. Jarosław Kubiak, prof. UEP
Promotor pomocniczy: dr Szymon Stereńczak
Pracę przyjęto dnia:

Podpis Promotora

Poznań 2026

Spis treści

| | |
|--|-----|
| Wstęp..... | 4 |
| 1. Efektywność rynku kryptowalut | 11 |
| 1.1 Teoria efektywności rynku | 11 |
| 1.2 Metody pomiaru efektywności rynku..... | 21 |
| 1.3 Charakterystyka rynku kryptowalut | 40 |
| 1.4 Przegląd dotychczasowych badań z zakresu efektywności rynku kryptowalut | 50 |
| 2. Czynniki behawioralne na rynku kryptowalut..... | 60 |
| 2.1 Rola psychologii w inwestowaniu na rynku finansowym | 60 |
| 2.2 Pomiar natężenia czynników behawioralnych | 75 |
| 2.3 Przegląd dotychczasowych badań dotyczących znaczenia czynników behawioralnych na rynku kryptowalut..... | 88 |
| 2.4 Efektywność rynku w kontekście finansów behawioralnych | 96 |
| 3. Koncepcja i metodyka badań empirycznych | 103 |
| 3.1 Hipotezy badawcze w świetle hipotezy rynku adaptacyjnego | 103 |
| 3.2 Koncepcja pomiaru dynamiki efektywności rynku Bitcoina | 113 |
| 3.3 Wybór zmiennych objaśniających i sposób ich pomiaru | 124 |
| 3.4 Dobór zmiennych kontrolnych..... | 133 |
| 4. Empiryczna analiza związku wybranych czynników behawioralnych z efektywnością rynku Bitcoina | 139 |
| 4.1 Charakterystyka próby badawczej i okres badania | 139 |
| 4.2 Dynamika efektywności rynku Bitcoina | 142 |
| 4.3 Identyfikacja czynników behawioralnych oddziałujących na dynamikę efektywności rynku Bitcoina | 146 |
| 4.4 Ocena wyników badania w odniesieniu do wymiarów błędzenia losowego | 157 |
| 4.5 Interpretacja uzyskanych rezultatów w kontekście teorii efektywności rynku oraz wyników dotychczasowych badań..... | 164 |
| Zakończenie | 170 |
| Bibliografia..... | 175 |
| Wykaz tabel | 212 |
| Spis wykresów | 213 |
| Spis schematów | 213 |
| Załączniki | 214 |

Wstęp

W dobie rosnącego dostępu do Internetu oraz powszechnego korzystania z technologii cyfrowych pojawia się ogromna ilość informacji. Przetworzenie tak dużych zasobów danych może przekraczać możliwości analityczne nawet najbardziej zaawansowanych komputerów. Z drugiej strony, wraz ze zwiększeniem ilości informacji może dojść do pogorszenia ich jakości, co dodatkowo utrudnia ich rzetelną analizę. Biorąc pod uwagę kluczowe znaczenie informacji dla funkcjonowania rynków finansowych, taka sytuacja nie pozostaje bez znaczenia dla ich efektywności. Ponadto, nadmiar wątpliwej jakości informacji utrudnia inwestorom podejmowanie decyzji, prowadząc do nieświadomego stosowania uproszczonych schematów myślenia (tzw. heurystyk). Im silniejsze emocje wywołuje treść informacji, tym większą wagę mogą jej przypisywać inwestorzy, co może skutkować wzrostem ich skłonności do nabycia bądź sprzedaży aktywów. Z ograniczoną racjonalnością uczestników rynku jest związana kwestia braku jego efektywności. Szczęólnego znaczenia nabiera to w odniesieniu do rynków aktywów, dla których trudno określić wartość fundamentalną i które cechują się wysoką zmiennością, zależną od emocji inwestorów. Przykładem takich aktywów są kryptowaluty, które na przestrzeni minionej dekady zyskały zainteresowanie wielu inwestorów jako forma alternatywnych inwestycji.

Kryptowaluty wyróżniają się na tle inwestycji tradycyjnych. W przeciwieństwie do walut czy akcji, nie mają one odgórnie określonego emitenta. Ponadto, uczestnicy tego rynku podejmują decyzje inwestycyjne w warunkach ograniczonego nadzoru organów państwowych oraz wysokiej zmienności stóp zwrotu. Takie czynniki utrudniają dokonanie rzetelnej analizy wartości kryptowalut oraz wywołują skrajnie emocje (m. in. euforię, panikę), co może skutkować podejmowaniem nieprzemyślanych decyzji inwestycyjnych. Czynniki behawioralne mogą mieć zatem duże znaczenie dla kształtowania zmian cen kryptowalut, co powinno znajdować odzwierciedlenie w zmianach poziomu efektywności rynku. Ze względu na brak jednoznacznie określonego zestawu publicznie dostępnych informacji, które powinny wpływać na ceny kryptowalut, na obecnym etapie rozwoju tego rynku najbardziej istotny jest poziom efektywności w formie słabej, czyli stopień, w jakim proces kształtowania cen odzwierciedla błądzenie losowe.

Jedno z pierwszych badań słabej formy efektywności rynku kryptowalut przeprowadził Urquhart (2016). Zauważył on, że poziom efektywności rynku Bitcoina zmienia się w czasie. Do podobnych wniosków doszli m. in. Bariviera (2017), Caporale i in. (2018) oraz Köchling i in.

(2019a), wskazując na zmienność poziomu efektywności rynku także w przypadku innych kryptowalut. To zjawisko próbowano tłumaczyć nieracjonalnym zachowaniem inwestorów (Zargar i Kumar, 2019). Jednakże, jak dotąd jedynymi analizowanymi czynnikami behawioralnym w ramach badań dotyczących efektywności rynku kryptowalut były sentyment inwestorów (Chu, Zhang i Chan, 2019) oraz niepewność inwestycyjna (Mokni i in., 2024). Wyniki tych badań nie wskazały jednoznacznie na występowanie zależności między tymi czynnikami a poziomem efektywności rynku Bitcoina.

Brak potwierdzenia związku między wskazanymi czynnikami behawioralnymi a poziomem efektywności rynku kryptowalut jest zastanawiający, biorąc pod uwagę emocje związane z postrzeganiem tych aktywów. Dotychczasowe badania potwierdziły, że inwestorzy na rynku kryptowalut podejmują decyzje inwestycyjne pod wpływem czynników behawioralnych. W szczególności wykazano, że heurystyka zakotwiczenia oraz tzw. uwaga inwestorów skierowana na inwestycję mają istotne znaczenie dla zachowania uczestników rynku Bitcoina (Kristoufek, 2013; Urquhart, 2017). Co więcej, zaobserwowano, że uwzględnienie tych czynników w modelu predykcyjnym może poprawiać skuteczność prognoz stóp zwrotu z Bitcoina (Gurdgiev i O'Loughlin, 2020; Zhu P. i in., 2021), co jest przejawem braku efektywności rynku. Można zatem oczekiwać, że czynniki behawioralne, takie jak heurystyka zakotwiczenia oraz uwaga inwestorów, oddziałują na poziom efektywności rynku kryptowalut. Nie były one jednak przedmiotem analiz w kontekście informacyjnej efektywności rynku.

Przeprowadzone do tej pory badania koncentrowały się głównie na ocenie poziomu efektywności rynku kryptowalut w kolejnych okresach (np. Bariviera (2017)). Podstawą teoretyczną tych badań była hipoteza rynku adaptacyjnego (AMH), która łączy zagadnienie efektywności rynku z elementami behawioralnymi (Lo, 2004). W myśl AMH zachowanie inwestorów jest zależne od ich przeszłych doświadczeń, co powoduje cykliczność efektywności rynku. Można zatem przypuszczać, że bieżący poziom efektywności rynku jest ujemnie skorelowany z jej poprzednim stanem. Jak dotąd nie badano jednak zmian poziomu efektywności rynku kryptowalut w stosunku do poprzedniego jej stanu, czyli jej dynamiki. Co więcej, w dotychczasowych badaniach poziom efektywności rynku wyznaczano obliczając wartość przyjętej miary błędzenia losowego w tzw. ruchomym oknie. Powodowało to, że zmieniał się zarówno początek, jak i koniec podokresów pomiaru poziomu efektywności rynku. Takie podejście nie mogło być zastosowane w przypadku niniejszej rozprawy, ponieważ podstawową miarą efektywności rynku w badaniu empirycznym był wykładnik Hursta, który

jest nominantą. Im bardziej jego wartość odbiega od 0,5 (wartość wzorcowa dla rynku efektywnego), tym poziom efektywności rynku jest niższy. Zatem, jeżeli kolejne wartości wykładnika Hursta są większe od 0,5, to ich zmiana świadczy o odwrotnym kierunku zmian poziomu efektywności rynku w stosunku do sytuacji, gdy obie jego wartości są mniejsze od 0,5. Dlatego nie można dynamiki efektywności wyznaczać jako różnicy między kolejnymi wartościami wykładnika Hursta w podokresach.

Istnieje zatem luka badawcza w zakresie pomiaru dynamiki efektywności rynku i czynników mogących wyjaśniać jej zmienność. Dotychczasowe badania nie potwierdziły występowania związku między wybranymi czynnikami behawioralnymi (sentymen inwestorów, niepewność inwestycyjna) a poziomem efektywności rynku kryptowalut. Biorąc pod uwagę charakterystykę tego rynku, można jednak oczekiwać, że zależność ta występuje.

Niniejsza rozprawa uzupełnia zatem dotychczasową wiedzę w zakresie finansów przynajmniej w trzech aspektach. W myśl AMH opracowano autorski sposób pomiaru dynamiki efektywności rynku, czyli zmiany poziomu efektywności rynku kryptowalut w stosunku do poprzedniego okresu. W odróżnieniu od wcześniejszych badań, takie ujęcie pozwala potencjalnie określić, który czynnik behawioralny odpowiada za większą poprawę bądź pogorszenie poziomu efektywności rynku. W ramach badania empirycznego zostały również uwzględnione dotąd niezbadane czynniki behawioralne, takie jak heurystyka zakotwiczenia oraz uwaga inwestorów. Ponadto, został wykorzystany inny sposób pomiaru sentymentu inwestorów niż dotychczas stosowany w badaniach poziomu efektywności rynku kryptowalut.

Jako reprezentanta rynku wybrano Bitcoina, ponieważ jest on najstarszą i największą kryptowalutą pod względem kapitalizacji rynkowej. Nie bez znaczenia jest również fakt, że jest on najpopularniejszą kryptowalutą, co może sugerować, że oddziaływanie heurystyki dostępności na zachowanie inwestorów na rynku Bitcoina jest silniejsze niż w przypadku pozostałych kryptowalut. Ponadto, najwięcej z przeprowadzonych badań dotyczy Bitcoina, co umożliwia ocenę uzyskanych rezultatów na tle innych badań.

Celem głównym rozprawy jest ocena związku pomiędzy wybranymi czynnikami behawioralnymi a efektywnością informacyjną rynku Bitcoina. W ramach rozprawy opracowano następujące cele szczegółowe:

1. Dokonanie syntezy dotychczasowych badań dotyczących efektywności rynku kryptowalut,

2. Usystematyzowanie stanu wiedzy w zakresie oddziaływania nieracjonalnych zachowań inwestorów na rynek kryptowalut,
3. Ocena przydatności testów efektywności rynku do przeprowadzenia badania,
4. Określenie sposobów pomiaru czynników behawioralnych,
5. Pomiar poziomu efektywności rynku Bitcoina w formie słabej,
6. Ocena zależności pomiędzy heurystyką zakotwiczenia, uwagą oraz sentymentem inwestorów a dynamiką efektywności rynku Bitcoina.

Na podstawie hipotezy rynku adaptacyjnego oraz wyników innych badań zostały sformułowane następujące hipotezy:

H1: Wzrost (spadek) uwagi inwestorów skierowanej na Bitcoina jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

H2: Wzrost (spadek) natężenia sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

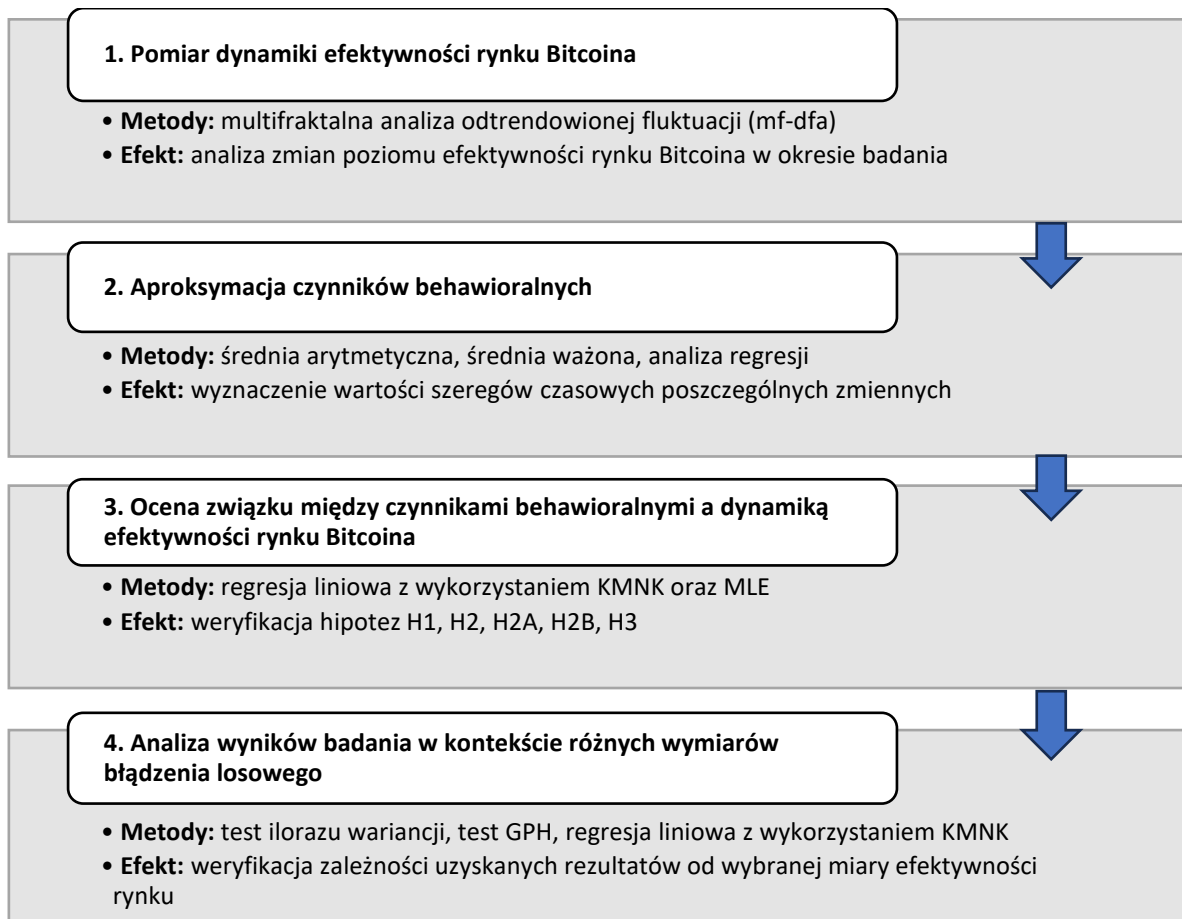
Do hipotezy drugiej postawiono dwie hipotezy szczegółowe:

H2A: Wzrost (spadek) natężenia pozytywnego sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

H2B: Wzrost (spadek) natężenia negatywnego sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

H3: Wzrost (spadek) skłonności inwestorów do ulegania heurystyce zakotwiczenia jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

Sformułowane hipotezy badawcze były weryfikowane na podstawie przeprowadzonego badania empirycznego, które składało się z kilku etapów (por. Schemat 1). W pierwszej kolejności została dokonana ocena przydatności miar efektywności rynku do przeprowadzenia badania. Następnie został opracowany autorski sposób pomiaru dynamiki efektywności rynku z wykorzystaniem najbardziej przydatnej miary, czyli wykładnika Hursta. Szereg miesięcznych zmian poziomu efektywności rynku został wyznaczony jako różnice między kolejnymi bezwzględnymi odchyleniami wykładnika Hursta od jego wartości wzorcowej. W efekcie dokonano analizy dynamiki efektywności rynku Bitcoina (etap 1).



Schemat 1. Etapy badania empirycznego

Źródło: Opracowanie własne

Drugim etapem badania było wyznaczenie wartości zmiennych objaśniających, które odnosiły się do czynników behawioralnych. Uwaga inwestorów była aproksymowana za pomocą indeksów wyszukiwań słowa „Bitcoin” w Google. Zostały wykorzystane dwa sposoby pomiaru uwagi inwestorów: indeks wyszukiwań pobrany dla całego okresu badania oraz tzw. ważony indeks GSV, który był wyznaczany jako średnia z dziennych wartości indeksu przemnożonych przez wagę danego miesiąca w całym okresie badania. W celu oszacowania natężenia pozytywnego oraz negatywnego sentymentu inwestorów została wykorzystana analiza regresji pomiędzy stopami zwrotu z Bitcoina a zmianami wartości indeksu wolumenu wyszukiwań fraz w Google, które miały pozytywny lub negatywny wydźwięk oraz były związane z ekonomią i finansami. W tym kontekście oszacowano 127 modeli regresyjnych. Skłonność inwestorów do ulegania heurystyce zakotwiczenia była aproksymowana za pomocą odchylenia przeciętnej ceny Bitcoina w danym miesiącu od jej historycznego maksimum.

W ramach etapu trzeciego została dokonana ocena związku między wybranymi czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina. W tym kontekście zostały

wykorzystane modele autoregresyjne z rozkładem opóźnień (ADL) oraz ze średnią ruchomą (ARMA). Uzasadnieniem autoregresyjnej postaci modeli była ujemna autokorelacja zmiennej zależnej, na którą wskazuje również AMH. Modele zostały oszacowane kolejno za pomocą Klasycznej Metody Najmniejszych Kwadratów (KMNK) oraz funkcji największej wiarygodności (MLE).

Ostatnim etapem badania empirycznego było przeprowadzenie testów odporności, aby ustalić czy rezultaty badań nie są zależne od sposobu pomiaru efektywności rynku. Ponieważ wykładnik Hursta odnosi się do dwóch wymiarów błędzenia losowego jednocześnie - niezależności stóp zwrotu oraz proporcjonalnego wzrostu wariancji w czasie, w tym celu został wykorzystany estymator ilorazu wariancji oraz estymator długiej pamięci Geweke'a i Portera-Hudaka (GPH). Analiza danych niezbędnych do przeprowadzenia badania została wykonana z wykorzystaniem programów Google Colab oraz RStudio.

Struktura pracy została podporządkowana osiągnięciu jej celu. W rozdziale pierwszym została przedstawiona teoria efektywności rynku oraz alternatywne koncepcje opisujące działanie rynków finansowych, tzn. hipoteza rynku adaptacyjnego oraz rynku fraktalnego. Następnie zostały sklasyfikowane metody pomiaru różnych form efektywności rynku. Ponadto, dokonano systematyzacji miar efektywności rynku w formie słabej ze względu na wymiary błędzenia losowego, do których się odnoszą. Pozwoliło to dokonać oceny metod weryfikacji efektywności rynku i wybrać najbardziej przydatne z nich do przeprowadzenia badania. W dalszej części tego rozdziału został scharakteryzowany rynek kryptowalut, co umożliwiło wskazanie znaczenia jego cech dla informacyjnej efektywności rynku. W szczególności zostały zaprezentowane podobieństwa i różnice między rynkiem kryptowalut a rynkiem akcji. Rozdział ten kończy się przedstawieniem wyników najważniejszych badań dotyczących efektywności rynku kryptowalut, które zostały sklasyfikowane ze względu na uzyskane rezultaty, najczęściej wykorzystywane źródła danych oraz stosowane miary. W ten sposób usystematyzowano dotychczasowy stan wiedzy w zakresie badań nad zależnością między czynnikami behawioralnymi a efektywnością rynku kryptowalut.

Drugi rozdział pracy obejmuje zagadnienia związane z finansami behawioralnymi. W pierwszej kolejności zostały scharakteryzowane przykłady nieracjonalnych zachowań inwestorów na rynku finansowym oraz sposoby ich pomiaru, co pozwoliło dokonać systematyki miar czynników behawioralnych. Następnie przeprowadzony został przegląd dotychczasowych badań dotyczących oddziaływania czynników behawioralnych na decyzje

inwestycyjne uczestników rynku kryptowalut. Zostało wykazane, że znaczenie czynników behawioralnych na tym rynku zmienia się w czasie, co może mieć związek ze zmianami warunków rynkowych. Drugi rozdział pracy kończy przegląd badań weryfikujących założenia oraz implikacje hipotezy rynku adaptacyjnego, co uwypukliło istniejącą lukę badawczą w zakresie związku między czynnikami behawioralnymi a efektywnością rynku kryptowalut.

Trzeci rozdział pracy ma charakter metodyczny. W pierwszej kolejności opisano w jaki sposób w kontekście hipotezy rynku adaptacyjnego czynniki behawioralne mogą prowadzić do zmian poziomu efektywności rynku Bitcoina. Potencjalne oddziaływanie zmieniających się warunków rynkowych na dynamikę efektywności rynku zostało zilustrowane schematem, który stanowił podstawę do wyprowadzenia hipotez badawczych. Następnie został opracowany autorski sposób pomiaru dynamiki efektywności rynku z wykorzystaniem różnych miar efektywności rynku - wykładnika Hursta, statystyki testu ilorazu wariancji oraz parametru rzędu integracji ułamkowej. W dalszej części szczegółowo opisano metodykę dotyczącą pomiaru wybranych czynników behawioralnych oraz zmiennych kontrolnych. Przedstawione zostały również argumenty przemawiające za wykorzystaniem poszczególnych miar czynników behawioralnych w ramach badania.

Czwarty rozdział pracy został poświęcony przedstawieniu i omówieniu wyników badania empirycznego. W pierwszej kolejności przeprowadzona została analiza dynamiki efektywności rynku Bitcoina, co pozwoliło wskazać zdarzenia nacechowane niepewnością inwestycyjną, których wystąpienie zbiegało się z dużymi zmianami efektywności tego rynku. W dalszej kolejności zostały przedstawione wyniki estymacji modeli oddziaływania czynników behawioralnych na dynamikę efektywności rynku Bitcoina, co umożliwiło dokonanie weryfikacji postawionych hipotez badawczych. Następnie zostały zaprezentowane wyniki dalszej analizy otrzymanych rezultatów w kontekście różnych wymiarów błędzenia losowego. Zostały wykorzystane inne miary efektywności rynku niż wykładnik Hursta, które dotyczą dwóch wymiarów błędzenia losowego osobno: liniowego wzrostu wariancji w czasie oraz niezależności stóp zwrotu. Rozdział ten kończy refleksja nad uzyskanymi rezultatami poznawczymi.

Ostatnią częścią rozprawy doktorskiej jest zakończenie, w ramach którego podsumowano najważniejsze efekty przeprowadzonych badań. Zostały przedstawione wnioski, implikacje oraz ograniczenia badania. Pracę kończą rekomendacje dotyczące kierunków kontynuacji badań.

1. Efektywność rynku kryptowalut

1.1 Teoria efektywności rynku

Efektywność rynku jest wielowymiarową koncepcją związaną z funkcjonowaniem rynków finansowych. W literaturze wskazuje się przynajmniej trzy podstawowe jej wymiary, takie jak: informacyjny, alokacyjny i transakcyjny (Czekaj i in., 2001, s. 30). Efektywność alokacyjna nawiązuje do odpowiedniego transferu i wykorzystywania zasobów przez podmioty gospodarcze, którym inwestorzy powierzają środki finansowe. W takiej sytuacji kapitał otrzymują jednostki, które posiadają odpowiednie zasoby, aby wykorzystać go w sposób optymalny. Efektywność transakcyjna polega na występowaniu konkurencji pomiędzy uczestnikami rynku, która prowadzi do ustalenia kosztów transakcyjnych na niskim poziomie. W tej sytuacji transakcje mogą być szybko zawierane, ponieważ niższe koszty transakcyjne mogą skłaniać do wejścia na rynek nowych inwestorów o niewielkim kapitale oraz dotychczasowych inwestujących do zawierania większej liczby transakcji (możliwe jest nabycie większej liczby walorów za tę samą kwotę). Efektywność informacyjna oznacza, że informacja dotycząca inwestycji notowanej na danym rynku jest szybko dostępna dla wszystkich jego uczestników. Jeżeli zachowują się oni racjonalnie, to ceny walorów notowanych na takim rynku powinny odzwierciedlać wszystkie dostępne informacje. Niemniej jednak, efektywność informacyjna nie może być traktowana rozłącznie od pozostałych wymiarów efektywności, gdyż implikuje ona optymalną alokację zasobów. Ponadto, niski poziom kosztów transakcyjnych zapewnia szybkie odzwierciedlenie informacji w cenach. Zatem różne wymiary efektywności rynku przenikają się. W niniejszej rozprawie pojęcie efektywności rynku będzie odnosiło się do efektywności informacyjnej.

Współcześnie wielu autorów (m. in. Bariviera, 2017; Tiwari, Debojyoti, Jana i Roubaud, 2018; Urquhart, 2016) podejmujących tematykę efektywności rynku odwołuje się do definicji Fama (1970). Według niego rynek efektywny to taki, na którym ceny zawsze odzwierciedlają w pełni dostępne informacje. Zachowanie cen aktywa notowanego na takim rynku można opisać jako błądzenie losowe (*random walk*) wokół jego wartości wewnętrznej (*intrinsic value*) (Fama, 1965a). W takiej sytuacji oczekiwania inwestorów co do przyszłych (ponadprzeciętnych) zmian cen (r_{t+1}) w okresie „t+1” warunkowane informacjami (Φ) dotyczącymi tego waloru w momencie „t” są równe zero, co można zapisać następująco:

$$E_t[r_{t+1} | \Phi_t] = 0 \quad (1)$$

Zakładając, że informacją w okresie „t” są historyczne notowania aktywa, można dojść do wniosku, że na rynku efektywnym kolejne zmiany cen są niezależne. W efekcie, szeregi czasowe zmian cen nie mogą być wykorzystane w znaczącym stopniu do przewidywania przyszłych zmian cen (Fama, 1965a). Oznacza to, że stopień zależności między zmianami cen na rynku efektywnym jest niewystarczający, aby uzyskać ponadprzeciętne stopy zwrotu.

U podstaw teorii efektywności rynku leży kilka założeń, które Fama (1970) uważa za wystarczające dla wystąpienia efektywności rynku. Jednakże dopowiada on, że efektywność rynku może również wystąpić bez ich spełnienia. Pierwsze założenie dotyczy kosztów transakcyjnych, takich jak podatki, opłaty brokerskie, itp. Zakłada się, że nie utrudniają one obrotu na rynku. Jednakże, wystąpienie znaczących kosztów transakcyjnych nie musi oznaczać braku efektywności rynku, gdyż mogą być one już odzwierciedlone w cenach aktywa. Poza tym uwzględnienie wysokich kosztów transakcyjnych może znacząco obniżyć zyskowność strategii inwestycyjnych, które mają na celu wykorzystanie anomalii rynkowych. Drugie założenie jest następujące - wszystkie informacje dotyczące notowanego aktywa są darmowe i dostępne dla wszystkich uczestników rynku. W rzeczywistości jest to trudne do spełnienia, dlatego warunkiem efektywności rynku może być wystarczająca liczba inwestorów, którzy mają łatwy dostęp do informacji. To znaczy, osiągnięcie ponadprzeciętnego zysku z inwestycji na podstawie analizy informacji rynkowej jest utrudnione, ponieważ ceny zdążą się do niej dostosować, zanim inwestor dokona zakupu lub sprzedaży tego waloru. Ostatnie z założeń jest następujące: wszyscy uczestnicy rynku są zgodni co do znaczenia danej informacji dla bieżących cen i rozkładów (prawdopodobieństwa) przyszłych cen aktywów. To założenie można uznać za najbardziej znaczące dla efektywności rynku, ponieważ nawet jeżeli informacje są łatwo i szybko dostępne, to nieprawidłowa ocena ich znaczenia może prowadzić do nieefektywności rynku. Aczkolwiek, jak wskazuje Fama, niezgodność między inwestorami nie powinna powodować braku efektywności rynku, jeśli wystarczająca liczba uczestników rynku będzie miała „prawidłowy osąd” o wpływie informacji na cenę waloru. Zatem, jeżeli większość inwestorów przypisuje nadmierną lub niedostateczną wagę niektórym informacjom, to rynek powinien być nieefektywny. Ponadto, im większa liczba tego typu inwestorów, tym niższy powinien być poziom efektywności rynku.

Uwzględniając rodzaj informacji, którymi mogą kierować się inwestorzy w podejmowaniu decyzji o kupnie lub sprzedaży walorów, Fama (1970) wyróżnił trzy formy efektywności rynku – słabą, półsilną i silną.

Słaba (*weak*) efektywność rynku oznacza, że aktualna cena aktywa odzwierciedla historyczne notowania jego cen. Nawiązując do równania numer 1, w tym przypadku „ Φ ” oznacza zbiór informacji dotyczących historycznych notowań aktywa. Zatem, jeżeli informacje te nie ulegną zmianie, to oczekiwana przez inwestorów ponadprzeciętna stopa zwrotu jest równa zero. W konsekwencji, na rynku efektywnym w formie słabej nie jest możliwe osiągnięcie ponadprzeciętnych zysków ze strategii inwestycyjnych wykorzystujących analizę techniczną.

Półsilna (*semi-strong*) efektywność rynku oznacza, że bieżąca cena aktywa odzwierciedla wszystkie publicznie dostępne informacje (m.in. sprawozdania finansowe, raporty spółek, ogłoszenia dywidend, splitów czy emisji nowych akcji). Zatem w kontekście tej formy efektywności rynku, zbiór „ Φ ” w równaniu numer 1 zawiera historyczne notowania inwestycji i publicznie dostępne informacje na jej temat, co prowadzi do zerowych oczekiwań inwestorów co do przyszłej ponadprzeciętnej zmiany ceny waloru (jeżeli rozważany zbiór informacji niej dotyczących się nie zmieni). W efekcie strategii inwestycyjne opierające się na przeszłych notowaniach cen i publicznie dostępnych informacjach dotyczących danego aktywa są nieopłacalne. Oznacza to, że nie jest możliwe osiągnięcie ponadprzeciętnych stóp zwrotu na podstawie analizy technicznej i fundamentalnej.

Najbardziej restrykcyjną formą efektywności rynku jest jego silna (*strong*) postać. W przypadku tej formy efektywności rynku zbiór „ Φ ” w równaniu numer 1 zawiera wszystkie informacje. Innymi słowy, rynek jest efektywny w formie silnej, jeśli wszystkie informacje są dyskontowane w cenach. Termin „wszystkie informacje” zawiera historyczne notowania cen, publicznie dostępne informacje i prywatne informacje, do których dostęp mają tylko pewne grupy inwestorów¹. Zatem silna efektywność rynku uwzględnia również słabą i półsilną efektywność rynku. Natomiast półsilna efektywność rynku obejmuje również słabą jego formę.

Badania efektywności rynku można pogrupować w zależności od formy efektywności rynku – słabej, półsilnej i silnej. Pierwsze badania w tym obszarze dotyczyły przede wszystkim weryfikacji słabej formy efektywności rynku. Ich wyniki wskazywały, że na podstawie analizy korelacji i serii nie można odrzucić hipotezy o słabej efektywności rynku (m. in. Kendall i Hill

¹ Na przykład, właściciel firmy ma dostęp do informacji o planowanych inwestycjach spółki zanim zostaną one ujawnione.

(1953), Osborne (1959), Fama (1965b)). Do podobnych wniosków doszli Alexander (1961), Cootner (1962), Fama i Blume (1966), którzy nie potwierdzili zyskowności tzw. strategii filtra².

W późniejszych latach wykorzystywano coraz bardziej zróżnicowane metody weryfikacji słabej efektywności rynku, co mogło wpłynąć na uzyskane rezultaty badań. Kemp i Reid (1971) udokumentowali występowanie autokorelacji pomiędzy zmianami cen aktywów inwestycyjnych. Dodatkowo, stwierdzili oni, że wybór metody badania błędzenia losowego cen może mieć znaczenie dla konkluzji o efektywności rynku. Prace Rozeffa i Kinneya (1976), Frencha (1980), Keima (1983) oraz Reinganuma (1983) wskazały na występowanie anomalii kalendarzowych (m. in. efekt stycznia, dnia tygodnia). Natomiast, zgodnie z hipotezą rynku efektywnego, dzień tygodnia czy inne anomalie nie powinny zawierać znaczącej informacji dla inwestorów, co powoduje brak możliwości uzyskiwania na ich podstawie ponadprzeciętnych stóp zwrotu. Kolejne prace potwierdziły występowanie także innych anomalii rynkowych, m. in. efektu momentum (Jegadeesh i Titman (1993, 2001) oraz efektu odwrócenia stóp zwrotu (De Bondt i Thaler, 1985). Jednakże, wyniki dotychczasowych badań sugerują, że kierunek zależności pomiędzy stopami zwrotu z inwestycji zmienia się wraz z upływem czasu (Lo i Mackinlay, 1988; Poterba i Summer, 1988; Lehmann, 1990; Chan, Jegadeesh i Lakonishok, 1996).

Dalsze badania słabej efektywności rynku (Bessembinder i Chan, 1998; Ready, 2002) wykazały, że wykorzystanie narzędzi analizy technicznej nie zawsze pozwala na tworzenie zyskownych strategii (w kontekście pokrycia kosztów transakcyjnych). Ponadto zastosowanie testów występowania pierwiastków jednostkowych zdaje się prowadzić do różnych wniosków dotyczących słabej efektywności rynku (Chan i in., 1997; Lee i in., 2000; Worthington i Higgs, 2004). Jednakże, w późniejszych latach zauważono, że również wykorzystanie testów ilorazu wariancji prowadzi do odmiennych wniosków odnośnie efektywności rynku, co może wynikać ze zróżnicowania poziomu rozwoju badanych rynków (Borges, 2010).

Istotny nurt badań w tym obszarze dotyczy także analizy poziomu efektywności rynku³ w kolejnych okresach (m.in. Cajueiro i Tabak, 2004; Lo, 2004; Wang, Liu i Gu, 2009; Kim i in. 2011, Kian-Ping i in. 2013; Sensoy, 2013; Charfeddine i Khediri, 2016; Al-Yahyaee i in., 2018; Duan i

² Kupowanie papieru wartościowego, gdy jego cena wzrośnie powyżej założonego „progu” określonego procentowo oraz sprzedawanie go, gdy spadki jego cen przekroczą pewien ustalony procent na podstawie historycznych zmian cen.

³ Poziom efektywności rynku oznacza stopień, w jakim proces zachowania cen odzwierciedla błędzenie losowe, które jest charakterystyczne dla rynku efektywnego w formie słabej.

in., 2021). W tym kontekście wskazuje się, że poziom efektywności rynku zmienia się w czasie, co nie jest zgodne z hipotezą rynku efektywnego. Ponadto zaobserwowano, że zmiany poziomu efektywności rynku zbiegają się ze zmianami warunków rynkowych.

Dotychczas podejmowano także próby zbadania pól silnej efektywności rynku. Ball i Brown (1968), Fama, Fischer, Jensen i Roll (1969) oraz Scholes (1972) wykorzystywali analizę zdarzeń (*event studies*) jako sposób weryfikacji tej formy efektywności rynku. Doprecyzowując, dokonali oni pomiaru reakcji cen aktywów na publiczne udostępnienie informacji takich jak ogłoszenia splitów, emisji akcji oraz zysków firm. Wyniki tych badań potwierdziły wcześniejsze rezultaty pokazując, że średnio nie jest możliwe wypracowanie ponadprzeciętnych zysków na podstawie publicznie dostępnych informacji, co jest zgodne z hipotezą pól silnej efektywności rynku. Do podobnych wniosków doszli Kraus i Stoll (1972). Przedstawili oni konkluzję, że po wystąpieniu transakcji pakietowej na rynku akcji nie można uzyskać znaczących ponadprzeciętnych stóp zwrotu, chociaż zaobserwowali je przed wystąpieniem tego zdarzenia.

Kolejne badania pól silnej efektywności rynku wykazały, że istnieje zależność pomiędzy stopami zwrotu z inwestycji a publicznie dostępnymi informacjami takimi jak wskaźnik cena/wartość księgową (Fama i French, 1992), rozmiar firmy (Keim, 1983; Reinganum, 1983), zmiany w rankingu „Value Line Investment Survey” dotyczącym popularnych akcji (Stickel, 1985), zmiany wysokości dywidend (Amihud i Murgia, 1997). Ponadto Reinganum (1981) zauważył, że średnie stopy zwrotu z portfeli inwestycyjnych, które zostały utworzone na podstawie wartości wskaźnika cena/zysk lub wielkości firmy, odbiegały od ich oczekiwanych wartości określonych na podstawie modelu CAPM (*capital asset pricing model*), co może świadczyć o braku efektywności rynku w formie pól silnej. Do podobnych wniosków prowadzą wyniki późniejszych badań (m.in. Griffin i in., 2010; Hung i in., 2015; Chen, 2016; Harshita i in., 2018, Otto i in., 2020; Kellner, 2024), wskazując, że informacje dotyczące fuzji i przejęć, wypłat dywidend oraz wyników finansowych spółek giełdowych są odzwierciedlane w cenach inwestycji z opóźnieniem.

Badania silnej efektywności rynku koncentrowały się głównie na kilku obszarach. Pierwszym z nich jest analiza możliwości osiągnięcia ponadprzeciętnych wyników przez menedżerów firm inwestycyjnych. Jedno z badań w tym obszarze przeprowadzili Niederhoffer i Osborne (1966). Na podstawie analizy arkusza zleceń sformułowali oni wniosek, że na Nowojorskiej Giełdzie Papierów Wartościowych (*New York Stock Exchange*) specjaliści mogą

osiągać zyski na podstawie ich poufnego dostępu do arkusza zleceń z limitem. Na przykład, liczba złożonych zleceń pozwala oszacować szanse na kontynuację trendu cen lub jego odwrócenie i w konsekwencji wystawić odpowiednie zlecenie kupna lub sprzedaży. Do podobnych konkluzji odnośnie do braku silnej efektywności rynku można dojść na podstawie wyników analiz przeprowadzonych przez m. in. Lakonishoka i Lee (2001), Jenga i in. (2003) oraz Cohena i in. (2012). Jednakże, istnieją także badania (m. in. Jensen (1968), Sharpe (1966), Malkiel (2005)), które wykazały, że profesjonalni uczestnicy rynku nie osiągają zysków wyższych od zysków z portfela inwestycyjnego składającego się z losowo wybranych akcji czy indeksu rynkowego.

Kolejną możliwością weryfikacji silnej efektywności rynku jest analiza kształtowania się stóp zwrotu przed wystąpieniem zdarzenia rynkowego (m. in. transakcje zakupu/sprzedaży papierów wartościowych dokonane przez kluczowych decydentów spółki akcyjnej, wtórne publiczne emisje akcji). Jedno z pierwszych badań w tym kontekście przeprowadził Scholes (1972), który zauważył, że można uzyskać pozytywne ponadprzeciętne stopy zwrotu w okresie przed wystąpieniem zdarzenia, co może odnosić się do dostępu do prywatnych informacji przez „insiderów”. Dalsze badania (Jaffe, 1974) potwierdzały, że „insiderzy” posiadają informacje, które nie są odzwierciedlone w cenach rynkowych. Jaffe (1974) wskazał, że nawet po upublicznieniu tych prywatnych informacji pozostali uczestnicy rynku mogą osiągać zyski inwestując na ich podstawie przez pewien czas. Ta możliwość uzyskania dodatkowych stóp zwrotu dzięki naśladowaniu „insiderów” przez inwestorów została również zauważona później przez Rozeff i Zaman (1988). Podobne wnioski można wysnuć na podstawie prac Dismona i Marsha (1984), Eltona, Grubera i Grossmana (1986) oraz Womacka (1996), tzn. inwestując na podstawie rekomendacji dostępnych tylko dla wybranych uczestników rynku (w danym czasie) można uzyskać ponadprzeciętne stopy zwrotu, co może świadczyć o braku silnej efektywności rynku. Ponadto wyniki przeprowadzonych badań (m.in. Augustin i in., 2019; Cziraki i in., 2021; Pham i Ausloos, 2022) sugerują, że ponadprzeciętne stopy zwrotu z inwestycji można uzyskać naśladowując zachowanie „insiderów” przed ogłoszeniem wykupu akcji lub fuzji i przejęć.

Na podstawie wyników dotychczasowych badań nie można jednoznacznie stwierdzić czy rynki są efektywne. Niejednoznaczność wniosków dotyczących słabej efektywności rynku może wynikać z przyjęcia w poszczególnych badaniach odmiennych modeli losowego zachowania cen na rynku efektywnym, co determinuje wybór metod/-y weryfikacji słabej efektywności rynku (Osińska, 2006).

Jedną z pierwszych prac dotyczących losowego zachowania cen walorów notowanych na rynku została napisana przez Bacheliera (1900). Zakładał on, że oczekiwane zyski dla spekulanta powinny być równe zero, tzn. bieżące oczekiwania kupującego i sprzedającego co do przyszłych ruchów cen są zerowe⁴. Niniejsze założenie zostało rozwinięte przez Samuelsona (1965) i zastosowane do opisu modelu zachowania cen na rynku nazywanego martyngałem (*martingale*).

Na podstawie analizy kontraktów futures na rynkach towarowych, Samuelson (1965) wnioskował, że sekwencja cen jest martyngałem, jeśli bieżąca cena w czasie „t” może być najlepszym oszacowaniem dowolnej przyszłej ceny⁵. Zatem wszystkie informacje z poprzednich szeregów cen, które są przydatne do prognozowania oczekiwanej przyszłej ceny są zawarte w bieżącej cenie aktywa, co skutkuje brakiem autokorelacji szeregu czasowego.

Innym modelem zachowania cen na rynku efektywnym jest błędzenie losowe. Według Fama (1970) w ramach modelu błędzenia losowego zakłada się m. in. niezależność kolejnych zmian cen i ich jednakowy rozkład. Zatem w modelu błędzenia losowego przyjmuje się, że informacje o przeszłych stopach zwrotu (np. z okresu t-1) nie mogą być wykorzystane do oceny rozkładu przyszłych stóp zwrotu (t+1), co implikuje m. in. niezależność wariancji (w przeciwieństwie do martyngału). Podsumowując, gdy proces cen jest martyngałem zakłada się, że tylko średnia rozkładu jest „nieprognozowalna”. W ramach modelu błędzenia losowego ponadto przyjmuje się, że także wyższe momenty rozkładu są „nieprognozowalne” (Osińska, 2006, s. 32). Innymi słowy, cały rozkład bieżących stóp zwrotu powinien być niezależny od rozkładu przeszłych stóp zwrotu.

Założenie dotyczące błędzenia losowego cen na rynku efektywnym było kwestionowane przez Samuelsona (1965), który argumentował, że nie odpowiada ono wymaganiom doskonałej konkurencji. Uszczegóławiając, jeżeli na rynku istnieje podmiot, który posiada dużą część pakietu akcji, może on sprzedawać je po ustalonej cenie. Zakładając, że popyt na takim rynku jest wynikiem działań wielu niezależnych kupujących, zachowanie cen akcji może przypominać proces losowy. Jednakże, na takim rynku „monopolista” mógłby uzyskać ponadprzeciętną stopę zwrotu ustalając „nierynkową” cenę sprzedaży, co jest sprzeczne z hipotezą efektywności rynku. Dlatego Samuelson (1965) proponował, aby zachowanie cen na

⁴ Tzw. uczciwa gra (*fair game*).

⁵ Zakładając, że inwestorzy oceniają cenę bieżącą przez jej wartość oczekiwaną odnosząc ją do informacji znanej w okresie „t”.

rynku konkurencyjnym było opisywane na pomocą martyngału. Zdaniem Famy (1965b), odrzucenie modelu błędzenia losowego cen nie musi oznaczać braku efektywności rynku, gdyż wystarczy, że proces cen będzie martyngałem. Może wystąpić sytuacja, w której wnioski o efektywności rynku wyciągane na podstawie modelu martyngału będą inne od wniosków wysnutych na podstawie modelu błędzenia losowego. Zatem model błędzenia losowego jest bardziej restrykcyjnym modelem zachowania cen na rynku efektywnym od martyngału.

W latach 80. powstały prace krytykujące inne założenia dotyczące także pól silnej i silnej formy efektywności rynku. Grossman i Stiglitz (1980) kwestionowali efektywność rynku argumentując, że jeżeli rynek jest efektywny, to m. in. nie jest możliwe uzyskiwanie ponadprzeciętnych stóp zwrotu na podstawie analizy fundamentalnej. Dlatego stwierdzili, że na takim rynku informacje dotyczące wartości fundamentalnej powinny być uważane przez inwestorów za nieprzydatne. Jednakże, jak zauważyli Grossman i Stiglitz, w rzeczywistości informacje fundamentalne są kosztowne. W konsekwencji można przyjąć, że pomagają one inwestorom w podejmowaniu decyzji dotyczących kupna bądź sprzedaży aktywów. Co więcej, w tym kontekście można przypuszczać, że rynek nie jest efektywny w formie pól silnej (brak spełnionego założenia o darmowym dostępie do informacji).

Inne argumenty przedstawił Shiller (1981). Według niego ceny akcji są zbyt zmienne, aby mogły zostać wyjaśnione przez model rynku efektywnego, co powoduje, że istnieje szansa na występowanie zyskownych strategii inwestycyjnych. Uszczegóławiając, Shiller zauważył, że zmienność wartości bieżącej przyszłych przepływów z tytułu dywidend nie jest odzwierciedlona w zmienności cen akcji. W tym kontekście dywidenda jest traktowana jako nowa informacja, więc jest to sprzeczne z założeniami silnej i pól silnej formy efektywności rynku. Ostatecznie Shiller (1981) doszedł do wniosku, że rynek jest nieefektywny albo model opisujący ruch cen na rynku efektywnym jest nieodpowiedni. W późniejszych latach badanie Shillera zostało poddane krytyce przez Kumara i Makhija (1986). Pokazali oni, że osiągnięcie podobnych rezultatów do badania Shillera wymaga przyjęcia założenia o stacjonarności szeregu czasowego cen akcji. Natomiast, jak twierdzą Kumar i Makhija (1986), błędzenie losowe zakłada niestacjonarność procesu cen. Zatem założenie dotyczące stacjonarności szeregu cen jest sprzeczne z modelem błędzenia losowego. Dlatego, Kumar i Makhija (1986) nie odrzucili hipotezy rynku efektywnego (w przeciwieństwie do Shillera).

Innym założeniem, które można kwestionować, jest „prawidłowy osąd” uczestników rynku co do znaczenia danej informacji dla zmian cen na rynku efektywnym, ponieważ badania (m.

in. Shleifer (2000), Shiller (2003)) potwierdzają nieracjonalność inwestorów. Ponadto, założenie o jednakowym rozkładzie stóp zwrotu na rynku efektywnym jest trudne do spełnienia z powodu zmieniających się warunków rynkowych. To znaczy, skrajne warunki rynkowe mogą skłaniać inwestorów do podjęcia decyzji inwestycyjnych, których w zwykłych okolicznościach by nie podjęli (np. z powodu odczuwania skrajnych emocji takich jak strach, euforia). W takich sytuacjach wystąpienie nietypowych wartości stóp zwrotu może być bardziej prawdopodobne niż w normalnych okolicznościach, co prowadzi do wystąpienia tzw. grubych ogonów rozkładu (Peters, 1994).

Zatem weryfikację hipotezy rynku efektywnego można sprowadzić do testowania niezależności zmian cen w kolejnych podokresach. Być może z tego powodu badania przeprowadzone w ostatnich latach koncentrują się często na analizie zmian poziomu efektywności rynku w różnych okresach (m.in. Duan i in., 2021; Wang i in., 2021; Assaf i in., 2022; Mensi i in., 2022; Azzam i in., 2023; Dinz-Maganini i in., 2023; Akbar i in., 2024). Podstawą teoretyczną tych badań są hipotezy rynku fraktalnego (FMH) i rynku adaptacyjnego⁶ (AMH). W ramach tych hipotez zakłada się, że efektywność rynku nie jest stanem, lecz procesem dynamicznym. Powodem takiego ujęcia jest różne zachowanie inwestorów w zależności od panujących warunków rynkowych. Innymi słowy, inwestorzy zachowują się odmiennie w sytuacji występowania kryzysów finansowych, politycznych czy „baniak spekulacyjnych”. Jednakże, w hipotezach tych stan odpowiadający efektywności rynku jest różnie definiowany.

W myśl FMH inwestorów dzieli się na dwie grupy - inwestorzy o krótkim i długim horyzoncie inwestycyjnym. Jeżeli liczba inwestorów o zróżnicowanym horyzoncie inwestycyjnym jest wystarczająco duża, to rynek jest stabilny (stan odpowiadający efektywności rynku), ponieważ wtedy wzrasta poziom płynności na rynku. Ponadto zakłada się, że szereg czasowy cen aktywa inwestycyjnego notowanego na rynku ma podobną strukturę w różnych interwałach czasowych („fraktalny” charakter szeregu). Jednakże, na skutek występowania kryzysów finansowych, gospodarczych lub politycznych, stabilność rynku zostaje zaburzona, ponieważ wtedy inwestorzy zmieniają horyzont inwestycyjny z długiego na krótki. W takiej sytuacji podejmują oni decyzje inwestycyjne pod wpływem sentymentu (zamiast analizy wartości fundamentalnej inwestycji). Zatem w przypadku FMH krótki horyzont inwestycyjny większości

⁶ Hipotezę rynku adaptacyjnego szczegółowo omówiono w podrozdziale 2.4.

uczestników rynku jest głównym czynnikiem prowadzącym do niestabilności rynku (Peters, 1994).

W porównaniu do FMH, w ramach hipotezy rynku adaptacyjnego mocniej podkreśla się znaczenie czynników behawioralnych dla zmian poziomu efektywności rynku. Według Lo (2004), poziom efektywności rynku zmienia się cyklicznie, co może być związane ze zmieniającymi się warunkami rynkowymi, które powodują zmiany w strukturze uczestników rynku. Dzieje się tak, ponieważ skrajne warunki rynkowe wywołują silne emocje. Jednakże, zachowanie inwestorów w tej sytuacji może być odmienne w zależności od ich doświadczenia. Na przykład, mniej doświadczeni mogą wychodzić z rynku gdy są zrażeni wcześniej poniesioną stratą z inwestycji. Część z dotychczasowych inwestorów może jednak pozostać na rynku, ponieważ wykazują oni szybszą adaptację do zmieniających się warunków rynkowych. To znaczy, wyciągają oni wnioski z popełnionych w przeszłości błędów (np. poniesionej straty w obliczu podobnych warunków). Zatem zgodnie z AMH zmniejszenie / zwiększenie liczby poszczególnych grup inwestorów na rynku (m. in. inwestorzy detaliczni, fundusze inwestycyjne) prowadzi do obniżenia / zwiększenia poziomu efektywności rynku (Lo, 2004).

Obie przytoczone hipotezy (AMH i FMH) wskazują, że czynniki behawioralne mogą powodować zaburzenie stanu odpowiadającego efektywności rynku. Jednym z założeń hipotezy rynku fraktalnego jest występowanie różnych horyzontów inwestycyjnych uczestników rynku. W przypadku instrumentów finansowych, które charakteryzuje brak wartości fundamentalnej i powiązania z cyklem koniunkturalnym, większość inwestorów może mieć krótki horyzont inwestycyjny niezależnie od okoliczności rynkowych (Peters, 1994). Zgodnie z FMH, w takim przypadku rynek powinien być ciągle niestabilny. Zatem hipoteza rynku fraktalnego nie opisuje prawidłowo zachowania inwestorów. W ramach hipotezy rynku adaptacyjnego w tej sytuacji możliwa jest zarówno poprawa, jak i pogorszenie poziomu efektywności rynku w zależności od tego, czy uczestnicy rynku uczą się na podstawie popełnionych w przeszłości błędów. Innymi słowy, w myśl AMH zmniejszenie podatności uczestników rynku na czynniki behawioralne może powodować zwiększenie poziomu efektywności. Zatem hipoteza rynku adaptacyjnego uwzględnia większe zróżnicowanie zachowania inwestorów na rynku finansowym niż hipoteza rynku fraktalnego.

Podsumowując, przytoczone badania nad efektywnością rynku dają zróżnicowane wyniki, jednakże coraz częściej potwierdzają brak efektywności rynku. Niejednoznaczność wniosków o efektywności rynku może wynikać z przyjętego modelu zachowania cen na rynku

efektywnym, zróżnicowania rozwoju badanych rynków oraz zmieniających się warunków rynkowych. Dlatego weryfikację słabej formy efektywności rynku należy sprowadzić do analizy jej poziomu w różnych okresach, czyli stopnia, w jakim proces zachowania cen odzwierciedla błądzenie losowe.

Z przedstawionych rozważań wynika, że poziom efektywności rynku zmienia się w czasie. W myśl hipotezy rynku adaptacyjnego zachowanie inwestorów powinno zależeć od ich przeszłych doświadczeń (Lo, 2004). Biorąc pod uwagę to oraz fakt, że poziom efektywności rynku odzwierciedla zachowanie inwestorów w okresie jego pomiaru, można dojść do wniosku, że efektywność rynku w bieżącym okresie powinna zależeć od jej poziomu w poprzednim okresie. Dlatego głównym przedmiotem rozważań w niniejszej pracy będą zmiany poziomu efektywności rynku w stosunku do poprzedniego okresu, czyli dynamika efektywności rynku. Takie ujęcie pozwala spojrzeć na ten problem badawczy z innej perspektywy niż dotychczas, gdyż w ten sposób można zbadać jakie czynniki są związane ze zmianami poziomu efektywności rynku. Ponadto, badanie siły zależności między dynamiką efektywności rynku a czynnikami behawioralnymi może wskazywać, który z nich mocniej oddziałuje na większą poprawę bądź pogorszenie efektywności informacyjnej, a nie samej efektywności. Zatem takie badanie może wskazać obszar, w ramach którego instytucje mające na celu zapewnienie stabilności rynków finansowych powinny zintensyfikować swoje działania.

1.2 Metody pomiaru efektywności rynku

W badaniach efektywności rynku wykorzystuje się szeroki zakres metod, które można pogrupować ze względu na analizowaną formę efektywności rynku - metody potwierdzenia słabej, półsilnej i silnej efektywności rynku (Czekaj i in., 2001, s. 37). Najczęściej wykorzystywane metody weryfikacji słabej efektywności rynku przedstawiono w tabeli 1.

Na rynku efektywnym w formie słabej, tj. jeżeli wszystkie przeszłe informacje o cenach są uwzględnione w bieżącej cenie, zachowanie cen rynkowych powinno przypominać błądzenie losowe. Zatem w celu weryfikacji tej formy efektywności rynku można odnieść się do różnych wymiarów błędzenia losowego, takich jak jednakowy i niezależny rozkład zmian cen, niestacjonarność procesu stochastycznego, liniowy wzrost wariancji w czasie i niezależność stóp zwrotu (Campbell i in., 1997). Dlatego w tym podrozdziale testy weryfikacji słabej

efektywności rynku zostaną podzielone na grupy odpowiadające poszczególnym wymiarom błędzenia losowego.

Tabela 1. Metody weryfikacji słabej efektywności rynku

| Metoda | Przykłady zastosowania |
|---|---|
| test „sekwencji i odwrotności” | Cowles i Jones (1937), Niederhoffer i Osborne (1966) |
| test serii | Working (1934), Alexander (1961), Fama (1965b), Borges (2010), Urquhart i Hudson (2013), Brauneis i Mestel (2018) |
| test z wykorzystaniem analizy technicznej | Alexander (1961), Cootner (1962), Fama i Blume (1966), James (1968), Dale i Workman (1980), Sweeney (1988), Bessembinder i Chan (1998), Ready (2002), Todea i in. (2009) |
| test autokorelacji | Kendall i Hill (1953), Alexander (1961), Lehmann (1990), Chan i in. (1996), Ito i Sugiyama (2009), Kim i in. (2011), Kian-Ping i in. (2013), Brauneis i Mestel (2018), Kołatka (2020) |
| test ilorazu wariancji | Lo i Mackinlay (1988), Poterba i Summer (1988), Lee et al. (2000), Worthington i Higgs (2004), Kim i in. (2011), Smith (2012); Kian-Ping i in. (2013), Brauneis i Mestel (2018), Boya (2019) |
| test obecności pierwiastka jednostkowego | Chan et al. (1997), Lee et al. (2000), Worthington i Higgs (2004), Borges (2010) |
| test występowania anomalii | Rozeff i Kinney (1976), French (1980), Keim (1983), Reinganum (1983), De Bondt i Thaler (1985), Jegadeesh i Titman (1993, 2001), Urquhart i McGroarty (2014), Al-Khazali i Mirzaei (2017), Xiong i in. (2019) |
| test zależności i korelacji długookresowych | Wang, Liu i Gu (2009), Sensoy (2013), Rodriguez i in. (2014), Charfeddine i Khediri (2016), Al-Yahyaee, Mensi i Yoon (2018), Hkiri i in. (2021), Dinz-Maganini i in. (2023) |

Źródło: Opracowanie własne na podstawie Ciołek (2019), Czekaj, Woś i Żarnowski (2001) i Zielonka (2003)

Pierwszym z omawianych wymiarów błędzenia losowego jest jednakowy i niezależny rozkład zmian cen (*Identical and Independent Distribution* (IID)). Jeżeli założymy, że cena waloru notowanego na rynku podlega błędzeniu losowemu i rozkład jej zmian jest symetryczny, to wystąpienie ujemnej lub dodatniej stopy zwrotu o takiej samej bezwzględnej wartości powinno być tak samo prawdopodobne (Campbell i in., 1997, s. 34-35). Jednym ze sposobów weryfikacji tego założenia jest zastosowanie metody „sekwencji i odwrotności”, która opiera się na analizie liczby następujących po sobie zmian cen o takich samych lub przeciwnych znakach (np. po spadku ceny następuje jej wzrost). W ramach testów sekwencji i odwrotności zakłada się, że rynek efektywny charakteryzuje takie samo prawdopodobieństwo wzrostu ceny jak jej spadku po wcześniej zanotowanym spadku (wzroście) ceny (Ciołek, 2019, s. 43).

Testy sekwencji i odwrotności wykorzystywano do badania rynków finansowych już w 1937 r. (Cowles i Jones, 1937). Zdaniem Niederhoffera i Osborna (1966), wyniki uzyskane tą

metodą nie zawsze mogą być wykorzystane w praktyce. Gdy liczba zmian znaków cen jest większa niż liczba sekwencji, na rynku może pozostawać dużo niezrealizowanych zleceń z limitem ceny, tzn. zleceń kupna (po danej cenie lub niższej) i sprzedaży (po zakładanej cenie lub wyższej). Sekwencja wzrostów zazwyczaj może nastąpić wtedy, gdy kolejne zlecenia kupna zostaną dopasowane do wszystkich zleceń sprzedaży z limitem (po danej cenie lub wyższej). Co więcej, wnioski wysnute na podstawie tej metody mogą być efektem charakterystyki obrotu giełdowego. Szansa na wystąpienie zmiany znaków z dodatniego (ujemnego) na ujemny (dodatni) może być mniejsza (większa) od prawdopodobieństwa otrzymania sekwencji dodatniej (ujemnej) w związku z istnieniem ograniczeń dotyczących krótkiej sprzedaży oraz braku możliwości osiągnięcia ceny ujemnej.

Założenie o jednakowym rozkładzie zmian cen odnosi się także do testów serii, które zostały zastosowane już w 1934 r. przez H. Workinga (1934). Seria oznacza co najmniej dwie zmiany cen o jednakowym znaku. Zatem mogą nastąpić serie wzrostów cen (kolejno po sobie), spadków albo cena może pozostać niezmienną (wystąpienie tej samej ceny co najmniej dwa razy z rzędu). Test serii można wykonać poprzez analizę różnicy między liczbą lub długością serii oczekiwanych (dla rozkładu losowego) a tych osiągniętych w rzeczywistości.

Przykładem tego rodzaju metod weryfikacji efektywności rynku jest test Walda-Wolfowitza (Osińska, 2006). W ramach tego testu oblicza się liczbę następujących po sobie wzrostów i spadków cen (lub dodatnich i ujemnych stóp zwrotu). Hipoteza zerowa w tym teście brzmi następująco: rozkłady serii wzrostów i spadków cen (lub stóp zwrotu) są takie same, czyli szereg ma charakter losowy. W celu zweryfikowania tej hipotezy wykorzystuje się statystykę „Z” o standaryzowanym rozkładzie normalnym, która została zdefiniowana w następujący sposób (Osińska, 2006, s. 36-37):

$$Z = \frac{|x-E(x)|-0,5}{\sqrt{Var(x)}}, \text{ gdy } x \geq E(x), \quad (5)$$

$$Z = -\frac{|x-E(x)|-0,5}{\sqrt{Var(x)}}, \text{ gdy } x \leq E(x), \quad (6)$$

gdzie „x” oznacza liczbę serii, $E(x) = \frac{2n_1n_2}{n_1+n_2} + 1$, $Var(x) = \frac{2n_1n_2(2n_1n_2-n_1-n_2)}{(n_1+n_2)^2(n_1+n_2-1)}$, n_1 oznacza liczbę wzrostów cen (dodatnich stóp zwrotu), a n_2 to liczba spadków cen (ujemnych stóp zwrotu).

Testy serii cechują się pewnymi ograniczeniami. W przypadku wystąpienia negatywnych wydarzeń (np. wojny i kryzysu finansowego) może dojść do zmiany przekonań inwestorów

odnośnie do prawdopodobieństwa zajścia zdarzeń rzadkich, co może skutkować wzrostem zmienności stóp zwrotu. W konsekwencji może dojść do zmiany kształtu ich rozkładu. Dlatego można przypuszczać, że odnotowany nagły wzrost liczby serii (różny od oczekiwanej liczby serii) jest naturalnym stanem rynku, który nie odbiega od efektywności, ponieważ odzwierciedla zmieniające się oczekiwania inwestorów. Po drugie, testy serii nie uwzględniają rozmiarów wzrostów i spadków cen, co może powodować, że zauważone odchylenia liczby serii od ich oczekiwanych wartości będą niemożliwe do wykorzystania w praktyce przez inwestora (może być wiele długich serii, które charakteryzują drobne zmiany cen). Z drugiej strony może dojść do sytuacji, w której wyniki testu serii sugerują nielosowy charakter dużych zmian cen. Jednakże, nagły znaczący wzrost ceny aktywa może świadczyć o jej szybkim dostosowaniu się do informacji rynkowej. Zatem zastosowanie testów serii może prowadzić do błędnych wniosków o poziomie efektywności rynku. Ponadto testy te nie pozwalają na sformułowanie wniosków odnośnie do kierunku zależności występującej między zmianami cen, co utrudnia zastosowanie ich wyników w praktyce.

Kolejnym wymiarem błędzenia losowego jest niestacjonarność procesu cen (p_t) (Czekaj i in., 2001). Zakładając, że dzisiejsza cena aktywa inwestycyjnego zależy od poprzedniej ($p_t = p_{t-1} + \epsilon_t$) i pierwsza jego cena (w okresie zerowym) była równa wartości losowej ($p_0 = \epsilon_0$), można otrzymać szereg, który jest sumą kolejnych białych szumów (ϵ_t), co przedstawia poniższy wzór (Osińska, 2006, s. 62-64):

$$p_t = \sum_{i=0}^t \epsilon_{t-i}, \quad (7)$$

gdzie $\epsilon_t \sim N(0, \sigma^2)$. Z powyższego wzoru wynika, że $p_1 = p_0 + \epsilon_1 = \epsilon_0 + \epsilon_1$, $p_2 = p_1 + \epsilon_2 = \epsilon_0 + \epsilon_1 + \epsilon_2$ itd. Zatem szereg podlegający błędzeniu losowemu jest niestacjonarny (wariancja zależy od czasu), co można zapisać następująco:

$$Var(p_t) = \sum_{i=0}^t Var(\epsilon_{t-i}) = t \times \sigma^2, \quad (8)$$

gdzie $Var(p_t)$ to wariancja szeregu czasowego.

W celu weryfikacji tej cechy błędzenia losowego wykorzystuje się testy występowania pierwiastka jednostkowego. Najczęściej stosowanym z nich jest test sformułowany przez Dickeya i Fullera (test DF). Koncepcję tego testu można przedstawić w następujący sposób. Załóżmy, że badany szereg czasowy cen (p_t) opisuje model liniowy⁷ (Osińska, 2006, s.69-70):

⁷Równanie numer 9 można także rozszerzyć na inne przypadki poprzez uwzględnienie stałej, trendu wielomianowego lub składnika sezonowego (Osińska, 2006, s. 69-70).

$$p_t = a \cdot p_{t-1} + \varepsilon_t, \quad (9)$$

gdzie ε to składnik losowy. Z równania numer 9 wynika, że gdy oszacowanie parametru „ a ” przy zmiennej p_{t-1} jest równe jeden, to przyjmuje się, że badany szereg czasowy jest niestacjonarny⁸. Natomiast, wartość parametru „ a ” mniejsza od jednościi wskazuje na stacjonarność szeregu czasowego (proces zintegrowany w stopniu zerowym).

W następnej kolejności powyższe równanie przekształca się do następującej postaci (Czekaj i in., 2001):

$$\Delta p_t = \beta \cdot p_{t-1} + \varepsilon_t, \quad (10)$$

gdzie $\beta = a - 1$. Zatem, jeżeli badany szereg czasowy (p_t) jest niestacjonarny, to wartość parametru „ β ” nie odbiega istotnie od zera. W tym przypadku szereg czasowy p_t można sprowadzić do postaci stacjonarnej przez różnicowanie jego wartości (proces zintegrowany co najmniej w stopniu pierwszym). Dlatego hipoteza zerowa dla testu DF brzmi następująco: szereg czasowy zmiennej p_t jest zintegrowany przynajmniej w stopniu pierwszym. W celu weryfikacji tej hipotezy wykorzystuje się statystykę DF, którą można przedstawić w taki sposób (Osińska, 2006):

$$DF = \hat{\beta} / s(\hat{\beta}), \quad (11)$$

gdzie $s(\hat{\beta})$ to średni błąd oszacowania współczynnika β w równaniu 10. Wartość tej statystyki równa bądź niższa od wartości krytycznej odczytanej z tablic oznacza, że szereg czasowy p_t jest stacjonarny. Jeżeli wartość statystyki DF jest wyższa od wartości krytycznej, to nie odrzuca się hipotezy zerowej, tzn. szereg czasowy p_t jest niestacjonarny. Innymi słowy, zakłada się, że proces ten jest zintegrowany co najmniej w stopniu pierwszym. Dlatego w tym przypadku procedurę różnicowania szeregu czasowego należy powtórzyć.

Testy występowania pierwiastka jednostkowego nie uwzględniają nieoczekiwanych zdarzeń gospodarczych, które powodują zmianę dotychczasowego zakresu wahań ceny instrumentu finansowego. Można zatem przypuszczać, że występują wtedy zmiany w poziomie wariancji. Jeżeli wariancja jest niestała w czasie, zastosowanie tego typu testów może prowadzić do błędnych wniosków o poziomie efektywności rynku. Inną wadą niektórych testów stacjonarnościi (np. testu DF) jest brak odpornościi ich wskazań w przypadku występowania autokorelacjii składnika losowego w weryfikowanym równaniu regresjii (równanie numer 10). Jednakże, w praktyce często stosuje się również m. in. rozszerzony test

⁸ Proces, w którym wartość oczekiwana i wariancja zmieniają się w czasie.

Dickey i Fuller (ADF) lub test Phillips-Perron (PP) (Chan et al., 1997; Lee et al., 2000; Borges, 2010), które są odporne na autokorelację składnika losowego.

Z niestacjonarnością procesu stochastycznego wiąże się także inny wymiar błędzenia losowego - liniowa zależność wariancji od czasu (równanie numer 8). Ten wymiar często sprowadza się do obliczania ilorazu wariancji (m. in. Lo i Mackinlay (1988), Kim i in. (2011)). W ramach tego testu weryfikuje się czy wariancja stóp zwrotu z „k” kolejnych okresów ($x_t + \dots + x_{t-k}$) i k-krotność wariancji stóp zwrotu dla jednego okresu (x_t) są sobie równe. Test ilorazu wariancji (VR) można zaprezentować poniższym równaniem (Czekaj i in., 2001):

$$VR_k = \frac{var(x_t + x_{t-1} + x_{t-2} + \dots + x_{t-k+1})}{k \cdot var(x_t)} \quad (12)$$

Jeżeli iloraz wariancji z „k” okresów nie jest istotnie różny od 1, oznacza to błędzenie losowe. Jednakże, może dojść do nieliniowej zmiany wariancji wynikającej ze zdarzeń, których nie można było przewidzieć. Zatem, tak jak w przypadku testów serii, wnioskowanie na podstawie ilorazu wariancji w tej sytuacji może okazać się niepoprawne, np. potwierdzając nieefektywność rynku, gdy jest on w rzeczywistości efektywny. Ponadto wybór liczby badanych „k” okresów może być subiektywny i wpływać na uzyskane rezultaty. Jednakże, istnieją zmodyfikowane wersje tej miary, które pozwalają częściowo złagodzić wpływ tych wad na wyniki uzyskane za pomocą tego testu, np. automatyczny test ilorazu wariancji (Kim, 2009).

W kontekście badania słabej efektywności rynku współcześnie często odnosi się także do innego wymiaru błędzenia losowego, czyli niezależności zmian cen (m. in. Aslan i Sensoy (2020), Khuntia i Pattanayak (2020), Takaishi i Adachi (2020), Assaf i in. (2022), Mensi i in. (2022), Mokni i in. (2024)). Jednym z przejawów tego wymiaru efektywności rynku jest brak autokorelacji stóp zwrotu w żadnym z analizowanych opóźnień, co można sprowadzić do weryfikacji czy szereg cen tworzy tzw. martyngał. Według Samuelsona (1965) zachowanie cen pewnego waloru (p_t) odzwierciedla martyngał, gdy wartość oczekiwana dzisiaj (w momencie „t”) ceny waloru w następnym okresie („t+1”), pod warunkiem zaobserwowanych notowań tego aktywa z przeszłości, jest równa dzisiejszej jego cenie, co można zapisać następująco:

$$E_t[p_{t+1} | p_t, p_{t-1}, p_{t-2}, \dots] = p_t \quad (13)$$

Biorąc pod uwagę powyższą zależność można stwierdzić, że wartość oczekiwana zmiany ceny waloru jest równa zero, gdy jest ona warunkowana całą historią jego notowań. W takim przypadku spadek i wzrost ceny są tak samo prawdopodobne (Campbell i in., 1997). Zatem ten

wymiar błędzenia losowego wiąże się również z inną jego cechą - symetrią rozkładu prawdopodobieństwa zmian cen.

W celu weryfikacji hipotezy o niezależności zmian cen aktywów można wykorzystać testy autokorelacji, które były stosowane już w połowie XX wieku (np. Kendall i Hill (1953)). Testy autokorelacji często sprowadza się do obliczania współczynnika korelacji (Szyszka, 2003, s. 37). W ten sposób mierzy się zależność pomiędzy dwoma zmiennymi, np. zmianą ceny w okresie bieżącym (Δp_t) a zmianą ceny z okresu poprzedniego (Δp_{t-1}). Współczynnik korelacji można przedstawić w następującej postaci (Szyszka, 2003):

$$cor(\Delta p_t, \Delta p_{t-1}) = \frac{cov(\Delta p_t, \Delta p_{t-1})}{\sqrt{var(\Delta p_t)} \cdot \sqrt{var(\Delta p_{t-1})}}, \quad (14)$$

gdzie $cov()$ oznacza kowariancję badanych zmiennych.

W praktyce stosowane są również inne sposoby obliczania współczynnika korelacji i określania badanych zmiennych. Jednym z nich jest tzw. statystyka portfelowa Boxa-Ljunga (*Portmanteau statistics*), która pozwala na zweryfikowanie hipotezy zerowej o braku autokorelacji aż do określonego opóźnienia „z” wartości szeregu czasowego. Wzór na statystykę Boxa- Ljunga (Q) jest następujący (Osińska, 2006, s. 35-36):

$$Q = N(N + 2) \sum_{i=1}^z \frac{\rho_i^2}{N-i}, \quad (15)$$

gdzie „N” to liczba stóp zwrotu (wielkość próby badawczej), „ ρ_i ” oznacza współczynniki autokorelacji (korelacji Pearsona) między stopami zwrotu rzędu „i”.

Problemem związanym z testami autokorelacji może być subiektywny wybór opóźnienia szeregu czasowego (rzędu autokorelacji) albo odmienny sposób pomiaru zmiennych. Ponadto może wystąpić sytuacja, w której współczynnik korelacji Pearsona będzie bliski zeru, co będzie niezgodne z rzeczywistością, jeżeli badana zależność jest nieliniowa. Przyczyną tego jest fakt, że współczynnik korelacji Pearsona uwzględnia w pełni tylko liniowe zależności. Można by zastanawiać się czy w tym kontekście nie należałoby zastosować testów nieparametrycznych. Jednakże, ich wykorzystanie prowadzi do utraty części informacji o wartościach szeregu czasowego. Na przykład, w trakcie obliczania wartości współczynnika korelacji Spearmana nadaje się obserwacjom rangi zamiast uwzględniać ich wartości, przez co traci się informacje o wielkości zmian cen.

W zakresie metod weryfikacji założenia o niezależności zmian cen na rynku efektywnym wyróżnia się także testy skuteczności strategii inwestycyjnych, w ramach których wykorzystuje

się analizę techniczną⁹. To znaczy, zakłada się, że prognozy dotyczące przyszłych cen są formułowane przez inwestora na podstawie historycznych notowań i danych transakcyjnych dotyczących analizowanego rynku (Czekaj i in., 2001, s. 37-38). Wnioski o (nie)efektywności rynku wyciąga się na podstawie porównania zysków, które uzyskano przez zastosowanie danej strategii inwestycyjnej ze średnią rynkową stopą zwrotu lub ze stopą zwrotu wynikającą z zastosowania strategii pasywnej „kup i trzymaj” dla danego rynku (Ciołek, 2019, s. 45-46).

Zaletą tej grupy testów jest to, że w trakcie pomiaru zyskowności strategii inwestycyjnych nie wymaga się, żeby zmiany cen miały określony rozkład (np. rozkład normalny). Jednakże, problemami związanymi z wykorzystywaniem testów skuteczności strategii inwestycyjnych są: nieobiektywność identyfikacji formacji geometrycznych na wykresach cen oraz subiektywny dobór okresów pomiaru narzędzi analizy technicznej (np. średnie kroczące). Ponadto, zastosowanie strategii inwestycyjnej nie daje jednoznacznych wniosków o efektywności rynku. Jeżeli zastosowanie danej strategii inwestycyjnej nie prowadzi do uzyskania ponadprzeciętnych stóp zwrotu nie oznacza to, że rynek jest efektywny. Może istnieć inna strategia inwestycyjna, której nie sprawdzono do tej pory. Zatem pomiar zyskowności strategii inwestycyjnych z wykorzystaniem analizy technicznej pozwala wnioskować tylko o nieefektywności rynku i może być nieobiektywny. Ponadto, wyniki badań (Bessembinder i Chan, 1998; Ready, 2002) wskazują, że zyski ze strategii inwestycyjnych wykorzystujących analizę techniczną mogą nie zrekompensować poniesionych kosztów transakcyjnych.

Inną możliwością weryfikacji założenia dotyczącego niezależności zmian cen na rynku efektywnym są testy występowania anomalii¹⁰. Część z nich wykorzystuje testy autokorelacji do pomiaru zależności stóp zwrotu od ich poprzednich wartości np. w danym kroku czasowym (dzień tygodnia, miesiąc, okres świąt itd.). Do metod weryfikacji występowania anomalii również należą testy zyskowności strategii inwestycyjnych, które opierają się na zaobserwowanych zjawiskach (m. in. efekt momentum, efekt odwrócenia stóp zwrotu). Jednakże, wraz z upublicznieniem wiadomości o istnieniu danej anomalii, strategie inwestycyjne konstruowane na ich podstawie często przestają być opłacalne. Ponadto

⁹ Przykładami często stosowanych narzędzi analizy technicznej są m. in. reguła filtra (Alexander, 1961; Fama i Blume, 1966; Sweeney, 1988) i średnie kroczące (Cootner, 1962; James, 1968; Dale i Workman, 1980).

¹⁰ Do często weryfikowanych anomalii należą efekt momentum - kontynuacja stóp zwrotu (Jagadeesh i Titman, 1993; Jagadeesh i Titman, 2001), odwrócony efekt momentum, czyli kupowanie akcji, które osiągały najgorsze stopy zwrotu w przeszłości (De Bondt i Thaler, 1985) oraz efekty kalendarzowe np. dzień tygodnia, miesiąc (Rozeff i Kinney, 1976; French, 1980; Keim, 1983; Reinganum, 1983).

uwzględnienie kosztów transakcyjnych może znacząco obniżyć uzyskane stopy zwrotu z takich strategii inwestycyjnych (Zielonka, 2003). Zatem wyniki testów występowania anomalii prowadzą tylko do wniosków o tymczasowej (nie)efektywności rynku i mogą być niemożliwe do opłacalnego wykorzystania ich w praktyce.

Ostatnią z wymienionych grup metod weryfikacji słabej efektywności rynku są testy zależności i korelacji długookresowych¹¹. Część z nich opiera się na założeniu, że proces losowy ma postać standardowego ruchu Browna (nazywany też procesem Wienera). Niech (x_t) będzie ruchem Browna (procesem stochastycznym), który spełnia poniższe warunki (Mandelbrot i Van Ness, 1968; Campbell i in. 1997, s. 342-346):

1. Dla każdego t_1 i t_2 spełniających warunek, że $0 \leq t_1 < t_2 \leq T$ przyrosty ruchu Browna są procesem gaussowskim, co można zapisać następująco:

$x(t_2) - x(t_1) \sim N(0, t_2 - t_1)$, gdzie „t” oznacza czas mierzony z taką samą częstotliwością (np. co sekundę), więc przyrosty ruchu Browna są procesem stacjonarnym przypominającym tzw. biały szum.

2. Przyrosty cen są niezależne, np. dla każdego $0 \leq t_1 < t_2 < t_3 < t_4 \leq T$:

$x(t_4) - x(t_3)$ jest niezależne od $x(t_2) - x(t_1)$.

3. Proces x_t jest ciągły.

Jeżeli powyższe warunki są spełnione i $T > 0$, to odchylenie standardowe przyrostu ruchu Browna $(x(t+T) - x(t))$ jest równe \sqrt{T} (Mandelbrot i Van Ness, 1968). W celu pomiaru niniejszej zależności wykorzystuje się wykładnik Hursta (H). Polega to na obliczeniu zasięgu (R) przeskalowanego odchyleniem standardowym (S) badanego szeregu czasowego (np. zmian cen), czyli R/S (*rescaled range*)¹². Następnie porównuje się zależność przeskalowanego zasięgu od czasu z wartością właściwą dla procesu losowego (ruch losowy oznacza, że przeskalowany zasięg jest proporcjonalny do pierwiastka czasu, czyli $t^{0,5}$). Opisaną zależność można przedstawić w następujący sposób (Czekaj i in., 2001):

$$\frac{R}{S} = a \cdot t^H, \quad (16)$$

¹¹ Tzw. miary długiej pamięci.

¹² Współcześnie również stosuje się inne metody estymacji wykładnika Hursta, takie jak modyfikacja R/S , odtrendowana analiza fluktuacji (*detrended fluctuation analysis*, DFA) czy inna jej wersja MF-DFA (*Multifractal detrended fluctuation analysis*) (Wang, Liu i Gu, 2009; Sensoy, 2013; Charfeddine i Khediri, 2016; Al-Yahyaee, Mensi i Yoon, 2018).

gdzie S to odchylenie standardowe, $R = (\max(sd_i) - \min(sd_i))$, a sd_i oznacza średnie odchylenie od przeciętnej wartości dla i -początkowych danych szeregu czasowego, t – czas. Jeżeli wartości wykładnika Hursta kształtują się w przedziale od 0 do 1 ($0 < H < 1$), to występuje wtedy tzw. ułamkowy ruch Browna (*fractional Brownian motion*), w przypadku którego zachodzi szczególna zależność pomiędzy wariancją (Var) a upływem czasu ($t - t_0$) (Peters, 1994, s. 184):

$$Var(t - t_0) \approx |t - t_0|^{2H}, \quad (17)$$

gdzie $t \geq t_0$.

Jak stwierdzają Czekaj, Woś i Żarnowski (2001, s. 88-90), zaletą miar zależności długookresowych w porównaniu do klasycznych miar korelacji jest możliwość uwzględnienia zależności z bardzo długich okresów. Dodatkowo zauważyli oni, że wartości wykładnika Hursta mogą być zależne od długości badanego szeregu czasowego – stabilne oszacowania uzyskuje się dla szeregu czasowego, który obejmuje okres nie dłuższy niż 5 lat.

Drugim rodzajem testów korelacji i zależności długookresowych są „Modele szeregów czasowych ułamkowo zintegrowanych” (*Fractionally differenced time series models*), które zostały opracowane przez Grangera i Joyeux (1980) i Hoskinga (1981). W ramach tych modeli zakłada się, że cena aktywa inwestycyjnego (p_t) spełnia następujący warunek (Campbell i in., 1997, s. 59-61):

$$(1 - L)^d p_t = \epsilon_t, \quad (18)$$

gdzie „ ϵ_t ” ma ten sam niezależny rozkład (*identical independent distributions, iid*) i oznacza tzw. biały szum, „ L ” to operator opóźnienia (np. $Lp_t = p_{t-1}$), a parametr „ d ” określa rząd integracji szeregu czasowego. Jeżeli we wzorze numer 18 za parametr „ d ” zostanie podstawiona liczba jeden, to szereg czasowy cen przyjmuje postać błędzenia przypadkowego, co można zapisać następująco (Osińska, s. 60-62):

$$\Delta p_t = \epsilon_t. \quad (19)$$

Zdaniem Petersa (1994, s. 170) w takim przypadku proces stochastyczny „ p_t ” ma charakter brązowego szumu (*brown motion*), czyli jest sumą białych szumów (równanie numer 7). Zatem odnosi się to także do innego wymiaru błędzenia losowego – niestacjonarności procesu stochastycznego. W literaturze wskazuje się również, że błędzenie losowe występuje, gdy parametr „ d ” jest równy zero (m. in. Peters (1994), Weron (2002), Zhou i in. (2021)). W takim przypadku wzór numer 18 można sprowadzić do postaci $p_t = \epsilon_t$. Według Petersa (1994, s. 170) proces p_t jest wtedy białym szumem.

Zdaniem Campbella i in. (1997, s.60), szereg czasowy poddany badaniu (p_t) jest stacjonarny gdy $d \in (-0,5, 0,5)$. Takie wartości parametru „ d ” wykazują specyficzne własności, tzn. znak parametru rzędu integracji ułamkowej (d) wskazuje na znak autokorelacji szeregu czasowego (dodatnią lub ujemną autokorelację). Gdy wartość parametru „ d ” jest większa od zera, siła autokorelacji zanika wolno w kolejnych opóźnieniach szeregu czasowego. Natomiast, wartość parametru „ d ” mniejsza od zera wskazuje na to, że siła autokorelacji w kolejnych opóźnieniach szeregu czasowego zmniejsza się w szybszym tempie niż poprzednio. Ponieważ oba te przypadki ($-0,5 < d < 0$ i $0 < d < 0,5$) charakteryzuje siła autokorelacji, która zanika wolniej niż w przypadku błędzenia losowego ($d = 0$), można przyjąć, że występuje wtedy tzw. pamięć (Campbell i in., 1997).

Warto nadmienić, że istnieje określona relacja pomiędzy rzędem integracji ułamkowej procesu (d) a wykładnikiem Hursta (H), którą można zapisać następująco (Peters, 1994):

$$H = 0,5 + d, \quad (20)$$

gdzie $d \in (-0,5, 0,5)$ oraz oznacza parametr określający pamięć szeregu, a $H \in (0, 1)$. Gdy błędzenie losowe ma postać ruchu Browna, wykładnik Hursta jest równy 0,5. Zgodnie z wzorem numer 20 w tym przypadku parametr „ d ” jest równy zero (brak autokorelacji szeregu czasowego). Natomiast, gdy proces stacjonarny charakteryzuje się tzw. pamięcią, parametr „ d ” jest większy bądź mniejszy od zera. Wartości parametru „ d ” spełniające nierówność: $-0,5 < d < 0$ oznaczają różowy szum. Natomiast, wartości parametru „ d ” należące do przedziału $0 < d < 0,5$ interpretuje się jako czarny szum (Peters, 1994). Znaczenie poszczególnych wartości parametru „ d ” i wykładnika Hursta dla procesu stacjonarnego zaprezentowano w tabeli 2.

Tabela 2. Znaczenie poszczególnych wartości parametru „ d ” i wykładnika Hursta dla procesu stacjonarnego

| Wartość parametru „ d ” | Wartość wykładnika Hursta (H) | Rodzaj szumu | Rodzaj „pamięci” szeregu czasowego |
|---------------------------|-----------------------------------|--------------|------------------------------------|
| $-0,5 < d < 0$ | $0 < H < 0,5$ | Różowy szum | Krótką pamięć |
| 0 | 0,5 | Biały szum | Brak pamięci |
| $0 < d < 0,5$ | $0,5 < H < 1$ | Czarny szum | Długa pamięć |

Źródło: Opracowanie własne na podstawie Peters (1994), Campbell i in. (1997), Czekaj, Woś i Żarnowski (2001)

Weryfikacja pól silnej efektywności rynku często jest przeprowadzana z wykorzystaniem takich metod jak eksperyment symulacyjny czy analiza reakcji cen na zdarzenia, co przedstawiono w tabeli 3.

Tabela 3. Metody weryfikacji pól silnej efektywności rynku

| Metoda | Przykłady zastosowania |
|-------------------------|--|
| analiza zdarzeń | Ball i Brown (1968), Fama, Fischer, Jensen i Roll (1969), Scholes (1972), Kraus i Stoll (1972), Stickel (1985), Amihud i Murgia (1997) |
| eksperyment symulacyjny | Reinganum (1981), Keim (1983), Reinganum (1983), Fama i French (1992) |

Źródło: Opracowanie własne na podstawie Ciołek (2019)

Eksperymenty symulacyjne polegają na pomiarze skuteczności strategii inwestycyjnych, które opierają się na analizie publicznie dostępnych informacji, takich jak np. wskaźniki fundamentalne¹³. Skuteczność strategii opierających się na informacjach fundamentalnych mierzy się za pomocą tzw. metody portfelowej. Polega ona na grupowaniu notowanych spółek (podmiotów) w ramach danego rodzaju instrumentu finansowego (np. akcji) na podstawie wartości wybranego wskaźnika fundamentalnego charakteryzującego podmiot. Powstałe w ten sposób grupy nazywa się portfelami. Następnie dokonuje się pomiaru wyników osiągniętych przez dany portfel w porównaniu do innych utworzonych portfeli. Jeżeli można uzyskać ponadprzeciętne stopy zwrotu z danego portfela (w stosunku do pozostałych) wtedy przyjmuje się, że rynek nie jest efektywny w formie pól silnej (Ciołek, 2019, s. 46-48). Problemami związanymi z tą metodą weryfikacji pól silnej efektywności rynku są subiektywność wyboru wskaźnika fundamentalnego i różne sposoby aproksymacji przeciętnych stóp zwrotu.

Kolejną możliwością weryfikacji pól silnej efektywności rynku jest analiza zdarzeń, takich jak ogłoszenia splitów, emisji akcji, zysków firm, nieprzewidywane zmiany dywidend, transakcje kupna dużej liczby walorów czy publiczne rekomendacje inwestycyjne wydawane przez ekspertów (Ball i Brown, 1968; Fama, Fischer, Jensen i Roll, 1969; Kraus i Stoll, 1972; Scholes, 1972; Stickel, 1985; Amihud i Murgia, 1997). W ramach tej metody zakłada się, że jeżeli cena aktywa szybko dostosowuje się do informacji dotyczącej zdarzenia rynkowego, to rynek jest

¹³ Do popularnych wskaźników fundamentalnych zalicza się m. in. iloraz ceny i zysku, ceny i wartości księgowej, wartość kapitalizacji rynkowej oraz współczynnik Beta (Reinganum, 1981; Keim, 1983; Reinganum, 1983; Fama i French, 1992).

efektywny w formie pól silnej. W przeciwnym razie, po wystąpieniu zdarzenia można zaobserwować ponadprzeciętne stopy zwrotu, co wskazuje na brak efektywności rynku.

Silna efektywność rynku może być weryfikowana za pomocą analizy stóp zwrotu z danego indeksu lub innego miernika zachowania całego rynku względem wyników podmiotów, które mogą mieć dostęp do informacji prywatnych (np. fundusze inwestycyjne mogą mieć dostęp do informacji przed ich upublicznieniem pozostałym inwestorom). W tym kontekście kluczowy jest brak pewności co do tego, czy te podmioty faktycznie posiadają informacje prywatne, które mogą mieć znaczenie dla obrotu giełdowego i korzystają z nich w celach inwestycyjnych. Ponadto wyniki badań (m. in. Sharpe (1966), Jensen (1968) i Malkiel (2005)) nie potwierdzają, aby fundusze inwestycyjne posiadały dostęp do poufnych informacji albo z nich korzystały.

Inną możliwością weryfikacji silnej efektywności rynku jest badanie działań osób, wobec których istnieje duża pewność, że mają dostęp do informacji prywatnych¹⁴. Do nich mogą należeć m. in. członkowie zarządu albo rad nadzorczych, inwestorzy o dużym udziale we własności podmiotu (tzw. blockholderzy). Ponadto, w celu weryfikacji silnej efektywności rynku można dokonać pomiaru stóp zwrotu w okresie, w którym rekomendacja jest udostępniana tylko wybranym odbiorcom (Ciołek, 2019, s. 48-50). Tę metodę wykorzystywali m. in. Dismon i Marsh (1984), Elton, Gruber i Grossman (1986) oraz Womack (1996). Do głównych problemów związanych z tą grupą testów zalicza się m. in. niereprezentatywność próby badawczej (publikowanie tylko takich rekomendacji, które okazały się zgodne z prawdą), niejednoznaczność w traktowaniu rekomendacji jako informacji prywatnej (Buczek, 2005, s. 32-33) oraz określenie podmiotów mających do nich dostęp. Podsumowanie najbardziej popularnych metod weryfikacji silnej efektywności rynku zawarto w tabeli 4.

Tabela 4. Metody weryfikacji silnej efektywności rynku

| Metoda | Przykłady zastosowania |
|--|---|
| ocena efektywności funduszy inwestycyjnych | Sharpe (1966), Jensen (1968), Malkiel (2005) |
| analiza możliwości wykorzystania informacji o działaniach potencjalnych insiderów | Scholes (1972), Jaffe (1974), Rozeff i Zaman (1988) |
| analiza stóp zwrotu osiągniętych na podstawie rekomendacji dostępnych dla wybranych inwestorów | Dismon i Marsh (1984), Elton, Gruber i Grossman (1986), Womack (1996) |

Źródło: Opracowanie własne na podstawie Ciołek (2019)

¹⁴ Takie metody zastosowali m. in. Jaffe (1974) oraz Rozeff i Zaman (1988).

Podsumowując, niektóre z wymienionych w tym podrozdziale metod weryfikacji słabej, półsilnej i silnej efektywności rynku cechują się podobnymi ograniczeniami (m. in. udział przeprowadzającego test w jego wykonaniu albo interpretacji wyników, wąski zakres wykorzystanych informacji, niezgodność z istniejącymi zasadami obrotu na rynku). Opisane wyżej ograniczenia pozwolą na ocenę przydatności poszczególnych metod do przeprowadzenia badania efektywności informacyjnej. Przydatność zostanie określona na podstawie dopasowania wybranego testu do rzeczywistych warunków i dokładności odzwierciedlenia stanu faktycznego danego rynku. Powinno to pomóc określić, czy wybrana metoda weryfikacji efektywności rynku zapewnia powtarzalność otrzymywanych wyników oraz odzwierciedla rzeczywiste zachowanie jego uczestników.

Przydatność testów efektywności rynku zostanie zweryfikowana na podstawie następujących kryteriów:

- 1) Zakres wykorzystywanych informacji (metoda, która jest przydatna powinna charakteryzować się szerokim zakresem wykorzystanych informacji),
- 2) Stopień obiektywizmu (z perspektywy przydatności pożądane jest małe znaczenie opinii użytkownika w trakcie stosowania metod weryfikacji efektywności rynku),
- 3) Zgodność z zasadami obrotu na danym rynku (aby metoda została uznana za przydatną powinna uwzględniać rzeczywiste reguły obrotu),
- 4) Jednoznaczność (przydatność testu efektywności rynku powinna być tożsama z jednoznaczną interpretacją informacji na jakich się on opiera i podmiotów mających do niej dostęp - rozróżnienie prywatnych i publicznych informacji),
- 5) Odporność na zdarzenia nieprzewidywalne (test będzie przydatny jeśli uwzględnia on w relatywnie dużym stopniu zależność będące efektem wystąpienia nieprzewidywalnych zdarzeń o dużym zasięgu, np. nieproporcjonalny wzrost wariancji w niektórych okresach, ryzyko zmieniające się w czasie).

Wyodrębnione kryteria oceny przydatności testów efektywności rynku przedstawiono w tabeli 5.

Tabela 5. Ocena przydatności testów efektywności rynku

| Lp. | Kryterium | Opis |
|-----|---|--|
| 1 | Zakres wykorzystywanych informacji | Należy zwrócić uwagę czy zastosowanie danego testu nie powoduje znaczącej utraty informacji o notowaniach z powodu uwzględnienia tylko części danych o szeregu cen np. uwzględnienie tylko znaków stóp zwrotu w testach serii. |
| 2 | Stopień obiektywizmu | Pożądanym jest mały wpływ postrzegania użytkownika w testowaniu efektywności rynku, co przekłada się na obiektywne wyniki i wnioski z przeprowadzonego badania (jak najwyższy stopień obiektywizmu). Obiektywizm można także rozumieć jako znaczną niezależność otrzymanych rezultatów od założeń przyjętych przez przeprowadzającego test. |
| 3 | Zgodność z zasadami obrotu na rynku | Testy efektywności rynku powinny zapewnić możliwość wykorzystania wysnutych na ich podstawie wniosków w praktyce. To znaczy, powinny one uwzględniać istnienie różnych ograniczeń dotyczących obrotu na rynku, np. brak możliwości krótkiej sprzedaży. |
| 4 | Jednoznaczność | Traktowanie informacji jako prywatnej lub publicznej powinno być w dużym stopniu jednoznaczne. W przeciwnym przypadku nie jest pewne jaka forma efektywności rynku jest poddana weryfikacji. Ponadto jednoznaczność można oceniać w kontekście zgodności w interpretacji wyników, tzn. czy rynek jest efektywny lub nieefektywny. |
| 5 | Odporność na zdarzenia nieprzewidywalne | Zdarzenia nieprzewidywalne występują nieregularnie, skutkując zwiększeniem niepewności gospodarczej, co prowadzi do częstej zmiany preferencji inwestorów i wzrostu zmienności, występowania tzw. wartości „odstających”, znacznych odchyłeń od trendu liniowego. W tej sytuacji wzrasta ryzyko inwestycyjne. Dlatego rekomenduje się sposoby analizy efektywności rynku, które uwzględniają różny charakter zależności w szeregu czasowym (długość, nieliniowość), zmienność w czasie ryzyka inwestycyjnego (oczekiwanej stopy zwrotu przez inwestorów), heteroskedastyczność. Niespełnienie tych warunków może prowadzić do uzyskania wskazań pozornie świadczących o (nie)efektywności rynku. |

Źródło: Opracowanie własne

Pierwsza z ocenianych grup testów efektywności rynku dotyczy weryfikacji jej słabej formy. Wszystkie metody analizy tej formy efektywności wykorzystują ogólnodostępne notowania. Można zatem jednoznacznie stwierdzić, że inwestorzy powinni mieć dostęp do informacji, na których opierają się te testy efektywności. Ponadto, większość z tych metod opiera się na szerokim zbiorze informacji. W tej kategorii jedynie testy sekwencji i odwrotności oraz serii wykorzystują wąski zakres informacji. Natomiast znaczenie opinii użytkownika w przeprowadzaniu pomiaru słabej efektywności rynku jest duże tylko w przypadku testów skuteczności strategii inwestycyjnych, w ramach których wykorzystuje się analizę techniczną. Wpływ subiektywizmu w przeprowadzaniu testów autokorelacji lub ilorazu wariancji można ograniczyć przez zautomatyzowanie procedury wyboru liczby badanych opóźnień na podstawie zależności zachodzących w badanym szeregu czasowym (np. test AVR).

Testy serii, sekwencji i odwrotności nie uwzględniają wartości możliwych do zaobserwowania cen, co może powodować, że uzyskane wyniki mogą być niemożliwe do

wykorzystania w praktyce. Ponadto, wyniki każdego z analizowanych testów słabej efektywności rynku należy traktować z ostrożnością w kontekście możliwego ograniczenia krótkiej sprzedaży na rynku. Testy korelacji i zależności długookresowych zdają się być najlepiej dopasowane do rzeczywistych warunków rynkowych. Miary długiej pamięci umożliwiają pomiar szybkości zaniku siły autokorelacji pomiędzy stopami zwrotu wraz z upływem czasu. Można zatem stwierdzić, że wnioski o nieefektywności wyciągane na podstawie tych testów będą z wysokim prawdopodobieństwem możliwe do wykorzystania przez inwestora w praktyce.

Ocena przydatności metod weryfikacji słabej efektywności rynku w kontekście spełnienia ostatniego kryterium pozwala dojść do wniosku, że testy sekwencji i odwrotności, serii, skuteczności wykorzystania analizy technicznej oraz testy zależności i korelacji długookresowych nie wykazują pełnej odporności na występowanie nieprzewidywalnych zdarzeń. Jednakże, niektóre z nich charakteryzują się pewnymi cechami, które mogą złagodzić wpływ tego typu zdarzeń na uzyskiwane rezultaty. Testy sekwencji i odwrotności oraz serii częściowo uwzględniają nieliniowość istniejących zależności w szeregu czasowym przez odniesienie do znaków stóp zwrotu. Na przykład, testy serii mogą dobrze odzwierciedlić naturę powstawania zjawisk nieprzewidywalnych skutkujących bańkami spekulacyjnymi poprzez znaczącą koncentrację naśladowczych działań inwestorów (nagły wzrost liczby serii). Niektóre testy zależności i korelacji długookresowych umożliwiają analizę nieliniowych zależności w kontekście wyboru różnych wartości parametru określającego badany rząd funkcji fluktuacji. Zaletą wykorzystania testów skuteczności analizy technicznej do weryfikacji słabej efektywności rynku jest brak wymogu odnoście do określonego rozkładu stóp zwrotu w czasie. Jednakże, w przypadku tej grupy metod może nie być zgodności co do interpretacji ich wyników (pozwalają one wnioskować tylko o nieefektywności rynku). Testy autokorelacji pozwalają ująć nieliniowość przez zastosowanie np. korelacji Spearmana. Jednakże, przez uwzględnienie tylko rang można nie doszacować wpływu zmian cen o bardzo dużej wartości. Natomiast niektóre testy ilorazu wariancji (np. test AVR) mogą odzwierciedlać pewien aspekt nieprzewidywalnych zdarzeń poprzez uwzględnienie warunkowej heteroskedastyczności stóp zwrotu. W tabeli 6 zaprezentowano porównanie przydatności wymienionych metod weryfikacji słabej formy efektywności rynku pod względem spełnienia przez nie ustalonych kryteriów.

Tabela 6. Porównanie przydatności testów słabej formy efektywności rynku

| Lp. | 1 | 2 | 3 | 4 | 5 |
|--|---|------------------------------|--|-----------------------|--|
| Metoda / Kryterium | Zakres wykorzystanych informacji | Stożenie obiektywizmu | Zgodność z zasadami obrotu na rynku | Jednoznaczność | Odporność na zdarzenia nieprzewidywalne |
| testy „sekwencji i odwrotności” | Wąski | Wysoki | Mała | Tak | Częściowa |
| testy serii | Wąski | Wysoki | Mała | Tak | Częściowa |
| testy z wykorzystaniem analizy technicznej | Szeroki | Niski | Częściowa | Nie | Częściowa |
| testy autokorelacji | Szeroki | Wysoki | Częściowa | Tak | Częściowa |
| testy ilorazu wariancji | Szeroki | Wysoki | Częściowa | Tak | Częściowa |
| testy obecności pierwiastka jednostkowego | Szeroki | Wysoki | Częściowa | Tak | Mała lub brak |
| testy anomalii | Szeroki | Wysoki | Częściowa | Tak | Mała lub brak |
| testy zależności i korelacji długookresowych | Szeroki | Wysoki | Częściowa | Tak | Częściowa |

Źródło: Opracowanie własne

Metody weryfikacji pól silnej formy efektywności rynku nie spełniają kryterium dotyczącego odporności na zdarzenia nieprzewidywalne, gdyż mogą one nie uwzględniać nieliniowości w zachowaniu stóp zwrotu. Jednakże, zmienność ryzyka inwestycyjnego w czasie można ująć w sposobie pomiaru oczekiwanych stóp zwrotu przez inwestorów (np. estymacja modelu CAPM w ruchomym oknie). Inną niedogodnością związaną z tą grupą metod jest subiektywny wybór wskaźnika fundamentalnego do modelu. Natomiast zaletą testów pól silnej efektywności rynku jest szeroki zakres wykorzystywanych informacji. Innym ograniczeniem tej grupy metod jest trudność w wykorzystaniu wyników przeprowadzonych testów w rzeczywistości,

ponieważ istnieją ograniczenia co do spadku ceny instrumentu finansowego (cena nie może być mniejsza od zera) oraz wykonania krótkiej sprzedaży. Ponadto w kontekście eksperymentów symulacyjnych można poddać w wątpliwość to, czy przeciętni inwestorzy faktycznie analizują dużą ilość informacji lub wskaźników fundamentalnych dotyczących różnych spółek i posiadają do tego odpowiednie zasoby, a także czy tylko na tej podstawie wybierają oni inwestycje. W tabeli 7 zaprezentowano podsumowanie oceny przydatności metod weryfikacji pól silnej formy efektywności rynku.

Tabela 7. Porównanie przydatności testów pól silnej formy efektywności rynku

| Lp. | 1 | 2 | 3 | 4 | 5 |
|---------------------------|---|-----------------------------|--|-----------------------|--|
| Metoda / Kryterium | Zakres wykorzystanych informacji | Stopień obiektywizmu | Zgodność z zasadami obrotu na rynku | Jednoznaczność | Odporność na zdarzenia nieprzewidywalne |
| analiza zdarzeń | Szeroki | Niski | Mała | Nie | Częściowa |
| eksperyment symulacyjny | Szeroki | Niski | Mała | Nie | Mała lub brak |

Źródło: Opracowanie własne

Testowanie silnej efektywności rynku może być problematyczne z uwagi na cechy przypisywane do metod jej weryfikacji, tzn. duże znaczenie opinii użytkownika w przeprowadzeniu testu i niejednoznaczność oceny czy inwestorzy faktycznie mają dostęp do prywatnych informacji i z nich korzystają. Założenia testów silnej efektywności rynku są niezgodne z rzeczywistymi warunkami obrotu, takimi jak m. in. ograniczenie krótkiej sprzedaży, możliwość wykorzystania informacji prywatnych przez zarządzających firmami inwestycyjnymi. Metody weryfikacji silnej efektywności rynku opierają się na szerokim zakresie dostępnych informacji. Jedynym wyjątkiem pod względem tego kryterium jest analiza stóp zwrotu osiąganych na podstawie rekomendacji dostępnych dla wybranych inwestorów, gdyż w tym przypadku próba badawcza może być niereprezentatywna. Ponadto, ta grupa metod weryfikacji efektywności rynku nie jest odporna na zdarzenia nieprzewidywalne. Podsumowanie oceny przydatności testów silnej efektywności rynku zamieszczono w tabeli 8.

Tabela 8. Porównanie przydatności testów silnej formy efektywności rynku

| Lp. | 1 | 2 | 3 | 4 | 5 |
|---|---|-----------------------------|--|-----------------------|--|
| Metoda / Kryterium | Zakres wykorzystanych informacji | Stopień obiektywizmu | Zgodność z zasadami obrotu na rynku | Jednoznaczność | Odporność na zdarzenia nieprzewidywalne |
| ocena efektywności funduszy inwestycyjnych | Szeroki | Niski | Mała | Nie | Mała lub brak |
| analiza możliwości wykorzystania informacji o działaniach potencjalnych insiderów | Szeroki | Niski | Mała | Nie | Mała lub brak |
| analiza zyskowności prywatnych rekomendacji | Wąski | Niski | Mała | Nie | Mała lub brak |

Źródło: Opracowanie własne

Konkludując, testy słabej efektywności rynku są najbardziej przydatne pod względem jednoznaczności oceny dostępu inwestorów do informacji. Jak opisano wyżej, większość z metod weryfikacji słabej formy efektywności rynku zapewnia możliwość częściowego wykorzystania ich wyników w praktyce, wysoki stopień obiektywności badania, szeroki zakres wykorzystywanych informacji. Dodatkowo niektóre z tych testów wykazują pewne cechy, które mogą złagodzić wpływ nieprzewidywalnych zdarzeń na uzyskane rezultaty. Wśród tych metod, testy autokorelacji, ilorazu wariancji oraz testy korelacji i zależności długookresowych spełniają kryteria przydatności w największym stopniu.

Z perspektywy badania efektywności informacyjnej, stopień obiektywności testowania czy zakres wykorzystywanych informacji wydają się być kluczowymi kryteriami. Odporność na nieprzewidywalne zdarzenia można częściowo zapewnić przez stosowanie metod weryfikacji słabej efektywności rynku w ujęciu dynamicznym, ponieważ w ten sposób można uwzględnić większą stabilność oszacowań i częściowo odróżnić efektywność rynku w normalnym okresie od jej kształtowania się w trakcie występowania nieprzewidywalnych zdarzeń rynkowych. Ponieważ testy korelacji i zależności długookresowych wykorzystują najszerszy zakres

informacji¹⁵ oraz umożliwiają określenie szybkości zaniku siły autokorelacji szeregu czasowego (Peters, 1994), w niniejszej pracy do pomiaru dynamiki efektywności rynku Bitcoina zostaną wykorzystane miary należące do tej grupy metod.

1.3 Charakterystyka rynku kryptowalut

Początkowo efektywność rynku badano głównie dla tradycyjnych aktywów (np. akcje czy towary). Jednakże, w drugiej dekadzie XXI wieku rozpoczęto analizowanie efektywności rynku, na którym odbywa się obrót nietradycyjnymi aktywami, takimi jak kryptowaluty (Urquhart, 2016). Ponieważ najstarszą i największą kryptowalutą pod względem kapitalizacji rynkowej jest Bitcoin, jest on głównym przedmiotem rozważań przedstawionych w niniejszej pracy.

Czas powstania kryptowalut przypisuje się do roku 2008, ponieważ wtedy została napisana praca opisująca pierwszą z nich - Bitcoina (Nakamoto, 2008). W myśl tej koncepcji kryptowaluty można zdefiniować jako elektroniczne systemy płatności umożliwiające przeprowadzenie transakcji bez udziału pośredników dzięki wykorzystaniu kryptografii¹⁶ do ich zabezpieczenia (Narayanan i in., 2016). Jednakże, jak dotąd, niewiele firm zaakceptowało płatności w kryptowalutach (Statista, 2021). W efekcie użytkownicy tych systemów podejmują decyzje gospodarcze w warunkach wyższej niepewności dotyczącej przeprowadzenia transakcji niż w przypadku tradycyjnych środków płatności. Niemniej jednak, charakterystyczne cechy kryptowalut sprawiają, że są one często wykorzystywane jako przedmiot inwestycji.


Jedną z cech wyróżniających kryptowaluty na tle tradycyjnych inwestycji jest trudna do określenia wartość fundamentalna (Britannica, 2021). Na przykład, wyniki jednego z badań (Chicago Booth Review, 2017) wskazują, że najwięcej osób wśród badanych nie było pewnych czy wartość fundamentalna Bitcoina przekracza przynajmniej 1000 dolarów. Istnieją prace (Cheah i Fry, 2015; Adcock i Gradojevic, 2019; Agosto, Cerchiello i Pagnottoni, 2022), w których badacze wskazują nawet na brak wartości fundamentalnej albo cech ilościowych kryptowalut, co powoduje trudności w ich wycenie. Trudność w jednoznacznym określeniu wartości fundamentalnej kryptowalut implikuje, że słaba efektywność rynku jest jedyną formą, która

¹⁵ W przypadku tych testów brak jest potrzeby określenia maksymalnego rzędu uwzględnianej autokorelacji. Ponadto, niektóre z nich odnoszą się do dwóch wymiarów błędzenia losowego jednocześnie.

¹⁶ Na przykład wzór, algorytm matematyczny, który przekształca daną informację w taki sposób, że będzie ona niezrozumiała dla innych osób. Pobrane 22 grudnia 2022 z <https://www.ibm.com/docs/pl/i/7.1?topic=concepts-cryptography>

może być obiektywnie zbadana. W konsekwencji, tylko metody opierające się na historycznych notowaniach inwestycji, takie jak np. analiza statystycznych zależności występujących pomiędzy zmianami cen mogą zostać obiektywnie wykorzystane do pomiaru efektywności informacyjnej tego rynku. Zatem należy dokonać charakterystyki kryptowalut, ponieważ może to mieć znaczenie dla poziomu efektywności rynku oraz wyboru odpowiednich metod badawczych.

Największą kryptowalutą pod względem kapitalizacji jest Bitcoin. Jednocześnie charakteryzuje go najdłuższa historia notowań. Dlatego jest on najlepszym reprezentantem zachowania całego rynku kryptowalut w długim okresie. Na wykresie 1 można zaobserwować znaczną dominację kapitalizacji Bitcoina w porównaniu do pozostałych kryptowalut.



Wykres 1. Udział kapitalizacji Bitcoina w rynku kryptowalut (stan na dzień 26.04.2025 r.)

Źródło: Opracowanie własne na podstawie coinmarketcap.com

Jedną z charakterystycznych cech kryptowalut jest wykorzystanie technologii nazywanej „łańcuchem bloków” (*blockchain*). Przeprowadzone transakcje na rynku są potwierdzane przez tzw. węzły (*nodes*, np. sprzęt komputerowy). Następnie dane dotyczące tych transakcji układane są w tzw. bloki, które są wzajemnie powiązane. To znaczy, że każdy z nich posiada zaszyfrowane odniesienie do historii przeprowadzonych transakcji. Utworzone w ten sposób bloki są rejestrowane w bazie danych, którą nazywa się „łańcuchem bloków” (Piech, 2016).

Kryptowaluty różnią się pod względem mechanizmu osiągnięcia konsensusu. Do najbardziej popularnych rozwiązań w tym zakresie należą: „dowód pracy” (*Proof of Work*) oraz „dowód stawki” (*Proof of Stake*)¹⁷. W ramach *Proof of Work* zakłada się, że węzły, których zadaniem jest weryfikacja bloku transakcji, rywalizują między sobą w celu rozwiązania skomplikowanego równania matematycznego. Rozwiązanie tego równania jest ustalane przez algorytm za pomocą metody losowej i wymaga zużycia ogromnej ilości energii (Scharnowski i Shi, 2021). Węzeł, który rozwiąże to równanie dodaje blok do *blockchaina* i otrzymuje nagrodę w jednostce „wydobytej” kryptowaluty¹⁸.

W porównaniu do „dowodu pracy”, *Proof of Stake* zużywa mniej energii elektrycznej. Zastosowany w jego przypadku algorytm losuje węzeł, który zweryfikuje i potwierdzi transakcje zawarte w bloku oraz zaproponuje kolejny blok do autoryzacji w sieci kryptowaluty. Powstały w ten sposób blok jest weryfikowany i potwierdzany przez inne węzły (tzw. walidatorów), którzy także są losowo wybierani przez algorytm. W zamian za udział w tym procesie węzły otrzymują nagrody w postaci jednostek danej kryptowaluty. Ponieważ weryfikacja transakcji w przypadku *Proof of Stake* opiera się głównie na podstawie danych, takich jak np. ilość posiadanych (zastawionych) jednostek kryptowaluty lub czas jej nabycia, działanie tego mechanizmu osiągnięcia konsensusu nie wymaga tak dużej mocy obliczeniowej jak w przypadku *Proof of Work* (Włosik, 2021, s.15-16). Zatem kryptowaluty wykorzystujące „dowód stawki” jako mechanizm osiągnięcia konsensusu mogą być postrzegane jako mniej energochłonne od tych działających na podstawie „dowodu pracy”. Dlatego w okresach wzrostu popularności postaw proekologicznych wśród inwestorów może dojść do realokacji kapitału z bardziej do mniej energochłonnych kryptowalut. W efekcie, w przypadku kryptowalut wykorzystujących *Proof of Work* wśród inwestorów mogą wystąpić zachowania stadne, co może prowadzić do okresowego obniżenia ich poziomu efektywności informacyjnej.

Inną cechą kryptowalut jest zróżnicowany poziom bezpieczeństwa ich systemów (np. odporność na próby dodania nieprawidłowego bloku transakcji do *blockchaina*). Za najbezpieczniejszą kryptowalutę uznaje się Bitcoina, ponieważ w jego przypadku bezpieczeństwo sieci jest gwarantowane ogromną mocą obliczeniową tzw. koparek (sprzęt do

¹⁷ *Proof of Work* jest zaimplementowany w systemie Bitcoina. W ramach drugiej najpopularniejszej kryptowaluty, czyli Ethereum, zastosowano *Proof of Stake*.

¹⁸ Tego typu uczestników rynku nazywa się górnikiemami.

tworzenia nowych bloków), które często są oddalone geograficznie od pozostałych z nich (Piech, 2016). Dlatego inwestorzy na tym rynku mogą być mniej skłonni do nieracjonalnego zachowania pod wpływem informacji o potencjalnych atakach hakerskich czy innych tego typu oszustwach niż w przypadku pozostałych kryptowalut. Powinno to prowadzić do relatywnie wyższego poziomu efektywności rynku Bitcoina w takich sytuacjach w porównaniu do innych kryptowalut. Z drugiej strony, zróżnicowanie lokalizacji koparek utrudnia określenie wartości fundamentalnej Bitcoina, ponieważ zaufanie do emitenta jest rozproszone na wiele podmiotów, przez co trudno jest przypisać je do określonej jednostki. W efekcie na rynku Bitcoina może istnieć więcej nieprzejrzystych informacji w kontekście określenia ryzyka inwestycji związanego z jego wydobyciem niż w przypadku kryptowalut o mniej zróżnicowanej lokalizacji koparek. Może to skutkować relatywnie niższym poziomem efektywności rynku Bitcoina.

Kryptowaluty różnią się pod względem określenia ich maksymalnej podaży oraz czasu jej osiągnięcia. Przykładowo druga największa kryptowaluta, Ethereum, nie ma określonej liczby możliwych do wydobycia jednostek. Natomiast maksymalna liczba Bitcoinów do wytworzenia wynosi 21 milionów jednostek. Co więcej, prędkość wprowadzania nowych jednostek tej kryptowaluty do obiegu maleje. Wynika to z faktu, że nowe jednostki Bitcoina powstają jako nagroda dla górników, której wartość za każdy blok transakcji jest zmniejszana o 50% co około 4 lata (*halving*)¹⁹ (Meynkhard, 2019). W efekcie szacuje się, że maksymalna podaż Bitcoina zostanie osiągnięta w 2140 roku (Coinbase, 2023). W przypadku pieniądza tradycyjnego nie ma jednak oszacowanej daty osiągnięcia maksymalnej jego ilości. Co więcej, poprzez kreowanie podaży pieniądza, banki centralne mogą wpływać na inflację, co powoduje spadek jego siły nabywczej. Dlatego inwestorzy mogą postrzegać inwestycje w kryptowaluty jako długoterminowe zabezpieczenie przed inflacją. Zatem niezależność ilości jednostek kryptowaluty w obiegu od decyzji państwowych instytucji może skłaniać inwestorów do relokacji kapitału z rynku walutowego na rynek kryptowalut, szczególnie w przypadku występowania wysokiej inflacji w gospodarce narodowej. W konsekwencji, w tych okresach może dojść do wystąpienia zachowań stadnych, co może przyczynić się do okresowego zmniejszenia poziomu efektywności rynku kryptowalut.

¹⁹ Halving następuje po dodaniu 210 000 nowych bloków do „łańcucha bloków” (Eksi i Schreitl, 2022).

Według Dwyer (2015), stopy zwrotu na rynku Bitcoina charakteryzuje wyższa zmienność niż w przypadku rynków walut czy złota. Zatem kryptowaluty mogą charakteryzować się mniejszymi możliwościami przechowywania wartości w porównaniu do inwestycji tradycyjnych. Wysoka zmienność kryptowalut może powodować napływ wielu informacji w krótkim odstępie czasu, utrudniając podjęcie odpowiedniej decyzji przez inwestorów. To uniemożliwia efektywne przewidywanie przyszłych ruchów cen kryptowalut na podstawie ich historycznych notowań, np. za pomocą formacji analizy technicznej. W efekcie metody analizy technicznej nie będą właściwymi do weryfikacji efektywności rynku kryptowalut.

Wymienione cechy kryptowalut, takie jak decentralizacja jego emisji, oparcie na technologii *blockchain*, wysoka zmienność cen czy oszacowany czas osiągnięcia maksymalnej podaży, mogą powodować, że uczestnicy rynku kryptowalut bardziej postrzegają je jako specyficzną inwestycję niż tradycyjny rodzaj lokaty kapitału lub formę dokonywania płatności. W przeciwieństwie do kryptowalut, wartość fundamentalna środków pieniężnych opiera się na zaufaniu do jednego emitenta (banku centralnego). Wartość fundamentalna akcji może odzwierciedlać oczekiwania inwestorów co do przyszłych zysków przedsiębiorstwa. Wartość fundamentalną złota można wyznaczyć na podstawie informacji o istniejących zasobach naturalnych i koszcie jego wydobywania. Natomiast wartość kryptowalut może opierać się na spekulacji (Cheah i Fry, 2015; Adcock i Gradojevic, 2019), sentymencie inwestorów (Agosto, Cerchiello i Pagnotoni, 2022), zmiennych ekonomicznych (np. podaż pieniądza, PKB, inflacja i stopa procentowa), trudności w emisji ich jednostek, technologii używanej do wydobywania (mocy obliczeniowej) albo nawet zaufaniu do technologii *blockchain* (Li i Wang, 2017; Hayes, 2019). Zaufanie do technologii w czasie szybkiego postępu technologicznego może być trudne we właściwej ocenie i sprzyjać nieracjonalnym zachowaniom inwestorów na tym rynku, co może skutkować powstawaniem baniek spekulacyjnych.

Jak wskazano powyżej, kryptowaluty są specyficzną inwestycją. Perez i Urbaniak (2013) zauważają, że w pewnych okresach dynamika ceny Bitcoina (najpopularniejszej kryptowaluty) jest bardzo podobna do zachowania charakterystycznego dla spekulacji giełdowej. Ponadto stwierdzają, że Bitcoin wykazuje niektóre cechy przypisywane do pieniądza jako środka tezauryzacji i bywa traktowany jako system płatności. Ta złożoność kryptowalut może powodować, że poziom efektywności rynku kryptowalut będzie inny niż w przypadku inwestycji tradycyjnych. Dlatego ważne jest rozpoznanie mechanizmów rynkowych, które są charakterystyczne dla inwestowania na rynku kryptowalut.

Podobnie do tradycyjnych instrumentów finansowych, nabycie kryptowalut jest możliwe na rynku pierwotnym i wtórnym. Jednym ze sposobów na zostanie właścicielem kryptowalut na rynku pierwotnym jest udział w ich wydobyciu, czyli weryfikacji i potwierdzaniu transakcji oraz tworzeniu nowych bloków. Alternatywą może być uczestnictwo w ofercie sprzedaży tokenów²⁰ (*ICO – initial coin offering*), która dotyczy podmiotów wykorzystujących technologię „łańcucha bloków”. Pierwszym etapem ICO jest opracowanie specjalnego dokumentu (tzw. *white paper*), który opisuje różne aspekty projektu inwestycyjnego²¹. Dokument ten przypomina prospekt emisyjny, który jest przygotowywany w ramach pierwszej publicznej oferty akcji. W następnej kolejności może dojść do przedsprzedaży tokenów (*pre-ICO*) po niższej cenie niż w ostatniej fazie ICO (Momtaz, 2020). Ostatnim etapem ICO jest publiczna oferta sprzedaży lub tzw. oferta prywatna, czyli skierowana do konkretnej grupy inwestorów (Blandin i in. 2019, s. 24). W efekcie, uczestnicy ICO dokonują transferu środków finansowych (w formie kryptowaluty lub waluty krajowej) na rzecz podmiotu oferującego, a w ramach rekompensaty nabywają oni tokeny, które uprawniają do otrzymania jednostek kryptowaluty. W trakcie ostatniego etapu ICO tokeny mogą być wprowadzane na platformę obrotu (Liu i Wang, 2019). Konkludując, w niektórych aspektach ICO jest podobne do pierwszej oferty publicznej (*IPO*), która jest stosowana w przypadku akcji. Aczkolwiek, w porównaniu do IPO, charakteryzuje ją mniejszy stopień uregulowania oraz niższe koszty transakcyjne (Momtaz, 2020). Można zatem oczekiwać, że rynek kryptowalut będzie cechował się niższym poziomem efektywności niż rynek akcji, ponieważ podczas ICO inwestorzy posiadają dostęp do mniejszej ilości „pewnych” informacji dotyczących ryzyka tej inwestycji związanego z emitentem (niż w przypadku IPO).

Podobną do ICO formą nabycia tokenów jest *Initial Exchange Offering* (*IEO*) – ogólnodostępna sprzedaż tokenów wspierana i gwarantowana przez platformę, na której dokonuje się transakcji kryptowalutami. Zapewnienie gwarancji IEO przez platformę polega na dokładnym zbadaniu projektu (*Customer Due Diligence*), który będzie wprowadzany na platformę obrotu. Inną różnicą między ICO a IEO jest fakt, że grupa docelowa IEO jest ograniczona do klientów platformy obrotu, która uczestniczy w tej ofercie (Marley, 2020). W konsekwencji IEO wydaje się przyczyniać do wyższego poziomu efektywności rynku niż ICO,

²⁰ Token oznacza cyfrową reprezentację własności.

²¹ M. in. opis emitenta, plan wykonania oraz prawne aspekty projektu inwestycyjnego (Liu i Wang, 2019).


gdyż w tej sytuacji część ryzyka zostaje dodatkowo przeniesiona na platformę obrotu, która zapewnia inwestorom gwarancję prawdziwości niektórych informacji związanych z tą ofertą.

Innym sposobem stania się właścicielem kryptowaluty na rynku pierwotnym jest uczestnictwo w tzw. rzucie (*Airdrop*), który jest dokonywany przez podmioty posiadające token oparty na ich „łańcuchu bloków” (Piech, 2016). Zrzut polega na transferze darmowych tokenów do dotychczasowych lub nowych uczestników rynku kryptowalut (aby zachęcić ich do inwestycji na tym rynku). W zamian za otrzymanie darmowego tokenu nabywca może być zobowiązany do wykonania pewnych działań na rzecz podmiotu dystrybuującego tokeny, np. promocji w mediach społecznościowych. Zatem celem rzutu może być zwiększenie zainteresowania projektem czy przyciągnięcie nowych klientów, co może doprowadzić do zwiększenia płynności danej kryptowaluty przed jej wprowadzeniem na giełdę (Binance academy, 2022). Pod względem potencjalnego efektu, jakim jest zwiększenie płynności na rynku i możliwości transferu dodatkowych tokenów do ich dotychczasowych właścicieli, to działanie przypomina split na rynku akcji. Jednakże, operacja rzutu różni się od podziału akcji pod względem potencjalnego zasięgu. W przeciwieństwie do splitu, zrzut może skutkować przekazaniem reprezentacji własności „za darmo” do nowego odbiorcy. Ponieważ zrzut może prowadzić do powstawania baniek spekulacyjnych na skutek szybkiego wzrostu popularności inwestycji, może to przyczyniać się do niższego poziomu efektywności rynku kryptowalut niż rynku akcji.

Kolejną operacją rynkową, która może wpływać na inwestycje w projekty dotyczące kryptowalut jest podział łańcucha bloków (*fork*). W tym przypadku zakłada się, że łańcuch bloków jest publicznym oprogramowaniem, w którym użytkownicy mogą zaproponować jego ulepszenie. Jeśli zdecydują się oni dokonać zmiany w tym protokole, to może nastąpić podział *blockchaina*. Ze względu na skutek tej zmiany można wyróżnić miękki (*soft fork*) i twardy podział (*hard fork*). Miękki podział odnosi się do efektu, którym jest jeden *blockchain*. W tym przypadku zmiana łańcucha bloków jest na tyle niewielka (np. wprowadzenie nowej funkcji), że można ją uwzględnić w dotychczasowym protokole *blockchain*. Twardy podział łańcucha bloków wynika z istotnej zmiany protokołu, co skutkuje niezgodnością z dotychczasowym protokołem *blockchain*. W rezultacie powstają dwa łańcuchy bloków - nowy i oryginalny, tzn. sprzed aktualizacji (Coinbase, 2022), co może skutkować zmniejszeniem liczby użytkowników mniej popularnego łańcucha bloków i tym samym utrudniać możliwość zawarcia transakcji między jego użytkownikami. W efekcie, może nastąpić zwiększenie czasu na odzwierciedlenie

informacji rynkowej w cenach kryptowalut po podziale łańcucha bloków. W takim przypadku informacje mogą zostać wykorzystane tylko przez niektórych inwestorów prowadząc do obniżenia poziomu efektywności rynku kryptowalut.

Na rynku wtórnym kryptowalut obrót może być dokonywany za pomocą tzw. giełd kryptowalut. Hileman i Rauchs (2017, s. 28) definiują giełdę kryptowalut (*cryptocurrency exchange*) jako dostarczyciela usług kupna / sprzedaży kryptowalut za inne formy pieniądza (np. walutę tradycyjną) czy aktywa. Od początku istnienia rynek giełd kryptowalut kształtuje się dynamicznie, co zaprezentowano na wykresie nr 2 przedstawiającym udział w rynku poszczególnych giełd (pod względem wolumenu obrotu Bitcoinem).



Wykres 2. Udział obrotów poszczególnych giełd w rynku Bitcoina

Źródło: Opracowanie własne na podstawie data.bitcoinity.org

Na wykresie można zauważyć, że giełdy, które w pewnym okresie były liderami branży, później utraciły swoją pozycję na rynku. Może być to związane z oszustwami obecnymi na rynku kryptowalut, które doprowadziły do upadku m. in. początkowego lidera branży - giełdy Mt. Gox w 2014 r. (Reuters, 2014). Ponadto na wykresie można zaobserwować, że giełdy Bitstamp i Bitfinex charakteryzuje względnie wysoki i stabilny w czasie udział w rynku w porównaniu do największych giełd kryptowalut. Jednakże, z uwagi na to, że giełda Bitstamp

została założona rok wcześniej niż giełda Bitfinex, posiada ona dłuższą historię notowań kryptowalut (Bitstamp, 2023; Bitfinex, 2023)²².

Według Włosik (2021, s.70-72, 77-78), nabycie kryptowalut jest również możliwe za pomocą podmiotów należących do rynku pozagiełdowego (*over-the-counter*). Wśród tych podmiotów znajdują się m. in. bitomaty²³, kantory i inni uczestnicy rynku, z którym zawiera się transakcje bezpośrednio. Poza tym, tak jak w przypadku akcji, istnieją sposoby inwestowania pośredniego bez posiadania własności danej kryptowaluty. W tej zbiorowości wyróżnia się także *exchange-traded products*, instrumenty pochodne i jednostki bądź certyfikaty uczestnictwa w funduszach inwestycyjnych.

Konkludując, na rynku kryptowalut można zaobserwować podobne możliwości obrotu do tych występujących w przypadku inwestycji tradycyjnych (np. akcje). Ponadto wprowadzenie możliwości obrotu instrumentami pochodnymi pozwala na możliwość osiągania zysków z inwestycji także w przypadku spadku jej wartości. Może to implikować większą symetrię rozkładu prawdopodobieństwa stóp zwrotu, serii stóp zwrotu itd. W konsekwencji możliwy jest bardziej losowy charakter szeregu zmian cen sugerujący zwiększenie poziomu efektywności rynku kryptowalut. Poza tym, kwestia niższych kosztów transakcyjnych związanych z zakupem bądź sprzedażą kryptowalut niż w przypadku tradycyjnych inwestycji, może prowadzić do niższego poziomu efektywności rynku kryptowalut, gdyż umożliwia to zawieranie większej liczby transakcji przy określonych zasobach. W efekcie strategia inwestycyjna, która byłaby nieopłacalna na rynku akcji (występują na nim relatywnie wyższe koszty transakcyjne), w kontekście kryptowalut może okazać się zyskowna. Z drugiej strony niższe koszty transakcyjne mogą powodować zwiększenie poziomu efektywności rynku, ponieważ mogą one przyciągać inwestorów o mniejszym kapitale skutkując zwiększeniem konkurencji na rynku kryptowalut (zmniejszeniem znaczenia inwestorów o dużym udziale w rynku).

Z przedstawionych rozważań wynika, że kryptowaluty są specyficzną inwestycją. Aczkolwiek istnieją podobieństwa między kryptowalutami a inwestycjami tradycyjnymi, takie jak m. in. niektóre mechanizmy pozyskiwania kapitału na rynku pierwotnym, podmioty rynku wtórnego czy instrumenty finansowe. Do cech odróżniających kryptowaluty od inwestycji

²² Dlatego, dane dotyczące kursu Bitcoina na potrzeby badania zostaną pobrane z giełdy Bitstamp.

²³ Bitomat to urządzenie, które w zamian za prowizję oferuje możliwość wypłaty waluty tradycyjnej (jeżeli klient chciałby zapłacić kryptowalutą) lub zakupu kryptowalut (Włosik, 2021, s. 22, 70-72).

tradycyjnych zalicza się m. in. trudność w określeniu wartości fundamentalnej, brak nadrzędnego emitenta, wysoką zmienność stóp zwrotu, oszacowany czas osiągnięcia maksymalnej podaży w przypadku niektórych z nich czy słabe uregulowanie tego rynku. Ponadto w przypadku niektórych kryptowalut istnieją charakterystyczne mechanizmy, które mogą prowadzić do zmian poziomu efektywności rynku. Szczególną kryptowalutą pod tym względem jest Bitcoin. W jego przypadku co pewien czas zmniejsza się ilość wydobywanych nowych jednostek kryptowaluty (*halving*). Ponieważ Bitcoin jest najstarszą kryptowalutą oraz charakteryzuje go największa kapitalizacja rynkowa, badania empiryczne zaplanowane w ramach tej pracy będą dotyczyły tej kryptowaluty.

Zaobserwowana wysoka zmienność na rynku Bitcoina w porównaniu do walut i złota (Dwyer, 2015), może świadczyć o częstym zawieraniu transakcji o charakterze spekulacyjnym na tym rynku. Przyczyną tego może być wspomniana trudność w określeniu wartości fundamentalnej kryptowalut (w odróżnieniu od akcji). Na przykład, w procesie wyceny kryptowalut inwestorzy mogą polegać przede wszystkim na nieobserwowalnych bezpośrednio czynnikach (poza analizą danych cenowych), takich jak zaufanie do emitenta, przyszłość technologii, niepewność dotycząca akceptacji kryptowalut jako środka płatniczego, które również są zmienne. Jak wskazuje Shiller (2003), nadmierna zmienność akcji (jako przybliżenie nieefektywności rynku) może być związana z nieracjonalnością inwestorów. Zatem wysoka zmienność notowań kryptowalut i nieobserwowalne komponenty mogą być trudne do prawidłowej oceny i skutkować błędami w myśleniu oraz heurystykami, co może powodować obniżenie poziomu efektywności rynku. Ponadto, ze względu na odmienną kryptowalut w porównaniu do innych inwestycji w kontekście sposobów ich pozyskania (m. in. ICO, IEO czy zrzut), istnieje potrzeba badania poziomu efektywności tego rynku.

Wobec przytoczonych problemów z określeniem wartości fundamentalnej kryptowalut, najbardziej właściwe wydaje się badanie słabej formy efektywności rynku opracowanej przez Famę. Znaczący udział elementów zmiennych i trudnych do oceny w kontekście wyceny kryptowalut implikuje, że powinno się wykorzystywać metody odporne na wysoką zmienność, różną reakcją inwestorów na zdarzenia, a także ich interpretację. Jednakże, zdarzające się co jakiś czas oszustwa na tym rynku i niepewność dotycząca przepisów regulujących działanie giełd kryptowalut mogą powodować, że poziom efektywności tego rynku będzie mocno zmieniać się w czasie. Dlatego dokonanie statycznego pomiaru efektywności rynku dla jednego długiego horyzontu czasowego może prowadzić do braku pogłębienia wniosków.

Wysoka zmienność stóp zwrotu z kryptowalut i częste wartości skrajne stóp zwrotu implikują zastosowanie metod pomiaru, które nie opierają się na założeniu o statycznym rozkładzie zmian cen w całym okresie badania. Zatem powinno stosować się metody, które umożliwiają analizę efektywności rynku w różnych następujących po sobie okresach oraz uwzględniają wartość stóp zwrotu (nie tylko ich znaki czy sekwencje).

1.4 Przegląd dotychczasowych badań z zakresu efektywności rynku kryptowalut

Jak dotąd powstało wiele badań dotyczących kryptowalut. Jednym z nurtów tych badań jest analiza efektywności informacyjnej rynku. Początkowo weryfikowano głównie słabą formę efektywności rynku Bitcoina. Jedno z pierwszych badań efektywności rynku kryptowalut zostało przeprowadzone na rynku Bitcoina przez Urquharta (2016). Wykorzystał onienne dane cenowe z okresu 2010 - 2016, które były pobrane jako średnia cena Bitcoina z różnych giełd. Ponadto podzielił on badany okres na dwa podokresy (2010-2013, 2013-2016), co umożliwiło uproszczoną weryfikację stałości poziomu efektywności rynku w czasie. Co więcej, w celu zbadania losowości szeregów czasowych zastosował różne testy, m. in. test Ljung-Boxa (autokorelacji stóp zwrotu), test serii Walda i Wolfowitza, test ilorazu wariancji oraz wykładnik Hursta. Na tej podstawie doszedł on do wniosku, że w perspektywie całego okresu Bitcoin nie jest rynkiem efektywnym w formie słabej. Aczkolwiek zauważył, że w drugim z wyróżnionych okresów niektóre testy wskazały na efektywność rynku Bitcoina, co może wskazywać na to, że poziom efektywności rynku zwiększa się w czasie. W kolejnej pracy Urquhart (2017) wykorzystał nieco inne dane, tzn.ienne notowania Bitcoina tylko z giełdy Bitstamp w latach 2012-2017. Zauważył, że ceny Bitcoina często oscylują wokół poziomów odpowiadających liczbom całkowitym, a ponad 10% transakcji kupna/sprzedaży Bitcoina odbywa się po cenach kończących się na „00” w części setnej. Jednakże, stwierdził on, że te tendencje w zachowaniu cen nie są na tyle istotne, aby na ich podstawie opracować zyskowną strategię inwestycyjną, co może wskazywać na efektywność rynku Bitcoina. Rozbieżność wniosków wysnutych przez Urquharta może wynikać z faktu, że w obu badaniach stosował on różne dane (w pierwszym badaniu wykorzystał on średnie kursy Bitcoina). Ponadto, tylko w drugim z tych badań wysnuł on wniosek o efektywności rynku na podstawie braku możliwości konstrukcji zyskowej strategii inwestycyjnej. Nieskuteczność jednej strategii inwestycyjnej nie jest tożsama z efektywnością rynku, ponieważ mogą istnieć inne zyskowe strategie inwestycyjne, których nie wzięto pod uwagę.

Podobnie do pierwszego z przytoczonych badań, Nadarajah i Chu (2017) analizowali słabą efektywność rynku Bitcoina w latach 2010 - 2016, dokonując podziału całego okresu na dwa podokresy. Jednakże, w odróżnieniu od wcześniejszych badań weryfikowali efektywność rynku na podstawie szeregu dziennych stóp zwrotu podniesionych do potęgi nieparzystej. W ten sposób Nadarajah i Chu (2017) sprawdzali, czy istnieją pewne wzorce w zachowaniu zmienności tego rynku, które nie są widoczne w kontekście surowych stóp zwrotu, co pośrednio może świadczyć o efektywności rynku bądź jej braku. Zastosowali oni podobne testy efektywności rynku do tych wykorzystanych przez Urquharta (2016). Uzyskane przez nich rezultaty w dużej mierze potwierdziły niezależność stóp zwrotu Bitcoina.

W ramach kolejnych badań słabej efektywności rynku Bitcoina wykorzystywano głównie testy zależności i korelacji długookresowych. Bariviera (2017) zastosował wykładnik Hursta do pomiaru poziomu efektywności rynku Bitcoina. Wykorzystał on różne metody jego estymacji – DFA (*Detrended fluctuation analysis*) i R/S (*Rescaled range analysis*). Podobnie do Urquharta (2016), wyniki badania przeprowadzonego przez Barwierę (2017) świadczą o tym, że w długim okresie Bitcoin jest rynkiem nieefektywnym. Poza tym, na podstawie oszacowań metodą DFA zauważył on, że w ostatnim czasie poziom efektywności rynku Bitcoina zwiększa się. Jiang i in. (2018) także analizowali słabą efektywność rynku Bitcoina wykorzystując technikę ruchomego okna. W tym celu zastosowali testy ilorazu wariancji, autokorelacji oraz występowania zależności długookresowych. Potwierdzili oni, że w latach 2010-2017 Bitcoin był rynkiem nieefektywnym (poziom jego efektywności zmieniał się w czasie) i charakteryzowało go występowanie długiej pamięci.

Tiwari i in. (2018) zastosowali różne miary długiej pamięci szeregu czasowego w celu weryfikacji efektywności rynku Bitcoina w podobnym czasookresie co Jiang i in. (2018). Zaobserwowali, że istnieją zarówno okresy efektywności rynku Bitcoina jak i jej braku. Khuntia i Pattanayak (2018) również doszli do wniosku, że poziom efektywności rynku Bitcoina zmienia się w czasie, co jest zgodne z hipotezą rynku adaptacyjnego (*Adaptive market hypothesis*, Lo (2004)). Co więcej, zauważyli, że może być to efektem behawioralnych uprzedzeń inwestorów i znaczących zdarzeń dotyczących kryptowalut (np. nowe regulacje, bankructwa giełd). Alvarez-Ramirez i in. (2018), wykorzystując wykładnik Hursta zaobserwowali, że rynek Bitcoina nie jest efektywny w formie słabej w całym okresie. Ponadto udokumentowali, że poziom efektywności tego rynku zmienia się w czasie, a wartość wykładnika Hursta wskazuje na występowanie długiej pamięci. Podobne rezultaty uzyskali oni stosując różne częstotliwości

danych cenowych. Dodatkowo, Alvarez-Ramirez i in. (2018) doszli do wniosku, że poziom efektywności rynku Bitcoina jest relatywnie wyższy w czasie spadkowego trendu jego notowań. Do podobnych konkluzji można dojść na podstawie pracy Kristoufka (2018). Zauważył on, że rynek Bitcoina jest efektywny tylko po wystąpieniu zjawiska tzw. baniek cenowych. Poza tym, wyniki tego badania świadczą o znaczącym i stabilnym udziale długiej pamięci w poziomie efektywności rynku Bitcoina w porównaniu do pozostałych badanych aspektów efektywności rynku, takich jak wymiar fraktalny (miara lokalnej struktury korelacji serii) oraz entropia (mierzy "skorelowanie seryjne").

Późniejsze badania (Aggarwal, 2019; Bouri i in., 2019) potwierdzają, że Bitcoin nie jest efektywny w formie słabej. W szczególności Aggarwal (2019) zauważył, że poziom efektywności rynku Bitcoina może być powiązany z występowaniem zjawiska „grupowania zmienności”²⁴. Dodatkowo stwierdził on, że zmienność stóp zwrotu z Bitcoina wzrasta bardziej po wzrostach niż spadkach jego cen, co może oznaczać większy wpływ pozytywnych wiadomości niż negatywnych na zachowanie inwestorów na tym rynku. Bouri i in. (2019) wykazali istnienie długiej pamięci dla szeregu stóp zwrotu. Zargar i Kumar (2019) badali poziom efektywności rynku Bitcoina opierając się na danych cenowych z giełdy Bitstamp. Na podstawie wyników różnych testów (głównie ilorazu wariancji) potwierdzili, że w przypadku danych cenowych wysokiej częstotliwości Bitcoin nie jest efektywnym rynkiem. Argumentowali oni, że poziom efektywności tego rynku może wynikać z braku odpowiednich regulacji i postawy większości inwestorów, którzy mogą podejmować decyzje inwestycyjne pod wpływem czynników psychologicznych zamiast fundamentalnych. Również wyniki badania przeprowadzonego przez Mbanga (2019) mogą wskazywać, że Bitcoin nie jest rynkiem efektywnym. Podobnie do Urquharta (2017), potwierdził on, że ceny Bitcoina oscylują wokół liczb całkowitych, ale z różną częstością w zależności od dnia tygodnia - najczęściej w piątki, a najrzadziej w poniedziałki.

Większość późniejszych prac również kwestionuje efektywność rynku Bitcoina. W ramach tych badań porównuje się poziom efektywności rynku Bitcoina do jego kształtowania się w przypadku innych kryptowalut albo tradycyjnych inwestycji, takich jak np. złoto, waluty, akcje itd. Podejmuje się również próby określenia czynników związanych z efektywnością rynku kryptowalut.

²⁴ Sytuacja gdy duże zmiany cen następują po sobie.

Caporale i in. (2018) badali długą pamięć szeregu stóp zwrotu z następujących kryptowalut: Bitcoina, Litecoina, Ripple'a, Dasha (największe kryptowaluty pod względem kapitalizacji). Wyszuli oni wniosek, że rynek kryptowalut nie jest efektywny w formie słabej. Jednakże, zauważyli, że poziom efektywności rynku kryptowalut zwiększa się.

Inne badanie (Brauneis i Mestel (2018)) potwierdziło, że poziom efektywności rynku kryptowalut jest pozytywnie związany z płynnością, a rynek Bitcoina jest najbardziej efektywny spośród największych kryptowalut pod względem kapitalizacji. Zatem zauważono, że może istnieć związek pomiędzy kapitalizacją rynkową a poziomem efektywności rynku Bitcoina. Wei (2018) również badał relację między płynnością a poziomem efektywności rynku kryptowalut. Udokumentował, że wykładnik Hursta był silnie powiązany z płynnością danej kryptowaluty i potwierdził, że Bitcoina charakteryzuje najwyższy poziom efektywności w porównaniu do pozostałych 465 badanych kryptowalut. Z drugiej strony, Al-Yahyaee i in. (2018) zaobserwowali, że poziom efektywności rynku Bitcoina (oszacowany za pomocą uogólnionego wykładnika Hursta) jest znacznie mniejszy niż poziom efektywności rynku złota, światowego indeksu akcji MSCI oraz dolara amerykańskiego.

Köchling i in. (2019a) doszli do wniosku, że nie można jednoznacznie stwierdzić, czy cena Bitcoina przed wprowadzeniem kontraktów futures była przewidywalna. Jednakże, zauważyli, że po uruchomieniu kontraktów futures na Bitcoin nie można odrzucić hipotezy o efektywności rynku za pomocą żadnego z zastosowanych testów. Zaobserwowali, że wartość wykładnika Hursta maleje w kierunku poziomu oznaczającego rynek efektywny. W innej pracy, Köchling i in. (2019b) potwierdzili, że w ostatnim czasie opóźnienie w reakcji ceny na nowe informacje dla badanych kryptowalut zmniejszyło się (poziom efektywności informacyjnej się zwiększył), co jest silnie związane z ich płynnością. Chu, Zhang i Chan (2019) analizowali związek między sentymentem wyrażonym w wiadomościach dotyczących kryptowalut a ich poziomem efektywności informacyjnej. Wyniki ich badania nie wskazały jednoznacznie na istnienie tej zależności.

Plastun i in. (2019) analizowali wartości wykładnika Hursta dla kryptowalut (Bitcoin, Ripple, Dash, Litecoin), rynków rozwiniętych, towarów i dwóch rynków rozwijających się (Rosja, Ukraina) w przekroju różnych dni tygodnia. Zaobserwowali, że w latach 2014-2018, badane szeregi czasowe charakteryzowały się różnym stopniem pamięci w zależności od dnia tygodnia, co może wskazywać, że rynek kryptowalut nie jest efektywny w formie słabej. W inny sposób efektywność zweryfikowali Aslan i Sensoy (2020). Przeprowadzili oni badanie

czterech największych kryptowalut (Bitcoin, Ethereum, Ripple i Litecoin), dla których oszacowali wartości wykładnika Hursta wykorzystując różne częstotliwości notowań. Aslan i Sensoy stwierdzili, że poziom efektywności rynku kryptowalut, oszacowany na podstawie notowań o częstotliwości 1 lub 60 minut, jest niższy niż w przypadku wykorzystywania danych z interwałów 5 lub 10 minut. Tran i Leirvik (2020) analizowali słabą formę efektywności rynku w przypadku pięciu największych kryptowalut pod względem kapitalizacji w latach 2013-2019. Potwierdzili, że poziom efektywności informacyjnej kryptowalut zwiększa się. Co więcej, według Tran i Leirvik (2020), Litecoin charakteryzował się najwyższym poziomem efektywności rynku w porównaniu do pozostałych kryptowalut. Takaishi i Adachi (2020) uzyskali wyniki, które przeczą słabej efektywności rynku Bitcoina. Ponadto, zaobserwowali, że poziom efektywności tego rynku zwiększa się, co może być związane ze wzrostem poziomu płynności Bitcoina. Al-Yahyaee i in. (2020) potwierdzili, że im wyższy poziom płynności, tym wyższy poziom efektywności rynku kryptowalut. Natomiast dla zmienności rynku kryptowalut zaobserwowali odwrotną zależność.

Innym czynnikiem, który może być powiązany ze stopami zwrotu uzyskiwanymi na rynku Bitcoina jest wolumen obrotu. Khuntia i Pattanayak (2020) zauważyli, że w czasie hossy lub bessy zmiany w wolumenie obrotu na tym rynku mogą wpływać na stopień długiej pamięci godzinowych stóp zwrotu z Bitcoina. Później, Noda (2021) wykorzystał dane cenowe Bitcoina i Ethereum z okresu 2013-2019 (dla Ethereum początkiem notowań jest rok 2015). Wysnuł on wniosek, że Bitcoin charakteryzuje się wyższym poziomem efektywności niż druga największa kryptowaluta. Podobnie do innych badań, Noda (2021) zauważył również, że po 2013 roku poziom efektywności rynku Bitcoina zwiększa się (z wyjątkiem kilku przypadków). Poza tym, stwierdził, że poziom efektywności rynku Bitcoina i Ethereum wzrasta wraz z płynnością.

Ostatnie badania słabej formy efektywności rynku kryptowalut dotyczą głównie jej poziomu w czasie wysokiej niepewności gospodarczej (także w odniesieniu do innych aktywów). Wang i in. (2021) stwierdzili, że na początku pandemii Covid-19, poziom efektywności rynku Bitcoina, indeksu S&P 500, dolara amerykańskiego i złota zmniejszył się. Jednakże, zauważyli, że zmiana poziomu efektywności rynku Bitcoina była mniejsza niż w przypadku pozostałych badanych rynków, co może świadczyć o posiadaniu przez Bitcoina właściwości przypisywanych do tzw. „bezpiecznej przystani”. Następnie, Assaf i in. (2022) stwierdzili, że po rozpoczęciu pandemii Covid-19, poziom efektywności rynku Bitcoina i

większości badanych przez nich kryptowalut znacząco się zmniejszył. Ponadto zaobserwowali, że w czasie po wystąpieniu bańki spekulacyjnej w 2017 r., poziom efektywności rynku kryptowalut również się zmniejszył. Mensi i in. (2022) doszli do wniosku, że poziom efektywności rynku Bitcoina, indeksu S&P500, obligacji skarbowych USA, dolara amerykańskiego, złota i ropy naftowej obniżył się w czasie pandemii. Jednakże, stwierdzili, że pandemia Covid-19 nie wpływała silnie na zmiany poziomu efektywności rynku Bitcoina w przeciwieństwie do pozostałych kryptowalut. Podobne wyniki do wcześniejszych prac otrzymali Fernandes i in. (2022) konkludując, że poziom efektywności rynku kryptowalut jest w dużym stopniu odporny na nieprzewidywalne szoki gospodarcze takie jak Covid-19. Jednakże, jak wskazał Phiri (2022), zmiany poziomu efektywności rynku Bitcoina nie są odizolowane od wpływu występowania nieprzewidywalnych zdarzeń takich jak Covid-19. Zauważył on, że poziom efektywności rynku szacowany na podstawie szeregu cen Bitcoina stopniowo zmniejsza się w okresach halvingu. Aczkolwiek, Phiri nie potwierdził tych rezultatów dla szeregu stóp zwrotu. Poza tym udokumentował, że na rynku Bitcoina występują efekty kalendarzowe, tzn. stopy zwrotu są bardziej przewidywalne między grudniem a lutym. Mokni i in. (2024) badali znaczenie różnych czynników dla poziomu efektywności rynku Bitcoina i Ethereum w latach 2016-2023. Na podstawie przeprowadzonego testu autokorelacji stóp zwrotu stwierdzili, że kierunek oddziaływania wskaźnika globalnego „stresu” na rynkach finansowych (*Financial stress indicator*) na poziom efektywności rynku nie zmienia się w okresie badania (jest ujemny). Jednakże, Mokni i in. (2024) nie potwierdzili istnienia zależności między poziomem efektywności rynku a indeksami niepewności polityki gospodarczej (EPU) i zmienności (VIX). Ponadto stwierdzili, że płynność rynku jest dodatnio powiązana z poziomem efektywności rynku Bitcoina.

Jak dotąd, niewiele było badań pólilnej formy efektywności rynku kryptowalut. Jedno z nich zostało przeprowadzone przez Vidal-Tomás i Ibañez (2018), którzy wykorzystywali dzienne dane cenowe Bitcoina pobrane z giełd Bitstamp i Mt.Gox dla lat 2011-2017. W celu weryfikacji efektywności rynku, analizowali oni reakcję stóp zwrotu z Bitcoina na wydarzenia dotyczące tej kryptowaluty i polityki monetarnej. Wyniki tego badania wskazują, że poziom efektywności informacyjnej rynku Bitcoina zwiększa się. Ponadto, Vidal-Tomás i Ibañez (2018) doszli do konkluzji, że rynek ten nie jest efektywny w formie pólilnej, ponieważ jego notowania nie reagują na zdarzenia dotyczące polityki monetarnej (Bitcoin jest zintegrowany

z rynkiem walutowym, więc jego cena powinna odzwierciedlać tego typu informacje²⁵). Ponadto stwierdzili, że giełda Bitstamp jest bardziej efektywna informacyjnie niż Mt.Gox.

Podsumowując, badania efektywności rynku kryptowalut dotyczą głównie weryfikacji jego słabej formy i przede wszystkim Bitcoina. Większość z nich potwierdza, że rynek ten nie jest efektywny i charakteryzuje go występowanie długiej pamięci. Początkowo, w ramach badań wskazywano, że poziom efektywności rynku kryptowalut zwiększa się wraz z upływem czasu. Jednakże, wyniki późniejszych badań świadczą o tym, że w ostatnich obejmowanych badaniem latach poziom efektywności rynku kryptowalut zmniejsza się. Podsumowanie wyników dotychczasowych badań efektywności rynku kryptowalut przedstawiono w tabeli 9.

Tabela 9. Badania efektywności rynku kryptowalut

| Rezultaty | Badania |
|---------------------------------|---|
| Rynek nie jest efektywny | Aggarwal (2019), Al-Yahyaee i in. (2018), Alvarez-Ramirez i in. (2018), Bouri i in. (2019), Brauneis i Mestel (2018), Fernandes i in. (2022), Jiang i in. (2018), Khuntia i Pattanayak (2018, 2020), Kristoufek (2018), Plastun i in. (2019), Tiwari i in. (2018), Urquhart (2016), Wei (2018), Vidal-Tomás i Ibañez (2018), Mbanga (2019), Zargar i Kumar (2019) |
| Rynek jest efektywny | Nadarajah i Chu (2017), Urquhart (2017) |
| Malejący poziom efektywności | Assaf i in. (2022), Mensi i in. (2022), Phiri (2022), Wang i in. (2021) |
| Wzrastający poziom efektywności | Bariviera (2017), Caporale i in. (2018), Köchling i in. (2019a), Köchling i in. (2019b), Noda (2021), Takaishi i Adachi (2020), Tran i Leirvik (2020) |

Źródło: Opracowanie własne

Z przeprowadzonego przeglądu badań wynika, że poziom efektywności rynku Bitcoina jest wyższy od jej poziomu zaobserwowanego dla pozostałych kryptowalut. Zatem z perspektywy właściwej alokacji zasobów, Bitcoin jest najbardziej odpowiednią inwestycją (w stosunku do innych kryptowalut). Jednakże, w niektórych badaniach uzyskuje się odmienne rezultaty w zależności od wybranej częstotliwości, dla której pobierane są notowania albo ich postaci (surowe stopy zwrotu a stopy zwrotu podniesione do danej potęgi). Ponadto, rozbieżność występuje w rodzaju wykorzystywanych danych w badaniach. Stosowane są indeksy całego rynku opracowywane przez różne firmy albo ceny transakcyjne pobrane z poszczególnych

²⁵ Bitcoin jest notowany na giełdach w walucie tradycyjnej (np. dolar amerykański). Dlatego jego ceny powinny reagować na zdarzenia dotyczące polityki banku centralnego mające na celu osłabienie/wzmocnienie kursu waluty (np. podwyższenie oprocentowania pożyczek międzybankowych).

giełd, np. Bitstamp. Jednakże, w celu weryfikacji słabej formy efektywności rynku często stosuje się miary należące do tej samej grupy metod, czyli testy korelacji i zależności długookresowych (wykładnik Hursta i jego różne modyfikacje). Innymi popularnymi sposobami weryfikacji słabej efektywności rynku wykorzystywanymi w badaniach kryptowalut są testy ilorazu wariancji i autokorelacji. Zatem w celu zapewnienia porównywalności rezultatów pomiaru poziomu efektywności rynku należałoby opierać się na metodach, źródłach danych i ich postaci, które były często stosowane w poprzednich badaniach. Ponadto, powinno się zachować ostrożność w interpretacji wniosków o zaobserwowanym stopniu losowości cen, ponieważ mogą one różnić się w zależności od wybranej częstotliwości notowań. Klasyfikacja badań ze względu na najczęściej wykorzystywane rodzaje metod i źródła danych została zaprezentowana w tabeli 10.

Tabela 10. Podział badań efektywności rynku kryptowalut ze względu na źródła danych i wykorzystywane metody

| Cecha | Najczęściej wybierane źródła danych lub metody | Przykłady badań |
|---------------|--|---|
| Źródło danych | giełdy Bitstamp | Bouri i in. (2019), Takaishi i Adachi (2020), Urquhart (2017), Vidal-Tomás i Ibañez (2018), Mbanga (2019), Zargar i Kumar (2019) |
| | Bitcoinaverage | Köchling i in. (2019a), Nadarajah i Chu (2017), Urquhart (2016) |
| | Coinmarketcap | Al-Yahyaee i in. (2018), Brauneis i Mestel (2018), Caporale i in. (2018), Fernandes i in. (2022), Köchling i in. (2019b), Noda (2021), Plastun i in. (2019), Wei (2018), Tran i Leirvik (2020) |
| | Coindesk | Aggarwal (2019), Alvarez-Ramirez i in. (2018), Bouri i in. (2019), Khuntia i Pattanayak (2018), Kristoufek (2018), Phiri (2022), Takaishi i Adachi (2020), Tiwari i in. (2018) |
| Metoda | testy korelacji i zależności długookresowych | Aggarwal (2019), Al-Yahyaee i in. (2018), Alvarez-Ramirez i in. (2018), Aslan i Sensoy (2020), Assaf i in. (2022), Brauneis i Mestel (2018), Bariviera (2017), Caporale i in. (2018), Jiang i in. (2018), Khuntia i Pattanayak (2020), Köchling i in. (2019a), Mensi i in. (2022), Plastun i in. (2019), Tiwari i in. (2018), Urquhart (2016), Takaishi i Adachi (2020), Wei (2018) |
| | test ilorazu wariancji | Aggarwal (2019), Brauneis i Mestel (2018), Jiang i in. (2018), Köchling i in. (2019a), Urquhart (2016), Wei (2018) |
| | test autokorelacji | Aggarwal (2019), Brauneis i Mestel (2018), Jiang i in. (2018), Köchling i in. (2019a), Urquhart (2016), Wei (2018) |

Źródło: Opracowanie własne

Wyniki dotychczasowych badań świadczą o tym, że poziom efektywności rynku kryptowalut jest powiązany z płynnością, kapitalizacją, zmiennością oraz wolumenem obrotu na tym rynku. Ponadto, zauważono, że techniczne aspekty Bitcoina (halving) mogą mieć znaczenie dla poziomu efektywności tego rynku (Phiri, 2022). Dlatego, o ile jest to możliwe należałoby uwzględnić te czynniki jako zmienne kontrolne w badaniu. Ponadto, jak dotąd nie potwierdzono jednoznacznie występowania zależności między niepewnością inwestycyjną lub sentymentem inwestorów²⁶ a poziomem efektywności rynku Bitcoina (Chu, Zhang i Chan, 2019; Mokni i in., 2024). W tabeli 11 zaprezentowano przykłady badań czynników związanych z poziomem efektywności rynku kryptowalut.

Tabela 11. Badania czynników efektywności rynku kryptowalut

| Analizowane czynniki | Przykłady badań poziomu efektywności rynku kryptowalut |
|-------------------------|---|
| Halving | Phiri (2022) |
| kapitalizacja | Brauneis i Mestel (2018) |
| niepewność inwestycyjna | Mokni i in. (2024) |
| płynność | Wei (2018), Brauneis i Mestel (2018), Köchling i in. (2019b), Al-Yahyaee i in. (2020), Takaishi i Adachi (2020), Mokni i in. (2024) |
| sentyment inwestorów | Chu, Zhang i Chan (2019) |
| wolumen obrotu | Khuntia i Pattanayak (2020) |
| zmienność | Al-Yahyaee i in. (2020) |

Źródło: Opracowanie własne

Na podstawie dotychczasowych badań nad efektywnością rynku kryptowalut można wyszczególnić także potencjalne czynniki, które mogą wyjaśniać zmiany jej poziomu. Do nich należą m. in. czynniki psychologiczne czy zdarzenia dotyczące regulacji tego rynku. Biorąc pod uwagę to oraz fakt, że poziom efektywności rynku Bitcoina często jest niższy od jej poziomu

²⁶ Autor jest świadomy, że użyte w tym kontekście sformułowanie nie oddaje w pełni znaczenia tego przejawu nieracjonalnego zachowania inwestorów. Jednakże, alternatywne pojęcia, takie jak „nastawienie inwestorów” czy „nastrój inwestorów” także nie odzwierciedlają znaczenia angielskiego terminu „investor sentiment”. Dlatego w niniejszej pracy zastosowano określenie, którego brzmienie jest najbliższe oryginalnego terminu, czyli „sentyment inwestorów”.

zaobserwowanego dla innych rynków, można przypuszczać, że znaczenie tych czynników dla zachowania inwestujących w kryptowaluty jest większe niż w przypadku tradycyjnych inwestycji.

2. Czynniki behawioralne na rynku kryptowalut

2.1 Rola psychologii w inwestowaniu na rynku finansowym

Pierwotnie zakładano, że uczestnicy rynku zachowują się racjonalnie, tzn. podejmują decyzje gospodarcze na podstawie analizy użyteczności różnych wyborów w warunkach ryzyka (Von Neumann i Morgenstern, 1944). Dążenie do maksymalizacji użyteczności można rozumieć jako decyzję konsumenta ukierunkowaną na uzyskanie największej oczekiwanej satysfakcji z wyboru usługi lub produktu (Bernoulli, 1954). W tych warunkach ukształtowało się tzw. klasyczne podejście do finansów, w ramach którego przyjmuje się założenie o racjonalności podmiotów gospodarczych (Barberis i Thaler, 2003). W tym kontekście zakłada się, że uczestnicy rynku prawidłowo oceniają nowe informacje z uwzględnieniem dotychczasowej wiedzy, co powinno doprowadzić do optymalnego wyboru, maksymalizującego oczekiwaną użyteczność inwestora. Zatem racjonalny podmiot gospodarczy powinien maksymalizować użyteczność. Jednakże, w rzeczywistości wydaje się, że uczestnicy rynku mogą różnie interpretować dany komunikat.

Simon (1955) jako jeden z pierwszych zakwestionował popularny wówczas pogląd o racjonalności jednostek ekonomicznych. Zasugerował przyjęcie bardziej realistycznego założenia o racjonalności jednostek gospodarczych, uwzględniając ich faktyczny dostęp do informacji i ograniczone możliwości obliczeniowe. Ponadto zauważył, że podmioty gospodarcze mogą dążyć do satysfakcjonujących wyborów, które nie muszą oznaczać najlepszych opcji. Allais (1953) również krytykował ówczesne pojmowanie racjonalności wskazując, że w rzeczywistości ludzie zachowują się inaczej, niż wynikałoby to z teorii oczekiwanej użyteczności (niespójność preferencji w warunkach zmieniającego się ryzyka). Z czasem brak możliwości wyjaśnienia wszystkich występujących zjawisk rynkowych przez klasyczny model oczekiwanej użyteczności został również dostrzeżony przez innych badaczy, np. Kahnemana i Tverskiego (1979). W konsekwencji powstał nowy nurt badań - finanse behawioralne.

Finanse behawioralne polegają na analizie zachowania uczestników rynku finansowego z perspektywy czynników psychologicznych (Zielonka, 2003). Przykładem zachowania podmiotów gospodarczych, które może mieć podstawy psychologiczne jest odmienna awersja do ryzyka w kontekście strat i zysków. Kahneman i Tversky (1979) zauważyli, że uczestnicy badania jakie przeprowadzili nie doszacowują prawdopodobieństwa uzyskania wyników,

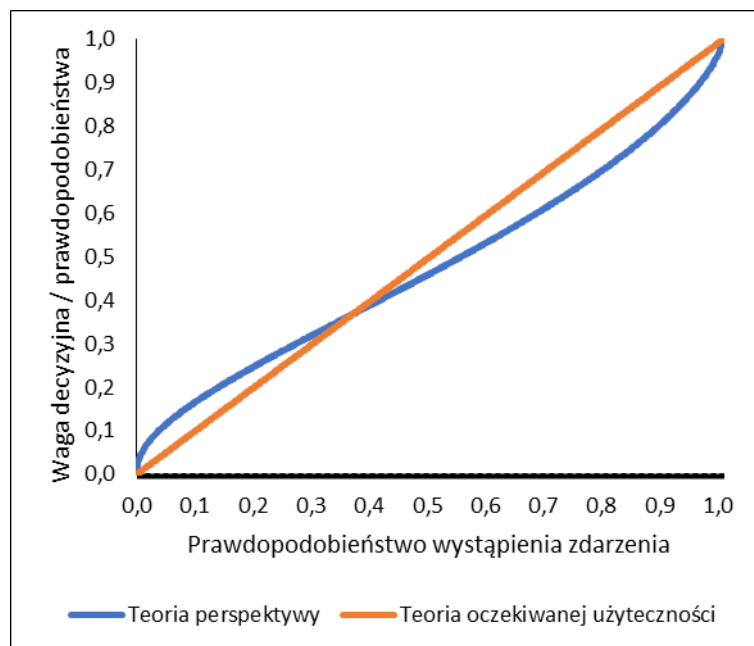
które są możliwe do wystąpienia (ale niepewne) w stosunku do pewnych zdarzeń (efekt pewności). Zatem preferują oni pewny zysk zamiast większego zysku, który nie jest gwarantowany. Może być to związane z traktowaniem pewnych zysków jako już posiadanych i w efekcie, nadawaniu im większej wagi niż niepewnym zyskom (awersja do ryzyka w kontekście zysków). Natomiast, w kontekście straty uczestnicy tego badania zachowywali się odwrotnie, czyli byli bardziej skłonni do podjęcia ryzyka niż do poniesienia pewnych strat. Przyczyną takiego działania może być to, że w obszarze strat przeszacowują oni prawdopodobieństwo wystąpienia zdarzeń rzadkich i większą wagę nadają posiadanemu majątkowi niż jego przyszłym zmianom.

Innym przykładem zachowania inwestorów, które może być efektem oddziaływania czynników psychologicznych jest krótkowzroczna awersja do strat (*myopic loss aversion*). Thaler, Tversky, Kahneman i Schwartz (1997) definiują to zjawisko jako połączenie częstego oceniania wyników inwestycji i większej awersji do strat niż zysków. W tym kontekście można nawiązać do dostrzeżonej przez badaczy prawidłowości, że długoterminowo znacznie wyższe stopy zwrotu uzyskiwano z inwestycji w akcje (w porównaniu do alokacji kapitału w bezpieczne aktywa, takie jak obligacje) (Zielonka, 2003). Według Benartziego i Thalera (1995) może to wynikać z dwóch skłonności inwestorów występujących jednocześnie: awersji do strat i oceniania wyników inwestycji w krótkim okresie. W porównaniu do obligacji, rynek akcji charakteryzuje przeciętnie wyższa zmienność cen. Dlatego inwestorzy bardziej wrażliwi na straty i często oceniający wyniki portfela inwestycyjnego mogą być bardziej skłonni do inwestowania w aktywa o mniejszym ryzyku (np. obligacje). Benartzi i Thaler (1995) zauważyli, że skłonność do inwestycji w akcje może wzrastać wraz z długością okresu oceny inwestycji. Ponadto, stwierdzili, że powodem krótkowzroczonej awersji do strat może być problem agencji. Zarządzający funduszem jest oceniany krótkoterminowo i zazwyczaj pracuje w funduszu krócej niż okres wymagany dla zyskowej inwestycji w akcje (w porównaniu do obligacji). Natomiast udziałowcy chcieliby uzyskiwać jak najwyższe stopy zwrotu, co jest bardziej prawdopodobne przy długoterminowej inwestycji. W ten sposób powstaje konflikt interesów między inwestorami a zarządzającymi ich funduszami.

Zatem inwestorzy mogą inaczej zachowywać się w obszarze zysku i straty, co zostało uwzględnione w teorii perspektywy (*prospect theory*). Teoria perspektywy zakłada, że wybory dokonywane przez jednostki gospodarcze zależą od ich wpływu na zmiany w ich majątku (zysk lub strata). Zysk lub strata są określane względem punktu odniesienia. Dlatego ten sam wybór

można uznać za zysk lub stratę w zależności od przyjętego punktu odniesienia. Przykładowo, rozbieżność między sformułowanym punktem odniesienia a posiadanym majątkiem jednostki (zysk lub strata) może być efektem niepogodzenia się podmiotu z poprzednio poniesioną stratą. W konsekwencji, podmiot będzie umniejszał rzeczywistą wartość zysku lub straty związanych z danym rozwiązaniem nowego problemu decyzyjnego uwzględniając wcześniej poniesioną stratę. W ten sposób wybory mogą być oceniane z perspektywy doświadczenia ludzi. Kahneman i Tversky (1979) doszli do konkluzji, że ludzie odczuwają bardziej straty niż zyski tej samej wielkości. Z tego względu inwestorzy mogą być bardziej skłonni do unikania strat niż osiągnięcia zysków o podobnej wartości. Wśród późniejszych badań również można znaleźć prace potwierdzające, że inwestorzy mogą wykazywać niechęć do strat np. w kontekście zmian w wartości ich majątku (Barberis i in., 2001).

Teoria perspektywy jest alternatywą wobec wcześniej powszechnie przyjmowanej teorii oczekiwanej użyteczności. Jedną z różnic pomiędzy tymi koncepcjami jest to, że w klasycznych finansach zakłada się, że uczestnicy rynku kierują się kryterium maksymalizacji użyteczności, która jest określona jako stan, np. majątku. Natomiast w teorii perspektywy przyjmuje się, że celem działania jednostki jest maksymalizacja zmian w majątku podmiotu (zysk lub strata). Druga różnica pomiędzy tymi nurtami dotyczy postępowania w warunkach ryzyka. Teoria oczekiwanej użyteczności zakłada, że podmioty zazwyczaj wykazują symetryczną awersję do ryzyka w obszarze strat i zysków. Natomiast, finanse behawioralne określają większą awersję do ryzyka w obszarze zysków i skłonność do ryzyka w kwestii strat. Ponadto, w teorii oczekiwanej użyteczności przyjęto, że rezultaty są określane prawdopodobieństwem ich otrzymania. W ramach teorii perspektywy zakłada się, że ludzie również wartościują swoje wybory (nadają im wagi). Subiektywnie określone wagi (znaczenia) konkretnych wyborów mogą różnić się od rzeczywistego prawdopodobieństwa wystąpienia zdarzenia. W efekcie, może to prowadzić do podjęcia nieracjonalnych decyzji. Przykładowe porównanie teorii oczekiwanej użyteczności z teorią perspektywy pod względem wag nadawanym poszczególnym prawdopodobieństwom przedstawiono na wykresie 3.



Wykres 3. Porównanie teorii oczekiwanej użyteczności z teorią perspektywy pod względem funkcji ważenia prawdopodobieństwa

Źródło: Opracowanie własne na podstawie Tversky i Kahneman (1992)

Nadanie odpowiedniego znaczenia informacjom dla podjęcia optymalnej decyzji wydaje się być bardzo trudnym i złożonym zadaniem. Aby dokonać właściwego wyboru, inwestor podejmuje próbę przeanalizowania wielu informacji (np. makroekonomicznych i dotyczących mikrootoczenia rozważanej inwestycji). Przetworzenie wszystkich dostępnych danych przez inwestora jest niemożliwe z uwagi na jego ograniczone zasoby, np. czasu. Co więcej, wybór analizowanych informacji i ocena ich znaczenia dla powodzenia inwestycji mogą następować pod wpływem takich czynników jak np. presja czasu, doświadczenie albo emocje²⁷. Dlatego uczestnicy rynku finansowego mogą przeprowadzić uproszczoną analizę problemu decyzyjnego, co nazywa się heurystyką (Nęcka, Orzechowski i Szymura, 2006, s. 440).

W literaturze przywołuje się różne przykłady heurystyk w podejmowaniu decyzji, które mogą występować także na rynku finansowym. Jedną z nich jest heurystyka dostępności, której występowanie zauważyli Tversky i Kahneman (1973). Według nich, heurystyka dostępności oznacza tendencję do określania prawdopodobieństwo zajścia danego zdarzenia na podstawie własnego doświadczenia lub łatwości, z jaką można przywołać to zdarzenie w pamięci. Na przykład, badane osoby częściej zapamiętywały dane bardziej znanych osób w porównaniu do tych mniej rozpoznawalnych publicznie. Może to wynikać z dokonywania przez

²⁷ Analiza sposobu myślenia ludzi jest zadaniem psychologii poznawczej (Ritter, 2003).

ludzi niepełnej oceny prawdopodobieństwa. To znaczy, w sytuacji gdy podmiot poddaje analizie złożony problem decyzyjny, może on głównie uwzględniać najprostsze i najbardziej dostępne przypadki (rozwiązania, które łatwiej sobie wyobrazić). Wyniki badań przeprowadzonych przez Tverskiego i Kahnemana (1973) potwierdziły, że prawdopodobieństwo wystąpienia zdarzeń, które łatwiej jest sobie wyobrazić może być przeceniane. Innymi słowy, większa dostępność niektórych informacji dotyczących pewnych możliwości może skutkować niedoszacowaniem wagi zdarzeń rzadkich (mniej dostępnych). Zatem heurystyka dostępności może prowadzić do podejmowania nieoptymalnych decyzji.

Wyniki innych badań świadczą o występowaniu heurystyki dostępności również wśród inwestorów. Na przykład, French i Poterba (1991) zauważyli, że w portfelach akcji większości inwestorów przeważają walory krajowe. Argumentowali, że inwestorzy mogą kierować się znajomością tych aktywów. To znaczy, inwestorzy mogą preferować bardziej znane im akcje z uwagi na to, że łatwiej jest im przywołać informacje na ich temat. Podobne wyniki uzyskali Grinblatt i Kolehary (2001) wskazując, że fińscy inwestorzy są bardziej skłonni do inwestycji w akcje fińskich firm, które publikowały raporty w języku ojczystym w porównaniu do spółek udostępniających raporty w obcym języku. Badanie Hubermana (2001) również przeczy racjonalności uczestników rynku odnosząc się do zauważonej tendencji wśród pracowników do posiadania na koncie emerytalnym akcji ich pracodawcy. Nofsinger i Varma (2013) zauważyli, że inwestorzy często odkupują akcje, które ostatnio sprzedali z zyskiem. Takim zachowaniem charakteryzowali się głównie ci uczestnicy rynku, którzy posiadali mniejszą wiedzę o inwestowaniu. Zatem niektórzy inwestorzy są bardziej skłonni do podejmowania decyzji inwestycyjnych na podstawie łatwiej dostępnych informacji, wywołujących pozytywne emocje. Występowanie heurystyki dostępności w podejmowaniu decyzji inwestycyjnych na rynku akcji potwierdziły wyniki późniejszych prac, m. in. Bakar i Yi (2016), Shah, Ahmad i Mahmood (2018).

Tversky i Kahneman (1973) stwierdzili, że człowiek może oceniać szansę zajścia danego zdarzenia opierając się na reprezentatywności (heurystyka reprezentatywności). Reprezentatywność może oznaczać stopień odzwierciedlenia znaczących cech przestrzeni zdarzeń elementarnych (zbiór możliwych przypadków) przez cechy danego zdarzenia²⁸. Przykładowo, jeżeli w rzucie monetą kilka razy z rzędu wypadł orzeł, to osoba ulegająca tej

²⁸ W przypadku rzutu monetą (zdarzenie), zbiór możliwych zdarzeń składa się z orła i reszki, a parametrem rozkładu (cechą) może być udział reszek i orłów.

heurystyce będzie postrzegać, że bardziej prawdopodobne jest otrzymanie w przyszłości reszki niż orła. W rzeczywistości jednak wystąpienie obu tych przypadków jest tak samo prawdopodobne. Zatem podejmowanie decyzji inwestycyjnych na podstawie podobieństwa cech zdarzenia do cech przestrzeni zdarzeń elementarnych może prowadzić do nieracjonalnych wyborów.

Chan, Frankel i Kothari (2003) zauważyli, że uczestnicy rynku finansowego mogą być skłonni do podejmowania decyzji inwestycyjnych na podstawie reprezentatywności zdarzenia. Na przykład, inwestorzy mogą przypisywać akcje firm do danej kategorii opierając się na ostatnio zaobserwowanej sekwencji ich przeszłych wyników. Jednakże, decyzje podejmowane w ten sposób mogą być nieoptymalne, ponieważ taka próba jest ograniczona - nie obejmuje wszystkich możliwych przypadków. W rezultacie inwestorzy mogą kształtować błędne oczekiwania co do prawdopodobieństwa osiągnięcia przez firmy przyszłych wyników. Zatem występowanie heurystyki reprezentatywności może skutkować niedostateczną lub nadmierną reakcją inwestorów na historyczne informacje dotyczące inwestycji, co potwierdzili m. in. Lakonishok, Shleifer i Vishny (1994) oraz Chan i in. (2003).

Chen i in. (2007) doszli do wniosku, że inwestorzy na rynku akcji mogą traktować historyczne stopy zwrotu jako sygnał przyszłego trendu cen, co prowadzi do wystąpienia „błędu reprezentatywności” (*representativeness bias*). Dodatkowo stwierdzili oni, że uczestnicy rynku mogą ulegać heurystyce reprezentatywności przez traktowanie dobrych cech firmy (np. jakość produktów) jako charakterystyk dobrej inwestycji. Późniejsze badania (m in. Waweru, Munyoki i Uliana (2008), Shah, Ahmad i Mahmood (2018)) również potwierdziły, że heurystyka reprezentatywności wpływa na podejmowanie decyzji inwestycyjnych na rynkach akcji.

W literaturze opisuje się także heurystykę afektu. Finucane, Alhakami, Slovic i Johnson (2000) zauważyli, że cechy przedmiotów oraz zdarzeń są skojarzone w różnym stopniu z uczuciami ludzi, a przywołanie wrażeń afektywnych może być łatwiejsze niż ocena zalet i wad lub analiza dotychczasowych przypadków. Dlatego, w ocenie ryzyka i korzyści związanych z problemem decyzyjnym podmioty mogą opierać się na reakcjach afektywnych (pozytywne lub negatywne uczucia), które są stymulowane przez wybrany element obiektu. Takie zachowanie nazywa się heurystyką afektu. Finucane, Alhakami, Slovic i Johnson (2000) przeprowadzili badanie, którego wyniki potwierdziły, że może istnieć odwrotna zależność między oceną ryzyka a oceną korzyści. Można to wyjaśnić za pomocą heurystyki afektu. Jeśli ludzie ulegają

heurystyce afektu, to osoba, u której dany temat wywołuje pozytywne uczucia, oceni wybór (odnoszący się do tego tematu) jako bardziej korzystny i mniej ryzykowny niż pozostali uczestnicy badania, u których ten temat nie zbudza aż tak pozytywnych uczuć.

Podobne wnioski można wysnuć w kontekście zachowania uczestników rynku finansowego. Ganzach (2000) przeprowadził eksperyment, w którym jedna grupa oceniała ryzyko inwestowania na trzydziestu nieznanym międzynarodowych giełdach, a druga grupa miała wskazać oczekiwaną stopę zwrotu z tych inwestycji. Wyniki tej symulacji potwierdziły ujemną korelację pomiędzy oczekiwaną przez uczestników stopą zwrotu a postrzeganym ryzykiem. Ta odwrotna relacja pomiędzy postrzeganym ryzykiem a oczekiwanymi stopami zwrotu wydaje się przeczyć racjonalności - z inwestycji w mało ryzykowne walory raczej oczekuje się niższych stóp zwrotu.

Inną heurystyką jest zakotwiczenie na wybranym punkcie odniesienia (heurystyka zakotwiczenia). Zakotwiczenie inwestorów może wynikać z wcześniej udostępnionej informacji dotyczącej inwestycji. Tversky i Kahneman (1974) zauważyli, że uczestnicy rynku wykazują nadmierną pewność co do wskazywania szans osiągnięcia określonych wartości przez indeks Dow Jones Industrial Average. Wyjaśnili oni, że inwestorzy mogą formułować prawdopodobieństwo zajścia danego zdarzenia na podstawie historycznych maksimów lub minimów indeksu albo wartości podanej w zadanym im pytaniu.

Badanie przeprowadzone przez George'a i Hwanga (2004) wskazało, że odchylenie poziomu cen aktywa inwestycyjnego od jego 52-tygodniowego maksimum jest lepszym predyktorem przyszłych stóp zwrotu niż historyczne zmiany jego cen. Zatem inwestorzy mogą wykorzystywać 52-tygodniowe maksimum jako punkt odniesienia, względem którego oceniają znaczenie informacji dotyczącej danego waloru. Li i Yu (2012) również zauważyli, że możliwe jest zakotwiczenie inwestorów na historycznych szczytach notowań indeksów giełdowych. Ponadto zaobserwowali, że historyczne maksima cen indeksu giełdowego lepiej odzwierciedlają przyszłe stopy zwrotu z inwestycji niż zmienne makroekonomiczne (np. miesięczna inflacja). Wyniki późniejszych badań, m. in. Waweru i in. (2008), Shah, Ahmad i Mahmood (2018) również wykazały, że uczestnicy rynku akcji mogą ulegać heurystyce zakotwiczenia w podejmowaniu decyzji inwestycyjnych.

Tversky i Kahneman (1974) zauważyli, że występowanie heurystyki zakotwiczenia wśród decydentów może prowadzić do ich nadmiernych lub zbyt małych oczekiwań względem złożonych zdarzeń. Według Griffina i Tverskiego (1992), nadmierna lub zbyt mała pewność

siebie może być związana z poziomem sentymentu wyrażonego przez treść komunikatu - czy jest on odbierany jako bardzo pozytywny lub negatywny przez jego odbiorców. Do nadmiernej lub zbyt małej pewności siebie przyczynia się również niewystarczające skupienie na rzeczywistej wadze lub wiarygodności informacji (np. wielkość próby, wiarygodność publikującego informację). Zatem nadmierną pewność siebie obserwuje się, gdy poziom sentymentu wywołanego przez treść informacji jest wysoki (np. bardzo pozytywny odbiór komunikatu przez jego odbiorców), a jej waga (znaczenie) mała. W odwrotnym przypadku może dojść do sformułowania zbyt małych oczekiwań przez inwestorów.

Niewystarczająca lub nadmierna reakcja inwestorów na informacje rynkowe może być również efektem zjawiska „wybiórczej atrybucji” (*self-attribution*). To znaczy, jeśli po podjęciu decyzji inwestycyjnej pojawiają się informacje, które potwierdzają słuszność zawarcia transakcji, może wzrosnąć przekonanie inwestora o własnych umiejętnościach. W takim przypadku inwestor może uważać swoje umiejętności i wiedzę za większe niż są w rzeczywistości. W efekcie może on dokonać kolejnej takiej samej transakcji. W ten sposób powstaje nadmierna reakcja inwestorów na informacje, która może prowadzić do wystąpienia krótkoterminowego efektu momentum. Jednakże, w długim okresie kolejne informacje powodują, że cena rynkowa zbliża się do wartości fundamentalnej inwestycji, co jest widoczne w postaci długoterminowego odwrócenia trendu cen akcji (Daniel, Hirshleifer i Subrahmanyam, 1998).

Podobny schemat myślenia inwestorów można przedstawić w kontekście „pułapki potwierdzenia”. Jest to sytuacja gdy podmiot, po podjęciu decyzji, poszukuje lub interpretuje dostępne informacje w sposób potwierdzający jego zdanie (Nickerson, 1998). Taki mechanizm działania może wynikać z preferowania przyjemnych uczuć (np. wywołanych „trafną” decyzją) ponad nieprzyjemne. W konsekwencji inwestor może ignorować wiadomości niezgodne z jego opinią, mimo, że mogą być one znaczące dla wartości inwestycji. Informacja potwierdzająca przekonanie inwestora może zwiększać jego skłonność do niezmienniania wcześniej podjętej decyzji. Badanie przeprowadzone przez Pouget i Villeneuve (2011) pokazało, że długie trzymanie się swojej opinii przez inwestorów ulegających pułapce potwierdzenia może przyczyniać się do nagłego wzrostu (nieadekwatnego do rzeczywistej wartości inwestycji) i spadku cen na rynku finansowym (krótkoterminowy efekt *momentum*). W tym kontekście „potwierdzająca” informacja może być traktowana jako wzmocnienie sygnału inwestycyjnego dla uczestników rynku finansowego.

Reakcje uczestników rynku na udostępnione informacje mogą wynikać z ich sentymentu²⁹ (Barberis, Shleifer i Vishny, 1998). Jeżeli spółka notowana na giełdzie ogłasza następujące po sobie wiadomości o wzroście jej zysków, to jest możliwe, że inwestujący będą nadmiernie optymistyczni co do jej przyszłych wyników finansowych. W efekcie będą oni wskazywali coraz wyższe prawdopodobieństwo zachowania dotychczasowego trendu cen akcji tej spółki. Taki sposób myślenia inwestorów może doprowadzić do ich nadmiernej reakcji na informacje i następnie do nieadekwatnie wysokiej ceny akcji. Aczkolwiek, w długim okresie ceny tego aktywa mogą lepiej odzwierciedlać rzeczywiste znaczenie opublikowanych informacji na jego temat (efekt *mean-reversion*). Zatem w krótkim okresie możliwe jest zaobserwowanie dużego wpływu sentymentu inwestorów na ich decyzje.

Dotychczas potwierdzono, że istnieje negatywny związek pomiędzy sentymentem inwestorów a przyszłymi stopami zwrotu uzyskiwanymi na rynku akcji (Fisher i Statman, 2000; Schmeling, 2009). Baker i Wurgler (2006) zauważyli, że sentyment może mieć większe znaczenie dla papierów wartościowych, których ceny są wysoce subiektywne, tzn. bardziej zależne od zmian popytu spekulacyjnego. Takie inwestycje nie posiadają odpowiednio długiej historii notowań, cechuje je wysokie ryzyko osiągnięcia sukcesu i porażki (np. akcje małych lub młodych spółek, firm o bardzo zmiennej wycenie rynkowej). Baker i Wurgler (2006) wykazali, że wysokie natężenie sentymentu inwestorów³⁰ jest związane z występowaniem w przyszłości niskich stóp zwrotu z tego typu akcji (i odwrotnie). Może to świadczyć o nadmiernym (niedostatecznym) optymizmie inwestorów co do przyszłej wartości „subiektywnych” inwestycji.

Zdaniem Zielonki (2003), do powstania nadmiernej pewności siebie inwestorów może przyczyniać się pozorne odczuwanie posiadania kontroli nad przyszłymi stopami zwrotu z inwestycji (tzw. iluzja kontroli). Odczuwanie „iluzji kontroli” może być wzmocnione przez kilka cech. Jedną z nich jest zapewnienie inwestorowi możliwości niezależnego wyboru walorów, które będą wchodziły w skład jego portfela inwestycyjnego. Może to skutkować odczuwaniem większej kontroli nad zachowaniem cen składników jego portfela niż w rzeczywistości. Do

²⁹ Sentyment inwestorów można zdefiniować jako optymizm bądź pesymizm uczestników rynku dotyczący inwestycji (Baker i Wurgler, 2006). Dlatego w rozprawie doktorskiej wyróżniono pozytywny (i negatywny) sentyment, co można rozumieć jako optymistyczne (pesymistyczne) nastawienie inwestorów odnośnie do przyszłych zmian cen inwestycji.

³⁰ Natężenie sentymentu inwestorów można zdefiniować jako siłę optymizmu lub pesymizmu wśród uczestników rynku w stosunku do przyszłej wartości inwestycji.

wzrostu pewności siebie inwestora może również dojść w sytuacji, gdy decyzja wcześniej przez niego dokonana zostaje potwierdzona kolejnymi wynikami, np. wzrostem cen po kupnie papieru wartościowego. Zatem odnosi się to do pułapki potwierdzenia oraz efektu wybiórczej atrybucji. Ponadto inwestorzy mogą ulegać iluzji kontroli opierając się na znajomości inwestycji (heurystyka dostępności). Na przykład, im bardziej popularny jest przedmiot inwestycji, tym silniejsze może być wrażenie jego znajomości (mimo, że w rzeczywistości można posiadać małą wiedzę o tym zagadnieniu). W konsekwencji, inwestor może odczuwać nadmierną kontrolę nad cenami wysoce popularnego aktywa inwestycyjnego.

Zielonka (2003) zauważa również, że inwestorzy mogą popełniać błędy myślenia wstecznego, tzn. po zajściu danego zdarzenia zmieniają oni wcześniej określoną przez nich szansę jego wystąpienia. Powodem takiego zachowania inwestorów może być obrona przed utratą własnej dumy. Możliwe jest również inne wytłumaczenie tego zjawiska - nowa informacja jest traktowana przez inwestora jako znacznie ważniejsza niż dotychczasowa wiedza o tym zdarzeniu, ponieważ lepiej określa ona rzeczywistość (w porównaniu do poprzednich informacji dotyczących tylko możliwych przypadków). W efekcie zmienia się znaczenie nadawane informacjom i określone na tej podstawie prawdopodobieństwo wystąpienia danego przypadku.

Innym zjawiskiem, które może prowadzić do nieoptymalnego zachowania inwestorów jest efekt utopionych kosztów. Oznacza to chęć podmiotu do kontynuowania inwestycji ze względu na zaangażowanie zasobów w przeszłości (czasu, siły, kapitału). Występowanie efektu kosztów utopionych potwierdzili Arkes i Blumer (1985). Zauważyli oni, że podmioty, które wcześniej poniosły koszt utopiony w odniesieniu do danego projektu, wskazują wyższe prawdopodobieństwo jego sukcesu od tych, które wcześniej nie zaangażowały zasobów w ten projekt. Zatem niektórzy inwestorzy mogą przyjmować wyższe prawdopodobieństwo uzyskania dodatnich stóp zwrotu z inwestycji, na analizę których poświęcili już dane zasoby (w porównaniu do tych, na które wcześniej nie ponieśli kosztów).

Księgowanie mentalne (*mental accounting*) jest kolejnym przykładem nieracjonalnego zachowania inwestorów. Według Thaler (1999), polega ono na dokonywaniu przez podmioty pewnych operacji poznawczych w celu organizowania, oceniania lub śledzenia ich działań finansowych. To znaczy, podmiot może analizować koszty i zyski związane z pewnymi wyborami rozłącznie („na osobnych kontach”), podczas gdy powinny one być rozważane razem. W efekcie może to prowadzić do negowania zachodzących zależności między tymi

wyborami, a następnie do podjęcia mniej opłacalnej decyzji (Ritter, 2003). W jednej z pierwszych prac nad księgowaniem mentalnym, Thaler (1985) podał przykład nieoptymalnego działania konsumenta, który zaciąga kredyt i posiada porównywalną kwotę zdeponowaną na lokacie. W tym przypadku koszt kredytu jest znacznie wyższy od zysków z lokaty. Zatem wydaje się, że jest to nieopłacalny wybór. Wyjaśnieniem takiego działania konsumenta może być rozłączne ocenianie tych wyborów, tzn. dokonywanie „księgowania” tych operacji na osobnych kontach, co może wynikać z innych celów tych działań. W tym kontekście, Shefrin i Statman (1984) zaobserwowali, że inwestorzy preferują dywidendy nad zyski kapitałowe, mimo że mogą mieć one taką samą wartość (przy założeniu braku podatków). Zatem możliwe jest, że inwestorzy dokonują analizy dywidend i zysków kapitałowych oddzielnie. Wytłumaczeniem takich preferencji inwestora może być zapewnienie mechanizmu „samokontroli”, który występuje w przypadku regularnych wypłat dywidendy (Shefrin i Statman, 1984). Inwestor może odczuwać, że otrzymanie dywidend zapewnia większą kontrolę nad własnymi oszczędnościami niż w przypadku wzrostu ceny akcji o podobną wartość.

W późniejszym artykule, Shefrin i Statman (1985) zaproponowali inną koncepcję opisującą nieoptymalne zachowanie inwestora - efekt dyspozycji. To zjawisko można przedstawić jako nadmiernie długie przetrzymywanie akcji spółek, które traciły na wartości i przedwczesną sprzedaż walorów, które charakteryzował wzrostowy trend ich cen. Może być to spowodowane dumą inwestora, która przyczynia się do chęci zakończenia inwestycji z zyskiem (zamiast realizacji straty, która jest związana z odczuwaniem żalu). Dlatego, w celu uniknięcia negatywnych odczuć, inwestorzy mogą zbyt długo zwlekać ze sprzedażą akcji, których ceny spadają (odwrotna tendencja występuje w sytuacji pozytywnych uczuć inwestora - dumy). Shefrin i Statman (1985) na podstawie badania długości okresu przetrzymywania akcji zyskowych i stratnych potwierdzili istnienie efektu dyspozycji wśród inwestorów. Barber i Odean (1999), wykorzystując dane o rachunkach inwestorów zauważyli, że akcje, których cena wzrosła o ponad 50 procent, były częściej sprzedawane niż akcje tracące na wartości. Może to świadczyć o występowaniu efektu dyspozycji wśród inwestorów.

Efekt „status quo” jest przykładem zachowania inwestorów, które może przeczyć logice. Samuelson i Zeckhauser (1988) zauważyli, że w podejmowaniu decyzji dotyczących gromadzenia kapitału emerytalnego (wybór między oszczędzaniem w funduszu „bezpiecznych” aktywów a inwestowaniem w akcje), część podmiotów nieracjonalnie

utrzymywało „status quo”. Uszczegóławiając, starsi pracownicy (zbliżający się do emerytury) nie zmieniali pierwotnie wybranej strategii inwestycyjnej (fundusz akcji) pomimo, że istniała możliwość darmowego przesunięcia środków na fundusz „bezpiecznych” aktywów. W tym czasie nowi uczestnicy funduszu lokowali kapitał w „bezpieczniejsze” aktywa, co mogło być związane z kondycją rynku akcji w tym okresie. Zatem w tym czasie racjonalni pracownicy w wieku przedemerytalnym powinni wybierać „bezpieczniejszy” fundusz zamiast akcji. Jak twierdzą Samuelson i Zeckhauser (1988), przyczyną efektu „status quo” może być większe odczuwanie potencjalnej straty wynikającej ze zmiany stanu dotychczasowego niż potencjalnych zysków z alternatywnej możliwości. Preferowanie dotychczas posiadanej formy oszczędzania kapitału nad jej zmianą jest nazywane efektem posiadania (*endowment effect*).

W literaturze można znaleźć badania nawiązujące do wpływu przeszłych doświadczeń inwestora na jego skłonność do podejmowania ryzyka. Na podstawie przeprowadzonych eksperymentów, Thaler i Johnson (1990) zauważyli występowanie efektów „na koszt firmy” (*house money effect*) i wyrównywania strat (*break-even effect*). Efekt „na koszt firmy” oznacza wzrost chęci inwestora do ponoszenia ryzyka w kontekście wcześniejszego odnotowania zysków. Powodem takiej postawy inwestora może być mniejsze odczuwanie potencjalnej straty, która może być pokryta z wcześniej „wygranych” pieniędzy (w przeciwieństwie do sytuacji, w której miałby on stracić tylko swoje oszczędności) (Thaler i Johnson, 1990). W przypadku wcześniejszych strat z inwestycji, może dojść do wystąpienia efektu wyrównywania strat - sytuacja, w której poniesione wcześniej straty zwiększają skłonność inwestora do ponoszenia ryzyka. Wyjaśnieniem tego zjawiska może być odczuwanie przez inwestora smutku związanego z doznaną w przeszłości stratą i chęci „odegrania się” w przyszłości. W tej sytuacji podmiot może przyjąć pewien poziom ryzyka, który wcześniej nie byłby dla niego akceptowalny (Thaler i Johnson, 1990).

Inne zjawisko, które jest przejawem nieracjonalnego zachowania, zauważył Festinger (1962). Według niego, jeśli podmiot próbuje dopasować dwa elementy informacji, które są ze sobą niespójne, może powstać tzw. dysonans poznawczy. Elementami informacji mogą być zachowania, uczucia, opinie itd. Zatem dysonans poznawczy jest związany z niespójną relacją między elementami informacji. W reakcji na powstały dysonans, podmiot może próbować zmienić elementy informacji w celu przywrócenia lub stworzenia spójności między nimi, np. zmienić swoją opinię oraz zachowanie. W efekcie podmiot może błędnie postrzegać rzeczywistość. Na przykład, po zakupie akcji jej cena spada. Jednakże, w tym czasie pojawia się

informacja o poprawiającej się koniunkturze gospodarczej. Zatem powstaje wtedy dysonans poznawczy między ujemną stopą zwrotu z inwestycji a dobrą wiadomością rynkową. W celu jego redukcji, podmiot może zmienić swoje przekonanie o atrakcyjności tej inwestycji albo pogłębić uzasadnienie wcześniej podjętej decyzji inwestycyjnej (następuje zwiększenie wagi decyzji wcześniej dokonanej).

W kontekście rynku finansowego można znaleźć badania, które potwierdzają występowanie dysonansu poznawczego wśród inwestorów. Na przykład, Antoniou, Doukas i Subrahmanyam (2013) zaobserwowali, że w okresach pozytywnego sentymentu „drobni” inwestorzy nie wykazują chęci do szybkiego pozbywania się akcji o najniższych stopach zwrotu. Może to wynikać z chęci redukcji dysonansu poznawczego pomiędzy uzyskiwanymi stopami zwrotu z inwestycji a sentymentem inwestorów. Pomimo pojawienia się złych informacji inwestorzy mogą mieć optymistyczne oczekiwania co do tych inwestycji.

Zachowania inwestorów mogą mieć charakter społeczny. Przykładem tego typu zjawiska jest kaskada informacyjna, która polega na ignorowaniu prywatnych informacji³¹ i naśladowaniu decyzji innych uczestników rynku w oparciu o ogólnodostępne informacje o ich działaniach. Takie zachowanie inwestora może wynikać z nadawania większego znaczenia (wiarygodności) posiadanym przez innych prywatnym informacjom niż tym, do których on sam ma dostęp (Szyszka, 2009, s. 85-86). Efektem tego zachowania może być wystąpienie bańki spekulacyjnej na rynku. Alevy, Haigh i List (2007) zauważyli, że część uczestników badania ignorowało swoje prywatne informacje, co mogło prowadzić do powstania kaskady informacyjnej. Co więcej, stwierdzili, że profesjonalni uczestnicy rynku w większym stopniu wykorzystywali swoje prywatne informacje i bardziej opierali swoje decyzje na jakości publicznej informacji (w porównaniu do badanych studentów). Zatem wydaje się, że kaskady informacyjne będą w mniejszym stopniu występowały na rynku, na którym udział profesjonalistów jest stosunkowo większy.

Innym społecznym zjawiskiem są zachowania stadne (*herding*). Ten przejaw nieracjonalnego zachowania inwestorów może wynikać także z czynników innych niż tylko informacje, tzn. interakcji pomiędzy uczestnikami rynku (Szyszka, 2009, s. 84). Przykładowo, wybór danego waloru przez wiele osób może sygnalizować jego jakość (korzyści zewnętrzne) (Alevy i in., 2007). Ponieważ zwiększenie popytu na rynku może skutkować wzrostem ceny

³¹ Przekonania, opinie inwestorów, czy nieujawnione informacje, do których mają oni dostęp itp.

waloru, w tej sytuacji nieracjonalnie zachowujący się inwestor zdecyduje się nabyć tę inwestycję. Dzieje się tak, ponieważ może on postrzegać, że wzrost ceny waloru świadczy o dostępie do prywatnych informacji przez innych uczestników rynku (Szyszka, 2009, s. 89).

Według Bikhchandani i Sharma (2000), *herding* można rozumieć na dwa sposoby. Po pierwsze, można sobie wyobrazić, że podmiot dokonuje inwestycji nie wiedząc, czy pozostali uczestnicy rynku faktycznie podjęli decyzję o kupnie lub sprzedaży papieru wartościowego. W tej sytuacji, jeżeli podmiot rozezna, że inni uczestnicy rynku nie inwestują, to również nie będzie już inwestował (inwestor zmienia decyzję naśladowując innych). Może również zaistnieć odwrotna sytuacja. Po dokonaniu obserwacji, że inni inwestują, uczestnik rynku zmienia wcześniej podjętą decyzję z nieinwestowania na inwestowanie. Naśladownictwo inwestora może wynikać z jego konformizmu lub przypuszczenia, że inni uczestnicy rynku mają dostęp do informacji, które nie zostały jeszcze opublikowane. Zachowania stadne mogą przejawiać się występowaniem efektu *momentum*, czyli skłonności inwestorów do wykorzystywania strategii inwestycyjnych zakładających kontynuację historycznych trendów cen aktywa inwestycyjnego (chęć naśladowania wcześniejszych działań inwestorów). Lin, Tsai i Lung (2013) potwierdzili, że zachowania stadne prowadzące do nieoptymalnych decyzji mogą istnieć na rynku akcji. Zauważyli, że istnieje negatywna korelacja między zachowaniem stadnym indywidualnych inwestorów (np. kupno akcji) a przyszłymi stopami zwrotu z tych walorów.

Nieracjonalne zachowania mogą wynikać z tzw. efektu sformułowania (*framing*). Polega on na odpowiedniej prezentacji problemu decyzyjnego, która wpływa na odczucie osoby zaangażowanej w jego rozwiązanie. Na przykład, może to skłaniać konsumenta do podjęcia sugerowanej przez sprzedającego decyzji mimo, że np. cena produktu po obniżce jest taka sama jak pewien czas temu (Ritter, 2003). Zmienność preferencji uczestników rynku na skutek przedstawienia tego samego problemu w różny sposób została zauważona przez Kahnemana i Tverskiego (1979).

Framing może przyjmować postać pozytywnego przedstawienia cechy danego produktu w celu skłonienia konsumenta do podjęcia określonej decyzji. Inną możliwością jest zaprezentowanie informacji w taki sposób, by możliwość uzyskania pewnej straty najlepiej oddziaływała na obiorcę wiadomości. W celu uniknięcia pewnej straty inwestor będzie skłonny do podjęcia ryzyka (*framing* decyzji ryzykownych). Przykładem jest reklama inwestycji wskazująca malejącą wartość pieniądza w ciągu ostatnich lat (pewna strata), co może

skutkować zwiększoną skłonnością do inwestowania u jej odbiorcy. *Framing* celu może przyjąć formę pozytywnego przedstawienia skutku podjęcia sugerowanego działania lub negatywnego sformułowania skutku niewykonania określonego zadania. Odbiorcy takiego komunikatu mocniej odczuwają negatywne skutki (strata) niezrealizowania sugerowanego działania niż zysk z jego realizacji. Dlatego podkreślenie negatywnych skutków niewykonania sugerowanej decyzji może skłonić odbiorców komunikatu do jej podjęcia (Zielonka, 2017). Na przykład, podkreślenie informacji o prawdopodobnej utracie nieubezpieczonego majątku może skłonić konsumenta do jego ubezpieczenia. Awersja do strat może spowodować, że podmiot będzie bardziej odczuwał negatywne skutki nieubezpieczenia majątku niż jego ubezpieczenia (koszt jego zakupu). Podsumowanie zaobserwowanych przejawów nieracjonalnego zachowania inwestorów usystematyzowanych według kryterium ich głównych przyczyn przedstawiono w tabeli 12.

Tabela 12. Systematyka przejawów nieracjonalnego zachowania inwestorów na rynku finansowym

| Źródła nieracjonalnego zachowania i myślenia inwestorów | Przejawy nieracjonalnego zachowania inwestorów |
|--|---|
| Emocje | pułapka potwierdzenia, sentyment inwestorów, awersja do strat, błąd myślenia wstecznego, efekt kosztów utopionych, księgowanie mentalne, efekt dyspozycji, efekt „status quo”, efekt „na koszt firmy”, efekt wyrównywania strat, krótkowzroczna awersja do strat, heurystyka afektu, efekt sformułowania, zachowania stadne |
| Ograniczone zasoby | heurystyka dostępności, heurystyka reprezentatywności, heurystyka zakotwiczenia, heurystyka afektu |
| Spółeczność (podejmowanie decyzji odnosząc się do działań innych osób) | kaskada informacyjna, zachowania stadne |
| Błędne poznanie (interpretacja) rzeczywistości | efekt wybiórczej atrybucji, pułapka potwierdzenia, iluzja kontroli, błąd myślenia wstecznego, księgowanie mentalne, efekt posiadania, efekt „na koszt firmy”, efekt wyrównywania strat, krótkowzroczna awersja do strat, dysonans poznawczy, zachowania stadne |

Źródło: Opracowanie własne na podstawie Zielonka (2003)

Podsumowując, wspomniane badania nad zachowaniem uczestników rynku finansowego wskazują, że mogą oni działać nieracjonalnie na skutek ograniczeń naturalnych, motywów

emocjonalnych, społecznych lub zniekształceń poznawczych. Po pierwsze, ograniczenia mogą dotyczyć trudności w analizie złożonego problemu decyzyjnego przez to, że człowiek posiada ograniczone zasoby, co może przyczynić się do ulegania heurystykom. Po drugie, człowiek jako istota emocjonalna kojarzy pewne zdarzenia oraz ich cechy jako mniej lub bardziej pozytywne bądź negatywne, co może skutkować zniekształcaniem postrzegania rzeczywistości w celu odczuwania tylko pozytywnych wrażeń. Duże natężenie emocji może przyczyniać się do zwiększonych oczekiwań inwestujących co do przyszłości inwestycji. Wysoka popularność inwestycji może wzmacniać naśladowcze zachowania inwestorów. Uczestnicy rynku finansowego, będącego przedmiotem znacznego zainteresowania ze strony mediów społecznościowych, mogą bardziej oddziaływać na innych przez możliwość łatwiejszego komunikowania się osób podobnie myślących. Ponadto, częste publikowanie informacji może prowadzić do zniekształceń w postrzeganiu rzeczywistości. Konkludując, natężenie emocji, zależność od działań innych (społeczność), złożoność publikowanych informacji na rynku finansowym i trudność w ich analizie mogą przyczyniać się do podejmowania nieoptymalnych decyzji inwestycyjnych. W przypadku wymienionych przejawów nieracjonalnego zachowania, interakcje różnych czynników mogą przyczyniać się do ich wystąpienia. Jednakże, emocje są źródłem większości zaobserwowanych zniekształceń w myśleniu i działaniu uczestników rynku finansowego. Dlatego można przypuszczać, że odgrywają one największą rolę w podejmowaniu nieoptymalnych decyzji przez inwestorów.

2.2 Pomiar natężenia czynników behawioralnych

Czynniki behawioralne można zdefiniować jako czynniki, których oddziaływanie na zachowanie inwestorów³² może nie być uzasadnione racjonalnie (Schabek, 2016, s. 13). Należą do nich m. in. heurystyki, zachowania stadne, sentyment inwestorów, awersja do strat itd. Natężenie tych czynników może wynikać z oddziaływania pomiędzy elementami motywacji działania inwestorów (emocje, ograniczone zasoby, społeczność, błędne poznanie rzeczywistości itd.) a dostępnymi informacjami. Na przykład, wzrost wartości akcji może powodować odczucie sukcesu u inwestorów, którzy nabyli je po niższej cenie. Sukces tych inwestorów i wzrastająca wartość inwestycji mogą przyciągać uwagę mediów. Jednocześnie

³² Zachowanie inwestorów może być mierzone bezpośrednio lub pośrednio przez mierniki zachowania rynku, np. stopy zwrotu, ceny aktywa inwestycyjnego i ich zmienność.

wzrasta entuzjazm i oczekiwania odnośnie do dalszych wzrostów cen akcji. W efekcie, możliwe są kolejne wzrosty cen (Shiller, 2003).

W literaturze istnieją różne sposoby pomiaru natężenia czynników behawioralnych, które można podzielić ze względu na rodzaj wykorzystywanych danych, tzn. dane pierwotne lub wtórne. Metodą opierającą się na danych pierwotnych jest obserwacja (symulacja) sytuacji decyzyjnej. Polega ona na przeprowadzeniu wywiadu (Ahmad i Wu, 2023) lub uzyskaniu odpowiedzi na zadane pytania (lub stwierdzenia) w formie kwestionariuszy (Hafez, 2021). Wywiad może być przeprowadzany na podstawie sformułowanego wcześniej pytania. Ponadto, może mieć on postać dyskusji na dany temat, aby poznać opinię respondenta. W rezultacie, możliwe jest poznanie sposobu myślenia inwestorów czy identyfikacja heurystyk (Ahmad i Wu, 2023).

Wykorzystanie kwestionariuszy charakteryzuje się mniejszą elastycznością niż w przypadku wywiadów - w trakcie wywiadu można modyfikować czy zadawać dodatkowe pytania. Jednakże, wywiady są bardziej czasochłonne. Kwestionariusze mogą zawierać szereg stwierdzeń lub pytań, na które respondent ma odpowiedzieć w określonej formie, np. poprzez wskazanie stopnia zgodności z danym stwierdzeniem (zazwyczaj przy wykorzystaniu skali Likerta). Zadawane pytania czy stwierdzenia mają na celu ujawnienie czynników behawioralnych, które oddziałują na podejmowanie decyzji inwestycyjnych przez uczestników badania (Zahera i Bansal, 2018). Na przykład, występowanie heurystyki dostępności można stwierdzić na podstawie pytania o podejmowanie decyzji na podstawie ostatnich doświadczeń (Al-mansour, 2020).

Po zebraniu danych można przeprowadzić analizę statystyczną zakodowanych odpowiedzi respondentów. Dzięki temu można stwierdzić czy i w jakim stopniu czynniki behawioralne oddziałują na podejmowanie decyzji inwestycyjnych. Na przykład, Almansour i Arabyat (2017) badali znaczenie czynników behawioralnych dla decyzji inwestycyjnych w kontekście podejmowania ryzyka. W tym przypadku model regresji może wyglądać następująco:

$$DM = \alpha + \sum_{i=1}^n \beta_i \cdot \text{czynnik behawioralny}_i + \varepsilon, \quad (21)$$

gdzie DM to zmienna oznaczająca skłonność do ryzyka w kontekście podejmowania decyzji inwestycyjnych (zgodność ze stwierdzeniem oznaczającym daną sytuację decyzyjną, np. wartości od 1 do 5), β to współczynnik przy „ i ” badanym czynnikiem behawioralnym, n to liczba badanych czynników behawioralnych, α to wyraz wolny, ε oznacza składnik losowy.

Wadą wykorzystania obserwacji sytuacji decyzyjnej jako sposobu pomiaru natężenia czynników behawioralnych może być czasochłonny proces zbierania danych, a następnie ich analizy. Innym problemem związanym z wykorzystaniem obserwacji sytuacji decyzyjnej jest fakt, że w trakcie jej stosowania wykorzystuje się dane zebrane tylko w pewnym czasie, przez co wyniki odnoszą się jedynie do krótkiego okresu. W przypadku pomiaru zjawiska dla długiego okresu (np. 10 lat) należałoby powtarzać proces zbierania danych co pewien czas - inwestorzy mogą inaczej działać w okresie wysokiej i niskiej niepewności na rynku. W efekcie proces zbierania danych może być bardzo pracochłonny. Innym ograniczeniem tego sposobu pomiaru czynników behawioralnych jest deklaratywność. Respondenci mogą zadeklarować, że w podejmowaniu decyzji inwestycyjnych biorą pod uwagę dany czynnik, jednak w rzeczywistości może być inaczej (i na odwrót).

Z powyższych rozważań wynika, że sposoby pomiaru natężenia czynników behawioralnych opierające się na danych pierwotnych cechują się różnymi ograniczeniami. Pomimo tego, są one powszechnie wykorzystywane w badaniach zachowania inwestorów na tradycyjnych rynkach finansowych. Analizy przeprowadzone z wykorzystaniem tych metod często potwierdzają występowanie heurystyk czy przejawów nieracjonalnego zachowania inwestorów (Bakar i Yi, 2016; Javed i in., 2017; Dickason i Ferreira, 2018).

W badaniach coraz częściej stosuje się jednak sposoby aproksymowania natężenia czynników behawioralnych, które opierają się na danych wtórnych. Do zalet wykorzystania tego typu danych należy zaliczyć możliwość automatyzacji ich analizy oraz dostępność długich szeregów czasowych. Wadą przypisywaną do większości z nich może być brak możliwości jednoznacznej interpretacji uzyskanych wyników. Innymi słowy, jedna miara może pośrednio odnosić się do różnych przejawów nieracjonalnego zachowania (czynniki behawioralne mogą wzajemnie na siebie oddziaływać). Na przykład, zachowania stadne mogą być aproksymowane za pomocą modeli rozproszenia stóp zwrotu. Ponadto wysokie natężenie sentymentu może powodować nadmiernie pozytywne oczekiwania inwestorów odnośnie wartości inwestycji, co może prowadzić do występowania zachowań stadnych. Zatem trudno jest stwierdzić, który przejaw nieracjonalnego zachowania inwestorów ma największą wagę w kontekście danej aproksymanty. Jednakże, można określić przejawy nieracjonalnego zachowania inwestorów, które odnoszą się do poszczególnych sposobów pomiaru, co szczegółowo przedstawiono w tabeli 13.

Tabela 13. Czynniki behawioralne i ich pomiar

| Czynniki behawioralne | Sposób aproksymacji | Szczegóły pomiaru | Przykłady miar |
|---|--|--|---|
| Sentyment inwestorów | Natężenie sentymentu dotyczące inwestycji lub rynku, Dane transakcyjne | <ul style="list-style-type: none"> - określenie sentymentu wyrażonego przez treść informacji rynkowych, opinie użytkowników mediów społecznościowych lub forum internetowego dotyczące inwestycji, - indeksy oceny sytuacji ekonomicznej przez konsumentów, - liczba wyszukiwań w Internecie dotyczących słów o negatywnym wydźwięku, - zmiany w danych transakcyjnych wskazujące na entuzjazm inwestorów, | <ul style="list-style-type: none"> - wskaźnik sentymentu Twittera, - indeks FEARS, - indeks zaufania konsumentów (CCI), - indeks sentymentu Bakera i Wurglera (2006), - The Crypto Fear & Greed Index, |
| Awersja do strat, Negatywny sentyment | Stopień niepewności inwestycyjnej, Natężenie negatywnego sentymentu | <ul style="list-style-type: none"> - liczba (lub częstość występowania) słów określających niepewność dotyczącą inwestycji w artykułach lub mediach społecznościowych, - liczba artykułów w czasopismach, które są związane z niepewnością, - zapytania odnośnie do słów dotyczących niepewności gospodarczej lub fraz o negatywnym wydźwięku w wyszukiwarce internetowej, | <ul style="list-style-type: none"> - indeks zmienności, - indeks ryzyka geopolitycznego, - indeks niepewności polityki gospodarczej, - indeks niepewności Twittera, - indeks niepewności Google, - indeks FEARS, |
| Heurystyka dostępności, Uwaga inwestorów | Popularność inwestycji | <ul style="list-style-type: none"> - liczba słów oznaczających nazwę inwestycji w artykułach lub mediach społecznościowych, - zapytania dotyczące inwestycji w wyszukiwarce internetowej, | <ul style="list-style-type: none"> - indeks wolumenu wyszukiwań w Google, - indeks wolumenu wyszukiwań w Baidu, - wolumen Tweetów, |
| Heurystyka afektu, Zachowania stadne, Sentyment inwestorów | Znaczenie wypowiedzi osób wpływowych | <ul style="list-style-type: none"> - określenie nastroju wypowiedzi osób wpływowych, - analiza reakcji cen aktywa na wypowiedzi osób wpływowych, | <ul style="list-style-type: none"> - wskaźnik sentymentu osób wpływowych Twittera, - wypowiedzi osób wpływowych jako zdarzenia, |
| Heurystyka zakotwiczenia, Heurystyka reprezentatywności, Odmierna awersja do ryzyka w kontekście zysków i strat, Nadmierna pewność siebie | Tendencje w transakcjach rynkowych | <ul style="list-style-type: none"> - częstość występowania pewnych wartości w notowaniach giełdowych, - zależność cen aktywa od jego historycznych notowań, - porównanie transakcji zyskowych i stratnych, - trendy w danych transakcyjnych świadczące o nadmiernej pewności siebie inwestorów, | <ul style="list-style-type: none"> - odchylenie notowań od 52-tygodniowego maksimum, - efekt odwrócenia stóp zwrotu, - długość trwania transakcji zyskowych i stratnych, - częstość zawierania transakcji na giełdzie i stopień dywersyfikacji portfela przez inwestorów, |
| Zachowania stadne | Modele rozproszenia stóp zwrotu | <ul style="list-style-type: none"> - analiza odchylenia stóp zwrotu od ich rynkowych wartości, | <ul style="list-style-type: none"> - przekrojowe standardowe odchylenie stóp zwrotu (CSSD), |

Źródło: Opracowanie własne

Z tabeli 13 wynika, że natężenie sentymentu pozwala bezpośrednio odwołać się do nastawienia inwestorów odnośnie do przyszłych zmian cen inwestycji. Stopień niepewności inwestycyjnej aproksymuje natężenie oddziaływania awersji do strat i negatywnego sentymentu dotyczącego danego rynku na zachowanie inwestorów. Popularność inwestycji w Internecie może aproksymować stopień oddziaływania heurystyki dostępności na decyzje inwestorów, a wypowiedzi osób wpływowych mogą zwiększyć skłonność inwestorów do ulegania heurystyce afektu. Heurystyka zakotwiczenia w podejmowaniu decyzji inwestycyjnych może być aproksymowana za pomocą analizy tendencji w transakcjach rynkowych. W ten sposób można również odnieść się do awersji do strat, heurystyki reprezentatywności oraz sentymentu inwestorów. Modele rozproszenia stóp zwrotu są wykorzystywane do oszacowania natężenia zachowań stadnych.

Pierwszym z omawianych sposobów aproksymacji czynników behawioralnych jest analiza natężenia sentymentu dotyczącego wybranego rynku bądź pojedynczej inwestycji. W badaniach przeprowadzonych w tym obszarze stosuje się różne ogólnodostępne dane, m. in. opinie na forum (np. StockTwits) lub w mediach społecznościowych (m. in. X.com, Reddit), informacje rynkowe (np. Reuters), indeksy wyszukiwań w Internecie (np. Google Trends), indeksy oceny sytuacji ekonomicznej przez konsumentów (Oprea, 2014; Chen i in., 2019; Kraaijeveld i Smedt, 2020; Burggraf i in., 2021; Guégan i Renault, 2021; Naeem i in., 2021; Anamika i Subramaniam, 2022; Bowden i Gemayel, 2022) lub kombinacje różnych czynników mogących odzwierciedlać sentyment, np. *The Crypto Fear & Greed Index*³³ (Łęt i in., 2023). Dane te mają zróżnicowaną postać, dlatego ich zastosowanie wiąże się z różnymi sposobami pomiaru sentymentu inwestorów. Na przykład, strona internetowa StockTwits umożliwia pobranie wiadomości użytkowników wraz z oznaczonym przez nich sentymentem odnośnie zachowania ceny inwestycji w przyszłości (np. pozytywny lub negatywny sentyment). Inną miarą sentymentu jest indeks FEARS, który opiera się na danych dotyczących liczby zapytań w Google dotyczących wybranych słów o negatywnym znaczeniu, np. bezrobocie, recesja, bankructwo. W konstrukcji tego indeksu, Da i in. (2015) uwzględnili dane dotyczące wyszukiwań w Internecie słów odnoszących się do obaw makroekonomicznych i mikroekonomicznych (dotyczących gospodarstwa domowego). W skrócie, wskaźnik FEARS

³³ Indeks ten uwzględnia takie czynniki jak zmienność cen, wolumen obrotu / momentum na rynku Bitcoina, liczbę postów w mediach społecznościowych i zapytań dotyczących Bitcoina w Google oraz jego udział w rynku kryptowalut. Wartość indeksu równa 0 oznacza ekstremalny strach, a 100 interpretuje się jako ekstremalną „chciwość” u inwestorów na rynku Bitcoina (<https://alternative.me/crypto/fear-and-greed-index/>).

można opisać jako średnią ze wskazań indeksów zapytań w Google dla tych słów. Zatem pozwala on na pomiar pesymizmu dotyczącego inwestycji i innych problemów decyzyjnych podmiotu gospodarczego.

Innym sposobem wyznaczania natężenia sentymentu inwestorów jest analiza opinii użytkowników mediów społecznościowych lub informacji rynkowych za pomocą technik przetwarzania języka naturalnego (*natural language processing*). Tego rodzaju analiza jest często przeprowadzona z wykorzystaniem specjalnych słowników, które pozwalają zakwalifikować słowa jako pozytywne, neutralne lub negatywne, np. słownik Loughrana i McDonalda (2011). Na tej podstawie obliczany jest zagregowany poziom sentymentu dla danych tekstowych w pewnym okresie czasu (Anamika i Subramaniam, 2022). Problemem związanym z tym sposobem aproksymacji czynników behawioralnych może być potrzeba pozyskania relatywnie dużej liczby opinii użytkowników mediów społecznościowych, co może być utrudnione ze względu na ograniczenia w dostępności tego typu danych.

Indeks zaufania konsumentów (*Consumer Confidence Index*) przybliża zaufanie konsumentów do sytuacji gospodarczej w danym kraju (OECD, 2023). Wskaźnik ten jest dostępny w kroku miesięcznym i opiera się na danych ankietowych odnośnie do sytuacji gospodarczej, rynku pracy itd. Zatem indeks zaufania konsumentów może przybliżyć optymizm inwestorów (Oprea, 2014). Jednakże, tak jak w przypadku innych miar wykorzystujących dane ankietowe posiada on kilka wad - deklaratywność i reprezentatywność tylko dla wybranego kraju. Ponadto, jest on dostępny dla poszczególnych państw, więc uwzględnia sentyment dotyczący wybranej gospodarki, co niekoniecznie musi odzwierciedlać nastawienie inwestorów w stosunku do inwestycji o zasięgu globalnym.

Wykorzystanie wymienionych miar sentymentu inwestorów wiąże się również z innymi wadami. Pierwszą z nich jest niejednoznaczność interpretacji ich wskazań - wysokie natężenie sentymentu inwestorów może prowadzić zarówno do nadmiernej pewności siebie, jak i chęci naśladowania innych. Druga wada wykorzystania sentymentu dotyczącego rynku³⁴ jako sposobu aproksymacji natężenia sentymentu inwestorów odnosi się do stopnia, w jakim odzwierciedla on rzeczywistość. Chiny są jedną z największych gospodarek świata, która jest powiązana kapitałowo z rynkami znajdującymi się w innych państwach. Dlatego zachowanie inwestorów pochodzących z tego państwa może być znaczące dla sytuacji na światowym rynku

³⁴ Sentyment dotyczący rynku można rozumieć jako nastawienie inwestorów co do przyszłych zmian cen aktywów notowanych na określonym rynku, które nie wynika z rzetelnej analizy dostępnych informacji.

finansowym. Jednakże, w Chinach nie można korzystać z wyszukiwarki firmy Google (Fang i in., 2021) i platformy X³⁵ (Yahoo, 2022). Dlatego miary opierające się na tych źródłach mogą nie uwzględniać znaczącego odsetka sentymentu dotyczącego globalnych aktywów inwestycyjnych. Zatem w przypadku indeksu FEARS można wysnuć wniosek, że nie odzwierciedla on zachowania inwestorów pochodzących z Chin. W efekcie, indeks ten może zawierać szum informacyjny, który może zniekształcać rzeczywisty sentyment dotyczący rynków silnie powiązanych z gospodarką chińską.

Jako miary stopnia niepewności inwestycyjnej w badaniach wykorzystuje się indeksy zmienności (*Volatility Index*) (Choi i Shin, 2022), ryzyka geopolitycznego (*Geopolitical Risk Index*) (Bouri i in., 2020), niepewności polityki gospodarczej (*Economic Policy Uncertainty - EPU*) (Demir i in., 2018), miary oparte na danych z Twittera (*Twitter-based Uncertainty*) (Wu i in., 2021), indeksy wyszukiwań słów w Google związanych z niepokojem (Chen i in., 2020) lub informacje statystyczne o negatywnych zdarzeniach globalnych (np. wzrost zachorowań na Covid-19) (Demir i in., 2020). Istotnym problemem związanym z tymi miernikami jest niejednoznaczność w ich interpretacji, tzn. który czynnik behawioralny one odzwierciedlają - niepewność czy negatywny sentyment inwestorów.

Indeks VIX (*Volatility Index*) jest miarą zmienności, która jest obliczana na podstawie ceny opcji wystawionych na indeks akcji S&P 500 (*Standard & Poor's 500*) (Choi i Shin, 2022). Indeks ten bezpośrednio odwołuje się do zmienności przypisywanej głównie do amerykańskiego rynku akcji, z którym wiele gospodarek jest powiązanych w kontekście przepływów kapitału. Dlatego niepewność przypisywana amerykańskim akcjom może dobrze odzwierciedlać niepewność na rynkach światowych.

Indeks ryzyka geopolitycznego (*Geopolitical Risk Index*) jest obliczany jako odsetek artykułów dotyczących napięć geopolitycznych, konfliktów wojennych, zagrożenia wojną, atakami terrorystycznymi itp. w ogólnej liczbie opublikowanych wiadomości w wiodących gazetach w danym okresie (Bouri i in. 2020; Caldara i Iacoviello, 2021). Odzwierciedla on zatem odsetek informacji dotyczących wybranego kraju(-ów) i część niepewności globalnej. Zatem indeks ryzyka geopolitycznego umożliwia analizę występowania heurystyki reprezentatywności wśród inwestorów. Taką możliwość zapewnia również inna miara - niepewność polityki gospodarczej (EPU). Indeks EPU dotyczy artykułów w krajowych

³⁵ W 2023 roku Twitter zmienił nazwę na „X”.

czasopismach, które są powiązane z niepewnością polityki gospodarczej (Baker i in., 2016). Indeks ten jest bardziej pojemny informacyjnie niż wspomniane proxy dla ryzyka geopolitycznego. Oprócz ryzyka związanego z niepewnością geopolityczną (np. wojna handlowa między krajami), indeks EPU uwzględnia także ryzyko jak m. in. katastrofy naturalne czy pandemia. Nieuwzględnienie tego ryzyka mogłoby znacząco zaniżyć znaczenie niepewności dla decyzji inwestycyjnych, ponieważ zjawiska globalne (np. pandemia) mogą powodować wzrost globalnego strachu. Zatem większa pojemność informacyjna EPU powoduje, że jest on najbardziej przydatną miarą niepewności w kontekście analizy zachowania inwestorów na rynku.

Ostatnią ze wspomnianych miar niepewności inwestycyjnej jest indeks niepewności Twittera. Indeks ten opiera się na poszukiwaniu słów związanych z niepewnością lub gospodarką w wiadomościach użytkowników Twittera (Baker i in., 2021). Zaletą tego indeksu w porównaniu do miary EPU lub ryzyka geopolitycznego jest możliwość pobierania danych w ujęciu dziennym (dla większości indeksów EPU i ryzyka geopolitycznego jest to krok miesięczny). Jednakże, indeks ten nie pozwala odróżnić niepewności globalnej od niepewności przypisywanej do sytuacji w różnych krajach (np. Chin). Ponadto, inwestorzy mieszkający w Chinach nie mogą korzystać z Twittera. Natomiast indeks EPU dla Chin może uwzględniać niepewność odzwierciedloną w artykułach napisanych w języku chińskim. Jak wspomniano wcześniej, sytuacja na rynkach azjatyckich (np. w Chinach) jest bardzo ważna dla obrotu na rynkach finansowych. Zatem uwzględnienie miar opartych o dane tylko z Twittera może nie być reprezentatywne dla pomiaru niepewności dotyczącej inwestycji.

Popularność inwestycji jest kolejnym sposobem aproksymacji czynników behawioralnych. Ograniczone zasoby inwestorów mogą powodować, że najwięcej uwagi poświęcają oni walorom najbardziej popularnym (tzw. uwaga inwestorów skierowana na daną inwestycję) (Da i in., 2011). Ponadto, w okresie najwyższej popularności rozważanej inwestycji mogą być oni bardziej skłonni podjąć ryzyko, którego w normalnych okolicznościach by nie zaakceptowali. Uszczegóławiając, zakładają oni, że działania innych są przejawem wiarygodności informacji, które w rzeczywistości są niepewne (tzw. społeczny dowód słuszności). Zatem indeksy wyszukiwań w Internecie mogą świadczyć o ograniczonej uwadze inwestorów i uleganiu heurystyce dostępności, a także prowadzić do występowania kaskad informacyjnych.

Stopień występowania heurystyki dostępności może być aproksymowany za pomocą popularności nazwy inwestycji w wyszukiwarce internetowej, np. Google lub Baidu (odpowiednik Google na rynek chiński), liczby tweetów lub komentarzy na forum (np. StockTwits) oraz artykułów dotyczących inwestycji (Kristoufek, 2013; Polasik i in., 2015; Philippas i in., 2019; Wen i in., 2019; Guégan i Renault, 2021). Wymienione sposoby pomiaru natężenia heurystyki dostępności cechuje kilka ograniczeń. Na przykład, Google nie dostarcza bezwzględnej miary wyszukiwań. Udostępnia on relatywne indeksy liczby wyszukiwań w Internecie w zależności od wybranego okresu. Poza pewnymi wyjątkami, indeksy firmy Google dla określonego okresu pomiaru są przedstawiane w postaci liczb z zakresu od 1 do 100 (dla bardzo małej ilości wyszukiwań w Internecie Google nie udostępnia wartości indeksu - są one oznaczone jako „<1”). Zatem zastosowanie tej miary może prowadzić do utraty części informacji.

Dane dotyczące wyszukiwań w Google i opinii na Twitterze nie uwzględniają w pełni popularności inwestycji wśród chińskich użytkowników (usługi te są oficjalnie zabronione w Chinach). Dlatego, liderem na rynku chińskim jest wyszukiwarka internetowa firmy Baidu. Baidu zbiera dane dotyczące fraz wyszukiwanych w Internecie w języku chińskim. Zatem nie jest możliwe dokładne odzwierciedlenie popularności inwestycji o charakterze globalnym wykorzystując tylko jedną miarę lub jeden język. Niestety dostęp do danych firmy Baidu jest utrudniony (m. in. potrzeba tłumaczenia informacji wyrażonych w języku chińskim). Być może dlatego w literaturze bardzo trudno jest znaleźć miarę, która agregowałaby różne źródła danych dotyczących popularności inwestycji.

Analiza znaczenia wypowiedzi osób wpływowych jest kolejną możliwością aproksymacji czynników behawioralnych. W ten sposób można zmierzyć stopień występowania heurystyki afektu wśród inwestorów. Na podstawie dostępnych informacji można zidentyfikować osoby publicznie rozpoznawalne, które osiągnęły sukces biznesowy. Takie osoby mogą posiadać znaczące zasoby finansowe czy kontakty. Dlatego inwestor może dojść do błędnego przekonania, że osoba wpływowa posiada dostęp do informacji prywatnych (np. ma większą wiedzę o przedmiocie inwestycji niż w przypadku pozostałych). Ponadto, wypowiedź eksperta wywołuje dodatkowe emocje i może przyczynić się do zachowań stadnych wśród inwestorów. Na przykład, wzrost liczby wypowiedzi „celebryty” może prowadzić do wzrostu popularności tematu tych komentarzy, gdyż wiele osób obserwuje aktywność osób wpływowych w mediach społecznościowych. Komentarz osoby wpływowej o popularnym aktywie inwestycyjnym może

szybko wywołać silne emocje wśród użytkowników mediów społecznościowych i błędną interpretację treści komunikatu jako upublicznienie informacji prywatnej.

Aby określić znaczenie osób wpływowych dla inwestycji analizuje się sentyment ich wypowiedzi lub reakcję cen rynkowych na ich komentarze. Dotychczasowe badania wykorzystują głównie dane pochodzące z Twittera (Kandi i in., 2021; Kinyua i in., 2021; Bhadkamar i Bhattacharya, 2022; Machus i in., 2022; Metta i in., 2022). Odnoszą się zatem one przede wszystkim do anglojęzycznych odbiorców opinii „influencerów”, co marginalizuje znaczenie inwestorów innych narodowości. Jako osoby wpływowe na rynkach finansowych w literaturze wymienia się przede wszystkim Elona Muska i Donalda Trumpa (Kandi i in., 2021; Kinyua i in., 2021; Bhadkamar i Bhattacharya, 2022; Machus i in., 2022; Metta i in., 2022). Jednakże, ograniczanie próby badawczej tylko do tych dwóch nazwisk może nie być reprezentatywne. Jako potencjalne osoby wpływowe można wskazać także dyrektorów firm notowanych na giełdzie (Caiffa i in., 2020). Takie ujęcie może nie być odpowiednie, gdyż ich możliwość wpływania na ceny akcji jest ograniczona prawnie (zakaz tzw. insider tradingu przez osoby na stanowiskach kierowniczych). Zatem ograniczeniem tego miernika jest konieczność wskazania kto jest wpływowy, co często jest wyborem kontrowersyjnym.

Kolejny sposób aproksymacji czynników behawioralnych dotyczy analizy tendencji w transakcjach rynkowych. Do tej grupy należy pomiar częstości wystąpienia różnych wartości w notowaniach aktywów, np. cen kończących się na „0” w liczbie dziesiętnej (Urquhart, 2017; Mbanga, 2019; Li i in., 2020). Przewaga pewnych wartości w notowaniach nad innymi może świadczyć o uleganiu heurystyce zakotwiczenia przez inwestorów. Ponadto, znaczenie heurystyki zakotwiczenia w podejmowaniu decyzji inwestycyjnych można przybliżyć za pomocą pomiaru możliwości przewidywania przyszłych cen aktywa inwestycyjnego lub uzyskiwanych stóp zwrotu na podstawie odchylenia jego notowań od 52-tygodniowego maksimum (George i Hwang, 2004; Wang, Wu i Wang, 2023).

Wykorzystanie danych na temat częstości wystąpienia różnych wartości w notowaniach aktywów do przybliżania heurystyki zakotwiczenia może nie być właściwe. Może to powodować problem niejednoznacznej interpretacji wyników - częstsze występowanie niektórych cyfr w notowaniach może wynikać z potrzeby usprawnienia negocjacji cenowych pomiędzy uczestnikami rynku (np. częste zaokrąglenia do pełnych liczb), co można uznać za racjonalne postępowanie. Zatem wykorzystanie tego sposobu aproksymacji w kontekście pomiaru skłonności inwestorów do ulegania heurystyce zakotwiczenia może być mylące.

Dane transakcyjne wykorzystuje się również do pomiaru efektu dyspozycji, co można odnieść do odmiennej awersji do ryzyka w obszarze zysków i strat (teoria perspektywy). Pomiar efektu dyspozycji może polegać na porównaniu średniej długości trwania „dwustronnych” (*round-trip*) transakcji³⁶ zakończonych zyskiem i stratą (Haryanto i in., 2020). W innych badaniach (np. Wen i in. (2022)) poszukuje się zależności w szeregu stóp zwrotu, aby stwierdzić czy występuje efekt momentum lub odwrócenia. Efekt odwrócenia stóp zwrotu może odnosić się do nadmiernej reakcji na informacje rynkowe, np. zbyt pozytywny początkowy odbiór wiadomości. Ponadto, niektórzy autorzy (np. Chen i in. (2007)) wykorzystują dane na temat częstotliwości zawierania transakcji na giełdzie i liczby aktywów w portfelu inwestycyjnym (stopień dywersyfikacji) w celu pomiaru skłonności inwestorów do nadmiernej pewności siebie. W tym kontekście zakłada się, że wysoka aktywność inwestorów (przy dużej koncentracji składu portfela inwestycyjnego) świadczy o ich nadmiernej pewności siebie.

Dane transakcyjne mogą być także wykorzystywane do pomiaru natężenia sentymentu. Na przykład, indeks opracowany przez Bakera i Wurglera (2006) opiera się na analizie wspólnej zmienności różnych „proxy” entuzjazmu inwestorów na rynku akcji: wolumenu obrotu na rynku, liczby nowych emisji, średniej stopy zwrotu z pierwszej oferty publicznej, premii z tytułu dywidendy, udziału emisji akcji w nowych emisjach (w odniesieniu do całego kapitału dłużnego i własnego), różnicy między rynkową ceną jednostki uczestnictwa w funduszu a wartością jego aktywów netto w przeliczeniu na jednostkę. Niestety, niektóre z tych czynników są dostępne tylko dla akcji. Dlatego indeks Bakera i Wurglera (2006) może być trudny do wykorzystania w praktyce w przypadku inwestycji innego typu.

Analiza danych transakcyjnych może również prowadzić do identyfikacji zachowań stadnych na rynku finansowym. Lakonishok, Shleifer i Vishny (1992) mierzą zachowania stadne jako nadwyżkę odsetka funduszy, które kupowały (lub sprzedawały) akcje tej samej spółki nad ich odsetkiem obliczonym dla całego rynku (wszystkich spółek). Inny sposób aproksymowania zachowań stadnych polega na analizie rozproszenia stóp zwrotu waloru wokół ich rynkowej wartości (Bouri i in., 2019; Vidal-Tomás i in., 2019). Jednymi z najbardziej popularnych metod pomiaru natężenia zachowań stadnych są modele rozproszenia stóp zwrotu: *Cross-sectional*

³⁶ Zysk / Strata z transakcji „round-trip” jest obliczana/-y jako różnica między sprzedażą waloru „A” za walutę „B” a kwotą przeznaczoną na odkupienie tego waloru w późniejszym terminie (z uwzględnieniem opłat transakcyjnych).

absolute deviation (CSAD) i *Cross-sectional standard deviation* (CSSD). Model CSSD wykorzystuje przekrojowe standardowe odchylenie stóp zwrotu jako miarę rozproszenia stóp zwrotu:

$$CSSD_{m,t} = \sqrt{\frac{\sum_{i=1}^N (r_{i,t} - r_{m,t})^2}{N-1}} \quad (22)$$

gdzie N to liczba walorów (np. kryptowalut), $r_{m,t}$ oznacza rynkową stopę zwrotu w okresie „ t ”, $r_{i,t}$ to stopa zwrotu z każdego waloru (i) dla wybranej częstotliwości notowań. Jeżeli rozproszenie stóp zwrotu jest małe w okresach znacznych zmian cen, to wnioskuje się o występowaniu zachowań stadnych. Innymi słowy, inwestorzy są wtedy bardziej skłonni „podążać za rynkiem” zamiast kierować się własnymi poglądami.

Aby odróżnić zachowania stadne od zachowań właściwych dla racjonalnej wyceny aktywów³⁷, Christie i Huang (1995) zaproponowali wykorzystanie regresji do analizy zależności między rozproszeniem stóp zwrotu a skrajnymi wartościami ich rozkładu:

$$CSSD_{m,t} = \alpha + \beta^U \cdot D_t^U + \beta^L \cdot D_t^L + \varepsilon_t \quad (23)$$

gdzie D_t^U / D_t^L to zmienne binarne przyjmujące wartość równą 1, jeżeli stopa zwrotu z rynku w czasie „ t ” znajduje się w skrajnie prawym / lewym ogonie rozkładu. W przypadku zachowań stadnych współczynniki β^U i β^L będą miały znak ujemny (pozytywny kierunek tej zależności jest zgodny z zachowaniem właściwym dla racjonalnej wyceny aktywów).

Khorana i in. (2000) zauważyli, że model racjonalnej wyceny aktywów zakłada liniową zależność pomiędzy rozproszeniem stóp zwrotu a rynkową stopą zwrotu (np. stopa zwrotu z indeksu rynkowego). Dlatego zmodyfikowali oni poprzedni model (CSSD) tak, aby uchwycić nieliniowość, którą mogą charakteryzować się zachowania uczestników w skrajnych warunkach rynkowych. Do pomiaru rozproszenia stóp zwrotu Khorana i in. (2000) wykorzystali model CSAD, który uwzględnia bezwzględne odchylenie stóp zwrotu zamiast standardowego (model CSSD). Ponadto, zaproponowali oni wykorzystanie regresji pomiędzy rozproszeniem stóp zwrotu z inwestycji a rynkową stopą zwrotu:

$$CSAD_{m,t} = \alpha + \beta_1 \cdot r_{m,t} + \beta_2 \cdot |r_{m,t}| + \beta_3 \cdot r_{m,t}^2 + \varepsilon_t \quad (24)$$

gdzie $CSAD$ to bezwzględne odchylenie stóp zwrotu, $r_{m,t}$ oznacza rynkową stopę zwrotu w okresie „ t ”. Istotne statystycznie i ujemne oszacowanie współczynnika β_3 potwierdza

³⁷ Według Christie i Huang (1995) model racjonalnej wyceny aktywów zakłada, że w warunkach zawirowań rynkowych (znaczące zmiany cen) rozproszenie stóp zwrotu będzie wzrastało. Aktywa notowane na danym rynku charakteryzuje różna wrażliwość na zachowanie stopy rynkowej.

występowanie zachowań stadnych. W przypadku dodatniego znaku tego współczynnika wnioskujemy się o zachowaniu rynku zgodnym z racjonalnym modelem wyceny aktywów.

Wadą modeli rozproszenia stóp zwrotu jest ich duża zależność od przyjętych założeń odnośnie do rynkowej stopy zwrotu. Dotychczas powstało wiele indeksów rynku (np. dla rynku amerykańskiego można uwzględnić S&P 500 i Dow Jones Industrial Average 30) i metod szacowania rynkowych stóp zwrotu (np. średnia ważona udziałem waloru w rynku lub równoważona). Ponadto, w rzeczywistości inwestorzy mogą mieć inne powody do naśladowania pozostałych, niż tylko zachowanie rynku (m. in. popularność, jakość aktywa, moda na daną branżę lub produkt). Dlatego wydaje się, że miara ta może nie uwzględniać znaczącej części zachowań stadnych, które mogą występować szczególnie w przypadku inwestycji w aktywa z sektora nowych technologii.

Przeprowadzony przegląd metod pomiaru natężenia czynników behawioralnych uwiarydlił, że sposoby ich identyfikacji różnią się pod względem rodzaju wykorzystywanych danych. Metody opierające się na danych pierwotnych pozwalają na dokładniejsze zbadanie sposobu myślenia inwestorów i określenie czynników behawioralnych niż metody odnoszące się do danych wtórnych. Do wad tego rodzaju sposobów pomiaru czynników behawioralnych należą jednak czasochłonny proces zbierania danych i ich analizy. Ponadto, w przypadku tego rodzaju metod uzyskanie reprezentatywnej próby badawczej dla globalnych aktywów inwestycyjnych może być bardzo trudne.

Do najpopularniejszych sposobów aproksymacji czynników behawioralnych z wykorzystaniem danych wtórnych należą: sentyment wyrażony w treści informacji lub opiniach na temat inwestycji udostępnianych w mediach, liczba wyszukiwań w Internecie dotyczących słów o danym wydzwięku, częstość występowania (lub liczba) słów określających niepewność dotyczącą inwestycji w artykułach lub mediach społecznościowych, liczba artykułów związanych z niepewnością, średnia ważona cena opcji wystawionych na indeks akcji S&P 500, popularność inwestycji, znaczenie wypowiedzi osób wpływowych, modele rozproszenia stóp zwrotu oraz tendencje w transakcjach rynkowych. Wykorzystanie tych metod pomiaru czynników behawioralnych umożliwia przeprowadzenie zautomatyzowanej analizy zachowania inwestorów. Ponadto, są one mniej czasochłonne niż obserwacja sytuacji decyzyjnej. Zatem sposoby aproksymacji czynników behawioralnych opierające się na danych wtórnych są bardziej przydatne do wykorzystania w praktyce niż te wykorzystujące dane pierwotne. Natomiast do ich wad należy m. in. niejednoznaczność interpretacji uzyskanych

wyników (nie jest pewne, które zjawisko nieracjonalnego zachowania inwestorów odzwierciedlają one w najwyższym stopniu).

2.3 Przegląd dotychczasowych badań dotyczących znaczenia czynników behawioralnych na rynku kryptowalut

Dotychczasowe badania występowania czynników behawioralnych były prowadzone głównie na rynkach akcji. Potwierdzają one występowanie różnych przejawów nieracjonalnego zachowania wśród inwestorów. Można oczekiwać, że inwestujący w kryptowaluty również mają skłonność do podobnych zachowań. Jednakże, liczba i zakres badań dotyczących rynku kryptowalut są znacznie mniejsze niż w przypadku rynku akcji.

Badania nad rynkiem kryptowalut koncentrują się głównie na pomiarze behawioralnych skłonności inwestorów z wykorzystaniem danych wtórnych. W ten sposób odnoszą się one do zachowań stadnych, sentymentu inwestorów, heurystyki zakotwiczenia, afektu i dostępności, uwagi inwestorów, nadmiernej pewności siebie, awersji do strat oraz niepewności inwestycyjnej. Dlatego w tym podrozdziale zostaną przedstawione badania najpopularniejszych czynników behawioralnych podejmowania decyzji inwestycyjnych na rynku kryptowalut.

Jednym z przejawów nieracjonalnego zachowania inwestorów na rynku kryptowalut jest naśladowanie innych. W tym kontekście większość wyników badań wskazuje na występowanie zachowań stadnych wśród inwestujących w kryptowaluty (m. in. Bouri, Gupta i Roubaud (2019), Vidal-Tomás i in. (2019), Kallinterakis i Wang (2019), Ballis i Drakos (2020), Omane-Adjepong i in. (2021), Ren i Lucey (2022)). Badania niepotwierdzające występowania tego typu zachowań wśród uczestników rynku kryptowalut (m. in. Kurt Gümüş i in. (2019), Nurbarani i Soepriyanto (2022)) cechowały się pewnymi ograniczeniami. Nurbarani i Soepriyanto (2022) badali postawy respondentów zamieszkujących tylko Dżakartę i jej okolicę (region w Indonezji). Kurt Gümüş, Gümüş i Çimen (2019) po raz pierwszy wykorzystali Index CCI 30 jako aproksymantę rynkowej stopy zwrotu w modelu rozproszenia stóp zwrotu. Jednakże, indeks ten nie uwzględnia zachowań części inwestorów na tym rynku, ponieważ obejmuje on tylko 30 największych kryptowalut.

W pewnych okresach skłonność inwestorów do zachowań stadnych na rynku kryptowalut może być silniejsza. Kallinterakis i Wang (2019), Ballis i Drakos (2020), Jalal i in. (2020) wykorzystali model rozproszenia stóp zwrotu do pomiaru siły zachowań stadnych wśród

inwestujących w kryptowaluty. Zauważyli, że skłonność inwestorów do „podążania za tłumem” jest silniejsza w okresie hossy na rynku kryptowalut. Bouri, Gupta i Roubaud (2019) oraz Choi, Kang i Yoon (2022) przeprowadzili analizę przekrojowego bezwzględnego rozproszenia stóp zwrotu na tym rynku. Doszli oni do wniosku, że natężenie zachowań stadnych zmienia się w czasie i może zależeć od niepewności polityki gospodarczej państw czy zawirowań gospodarczych. Vidal-Tomás, Ibáñez i Farinós (2019) zaobserwowali, że zachowania stadne występują w przypadku najmniejszych i największych kryptowalut. Ponadto stwierdzili, że inwestujący w kryptowaluty o niewielkiej kapitalizacji mogą podejmować podobne decyzje inwestycyjne na podstawie informacji dotyczących największych z nich pod względem kapitalizacji. Ren i Lucey (2022) również wykorzystali modele CASD i CSSD do pomiaru siły zachowań stadnych wśród inwestorów na tym rynku. Zaobserwowali, że zachowania stadne występują głównie w przypadku bardziej energochłonnych kryptowalut i w czasie bessy.

Innym przejawem nieracjonalnego zachowania inwestorów na rynku kryptowalut jest podejmowanie decyzji inwestycyjnych pod wpływem sentymentu. Karalevicius, Degrande i De Weerd (2018) doszli do wniosku, że może istnieć związek pomiędzy sentymentem inwestorów aproksymowanym za pomocą znaczenia słów zawartych w wiadomościach dotyczących Bitcoina a zachowaniem jego ceny. Ponadto zauważyli, że w początkowym okresie po opublikowaniu wiadomości, reakcja cen Bitcoina była zgodna z sentymentem wyrażonym w tych informacjach. Jednakże, w późniejszym okresie kierunek zachowania cen Bitcoina ulegał odwróceniu. Eom i in. (2019) zaobserwowali, że sentyment inwestorów określony na podstawie danych z Google Trends może zawierać istotną wartość informacyjną w kontekście przyszłych zmian zmienności Bitcoina. Gurdgiev i O'Loughlin (2020) oraz Kraaijeveld i Smedt (2020) uzyskali podobne rezultaty, które świadczą o możliwości przewidywania zmian cen kryptowalut za pomocą sentymentu inwestorów. Rognone, Hyde i Zhang (2020) zauważyli, że inwestorzy na rynku Bitcoina reagują pozytywnie zarówno na negatywne, jak i pozytywne wiadomości, co odróżnia tę kryptowalutę od tradycyjnych inwestycji. Corbet i in. (2020a) udokumentowali, że negatywny sentyment wywołany przez pandemię COVID-19 wpływał na stopy zwrotu z kryptowalut. Naeem, Mbarki i Shahzad (2021) potwierdzili, że sentyment użytkowników Twittera oraz indeks FEARS mogą być predyktorami stóp zwrotu uzyskiwanych na rynku kryptowalut. Guégan i Renault (2021) doszli do wniosku, że istnieje statystycznie istotny związek pomiędzy stopami zwrotu uzyskiwanymi na rynku

Bitcoina a sentymentem inwestorów. López-Cabarcos i in. (2021) zauważyli, że sentyment dotyczący indeksu S&P 500 może wpływać na zmienność Bitcoina w okresach niskiej zmienności na rynku akcji. Podsumowując, większość badań potwierdza znaczenie sentymentu inwestorów dla podejmowania decyzji inwestycyjnych na rynku kryptowalut. Ponadto zaobserwowano, że oddziaływanie sentymentu inwestorów na zmienność, zachowanie cen oraz stóp zwrotu z kryptowalut może zmieniać się i być zależne od panujących warunków rynkowych.

Odmienna awersja do ryzyka w obszarze zysków i strat może przejawiać się występowaniem efektu dyspozycji, który był przedmiotem badań prowadzonych na rynku kryptowalut. Haryanto, Subroto i Ulpah (2020) zauważyli, że w okresie hossy na rynku Bitcoina średni czas trwania transakcji zakończonej zyskiem jest dłuższy niż w przypadku transakcji ze stratą (odwrotny efekt dyspozycji). Ponadto wykazali, że efekt dyspozycji występuje wśród inwestorów, gdy cena Bitcoina jest w trendzie spadkowym. Al-mansour (2020) przeprowadził badanie ankietowe wśród inwestujących w kryptowaluty w Zjednoczonych Emiratach Arabskich. Wyniki jego badania wskazały na występowanie m. in. efektu dyspozycji i heurystyki reprezentatywności. Das, Ahmed i Pachoni (2022) przeprowadzili badanie kwestionariuszowe wśród indyjskich inwestorów na rynku kryptowalut. Doszli do konkluzji, że charakteryzuje ich odmienna awersja do ryzyka w obszarze zysków i strat. Sood i in. (2023) potwierdzili, że inwestujący w kryptowaluty w Indiach są bardziej skłonni do zbyt długiego przetrzymywania inwestycji przynoszących straty, niż do zbyt szybkiego pozbywania się inwestycji zyskowych. Ponadto zaobserwowali, że zachowania stadne silnie oddziałują na podejmowanie decyzji inwestycyjnych na rynku kryptowalut. Schatzmann i Haslhofer (2023) zauważyli, że efekt dyspozycji występuje na rynku Bitcoina tylko w pewnych okresach, szczególnie w czasie jego rosnącej popularności w mediach. Konkludując, inwestorzy na rynku kryptowalut, niezależnie od państwa ich pochodzenia, mogą mieć odmienną awersję do ryzyka w kontekście zysków i strat. Wskazują na to zarówno badania wykorzystujące dane wtórne jak i pierwotne. Wrażliwość na zyski i straty inwestujących w kryptowaluty może zmieniać się w czasie, co może wynikać z emocji, jakie wywołują w nich różne warunki rynkowe (np. hossa lub bessa) i zmiany popularności inwestycji w mediach.

Stopień niepewności inwestycyjnej może aproksymować awersję do strat lub negatywny sentyment. Wyniki badań nad kryptowalutami wskazują, że niepewność inwestycyjna może mieć znaczenie dla stóp zwrotu uzyskiwanych na tym rynku. Demir i in. (2018) potwierdzili, że

stopę zwrotu z Bitcoina są negatywnie związane z niepewnością polityki gospodarczej (EPU). Shaikh (2020) doszedł do wniosku, że niepewność gospodarcza w Stanach Zjednoczonych i Japonii oddziałuje negatywnie na stopę zwrotu z Bitcoina, a EPU Chin - pozytywnie. Podobnie, Cheng i Yen (2020) udokumentowali, że niepewność gospodarcza Chin może być pozytywnie związana z przyszłymi miesięcznymi stopami zwrotu uzyskiwanymi na rynku Bitcoina. Jednakże, wyniki ich badania nie wskazały na występowanie tej zależności w przypadku innych kryptowalut - Ethereum, Ripple'a i Litecoina. Ponadto, nie potwierdzili możliwości predykcji stóp zwrotu z kryptowalut za pomocą EPU Stanów Zjednoczonych, Korei Południowej i Japonii. Corbet i in. (2020b) zaobserwowali, że wzrost liczby negatywnych wiadomości makroekonomicznych dotyczących bezrobocia i dóbr trwałych skutkuje wzrostem stóp zwrotu z Bitcoina (i odwrotnie). Bouri, Gupta i Vo (2020) doszli do wniosku, że zmiany cen Bitcoina zależą od zmian wartości indeksu ryzyka geopolitycznego. López-Cabarcos i in. (2021) potwierdzili, że zmiany wartości indeksu VIX (miara niepewności) wpływają na zmienność na rynku Bitcoina.

Podobnie do wcześniejszych badań, Yen i Cheng (2021) zauważyli, że tylko EPU Chin negatywnie wpływa na przyszłą zmienność Bitcoina i Litecoina. W przypadku indeksów niepewności polityki gospodarczej w Stanach Zjednoczonych, Japonii i Korei Południowej nie potwierdzili takiej zależności. Colon i in. (2021) badali reakcję notowań 25 największych kryptowalut na niepewność polityki gospodarczej i ryzyko geopolityczne. Wyniki ich badania wskazały, że niepewność ma znaczenie dla zachowania stóp zwrotu na rynku kryptowalut. Wang i in. (2020) potwierdzili, że oddziaływanie EPU Stanów Zjednoczonych na rynek Bitcoina jest większe niż w przypadku EPU Wielkiej Brytanii. Ponadto stwierdzili, że w okresie następującym po osiągnięciu wysokich wartości przez EPU Stanów Zjednoczonych zwiększa się zmienność i wolumen obrotu na rynku Bitcoina (dla EPU Wielkiej Brytanii nie potwierdzono tej zależności). Wu i in. (2021) wykorzystali dane z Twittera do pomiaru niepewności gospodarczej i zauważyli, że w pewnych okresach niepewność gospodarcza oddziałuje pozytywnie na stopę zwrotu z Bitcoina, Ethereum i Ripple'a. Choi i Shin (2022) potwierdzili, że ceny Bitcoina reagują spadkiem na szoki niepewności mierzone indeksem VIX. Jednakże, nie zaobserwowali takiej reakcji Bitcoina w przypadku szoków związanych z niepewnością polityki gospodarczej (EPU).

Niektórzy badacze kryptowalut zajmują się pomiarem znaczenia negatywnego sentymentu inwestorów wywołanego przez globalne zjawiska nacechowane niepewnością. Na przykład,

Chen, Liu i Zhao (2020) zauważyli, że zmienność na rynku Bitcoina mogła być zwiększona wskutek negatywnego sentymentu przybliżanego wzrostem zainteresowania pandemią koronawirusa wśród użytkowników wyszukiwarki internetowej Google. Demir i in. (2020) sformułowali wniosek, że istnieje zależność między negatywnymi zdarzeniami, takimi jak liczba zachorowań i zgonów COVID-19 a cenami Bitcoina - związek ten początkowo miał charakter negatywny, lecz z czasem stał się pozytywny.

Kolejnym czynnikiem, który może wzmacniać skłonność inwestorów do ulegania heurystykom jest wysoka popularność inwestycji³⁸. Początkowo badania potwierdzały, że inwestorzy na rynku kryptowalut mogą podejmować decyzje inwestycyjne na podstawie popularności inwestycji w Internecie. Kristoufek (2013) oraz Garcia i in. (2014) zauważyli, że wzrost popularności Bitcoina w Internecie może zachęcać inwestorów do kupna tej kryptowaluty i powodować dalszy wzrost jej cen. Badanie przeprowadzone przez Polasika i in. (2015) potwierdziło, że popularność (jako liczba wyszukiwań w Google lub artykułów w czasopismach dotyczących Bitcoina), sentyment wyrażony w artykułach dotyczących Bitcoina oraz wolumen transakcji są głównymi czynnikami napędzającymi stopy zwrotu na tym rynku. Ponadto, Matta, Lunesu i Marchesi (2015) zauważyli, że liczba wyszukiwań w przeglądarce Google dotyczących Bitcoina może być predyktorem wolumenu obrotu na tym rynku.

Wyniki niektórych badań przeprowadzonych w późniejszym okresie przeczyły znaczeniu uwagi inwestorów na rynku kryptowalut. Urquhart (2018) doszedł do wniosku, że popularność inwestycji w Internecie nie jest istotnym predyktorem zmienności, wolumenu obrotu czy stóp zwrotu na rynku Bitcoina. Bleher i Dimpfl (2019), Panagiotidis, Stengos i Vravosinos (2019) oraz Guégan i Renault (2021) również nie potwierdzili, aby uwaga inwestorów skierowana na Bitcoina miała znaczenie dla stóp zwrotu uzyskiwanych na tym rynku. Jednakże, Bleher i Dimpfl (2019) zaobserwowali, że wyższy wolumen wyszukiwań nazwy kryptowaluty w Google jest związany z wyższą jej zmiennością.

Większość ostatnich badań potwierdza, że znaczenie uwagi inwestorów skierowanej na kryptowaluty może się zmieniać w czasie. Philippas i in. (2019) zauważyli, że oddziaływanie dostępności informacji na temat kryptowalut w Internecie na zachowanie cen Bitcoina jest największe w czasach wysokiej niepewności. Smuts (2019) doszedł do konkluzji, że relacja pomiędzy zachowaniem cen kryptowalut a ich popularnością w Internecie nie jest cały czas

³⁸ Liczbę zapytań w wyszukiwarce internetowej lub informacji w mediach dotyczących aktywa inwestycyjnego interpretuje się również jako uwagę inwestorów skierowaną na daną inwestycję (Da i in., 2011).

pozytywna, jak początkowo wskazywano. Subramaniam i Chakraborty (2020) zaobserwowali, że inwestorzy zwracają większą uwagę na kryptowaluty, które są częściej przedmiotem zainteresowania mediów (m. in. Bitcoin i Ethereum). Zhu i in. (2021) potwierdzili, że dzienny i miesięczny wolumen wyszukiwań dotyczących Bitcoina w Google ma wpływ na zachowanie zmienności i stóp zwrotu na rynku Bitcoina. Liu i Tsyvinski (2021) zauważyli, że popularność kryptowalut w Internecie może być predyktorem przyszłych stóp zwrotu na tym rynku. Li, Goodell i Shen (2021) doszli do konkluzji, że oddziaływanie popularności aproksymowanej za pomocą Twittera na rynek kryptowalut trwa krócej niż w przypadku indeksów wyszukiwań Googla. Smales (2022) zauważył, że wzrost popularności kryptowalut jest związany z wyższymi stopami zwrotu, większą zmiennością i niższą płynnością na tym rynku. Bakas, Magkonis i Oh (2022) doszli do wniosku, że najważniejszymi czynnikami kształtowania się zmienności Bitcoina są jego popularność, liczba Bitcoinów w obiegu, indeks zaufania amerykańskich konsumentów oraz indeks S&P500. Podsumowując, wyniki dotychczasowych badań wskazują, że oddziaływanie popularności kryptowalut na zachowanie inwestorów na tym rynku może zmieniać się w czasie. Ponadto zaobserwowano, że oddziaływanie uwagi inwestorów określanej z wykorzystaniem indeksu Googla może trwać dłużej niż w przypadku wykorzystania danych pobranych z Twittera.

Następnym czynnikiem behawioralnym badanym w kontekście kryptowalut jest emocjonalna reakcja inwestora wywołana przez skojarzenia z pewnymi osobami. Uszczegóławiając, opublikowanie informacji na temat inwestycji przez osobę wpływową lub wiadomości odnoszących się do jej zachowania w kontekście inwestycji może wywołać emocje wśród inwestorów i skłaniać ich do ulegania heurystyce afektu. Być może dlatego Cerda i Reutter (2019) zauważyli, że wypowiedzi osób wpływowych w mediach społecznościowych mogą wpływać na cenę Bitcoina. Dalsze badania przeprowadzone przez Huynha (2021) oraz Tandon i in. (2021) potwierdziły, że komentarze Donalda Trumpa lub Elona Muska w mediach społecznościowych mogą być znaczące dla zachowania notowań kryptowalut w krótkim okresie. W późniejszym okresie, Huynh (2022) zaobserwował, że sentyment (pozytywny i negatywny) wyrażony w opiniach Elona Muska w mediach społecznościowych może być związany z uzyskiwanymi stopami zwrotu z Bitcoina i Ethereum. Shahzad, Anas i Bouri (2022) zauważyli, że tweety Elona Muska dotyczące Bitcoina i Dogecoina mogą prowadzić do powstawania „baniek spekulacyjnych” na tych rynkach. Lennart (2023) uzyskał istotne statystycznie ponadnormalne stopy zwrotu po zdarzeniach odnoszących się do tweetów Elona

Muska dotyczących kryptowalut. Ostatnie prace również potwierdzają, że wypowiedzi osób wpływowych mają znaczenie dla zachowania cen kryptowalut (m. in. Bouteska i in. (2023), Chahooki, Jahanbin i Sutikno (2023)). Zatem wyniki większości badań wskazują, że wypowiedzi osób wpływowych w mediach społecznościowych mogą oddziaływać na zachowanie inwestorów na rynku kryptowalut. Być może przyczyną jest to, że inwestorzy przypisują większą wagę opiniom celebrytów niż własnym, co może prowadzić do zachowań stadnych uczestników rynku. Jednakże, wyniki niektórych badań potwierdzają, że zjawisko to może występować tylko w krótkim okresie.

W badaniach nad rynkiem kryptowalut podejmowano również próbę pomiaru znaczenia skłonności inwestorów do ulegania heurystyce zakotwiczenia w podejmowaniu decyzji inwestycyjnych. Jak dotąd, potwierdzono, że inwestorzy mogą ulegać heurystyce zakotwiczenia na podstawie skojarzeń z pewnymi cyframi w notowaniach inwestycji (m. in. Urquhart (2017), Mbanga (2019), Li, Li i Xu (2020)). Aczkolwiek można znaleźć prace, które kwestionują psychologiczną przyczynę tego zjawiska. Na przykład, Hu i in. (2019) stwierdzili, że im wyższa cena transakcyjna kryptowalut, tym częściej występuje ona w postaci liczb całkowitych, co może wynikać z chęci ułatwienia przeprowadzenia transakcji czy negocjacji. Niektórzy autorzy zauważyli również, że inwestorzy na rynku Bitcoina mogą mieć skłonność do podejmowania decyzji inwestycyjnych na podstawie takich zdarzeń jak halving, ponieważ oczekują oni wzrostu ceny Bitcoina po wystąpieniu tego zdarzenia, tak jak miało to miejsce w przeszłości. Meynkhart (2019), wykorzystując korelację rang Kendalla udokumentował, że zmniejszenie wynagrodzenia za wydobycie Bitcoina o połowę co cztery lata (halving) może prowadzić do wzrostu wartości rynkowej kryptowaluty. Jednakże, Wang, Chu i Yang (2019) nie potwierdzili, aby cena rynkowa kryptowalut była wrażliwa na zdarzenia dotyczące halvingu. Niemniej jednak Sood i in. (2023) zauważyli, że uczestnicy rynku kryptowalut traktują historycznie najwyższe ceny jako ważny punkt odniesienia w podejmowaniu decyzji inwestycyjnych, więc można stwierdzić, że inwestujący w kryptowaluty ulegają heurystyce zakotwiczenia.

Dotychczasowe badania również potwierdzają, że inwestujący w kryptowaluty mają tendencję do nadmiernej pewności siebie (Foley i in., 2022; Sood i in., 2023). Do podobnych wniosków można dojść na podstawie badań, w których wykorzystuje się dane wtórne do pomiaru natężenia czynników behawioralnych. Wen i in. (2022) zaobserwowali występowanie efektu odwrócenia stóp zwrotu na rynku kryptowalut, co może świadczyć o nadmiernej

pewności siebie inwestorów. Rebman i in. (2022) udokumentowali, że publiczne postrzeganie technologii *blockchain* opiera się w większym stopniu na jej przyszłych pozytywnych perspektywach, niż na aktualnym stanie wiedzy, co także wskazuje na nadmierną pewność siebie użytkowników kryptowalut. Wnioski te są tożsame z wynikami późniejszych badań (Sudzina i in., 2023). Podsumowanie badań nad występowaniem czynników behawioralnych na rynku kryptowalut zaprezentowano w tabeli 14.

Tabela 14. Wyniki badań nad występowaniem czynników behawioralnych na rynku kryptowalut

| Czynnik behawioralny | Badania potwierdzające występowanie danego czynnika | Badania niepotwierdzające jednoznacznie występowania danego czynnika |
|--|--|---|
| Nadmierna pewność siebie | Foley i in. (2022), Rebman i in. (2022), Wen i in. (2022), Sood i in. (2023), Sudzina i in. (2023) | - |
| Heurystyka zakotwiczenia | Urquhart (2017), Mbanga (2019), Meynkhard (2019), Li i in. (2020), Sood i in. (2023) | Hu i in. (2019), Wang i in. (2019) |
| Heurystyka afektu w kontekście opinii osób wpływowych | Cerda i Reutter (2019), Tandon i in. (2021), Huynh (2022), Shahzad i in. (2022), Bouteska i in. (2023), Chahooki i in. (2023), Lennart (2023) | Huynh (2021) |
| Uwaga inwestorów, Heurystyka dostępności | Kristoufek (2013), Garcia i in. (2014), Polasik i in. (2015), Matta i in. (2015), Philippas i in. (2019), Subramaniam i Chakraborty (2020), Liu i Tsyvinski (2021), Zhu i in. (2021), Li i in. (2021), Bakas i in. (2022), Smales (2022) | Urquhart (2018), Bleher i Dimpfl (2019), Panagiotidis i in. (2019), Guégan i Renault (2021) |
| Awersja do strat, niepewność inwestycyjna | Demir i in. (2018), Bouri i in. (2020), Chen i in. (2020), Corbet i in. (2020b), Demir i in. (2020), Shaikh (2020), Colon i in. (2021), López-Cabarcos i in. (2021), Wu i in. (2021), Choi i Shin (2022) | Cheng i Yen (2020), Wang i in. (2020), Yen i Cheng (2021) |
| Odmierna awersja do ryzyka w kontekście zysków i strat | Al-mansour (2020), Haryanto i in. (2020), Das i in. (2022), Schatzmann i Haslhofer (2023), Sood i in. (2023) | - |
| Sentyment inwestorów | Karalevicius i in. (2018), Eom i in. (2019), Corbet i in. (2020a), Gurdgiev i O'Loughlin (2020), Kraaijeveld i Smedt (2020), Guégan i Renault (2021), López-Cabarcos i in. (2021), Naeem i in. (2021) | Chu i in. (2019), Rognone i in. (2020) |
| Zachowania stadne | Bouri i in. (2019), Vidal-Tomás i in. (2019), Kallinterakis i Wang (2019), Ballis i Drakos (2020), Omane-Adjepong i in. (2021), Ren i Lucey (2022) | Kurt Gümüş i in. (2019), Nurbarani i Soepriyanto (2022) |

Źródło: Opracowanie własne

W niniejszym podrozdziale przedstawiono wyniki badań czynników behawioralnych występujących na rynku kryptowalut. Trudno jest jednoznacznie stwierdzić czy heurystyka zakotwiczenia ma znaczenie w podejmowaniu decyzji inwestycyjnych na rynku kryptowalut. Potwierdzono, że inwestujący w kryptowaluty mają odmienną awersję do ryzyka w kontekście

zysków i strat, podejmują decyzje inwestycyjne pod wpływem zachowań stadnych, stopnia niepewności inwestycyjnej, sentymentu inwestorów, popularności inwestycji oraz ulegają heurystyce dostępności. Zaobserwowano również, że oddziaływanie tych czynników behawioralnych na zachowanie inwestorów na rynku kryptowalut zmienia się w czasie, co może być związane ze zmianami warunków rynkowych. Ponadto, z przeglądu literatury wynika, że inwestorów na rynku kryptowalut charakteryzuje nadmierna pewność siebie oraz uleganie heurystyce afektu, szczególnie w krótkim okresie.

2.4 Efektywność rynku w kontekście finansów behawioralnych

W latach 70. XX wieku Fama sformułował hipotezę rynku efektywnego. Zakłada ona, że inwestorzy są zasadniczo racjonalni, a zmiany cen aktywów notowanych na rynku efektywnym mają charakter losowy. Jednakże, wraz z upływem czasu coraz częściej kwestionowano różne założenia leżące u podstaw hipotezy rynku efektywnego (Grossman i Stiglitz, 1980; Shiller, 1981). Jednym z nich było założenie o racjonalności podmiotów gospodarczych (np. Kahneman i Tversky (1979)). Przejawem nieracjonalnego zachowania inwestorów jest podejmowanie decyzji inwestycyjnych pod wpływem czynników behawioralnych, co można interpretować jako zaprzeczenie hipotezy rynku efektywnego (Shiller, 2003). Zatem koncepcje finansów behawioralnych i efektywności rynku były przez długi czas postrzegane jako sprzeczne, aż do momentu sformułowania hipotezy rynku adaptacyjnego (*Adaptive market hypothesis*, AMH) (Lo, 2004). Dlatego w tym podrozdziale omówiono hipotezę rynku adaptacyjnego, jej założenia oraz implikacje. Ponadto, dokonano przeglądu najważniejszych badań nad AMH, które pogrupowano według metod weryfikacji zależności wynikających z tej hipotezy. Wyróżniono prace wykorzystujące testy skuteczności strategii inwestycyjnych i występowania anomalii kalendarzowych, testy autokorelacji, ilorazu wariancji oraz serii, testy korelacji i zależności długookresowych oraz metody badawcze uwzględniające nieliniowy charakter zależności występujących w szeregu czasowym.

W myśl hipotezy rynku adaptacyjnego, zyskowość strategii inwestycyjnych zmienia się wraz ze zmieniającymi się warunkami rynkowymi. Może to wynikać z trudności w podejmowaniu optymalnych decyzji inwestycyjnych w szybko zmieniającym się środowisku rynkowym. Zmiana otoczenia rynkowego może powodować, że inwestorzy popełniają błędy ulegając heurystykom, co może skutkować tymczasowym zmniejszeniem poziomu efektywności rynku. Uczestnicy rynku adaptacyjnego uczą się jednak na podstawie

popęłnianych błędów. Dlatego przyjmuje się, że po pewnym czasie rynek ponownie zbliża się do punktu równowagi (efektywność informacyjna rynku poprawia się). Konkludując, w myśl AMH poziom efektywności rynku może zmieniać się w czasie i być związany z występowaniem czynników behawioralnych.

Hipoteza rynku adaptacyjnego opiera się na kilku założeniach (Lo, 2004):

- warunki rynkowe się zmieniają,
 - celem uczestników rynku jest maksymalizacja zysku,
 - konkurencja między grupami inwestorów prowadzi do zmian w poziomie efektywności rynku,
 - uczestnicy rynku dokonują nieoptymalnych wyborów i uczą się na podstawie doświadczenia,
 - uczestnicy rynku podlegają naturalnej selekcji - na rynku pozostaną jedynie ci inwestorzy, którzy dostosują się do zmieniającego się środowiska poprzez zmianę strategii inwestycyjnych.
- Według Lo (2004), spełnienie powyższych założeń może prowadzić do następujących implikacji:

1. Relacja pomiędzy ryzykiem a zyskiem nie jest stała w czasie. Preferencje inwestorów odnośnie do ryzyka są kształtowane przez naturalną selekcję. Inwestorzy, którzy doświadczyli ogromnych strat w przeszłości mogą nie być chętni do podjęcia takiego samego ryzyka jak wcześniej. Może to wynikać z faktu, że są oni bardziej wrażliwi na straty niż zyski tej samej wysokości (teoria perspektywy).
2. W pewnych okresach istnieją strategie inwestycyjne przynoszące zyski (inaczej niż w przypadku rynku efektywnego), co może być związane ze zmieniającymi się warunkami rynkowymi, np. z wprowadzeniem nowych regulacji.
3. Strategie inwestycyjne, które początkowo przynosiły straty, mogą stać się zyskowne wskutek zmiany warunków środowiskowych, np. wejścia na rynek nowych inwestorów (przeczy to hipotezie rynku efektywnego).
4. Rozwój różnych umiejętności³⁹ jest kluczowy dla przetrwania. W kontekście hipotezy rynku efektywnego zakładano, że biorąc pod uwagę pewien poziom ryzyka można uzyskać stopy zwrotu na oczekiwanym poziomie. Natomiast Lo (2004) stwierdza, że lepszym sposobem, aby uzyskać stopy zwrotu na oczekiwanym poziomie, jest dostosowanie się do zmieniających się warunków rynkowych. Przetrwanie inwestorów w szybko zmieniającym

³⁹ Na przykład, umiejętność szybkiego uczenia się na własnych błędach.

się środowisku może ułatwić rozwój szerokiego zakresu umiejętności dostosowanych do różnych warunków rynkowych.

W kontekście hipotezy rynku adaptacyjnego czynniki behawioralne odgrywają znaczącą rolę w kształtowaniu zmian poziomu efektywności rynku, co jest związane ze zmianami otoczenia rynkowego. Gdy warunki rynkowe ulegają zmianie, dotychczasowe schematy myślenia i działania inwestorów przestają być efektywne, przez co poszukują oni nowych strategii postępowania. W efekcie inwestorzy mogą popełniać błędy behawioralne, co wzmacniają również emocje (m. in. strach, chciwość) wywoływane przez zmiany warunków rynkowych. Emocje jednak nie muszą być przeciwstawne racjonalnemu zachowaniu, ponieważ zwiększają one efektywność uczenia się inwestorów na własnych błędach. W ten sposób uczestnicy rynku mogą adaptować się do nowej rzeczywistości gospodarczej (Lo, 2004). Zatem w krótkim okresie zwiększenie natężenia czynników behawioralnych może prowadzić do obniżenia poziomu efektywności rynku, np. inwestorzy mogą przeceniać znaczenie dostępnych informacji rynkowych dla przyszłych zmian cen waloru. Natomiast w dłuższej perspektywie czasowej może to sprzyjać zwiększeniu poziomu efektywności rynku, zakładając, że inwestorzy uczą się na własnych błędach.

Od czasu sformułowania hipotezy rynku adaptacyjnego przeprowadzono liczne badania służące jej weryfikacji. Wiele z nich potwierdza, że hipoteza rynku adaptacyjnego może dobrze odwzorowywać rzeczywiste zachowanie rynku finansowego, np. zmieniający się w czasie poziom efektywności rynku w kontekście tradycyjnych aktywów (Lim, 2007; Lim i Brooks, 2011; Ito i in., 2016; Noda, 2016; Okorie i Lin, 2021) oraz kryptowalut (Bariviera, 2017; Khuntia i Pattanayak, 2018; Noda, 2021). Ponadto zaobserwowano, że w przypadku azjatyckich rynków akcji stopy zwrotu ze strategii inwestycyjnych wykorzystujących średnią ruchomą (Todea i in., 2009) oraz anomalie kalendarzowe (Xiong i in., 2019) zmieniają się w czasie, co jest zgodne z hipotezą rynku adaptacyjnego. Do podobnych wniosków można dojść na podstawie wyników badań nad występowaniem anomalii kalendarzowych przeprowadzonych na innych rynkach. Prace te potwierdziły, że występowanie dziennych, tygodniowych i miesięcznych efektów kalendarzowych, efektu poniedziałku, stycznia, „przełomu miesiąca” oraz Halloween zmienia się w czasie (Urquhart i McGroarty, 2014; Al-Khazali i Mirzaei, 2017).

W badaniach weryfikujących hipotezę rynku adaptacyjnego stosuje się także inne testy, tzn. autokorelacji, ilorazu wariancji oraz serii. Wyniki badań przeprowadzonych z wykorzystaniem

tych testów potwierdziły, że zarówno w przypadku rynków rozwiniętych jak i wschodzących poziom efektywności informacyjnej zmienia się w czasie (m. in. Ito i Sugiyama (2009), Urquhart i Hudson (2013), Shi i in. (2017)). Ponadto, Kim i in. (2011), Smith (2012) oraz Boya (2019) zaobserwowali, że wzrosty przewidywalności stóp zwrotu na różnych rynkach zbiegają się z ważnymi zdarzeniami makroekonomicznym, takimi jak kryzysy gospodarcze i polityczne. Zatem wzrost niepewności wśród inwestorów może być powiązany ze zmniejszeniem poziomu efektywności rynku. Jednakże, w literaturze można znaleźć badania (m. in. Kim i in. (2011), Mokni i in. (2024)), które pomimo wykorzystywania podobnych testów efektywności rynku nie potwierdzają jednoznacznie związku między stopniem niepewności inwestycyjnej a poziomem efektywności rynku.

Kolejną grupę badań weryfikujących założenia lub implikacje AMH stanowią prace wykorzystujące testy zależności i korelacji długookresowych (m. in. Alvarez-Ramirez i in. (2012), Rodriguez i in. (2014)). Wyniki tych badań wskazują na to, że w przypadku rynków rozwiniętych poziom efektywności informacyjnej zmienia się cyklicznie. Natomiast w kontekście rynków wschodzących obserwuje się, że poziom efektywności rynku wzrasta w długim horyzoncie czasowym (m. in. Qin i in. (2015), Sukpitak i Hengpunya (2016)). Jednakże, niezależnie od stopnia rozwoju rynku, zmiany poziomu efektywności rynku w krótkim okresie tłumaczy się reakcją inwestorów na zmiany polityki gospodarczej (Alvarez-Ramirez i in., 2012; Hkiri i in., 2021) lub globalne zdarzenia nacechowane wysoką niepewnością, np. COVID-19 (Dinz-Maganini i in., 2023). Do najczęściej wykorzystywanych metod pomiaru poziomu efektywności rynku w tej grupie badań należy wykładnik Hursta (m. in. Alvarez-Ramirez i in. (2012), Hull i McGroarty (2014), Al-Yahyaee i in. (2018)).

W ostatniej grupie można wyróżnić badania wykorzystujące przede wszystkim testy występowania nieliniowych zależności w szeregu czasowym, np. test BDS opracowany przez Brocka, Decherta, Scheinkmana i LeBarona (m. in. Urquhart i McGroarty (2016), Kołatka (2020) oraz Akbar i in. (2024)). Na podstawie wyników tych badań można dojść do podobnych wniosków - przewidywalność stóp zwrotu z akcji notowanych na różnych rynkach zmienia się w czasie, aczkolwiek reagują one inaczej na zmiany warunków rynkowych (m. in. początek epidemii Covid-19, kryzys kredytów hipotecznych sub-prime w USA).

W myśl hipotezy rynku adaptacyjnego zakłada się, że inwestorzy mają tendencję do nieświadomego podejmowania decyzji inwestycyjnych pod wpływem czynników behawioralnych, co może być związane ze zmieniającym się otoczeniem rynkowym.

Mushinada (2020) na podstawie badania ankietowego potwierdził, że indyjskich inwestorów charakteryzuje skłonność do dostosowywania się do zmieniających się warunków w przypadku poniesienia straty (awersja do strat) lub zdarzeń nacechowanych niepewnością, co potwierdza słuszność hipotezy rynku adaptacyjnego.

W kontekście badań nad AMH można spotkać się z pojęciem postrzeganego poziomu efektywności rynku, który odzwierciedla ocenę stopnia efektywności rynku zadeklarowaną przez jego uczestników. Pomiar poziomu tej efektywności może odbywać się przez wskazanie w jakim stopniu respondent zgadza się ze stwierdzeniami odwołującymi się do cech rynku efektywnego. Na przykład, na rynku efektywnym inwestor może w dużym stopniu zgadzać się ze stwierdzeniem, że „ceny akcji spółek notowanych na giełdzie odzwierciedlają ich wartość wewnętrzną” (Hadi, 2017). Dotychczasowe badania potwierdzają negatywny związek pomiędzy poziomem efektywności pakistańskiego rynku postrzeganym przez respondentów a czynnikami behawioralnymi, takimi jak heurystyka dostępności (Hadi, 2017) czy zachowania stadne (Ahmed i Wu, 2022). Shah, Ahmad i Mahmood (2018) udokumentowali, że heurystyki reprezentatywności, dostępności i zakotwiczenia oraz nadmierna pewność siebie występujące wśród inwestujących w akcje notowane na pakistańskiej giełdzie mają negatywny wpływ na postrzegany przez nich poziom efektywności tego rynku. Do podobnych wniosków doszli Jalal i Leonelli (2021), potwierdzając, że postrzegany przez europejskich inwestorów poziom efektywności rynku kryptowalut może być związany z ich skłonnością do nadmiernej pewności siebie.

W części badań podejmuje się próbę określenia znaczenia czynników behawioralnych dla przewidywalności stóp zwrotu, która jest przejawem braku efektywności rynku. Vozlyublennai (2014), Tantaopas, Padungsaksawasdi i Treepongkaruna (2016) oraz Han, Li i Yin (2018) zauważyli, że uwaga inwestorów zmniejsza przewidywalność stóp zwrotu z indeksów obligacji i towarów, a także akcji notowanych na rynkach wschodzących i rozwiniętych. Spadek przewidywalności stóp zwrotu z inwestycji może wskazywać na wzrost poziomu efektywności rynku. Dodatkowo Han, Li i Yin (2018) stwierdzili, że wyższy poziom efektywności rynku może być związany z szybszym rozpowszechnianiem informacji na rynkach rozwiniętych, a niższy poziom efektywności rynku może wynikać z rzadszego korzystania z Internetu i większych ograniczeń krótkiej sprzedaży, które występują na rynkach rozwijających się. Balcilar i in. (2019) udokumentowali, że EPU globalne i na poziomie państw może być wykorzystane do przewidywania zmienności stóp zwrotu z akcji notowanych na rynkach w Malezji oraz Korei

Południowej. Jednakże, nie potwierdzili tych rezultatów w przypadku Hongkongu. Tripathi, Vipul i Dixit (2020) badali autokorelacje stóp zwrotu z notowań 21 indeksów rynkowych. Zauważyli oni ujemną autokorelację w przypadku najwyższych stóp zwrotu i dodatnią autokorelację dla najniższych stóp zwrotu. Może to wskazywać na znaczenie sentymentu inwestorów dla przewidywalności stóp zwrotu z notowań indeksów rynkowych⁴⁰.

Powyższe badania nie potwierdzają jednoznacznie czy wzrost natężenia czynników behawioralnych wiąże się ze wzrostem przewidywalności stóp zwrotu z inwestycji tradycyjnych. Do innych wniosków można dojść na podstawie dotychczasowych badań nad rynkiem kryptowalut. Wyniki tych badań wskazują, że czynniki behawioralne mogą być wykorzystane do przewidywania stóp zwrotu z kryptowalut. Do tych czynników zalicza się sentyment inwestorów oraz awersję do strat (Kraaijeveld i Smedt, 2020; Naeem i in., 2021), niepewność polityki gospodarczej w Chinach (Cheng i Yen, 2020) i uwagę inwestorów (Liu i Tsyvinski, 2021). Aczkolwiek, można także znaleźć artykuły kwestionujące rolę uwagi inwestorów w prognozowaniu stóp zwrotu z kryptowalut (Urquhart, 2018).

Przewidywalność cen aktywa może świadczyć o braku efektywności rynku (zależność między bieżącymi a historycznymi cenami waloru). Dlatego przypuszcza się, że wzrost natężenia czynników behawioralnych jest powiązany ze spadkiem poziomu efektywności rynku kryptowalut. Jak dotąd nie zbadano znaczenia niektórych czynników behawioralnych dla efektywności rynku kryptowalut (m. in. uwaga inwestorów, heurystyka zakotwiczenia). Istnieje zatem luka badawcza w kontekście pomiaru związku między czynnikami behawioralnymi a dynamiką efektywności rynku kryptowalut.

Podsumowując, wyniki większości przytoczonych badań są zgodne z hipotezą rynku adaptacyjnego. Zauważono, że poziom efektywności rynku zmienia się w czasie, co może wynikać ze zmian warunków rynkowych. Wyniki badań wskazały, że zyskowność strategii inwestycyjnych zmienia się wraz z upływem czasu, a anomalie kalendarzowe występują tylko w niektórych okresach. Ponadto potwierdzono, że postrzegany przez respondentów poziom efektywności rynku jest negatywnie związany z behawioralnymi skłonnościami inwestorów. Postrzegany przez respondentów poziom efektywności rynku może różnić się od jej rzeczywistego ukształtowania, co może tłumaczyć rozbieżność w wynikach badań

⁴⁰ Dodatnia autokorelacja stóp zwrotu może świadczyć o niedostatecznej reakcji inwestorów na informacje w czasie niskiego sentymentu, a ujemna autokorelacja (efekt odwrócenia) może wskazywać na nadmierną reakcję w okresie wysokiego sentymentu.

ankietowych i wykorzystujących dane wtórne do pomiaru znaczenia czynników behawioralnych. Poza tym, można dojść do wniosku, że oddziaływanie czynników behawioralnych na przewidywalność stóp zwrotu z inwestycji jest bardziej jednoznaczne na rynku kryptowalut, niż na rynkach tradycyjnych. Może to wynikać z większej zmienności i trudności w określeniu wartości fundamentalnej kryptowalut niż w przypadku inwestycji tradycyjnych. W efekcie, inwestujący w kryptowaluty mogą w większym stopniu ulegać heurystykom.

3. Koncepcja i metodyka badań empirycznych

3.1 Hipotezy badawcze w świetle hipotezy rynku adaptacyjnego

W myśl hipotezy rynku adaptacyjnego poziom efektywności rynku zmienia się wraz ze zmieniającymi się warunkami rynkowymi. Do nich można zaliczyć w szczególności niepewność inwestycyjną⁴¹, której zmiany mogą wywoływać w inwestorach skrajne emocje. Na przykład, wzrost niepewności inwestycyjnej może prowadzić do nasilenia się strachu wśród uczestników rynku. Jednakże, inwestorzy wolą doznawać satysfakcji z uzyskanej dodatkowej stopy zwrotu niż negatywnych uczuć (np. żalu) związanych ze stratą z inwestycji, co może skłaniać ich do interpretowania rzeczywistości w sposób potwierdzający podjętą wcześniej decyzję lub poszukiwania informacji ją potwierdzających (pułapka potwierdzenia) (Nickerson, 1998). W efekcie inwestorzy mogą zbyt długo trzymać się swojej opinii na temat wartości inwestycji, co może prowadzić do nieracjonalnego zachowania (np. efektu dyspozycji). Ponadto, gdy większość inwestorów niepoprawnie ocenia znaczenie informacji dla wartości aktywów notowanych na danym rynku, może dojść do wystąpienia zachowań stadnych. W ten sposób poziom informacyjnej efektywności tego rynku może się obniżyć. Można zatem oczekiwać, że czynniki behawioralne są związane ze zmianami poziomu efektywności rynku. Jednakże, reakcja inwestorów na zmiany warunków rynkowych może być różna i wynikać także z ich doświadczenia (Lo, 2004).

Dotychczas zaobserwowano, że większy udział inwestorów instytucjonalnych na rynku może być związany z mniejszym stopniem występowania efektu dyspozycji (Bashall i in., 2018; Hincapié-Salazar i Agudelo, 2020). Przykładem inwestorów instytucjonalnych są fundusze inwestycyjne, których menedżerowie mogą być mniej podatni na czynniki behawioralne (np. nadmierną pewność siebie (Lowies i in., 2014)) niż inwestorzy indywidualni. Huang, Sialm i Zhang (2011) zauważyli, że menedżerowie funduszy inwestycyjnych mogą posiadać umiejętność określenia odpowiedniego momentu wejścia i wyjścia z inwestycji (*market timing*). Dlatego można zakładać, że inwestorzy instytucjonalni cechują się dużym doświadczeniem i wiedzą (*sophisticated investors*). Zatem decyzje inwestycyjne podejmowane przez fundusze inwestycyjne mogą być w większym stopniu racjonalne niż w przypadku przeciętnego inwestora.

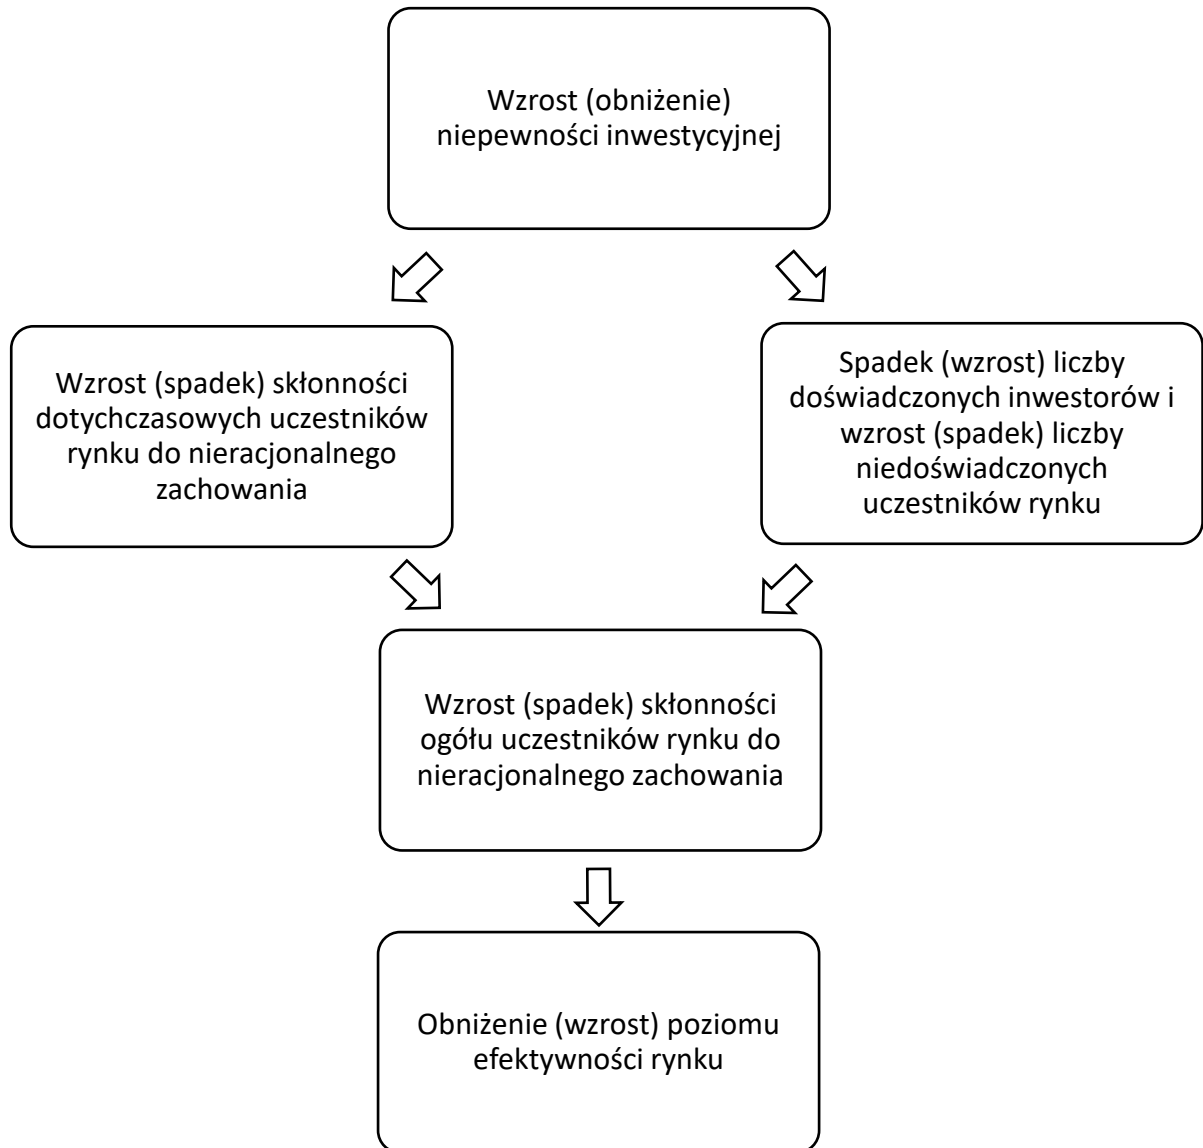
⁴¹ Niepewność inwestycyjna może być rozumiana jako nieprzewidywalność sytuacji rynkowej, która utrudnia podjęcie decyzji inwestycyjnej.

Doświadczeni inwestorzy mogą w mniejszym stopniu ulegać czynnikom behawioralnym na bardziej ryzykownych rynkach niż pozostali uczestnicy tego typu rynków (niedoświadczeni inwestorzy). W okresie wzrostu niepewności inwestycyjnej dokonują oni realokacji zasobów z bardziej do mniej ryzykownych rynków (*flight to quality*) (Chalmers i in., 2013). Przyczyną takiego zachowania bardziej doświadczonych inwestorów może być to, że są mniej podatni na utrzymywanie w portfelu inwestycyjnym walorów, które potencjalnie tracą na wartości lub mogą być przewartościowane (Bashall i in., 2018). W efekcie udział niedoświadczonych inwestorów na rynku może wzrastać w okresie wzrostu niepewności inwestycyjnej. Cena notowanego aktywa na giełdzie odzwierciedla także zachowanie dotychczasowych inwestorów (niedoświadczonych inwestorów i części doświadczonych uczestników rynku, którzy pozostali na rynku w okresie wzrostu niepewności inwestycyjnej). W tym czasie skłonność do ryzyka (i ulegania heurystykom) dotychczasowych uczestników rynku może zwiększać się z powodu chęci uzyskania przewagi informacyjnej⁴² lub „odegrania się” po poniesionej stracie z inwestycji (*break-even effect*) (Thaler i Johnson, 1990). Zatem decyzje (zachowania) dotychczasowych inwestorów w okresie wzrostu niepewności inwestycyjnej mogą przyczyniać się do obniżenia poziomu efektywności rynku.

Znaczenie niedoświadczonych inwestorów dla zmian poziomu efektywności rynku może zmniejszać się w sytuacji odwrotnej, tzn. obniżenia niepewności inwestycyjnej. W takich warunkach część niedoświadczonych inwestorów może być zrażona wcześniej poniesioną stratą, co może skłonić ich do zaprzestania inwestycji na tym rynku. Być może dlatego, że bardziej odczuwają żal z powodu straty z inwestycji niż satysfakcję z możliwych do osiągnięcia zysków w przyszłości, co przekłada się na ocenę prawdopodobieństwa poniesienia straty w przyszłości (Kahneman i Tversky, 1979). W tym czasie na rynek mogą powrócić doświadczeni inwestorzy, którzy wcześniej dokonali realokacji kapitału nabywając mniej ryzykowne aktywa. Ponadto, niektórzy niedoświadczeni uczestnicy rynku mogą uczyć się na własnych błędach popełnionych w warunkach wzrostu niepewności, co może prowadzić do zmniejszenia ich skłonności do nieracjonalnego zachowania. W efekcie, w okresie zmniejszenia niepewności inwestycyjnej na rynku pozostaje część dotychczasowych inwestorów, którzy potrafili dostosować się do nowych warunków rynkowych. Zatem zmniejszenie niepewności

⁴² Inwestorzy mogą podejmować decyzje inwestycyjne na podstawie szumu informacyjnego (np. plotek) zamiast faktów, ponieważ wierzą, że mają one znaczenie dla wartości inwestycji. Jednakże, w ten sposób podejmują oni błędne decyzje inwestycyjne, co może skutkować poniesieniem straty (*noise trading*) (Black, 1986)

inwestycyjnej może prowadzić do zmniejszenia skłonności uczestników rynku (ogółem) do nieracjonalnego zachowania i skutkować wzrostem poziomu informacyjnej efektywności rynku. Związek pomiędzy różnymi warunkami rynkowymi a dynamiką efektywności rynku zaprezentowano na schemacie 2.



Schemat 2. Oddziaływanie zmieniających się warunków rynkowych na dynamikę efektywności rynku kapitałowego

Źródło: Opracowanie własne

Na podstawie schematu 2 można stwierdzić, że skłonność dotychczasowych uczestników rynku do nieracjonalnego zachowania i proporcja inwestorów doświadczonych do niedoświadczonych na rynku zmieniają się w czasie wskutek zmian niepewności inwestycyjnej. Łączne występowanie tych zależności nie jest konieczne, aby nastąpiła zmiana poziomu

efektywności rynku. Zatem wystarczy aby zaobserwowano jedną z nich. Jednakże, w przypadku istnienia obydwu zależności można oczekiwać, że oddziaływanie czynników behawioralnych na dynamikę efektywności rynku będzie bardziej widoczne.

Siła oddziaływania czynników behawioralnych na dynamikę efektywności rynku może wynikać z jego specyfiki. Jednym z rynków, który wykazuje specyficzne cechy w kontekście udziału doświadczonych i niedoświadczonych inwestorów jest rynek kryptowalut. Zdaniem Fonseci i in. (2020), użytkownicy kryptowalut mają niewielkie doświadczenie inwestycyjne. Dodatkowo zauważono, że liczba inwestorów instytucjonalnych na rynku kryptowalut w niektórych okresach zmniejsza się, co może być związane ze wzrostem niepewności na tym rynku (np. upadek giełdy kryptowalut FTX w listopadzie 2022 r.). Jednakże, na rynku kryptowalut przeważają inwestorzy indywidualni (Thomas i Sabater, 2022). Dlatego jest wysoce prawdopodobne, że dla zmiany poziomu efektywności tego rynku większe znaczenie będzie miała zmieniająca się skłonność niedoświadczonych inwestorów do ulegania przejawom nieracjonalności niż zachowanie doświadczonych inwestorów w ogóle. Sprawia to, że oddziaływanie czynników behawioralnych na dynamikę efektywności rynku kryptowalut może być większe niż w przypadku rynku o większym udziale doświadczonych inwestorów.

Kryptowalutą o największej kapitalizacji jest Bitcoin. Inwestujących na tym rynku można próbować zidentyfikować na podstawie rejestru *blockchain*, wykorzystując adresy IP, dane z giełdy lub platformy, na której podmiot dokonuje transakcji związanych z kryptowalutami (zazwyczaj giełdy mają obowiązek identyfikacji tożsamości inwestora) (Binance, 2024). Jednakże, w tym przypadku należałoby pozyskać informacje od podmiotów tradycyjnego systemu finansowego. Może to okazać się niezwykle trudne do zrealizowania z uwagi na dużą liczbę podmiotów tradycyjnego systemu finansowego i rozproszenie geograficznie inwestorów na rynku Bitcoina. Ponadto, dane zawarte w *blockchainie* nie zawierają bezpośrednich informacji o właścicielu kryptowaluty, co powoduje, że identyfikacja tożsamości użytkownika może być utrudniona przez wykorzystywanie połączenia VPN, czyli tzw. wirtualnej sieci prywatnej (*virtual private network*) lub nowych adresów Bitcoina w celu przeprowadzenia nowych transakcji (Bitcoin.org, 2024). Dlatego bezpośredni pomiar udziału doświadczonych i niedoświadczonych inwestorów na tym rynku w różnych okresach jest w zasadzie niemożliwy.

Jednym z czynników behawioralnych, szeroko badanym w kontekście zmian cen na rynku Bitcoina, jest tzw. uwaga inwestorów skierowana na to aktywo (m. in. Kristoufek (2013), Zhu

P. i in. (2021)). Zdaniem Da, Engelberga i Gao (2011), inwestorzy mogą poświęcać najwięcej uwagi walorom najbardziej popularnym, ponieważ mają ograniczone zasoby. Zatem wzrost uwagi inwestorów skierowanej na aktywo może wynikać ze wzrostu popularności inwestycji i trudności w przetworzeniu dostępnych informacji niej dotyczących. Dzieje się tak, ponieważ wzrost popularności inwestycji może prowadzić do zwiększenia dostępności informacji o dużej niepewności (np. prognoza przyszłej ceny), które dotyczą popularnego tematu. Media społecznościowe są często wykorzystywane do publikowania treści, które wywołują emocjonalne i krótkoterminowe reakcje ich użytkowników (Li i in., 2021). Zatem nagły wzrost popularności inwestycji (skutkujący wzrostem zainteresowania inwestorów) może prowadzić do wzrostu zainteresowania mediów tym tematem, co niekoniecznie przekłada się na rzetelność publikowanych informacji. Gdy dostępność informacji na temat inwestycji się zwiększa, może dojść do wzrostu skłonności dotychczasowych inwestorów do ulegania heurystyce dostępności, ponieważ czas potrzebny na przeanalizowanie dostępnych informacji się wydłuża. Zatem w warunkach wysokiej dostępności informacji dotyczących zajścia niektórych zdarzeń rynkowych (np. wzrost ceny Bitcoina), inwestor może przeceniać prawdopodobieństwo ich wystąpienia kierując się ilością informacji uzasadniających podjęcie danej decyzji inwestycyjnej, a nie ich jakością. Może to skutkować niedoszacowaniem wagi zdarzeń rzadkich w podejmowaniu decyzji inwestycyjnych (Tversky i Kahneman, 1973).

Według Smalesa (2022), wysokość uzyskiwanych stóp zwrotu z Bitcoina jest związana ze zmianami uwagi inwestorów skierowanej na Bitcoina. Wysokie stopy zwrotu z inwestycji mogą przyciągać uwagę niedoświadczonych inwestorów, którzy nie chcą „stracić okazji inwestycyjnej” (*fear of missing out*) (Güngör i in., 2022). W tym czasie doświadczeni inwestorzy mogą realizować zyski z inwestycji, ponieważ mogą mieć większe umiejętności wycucia rynku (*market timing*) (Huang i in., 2011). Zatem wzrost uwagi inwestorów skierowanej na Bitcoina może prowadzić do wzrostu liczby niedoświadczonych inwestorów i zmniejszenia liczby doświadczonych uczestników tego rynku. Ponadto, w tym czasie może nastąpić wzrost skłonności dotychczasowych inwestorów do ulegania heurystyce dostępności. Obydwa przedstawione mechanizmy mogą prowadzić do obniżenia poziomu efektywności rynku Bitcoina.

Na podstawie relacji przedstawionych na schemacie 2 i opisanego wyżej mechanizmu zależności między uwagą inwestorów a efektywnością rynku Bitcoina postawiono następującą hipotezę:

H1: *Wzrost (spadek) uwagi inwestorów skierowanej na Bitcoina jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.*

Drugim czynnikiem behawioralnym z rozważanych w dotychczasowych badaniach nad zachowaniem uczestników rynku Bitcoina jest sentyment inwestorów. Na podstawie AMH można przyjąć, że poziom efektywności rynku zmienia się wskutek zmian niepewności inwestycyjnej⁴³. Wzrost niepewności i związanych z nią obaw o wystąpienie negatywnego zdarzenia (np. bankructwo, spadek zysków firmy) mogą powodować wzrost natężenia negatywnego sentymentu (np. strachu) wśród inwestorów, ponieważ bardziej odczuwają oni potencjalną stratę niż zysk tej samej wielkości (Kahneman i Tversky, 1979). Zatem, jeżeli dotychczasowi inwestorzy oceniają prawdopodobieństwo osiągnięcia zysku lub poniesienia straty na podstawie informacji nacechowanych emocjonalnie, to mogą oni podejmować nieracjonalne decyzje inwestycyjne.

Dotychczasowym inwestorom może być łatwiej przywołać w pamięci elementy informacji wzbudzające w nich silniejsze emocje (np. strach czy euforię) niż przeprowadzić analizę złożonego problemu inwestycyjnego, co może skłaniać ich do ulegania heurystyce afektu (Finucane i in., 2000). Dlatego, im silniejsze emocje powoduje pojawiająca się informacja, tym dotychczasowi inwestorzy mogą w większym stopniu ulegać zniekształceniom poznawczym w trakcie jej analizy. Zatem możliwa jest również inna zależność. W czasie dobrych perspektyw dla rynku Bitcoina, natężenie emocji pozytywnych wśród dotychczasowych inwestorów może nasilać się (wzrost natężenia pozytywnego sentymentu), co może prowadzić do podejmowania nieracjonalnych decyzji inwestycyjnych.

Podsumowując, zarówno wzrost natężenia pozytywnego jak i negatywnego sentymentu inwestorów może zwiększyć ich skłonność do podejmowania nieracjonalnych decyzji inwestycyjnych. Takie zachowanie może dotyczyć głównie mniej doświadczonych inwestorów, którzy są bardziej podatni na przejawy nieracjonalności. To znaczy, w okresie wzrostu natężenia negatywnego sentymentu może dojść do wzrostu ich skłonności do ulegania heurystyce afektu, co może prowadzić do zwiększenia chęci do szybkiej sprzedaży walorów. W efekcie na rynku Bitcoina liczba niedoświadczonych inwestorów mogłaby ulec zmniejszeniu. Natomiast, w okresie wzrostu natężenia pozytywnego sentymentu, wysokie stopy zwrotu z

⁴³ W kontekście kryptowalut potwierdza się, że uczestnicy tego rynku zachowują się nieracjonalnie działając pod wpływem zmian warunków panujących na tym rynku (Gurdgiev i O'Loughlin, 2020).

inwestycji mogą skłaniać niedoświadczonych inwestorów do wejścia na rynek Bitcoina. Zatem wzrost natężenia pozytywnego sentymentu może prowadzić do wzrostu skłonności uczestników rynku Bitcoina do ulegania heurystyce afektu. Ponadto, w takiej sytuacji mogą być oni bardziej podatni na „lęk przed przegapieniem okazji” (Güler, 2023). Obydwie zależności mogą prowadzić do wzrostu skłonności ogółu inwestorów do nieracjonalnych zachowań (podejmowania decyzji inwestycyjnych pod wpływem emocji zamiast na podstawie rzetelnej analizy informacji dotyczących przyszłej wartości inwestycji). Powoduje to, że dostępne informacje na temat inwestycji nie są w pełni odzwierciedlone w jej cenie, dlatego w tej sytuacji może dojść do obniżenia poziomu efektywności rynku Bitcoina.

Biorąc pod uwagę przedstawiony powyżej mechanizm zależności między natężeniem sentymentu a poziomem efektywności rynku Bitcoina oraz opracowany schemat 2 (str. 105), postawiono następującą hipotezę:

H2: *Wzrost (spadek) natężenia sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.*

Zachowanie inwestorów pod wpływem negatywnego sentymentu może różnić się od ich zachowania w przypadku pozytywnego sentymentu, na co wskazują wyniki badania przeprowadzonego przez Da i in. (2015). Ponadto, w myśl teorii perspektywy można przypuszczać, że inwestorzy silniej reagują na informacje o negatywnym niż pozytywnym znaczeniu dla wartości inwestycji (Kahneman i Tversky, 1979). Dlatego postawiono dwie hipotezy szczegółowe do hipotezy drugiej:

H2A: *Wzrost (spadek) natężenia pozytywnego sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.*

H2B: *Wzrost (spadek) natężenia negatywnego sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.*

Kolejnym czynnikiem behawioralnym, który jest przedmiotem badań prowadzonych na rynku kryptowalut jest heurystyka zakotwiczenia⁴⁴. Dotychczas zauważono, że inwestorzy na rynku kryptowalut podejmują decyzje inwestycyjne odnosząc się do najwyższych historycznych cen aktywa inwestycyjnego (Sood i in., 2023). George i Hwang (2004) udokumentowali, że odchylenie aktualnej ceny rynkowej aktywa inwestycyjnego od jej 52-tygodniowego maksimum może być wykorzystane do przewidywania przyszłych stóp zwrotu z inwestycji, co pośrednio świadczy o braku efektywności rynku. Zatem wzrost skłonności inwestorów do ulegania heurystyce zakotwiczenia może być związany z obniżeniem poziomu efektywności rynku Bitcoina.

Skłonność inwestorów do ulegania heurystyce zakotwiczenia może zmieniać się wskutek warunków rynkowych. Wzrost niepewności może oddziaływać na spadek ceny i powodować wzrost zmienności na rynku, co utrudnia podejmowanie decyzji inwestycyjnych. W takiej sytuacji odchylenie ceny aktywa od jej historycznego maksimum zwiększa się (George i Hwang, 2004). Wraz z oddalaniem się ceny od jej historycznego maksimum, chęć do spekulacji na temat przyszłych wzrostów cen wśród inwestorów indywidualnych wzrasta, ponieważ oczekują oni powrotu ceny aktywa w okolice jej historycznych maksimum (Wang i in., 2023). Inwestorzy indywidualni mogą stanowić większość dotychczasowych uczestników rynku kryptowalut⁴⁵. Można zatem przypuszczać, że w okresie wzrostu niepewności uczestnicy rynku Bitcoina w większym stopniu ulegają heurystyce zakotwiczenia, co powinno prowadzić do obniżenia poziomu efektywności rynku Bitcoina.

W okresie wzrostu niepewności niechęć dotychczasowych inwestorów do strat może się zwiększyć (z powodu niskiej ceny aktywa), co wraz z oddziaływaniem heurystyki zakotwiczenia na podejmowanie decyzji inwestycyjnych może prowadzić do wystąpienia efektu dyspozycji - zbyt długiego utrzymywania w portfelu inwestycyjnym walorów, które potencjalnie tracą na wartości. Zatem przeciętna skłonność dotychczasowych inwestorów do sprzedaży aktywa może się zmniejszać w okresie wzrostu niepewności, ponieważ wtedy inwestorzy indywidualni w większym stopniu ulegają heurystyce zakotwiczenia, wzrasta ich awersja do strat i skłonność do ryzyka, co prowadzi do wystąpienia efektu dyspozycji. Dlatego, pomimo poniesienia strat z inwestycji, większość z nich pozostaje na rynku Bitcoina przez dłuższy czas. W tym czasie

⁴⁴ Uleganie heurystyce zakotwiczenia może przejawiać się podejmowaniem decyzji inwestycyjnych na podstawie historycznych szczytów lub dołków notowań (Tversky i Kahneman, 1974).

⁴⁵ Dotychczasowi uczestnicy rynku oznaczają niedoświadczonych i część doświadczonych inwestorów, którzy pozostali na rynku w okresie wzrostu niepewności inwestycyjnej.

doświadczeni inwestorzy mogą w mniejszym stopniu ulegać heurystyce zakotwiczenia i dążyć do ochrony kapitału kierując się minimalizacją ryzyka portfela inwestycyjnego. Możliwe, że dokonują oni wtedy realokacji kapitału sprzedając aktywa inwestycyjne, które potencjalnie tracą na wartości i nabywając inwestycje, których wartość zwiększa się w okresie wzrostu niepewności. Jeśli utrzymują oni w portfelu inwestycje, z których stopy zwrotu są mocno skorelowane z cyklem koniunkturalnym oraz Bitcoinu, to w okresie wzrostu niepewności inwestycyjnej (okres spadku cen akcji) będą chcieli nabywać aktywa, których wartość zmienia się w przeciwnym kierunku do zmian wartości aktywa o mniejszej zmienności cen, czyli akcji. Bitcoin nie jest tzw. silną bezpieczną⁴⁶ przystanią dla portfela akcji notowanych na rynkach rozwiniętych (Mizerka i in., 2020). Natomiast złoto jest negatywnie skorelowane ze stopami zwrotu z inwestycji w akcje notowane na tego typu rynkach (Baur i McDermott, 2010). Dlatego doświadczeni inwestorzy mogą wycofywać kapitał z rynku Bitcoinu i zwiększać ekspozycję portfela inwestycyjnego na rynek złota. Można zatem oczekiwać, że w okresie wzrostu niepewności nastąpi spadek ich liczby na rynku Bitcoinu. W tym czasie niedoświadczeni inwestorzy pozostają na rynku, ponieważ są bardziej podatni na efekt dyspozycji. Powoduje to wzrost skłonności ogółu inwestorów do ulegania heurystyce zakotwiczenia. W ten sposób poziom efektywności rynku Bitcoinu zmniejsza się.

W okresie obniżenia niepewności inwestycyjnej mogą pojawiać się informacje na temat pozytywnych perspektyw danego rynku, co może być związane ze wzrostem cen walorów notowanych na tym rynku. Wraz ze zbliżaniem się ceny rynkowej do historycznego maksimum notowań, skłonność niedoświadczonych inwestorów do szybkiej realizacji zysków z inwestycji może wzrosnąć (zmniejsza się ich skłonność do ryzyka) (George i Hwang, 2004). Zatem stają się oni mniej podatni na zachowania spekulacyjne, ponieważ według nich bardziej prawdopodobne jest, że cena aktywa spadnie po osiągnięciu historycznego maksimum niż wzrośnie. W okresie wzrostów cen Bitcoinu, na ten rynek mogą powrócić doświadczeni inwestorzy, których zachowanie w mniejszym stopniu prowadzi do występowania efektu dyspozycji (są mniej skłonni do zbyt szybkiej realizacji zysków). Zatem, jeśli niedoświadczeni inwestorzy przedwcześnie realizują zyski z inwestycji, to można założyć, że wychodzą oni z rynku. W tym samym czasie doświadczeni inwestorzy powracają na rynek Bitcoinu. W efekcie

⁴⁶ Silną bezpieczną przystań (*a strong safe haven*) zdefiniować można jako aktywo, które jest negatywnie skorelowane z portfelem inwestycyjnym lub innym aktywem, utrzymywanym w portfelu inwestycyjnym w czasie wysokiej niepewności (Baur i McDermott, 2010).

ich udział na rynku zwiększa się. Ponieważ doświadczeni inwestorzy są mniej podatni na przejawy nieracjonalnego zachowania, można stwierdzić, że skłonność ogółu inwestorów do ulegania heurystyce zakotwiczenia zmniejsza się. W ten sposób poziom efektywności rynku Bitcoina zwiększa się.

Na podstawie przedstawionego powyżej opisu relacji między skłonnością do ulegania heurystyce zakotwiczenia a poziomem efektywności rynku Bitcoina oraz opracowanego schematu dotyczącego zależności pomiędzy zmianami warunków rynkowych a intensywnością występowania błędów behawioralnych wśród inwestorów, postawiono następującą hipotezę:

H3: *Wzrost (spadek) skłonności inwestorów do ulegania heurystyce zakotwiczenia jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.*

Powyższe rozważania wskazują, że zmiany poziomu efektywności rynku Bitcoina mogą być związane z oddziaływaniem czynników behawioralnych na decyzje (zachowania) dotychczasowych uczestników rynku Bitcoina. Ponadto, reakcje inwestorów na zmiany warunków rynkowych mogą być różne i związane z ich doświadczeniem. Mniej doświadczeni inwestorzy mogą podejmować decyzje inwestycyjne w większym stopniu pod wpływem sentymentu lub uwagi inwestorów skierowanej na Bitcoina oraz ulegać heurystyce zakotwiczenia. Wysoki udział niedoświadczonych inwestorów na rynku Bitcoina może powodować, że zależność między dynamiką efektywności rynku Bitcoina a czynnikami behawioralnymi będzie silniejsza niż w przypadku innych, mniej ryzykownych aktywów.

W niniejszej pracy zostały postawione trzy hipotezy badawcze, które wynikają z przeprowadzonego przeglądu literatury dotyczącej znaczenia czynników behawioralnych na rynku kryptowalut i ich związku ze zmianami poziomu efektywności tego rynku (podrozdziały 2.3 i 2.4). W toku badania rozważano następujące czynniki behawioralne: sentyment inwestorów, uwaga inwestorów skierowana na dany rynek, heurystyki afektu, dostępności, reprezentatywności i zakotwiczenia, awersja do strat, odmienna awersja do ryzyka w kontekście zysków i strat, nadmierna pewność siebie, zachowania stadne. Niestety, w większości przypadków dane niezbędne do pomiaru natężenia czynników behawioralnych w przyjętym okresie badania nie były dostępne (lub ich pozyskanie było bardzo drogie).

3.2 Koncepcja pomiaru dynamiki efektywności rynku Bitcoina

Rynek efektywny w formie słabej cechuje się niezależnością kolejnych zmian cen oraz brakiem możliwości uzyskiwania ponadprzeciętnych stóp zwrotu na podstawie historycznych notowań inwestycji. Zatem zachowanie cen na takim rynku powinno przypominać błądzenie losowe. Ponieważ testy zależności i korelacji długookresowych mają szereg zalet związanych z ich stosowaniem⁴⁷, w niniejszej pracy zostaną wykorzystane miary należące do tej grupy testów.

Na rynku efektywnym proces kształtowania się cen ma charakter losowy. Specyficznym przypadkiem błądzenia losowego jest ruch Browna⁴⁸. Dla ruchu Browna charakterystyczna jest proporcjonalna zależność między zmiennością badanego szeregu czasowego (σ) a pierwiastkiem upływu czasu (t), co można zapisać następującym wzorem (Peters, 1994):

$$\sigma \sim \sqrt{t} \quad (25)$$

Tę relację mierzy się za pomocą wykładnika Hursta⁴⁹. W celu jego oszacowania zazwyczaj analizuje się związek pomiędzy zmiennością a wybranymi długościami okresu próbkowania (n), odzwierciedlającymi różne skale czasowe, co przedstawia poniższy wzór (Kantelhardt i in., 2002):

$$F(n) = n^h, \quad (26)$$

gdzie h oznacza wartość wykładnika Hursta, a $F(n)$ to wartość wybranej miary zmienności badanego szeregu czasowego. Zatem wartość wykładnika Hursta wskazuje na stopień podobieństwa zachowania szeregu czasowego do błądzenia losowego.

Interpretując wykładnik Hursta (H) można rozpatrywać trzy przypadki (Peters, 1994):

$$H \begin{cases} > 0,5, & \text{co oznacza persystentny szereg czasowy, czyli rynek nieefektywny} \\ = 0,5, & \text{co oznacza błądzenie losowe szeregu czasowego, czyli rynek efektywny} \\ < 0,5, & \text{co oznacza antypersystentny szereg czasowy, czyli rynek nieefektywny} \end{cases}$$

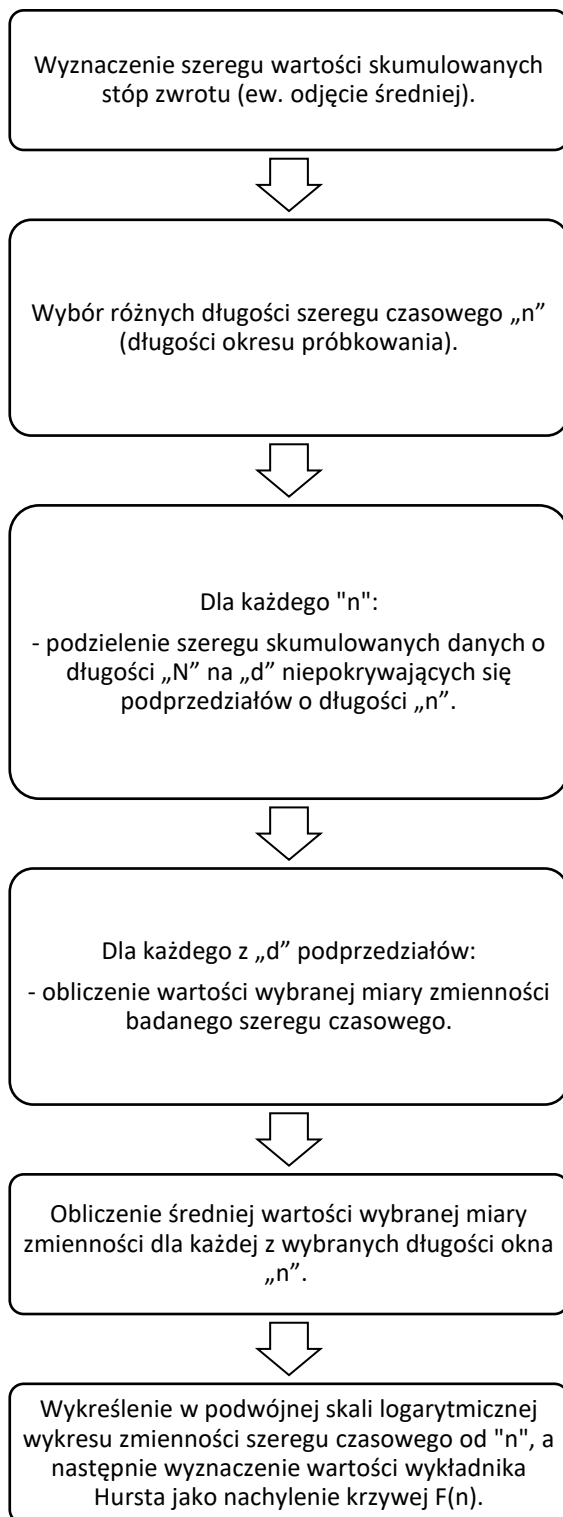
Występowanie procesu persystentnego oznacza, że badany szereg czasowy charakteryzuje się dodatnią autokorelacją. Niniejszą zależność można rozumieć jako duże prawdopodobieństwo zachowania dotychczasowego trendu cen walorów notowanych na rynku. Występowanie antypersystentnego szeregu czasowego można rozumieć jako ujemną autokorelację. Innymi słowy, jest wysoce prawdopodobne, że po wzroście ceny nastąpi jej spadek. Wartości wykładnika Hursta bliższe „1” lub „0” oznaczają silniejszą autokorelację

⁴⁷ Zalety testów zależności i korelacji długookresowych omówiono w podrozdziale 1.2.

⁴⁸ Najważniejsze założenia ruchu Browna przedstawiono w podrozdziale 1.2

⁴⁹ Szczegóły dotyczące wykładnika Hursta zaprezentowano w podrozdziale 1.2.

szeregu czasowego. Zatem im wartość wykładnika Hursta bardziej odbiega od 0,5, tym prawdopodobieństwo uzyskania ponadprzeciętnych stóp zwrotu na podstawie przeszłych informacji cenowych może być większe, czyli poziom efektywności rynku jest niższy. Ogólną procedurę wyznaczania wykładnika Hursta zaprezentowano na schemacie 3.



Schemat 3. Ogólny schemat szacowania wykładnika Hursta

Źródło: Opracowanie własne

W badaniach wykorzystuje się różne metody szacowania wykładnika Hursta. Do najpopularniejszych metod jego wyznaczania należą: analiza przeskalowanego zasięgu (*rescaled range analysis*, R/S), która została opracowana przez Hursta (1951), analiza odtrendowanej fluktuacji (*Detrended Fluctuation Analysis*, DFA), która została zaproponowana przez Penga i in. (1995) oraz multifrakalna analiza odtrendowanej fluktuacji (*Multifractal Detrended Fluctuation Analysis*, MF-DFA), którą rozwinęli Kantelhardt i in. (2002). Ponieważ poszczególne kroki szacowania wykładnika Hursta mogą różnić się w zależności od zastosowanej metody, schemat szacowania wykładnika Hursta zostanie omówiony również z uwzględnieniem najważniejszych różnic między nimi.

Uwzględniając rozbieżności i podobieństwa między R/S, DFA i MF-DFA, szczegółowy proces szacowania wykładnika Hursta można przedstawić w następujący sposób:

1) Na podstawie szeregu czasowego stóp zwrotu (r_t) o długości „N” dla wszystkich obserwacji wyznacza się wartości skumulowane (X_t). W przypadku DFA i MF-DFA na tym etapie można odjąć średnią stóp zwrotu z badanego okresu (*mean*). Jednakże, nie jest to wymagane, gdyż szereg czasowy może być „oczyszczony” na czwartym etapie przez eliminację lokalnego trendu ($y_v(t)$, krok 4) w podprzedziałach. Natomiast, w ramach R/S odjęcie średniej stóp zwrotu od ich wartości w podprzedziałach jest obligatoryjne. Zatem ogólny wzór na wartość skumulowaną można zapisać w następujący sposób:

$$X_t = \sum_{i=1}^t |r_i - mean|, \text{ gdzie } t = 1, \dots, N. \quad (27)$$

2) Wybór kilku różnych długości okresów próbkowania (n) (długości podprzedziałów).

3) Podzielenie szeregu skumulowanych danych (X_t) o długości „N” na „d” niepokrywających się podprzedziałów o długości „n” ($n = \frac{N}{d}$). Krok ten dotyczy wszystkich rozważanych metod szacowania wykładnika Hursta. W przypadku metody MF-DFA procedura podziału szeregu wartości skumulowanych jest dodatkowo przeprowadzana od końca tego szeregu, tzn. ostatni element szeregu czasowego jest traktowany jako pierwszy (w ten sposób uzyskuje się „2d” podprzedziałów). Powodem takiego sposobu podziału szeregu czasowego jest fakt, że szereg czasowy nie zawsze jest iloczynem rozważanej skali czasowej „n” (przyjętej długości podprzedziału)⁵⁰.

4) Dla każdego z „d” podprzedziałów:

⁵⁰ Na przykład, szereg o długości 1009 obserwacji można podzielić na 100 różnych podprzedziałów o tej samej długości dziesięciu stóp zwrotu. W przypadku metody DFA zachowanie stóp zwrotu w ostatnim podprzedziale nie zostałyby uwzględnione, ponieważ jego długość jest krótsza niż wymagana („9 < 10”).

- w przypadku zastosowania R/S oblicza się przeskalowany zasięg ($R/S(n, v)$) w podprzedziałach o długości „n”:

$$R/S(n, v) = (X_{max} - X_{min})/S, \quad (28)$$

gdzie X_{max}/X_{min} to maksymalna/minimalna wartość skumulowana w danym podprzedziale „v”, S to odchylenie standardowe szeregu stóp zwrotu w podprzedziale o numerze $v = 1, \dots, d$,

- w przypadku wykorzystania DFA lub MF-DFA wyznacza się lokalny trend ($y_v(t)$) w podprzedziale „v”, gdzie $v = 1, \dots, d$ i oznacza numer podprzedziału. Ponieważ wartości $y_v(t)$ mogą być szacowane z wykorzystaniem wielomianu dowolnego stopnia (w), funkcję tą można zapisać następująco:

$$y_v(t) = a_w t^w + a_{w-1} t^{w-1} + \dots + b, \quad (29)$$

gdzie $a_w \neq 0$, „b” to wyraz wolny, „t” to czas. W ramach DFA często przyjmuje się, że lokalny trend ma postać funkcji liniowej (tzn. $w = 1$), której parametry są wyznaczone KMNK.

Następnie dla każdego podprzedziału o numerze $v = 1, \dots, d$ oblicza się wariancję za pomocą zdefiniowanej poniżej funkcji:

$$F^2(n, v) = \frac{1}{n} \sum_{t=1}^n \{X[(v-1)n + t] - \widehat{y}_v(t)\}^2, \quad (30)$$

- w przypadku zastosowania MF-DFA również dla każdego podprzedziału o numerze $v = d + 1, \dots, 2d$ oblicza się wariancję za pomocą następującej funkcji:

$$F^2(n, v) = \frac{1}{n} \sum_{t=1}^n \{X[N - (v-d)n + t] - \widehat{y}_v(t)\}^2. \quad (31)$$

5) Dla każdej z wybranych długości okna „n” oblicza się średnią wartość wybranej miary zmienności:

- w przypadku zastosowania metody R/S oblicza się średni przeskalowany zasięg:

$$R/S(n) = \frac{1}{d} \sum_{v=1}^d R/S(n, v), \quad (32)$$


- w przypadku wykorzystania DFA oblicza się funkcję fluktuacji rzędu drugiego:

$$F(n) = \left\{ \frac{1}{d} \sum_{v=1}^d [F^2(n, v)] \right\}^{1/2}, \quad (33)$$

- w przypadku MF-DFA, liczy się funkcję fluktuacji rzędu „q” dla długości okna „n”:

$$F_q(n) = \left\{ \frac{1}{2d} \sum_{v=1}^{2d} [F^2(n, v)]^{q/2} \right\}^{1/q}. \quad (34)$$

6) Kroki od 3) do 5) powtarza się dla kilku rozmiarów okna „n”. W przypadku zastosowania metody R/S również krok pierwszy jest powtarzany dla każdej z wybranych długości okna „n”. Następnie wykreśla się w podwójnej skali logarytmicznej wykres średnich wartości wybranej miary zmienności od „n” i dopasowuje się do niego linię trendu za pomocą KMNK. Współczynnik nachylenia tej linii jest wartością wykładnika Hursta. Niniejszą zależność dla losowego procesu cen przedstawiono na wykresie 4.



Wykres 4. Przykład wyznaczenia wykładnika Hursta (H) na podstawie długości okresów próbkowania (n) i odpowiednich wartości miary zmienności (F(n))

Źródło: Opracowanie własne

Wskazane różnice w szacowaniu wykładnika Hursta za pomocą różnych metod mogą powodować, że oszacowany stopień pamięci szeregu czasowego będzie różnił się w zależności od przyjętego sposobu pomiaru. Analiza przeskalowanego zasięgu nie jest odporna na niestacjonarność szeregu czasowego (Bariviera i in., 2017). Niestacjonarność może być właściwością szeregu stóp zwrotu z Bitcoiną, ponieważ na tym rynku występuje tzw. grupowanie się zmienności (Aggarwal, 2019). Zatem analiza przeskalowanego zasięgu może nie być właściwą metodą do oceny stopnia losowości zachowania stóp zwrotu z inwestycji, które charakteryzuje wysoka zmienność cen (np. Bitcoin).

Według Grau-Carles (2000), metoda DFA jest bardziej odporna na niestacjonarność badanych szeregów czasowych niż analiza przeskalowanego zasięgu. Innymi słowy, zastosowanie analizy odtrendowanej fluktuacji nie prowadzi do wskazania pozornej długiej pamięci szeregu czasowego, która w rzeczywistości może być skutkiem jego niestacjonarności.

Może to wynikać ze znaczącej różnicy między tymi metodami szacowania wykładnika Hursta - tylko MF-DFA i DFA zakładają „oczyszczenie” szeregu czasowego z lokalnego trendu występującego w podprzedziałach „ ν ” (krok 4). Zazwyczaj zakłada się, że lokalny trend ma postać funkcji liniowej lub kwadratowej (Kristoufek, 2010), co pozwala skutecznie usunąć trendy występujące w danych⁵¹. Zatem przyjmując pierwszy lub drugi stopień wielomianu do odtrendowania szeregu stóp zwrotu w trakcie szacowania wartości wykładnika Hursta za pomocą DFA można uzyskać bardziej wiarygodne rezultaty dotyczące stopnia pamięci szeregu czasowego.

Zaletą stosowania multifraktalnej analizy odtrendowanej fluktuacji jest możliwość zmieniania wartości różnych parametrów, które w pozostałych metodach w trakcie szacowania wykładnika Hursta są „z góry” przyjmowane za stałe (Kantelhardt i in., 2002). Jednym z etapów szacowania wykładnika Hursta metodą MF-DFA jest podział badanego szeregu czasowego na rozłączne podprzedziały o równej długości. W przypadku metody DFA ta procedura jest wykonywana tylko od początku do końca szeregu czasowego (w jednym kierunku), co w pewnej sytuacji może prowadzić do niedoszacowania stopnia jego pamięci. Na przykład, jeśli liczba stóp zwrotu w różnych miesiącach okresu badania zmienia się znacząco, to zachowanie pozostałej części szeregu stóp zwrotu po jego podziale na równe podprzedziały może nie zostać uwzględnione w badaniu. Dzieje się tak, ponieważ w tym przypadku liczba obserwacji w ostatnim podprzedziale może być mniejsza od liczby notowań w pozostałych podprzedziałach (przyjętej długości podprzedziału). W efekcie, wartość wykładnika Hursta wyliczona na podstawie DFA może nie odzwierciedlać rzeczywistego zachowania szeregu czasowego. Bardziej odporną metodą na zmiany długości badanego szeregu czasowego jest MF-DFA, w ramach której podział badanego szeregu czasowego na rozłączne podprzedziały o równej długości jest wykonywany w dwóch kierunkach - od początku do końca szeregu czasowego i odwrotnie. Zatem możliwość analizy korelacji występujących w szeregu czasowym o długości, która nie jest krotnością ustalonej długości podprzedziału, jest argumentem przemawiającym za wykorzystaniem MF-DFA. Inną zaletą tej metody szacowania wykładnika Hursta jest możliwość wyboru rzędu funkcji fluktuacji. Ponadto, symulacje przeprowadzone przez Werona (2002) i Kristoufka (2010) pokazały, że oszacowania uzyskiwane na podstawie analizy odtrendowanej fluktuacji są bardziej stabilne niż w

⁵¹ Wartości wykładnika Hursta uzyskane przy założeniu wielomianu trzeciego stopnia nie różnią się znacznie od jego oszacowań w przypadku wielomianu pierwszego stopnia (Vandewalle i in., 1997).

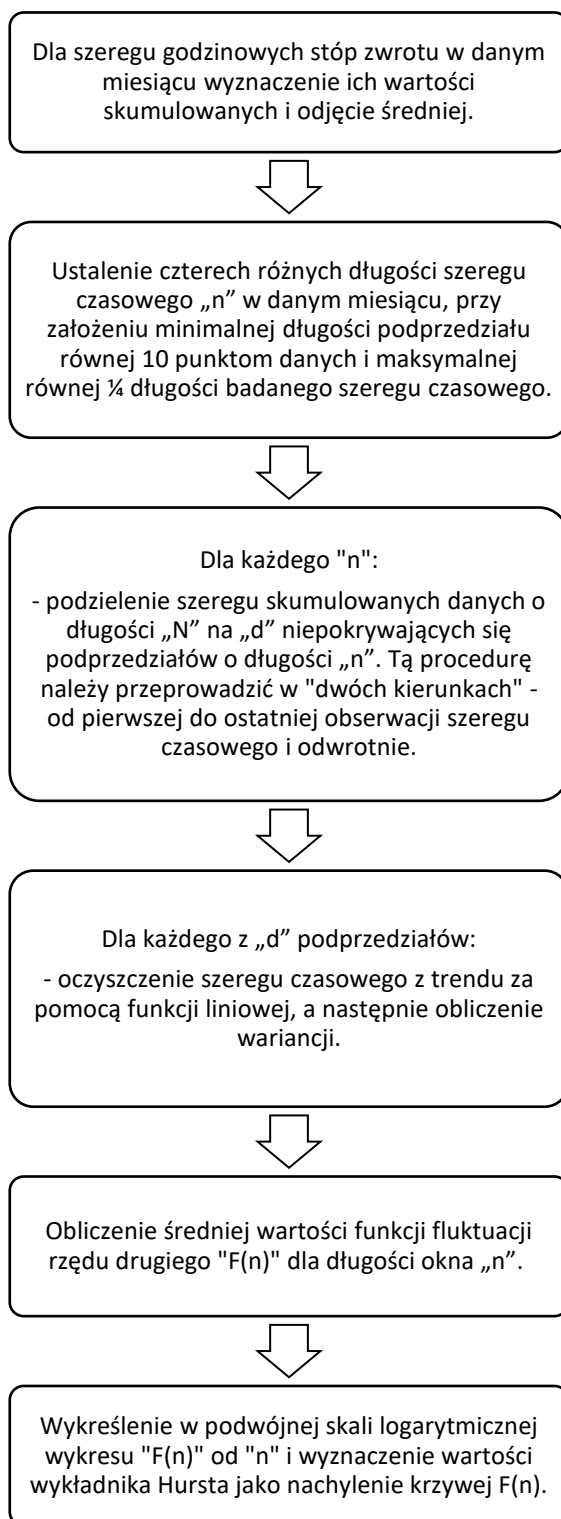
przypadku innych klasycznych metod szacowania stopnia długiej pamięci szeregu czasowego. Ponieważ DFA jest prostszą odmianą MF-DFA, to można oczekiwać, że multifraktalna analiza odtrendowanej fluktuacji przy odpowiednich założeniach (funkcji fluktuacji rzędu drugiego - „ $q=2$ ”) będzie zapewniała równie stabilne oszacowania wykładnika Hursta co DFA. Zatem MF-DFA jest najbardziej odpowiednim sposobem szacowania wykładnika Hursta w przypadku niniejszego badania.

Biorąc pod uwagę zalety związane z wykorzystaniem wykładnika Hursta w badaniu zaplanowanym w ramach niniejszej pracy, poziom efektywności rynku został oszacowany za pomocą multifraktalnej analizy odtrendowanej fluktuacji. Badanym szeregiem czasowym były godzinowe stopy zwrotu z Bitcoina. Żeby zapewnić zgodność okresu pomiaru zmiennych niezależnych i zmiennej zależnej, a także większą liczbę stopni swobody, wartości wykładnika Hursta obliczono w ruchomym oknie o długości jednego miesiąca z krokiem przesunięcia równym jeden miesiąc⁵². W efekcie wykładnik Hursta odzwierciedla stopień podobieństwa do błędzenia losowego godzinowych stóp zwrotu w danym miesiącu.

W ramach MF-DFA przyjęto liniową funkcję do oczyszczenia szeregu czasowego z trendu i obliczono funkcję fluktuacji rzędu drugiego. W trakcie szacowania wartości wykładnika Hursta uwzględniono cztery⁵³ różne długości okresu próbkowania (długości podprzedziałów, na które równo dzieli się badany szereg czasowy), rozmieszczone w równych odstępach na wykresie w skali logarytmicznej (krok 6.). Dzięki temu oszacowania parametrów regresji, która służy do estymacji wartości wykładnika Hursta nie powinny być obarczone dużym błędem szacunku. Dla stabilności oszacowań również rekomenduje się, aby przyjąć minimalną długość podprzedziału równą przynajmniej 10 punktom danych i maksymalną równą $\frac{1}{4}$ długości badanego szeregu czasowego (Kantelhardt i in., 2002; Gulich i Zunino, 2014). W niniejszym badaniu minimalna długość przedziału była równa 10 punktom danych, a maksymalna liczba obserwacji w przedziale wynosiła $\frac{1}{4}$ długości szeregu czasowego (około 180 obserwacji). W ten sposób uzyskano szereg wartości wykładnika Hursta w kolejnych miesiącach okresu badania. Podsumowanie przyjętych założeń w kolejnych etapach szacowania wykładnika Hursta przedstawiono na schemacie 4.

⁵² W przypadku okresu dłuższego niż 5 lat, indeksy zapytań w Google dostępne są tylko w częstotliwości miesięcznej.

⁵³ Wartości parametrów regresji wykorzystywanej do wyznaczenia wartości wykładnika Hursta, oszacowane tylko na podstawie 3 punktów danych (różne długości podprzedziału) mogą być obarczone dużym błędem szacunku (Weron, 2002).



Schemat 4. Schemat szacowania wartości wykładnika Hursta na potrzeby badania

Źródło: Opracowanie własne

Aby zmierzyć dynamikę efektywności rynku zazwyczaj dokonuje się pomiaru poziomu efektywności rynku w nakładających się na siebie podokresach (Bariviera, 2017). W ten sposób

kolejne wartości miary efektywności rynku są od siebie zależne, a ich zmiany mogą wskazywać na wzrost lub spadek poziomu efektywności rynku w stosunku poprzedniego okresu. Takie podejście może jednak powodować trudność w jednoznacznym wskazaniu momentu wystąpienia zdarzenia, które mogło wpłynąć na zmianę poziomu efektywności rynku - w ramach tzw. nakładającego się ruchomego okna zmieniają się zarówno początek, jak i koniec analizowanego okresu. Na przykład, zmiana poziomu efektywności rynku oszacowanego w ruchomym oknie z krokiem przesunięcia równym jednemu dniowi może wynikać zarówno ze zdarzenia, które miało miejsce na początku, jak i na końcu badanego okresu. Dlatego w niniejszym badaniu poziom efektywności rynku Bitcoina będzie wyznaczany w rozłącznych okresach, co pozwala uniknąć niejasności interpretacyjnych.

Wykładnik Hursta (H) jest względną miarą efektywności rynku, co utrudnia jego wykorzystanie do pomiaru dynamiki w przypadku występowania dużej zmienności jego oszacowań. Na przykład, jeżeli w miesiącu „t” wartość H wyniosła 0,45, a w miesiącu następnym „t+1” wartość H była równa 0,47, to wartość wykładnika Hursta zbliżyła się do wartości oznaczającej błądzenie losowe (zwiększenie poziomu efektywności rynku). W sytuacji gdy pierwsza wartość wykładnika Hursta jest wyższa (lub niższa) od 0,5, a następna wartość jest niższa (lub wyższa) od 0,5, interpretacja zmiany poziomu efektywności rynku jest bardziej skomplikowana niż poprzednio. Na przykład, gdyby w miesiącu „t+1” wartość H wzrosła do 0,58 (zamiast 0,47), oznaczałoby to zmniejszenie poziomu efektywności rynku, ponieważ odchylenie wartości wykładnika Hursta od 0,5 zwiększyło się (pierwotnie odchylenie wynosiło 0,05, a po zmianie było równe 0,08). W tym przypadku wartości wykładnika Hursta nie można od siebie odjąć. Wynika to z tego, że wartość H powyżej 0,5 jest destymulantą, a wartość wykładnika Hursta poniżej 0,5 jest stymulantą. Zatem chcąc badać dynamikę należy zastosować inną metodę pomiaru zmian poziomu efektywności rynku.

W różnych badaniach (m. in. Kristoufek i Vosvrda (2013), Ren i in. (2024)) zauważono, że poziom efektywności rynku można zmierzyć za pomocą bezwzględnego odchylenia miary efektywności rynku od jej wartości, jaka wystąpiłaby gdyby rynek był efektywny. Zatem to nie wartość wykładnika Hursta sama w sobie wskazuje na poziom efektywności rynku, ale jej odchylenie od punktu odniesienia (0,5). Dlatego zmiana poziomu efektywności rynku jest liczona jako zmiana kolejnych wartości bezwzględnego odchylenia wykładnika Hursta od wartości 0,5 (wartości, jaka wystąpiłaby w przypadku błądzenia losowego stóp zwrotu). W celu uproszczenia interpretacji tej zmiennej wyłączono minus przed nawias. Zatem zmienną

zależną w badaniu jest miesięczna zmiana efektywności rynku, którą można zapisać następującym wzorem:

$$Zm_ef_t = -(|H_t - 0,5| - |H_{t-1} - 0,5|), \quad (35)$$

gdzie Zm_ef_t oznacza zmianę poziomu efektywności rynku w okresie „t” w stosunku do okresu „t-1”, H_t to wartość wykładnika Hursta w okresie „t”, „ $|H_t - 0,5|$ ” („ $|H_{t-1} - 0,5|$ ”) oznaczają stopień podobieństwa zachowania szeregu czasowego do błędzenia losowego w bieżącym (poprzednim) miesiącu. Dodatnie (ujemne) wartości zmiennej Zm_ef oznaczają wzrost (spadek) poziomu efektywności rynku w porównaniu do poprzedniego miesiąca.

Wykorzystując wykładnik Hursta do wyznaczenia poziomu efektywności rynku dokonuje się pomiaru relacji pomiędzy zmiennością badanego szeregu czasowego a długością okresu próbkowania. Błądzenie losowe charakteryzuje się również tym, że wariancja szeregu czasowego z badanego okresu jest „k-krotnością” wariancji zmierzonej w podokresie. Dlatego, w celu pogłębienia wyników badania wykorzystano również inną miarę - test ilorazu wariancji. Dla procesu losowego iloraz wariancji stóp zwrotu z „k” okresów i „k-krotności” wariancji z jednego okresu jest równy 1, co oznacza rynek efektywny (wzór nr 12 w podrozdziale 1.2). Zatem porównując oszacowania ilorazu wariancji z liczbą 1 można określić czy badany szereg czasowy charakteryzuje błędzenie losowe (Choi, 1999).

Klasyczna metoda przeprowadzenia tego testu poziomu efektywności rynku może jednak dawać błędne rezultaty, gdyż wybór wartości parametru „k” jest subiektywny (Choi, 1999). Ponadto, wyniki tego testu dla małych prób badawczych, które charakteryzuje warunkowa heteroskedastyczność mogą nie być dokładne (Kim, 2009). Dlatego zastosowano automatyczny test ilorazu wariancji (*Automatic variance ratio test, AVR*). W ramach tego testu optymalna wartość parametru „k” jest ustalana niezależnie od użytkownika, na podstawie zależności zachodzących w danych.

Statystyka testu ilorazu wariancji może być zapisana jako ważona suma współczynników autokorelacji stóp zwrotu. Zatem dla szeregu stóp zwrotu r_t z okresu „t” ($t=1,2,3,\dots,N$) estymator ilorazu wariancji jest zdefiniowany w następujący sposób⁵⁴:

$$\widehat{VR}(k) = 1 + 2 \sum_{i=1}^{N-1} m\left(\frac{i}{k}\right) \hat{\rho}(i), \quad (36)$$

⁵⁴ Estymator ilorazu wariancji jest szacowany z wykorzystaniem jądra QS (*Quadratic Spectral kernel*), co odzwierciedla funkcja $m(x)$ (Kim, 2009).

gdzie $\hat{\rho}(i) = \frac{\sum_{t=1}^{N-i}(r_t - \hat{u})(r_{t+i} - \hat{u})}{\sum_{t=1}^N (r_t - \hat{u})^2}$, $\hat{u} = N^{-1} \sum_{t=1}^N r_t$, $m(x) = \frac{25}{12\pi^2 x^2} \left[\frac{\sin(\frac{6\pi x}{5})}{\frac{6\pi x}{5}} - \cos(\frac{6\pi x}{5}) \right]$, „k” to

liczba kolejnych okresów (opóźnień) uwzględnionych w trakcie obliczania ilorazu wariancji (maksymalny rząd opóźnienia), „i” oznacza rząd autokorelacji stóp zwrotu.

Choi (1999) zauważył, że dokonując standaryzacji estymatora ilorazu wariancji ($\widehat{VR}(k)$) statystyka testowa dla hipotezy zerowej o nieskorelowaniu stóp zwrotu przyjmuje następującą postać:

$$AVR(k) = \sqrt{N/k} [VR(k) - 1] / \sqrt{2} \quad (37)$$

gdzie stopy zwrotu mają ten sam niezależny rozkład (*identical independent distribution, iid*). Wartość statystyki AVR wyższa od zera oznacza dodatnią autokorelację stóp zwrotu. Natomiast wartość tej statystyki niższa od zera oznacza ujemną autokorelację stóp zwrotu. Można zatem stwierdzić, że wartość statystyki AVR wskazuje na stopień przewidywalności stóp zwrotu z inwestycji na podstawie jej historycznych notowań (Kim i in., 2011). Dlatego zmiana poziomu efektywności rynku w przypadku tej miary będzie liczona jako pierwsze różnice kolejnych bezwzględnych wartości statystyki AVR. Ponadto, zmienna ta zostanie przemnożona przez „-1”. Dzięki temu zmienną $Zm_Ef_t^{AVR}$ można interpretować podobnie do zmiany efektywności rynku (Zm_ef_t) wyprowadzonej na podstawie definicji wykładnika Hursta (wzór numer 35). Zmienną oznaczającą zmianę poziomu efektywności rynku oszacowaną na podstawie statystyki AVR wyraża poniższy wzór:

$$Zm_Ef_t^{AVR} = -(AVR_t - AVR_{t-1}), \quad (38)$$

gdzie $Zm_Ef_t^{AVR}$ oznacza zmianę poziomu efektywności rynku w okresie „t” w stosunku do okresu „t-1”, AVR_t to wartość statystyki AVR w okresie „t”. Dodatnia (ujemna) wartość zmiennej $Zm_Ef_t^{AVR}$ oznacza wzrost (spadek) poziomu efektywności rynku w porównaniu do poprzedniego miesiąca.

Wykładnik Hursta jako miara efektywności rynku odwołuje się do stopnia niezależności stóp zwrotu z inwestycji. Ten wymiar błędzenia losowego znajduje także odzwierciedlenie w testach rzędu integracji ułamkowej. Dlatego, w celu przeprowadzenia dodatkowych analiz w badaniu zostanie wykorzystany estymator rzędu integracji ułamkowej (GPH), opracowany przez Geweke’a i Portera-Hudaka (1983). Zaletą tego estymatora jest jego odporność na krótkookresowe zaburzenia występujące w ramach badanego procesu (Gurgul i in., 2009).

Szacowanie długiej pamięci z wykorzystaniem GPH można podzielić na dwa zasadnicze etapy (Gurgul i in., 2009):

1. Obliczenie periodogramu szeregu czasowego $\{r_1, r_2, \dots, r_N\}$ przy częstotliwości λ_k , co można zapisać następująco:

$$I(\lambda_k) = \frac{1}{2\pi N} \left| \sum_{t=1}^N r_t e^{it\lambda_k} \right|^2, \quad (39)$$

gdzie „ r_t ” to wartość obserwacji szeregu czasowego w okresie „ t ”, „ N ” to liczba obserwacji, $\lambda_k = \frac{2\pi k}{N}$ oznacza częstotności Fouriera zakładając, że $k = 1, 2, \dots, m$. W niniejszym badaniu założono, że parametr „ m ” jest równy $N^{0,5}$, tak jak proponują Geweke i Porter-Hudak (1983)⁵⁵.

2. Estymacja przekształconego równania funkcji gęstości spektralnej⁵⁶ za pomocą Klasycznej Metody Najmniejszych Kwadratów. W ten sposób następuje oszacowanie parametru „ d ” (rzędu integracji ułamkowej). Postać szacowanego równania w tym kroku jest następująca:

$$\ln(I(\lambda_k)) \approx a - 2d \ln(I(\lambda_k)) + \varepsilon, \quad (40)$$

gdzie „ a ” jest stałą, „ ε ” to składnik losowy.

W przypadku estymatora GPH zmienna zależna będzie wyznaczana jako przyrosty logarytmiczne z kolejnych bezwzględnych wartości parametru „ d ”⁵⁷. W celu ujednoczenia interpretacji wartości tej zmiennej zostały również przemnożone przez „-1”, co przedstawia poniższy wzór:

$$Zm_Ef_t^{GPH} = -(\ln(|d_t|) - \ln(|d_{t-1}|)), \quad (41)$$

gdzie $Zm_Ef_t^{GPH}$ oznacza zmianę efektywności rynku w okresie „ t ” w stosunku do okresu „ $t-1$ ”, d_t to wartość parametru rzędu integracji ułamkowej w okresie „ t ”. Dodatnia (ujemna) wartość zmiennej $Zm_Ef_t^{GPH}$ oznacza wzrost (spadek) poziomu efektywności rynku w porównaniu do poprzedniego miesiąca.

3.3 Wybór zmiennych objaśniających i sposób ich pomiaru

W pracy postawiono trzy hipotezy badawcze. Pierwsza z nich dotyczy związku pomiędzy uwagą inwestorów skierowaną na Bitcoina a zmianą poziomu efektywności tego rynku. Druga

⁵⁵ Zdaniem Werona (2002) mniejsze wartości wykładnika odnoszącego się do parametru „ N ” niż 0,5 prowadzą do większych błędów oszacowań długiej pamięci szeregu czasowego.

⁵⁶ Dla procesu charakteryzującego się długą pamięcią oznaczoną parametrem „ d ” funkcja gęstości spektralnej ma postać $f(\lambda) \sim c\lambda^{-2d}$.

⁵⁷ Dzięki transformacji logarytmicznej w trakcie obliczania wartości zmiennej rozkład reszt modelu ekonometrycznego został zbliżony do rozkładu normalnego (na podstawie testów Jarque-Bera i Shapiro-Wilka).

z wyprowadzonych hipotez odnosi się do zależności pomiędzy natężeniem sentymentu inwestorów a zmianą poziomu efektywności rynku Bitcoina. W ramach ostatniej hipotezy badawczej analizie będzie poddany związek pomiędzy skłonnością inwestorów do ulegania heurystyce zakotwiczenia a zmianą poziomu efektywności rynku Bitcoina.

Uwaga inwestorów skierowana na Bitcoina jest w pracy aproksymowana za pomocą indeksów wyszukiwań słowa „bitcoin” w wyszukiwarce Google (*GSV*). Tak jak w innych badaniach (m. in. Kristoufek (2013), Garcia i in. (2014)), jednym z powodów wyboru indeksu *GSV* jako aproksymanty uwagi inwestorów jest dostępność danych. Dane dotyczące liczby zapytań w wyszukiwarce Google są ogólnodostępne i można je pobrać dla całego okresu istnienia Bitcoina. Alternatywną możliwością jest przybliżenie uwagi inwestorów na podstawie liczby opublikowanych informacji na temat Bitcoina. Zmienna ta jednakże zdaje się odzwierciedlać w większym stopniu uwagę mediów niż gospodarstw domowych - wzrost liczby opublikowanych wiadomości na temat Bitcoina nie musi oznaczać analogicznego wzrostu zainteresowania inwestorów tym tematem (Da i in., 2011).

Inną aproksymantą uwagi inwestorów jest liczba opinii użytkowników mediów społecznościowych dotyczących kryptowalut lub Bitcoina. Jednakże, pozyskanie tego typu danych z serwisów takich jak X (dawniej Twitter), Reddit lub Stocktwits dla całego okresu badania jest niemożliwe (m. in. z uwagi na limity pobierania) lub bardzo drogie. Dlatego te sposoby pomiaru uwagi inwestorów nie są wykorzystywane w ramach niniejszego badania.

Przewagą indeksu *GSV* nad wspomnianymi aproksymantami jest również to, że w większym stopniu odzwierciedla on zachowanie mniej doświadczonych inwestorów (*less sophisticated investors*), którzy są bardziej podatni na czynniki behawioralne (Da i in., 2011). Na rynku kryptowalut przeważają niedoświadczeni inwestorzy indywidualni (Fonseca i in., 2020; Thomas i Sabater, 2022). Można zatem oczekiwać, że indeks *GSV* w dużym stopniu odzwierciedla przeciętną uwagę inwestorów na rynku kryptowalut.

Inną zaletą indeksu *GSV* w kontekście aproksymowania uwagi inwestorów jest dominująca pozycja Google’a na rynku wyszukiwarek internetowych⁵⁸. Aczkolwiek, Google nie ma większościowego udziału w rynku chińskim - jego udział szacuje się na około 20% (NetMarketShare, 2014, za: Gao i in., 2020). Wynika to z tego, że korzystanie z wyszukiwarki Google w Chinach jest oficjalnie zabronione. Pomimo tego użytkownicy Internetu w Chinach

⁵⁸ Firma Google w latach 2015-2024 posiadała około 90% udziału w rynku wyszukiwarek internetowych na świecie (StatCounter, 2024).

mogą mieć dostęp do tej wyszukiwarki za pomocą tzw. wirtualnych sieci prywatnych (VPN). Jednakże, brak wiedzy na ten temat lub obawy dotyczące możliwych represji ze strony władz chińskich za nieprzestrzeganie tego zakazu mogą zniechęcać do korzystania z usług Google'a. Zatem indeks GSV odzwierciedla zachowanie inwestorów indywidualnych w większości państw na świecie.

Indeks GSV przyjmuje wartości w skali od 1 do 100, gdzie wartość równa „100” oznacza maksymalną liczbę zapytań w wybranym okresie. Jednakże, gdy liczba zapytań w Internecie jest zbyt mała w stosunku do maksymalnej ich liczby w wybranym okresie, to wartość tego indeksu jest oznaczona jako „<1”. Zatem w pewnych okresach w szeregu czasowym mogą wystąpić brakujące wartości, które zazwyczaj zastępuje się zerem.

Wadą indeksu GSV jest zależność częstotliwości udostępnianych wartości od wybranego okresu pobierania. Dla okresu dłuższego niż 5 lat można pobrać tylko jego miesięczne wartości (Google Trends, 2024), co może prowadzić do niedoszacowania zmienności tego indeksu. Powodem tego jest mała precyzja sposobu prezentacji danych dotyczących wyszukiwań w Internecie przez firmę Google. Na przykład, gdy tylko w kilku miesiącach odnotowano bardzo dużą liczbę zapytań w Google'u na dany temat, to indeks GSV dla większości miesięcy w okresie badania będzie przyjmował wartości bliskie zeru. Jeżeli na podstawie takich danych zostanie obliczony szereg zmian miesięcznych wartości indeksu GSV, to jego zmienność może być niedoszacowana. Dzieje się tak, ponieważ obliczając pierwsze różnice (w celu sprowadzenia zmiennej do postaci stacjonarnej) na podstawie następujących po sobie małych wartości można uzyskać szereg, który w pewnych okresach charakteryzuje się brakiem zmienności. W efekcie można dojść do wniosku, że w tych okresach poziom uwagi inwestorów skierowanej na Bitcoina nie zmieniał się. Zatem w ten sposób może dojść do niedoszacowania zmienności indeksu.

Rozwiązaniem powyższego problemu jest obliczenie tzw. ważonego indeksu GSV (Zhu i in., 2021). W ten sposób można oszacować potencjalne wartości tego indeksu jakie mogłyby wystąpić w okresie dłuższym niż 5 lat. Zaletą takiego podejścia jest częściowe uwzględnienie w badaniu danych dziennych, które charakteryzuje większa zmienność niż w przypadku częstotliwości miesięcznej. Innymi słowy, zmienność wartości ważonego indeksu GSV powinna

być większa niż w przypadku indeksu wygenerowanego automatycznie dla całego okresu badania⁵⁹.

W związku z powyższym, w badaniu uwzględnione są dwie postacie indeksu GSV - indeks o częstotliwości miesięcznej pobrany dla całego okresu badania (GSV_t) oraz ważony indeks GSV (GSV_{w_t}). Wartość drugiego z tych indeksów (GSV_{w_t}) jest obliczana jako iloczyn wartości indeksu z danego miesiąca w całym okresie badania (wartość indeksu GSV_t z miesiąca „t”) i kolejnych dziennych wartości indeksu GSV pobranych dla danego miesiąca „t” ($GSV_{d,t}$). Ostatecznie w badaniu oblicza się średnią z dziennych wartości ważonego indeksu GSV w danym miesiącu. Wzór na wartość ważonego indeksu GSV (GSV_{w_t}) jest następujący (Zhu i in., 2021):

$$GSV_{w_t} = \frac{1}{n} \sum_{d=1}^n GSV_t * GSV_{d,t}, \quad (42)$$

gdzie „n” to liczba dni w miesiącu „t”, „d” to dany dzień w miesiącu, „ GSV_t ” to wartość indeksu o częstotliwości miesięcznej w okresie „t”, „ $GSV_{d,t}$ ” to wartość indeksu w dniu „d”.

Natężenie sentymentu inwestorów na potrzeby badania jest przybliżane za pomocą procedury opracowanej przez Da i in. (2015), w ramach której wykorzystuje się indeksy wolumenu wyszukiwań w Google dotyczące słów o określonym wydźwięku - pozytywnym lub negatywnym. Wybór tego sposobu aproksymacji sentymentu inwestorów podyktowany jest możliwością oszacowania za jego pomocą natężenia pozytywnego i negatywnego sentymentu inwestorów w całym okresie istnienia Bitcoina. Dane dotyczące wartości innych ogólnodostępnych wskaźników sentymentu inwestorów na rynku kryptowalut są możliwe do pobrania tylko dla relatywnie krótkiego okresu badania. Na przykład, The Crypto Fear & Greed Index⁶⁰ jest dostępny dla okresu po 2018 roku. Po drugie, dane na temat opinii bądź sentymentu użytkowników mediów społecznościowych (m. in. X, Reddit, Stocktwits) na temat kryptowalut lub Bitcoina nie są dostępne dla całego okresu badania (lub koszt ich pozyskania jest bardzo wysoki). Zatem zastosowanie sposobu szacowania sentymentu inwestorów opracowanego przez Da i in. (2015) umożliwia objęcie dłuższego okresu niż gdyby wykorzystać inny ogólnodostępny wskaźnik sentymentu lub dostępne dane z mediów społecznościowych. Ponadto, jak wspomniano wcześniej, indeksy wyszukiwań na dany temat w Google głównie

⁵⁹ Na przykład, gdy indeks GSV pobrany dla całego okresu badania wskazuje „1” w miesiącu „t”, to „ważony” indeks GSV wynosi wtedy 1,48. Jeżeli w kolejnym miesiącu „t+1” indeks GSV znowu wskaże „1”, jest wysoce prawdopodobne, że wartość „ważonego” indeksu GSV zmieni się, np. wzrośnie do 1,80.

⁶⁰ alternative.me/crypto/fear-and-greed-index/#history

odzwierciedlają zachowanie inwestorów indywidualnych, którzy są bardziej podatni na przejawy nieracjonalności i przeważają na rynku kryptowalut. Dlatego, miernik ten wykorzystano do pomiaru natężenia sentymentu inwestorów na rynku Bitcoina.

Szacowanie wartości natężenia negatywnego sentymentu inwestorów (FEARS) na rynku Bitcoina w badaniu zostanie przeprowadzone w następujący sposób (Da i in., 2015):

1. Wyselekcjonowanie słów o negatywnym lub pozytywnym wydźwięku, które są związane z ekonomią na podstawie danych ze słowników „Harvard IV-4 Dictionary” i „Lasswell Value Dictionary” (149 terminów). Następnie, dla każdego wybranego słowa zidentyfikowanie dziesięciu najpopularniejszych wyrażen⁶¹ pod względem liczby wyszukiwań w Internecie (łącznie $10 \cdot 149 = 1490$ wyrażen). Dla tych 1490 wyrażen i 149 wcześniej zidentyfikowanych terminów pobranie szeregów czasowych indeksu GSV dla wybranego okresu badania, uwzględniając dane pochodzące „z całego świata”, co odpowiada międzynarodowej strukturze inwestorów na rynku Bitcoina.

2. Usunięcie duplikatów i szeregów czasowych GSV dotyczących wyszukiwanych wyrażen lub słów, w przypadku których wystąpiły brakujące wartości (Google nie udostępnia wartości indeksów GSV w przypadku zbyt małej liczby wyszukiwań danego słowa).

3. Z pozostałych szeregów czasowych GSV (krok 2.) pozostawienie tylko tych, które dotyczą słów lub wyrażen związanych z ekonomią i finansami. W efekcie nastąpiło ograniczenie początkowej próby do 127 różnych szeregów czasowych GSV (dla zidentyfikowanych wyrażen i słów łącznie)⁶². Podobną wielkość próby na tym etapie badania otrzymali Da i in. (2015) - 118 elementów (pomimo, że szacowali natężenie sentymentu inwestorów tylko na rynku amerykańskim). Ponadto, większość terminów lub wyrażen przez nich zidentyfikowanych jest podobna do tych wyselekcjonowanych w ramach niniejszego badania. Wy tłumaczeniem tego może być fakt, że rynki finansowe są znacząco powiązane z rynkiem amerykańskim lub/i wyszukiwane wyrażenia są w języku angielskim.

4. Dla każdego wyrażenia lub terminu „i” w miesiącu „t” obliczenie zmiany logarytmu wartości indeksu wolumenu wyszukiwań w Google (GSV):

$$\Delta GSV_{i,t} = \ln(GSV_{i,t}) - \ln(GSV_{i,t-1}) \quad (43)$$

⁶¹ Wyrażenie odzwierciedla kombinację słów lub jedno słowo powiązane z wybranym terminem ekonomicznym, które są często wyszukiwane w Internecie przez użytkowników Google’a. Na przykład, dla słowa „bankruptcy” użytkownicy Google’a wyszukują także często „file bankruptcy”, „chapter 7 bankruptcy” itd.

⁶² Słowa/wyrażenia zaliczane do ostatecznej próby są oznaczone numerem „i” (i=1,2, 3,...,127).

5. Dla każdego wyrażenia lub terminu „i” przeprowadzenie winsoryzacji na poziomie 5%, usunięcie sezonowości⁶³ i dokonanie standaryzacji wartości szeregów czasowych $\Delta GSV_{i,t}$ (podzielenie przez odchylenie standardowe danego szeregu czasowego), co prowadzi do uzyskania zmiennej zdefiniowanej jako $\Delta AGSV_{i,t}$ (skorygowany indeks wolumenu wyszukiwań w Google).

6. Dla różnych wyrażen lub słów „i” oszacowanie regresji pomiędzy stopami zwrotu z Bitcoin a odpowiednimi wartościami indeksu $\Delta AGSV_{i,t}$ (krok 5.) w kolejnych miesiącach.

7. Na podstawie oszacowań regresji (pkt. 6) opracowanie rankingu wyszukiwanych w Internecie wyrażen i słów „i” (R^i). W ten sposób szeregi czasowe dla tych słów i wyrażen zostają uszeregowane od najmniejszych do największych wartości oszacowanego współczynnika przy zmiennej $\Delta AGSV_{i,t}$ w okresie badania. $R^i=1$ oznacza szereg czasowy GSV dla wyrażenia/słowa „i”, w przypadku którego otrzymano największą ujemną wartość współczynnika przy tej zmiennej (najsilniejszy negatywny związek ze stopami zwrotu z Bitcoin). Natomiast, $R^i=127$ wskazuje na szereg czasowy GSV dla wyrażenia/słowa „i” o najsilniejszym pozytywnym związku ze stopami zwrotu z Bitcoin. Ostatecznie tylko trzydzieści wyrażen lub słów, o najbardziej negatywnym związku ze stopami zwrotu z Bitcoin ($R^i = 1,2,3, \dots, 30$) jest uwzględnianych w trakcie szacowania wartości tego wskaźnika⁶⁴.

8. Policzenie średniej wartości wybranych trzydziestu indeksów $\Delta AGSV_{i,t}$ (krok 7.) dla kolejnych miesięcy w okresie badania ($\Delta AGSV_t$), co opisano wzorem:

$$FEARS_t = \sum_{i=1}^{30} \Delta AGSV_{t,R^i} / 30, \quad (44)$$

gdzie „ $\Delta AGSV_{t,R^i}$ ” oznacza $\Delta AGSV_{i,t}$ dla słowa/wyrażenia „i”, w przypadku którego oszacowanie parametru miało ranking „ R^i ” w miesiącu „t”. Dodatnia (ujemna) wartość indeksu $FEARS_t$ oznacza wzrost (spadek) natężenia negatywnego sentymentu inwestorów na rynku Bitcoin w porównaniu do poprzedniego miesiąca.

W badaniu zostanie również oszacowane natężenie pozytywnego sentymentu inwestorów na rynku Bitcoin (GREED). Szacowanie wartości indeksu GREED jest w dużym stopniu podobne do procedury szacowania indeksu FEARS - inny sposób postępowania dotyczy tylko

⁶³ Sezonowość wartości szeregów czasowych wyeliminowano na podstawie metody LOESS opracowanej przez Cleveland i in. (1990).

⁶⁴ Uwzględnione indeksy $\Delta AGSV$ w przypadku szacowania natężenia negatywnego sentymentu ostatecznie dotyczyły trzydziestu wyrażen bądź słów, które miały tylko negatywny wydźwięk. Natomiast, natężenie pozytywnego sentymentu inwestorów odzwierciedlało trzydzieści indeksów $\Delta AGSV$, które miały wyłącznie charakter pozytywny.

7. i 8. kroku. W ramach kroku 7. (powyżej zdefiniowanej procedury szacowania indeksu FEARS), do oszacowania natężenia pozytywnego sentymentu inwestorów wykorzystuje się trzydzieści szeregów czasowych GSV, które charakteryzują największe dodatnie wartości oszacowań parametrów przy zmiennej $\Delta AGSV_{i,t}$. Następnie szacuje się średnią wartości wybranych szeregów czasowych w kolejnych miesiącach. Wzór na ostateczną wartość indeksu GREED jest następujący:

$$GREED_t = \sum_{i=98}^{127} \Delta AGSV_{t,R^i} / 30, \quad (45)$$

gdzie „ $\Delta AGSV_{t,R^i}$ ” oznacza $\Delta AGSV_{i,t}$ dla słowa/wyrażenia „ i ”, w przypadku którego oszacowanie parametru miało ranking „ R^i ” w miesiącu „ t ”. Dodatnia (ujemna) wartość indeksu $GREED_t$ oznacza wzrost (spadek) natężenia pozytywnego sentymentu inwestorów na rynku Bitcoina w porównaniu do poprzedniego miesiąca.

Skłonność inwestorów do ulegania heurystyce zakotwiczenia w pracy jest aproksymowana za pomocą odchylenia ceny rynkowej od jej maksimum w ostatnich 52 tygodniach (George i Hwang, 2004). Miara ta zdaje się dobrze odzwierciedlać zachowanie uczestników rynku kryptowalut, którzy podejmują decyzje inwestycyjne na podstawie historycznych szczytów notowań inwestycji (Sood i in., 2023). Innym argumentem przemawiającym za wykorzystaniem odchylenia ceny rynkowej od jej historycznego maksimum jest łatwa dostępność danych niezbędnych do oszacowania wartości tej miary, czyli notowań Bitcoina. Po trzecie, odchylenie ceny rynkowej od jej historycznego maksimum jest podstawową informacją, do której dostęp mają inwestorzy (George i Hwang, 2004). Z drugiej strony, rynek Bitcoina charakteryzuje wysoka zmienność stóp zwrotu (Dwyer, 2015), co powoduje, że niedoświadczonym inwestorom trudno jest przeprowadzić szybką i dogłębną analizę tego rynku. Jest zatem wysoce prawdopodobne, że większość inwestorów na tym rynku ulega heurystyce zakotwiczenia na podstawie historycznych notowań inwestycji.

Jedną z wad tego sposobu pomiaru jest to, że zarówno bardzo duże, jak i małe odchylenie ceny rynkowej od jej historycznego maksimum może oznaczać wzrost skłonności inwestorów do ulegania przejawom nieracjonalności. Historyczny szczyt notowań może być postrzegany przez inwestorów jako „psychologiczna bariera” (Wang i in., 2023). W tej sytuacji mogą oni obawiać się, że cena rynkowa zacznie spadać po osiągnięciu historycznego maksimum. Dlatego chęć do realizacji zysków przez inwestorów powinna wzrastać wraz ze zbliżaniem się ceny rynkowej do jej historycznego maksimum. Z perspektywy niniejszego badania tylko zbyt

długie utrzymywanie walorów tracących na wartości przez niedoświadczonych inwestorów jest kluczowe dla obniżenia poziomu efektywności rynku. W przypadku zbyt szybkiej realizacji zysków z inwestycji przez niedoświadczonych inwestorów, wraz ze zbliżaniem się ceny do „psychologicznej bariery” zakłada się, że na rynek powracają doświadczeni inwestorzy, co powinno prowadzić do zmniejszenia przeciętnej skłonności inwestorów do nieracjonalnego zachowania (schemat 2 zaprezentowany w podrozdziale 3.1).

Podsumowując, skłonność inwestorów do ulegania heurystyce zakotwiczenia w pracy będzie aproksymowana za pomocą odchylenia średniej ceny Bitcoina w miesiącu „ t ” (P_t) od jej maksimum w ciągu ostatnich 12 miesięcy ($52HIGH_t$), co można przedstawić następująco (Wang i in., 2023):

$$W52_t = \frac{P_t}{52HIGH_t} \quad (46)$$

gdzie „ t ” oznacza bieżący miesiąc. Wskaźnik $W52_t$ może przyjmować wartości z zakresu od 0 do 1. Im wartość tego wskaźnika jest bliższa 0, tym większa skłonność inwestorów do ulegania heurystyce zakotwiczenia. Zatem spadek wartości zmiennej $W52_t$ skutkuje wzrostem przeciętnej skłonności ogółu inwestorów do ulegania heurystyce zakotwiczenia w porównaniu do poprzedniego miesiąca (i odwrotnie).

Na dalszym etapie badania dokonano weryfikacji czy zmienne są stacjonarne (lub skointegrowane ze zmienną zależną), ponieważ w przeciwnym razie może dojść do oszacowania tzw. „regresji pozornej”. Zmienne objaśniające były sprawdzane pod względem spełnienia warunku stacjonarności za pomocą dwóch testów statystycznych: Kwiatkowski-Phillips-Schmidt-Shin (KPSS) opracowanego przez Shin i in. (1992) i Augmented Dickey-Fuller (ADF), który został zaproponowany przez Dickey’a i Fullera (1981).

W pierwszej kolejności zweryfikowano stacjonarność pierwotnej postaci zmiennych objaśniających. Jeżeli stacjonarność tych zmiennych nie była jednoznacznie potwierdzona (wskazania testów statystycznych), dokonywano ich przekształceń. Aby zapewnić porównywalność interpretacji oddziaływania zmiennych na dynamikę efektywności rynku, w pierwszej kolejności rozważano sprowadzenie zmiennych do tej samej postaci - zmian logarytmów ich miesięcznych wartości⁶⁵. Wyniki testów stacjonarności zmiennych zaprezentowano w tabeli 15.

⁶⁵ Zmienne $FEARS_t$ i $GREED_t$ w podstawowej postaci odzwierciedlają średnią z przyrostów logarytmów wartości innych wskaźników (indeksów GSV) w danym okresie. Dlatego, w przypadku potrzeby przekształcenia innych zmiennych do postaci przyrostów logarytmów, zmienne te mogą pozostać w pierwotnej postaci.

Tabela 15. Wyniki testów stacjonarności dla zmiennych objaśniających i zmiennej objaśnianej

| Zmienna | Statystyka testu ADF | Statystyka testu KPSS |
|--|----------------------|-----------------------|
| <i>testy przeprowadzone na wartościach zmiennych (grupa 1)</i> | | |
| Zm_ef_t | -7,736* | 0,0252 |
| $W52_t$ | -2,7397 | 0,1234 |
| GSV_t | -3,3804*** | 1,0386* |
| $GSVw_t$ | -2,9698 | 1,3259* |
| $FEARS_t$ | -4,5925* | 0,0592 |
| $GREED_t$ | -6,7409* | 0,0381 |
| <i>testy przeprowadzone na przyrostach logarytmów wartości zmiennych (grupa 2)</i> | | |
| $\Delta W52_t$ | -4,3417* | 0,0503 |
| ΔGSV_t | -5,2059* | 0,0702 |
| $\Delta GSVw_t$ | -6,0025* | 0,0515 |

Uwaga: "****", "***", "**" oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. KPSS oznacza Kwiatkowski–Phillips–Schmidt–Shin, skrót "ADF" należy czytać jako Augmented Dickey-Fuller. Dane dotyczą okresu od 1.12.2013 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Na podstawie tabeli 15. można zauważyć, że wyniki testów ADF i KPSS w grupie pierwszej (testy przeprowadzone na wartościach zmiennych) dla $W52_t$ i GSV_t są niejednoznaczne, a „ważony” indeks GSV jest niestacjonarny. Oba testy wskazały na stacjonarność zmiennej niezależnej tylko w przypadku miar sentymentu inwestorów - $FEARS_t$ i $GREED_t$. Przyczyną tego jest to, że wartości tych zmiennych są średnimi ze wskazań indeksów GSV, które przekształcono do postaci przyrostów logarytmów.

Na podstawie wyników testów ADF i KPSS przeprowadzonych na drugiej grupie zmiennych (przekształconych) można jednoznacznie stwierdzić, że $\Delta W52_t$, $\Delta GSVw_t$ i ΔGSV_t spełniają warunek stacjonarności. Zatem zmienne objaśniające w niniejszym badaniu mają następującą postać:

- zmienne $GSVw_t$ i GSV_t opisujące uwagę inwestorów są wyrażone jako przyrosty logarytmów ich wartości, co można zapisać w następujący sposób:

$$\Delta GSVw_t = \ln(GSVw_t) - \ln(GSVw_{t-1}), \quad (47)$$

$$\Delta GSV_t = \ln(GSV_t) - \ln(GSV_{t-1}), \quad (48)$$

gdzie „ln” to logarytm naturalny, „t” - bieżący miesiąc. Wzrost wartości zmiennej $GSV_t/GSVw_t$ (dodatnia wartość $\Delta GSV_t/\Delta GSVw_t$) skutkuje wzrostem poziomu przeciętnej uwagi ogółu inwestorów skierowanej na Bitcoina (i odwrotnie).

- wskaźnik $W52_t$ ma postać przyrostów logarytmów z jego wartości. Wzór dla tej zmiennej jest następujący:

$$\Delta W52_t = \ln(W52_t) - \ln(W52_{t-1}), \quad (49)$$

gdzie „ \ln ” to logarytm naturalny, „ t ” - bieżący miesiąc. Ujemna (dodatnia) wartość $\Delta W52_t$ skutkuje wzrostem (spadkiem) przeciętnej skłonności ogółu inwestorów do ulegania heurystyce zakotwiczenia.

3.4 Dobór zmiennych kontrolnych

Dobór zmiennych kontrolnych do badania został dokonany na podstawie rezultatów innych badań i przesłanek teoretycznych. Dotychczas jedynymi zmiennymi, których oddziaływanie na stopień przewidywalności stóp zwrotu z Bitcoina zostało jednoznacznie potwierdzone były: płynność, zmienność i wolumen obrotu na rynku (Al-Yahyaee i in., 2020; Khuntia i Pattanayak, 2020; Mokni i in., 2024). Jednakże, na podstawie wyników badań nad rynkiem kryptowalut zidentyfikowano także inne czynniki, które mogą być związane z poziomem efektywności rynku Bitcoina.

Wyniki badań przeprowadzonych przez Brauneisa i Mestela (2018) wskazały, że kapitalizacja oddziałuje pozytywnie na efektywność rynku kryptowalut. Al-Yahyaee i in. (2020) oraz Mokni i in. (2024) zauważyli, że wzrost poziomu płynności na rynku Bitcoina prowadzi do wzrostu poziomu jego efektywności. Dodatkowo, Al-Yahyaee i in. (2020) stwierdzili, że im wyższy poziom zmienności, tym niższy poziom efektywności rynku kryptowalut. Khuntia i Pattanayak (2020) zaobserwowali, że wolumen obrotu oddziałuje na stopień długiej pamięci stóp zwrotu z Bitcoina. Ponadto, wzrost niepewności inwestycyjnej może przyczyniać się do zmniejszenia poziomu efektywności rynku, co jest zgodne z zaprezentowanym schematem 2 w podrozdziale 3.1. Biorąc to pod uwagę i inne wskazane wyżej zależności, jako potencjalne zmienne kontrolne wybrano płynność, kapitalizację, zmienność, wolumen obrotu na rynku oraz niepewność inwestycyjną.

Wybór ostatecznej postaci zmiennych kontrolnych w badaniu będzie zależał od spełnienia przez nie warunku stacjonarności. W tym celu zostaną przeprowadzone dwa testy: Kwiatkowski-Phillips-Schmidt-Shin (KPSS) i Augmented Dickey-Fuller (ADF). Ponieważ zmienne objaśniające dotyczące czynników behawioralnych (podrozdział 3.3) zostały zdefiniowane jako przyrosty logarytmów, w pierwszej kolejności zmienne kontrolne będą przekształcane do tej postaci. Dzięki temu oszacowania parametrów przy różnych zmiennych będą mogły być podobnie interpretowane (np. jako procentowa zmiana wartości badanego zjawiska). Ponadto, stosując transformację logarymiczną zmiennej będzie można zmniejszyć znaczenie wartości odstających.

Pierwszą zmienną kontrolną w badaniu jest kapitalizacja rynku Bitcoina (MC_t). Na podstawie wyników testów ADF i KPSS (tabela A1 w załączniku 2) można dojść do wniosku, że wartości tej zmiennej są niestacjonarne. Jednakże, testy ADF i KPSS przeprowadzone na przyrostach logarytmów kapitalizacji rynku Bitcoina wskazują na stacjonarność zmiennej. Dlatego zmiana kapitalizacji rynku Bitcoina będzie zdefiniowana następująco:

$$\Delta MC_t = \ln(MC_t) - \ln(MC_{t-1}), \quad (50)$$

gdzie „ln” oznacza logarytm naturalny, „t” – bieżący miesiąc. Dodatnia (ujemna) wartość tej zmiennej świadczy o wzroście (spadku) kapitalizacji rynku Bitcoina.

Druga zmienna kontrolna odnosi się do poziomu płynności na rynku Bitcoina. Tak jak w innych badaniach efektywności rynku kryptowalut (m. in. Wei (2018), Takaishi i Adachi (2020)), poziom płynności na rynku Bitcoina jest przybliżany za pomocą miary ograniczonej płynności Amihuda (2002). Wzór na wartość miary Amihuda (2002) (ILLIQ) jest następujący:

$$ILLIQ_t = \frac{1}{N} \sum_{h=1}^N \frac{|R_h|}{V_h}, \quad (51)$$

gdzie „t” - bieżący miesiąc, „N” to liczba godzin w miesiącu „t”, podczas których dokonano transakcji na rynku Bitcoina, R_h to stopa zwrotu w godzinie „h” w badanym miesiącu, V_h oznacza wartość wolumenu obrotu w godzinie „h”.

Na dalszym etapie badania weryfikowano stacjonarność miary Amihuda (2002). Wyniki testów ADF i KPSS (tabela A2 w załączniku 2) wskazały, że miara Amihuda charakteryzuje się stacjonarnością w okresie badania. Jednakże, z uwagi na postać innych zmiennych objaśniających (przyrosty logarytmów), sprawdzono również stacjonarność przyrostów logarytmów miary Amihuda.

Na podstawie wyników testów ADF i KPSS stwierdzono, że przyrosty logarytmów poziomu płynności na rynku Bitcoina są stacjonarne. Ponieważ transformacja logarymiczna zmniejsza znaczenie wartości odstających, wybrano tę postać zmiennej jako ostateczną. Dodatkowo wartości tej zmiennej przemnożono przez „-1” (w celu ujednoczenia interpretacji kierunku zmian zmiennych kontrolnych). Zatem poziom płynności na rynku Bitcoina będzie wyrażony następująco:

$$\Delta ILLIQ_t = \ln(ILLIQ_{t-1}) - \ln(ILLIQ_t), \quad (52)$$

gdzie „ln” oznacza logarytm naturalny, „t” - bieżący miesiąc. Interpretacja tej zmiennej jest następująca: ujemna (dodatnia) wartość tej zmiennej świadczy o spadku (wzroście) poziomu płynności w stosunku do poprzedniego miesiąca.

Kolejna zmienna kontrolna dotyczy wolumenu obrotu na rynku Bitcoina (Vol_t), który jest wyrażony w dolarach amerykańskich. Na podstawie wyników testów ADF i KPSS można stwierdzić, że zmienna ta nie jest stacjonarna. Jednakże, przyrosty logarytmów wolumenu obrotu na rynku Bitcoina (ΔVol_t) są stacjonarne (tabela A3 w załączniku 2). Dlatego zmienna odnosząca się do wolumenu obrotu na rynku Bitcoina w badaniu będzie przyjmowała następującą postać:

$$\Delta Vol_t = \ln(Vol_t) - \ln(Vol_{t-1}), \quad (53)$$

gdzie „ln” oznacza logarytm naturalny, „t” - bieżący miesiąc. Dodatnia wartość zmiennej ΔVol_t oznacza wzrost wolumenu obrotu na rynku Bitcoina (i odwrotnie).

Inną zmienną kontrolną w badaniu jest zmienność na rynku Bitcoina w kolejnych miesiącach (Sd_t). Zmienność jest aproksymowana za pomocą odchylenia standardowego godzinowych stóp zwrotu z Bitcoina w danym miesiącu. Na podstawie przeprowadzonych testów ADF i KPSS można stwierdzić, że pierwotna postać tej zmiennej jest stacjonarna (tabela A4 w załączniku 2). Ponieważ pozostałe zmienne kontrolne są w postaci przyrostów logarytmów, zweryfikowano również stacjonarność przyrostów logarytmów z wartości zmienności (ΔSd_t).

Zaprezentowane w tabeli A4 wyniki testów stacjonarności wskazują, że przyrosty logarytmów zmienności stóp zwrotu z Bitcoina są stacjonarne. Zatem zmienna ta jest wyrażona w następujący sposób:

$$\Delta Sd_t = \ln(Sd_t) - \ln(Sd_{t-1}), \quad (54)$$

gdzie „ln” oznacza logarytm naturalny, a „ Sd_t ” to odchylenie standardowe stóp zwrotu z godzin w miesiącu „t”. Dodatnia wartość zmiennej ΔSd_t oznacza wzrost zmienności na rynku Bitcoina (i odwrotnie).

Ostatnia zmienna kontrolna odnosi się do stopnia niepewności inwestycyjnej na rynku finansowym. Aproksymantą stopnia niepewności inwestycyjnej w pracy jest indeks VIX (VIX_t), który jest miarą oczekiwanej przez inwestorów zmienności na amerykańskim rynku akcji. Ponieważ rynek Bitcoina jest zintegrowany z rynkiem światowym pod względem przepływów kapitału (Statista, 2022), warunki panujące na rynku amerykańskim mogą oddziaływać na zachowanie inwestorów na rynku Bitcoina. Można zatem stwierdzić, że indeks VIX dobrze odzwierciedla globalną niepewność inwestycyjną na rynkach finansowych, co w dużym stopniu oddaje międzynarodową strukturę geograficzną inwestorów na rynku kryptowalut.

W toku badania pobrany szereg wartości indeksu VIX poddano pewnym przekształceniom. W pierwszej kolejności obliczono średnie wartości indeksu VIX (VIX_t) w kolejnych miesiącach badania. Powodem tego była rozbieżność pomiędzy częstotliwością notowań wartości tego indeksu (dzienna częstotliwość) a częstotliwością pomiaru zmiennej zależnej (miesięczna zmiana poziomu efektywności rynku Bitcoina). W ten sposób uzyskano szereg czasowy średnich wartości indeksu VIX w kolejnych miesiącach, który poddano weryfikacji pod kątem spełnienia warunku stacjonarności. Wyniki testów stacjonarności dla indeksu VIX przedstawiono w tabeli A5 w załączniku 2.

Na podstawie przeprowadzonych testów ADF i KPSS nie stwierdzono jednoznacznie, aby podstawowa postać indeksu VIX była stacjonarna. Dlatego tę zmienną przekształcono do postaci przyrostów logarytmów ze średnich wartości indeksu VIX w kolejnych miesiącach. Następnie dokonano ponownej weryfikacji stacjonarności zmiennej w tej postaci. Wyniki testów ADF i KPSS potwierdziły, że druga postać tej zmiennej jest stacjonarna. Zatem w badaniu zmienna odnosząca się do indeksu VIX została wyrażona jako przyrosty logarytmów ze średnich jego wartości w kolejnych miesiącach, co opisano wzorem:

$$\Delta VIX_t = \ln(VIX_t) - \ln(VIX_{t-1}), \quad (55)$$

gdzie „ln” oznacza logarytm naturalny, „t” - bieżący miesiąc, VIX_t to średnia wartość indeksu VIX w miesiącu „t”. Dodatnia wartość zmiennej ΔVIX_t oznacza wzrost przeciętnej wartości indeksu VIX w miesiącu „t” w stosunku do poprzedniego miesiąca (i odwrotnie).

Zmienne kontrolne w badaniu nie powinny być ze sobą mocno powiązane. W przeciwnym razie może dojść do uzyskania zawyżonych lub zaniżonych oszacowań parametrów modelu. Dlatego obliczono współczynniki korelacji Pearsona pomiędzy zmiennymi poddanymi badaniu.

Na podstawie wyników zamieszczonych w tabeli 16 można stwierdzić, że silna korelacja wystąpiła w przypadku związku pomiędzy zmiennością a wolumenem obrotu na rynku Bitcoina. Jednakże, wartość współczynnika korelacji Pearsona nie oddaje w pełni wartości informacyjnej wnoszonej przez zmienną do modelu, ponieważ może być ona liniową kombinacją innych zmiennych objaśniających uwzględnionych w badaniu (tzw. współliniowość). Dlatego dokonano także weryfikacji współliniowości wolumenu obrotu i zmienności względem wszystkich zmiennych. Wyznaczone wartości czynników inflacji wariacji (*Variance Inflation Factor, VIF*) dla obu tych zmiennych kształtowały się na poziomie liczby 4, co sugeruje umiarkowaną siłę współliniowości. Ponieważ wolumen obrotu jest

mocniej skorelowany ze zmienną objaśnianą niż zmienność, jako zmienną kontrolną wybrano wolumen obrotu (zamiast zmienności).

Tabela 16. Macierz korelacji pomiędzy zmiennymi w badaniu

| <i>rho</i> | <i>Zm_ef</i> | ΔGSV | $\Delta GSVw$ | <i>Fears</i> | <i>Greed</i> | $\Delta W52$ | ΔMC | $\Delta ILLIQ$ | ΔVol | ΔSd | ΔVIX |
|----------------|--------------|--------------|---------------|--------------|--------------|--------------|-------------|----------------|--------------|-------------|--------------|
| <i>Zm_ef</i> | 1,00 | -0,06 | 0,10 | 0,02 | 0,16 | -0,01 | 0,08 | 0,16 | 0,15 | 0,06 | -0,02 |
| ΔGSV | -0,06 | 1,00 | 0,05 | 0,06 | 0,03 | 0,17 | 0,34 | -0,14 | -0,01 | -0,17 | 0,03 |
| $\Delta GSVw$ | 0,10 | 0,05 | 1,00 | -0,02 | -0,01 | 0,05 | 0,26 | -0,17 | 0,59 | 0,48 | 0,08 |
| <i>Fears</i> | 0,02 | 0,06 | -0,02 | 1,00 | 0,17 | -0,23 | -0,27 | -0,06 | 0,03 | 0,10 | 0,38 |
| <i>Greed</i> | 0,16 | 0,03 | -0,01 | 0,17 | 1,00 | 0,14 | 0,34 | 0,05 | 0,07 | -0,05 | -0,09 |
| $\Delta W52$ | -0,01 | 0,17 | 0,05 | -0,23 | 0,14 | 1,00 | 0,33 | 0,22 | 0,04 | -0,22 | -0,25 |
| ΔMC | 0,08 | 0,34 | 0,26 | -0,27 | 0,34 | 0,33 | 1,00 | -0,09 | 0,27 | -0,08 | -0,18 |
| $\Delta ILLIQ$ | 0,16 | -0,14 | -0,17 | -0,06 | 0,05 | 0,22 | -0,09 | 1,00 | -0,31 | -0,29 | -0,10 |
| ΔVol | 0,15 | -0,01 | 0,59 | 0,03 | 0,07 | 0,04 | 0,27 | -0,31 | 1,00 | 0,81 | 0,09 |
| ΔSd | 0,06 | -0,17 | 0,48 | 0,10 | -0,05 | -0,22 | -0,08 | -0,29 | 0,81 | 1,00 | 0,14 |
| ΔVIX | -0,02 | 0,03 | 0,08 | 0,38 | -0,09 | -0,25 | -0,18 | -0,10 | 0,09 | 0,14 | 1,00 |

Uwaga: „rho” oznacza współczynnik korelacji pomiędzy zmiennymi w poszczególnych wierszach i kolumnach

Innym argumentem przemawiającym za wyborem wolumenu obrotu (zamiast zmienności) jako zmiennej kontrolnej jest fakt, że tylko w przypadku wolumenu obrotu potwierdza się znaczenie tej zmiennej dla stopnia przewidywalności stóp zwrotu z Bitcoina⁶⁶ na podstawie analizy danych godzinowych (Khuntia i Pattanayak (2020)). Jednakże, oszacowany stopień pamięci szeregu czasowego może różnić się w zależności od wybranej częstotliwości notowań w badaniu. Innymi słowy, zależności zachodzące pomiędzy danymi dziennymi nie muszą również występować w przypadku danych o wyższej częstotliwości (np. godzinowych stóp zwrotu). Ponieważ w tym badaniu wykorzystuje się godzinowe stopy zwrotu, to bardziej prawdopodobne jest, że wolumen obrotu oddziałuje mocniej na zmiany poziomu efektywności rynku Bitcoina niż zmienność.

Zmienność i wolumen obrotu na rynku Bitcoina są umiarkowanie powiązane (współczynniki korelacji przyjmują wartości pomiędzy 0,4 a 0,6) z uwagą inwestorów skierowaną na Bitcoina aproksymowaną za pomocą „ważonego” indeksu GSV. Dlatego, w przypadku uwagi inwestorów aproksymowanej za pomocą „ważonego” indeksu GSV, model cząstkowy nie będzie uwzględniał zmienności i wolumenu obrotu na rynku Bitcoina. Podsumowując, przyjęty zestaw zmiennych kontrolnych w badaniu będzie następujący: płynność, kapitalizacja,

⁶⁶ Oddziaływanie zmienności na poziom efektywności rynku Bitcoina potwierdzono na podstawie danych dziennych (Al-Yahyaee i in., 2020).

wolumen obrotu na rynku Bitcoina oraz niepewność inwestycyjna na rynku finansowym. Dodatkowo, w celu sprawdzenia odporności wyników można rozważyć usunięcie zmiennych kontrolnych z modeli cząstkowych, które są najmocniej związane ze zmiennymi aproksymującymi sentyment inwestorów - tj. odnoszących się do stopnia niepewności inwestycyjnej i kapitalizacji rynku Bitcoina.

4. Empiryczna analiza związku wybranych czynników behawioralnych z efektywnością rynku Bitcoina

W związku ze zidentyfikowaną luką badawczą, niniejszy rozdział poświęcony został przedstawieniu wyników badania oddziaływania czynników behawioralnych na dynamikę efektywności rynku Bitcoina. W pierwszym podrozdziale dokonano charakterystyki próby badawczej i okresu badania. W drugim podrozdziale omówiono dynamikę efektywności rynku Bitcoina w badanym okresie. W następnej części przedstawiono i opisano wyniki estymacji modeli ekonometrycznych, a także dokonano weryfikacji hipotez badawczych. W ostatniej części tego rozdziału przeprowadzono pogłębioną analizę wyników badania oraz zaprezentowano możliwe wyjaśnienia uzyskanych rezultatów.

4.1 Charakterystyka próby badawczej i okres badania

Celem badania zaplanowanego w ramach rozprawy jest ocena związku pomiędzy wybranymi czynnikami behawioralnymi a efektywnością informacyjną rynku Bitcoina. Dobór zmiennych odzwierciedlających badane wielkości oraz zmiennych kontrolnych został omówiony w podrozdziałach 3.2, 3.3 i 3.4. Na potrzeby ich pomiaru wykorzystano następujące dane w postaci szeregu czasowego:

- dane transakcyjne dotyczące Bitcoina z giełdy Bitstamp⁶⁷,
- szeregi czasowe wolumenu obrotu i kapitalizacji rynku Bitcoina⁶⁸,
- miesięczne wartości indeksów wyszukiwań frazy „bitcoin” w Google pobrane dla całego okresu badania⁶⁹,
- dzienne wartości indeksów wyszukiwań frazy „bitcoin” w Google pobrane dla kolejnych miesięcy w okresie badania,
- miesięczne wartości indeksów zapytań dotyczących słów i wyrażeń o negatywnym lub pozytywnym wydźwięku, związanych z ekonomią i finansami na potrzeby szacowania wartości sentymentu inwestorów,
- szereg czasowy dziennych notowań indeksu VIX⁷⁰,
- daty halvingów⁷¹

⁶⁷ <http://api.bitcoincharts.com/v1/csv/>

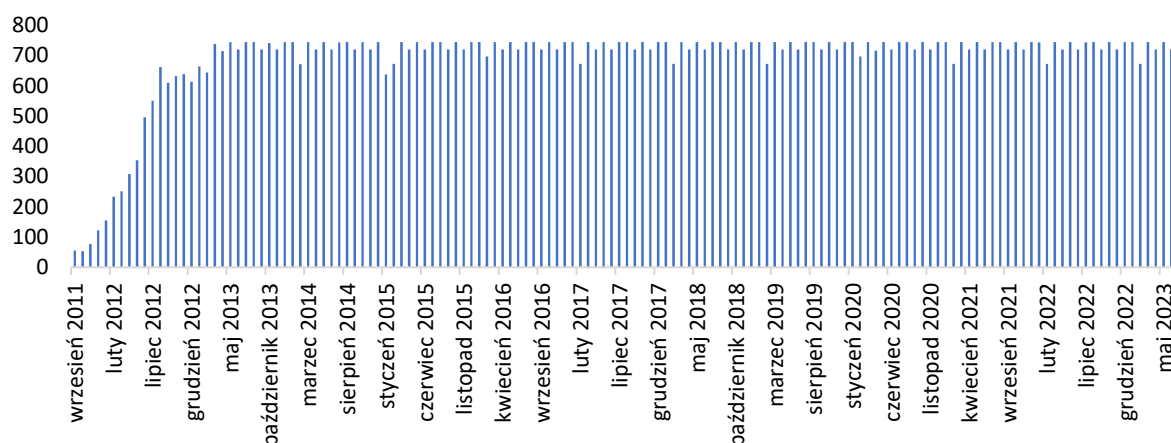
⁶⁸ <https://data.bitcoinity.org>

⁶⁹ <https://trends.google.pl/trends/>

⁷⁰ https://www.cboe.com/tradable_products/vix/vix_historical_data/

⁷¹ <https://www.binance.com/en/events/bitcoin-halving>

Ze względu na ustabilizowanie się rynku Bitcoina dopiero po 2013 roku, badaniem objęto okres od grudnia 2013 do czerwca 2023 r. Przed początkiem okresu badania zaobserwowano znacznie mniejszą miesięczną liczbę transakcji niż w późniejszym czasie, co zostało przedstawione na wykresie 5. Zbyt mała liczba transakcji mogłaby zaburzać stabilność oszacowań zmiennych (m. in. wykładnika Hursta, miary poziomu płynności).



Wykres 5. Liczba godzin w kolejnych miesiącach, podczas których doszło do transakcji na rynku Bitcoina

Źródło: Opracowanie własne na podstawie danych pobranych z <http://api.bitcoincharts.com/v1/csv/>

W celu zmniejszenia znaczenia obserwacji odstających dla uzyskanych oszacowań parametrów regresji (zjawisko „pozornej” regresji) (Gruszczyński, 2013), przeprowadzono analizę występowania obserwacji nietypowych. Wartość zmiennej była uznana za odstającą, jeśli była mniejsza od różnicy pomiędzy kwartylem pierwszym (Q_1) a 1,5-krotnością rozstępu międzykwartylowego (IQR) lub większa od wartości kwartyla trzeciego (Q_3) powiększonego o 1,5-krotność rozstępu międzykwartylowego. Zakres wartości zmiennej, które uznano za typowe przedstawiono poniżej (Giudici, 2003):

$$[Q_1 - 1,5 \times IQR, Q_3 + 1,5 \times IQR] \quad (56)$$

Zidentyfikowane obserwacje odstające zastąpiono wartościami odpowiadającymi granicom powyższego przedziału, czyli $Q_1 - 1,5 \times IQR$ i $Q_3 + 1,5 \times IQR$ (Dash i in., 2023).

Na dalszym etapie badania dokonano weryfikacji normalności rozkładu zmiennych poddanych badaniu. Na podstawie wartości kurtozy (2,76), skośności (0,40) i testu Jarque-Bera nie stwierdzono, aby rozkład zmiennej zależnej różnił się znacznie od rozkładu

normalnego⁷². Jednakże, test Shapiro-Wilka wskazał, że rozkład zmiennej objaśnianej może różnić się od normalnego. Dlatego należy być ostrożnym we wnioskowaniu o rozkładzie tej zmiennej. Jednakże, warunkiem wystarczającym dla interpretacji wyników testów statystycznych w analizie regresji jest rozkład normalny składnika losowego, ponieważ rozkład statystyk jest wtedy zbliżony do wymaganego (t-Studenta, F) (Welfe, 2014, s. 31-32). Statystyki opisowe dla zmiennej zależnej i innych zmiennych poddanych badaniu przedstawiono w tabeli 17.

Wśród zmiennych objaśniających największą bezwzględną wartość współczynnika zmienności w okresie badania odnotowano dla płynności oraz uwagi inwestorów skierowanej na Bitcoina (ΔGSV_w). Zmienna zależna charakteryzowała się największą wartością współczynnika zmienności, co może wynikać z rzędu wielkości tej zmiennej (najniższej bezwzględnej średniej wartości badanej cechy).

Tabela 17. Statystyki opisowe dla zmiennej zależnej i zmiennych objaśniających

| | Średnia | Odchylenie standardowe | Współczynnik zmienności | Skośność | Kurtoza | Statystyka testu Jarque-Bera | Statystyka testu Shapiro-Wilka |
|----------------|---------|------------------------|-------------------------|----------|---------|------------------------------|--------------------------------|
| <i>Zm_ef</i> | -0,0001 | 0,0312 | 312 | 0,3961 | 2,7600 | 3,255 | 0,9618* |
| ΔVol | 0,0143 | 0,4175 | 29,1958 | 0,3870 | 2,5019 | 4,0245 | 0,9727** |
| ΔMC | 0,0363 | 0,2093 | 5,7658 | -0,0578 | 2,6990 | 0,4938 | 0,9852 |
| $\Delta ILLIQ$ | 0,0025 | 0,6193 | 247,72 | -0,2892 | 3,3147 | 2,0599 | 0,9577* |
| ΔVIX | -0,0087 | 0,1614 | 18,5517 | 0,2947 | 2,7353 | 1,9827 | 0,9774** |
| <i>FEARS</i> | -0,0061 | 0,4016 | 65,8361 | 0,2519 | 2,5201 | 2,2996 | 0,9849 |
| <i>GREED</i> | 0,0337 | 0,3887 | 11,5341 | 0,1065 | 2,3058 | 2,5043 | 0,9854 |
| $\Delta W52$ | 0,0055 | 0,1550 | 28,1818 | 0,1898 | 2,8412 | 0,8111 | 0,9850 |
| ΔGSV | -0,0031 | 0,2239 | 72,2258 | 0,1120 | 2,5259 | 1,306 | 0,9600* |
| ΔGSV_w | -0,0013 | 0,3659 | 281,4615 | -0,0568 | 2,1579 | 3,4294 | 0,9679* |

Uwaga: "****", "***", "*" oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. W celu ujednoczenia interpretacji współczynnik zmienności jest obliczany jako iloraz odchylenia standardowego i bezwzględnej wartości średniej.

Wartości współczynników skośności badanych szeregów czasowych oscylowały wokół zera, a kurtoza znajdowała się w przedziale od 2,16 do 3,31. Można zatem oczekiwać, że rozkłady badanych zmiennych nie różnią się znacznie od rozkładu normalnego. Wśród zmiennych poddanych badaniu, najmniejszą skośnością cechowały się: kapitalizacja rynku Bitcoina i uwaga inwestorów aproksymowana z wykorzystaniem „ważonego” indeksu GSV. Natomiast

⁷² Dla „idealnego” rozkładu normalnego skośność powinna wynosić 0, a kurtoza 3.

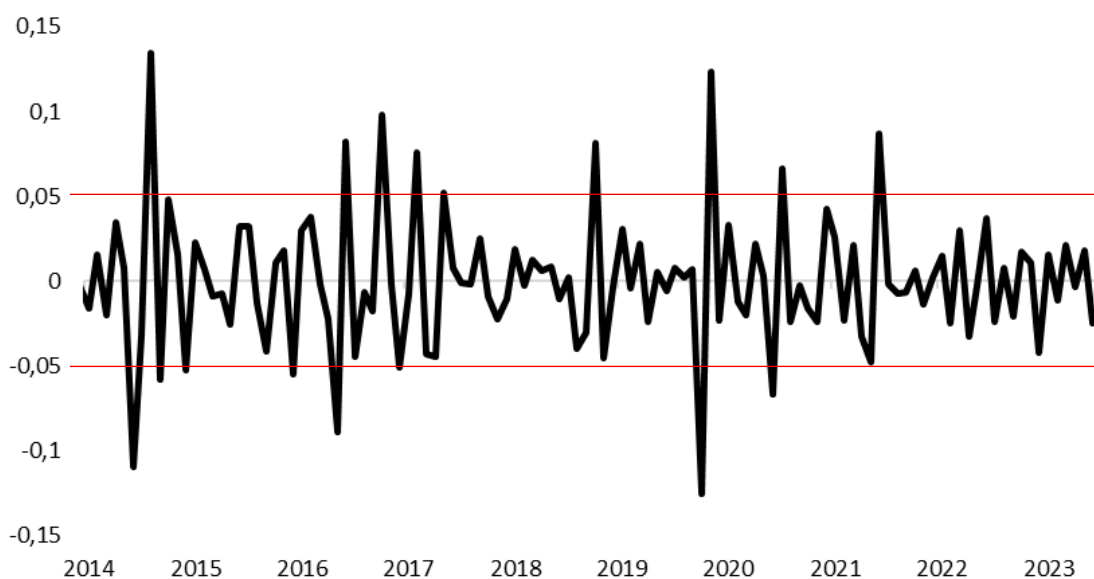
zmienna zależna, indeks *VIX* i zmienna $\Delta W52$ miały rozkłady najbardziej zbliżone do normalnego pod względem wartości kurtozy.

Wyniki testów statystycznych dotyczących rozkładów zmiennych były niejednoznaczne w większości przypadków. Test Jarque-Bera wskazał na brak podstaw do odrzucenia hipotezy o rozkładzie normalnym zmiennej we wszystkich przypadkach. Na podstawie testu Shapiro-Wilka nie odrzucono hipotezy o normalności rozkładu zmiennych *FEARS*, *GREED*, *ΔMC* oraz $\Delta W52$. Rozbieżność pomiędzy wskazaniem testów statystycznych dla większości zmiennych poddanych badaniu może wynikać z konstrukcji tych testów. Test Jarque-Bera jest bardziej wrażliwy na wielkość próby badawczej niż test Shapiro-Wilka. Wskazania pierwszego z tych testów opierają się na analizie skośności i kurtozy, których wartości powinny asymptotycznie dążyć do właściwych dla rozkładu normalnego. Test Shapiro-Wilka polega na porównywaniu wartości statystyk mierzących zmienność, uporządkowanie oraz symetrię rozkładu próby empirycznej z ich oczekiwanymi wartościami w przypadku danych pochodzących z rozkładu normalnego. Zatem w przypadku małej próby badawczej⁷³ test Shapiro-Wilka ma większą moc (jest bardziej wiarygodny) niż test Jarque-Bera.

4.2 Dynamika efektywności rynku Bitcoina

W dotychczasowych badaniach czynników mających związek z dynamiką efektywności rynku Bitcoina dokonywano pomiaru poziomu efektywności rynku w tzw. nakładającym się ruchomym oknie. Na potrzeby niniejszego badania zmienna zależna została zdefiniowana jako zmiana poziomu efektywności rynku w stosunku do poprzedniego miesiąca. Taki sposób pomiaru dynamiki efektywności rynku jest zbieżny z założeniami hipotezy rynku adaptacyjnego (AMH). W ramach AMH zakłada się, że poziom efektywności rynku zmienia się cyklicznie, a inwestorzy podejmują decyzje inwestycyjne pod mniejszym lub większym wpływem emocji, w zależności od przeszłych doświadczeń (Lo, 2004). Dlatego powinna występować zależność pomiędzy poziomem efektywności rynku w bieżącym i poprzednim okresie, co uwzględniono w badaniu dokonując pomiaru dynamiki efektywności rynku. Szereg czasowy wartości tej zmiennej - miesięcznej zmiany poziomu efektywności rynku Bitcoina wyznaczonej na podstawie oszacowań wartości wykładnika Hursta w okresie od stycznia 2014 r. do czerwca 2023 r. zaprezentowano na wykresie 6.

⁷³ Razali i Wah (2011) zauważyli, że w przypadku próby mniejszej niż 2000 obserwacji test Shapiro-Wilka ma większą moc niż inne testy rozkładu normalnego.



Wykres 6. Miesięczne zmiany poziomu efektywności rynku Bitcoina

Uwaga: Dane obejmują okres od 1.01.2014 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Na podstawie wykresu 6 można stwierdzić, że znaczące zmiany poziomu efektywności rynku Bitcoina wystąpiły w kilku okresach. Pierwszy z nich dotyczy początku 2014 roku. W tym okresie upadła jedna z bardziej znaczących giełd kryptowalut (Mt.Gox). Ponadto, Ludowy Bank Chin nakazał bankom komercyjnym i firmom płatniczym zamknięcie wszystkich kont należących do podmiotów, które umożliwiają zawieranie transakcji z wykorzystaniem kryptowalut⁷⁴. Duża zmienność poziomu efektywności rynku Bitcoina w tym okresie mogła być spowodowana wzrostem strachu wśród inwestorów i w konsekwencji wyprzedają Bitcoina, która doprowadziła do tymczasowego pogorszenia poziomu efektywności tego rynku, co może wynikać z małego udziału inwestorów instytucjonalnych (bardziej doświadczonych) na tym rynku w początkowym okresie jego istnienia (Huang i in., 2022). To zmniejszenie poziomu efektywności rynku Bitcoina trwało bardzo krótko. Podobna zmiana poziomu efektywności rynku Bitcoina nastąpiła w kolejnym okresie, z tym że dotyczyła jego wzrostu. Możliwe zatem, że po upadku giełdy Mt. Gox oraz wprowadzeniu ograniczenia dotyczącego obrotu Bitcoinem przez firmy zarejestrowane na terytorium Chin, większość z pozostałych na rynku inwestorów bardzo szybko zaadoptowała się do nowych warunków.

Znaczne wahania w poziomie efektywności rynku Bitcoina zaobserwowano również w późniejszych latach, tzn. 2016-2017. Wysoką dynamikę efektywności rynku Bitcoina na

⁷⁴ W tym okresie chińskie giełdy Bitcoina stanowiły większość udziału w tym rynku pod względem wolumenu obrotu tą kryptowalutą (Gloudeman, 2014).

początku tego okresu można przypisać do zachowania inwestorów pochodzących z Chin, ponieważ wtedy doszło do nagłego dużego spadku cen akcji notowanych na chińskiej giełdzie (Money, 2016). Takie warunki mogły spowodować wzrost niepewności odnośnie do przyszłej wartości akcji oraz nasilenie obaw dotyczących wystąpienia długotrwałej recesji na rynku. W efekcie mogło dojść do wzrostu awersji do ryzyka wśród chińskich inwestorów, którzy stanowili wtedy duży udział w rynku Bitcoina (Tovanich i in., 2021). Można zatem przypuszczać, że w okresie wzrostu niepewności inwestorzy ci pozbywali się bardziej ryzykownych aktywów (walorów o wyższej zmienności) z portfela inwestycyjnego i nabywali walory należące do tzw. bezpiecznych przystani. Ponieważ Bitcoin nie jest tzw. bezpieczną przystanią dla portfela akcji (Mizerka i in., 2020) oraz cechuje się wysoką zmiennością (Dwyer, 2015), w okresie wzrostu niepewności na rynku chińskim skłonność jego uczestników do sprzedaży tej kryptowaluty mogła wzrosnąć. Zatem w tym przypadku możliwe było zaobserwowanie zachowań stadnych, które powinny prowadzić do obniżenia poziomu efektywności rynku.

W latach 2016-2017 nastąpiły istotne zmiany instytucjonalne odnośnie do Bitcoina. W roku 2016 Japonia, jako jedna z największych gospodarek na świecie, uznała kryptowaluty za legalny środek płatniczy (ustawa *Payment Services Act*). Ponadto, w trakcie tego okresu Bitcoin stał się przedmiotem analiz instytucji finansowych. Na przykład, w roku 2016 grupa CME (jedna z wiodących firm umożliwiających obrót instrumentami pochodnymi) zaczęła obliczać kurs referencyjny Bitcoina z różnych giełd (CME, 2016), co mogło sugerować, że w przyszłości może ona poszerzyć ofertę o instrumenty pochodne oparte o kurs tej kryptowaluty. Takie zdarzenia mogły doprowadzić do znacznego wzrostu dostępności rzetelnych informacji na temat Bitcoina oraz poziomu płynności na rynku, który zaobserwowano w tym okresie (Takaishi i Adachi, 2020). W efekcie poziom efektywności informacyjnej mógł się zwiększyć. Jednakże, reakcja inwestorów na dobre wiadomości mogła być zbyt mocna, co może wynikać z nasilenia się skrajnie pozytywnych emocji (euforii). Ponadto, w dalszej części roku 2016 doszło także do serii ataków hakerskich na giełdy kryptowalut, m. in. Bitfinex (jedna z większych giełd w tym okresie), Gatecoin (CoinDesk, 2016; Binance, 2025), które mogły powodować wzrost strachu wśród inwestorów. W efekcie mogło dojść do nasilenia się zachowań stadnych. Dlatego w tym okresie można zaobserwować, że znaczne wzrosty poziomu efektywności rynku Bitcoina często poprzedzały jej znaczne spadki (odwrotnie niż w przypadku wzrostu niepewności inwestycyjnej).

Wysokie zmiany poziomu efektywności rynku Bitcoina wystąpiły także w drugiej połowie 2018 roku. Okres ten zbiega się z „wielkim krachem” na rynku kryptowalut, który doprowadził do spadku cen 95 największych z nich. Ten kryzys mógł być spowodowany rezygnacją jednego z największych banków inwestycyjnych (Goldman Sachs) z planu utworzenia departamentu obrotu kryptowalutami. Ponadto, w tym okresie około 111 000 Bitcoinów zostało przeniesionych do różnych portfeli w celu ich sprzedaży na platformie Silk Road, która obsługiwała nielegalne transakcje (Manahov, 2024).

Ponadprzeciętne zmiany poziomu efektywności rynku Bitcoina wystąpiły również w latach 2020-2021. Mogły one wynikać z nasilenia się strachu wśród inwestorów wywołanego pandemią koronawirusa Covid-19. Wskazane okresy charakteryzowały się wysoką globalną niepewnością inwestycyjną, co mogło wpłynąć na zawyżenie postrzegania prawdopodobieństwa poniesienia straty przez niedoświadczonych inwestorów. W efekcie, inwestorzy cechujący się większą awersją do strat mogli dokonywać realokacji kapitału z bardziej do mniej ryzykownych inwestycji. Ponieważ Bitcoin jest inwestycją o relatywnie wysokiej zmienności, można przypuszczać, że w tym czasie inwestorzy sprzedawali Bitcoiny i kupowali bardziej bezpieczne aktywa, takie jak np. obligacje skarbowe, które oferowały możliwość uzyskania stałego dochodu przy mniejszym ryzyku. Ponadto, Chiny, które były jednym z najbardziej znaczących państw na rynku wydobywania Bitcoina, w roku 2021 ostatecznie zakazały obrotu i wydobywania kryptowalut na ich terytorium (BBC, 2021). To wydarzenie mogło spowodować wzrost obaw inwestorów o przyszłość tej kryptowaluty, ponieważ jej bezpieczeństwo jest warunkowane m. in. skoncentrowaną mocą obliczeniową w systemie Bitcoin.

Pod koniec okresu badania, tzn. w latach 2022-2023 można zaobserwować relatywnie niewielkie zmiany poziomu efektywności rynku Bitcoina. Ta obniżona dynamika efektywności może wynikać z faktu, że w ostatnich latach udział inwestorów instytucjonalnych w tym rynku znacząco się zwiększył (Huang i in., 2022). Ponieważ bardziej doświadczeni inwestorzy są mniej podatni na czynniki behawioralne (Bashall i in., 2018; Hincapié-Salazar i Agudelo, 2020), jest możliwe, że w czasie wydarzeń nacechowanych emocjonalnie podejmują oni bardziej świadome decyzje inwestycyjne niż mniej doświadczeni. Zatem czynniki behawioralne mogą mieć mniejsze znaczenie dla dynamiki efektywności rynku Bitcoina zaobserwowanej w ostatnim podokresie badania.

Podsumowując, w niniejszym podrozdziale wskazano przykłady zdarzeń nacechowanych wysoką niepewnością inwestycyjną, których wystąpienie zbiegało się z dużą zmiennością poziomu efektywności rynku Bitcoina. Zatem hipoteza rynku adaptacyjnego zdaje się dobrze odzwierciedlać zachowanie inwestorów na rynku Bitcoina. Ponadto zaobserwowano, że po dużym spadku efektywności rynku Bitcoina zazwyczaj następował jej duży wzrost, co wskazuje na krótkoterminowość zmian poziomu efektywności tego rynku. To przypuszczenie potwierdza fakt, że współczynnik autokorelacji pierwszego rzędu dla zmian poziomu efektywności rynku Bitcoina był ujemny (-0,41). Dlatego można stwierdzić, że dynamika efektywności tego rynku cechuje się cyklicznością, a inwestorzy na tym rynku szybko adaptują się do nowych warunków rynkowych.

4.3 Identyfikacja czynników behawioralnych oddziałujących na dynamikę efektywności rynku Bitcoina

W niniejszym podrozdziale weryfikacji poddano trzy postawione hipotezy badawcze odnoszące się do zależności pomiędzy czynnikami behawioralnym a dynamiką efektywności rynku Bitcoina. Analiza tego związku została dokonana na podstawie oszacowań modeli regresji z wykorzystaniem Klasycznej Metody Najmniejszych Kwadratów (KMNK). Ponieważ zmienne odnoszące się do czynników behawioralnych mogą być ze sobą skorelowane, oszacowano również modele cząstkowe⁷⁵, które dotyczą pojedynczych czynników behawioralnych. W dalszej kolejności sprawdzono odporność wyników oszacowań uzyskanych w ramach tych modeli pod kątem zastosowania innego estymatora - funkcji największej wiarygodności.

W badaniu wykorzystano zestaw danych w postaci szeregów czasowych opisanych w podrozdziałach 3.2, 3.3, 3.4 i 4.1. Częstym problemem związanym z analizą tego typu danych jest ich autokorelacja. Wpływ tej niedogodności na uzyskane oszacowania przy zmiennych można ograniczyć przez zastosowanie modeli autoregresyjnych. Z tego powodu przyjęto, że podstawowy model ma postać autoregresyjną z rozkładem opóźnień zmiennych objaśniających, co przypomina model ADL (*Autoregressive Distributed Lag model*). Uzasadnieniem ekonomicznym postaci autoregresyjnej jest założenie hipotezy rynku adaptacyjnego (AMH), w myśl którego zmiany poziomu efektywności rynku cechują się cyklicznością. Zatem dynamika efektywności rynku powinna być ujemnie skorelowana z jej

⁷⁵ Jednym z założeń KMNK jest brak istotnej korelacji pomiędzy zmiennymi.

przeszłym stanem, na co wskazano w podrozdziale 4.2. Ponadto, można zakładać, że dostosowanie się inwestorów do nowych warunków rynkowych czy regulacji dotyczących giełd kryptowalut może następować z opóźnieniem.

Według Góreckiego (2013, s. 186-192), bardzo ważnym etapem w ocenie poprawności modelu ADL jest weryfikacja czy występuje autokorelacja składnika losowego. Jeśli nie podlega on autokorelacji, to można przyjąć, że opóźniona zmienna objaśniana nie jest skorelowana ze składnikiem losowym. Górecki (2013) proponuje, aby w tym celu wykorzystać test Durбина-Watsona. Jednakże, test ten służy tylko do weryfikacji występowania autokorelacji pierwszego rzędu. Zatem występowanie autokorelacji dalszego rzędu sprawdzono na podstawie korelogramu reszt w kolejnych opóźnieniach.

Brak autokorelacji składnika losowego nie jest jedynym warunkiem, aby estymator KMNK był najlepszym liniowym nieobciążonym estymatorem (*Best Linear Unbiased Estimator*). Dlatego przeprowadzono także inne testy diagnostyczne szacowanych modeli: test RESET (poprawność specyfikacji modelu ekonometrycznego), test Shapiro-Wilka (normalność rozkładu reszt), test Breuscha-Pagana (homoskedastyczność reszt). Z uwagi na obniżoną dynamikę efektywności rynku w latach 2022-2023 (podrozdział 4.2), przeprowadzono również test Chowa dla trzech punktów załamania strukturalnego: lipiec 2016 r. i maj 2020 r. (odpowiada to kolejnym halvingom na rynku Bitcoina) oraz marzec 2018 r. (połowa okresu badania). W celu weryfikacji założenia o braku znaczącej współliniowości zmiennych objaśniających, przeanalizowano wartości czynników inflacji wariacji dla wszystkich zmiennych, które zostały uwzględnione w modelu.

Specyfikacja szacowanych modeli podstawowych została dobrana na podstawie metody „od szczególnego do ogólnego” (Gruszczński i in., 2009, s. 231). Na początku szacowano model bez uwzględnienia opóźnień zmiennych zależnych. Następnie uwzględniano kolejne opóźnienia zmiennej zależnej tak długo, aż nie zostały spełnione warunki KMNK dotyczące składnika losowego (m. in. brak autokorelacji, homoskedastyczność, rozkład normalny reszt). Ogólna postać szacowanego modelu jest następująca:

$$Zm_ef_t = a_0 + a_1Zm_ef_{t-1} + a_2Zm_ef_{t-2} + \beta_1\Delta GSV_t + \beta_2FEARS_t + \beta_3GREED_t + \beta_4\Delta W52_t + \beta_5\Delta ILLIQ_t + \beta_6\Delta ILLIQ_{t-1} + \beta_7\Delta Vol_t + \beta_8\Delta MC_t + \beta_9\Delta VIX_t + \varepsilon, \quad (57)$$

gdzie Zm_ef_t oznacza zmianę poziomu efektywności rynku w okresie „t” w stosunku do okresu „t – 1”, a_0 to stała, ΔGSV_t to zmiana wartości indeksu wyszukiwań na świecie frazy

„bitcoin” w Google w okresie „ t ”, $FEARS_t/GREED_t$ oznacza zmianę natężenia negatywnego/pozytywnego sentymentu inwestorów w okresie „ t ”, $\Delta W52_t$ oznacza zmianę odchylenia średniej ceny rynkowej od 52-tygodniowego maksimum notowań Bitcoina w okresie „ t ”, $\Delta ILLIQ_t$, ΔVol_t , ΔMC_t , ΔVIX_t to zmiany odpowiednio: poziomu płynności, wolumenu obrotu, kapitalizacji rynku Bitcoina oraz indeksu VIX w okresie „ t ”, „ ε ” oznacza składnik losowy.

We wszystkich modelach typu ADL zastosowano błędy standardowe odporne na autokorelację i heteroskedastyczność reszt (Newey-West). Powodem takiego podejścia był fakt, że współczynnik autokorelacji reszt przy trzecim opóźnieniu był na granicy istotności statystycznej. W procesie szacowania odpornych błędów standardowych założono liczbę opóźnień równą części całkowitej z pierwiastka czwartego stopnia z liczebności próby badawczej (Newey i West, 1987), czyli uwzględniono trzy opóźnienia.

Pierwszy z estymowanych modeli podstawowych dotyczył łącznego oddziaływania czynników behawioralnych na dynamikę efektywności rynku Bitcoina. Wyniki estymacji tego modelu zaprezentowane w tabeli 18 wskazują, że oszacowanie parametru przy zmiennej dotyczącej uwagi inwestorów nie jest statystycznie różne od zera. Innymi słowy, uwaga inwestorów nie ma znaczenia dla wyjaśnienia zmienności zmiennej objaśnianej. Nieistotność tej zależności potwierdzają wyniki estymacji modelu oddziaływania uwagi inwestorów aproksymowanej za pomocą „ważonego” indeksu GSV na dynamikę efektywności rynku Bitcoina (tabela B2 w załączniku 3). Zatem uzyskane wyniki nie dają podstaw do potwierdzenia hipotezy H1:

Wzrost (spadek) uwagi inwestorów skierowanej na Bitcoina jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

Brak tego związku może wynikać z faktu, że Google udostępnia indeksy popularności danej frazy w Internecie w wybranym okresie w postaci znormalizowanej w procentach od 0 do 100, co może powodować niedoszacowanie rzeczywistej dynamiki uwagi inwestorów. Ponadto, możliwe, że początkowo skłonność inwestorów do podejmowania decyzji inwestycyjnych pod wpływem popularności Bitcoina była silniejsza. Jednakże, wraz z rozwojem rynku kryptowalut powstawały wyspecjalizowane platformy, które zapewniały dostęp do coraz większej liczby zaawansowanych narzędzi analitycznych (m. in. Alternative.me, Seekingalpha.com). Można przypuszczać, że popularność korzystania z takich narzędzi wśród inwestorów na rynku Bitcoina zwiększała się wraz z upływem czasu, ponieważ mogli oni uczyć się na swoich błędach

(Lo, 2004). W efekcie, trudność w przetworzeniu dużej ilości informacji na temat inwestycji (jedna z przyczyn występowania tego zjawiska) mogła się zmniejszyć, co przyczyniło się do osłabienia związku między uwagą inwestorów a ich zachowaniem na rynku Bitcoina. Innym wytłumaczeniem nieistotnego statystycznie oszacowania parametru modelu przy zmiennej ΔGSV może być to, że zmiany indeksu GSV bardziej mogą odzwierciedlać niepewność niż uwagę inwestorów, co zostało zauważone w kontekście rynku akcji przez Szczygielskiego i in. (2023).

Tabela 18. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina

| Zmienna | Współczynnik | Błąd standardowy |
|----------------------------------|---------------------------|------------------|
| Zm_ef_(t-1) | -0,58394*** | 0,07971 |
| Zm_ef_(t-2) | -0,43502*** | 0,07330 |
| $\Delta ILLIQ_t$ | 0,00846* | 0,00431 |
| $\Delta ILLIQ_{(t-1)}$ | 0,00244 | 0,00349 |
| ΔVol_t | 0,01018 | 0,00719 |
| ΔMC_t | -0,00553 | 0,01423 |
| ΔVIX_t | -0,00373 | 0,01519 |
| ΔGSV_t | -0,00089 | 0,00998 |
| FEARS_t | -0,00153 | 0,00747 |
| GREED_t | 0,01214* | 0,00722 |
| $\Delta W52_t$ | 0,00575 | 0,01549 |
| Stała | -0,00034 | 0,00195 |
| Liczba obserwacji | 112 | |
| Skorygowany R^2 | 0,32532 | |
| Błąd standardowy reszt | 0,02580 (df = 100) | |
| Statystyka F | 5,86571*** (df = 11; 100) | |
| Statystyka testu Durбина-Watsona | 2,1821 | |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%.

Druga z hipotez weryfikowanych na podstawie uzyskanych oszacowań parametrów modelu podstawowego dotyczyła zależności pomiędzy natężeniem sentymentu inwestorów a

dynamiką efektywności rynku Bitcoina. W ramach tej hipotezy postawiono dwie hipotezy szczegółowe. Pierwsza z nich dotyczyła natężenia pozytywnego sentymentu inwestorów, druga natężenia negatywnego sentymentu inwestorów. Zatem oszacowano osobno parametry przy zmiennych odnoszących się do natężenia negatywnego i pozytywnego sentymentu inwestorów.

Oszacowanie parametru przy zmiennej oznaczającej natężenie pozytywnego sentymentu inwestorów jest dodatnie i statystycznie różni się od zera (tabela 18). Do tych samych wniosków można dojść na podstawie oszacowań parametrów modelu cząstkowego (tabela B4 w załączniku 3). Zatem kierunek zależności pomiędzy natężeniem pozytywnego sentymentu inwestorów a dynamiką efektywności rynku Bitcoina jest przeciwny do zakładanego, co nie daje podstaw do potwierdzenia hipotezy H2A:

Wzrost (spadek) natężenia pozytywnego sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

Wytłumaczeniem uzyskanych rezultatów może być zachowanie niedoświadczonych uczestników tego rynku. Jest wysoce prawdopodobne, że ci inwestorzy wchodzi na rynek Bitcoina w okresie wzrostu natężenia pozytywnego sentymentu. To zachowanie inwestorów może być wzmacniane na skutek odczuwania przez nich lęku przed przegapieniem okazji inwestycyjnej (tzw. FOMO). Ponieważ zwiększa się wtedy liczba inwestorów w obu grupach (doświadczeni i niedoświadczeni) na rynku Bitcoina, horyzonty inwestycyjne uczestników tego rynku mogą stać się bardziej zróżnicowane. Zatem poziom efektywności rynku może wtedy okresowo się zwiększać, co jest w pewnym stopniu zgodne z poglądem przedstawionym przez Lo (2004). Natomiast, spadek natężenia pozytywnego sentymentu może być odbierany przez niedoświadczonych inwestorów jako negatywny sygnał inwestycyjny, tzn. zwiększenie prawdopodobieństwa poniesienia straty lub obniżenia potencjalnego zysku z tej inwestycji. Dlatego ich skłonność do sprzedaży Bitcoina może wtedy wzrastać. Zatem w okresie spadku natężenia pozytywnego sentymentu ci inwestorzy mogą wychodzić z rynku Bitcoina, co może prowadzić do okresowego zmniejszenia poziomu efektywności tego rynku.

Oszacowanie parametru przy zmiennej dotyczącej natężenia negatywnego sentymentu inwestorów nie jest statystycznie różne od zera (tabela 18). Może to wynikać z faktu, że awersja do strat jest jednym z najmniej znaczących czynników behawioralnych oddziałujących na zachowanie inwestorów na rynku kryptowalut (Sood i in., 2023). Jeżeli potencjalna strata z

inwestycji ma małe znaczenie dla zachowania inwestorów, to wahania natężenia negatywnego sentymentu inwestorów mogą nie oddziaływać znacząco na zmiany stopnia pamięci szeregu czasowego. Biorąc pod uwagę wyniki estymacji modelu przedstawione w tabeli 18 stwierdzono zatem, że nie ma podstaw do potwierdzenia hipotezy H2B:

Wzrost (spadek) natężenia negatywnego sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

Brak potwierdzenia hipotezy drugiej może również wynikać z informacji, które wykorzystuje się w trakcie szacowania wartości indeksów FEARS i GREED. Indeksy te odzwierciedlają globalny sentyment inwestorów indywidualnych na rynkach finansowych. Zatem w trakcie szacowania wartości tych indeksów nie bierze się pod uwagę m. in. słów i emotikonów, które są charakterystycznym środkiem komunikacji użytkowników Bitcoina w mediach. Jednakże, pozyskanie tych informacji dla całego okresu badania nie jest możliwe z uwagi na ograniczony dostęp do danych z mediów społecznościowych. Podobne wyniki uzyskali Chu, Zhang i Chan (2019), którzy nie potwierdzili jednoznacznie znaczenia sentymentu wyrażonego w informacjach rynkowych dla poziomu efektywności rynku kryptowalut. Konkludując, nie ma podstaw do przyjęcia hipotezy drugiej (H2):

Wzrost (spadek) natężenia sentymentu inwestorów jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

Oszacowanie parametru przy zmiennej dotyczącej skłonności inwestorów do zakotwiczenia na 52-tygodniowym maksimum notowań Bitcoina nie jest statystycznie różne od zera (tabela 18). Zatem nie ma podstaw do przyjęcia hipotezy H3:

Wzrost (spadek) skłonności inwestorów do ulegania heurystyce zakotwiczenia jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina.

Brak potwierdzenia hipotezy trzeciej jest sprzeczny z wynikami badania przeprowadzonego przez George'a i Hwanga (2004) na rynku akcji, co może wynikać z relatywnie wysokiej zmienności cen Bitcoina. Takie warunki mogą wywoływać silne emocje wśród inwestorów (zarówno pozytywne jak i negatywne), więc ich decyzje inwestycyjne mogą być często zmieniane, co dotyczy w szczególności mniej doświadczonych z nich.

Oszacowania przy zmiennych kontrolnych są zbieżne z oczekiwaniami. Związek między płynnością a dynamiką efektywności rynku Bitcoina jest dodatni i statystycznie różny od zera.

Tą zależność potwierdzają wyniki innych badań (Brauneis i Mestel, 2018; Wei, 2018; Al-Yahyaee i in., 2020; Mokni i in., 2024). Inną zmienną kontrolną w badaniu jest wolumen obrotu. Oszacowanie parametru przy tej zmiennej jest również dodatnie, co jest zbieżne z wynikami, które otrzymali Khuntia i Pattanayak (2020). Jednakże, poziom istotności statystycznej dla wolumenu obrotu jest wyższy niż w przypadku płynności (16%). Oszacowania parametrów przy pozostałych zmiennych kontrolnych (kapitalizacja rynku Bitcoina, niepewność inwestycyjna) nie są statystycznie różne od zera. Związek pomiędzy poziomem efektywności rynku Bitcoina a niepewnością inwestycyjną nie został również jednoznacznie potwierdzony przez Mokniego i in. (2024).

Wyniki estymacji modeli cząstkowych potwierdzają uzyskane oszacowania parametrów przy zmiennych odnoszących się do czynników behawioralnych (załącznik 3). Zatem korelacja pomiędzy czynnikami behawioralnymi a zmiennymi w poszczególnych modelach nie oddziałuje znacząco na uzyskane rezultaty. Przeprowadzone testy założeń KMNK wskazują, że w przypadku szacowanych modeli nie występuje problem z ich specyfikacją, autokorelacją reszt pierwszego rzędu oraz współliniowością zmiennych objaśniających. Ponadto wykazano, że reszty są homoskedastyczne i mają rozkład zbliżony do normalnego.

W toku badania przeprowadzono również test Chowa dla trzech punktów załamania strukturalnego: lipiec 2016 r. i maj 2020 r. (odpowiada to kolejnym halvingom na rynku Bitcoina) oraz marzec 2018 r. (połowa okresu badania). W pierwszym kroku próba badawcza została podzielona na dwie grupy według każdej z podanych dat. Następnie szacowano osobne modele dla tych sześciu okresów. Dla każdego z tych modeli obliczano sumę kwadratów reszt, które posłużyły do policzenia wartości statystyk F. W ostatnim kroku porównywano wartość statystyki F z wartością krytyczną. Na tej podstawie stwierdzono, że oszacowania parametrów modelu (tabela 18) dla wszystkich wyszczególnionych okresów nie różnią się istotnie względem każdej z wyszczególnionych dat. Jest to zgodne z rezultatami wcześniejszego badania znaczenia halvingu dla poziomu efektywności rynku Bitcoina (Phiri, 2022).

Oszacowania parametrów modelu przedstawione w tabeli 18 odzwierciedlają tzw. krótkoterminowe oddziaływanie zmiennych objaśniających w danym okresie na zmienną zależną. Dlatego obliczono również długoterminowe mnożniki dla parametrów modelu przy poszczególnych zmiennych (Gruszczyński i in., 2009, s. 229-232). Zakładając, że zmienne są

stacjonarne⁷⁶, długoterminowy mnożnik wyznaczono jako pochodną z funkcji (przekształcona ogólna postać modelu) względem zmiennej, co prowadzi do następującego wyrażenia:

$$\frac{\partial y}{\partial x} = \frac{\sum_{i=1}^j \alpha_i}{1 - \sum_{k=1}^l \beta_k} \quad (58)$$

gdzie „y” to rozważana postać funkcyjna modelu, „x” to zmienna, której długoterminowy mnożnik należy wyznaczyć, „j” oznacza liczbę opóźnień przy zmiennej objaśniającej, której współczynniki oznaczono jako „ α_i ”, „l” to liczba opóźnień przy zmiennej objaśnianej, współczynniki przy opóźnionych zmiennych zależnych oznaczono jako „ β_k ”. Statystyczną istotność długoterminowych mnożników sprawdzono za pomocą testu liniowych restrykcji wykorzystując statystykę F. Długoterminowe mnożniki dla poszczególnych zmiennych zaprezentowano w tabeli 19.

Tabela 19. Długoterminowe mnożniki dla poszczególnych zmiennych

| Zmienna | Długoterminowy mnożnik | Statystyka F (p-value) |
|----------------|------------------------|---------------------------|
| Δ ILLIQ | 0,0054 | 2,0865 (0,1295) |
| Δ Vol | 0,0050 | 2,0079 (0,1596) |
| Δ MC | -0,0027 | 0,1512 (0,6982) |
| Δ VIX | -0,0018 | 0,0604 (0,8064) |
| Δ GSV | -0,0004 | 0,0008 (0,9288) |
| FEARS | -0,0008 | 0,0421 (0,8378) |
| GREED | 0,0060* | 2,8279 (0,0958) |
| Δ W52 | 0,0028 | 0,1377 (0,7113) |

Uwagi: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%, Wyniki na podstawie oszacowań parametrów w modelu łącznego oddziaływania czynników behawioralnych na dynamikę efektywności rynku Bitcoina.

Wyniki zawarte w tabeli 19 wskazują, że jedyny istotny statystycznie długoterminowy mnożnik dotyczy natężenia pozytywnego sentymentu inwestorów, co potwierdza rezultaty uzyskane w ramach modelu ADL. Kierunek łącznego oddziaływania tej zmiennej na dynamikę efektywności rynku Bitcoina jest zgodny z krótkoterminowym efektem (tabela 18), ale przeciwny do zakładanego (hipoteza H2A). Wyniki testu F wskazują, że istotność statystyczna

⁷⁶ Przeprowadzone testy wskazują na stacjonarność zmiennych.

kombinacji wszystkich oszacowań parametrów przy zmiennej dotyczącej poziomu płynności jest niższa niż w przypadku modelu, którego wyniki estymacji przedstawiono w tabeli 18. Możliwe zatem, że związek pomiędzy poziomem płynności a dynamiką efektywności rynku Bitcoina jest krótkotrwały lub nieliniowy.

W dalszej części badania przeprowadzono test odporności uzyskanych rezultatów. W tym celu wykorzystano inny estymator parametrów modelu - funkcję największej wiarygodności. Ponadto, na podstawie wykresów ACF (autokorelacji zmiennej) i PACF (autokorelacji cząstkowej) wygenerowanych dla zmiennej objaśnianej przyjęto, że model powinien mieć postać autoregresyjną ze średnią ruchomą (ARMA) (Gruszczyński i in., 2009, s.209-210). Dobór specyfikacji tego modelu został dokonany na podstawie metody „od szczególnego do ogólnego” (tak jak w przypadku modelu ADL). To znaczy, w pierwszej kolejności oszacowano model z jednym opóźnieniem. Następnie szacowano modele o różnych specyfikacjach dodając kolejne opóźnienia zmiennej zależnej. Oszacowane modele ARMA sprawdzano pod względem braku autokorelacji składnika losowego (test Ljung-Boxa i wykres autokorelacji ACF), normalności rozkładu (histogram, wykres kwantylowy, test Shapiro-Wilka) i homoskedastyczności reszt (na podstawie wykresów reszt i ich standaryzowanych wartości). Jako ostateczną postać modelu przyjęto ARMA (6,1), ponieważ jako jedyny spośród rozważanych specyfikacji spełniał powyższe warunki. Wyniki estymacji modelu ARMA - łącznego oddziaływania czynników behawioralnych na dynamikę efektywności rynku Bitcoina przedstawiono w tabeli 20.

Wyniki estymacji modelu ARMA są ilościowo i jakościowo zbliżone do oszacowań parametrów w przypadku modelu ADL, co nie zmienia wcześniejszych wniosków. Oszacowania parametrów przy zmiennych odzwierciedlających skłonność inwestorów do ulegania heurystyce zakotwiczenia, ich uwagę oraz sentyment inwestorów nie są statystycznie różne od zera. Co więcej, znaki współczynników przy tych zmiennych są takie same jak w przypadku modelu ADL. Zatem oszacowanie parametru przy zmiennej GREED jest dodatnie, co nie jest zgodne z postawioną hipotezą H2A. Niemniej jednak, w przypadku tego modelu prawdopodobieństwo popełnienia błędu I rodzaju w kontekście oszacowanego parametru przy zmiennej oznaczającej natężenie pozytywnego sentymentu inwestorów zwiększyło się około 10% do 17%. Wyniki estymacji modeli cząstkowych typu ARMA (tabele C1-C5 w załączniku 4) również potwierdzają wcześniejsze wnioski.

Tabela 20. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina – model ARMA

| Zmienna | Współczynnik | Błąd standardowy |
|--------------------------------------|--------------|------------------|
| Zm_ef_(t-1) | -0,13673 | 0,14060 |
| Zm_ef_(t-2) | -0,34772*** | 0,11800 |
| Zm_ef_(t-3) | -0,14702 | 0,12639 |
| Zm_ef_(t-4) | -0,23582** | 0,11257 |
| Zm_ef_(t-5) | -0,20686** | 0,10542 |
| Zm_ef_(t-6) | -0,26609*** | 0,10308 |
| MA(1) | -0,82653*** | 0,11583 |
| Stała | -0,00029 | 0,00030 |
| Δ GSV_t | -0,00417 | 0,00687 |
| FEARS_t | -0,00058 | 0,00223 |
| GREED_t | 0,00791 | 0,00569 |
| Δ W52_t | 0,00262 | 0,00501 |
| Δ ILLIQ_t | 0,00741** | 0,00353 |
| Δ ILLIQ_(t-1) | -0,00646* | 0,00340 |
| Δ Vol_t | 0,00993** | 0,00473 |
| Δ MC_t | -0,00398 | 0,00579 |
| Δ VIX_t | 0,00530 | 0,01126 |
| Wartość kryterium informacyjnego AIC | -518,79 | |
| Wartość kryterium informacyjnego BIC | -469,70 | |

Uwagi: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%. MA(1) oznacza średnią ruchomą rzędu 1 dla składnika losowego.

Rozbieżność w istotności współczynników poszczególnych zmiennych w modelach ADL i ARMA może wynikać z różnych sposobów uwzględnienia występowania autokorelacji reszt

modelu. W przypadku modeli ADL zastosowano błędy Newey-Westa odporne na heteroskedastyczność i autokorelację reszt. W modelu ARMA uwzględniono dalsze opóźnienia zmiennej zależnej, co mogło zmniejszyć autokorelację reszt modelu. Ponadto, tylko w ramach modelu ARMA założono, że składnik losowy podlega procesowi średniej ruchomej rzędu 1.

Podsumowując, wyniki estymacji różnych modeli wskazały, że wzrost (spadek) natężenia analizowanych czynników behawioralnych nie jest związany ze zmniejszeniem (zwiększeniem) poziomu efektywności rynku Bitcoina. Zatem nie potwierdzono trzech postawionych hipotez dotyczących zależności między uwagą inwestorów, natężeniem sentymentu inwestorów lub skłonnością inwestorów do ulegania heurystyce zakotwiczenia a dynamiką efektywności rynku Bitcoina. Ponadto, przeprowadzone badanie wykazało, że związek między natężeniem pozytywnego sentymentu inwestorów a efektywnością informacyjną rynku jest dodatni. Uzyskane rezultaty potwierdziły, że wzrost poziomu płynności lub wolumenu obrotu jest związany ze zwiększeniem poziomu efektywności rynku Bitcoina (i odwrotnie), co jest zgodne z wynikami innych badań.

Brak potwierdzenia stawianych hipotez może wynikać z kilku kwestii. Po pierwsze, uwaga inwestorów skierowana na Bitcoina może być trudna do zmierzenia w tak długim okresie badania z powodu zmian poziomu zmienności popularności tej kryptowaluty. Uzyskane oszacowania modelu mogły także być związane ze zwiększeniem udziału doświadczonych inwestorów na rynku i rozwojem ich wiedzy. W późniejszym okresie istnienia Bitcoina inwestorzy na tym rynku mogli częściej korzystać z zaawansowanych narzędzi analitycznych. Po trzecie, w badaniu dokonano pomiaru natężenia globalnego⁷⁷ sentymentu uczestników tego rynku. Jednakże, w przypadku Bitcoina większe znaczenie mógł mieć sentyment wyrażony w opiniach użytkowników mediów społecznościowych (umożliwiają one szybkie rozpowszechnianie informacji wśród osób zainteresowanych danym tematem). Zatem w przypadku inwestorów korzystających z mediów społecznościowych, reakcja na ogłoszenie informacji mogła być szybsza niż w przypadku pozostałych uczestników tego rynku. Innym wytłumaczeniem mogła być wysoka zmienność cen Bitcoina, co mogło prowadzić do częstych zmian decyzji inwestycyjnych niedoświadczonych inwestorów.

⁷⁷ Natężenie sentymentu wyznaczono z uwzględnieniem indeksów GSV, które dotyczyły zapytań na temat słów bądź fraz ogólnie związanych z ekonomią i finansami. W efekcie, oszacowane wartości zmiennych mogą mieć charakter globalny, tzn. odzwierciedlać zachowanie inwestorów także w odniesieniu do innych aktywów niż Bitcoin.

Nie bez znaczenia dla braku potwierdzenia postawionych hipotez może być fakt, że w badaniu wzięto pod uwagę tylko pewien aspekt zachowania cen na rynku efektywnym w formie słabej, tzn. niezależność stóp zwrotu i proporcjonalny wzrost wariancji do upływu czasu. Ponadto, zachowanie stóp zwrotu z Bitcoina może charakteryzować inny rodzaj błędzenia losowego niż założony na potrzeby niniejszego badania. Jednakże, dokładne określenie procesu stochastycznego występującego na rynku może być bardzo trudne. Dlatego, w następnym podrozdziale zostaną przeprowadzone dodatkowe analizy z zastosowaniem innych miar dynamiki efektywności rynku Bitcoina.

4.4 Ocena wyników badania w odniesieniu do wymiarów błędzenia losowego

Na podstawie wyników przedstawionych w poprzednim podrozdziale nie potwierdzono trzech postawionych hipotez badawczych. Ponadto, przeprowadzono test odporności wyników badania, który miał na celu ocenę zależności uzyskanych rezultatów od wybranej postaci modelu i estymatora. W tym podrozdziale zostały zaprezentowane wyniki dodatkowych analiz, które miały na celu zastosowanie innych niż dotychczas miar poziomu efektywności rynku w formie słabej.

Zastosowana wcześniej miara efektywności rynku (wykładnik Hursta) w modelu podstawowym odnosiła się do dwóch wymiarów błędzenia losowego jednocześnie, tzn. niezależności stop zwrotu i proporcjonalnego wzrostu wariancji w czasie (ruch Browna)⁷⁸. Jednakże, oddziaływanie czynników behawioralnych na dynamikę efektywności rynku Bitcoina może różnić się w zależności od badanego wymiaru błędzenia losowego. Dlatego, w celu pogłębienia badania zostały wykorzystane następujące miary efektywności rynku: statystyka testu ilorazu wariancji (AVR) oraz parametr rzędu integracji ułamkowej (d). Dzięki wykorzystaniu tych miar możliwe było odniesienie osobno do liniowego wzrostu wariancji w czasie⁷⁹ oraz niezależności stóp zwrotu.

W pierwszej kolejności oszacowano wartości statystyki testu ilorazu wariancji (AVR) oraz parametru rzędu integracji ułamkowej (d) w kolejnych miesiącach⁸⁰. Następnie, wartości tych zmiennych przekształcono w celu zbliżenia ich rozkładu do normalnego i sprowadzenia do

⁷⁸ Wymiary błędzenia losowego omówiono w podrozdziale 1.2.

⁷⁹ Błędzenie losowe charakteryzuje się liniowym wzrostem wariancji w czasie. Ruch Browna jest tylko pewnym jego przypadkiem, tzn. w ramach tego typu procesu zakłada się proporcjonalną zmianę wariancji wraz z upływem czasu.

⁸⁰ Szczegółowy sposób pomiaru zmiennych zależnych omówiono w podrozdziale 3.2.

postaci stacjonarnej. Pierwsza z nich została przedstawiona jako przyrosty kolejnych miesięcznych jej wartości i oznaczona jako Zm_Ef^{AVR} . Druga zmienna zależna odnosząca się do parametru rzędu integracji ułamkowej była obliczona jako przyrosty logarytmów bezwzględnych wartości parametru „d”. Została ona zdefiniowana jako Zm_Ef^{GPH} . Wartości obu zmiennych zostały przemnożone przez „-1”, żeby ujednolicić ich interpretację ze zmienną objaśnianą wyznaczoną na podstawie wykładnika Hursta. Zatem dodatnia (ujemna) wartość zmiennych objaśnianych oznacza wzrost (spadek) poziomu efektywności rynku w porównaniu do poprzedniego miesiąca. Wyniki testów stacjonarności, normalności rozkładu oraz wartości statystyk opisowych dla tych zmiennych zostały przedstawione w tabeli 21.

Tabela 21. Charakterystyki rozkładu zmiennych zależnych zastosowanych w ramach testów odporności

| Statystyki | Zm_Ef^{AVR} | Zm_Ef^{GPH} |
|--------------------------------|----------------|----------------|
| Średnia | 0,0026 | -0,0004 |
| Odchylenie standardowe | 1,2109 | 1,5549 |
| Skośność | -0,2244 | -0,0871 |
| Kurtoza | 2,6221 | 3,3100 |
| Statystyka testu Jarque-Bera | 1,6351 | 4,0245 |
| Statystyka testu Shapiro-Wilka | 0,9813 | 0,9791*** |
| Statystyka testu ADF | -7,9924* | -7,0404* |
| Statystyka testu KPSS | 0,0284 | 0,0319 |

Uwaga: “***”, “**”, “*” oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. KPSS oznacza Kwiatkowski–Phillips–Schmidt–Shin, skrót “ADF” należy czytać jako Augmented Dickey–Fuller. Wartości obu zmiennych zostały zwinsoryzowane na 2. i 98. percentylu.

Na podstawie wartości kurtozy, skośności i wyników testów Jarque-Bera wykazano, że rozkłady obu zmiennych nie różnią się znacznie od rozkładu normalnego (tabela 21). Jednakże, wyniki testu Shapiro-Wilka wskazały na odrzucenie hipotezy zerowej w przypadku zmiennej odnoszącej się do rzędu integracji ułamkowej. Ponadto, zaobserwowano wysokie wartości odchylenia standardowego przy relatywnie małej średniej wartości obu zmiennych. Dlatego stwierdzono, że charakteryzują się one wyższą wartością współczynnika zmienności w porównaniu do dynamiki efektywności rynku Bitcoina obliczonej na podstawie wykładnika Hursta (tabela 17). Ta rozbieżność mogła wynikać z faktu, że zmienne te odnoszą się do różnych wymiarów błędzenia losowego. Ponadto, mogła być to kwestia przeciwnych kierunków zmian Zm_Ef^{AVR} w stosunku do Zm_Ef^{GPH} , co zaobserwowano w niektórych okresach (wykres A w załączniku). Na podstawie wyników testów ADF i KPSS wysnuto wniosek, że zmienne Zm_Ef^{AVR} i Zm_Ef^{GPH} są stacjonarne.

W kolejnym etapie oszacowano modele związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina z różnymi zmiennymi zależnymi: Zm_Ef^{AVR} i Zm_Ef^{GPH} . Na podstawie wykresów funkcji autokorelacji wyznaczonych dla obydwu zmiennych objaśnianych zauważono, że szacowane modele dla obu zmiennych powinny mieć postać autoregresyjną (ADL), tak jak to miało miejsce w modelach, w których poziom efektywności był określany za pomocą wykładnika Hursta. Dobór specyfikacji tych modeli został dokonany na podstawie metody „od szczególnego do ogólnego”.

Jako ostateczną postać modelu ze zmienną Zm_Ef^{AVR} przyjęto AR(1), ponieważ model ten w największym stopniu spełniał założenia KMNK spośród rozważanych specyfikacji. Wartości współczynników VIF były poniżej liczby 2 dla wszystkich zmiennych. Na podstawie testu Breuscha-Pagana nie odrzucono hipotezy zerowej o homoskedastyczności reszt na poziomie 10%. Stwierdzono, że rozkład reszt modelu istotnie nie różni się od rozkładu normalnego zakładając poziom istotności równy 10% (test Shapiro-Wilka). Jednakże, reszty modelu cechowały się istotną autokorelacją w drugim opóźnieniu. Dlatego, w ramach tego modelu zastosowano błędy Newey-Westa, które są odporne na autokorelację i heteroskedastyczność reszt. Innym problemem związanym z tym modelem była jego specyfikacja (testy RESET wskazały na odrzucenie hipotezy zerowej o poprawnej specyfikacji przy poziomie istotności równym 10%). Zatem wyniki estymacji tego modelu przedstawione w tabeli 22 należy ostrożnie interpretować, ponieważ badane zależności mogą być nieliniowe.

Oszacowania parametrów modelu ze zmienną Zm_Ef^{AVR} wskazują, że znaki współczynników przy zmiennych odnoszących się do uwagi oraz sentymentu inwestorów są takie same jak w przypadku modeli przedstawionych w poprzednim podrozdziale (4.3). Jednakże, związek pomiędzy czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina jest nieistotny statystycznie na poziomie 10% (tabela 22). Zatem wyniki estymacji tego modelu nie potwierdzają wcześniejszych rezultatów modelu z wykładnikiem Hursta w kontekście zmiennej odzwierciedlającej natężenie pozytywnego sentymentu inwestorów. Co więcej, spośród zmiennych kontrolnych, jedynie oszacowanie parametru przy wolumenie obrotu na rynku Bitcoina jest statystycznie różne od zera. Kierunek tej zależności jest dodatni, co jest zgodne z wcześniej uzyskanymi rezultatami badania. Zatem wyniki estymacji tego modelu wskazują, że związek pomiędzy poziomem płynności a dynamiką efektywności rynku Bitcoina jest nieistotny statystycznie na poziomie 10%, co nie potwierdza uzyskanych

oszacowań parametrów modeli ADL i ARMA przedstawionych w poprzednim podrozdziale. Tak jak w przypadku większości tych modeli (podrozdział 4.3), oszacowania przy pozostałych zmiennych nie różnią się statystycznie od zera.

Tabela 22. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina obliczoną z wykorzystaniem testu ilorazu wariancji

| Zmienna | Współczynnik | Błąd standardowy |
|----------------------------------|---------------------------|------------------|
| Zm_ef_(t-1) | -0,53075*** | 0,08183 |
| Δ ILLIQ_t | 0,02924 | 0,16177 |
| Δ ILLIQ_(t-1) | 0,09198 | 0,13551 |
| Δ Vol_t | 0,48234* | 0,26184 |
| Δ MC_t | -0,33261 | 0,59405 |
| Δ VIX_t | -0,83668 | 0,71017 |
| Δ GSV_t | -0,09493 | 0,46562 |
| FEARS_t | -0,11274 | 0,30395 |
| GREED_t | 0,25430 | 0,25858 |
| Δ W52_t | -0,08791 | 0,65280 |
| Stała | 0,00479 | 0,07029 |
| Liczba obserwacji | 113 | |
| Skorygowany R ² | 0,24309 | |
| Błąd standardowy reszt | 1,04730 (df = 102) | |
| Statystyka F | 4,59707*** (df = 10; 102) | |
| Statystyka testu Durбина-Watsona | 2,3241 | |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%.

Model, którego wyniki estymacji przedstawiono w tabeli 22, został sprawdzony pod względem występowania załamań strukturalnych (test Chowa). Nie stwierdzono, aby parametry tego modelu różniły się istotnie gdyby podzielono próbę badawczą względem trzech dat: lipiec 2016 r. i maj 2020 r. oraz marzec 2018 r.

Nieistotność oszacowań parametrów przy zmiennych odnoszących się do poziomu płynności i natężenia pozytywnego sentymentu inwestorów (tabela 22) może wynikać z faktu, że wykorzystane miary efektywności rynku do wyznaczenia zmiennej zależnej w poszczególnych modelach uwzględniają różne wymiary błędzenia losowego. W ramach testu

ilorazu wariancji zakłada się, że błędzenie losowe przejawia się w liniowej zależności wariancji od czasu. Jednakże, wykładnik Hursta odnosi się do dwóch wymiarów błędzenia losowego - niezależności stóp zwrotu i proporcjonalnej (liniowej) zależności wariancji od czasu, co jest charakterystyczne dla ruchu Browna. Możliwe zatem, że oddziaływanie poziomu płynności i natężenia pozytywnego sentymentu inwestorów na dynamikę efektywności rynku Bitcoina przejawia się w innym wymiarze błędzenia losowego niż liniowa zależność wariancji od czasu (np. niezależności stóp zwrotu) albo/i tylko w proporcjonalnej zależności wariancji od czasu. Innym wytłumaczeniem niepotwierdzenia oszacowań przy tych zmiennych, które uzyskano w przypadku podstawowego modelu ADL może być występowanie innego procesu stochastycznego niż ruch Browna. Jeżeli na rynku Bitcoina występuje inny rodzaj błędzenia losowego niż zakładany, to zależność wariancji od czasu może być nieliniowa. W takim przypadku, test ilorazu wariancji może prowadzić do błędnych wskazań.

Następny model, który został oszacowany w ramach pogłębionej analizy wyników badania dotyczył zmiennej Zm_Ef^{GPH} . Model ten miał postać AR(5), ponieważ specyfikacja ta w najwyższym stopniu spełniała założenia KMNK. Wyniki estymacji tego modelu przedstawiono w tabeli 23.

Wyniki estymacji modelu ze zmienną Zm_Ef^{GPH} wskazują, że związek między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina jest nieistotny statystycznie na poziomie 10%. Ponadto, znaki współczynników przy zmiennych dotyczących skłonności inwestorów do ulegania heurystyce zakotwiczenia, uwagi inwestorów oraz natężenia pozytywnego sentymentu inwestorów są przeciwne do tych uzyskanych w ramach modelu podstawowego. W odróżnieniu od otrzymanych wcześniej rezultatów, wyniki estymacji tego modelu wskazują na brak statystycznej istotności współczynników przy zmiennych: GREED i ΔVol . Oszacowanie parametru przy zmiennej odzwierciedlającej zmiany poziomu płynności jest dodatnie i statystycznie różne od zera. Kierunek tej zależności jest zgodny z wynikami estymacji modeli zaprezentowanych w poprzednim podrozdziale. Zatem wyniki estymacji tego modelu również nie potwierdzają istnienia związku pomiędzy czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina.

Tabela 23. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina obliczoną z wykorzystaniem modelu rzędu integracji ułamkowej GPH

| Zmienna | Współczynnik | Błąd standardowy |
|----------------------------------|--------------------------|------------------|
| Zm_ef_(t-1) | -0,67287*** | 0,11564 |
| Zm_ef_(t-2) | -0,62697*** | 0,16389 |
| Zm_ef_(t-3) | -0,33468** | 0,12931 |
| Zm_ef_(t-4) | -0,25591** | 0,11787 |
| Zm_ef_(t-5) | -0,15822 | 0,09828 |
| Δ ILLIQ_t | 0,35124* | 0,19387 |
| Δ ILLIQ_(t-1) | -0,01790 | 0,21805 |
| Δ Vol_t | 0,55178 | 0,41292 |
| Δ MC_t | -0,92822 | 0,73415 |
| Δ VIX_t | -0,91411 | 0,76989 |
| Δ GSV_t | 0,45314 | 0,67018 |
| FEARS_t | -0,30486 | 0,41961 |
| GREED_t | -0,19218 | 0,40270 |
| Δ W52_t | -0,43554 | 0,96611 |
| Stała | 0,08416 | 0,11096 |
| Liczba obserwacji | 109 | |
| Skorygowany R ² | 0,32807 | |
| Błąd standardowy reszt | 1,25505 (df = 94) | |
| Statystyka F | 4,76649*** (df = 14; 94) | |
| Statystyka testu Durбина-Watsona | 2,0480 | |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%.

Model, którego wyniki estymacji przedstawiono w tabeli 23 został sprawdzony pod względem występowania załamań strukturalnych i spełnienia różnych założeń KMNK. Przeprowadzone testy wskazały na brak istotnych autokorelacji reszt w każdym z analizowanych opóźnień oraz poprawną specyfikację (test RESET). Na podstawie wskazań testu Breuscha-Pagana odrzucono hipotezę zerową o homoskedastyczności reszt modelu. Dlatego, przy szacowaniu błędów standardowych parametrów tego modelu zastosowano

błędy Newey'a-Westa. Test Chowa wskazał na brak istotnych statystycznie załamań strukturalnych dla trzech dat: lipiec 2016 r. i maj 2020 r. oraz marzec 2018 r.

Podsumowując, na podstawie oszacowań parametrów modeli z różnymi zmiennymi objaśnianymi nie potwierdzono występowania związku pomiędzy czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina. Jedynie w przypadku modelu ADL z wykładnikiem Hursta wskazano, że oszacowanie parametru przy zmiennej oznaczającej natężenie pozytywnego sentymentu inwestorów jest dodatnie i istotne statystycznie. Brak potwierdzenia wyników estymacji modelu podstawowego w kontekście natężenia pozytywnego sentymentu inwestorów mógł wynikać z rozbieżności pomiędzy wskazaniem wykładnika Hursta a oszacowaniami parametru rzędu integracji ułamkowej dla szeregu czasowego, którego rozkład różnił się od rozkładu normalnego⁸¹ (Ding i in., 2021). Ponadto, oszacowane modele charakteryzowały się ograniczeniami (m. in. heteroskedastyczność, rozkład reszt odbiegający od rozkładu normalnego⁸²), które mogły skutkować niepotwierdzeniem rezultatów przedstawionych w poprzednim podrozdziale.

Wyniki przeprowadzonych dodatkowych analiz wskazały na występowanie związku pomiędzy wolumenem obrotu na rynku Bitcoina a dynamiką efektywności tego rynku tylko w przypadku modelu ze zmienną zależną odnoszącą się do liniowego wzrostu wariancji w czasie. Natomiast istnienie asocjacji pomiędzy poziomem płynności a dynamiką efektywności rynku Bitcoina potwierdziły oszacowania parametrów modelu, w przypadku którego zmienna zależna została wyznaczona na podstawie parametru rzędu integracji ułamkowej⁸³. Zatem zależność między płynnością lub wolumenem obrotu a dynamiką efektywności rynku Bitcoina przejawia się tylko w niektórych wymiarach błędzenia losowego.

Występowanie związku pomiędzy natężeniem pozytywnego sentymentu inwestorów a zmianami poziomu efektywności rynku Bitcoina potwierdzono tylko w przypadku modelu ze zmienną zależną wyznaczoną na podstawie wykładnika Hursta. Można zatem dojść do wniosku, że wykładnik Hursta jest bardziej pojemną informacyjnie miarą dynamiki efektywności rynku Bitcoina niż wykorzystane testy ilorazu wariancji czy rzędu integracji ułamkowej. Zauważono, że zmiany poziomu efektywności rynku wyznaczone za pomocą

⁸¹ Na podstawie testu Jarque-Bera stwierdzono, że rozkład godzinowych logarytmicznych stóp zwrotu z Bitcoina w okresie badania istotnie różni się od rozkładu normalnego.

⁸² Jeżeli rozkład reszt jest zbliżony do rozkładu normalnego, to testy takie jak t i F zachowują moc statystyczną, tzn. poziomy istotności tych testów pozostają na pierwotnym poziomie (Maddala, 2008, s. 488).

⁸³ Zmienna ta odnosi się do jednego wymiaru błędzenia losowego - niezależności stóp zwrotu.

modelu rzędu integracji ułamkowej lub statystyki ilorazu wariancji cechują się znacznie wyższą zmiennością niż w przypadku ich oszacowań uzyskanych z wykorzystaniem wykładnika Hursta. Może to wynikać z faktu, że spośród tych miar tylko wykładnik Hursta odnosi się do proporcjonalnego wzrostu wariancji w czasie i niezależności stóp zwrotu.

4.5 Interpretacja uzyskanych rezultatów w kontekście teorii efektywności rynku oraz wyników dotychczasowych badań

Wyniki badań empirycznych przedstawione w poprzednich podrozdziałach nie pozwalają jednoznacznie stwierdzić występowania zależności między analizowanymi czynnikami behawioralnymi a efektywnością informacyjną rynku Bitcoina. Jednakże, w myśl hipotezy rynku adaptacyjnego skłonność inwestorów do nieracjonalnych zachowań może zmieniać się wskutek zmian warunków rynkowych, co przyczynia się do zmian poziomu efektywności rynku (Lo, 2004). Ponadto, dotychczasowe badania potwierdzają, że czynniki behawioralne mają znaczenie dla przewidywalności cen Bitcoina (Kraaijeveld i Smedt, 2020; Liu i Tsyvinski, 2021; Naeem i in., 2021), która jest jednym z przejawów braku efektywności rynku. Biorąc pod uwagę rozważania, które stanowiły podstawę wyprowadzenia hipotez badawczych, można przypuszczać, że czynniki behawioralne mają jednak znaczenie dla zmian poziomu efektywności rynku Bitcoina. Dlatego podjęto refleksję nad wyjaśnieniem uzyskanych rezultatów poznawczych.

W ramach niniejszej dysertacji założono, że stosunek inwestorów doświadczonych do niedoświadczonych oraz/lub skłonność dotychczasowych⁸⁴ uczestników rynku do nieracjonalnych zachowań zmieniają się wskutek zmian warunków rynkowych (podrozdział 3.1). Zatem struktura uczestników tego rynku może warunkować występowanie zależności między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina. W literaturze istnieją różne klasyfikacje inwestorów na tym rynku (m. in. Lee i in., 2020; Mizerka i in., 2020; Jahanshahloo i in., 2023). Dlatego w tym podrozdziale zostaną przedstawione możliwe wyjaśnienia uzyskanych rezultatów w kontekście innej struktury uczestników rynku Bitcoina niż podział inwestorów ze względu na ich doświadczenie. Wśród potencjalnych przyczyn uzyskanych wyników zostaną także wyróżnione następujące: niestabilność rynku, wysoki poziom szumu informacyjnego oraz wysoka popularność korzystania z zaawansowanych narzędzi analitycznych przez inwestujących w Bitcoina.

⁸⁴ Inwestorzy, którzy pozostali na rynku w okresie wzrostu niepewności inwestycyjnej.

Ze względu na cel zawierania transakcji wśród uczestników rynku Bitcoina można wyodrębnić następujące grupy (Jahanshahloo i in., 2023): 1) podmioty zajmujące się wydobyciem kryptowalut, 2) firmy oferujące usługi płatnicze lub inwestycyjne z wykorzystaniem Bitcoina, 3) inwestorów indywidualnych podejmujących decyzje inwestycyjne o charakterze spekulacyjnym (tzw. hazardystów (Kim i in., 2020)) oraz 4) inwestorów wykorzystujących długoterminowe strategie inwestycyjne (np. typu „*buy and hold*”). Pierwszą z wyróżnionych grup stanowią podmioty, których głównym celem jest maksymalizacja zysku ze sprzedaży Bitcoinów otrzymanych w zamian za weryfikację oraz dodanie bloku transakcji do *blockchaina*. Charakteryzuje ich relatywnie niska częstotliwość zawierania transakcji i mały udział w rynku.

Do drugiej grupy uczestników rynku Bitcoina należą firmy, które umożliwiają wykorzystanie kryptowalut jako środka płatniczego lub pośrednie inwestowanie na tym rynku. Jednakże, ze względu na wysoką zmienność (Dwyer, 2015) oraz niski stopień akceptacji Bitcoina jako powszechnego środka płatności wśród podmiotów prywatnych (Statista, 2021), można przypuszczać, że motyw transakcyjny ma relatywnie małe znaczenie na tym rynku. Innymi podmiotami należącymi do tej grupy są firmy, które oferują ekspozycję na Bitcoina bez potrzeby jego posiadania (m. in. internetowe platformy handlowe, inwestorzy instytucjonalni). Tego typu podmioty mogą cechować się większym doświadczeniem i/lub wiedzą, dlatego są mniej podatne na czynniki behawioralne niż przeciętny inwestor. Jednakże, przez większość okresu objętego analizą, udział w rynku Bitcoina podmiotów należących do tej grupy pozostawał na relatywnie niskim poziomie, na co wskazują wyniki badania przeprowadzonego przez Jahanshahloo i in. (2023).

Odmienna sytuacja występuje w przypadku trzeciej grupy, czyli inwestorów indywidualnych dokonujących transakcji o charakterze spekulacyjnym, które zdają się odgrywać coraz większą rolę na rynku Bitcoina. Inwestorów zaliczanych do tej grupy charakteryzuje częste zawieranie transakcji giełdowych (Jahanshahloo i in., 2023), co może skutkować wystąpieniem krótkotrwałych trendów cenowych. Zatem decyzje inwestycyjne podejmowane przez spekulantów powinny w dużym stopniu zależeć od czynników behawioralnych. Jednakże, zaobserwowano, że inwestorzy ci posiadają relatywnie niewielką liczbę Bitcoinów (Jahanshahloo i in., 2023). Dlatego przeprowadzane przez nich transakcje

spekulacyjne mogły mieć mniejszy wpływ na zachowanie cen na tym rynku w okresach zwiększonej aktywności największych użytkowników Bitcoina⁸⁵ niż zazwyczaj.

Największy udział w rynku Bitcoina mają inwestorzy należący do ostatniej grupy, których charakteryzuje rzadkie zawieranie transakcji. Może to świadczyć o wykorzystywaniu przez nich strategii inwestycyjnych typu „*buy and hold*” (Jahanshahloo i in., 2023). Przyczynami takiego zachowania może być chęć dywersyfikacji portfela inwestycyjnego (Bouri i in., 2017) lub zabezpieczenia majątku przed inflacją (Choi i Shin, 2022). Na przykład, jeżeli Bitcoin stanowi niewielką część portfela inwestycyjnego, tego typu uczestnicy rynku mogą być mniej wrażliwi na spadki cen na tym rynku, ponieważ ich wpływ na wartość całego majątku inwestora jest ograniczony. Argumentem przemawiającym za tym jest również fakt, że niektórzy inwestorzy⁸⁶ na rynku kryptowalut są w mniejszym stopniu podatni na awersję do strat w porównaniu do innych czynników behawioralnych (Sood i in., 2023). Innymi słowy, potencjalne straty z inwestycji nie wpływają znacząco na ich decyzje inwestycyjne. Zatem brak potwierdzenia postawionych hipotez może wynikać z tego, że w analizowanych warunkach dominowali inwestorzy mniej podatni na czynniki behawioralne.

Wyniki badań empirycznych można także interpretować w kontekście struktury inwestorów zaobserwowanej przez Lee i in. (2020). Według nich, wśród uczestników rynku Bitcoina należy wyróżnić m. in. inwestorów posiadających wiedzę na temat nowych technologii oraz spekulantów. Przyjmuje się, że spekulanci mają krótki horyzont inwestycyjny, ponieważ podejmują decyzje inwestycyjne na podstawie analizy historycznych trendów cenowych. W zależności od poziomu zmienności wykorzystują oni strategie inwestycyjne typu *momentum* (kontynuacji stóp zwrotu) lub *contrarian* (reakcji odwrotnej do poprzednio zaobserwowanego trendu stóp zwrotu). W efekcie mogą być oni w większym stopniu podatni na czynniki behawioralne niż pozostali. Z kolei uczestnicy rynku Bitcoina posiadający wiedzę na temat nowych technologii mają zazwyczaj długoterminowy horyzont inwestycyjny, co wynika z faktu, że podejmują oni decyzje inwestycyjne na podstawie analizy potencjału wykorzystania Bitcoina w gospodarce⁸⁷ (jego przyszłej wartości). W konsekwencji, powinni

⁸⁵ Inwestorzy należący do ostatniej z omawianych grup.

⁸⁶ Ponieważ zaobserwowano, że bardziej doświadczeni inwestorzy są w mniejszym stopniu podatni na efekt dyspozycji (Bashall i in., 2018), można przypuszczać, że ci uczestnicy rynku charakteryzują się relatywnie wysokim poziomem doświadczenia.

⁸⁷ Na przykład, poziomu akceptacji płatności z wykorzystaniem kryptowalut przez różne podmioty gospodarcze oraz instytucje.

mieć oni mniejszą skłonność do podejmowania decyzji inwestycyjnych pod wpływem czynników behawioralnych niż pozostali uczestnicy tego rynku. Ponieważ przez większość okresu badania na rynku Bitcoina przeważali długoterminowi⁸⁸ inwestorzy (Sornette i Zhang, 2025), można stwierdzić, że decyzje inwestycyjne podejmowane przez przeciętnego uczestnika rynku były w niewielkim stopniu zależne od czynników behawioralnych. Zatem miesięczna zmiana poziomu efektywności rynku Bitcoina⁸⁹ mogła w dużej mierze odzwierciedlać zachowanie inwestorów, którzy są mniej podatni na czynniki behawioralne, co może być jedną z przyczyn braku potwierdzenia hipotez badawczych. Ponieważ tego typu inwestorzy mają dłuższy horyzont inwestycyjny niż ci w większym stopniu podatni na nieracjonalne zachowania, związek między czynnikami behawioralnymi a poziomem efektywności rynku powinien być mocniejszy w przypadku wykorzystania danych o wyższej częstotliwości, co jest możliwe dzięki skróceniu okresu pomiaru zmiennych. Biorąc pod uwagę przedstawione rozważania, można zatem przypuszczać, że czynniki behawioralne oddziałują na poziom efektywności rynku Bitcoina w interwałach czasowych krótszych niż miesięczne.

Kolejnym możliwym wyjaśnieniem uzyskanych rezultatów jest fakt, że rynek kryptowalut charakteryzował się wysoką niestabilnością. Zlecenia kupna lub sprzedaży Bitcoina były składane w warunkach częstych zmian przepisów dotyczących wydobycia kryptowalut, występujących oszustw oraz ataków hakerskich (Khuntia i Pattanayak, 2020). Takie warunki mogły powodować nieracjonalne zachowania inwestorów, tzn. podejmowanie decyzji inwestycyjnych z wykorzystaniem heurystyk. Zatem, gdy pojawiały się informacje o możliwym wystąpieniu negatywnego zdarzenia, inwestorzy mogli zawyżać prawdopodobieństwo jego zajścia, co mogło skutkować sprzedażą dużej liczby Bitcoinów w krótkim czasie⁹⁰. Jednakże, tego typu informacje są weryfikowane przez profesjonalne serwisy informacyjne, takie jak *CoinDesk* czy *Cointelegraph*. Dzięki ich działaniom nieprawdziwe informacje mogły zostać szybko zweryfikowane, co prowadziło do zmiany sentymentu inwestorów i odwrócenia ich wcześniejszych reakcji (kupnem dużej liczby Bitcoinów). Zatem, pomimo że część inwestorów ulegała czynnikom behawioralnym, wysoka niestabilność warunków rynkowych mogła spowodować, że zmiany cen Bitcoina nie wykazywały wyraźnego trendu w analizowanym

⁸⁸ Zakłada się, że tego typu inwestorzy mają horyzont inwestycyjny dłuższy niż jeden rok (Sornette i Zhang, 2025).

⁸⁹ W ramach niniejszego badania analizie poddano związek między miesięczną zmianą poziomu efektywności rynku Bitcoina a miesięcznym natężeniem czynników behawioralnych.

⁹⁰ Uczestnicy rynku Bitcoina mają tendencję do podejmowania decyzji inwestycyjnych na podstawie niezweryfikowanych informacji, zamiast na podstawie faktów (Huynh, 2022).

okresie, przypominając błądzenie losowe (zachowanie cen typowe dla rynku efektywnego). Mogło to skutkować brakiem potwierdzenia związku między czynnikami behawioralnymi a poziomem efektywności rynku Bitcoina. Nie można jednak wykluczyć, że zależność ta występuje w krótszym interwale czasowym niż miesięczny.

W podobny sposób można tłumaczyć fakt, że w ramach niniejszego badania nie zaobserwowano występowania zależności między uwagą inwestorów a dynamiką efektywności rynku Bitcoina. Uczestnicy tego rynku są szczególnie narażeni na zdarzenia o charakterze manipulacyjnym typu „*pump and dump*” (Hamrick i in., 2021), co wynika z braku odpowiednich przepisów dotyczących ochrony interesów inwestorów. Tego typu zjawiska polegają na sztucznym zawyżaniu ceny waloru poprzez udostępnianie nieprawdziwych informacji na temat inwestycji. Jeżeli zjawiska typu „*pump and dump*” występują często w kontekście danego rynku, to jego uczestnicy mogą otrzymywać dużą ilość nieprawdziwych informacji o inwestycji. Jest zatem możliwe, że Bitcoin charakteryzuje się wysokim poziomem szumu informacyjnego, co utrudnia podejmowanie świadomych decyzji inwestycyjnych. W efekcie inwestorzy ulegający heurystyce dostępności mogli wykazywać różne zachowania. Na przykład, część z nich kupowała Bitcoina, podejmując decyzje pod wpływem wysokiej dostępności niepotwierdzonych informacji o pozytywnych perspektywach tego rynku. Jednakże, w tym samym czasie mogły pojawiać się informacje rynkowe o negatywnym wydzwieku skłaniające innych inwestorów do sprzedaży Bitcoina. W takich warunkach zróżnicowanie zachowania uczestników rynku mogło się zwiększyć, skutkując niejednoznaczną reakcją ceny Bitcoina na wzrost uwagi inwestorów skierowanej na tę inwestycję. W konsekwencji zachowanie cen na tym rynku mogło przypominać błądzenie losowe, co jest charakterystyczne dla rynku efektywnego, mimo że w rzeczywistości inwestorzy mogli zachowywać się nieracjonalnie.

Wysoka popularność korzystania z zaawansowanych narzędzi analitycznych może również być przyczyną niepotwierdzenia występowania zależności pomiędzy czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina. Wśród uczestników tego rynku występują osoby posiadające wiedzę w zakresie nowych technologii (Lee i in., 2020). Można zatem przypuszczać, że mają oni odpowiednią wiedzę na temat możliwości wykorzystania programów komputerowych do automatyzacji podejmowania decyzji inwestycyjnych. Ponieważ kryptowaluty cechują się wyższą zmiennością niż inwestycje tradycyjne, tego typu strategie inwestycyjne mogą być częściej stosowane przez uczestników tego rynku niż w

przypadku innych inwestycji (Cohen, 2023). Zatem, mimo że większość z inwestujących na tym rynku charakteryzuje się niewielkim doświadczeniem, a tym samym powinna być podatna na czynniki behawioralne, mogą oni wykorzystywać algorytmiczne strategie inwestycyjne. Wysoka popularność tego typu metod inwestycyjnych wśród uczestników rynku prowadzi do zmniejszenia czasu ich reakcji na odchylenia ceny aktywa od jego historycznych maksimów. Ponadto, inwestorzy stosujący tego typu strategie inwestycyjne nie są podatni na informacje nacechowane emocjonalnie, gdyż decyzje inwestycyjne są podejmowane automatycznie. Dlatego znaczenie czynników behawioralnych dla nieracjonalnego zachowania inwestujących w analizowanych warunkach mogło być znikome, co przekładało się na brak ich związku z efektywnością informacyjną rynku Bitcoina.

Podsumowując, z powyższych rozważań wynika, że główną przyczyną niepotwierdzenia postawionych hipotez badawczych mogła być struktura inwestorów na rynku Bitcoina. W ramach niniejszej pracy przyjęto, że podział inwestorów na doświadczonych oraz niedoświadczonych warunkuje występowanie zależności między czynnikami behawioralnymi a efektywnością informacyjną rynku Bitcoina. Jednakże, nie wzięto pod uwagę różnic w zachowaniu uczestników tego rynku ze względu na cel zawierania transakcji bądź ich wiedzę na temat nowych technologii, które mogły mieć wpływ na uzyskane rezultaty. Ponadto, wśród innych przyczyn otrzymanych wyników należy wyróżnić: wysoki poziom szumu informacyjnego, niestabilność rynku Bitcoina oraz wysoką popularność korzystania z zaawansowanych narzędzi analitycznych w ramach strategii inwestycyjnych. Można jednak przypuszczać, że inwestorzy na tym rynku są podatni na czynniki behawioralne. Związek między tymi czynnikami a poziomem efektywności rynku Bitcoina może występować w krótszym interwale czasowym lub tylko w przypadku niektórych przejawów braku efektywności rynku, np. przewidywalności stóp zwrotu. Dlatego potrzebne są dalsze badania w tym obszarze.

Zakończenie

Celem pracy była ocena związku pomiędzy wybranymi czynnikami behawioralnymi a efektywnością informacyjną rynku Bitcoina. Aby go osiągnąć, przeprowadzony został przegląd literatury dotyczącej efektywności rynku kryptowalut oraz nieracjonalnych zachowań inwestorów, co pozwoliło na precyzyjne określenie luki badawczej. W toku badania zostały również określone najbardziej odpowiednie miary efektywności rynku oraz sposoby pomiaru czynników behawioralnych do jego przeprowadzenia. Dzięki temu możliwe było dokonanie rzetelnej analizy występowania zależności między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina. W celu weryfikacji istnienia tej zależności zostały wykorzystane modele autoregresyjne.

Inspirując się hipotezą rynku adaptacyjnego (AMH) przedstawiono dwa potencjalne mechanizmy oddziaływania niepewności inwestycyjnej na poziom efektywności rynku. Wzrost niepewności inwestycyjnej może spowodować zwiększenie skłonności dotychczasowych uczestników rynku do nieracjonalnego zachowania. Ponadto, w takich warunkach może dojść do spadku liczby doświadczonych inwestorów i wzrostu liczby niedoświadczonych uczestników rynku. Ponieważ mniej doświadczeni inwestorzy są w większym stopniu podatni na przejawy nieracjonalnego zachowania, w ten sposób dochodzi do obniżenia poziomu efektywności rynku. Zatem obydwa przypadki mogą prowadzić do obniżenia poziomu efektywności rynku, co stanowiło podstawę do sformułowania trzech hipotez badawczych. W ramach nich przyjęto, że istnieje związek między odpowiednio uwagą inwestorów, ich skłonnością do ulegania heurystyce zakotwiczenia, natężeniem sentymentu inwestorów a dynamiką efektywności rynku Bitcoina.

W celu weryfikacji postawionych hipotez zostało przeprowadzone badanie empiryczne, które poprzedzała ocena przydatności poszczególnych miar efektywności rynku. Na podstawie zakresu wykorzystywanych informacji, stopnia obiektywizmu, zgodności z zasadami obrotu na rynku, odporności na zdarzenia nieprzewidywalne oraz jednoznaczności interpretacji stwierdzono, że najbardziej przydatne są testy korelacji i zależności długookresowych. Cechują się one największą pojemnością informacyjną pod względem odzwierciedlenia zachowania cen na rynku efektywnym w formie słabej, czyli błędzenia losowego. Do tej grupy miar efektywności rynku należy wykładnik Hursta, który odnosi się do dwóch wymiarów błędzenia losowego jednocześnie. Z tego względu został on wybrany jako podstawowa miara poziomu efektywności rynku Bitcoina.

Przedmiotem badania empirycznego była jednak dynamika efektywności rynku, a nie jej poziom. Dlatego w rozprawie został opracowany autorski sposób jej pomiaru - została ona wyznaczona jako zmiana kolejnych bezwzględnych odchyłeń wartości wykładnika Hursta od jego wartości określającej stan rynku efektywnego. Dokonana analiza zmian poziomu efektywności rynku Bitcoina pozwoliła stwierdzić, że wystąpienie zdarzeń nacechowanych niepewnością inwestycyjną zbiega się z dużymi i krótkotrwałymi zmianami poziomu efektywności tego rynku. Ponieważ w myśl hipotezy rynku adaptacyjnego zmiana warunków rynkowych wiąże się ze zmianą skłonności inwestorów do nieracjonalnego zachowania, zaobserwowana zależność może pośrednio wskazywać na występowanie związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina.

Wyniki przeprowadzonych badań empirycznych nie dały jednak podstaw do potwierdzenia postawionych hipotez. Nie zostało potwierdzone, że zachodzi zależność między uwagą inwestorów, natężeniem negatywnego sentymentu lub skłonnością inwestorów do ulegania heurystyce zakotwiczenia a dynamiką efektywności rynku Bitcoina. Jednocześnie zostało zaobserwowane, że związek między pozytywnym sentymentem inwestorów a poziomem efektywności rynku Bitcoina jest dodatni, czyli przeciwny do zakładanego. Zatem zależność między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina może być bardziej złożona niż oczekiwano.

Choć występowanie związku między czynnikami behawioralnymi a efektywnością informacyjną rynku Bitcoina nie zostało potwierdzone, z przeprowadzonych badań wynikają istotne implikacje. Jedną z nich jest propozycja poszerzenia AMH (Lo, 2004). W ramach hipotezy rynku adaptacyjnego nie zostało wskazane, który z przejawów nieracjonalności inwestorów w większym stopniu odpowiada za zmiany poziomu efektywności rynku. Uzyskane rezultaty sugerują, że dla dynamiki efektywności rynku największe znaczenie ma zachowanie inwestorów pod wpływem pozytywnego sentymentu. Wzrost natężenia tego czynnika behawioralnego może powodować wzrost liczby mniej doświadczonych (lub niedoświadczonych) inwestorów, których charakteryzuje krótki horyzont inwestycyjny. Wejście na rynek tego typu inwestorów prowadzi do większego zróżnicowania horyzontów inwestycyjnych ogółu inwestujących. W efekcie zwiększa się poziom płynności na rynku, której rolę w kształtowaniu zachowania cen podkreśla się w ramach hipotezy rynku fraktalnego. W konsekwencji szybkość odzwierciedlenia dostępnych informacji na temat inwestycji w jej cenie może się zwiększyć (poziom efektywności rynku wzrasta). Powyższe przypuszczenie

potwierdzają wyniki przeprowadzonego badania, z którego wynika, że wyższy poziom płynności jest powiązany z wyższym poziomem efektywności rynku Bitcoina. Hipotezę rynku adaptacyjnego należy zatem rozwinąć poprzez uwzględnienie znaczenia zróżnicowania horyzontów inwestycyjnych i natężenia pozytywnego sentymentu dla zmian poziomu efektywności rynku.

Brak potwierdzenia zależności między natężeniem negatywnego sentymentu inwestorów, ich skłonnością do ulegania heurystyce zakotwiczenia oraz uwagą inwestorów a dynamiką efektywności rynku Bitcoina stanowi użyteczną informację dla inwestorów. Ponieważ wyniki przeprowadzonych badań wskazują na brak efektywności tego rynku, można wysnuć wniosek, że występuje zależność między przeszłymi a bieżącymi stopami zwrotu z Bitcoina. Oznacza to, że informacje na temat przeszłych stóp zwrotu z Bitcoina mogą zostać wykorzystane do predykcji ich przyszłych wartości. Interpretując to w kontekście braku potwierdzenia postawionych hipotez, można stwierdzić, że niezależnie od wzrostu natężenia czynników behawioralnych, informacje na temat przeszłych stóp zwrotu z Bitcoina są istotne dla zyskowności strategii inwestycyjnych.

Wyniki przeprowadzonego badania można wykorzystać do poprawy skuteczności strategii inwestycyjnych także w innym aspekcie. Jako miarę efektywności rynku zastosowano wykładnik Hursta, który generuje obiektywne sygnały inwestycyjne. W literaturze przedmiotu wskazuje się, że znaczne spadki cen spowodowane wystąpieniem krachów rynkowych następują po dużych spadkach wartości wykładnika Hursta lub zmianie charakteru pamięci stóp zwrotu (przejście z długiej do krótkiej pamięci) (Grech i Mazur, 2004). W kontekście występowania tego typu zdarzeń istotną rolę mogą odgrywać emocje inwestorów, które prowadzą do występowania krótkotrwałych trendów rynkowych. Jednakże, uzyskane wyniki sugerują, że zmiany wartości wykładnika Hursta nie wynikają z emocjonalnego zachowania inwestorów, co sugeruje, że ten sygnał można traktować jako obiektywną przesłankę spodziewanego spadku ceny. Zatem strategie inwestycyjne uczestników rynku Bitcoina powinny uwzględniać sygnały ostrzegawcze płynące z zanikania lub zmian charakteru pamięci stóp zwrotu z inwestycji. Niemniej jednak, z przeprowadzonej dyskusji na temat możliwych przyczyn niepotwierdzenia hipotez wynika, że czynniki behawioralne mogą być powiązane ze zmianami wykładnika Hursta, ale w innych warunkach niż uwzględnione w badaniu. Należy zatem zachować ostrożność w interpretacji uzyskanych rezultatów, odnosząc je do analizowanych warunków.

Rezultaty i wnioski z badań empirycznych przedstawionych w rozprawie należy traktować z rozwagą ze względu na ograniczenia badania. Pierwszym z nich było założenie dotyczące modelu błędzenia losowego, który opisuje proces kształtowania cen na rynku efektywnym. Przyjęto, że rynek jest efektywny, jeżeli stopy zwrotu zachowują się zgodnie z ruchem Browna. Jednakże, istnieją różne modele błędzenia losowego. Na przykład, proces Lévy'ego może lepiej odzwierciedlać zachowanie stóp zwrotu z inwestycji charakteryzujących się rozkładem o tzw. grubych ogonach. Jeżeli proces ten jest właściwy do opisanie zmian cen Bitcoina na rynku efektywnym, to wartość wykładnika Hursta oznaczająca błędzenie losowe może być inna niż przyjęta w niniejszym badaniu. Biorąc pod uwagę to oraz fakt, że poziom efektywności rynku oznacza stopień odzwierciedlenia losowego zachowania cen, należy stwierdzić, że założenie innego procesu stochastycznego niż ruch Browna ma znaczenie dla wyników pomiaru dynamiki efektywności rynku Bitcoina.

Drugie ograniczenie wynikało z dostępu do danych. Z tego względu badaniem zostały objęte wybrane czynniki behawioralne, a pomiar sentymentu inwestorów został dokonany w ograniczonym zakresie. W ramach badania nie został uwzględniony sentyment wyrażony w opiniach użytkowników mediów społecznościowych, które mogą odgrywać znaczącą rolę w kształtowaniu zmian cen kryptowalut, co powinno przekładać się na dynamikę efektywności rynku.

Kolejnym ograniczeniem badania było wykorzystanie do pomiaru efektywności rynku Bitcoina notowań godzinowych. Z przeprowadzonego przeglądu literatury wynika, że rezultaty pomiaru poziomu efektywności rynku Bitcoina różnią się w zależności od przyjętej częstotliwości danych. Zatem częstotliwość notowań Bitcoina może mieć znaczenie dla wyników pomiaru dynamiki efektywności tego rynku. Ograniczeniem badania jest również zakres informacji, które uwzględniono do określenia poziomu efektywności rynku, tzn. rozpatrywano jej słabą formę.

Uzyskane rezultaty mogą stać się inspiracją do podjęcia dalszych badań w różnych obszarach. Przedstawione w rozdziale czwartym rozważania sugerują, że przyszłe badania powinny uwzględniać w szczególności strukturę inwestorów na rynku Bitcoina. Jedną z możliwości wzięcia jej pod uwagę jest zbadanie związku między czynnikami behawioralnymi a poziomem efektywności rynku w innych interwałach czasowych niż miesięczne. Można zaproponować także odmienne rozwiązanie metodyczne w zakresie wykorzystania miar efektywności rynku odnoszących się do wymiarów błędzenia losowego innych niż niezależność

stóp zwrotu oraz liniowość wzrostu wariacji w czasie. Interesującym kierunkiem badań jest również dokonanie pomiaru sentymentu inwestorów w sposób inny niż dotychczas, czyli na podstawie wydźwięku opinii użytkowników mediów społecznościowych na temat Bitcoina. Badania przeprowadzone w ramach niniejszej rozprawy warto także poszerzyć o dotąd nieuwzględnione czynniki behawioralne, np. uwagę inwestorów skierowaną na hasła proekologiczne, która może mieć szczególne znaczenie dla poziomu efektywności rynku w przypadku mniej energochłonnych kryptowalut. Zasadne wydaje się zatem rozszerzenie przeprowadzonych badań w ramach tej pracy, uwzględniając inne kryptowaluty niż Bitcoin czy nawet inwestycje tradycyjne. W kontekście uzyskanych rezultatów, za ciekawy obszar badań można także uznać ocenę znaczenia czynników behawioralnych dla siły i kierunku zależności między niepewnością inwestycyjną a poziomem efektywności rynku.

Pomimo, iż czynniki behawioralne prawdopodobnie odgrywają znaczącą rolę w kształtowaniu cen kryptowalut, nie zaobserwowano związku między tymi czynnikami a dynamiką efektywności rynku Bitcoina. Co więcej, uzyskane rezultaty sugerują, że zależność między pozytywnym sentymentem a poziomem efektywności informacyjnej Bitcoina jest bardziej złożona niż oczekiwano. Ponieważ w ostatnich latach inwestorzy podejmują decyzje inwestycyjne w warunkach stale rosnącej niepewności geopolitycznej i gospodarczej, można oczekiwać, że czynniki behawioralne nabierają na znaczeniu w kontekście wycen instrumentów finansowych. Potrzebne są zatem dalsze badania nad zależnością między czynnikami behawioralnymi a dynamiką efektywności rynku kryptowalut.

Bibliografia

- Adcock, R. i Gradojevic, N. (2019). Non-fundamental, non-parametric Bitcoin forecasting. *Physica A: Statistical Mechanics and its Applications*, 531(C). <https://doi.org/10.1016/j.physa.2019.121727>
- Aggarwal, D. (2019). Do bitcoins follow a random walk model? *Research in Economics*, 73, 15–22. <http://dx.doi.org/10.1016/j.rie.2019.01.002>
- Agosto, A., Cerchiello, P. i Pagnottoni, P. (2022). Sentiment, Google queries and explosivity in the cryptocurrency market. *Physica A: Statistical Mechanics and its Applications*, 605. <https://doi.org/10.1016/j.physa.2022.128016>.
- Ahmad, M. i Wu, Q. (2022). Does herding behavior matter in investment management and perceived market efficiency? Evidence from an emerging market. *Management Decision*, 60(8), 2148-2173. <https://doi.org/10.1108/MD-07-2020-0867>
- Ahmad, M. i Wu, Q. (2023). Heuristic-driven biases as mental shortcuts in investment management activities: a qualitative study. *Qualitative Research in Financial Markets*. <https://doi.org/10.1108/QRFM-10-2022-0167>
- Akbar, M., Ullah, I., Ali, S. i Rehman, N. (2024). Adaptive market hypothesis: A comparison of Islamic and conventional stock indices. *International Review of Economics & Finance*, 89, 460-477. <https://doi.org/10.1016/j.iref.2023.06.020>
- Alevy, J. E., Haigh, M. S. i List, J. A. (2007). Information Cascades: Evidence from a Field Experiment with Financial Market Professionals. *The Journal of Finance*, 62(1), 151–180. Pobrane z <http://www.jstor.org/stable/4123459>
- Alexander, S. S. (1961). Price Movements in Speculative Markets: Trends or Random Walks. *Industrial Management Review*, 2(2), 7–26. Pobrane z <http://history.technicalanalysis.org.uk/Alex64.pdf>
- Allais, M. (1953). Le Comportement de l'Homme Rationnel devant le Risque: Critique des Postulats et Axiomes de l'Ecole Americaine. *Econometrica*, 21(4), 503–546. <https://doi.org/10.2307/1907921>
- Alvarez-Ramirez, J., Rodriguez, E. i Espinosa-Paredes, G. (2012). A partisan effect in the efficiency of the US stock market. *Physica A: Statistical Mechanics and its Applications*, 391(20), 4923-4932. <https://doi.org/10.1016/j.physa.2012.05.005>

- Alvarez-Ramirez, J., Rodriguez, E. i Ibarra-Valdez, C. (2018). Long-range correlations and asymmetry in the Bitcoin market. *Physica A: Statistical Mechanics and Its Applications*, 492, 948–55. <https://doi.org/10.1016/j.physa.2017.11.025>
- Almansour, B. Y. i Arabyat, Y. A. (2017). Investment decision making among Gulf investors: Behavioural finance perspective. *International Journal of Management Studies*, 24(1), 41–71. <https://doi.org/10.32890/ijms.24.1.2017.10476>
- Al-Khazali, O. i Mirzaei, A. (2017). Stock market anomalies, market efficiency and the adaptive market hypothesis: Evidence from Islamic stock indices. *Journal of International Financial Markets, Institutions and Money*, 51, 190-208. <https://doi.org/10.1016/j.intfin.2017.10.001>
- Al-mansour, B.Y. (2020). Cryptocurrency Market: Behavioral Finance Perspective. *Journal of Asian Finance, Economics and Business*, 7(12), 159–168. <https://doi.org/10.13106/jafeb.2020.vol7.no12.159>
- Al-Yahyaee, K. H., Mensi, W. i Yoon, S. (2018). Efficiency, multifractality, and the long-memory property of the Bitcoin market: A comparative analysis with stock, currency, and gold markets. *Finance Research Letters*, 27, 228-234. <https://doi.org/10.1016/j.frl.2018.03.017>
- Al-Yahyaee, K. H., Mensi, W., Ko, H.-U., Yoon, S.-M. i Kang, S. H. (2020). Why cryptocurrency markets are inefficient: The impact of liquidity and volatility. *The North American Journal of Economics and Finance*, 52(C). <https://doi.org/10.1016/j.najef.2020.101168>
- Amihud, Y. i Murgia, M. (1997). Dividends, Taxes, and Signaling: Evidence from Germany. *The Journal of Finance*, 52, 397-408. <https://doi.org/10.1111/j.1540-6261.1997.tb03822.x>
- Amihud, Y. (2002). Illiquidity and stock returns: cross-section and time-series effects. *Journal of Financial Markets*, 5(1), 31-56. [https://doi.org/10.1016/S1386-4181\(01\)00024-6](https://doi.org/10.1016/S1386-4181(01)00024-6)
- Anamika, A. i Subramaniam S. (2022). Do news headlines matter in the cryptocurrency market?. *Applied Economics*, 54-54, 6322-6338. <https://doi.org/10.1080/00036846.2022.2061904>
- Antonioni, C., Doukas, J. A. i Subrahmanyam, A. (2013). Cognitive Dissonance, Sentiment, and Momentum. *The Journal of Financial and Quantitative Analysis*, 48(1), 245–275. Pobrane z <http://www.jstor.org/stable/43303799>

- Arkes, H. i Blumer, C. (1985). The psychology of sunk cost. *Organizational Behavior and Human Decision Processes*, 35(1), 124-140. [https://doi.org/10.1016/0749-5978\(85\)90049-4](https://doi.org/10.1016/0749-5978(85)90049-4)
- Aslan, A. i Sensoy, A. (2020). Intraday efficiency-frequency nexus in the cryptocurrency markets. *Finance Research Letters*, 35(C). doi: 10.1016/j.frl.2019.09.013
- Assaf, A., Bhandari, A., Charif, H. i Demir, E. (2022). Multivariate long memory structure in the cryptocurrency market: The impact of COVID-19. *International Review of Financial Analysis*, 82(C). <https://doi.org/10.1016/j.irfa.2022.102132>
- Augustin, P., Brenner, M. i Subrahmanyam, M. G. (2019). Informed options trading prior to takeover announcements: Insider trading? *Management Science*, 65(12), 5597–5618. <https://doi.org/10.1287/mnsc.2018.3122>
- Azzam, I., El-Masry, A. i Yamani, E. (2023). Foreign exchange market efficiency during COVID-19 pandemic. *International Review of Economics & Finance*, 86. <https://doi.org/10.1016/j.iref.2023.03.043>
- Bachelier, L. (1900). Théorie de la spéculation. *Annales scientifiques de l'École Normale Supérieure*, 17, 21-86. <https://doi.org/10.24033/asens.476>
- Bakas, D., Magkonis, G. i Oh, E. Y. (2022). What drives volatility in Bitcoin market?. *Finance Research Letters*, 50. <https://doi.org/10.1016/j.frl.2022.103237>
- Bakar, S. i Yi, A.N. (2016). The Impact of Psychological Factors on Investors' Decision Making in Malaysian Stock Market: A Case of Klang Valley and Pahang. *Procedia Economics and finance*, 35, 319-328. [https://doi.org/10.1016/S2212-5671\(16\)00040-X](https://doi.org/10.1016/S2212-5671(16)00040-X)
- Baker, M. i Wurgler, J. (2006). Investor Sentiment and the Cross-Section of Stock Returns. *The Journal of Finance*, 61, 1645-1680. <https://doi.org/10.1111/j.1540-6261.2006.00885.x>
- Baker, S. R., Bloom, N. i Davis, S. J. (2016). Measuring economic policy uncertainty, *Quarterly Journal of Economics*, 131(4), 1593-1636. <https://doi.org/10.1093/qje/qjw024>
- Baker, S. R., Bloom, N., Davis, S. J. i Renault, T. (2021). Twitter-Derived Measures of Economic Uncertainty. https://policyuncertainty.com/media/Twitter_Uncertainty_5_13_2021.pdf
- Balcilar, M., Gupta, R., Kim, W.-J. i Kyei, C. (2019). The role of economic policy uncertainties in predicting stock returns and their volatility for Hong Kong, Malaysia and South Korea.

- International Review of Economics & Finance*, 59(C), 150-163.
<https://doi.org/10.1016/j.iref.2018.08.016>
- Ball, R. i Brown, P. (1968). An Empirical Evaluation of Accounting Income Numbers. *Journal of Accounting Research*, 6(2), 159–178. doi: 10.2307/2490232
- Ballis, A. i Drakos, K. (2020). Testing for herding in the cryptocurrency market. *Finance Research Letters*, 33. <https://doi.org/10.1016/j.frl.2019.06.008>
- Barber, B. M. i Odean, T. (1999). The Courage of Misguided Convictions. *Financial Analysts Journal*, 55(6), 41–55. Pobrane z <http://www.jstor.org/stable/4480208>
- Barberis, N., Shleifer, A. i Vishny, R. (1998). A model of investor sentiment. *Journal of Financial Economics*, 49, 307-343. [https://doi.org/10.1016/S0304-405X\(98\)00027-0](https://doi.org/10.1016/S0304-405X(98)00027-0)
- Barberis, N., Huang, M. i Santos, T. (2001). Prospect Theory and Asset Prices. *The Quarterly Journal of Economics*, 116 (1), 1–53. <https://doi.org/10.1162/003355301556310>
- Barberis, N. C. i Thaler, R. H. (2003). *A Survey of Behavioural Finance*. *Handbook of The Economics Of Finance*, 1053-1128 (NBER Working Paper No. 9222). Pobrane z https://www.nber.org/system/files/working_papers/w9222/w9222.pdf
- Bariviera, A. F. (2017). The inefficiency of Bitcoin revisited: A dynamic approach. *Economics Letters*, 161, 1-4. <https://doi.org/10.1016/j.econlet.2017.09.013>
- Bariviera, A. F., Basgall, M. J., Hasperué, W. i Naiouf, M. (2017). Some stylized facts of the Bitcoin market. *Physica A: Statistical Mechanics and its Applications*, 484(C), 82–90. <https://doi.org/10.1016/j.physa.2017.04.159>
- Bashall, J., Willows, G. D. i West, D. (2018). The Extent to Which Professional Advice Can Reduce the Disposition Effect: An Emerging Market Study. *Journal of Emerging Market Finance*, 17(2), 229-249. <https://doi.org/10.1177/0972652718776861>
- Baur, D. G. i McDermott, T. K. (2010). Is gold a safe haven? International evidence. *Journal of Banking & Finance*, 34(8), 1886–1898. <https://doi.org/10.1016/j.jbankfin.2009.12.008>
- BBC. (2021). *China declares all crypto-currency transactions illegal*. 24 September 2021, <https://www.bbc.com/news/technology-58678907>
- Benartzi, S. i Thaler, R. H. (1995). Myopic Loss Aversion and the Equity Premium Puzzle. *The Quarterly Journal of Economics*, 110(1), 73–92. <https://doi.org/10.2307/2118511>
- Bernoulli, D. (1954). Exposition of a New Theory on the Measurement of Risk. *Econometrica*, 22(1), 23–36. <https://doi.org/10.2307/1909829>

- Bessembinder, H. i Chan, K. (1998). Market Efficiency and the Returns to Technical Analysis. *Financial Management*, 27(2), 5–17. <https://doi.org/10.2307/3666289>
- Bhadkamar, A. i Bhattacharya, S. (2022). Tesla Inc. Stock Prediction using Sentiment Analysis. *Australasian Accounting, Business and Finance Journal*, 16(5), 52-66. <https://doi.org/10.14453/aabfj.v16i5.05>
- Bikhchandani, S. i Sharma, S. (2000). Herd Behavior in Financial Markets. *IMF Econ Rev*, 47, 279–310. <https://doi.org/10.2307/3867650>
- Binance. (2024). Pobrane z <https://www.binance.com/pl/square/post/3816441059057>
- Binance. (2025). Pobrane z <https://www.binance.com/pl/square/post/20621514332569>
- Binance academy. (2022). *Czym Jest Krypto Airdrop?* Pobrane z <https://academy.binance.com/pl/articles/what-is-a-crypto-airdrop>
- Bitcoin.org. (2024). Pobrane z [27.09.2024] <https://bitcoin.org/pl/co-potrzebujesz-wiedziec>
- Bitfinex. (b.d.). Pobrane 5 stycznia 2023 z <https://www.bitfinex.com/about/>
- Bitstamp. (b.d.). Pobrane 5 stycznia 2023 z <https://www.bitstamp.net/about-us/>
- Black, F. (1986). Noise. *The Journal of Finance*, 41, 528-543. <https://doi.org/10.1111/j.1540-6261.1986.tb04513.x>
- Blandin, A., Cloots, A., Hussain, H., Rauchs, M., Saleuddin, R., Allen, J., Zhang, B. i Cloud, K. (2019). *The Global cryptoasset regulatory landscape study*. Cambridge Centre for alternative finance. Pobrane z <https://www.jbs.cam.ac.uk/wp-content/uploads/2020/08/2019-04-ccaf-global-cryptoasset-regulatory-landscape-study.pdf>
- Bleher, J. i Dimpfl, T. (2019). Today I got a million, tomorrow, I don't know: On the predictability of cryptocurrencies by means of Google search volume. *International Review of Financial Analysis*, 63, 147–159. <https://doi.org/10.1016/j.irfa.2019.03.003>
- Borges, M. R. (2010). Efficient market hypothesis in European stock markets. *The European Journal of Finance*, 16:7, 711-726. <https://doi.org/10.1080/1351847X.2010.495477>
- Bouri, E., Molnár, P., Azzi, G., Roubaud, D. i Hagfors, L. I. (2017). On the hedge and safe haven properties of Bitcoin: Is it really more than a diversifier?. *Finance Research Letters*, 20(C), 192–198. <https://doi.org/10.1016/j.frl.2016.09.025>
- Bouri, E., Gupta, R. i Roubaud, D. (2019). Herding behaviour in cryptocurrencies. *Finance Research Letters*, 29, 216-221. <https://doi.org/10.1016/j.frl.2018.07.008>

- Bouri, E., Gil-Alana, L. A., Gupta, R. i Roubaud, D. (2019). Modelling long memory volatility in the Bitcoin market: Evidence of persistence and structural breaks. *International Journal of Finance & Economics*, 24, 412–26. <https://doi.org/10.1002/ijfe.1670>
- Bouri, E., Gupta, R. i Vo, X. V. (2020). Jumps in Geopolitical Risk and the Cryptocurrency Market: The Singularity of Bitcoin. *Working Papers*, No. 202015, University of Pretoria, Department of Economics. Pobrane z https://www.up.ac.za/media/shared/61/WP/wp_2020_15.zp186754.pdf
- Bouteska, A., Hajek, P., Abedin, M. i Dong, Y. (2023). Effect of twitter investor engagement on cryptocurrencies during the COVID-19 pandemic. *Research in International Business and Finance*, 64. <https://doi.org/10.1016/j.ribaf.2022.101850>
- Bowden, J. i Gemayel, R. (2022). Sentiment and trading decisions in an ambiguous environment: A study on cryptocurrency traders. *Journal of International Financial Markets, Institutions and Money*, 80. <https://doi.org/10.1016/j.intfin.2022.101622>
- Boya, C. M. (2019). From efficient markets to adaptive markets: Evidence from the French stock exchange. *Research in International Business and Finance*, 49, 156-165. <https://doi.org/10.1016/j.ribaf.2019.03.005>
- Brauneis, A. i Mestel, R. (2018). Price discovery of cryptocurrencies: Bitcoin and beyond. *Economics Letters*, 165, 58-61. <https://doi.org/10.1016/j.econlet.2018.02.001>
- Britannica. (2021). *What is Bitcoin's fundamental value? That's a good question*. Pobrane 19.01.2023 z <https://www.britannica.com/story/what-is-bitcoins-fundamental-value-thats-a-goodquestion>
- Buczek, S. B. (2005). *Efektywność informacyjna rynków akcji: teoria a rzeczywistość*. Warszawa: Szkoła Główna Handlowa w Warszawie.
- Burggraf, T., Huynh, T. L. D., Rudolf, M. i Wang, M. (2021). Do FEARS drive Bitcoin?. *Review of Behavioral Finance*, 13(3), 229-258. <https://doi.org/10.1108/RBF-11-2019-0161>
- Caiffa, M., Farina, V. i Fattobene, L. (2020). All that glitters is not gold: CEOs' celebrity beyond media content. *International Journal of Finance and Economics*, 25, 444–460. <https://doi.org/10.1002/ijfe.1761>
- Cajueiro, D. i Tabak, B. (2004). The Hurst exponent over time: testing the assertion that emerging markets are becoming more efficient. *Physica A: Statistical Mechanics and its Applications*, 336(3), 521-537. <https://doi.org/10.1016/j.physa.2003.12.031>

- Caldara, D. i Iacoviello, M. (2021). Measuring Geopolitical Risk. *International Finance Discussion Papers*, No. 1222r1. Washington: Board of Governors of the Federal Reserve System. <https://doi.org/10.17016/IFDP.2022.1222r1>.
- Campbell, J., Lo, A., i MacKinlay, A. (1997). *The Econometrics of Financial Markets*. Princeton: Princeton University Press.
- Caporale, G. M., Gil-Alana, L. i Plastun, A. (2018). Persistence in the cryptocurrency market. *Research in International Business and Finance*, 46(C), 141-148. doi: 10.1016/j.ribaf.2018.01.002
- Cary, M. (2021). Down with the #DogeFather: Evidence of a Cryptocurrency Responding in Real Time to a Crypto-Tastemaker. *Journal of Theoretical Application and Applied Electronic Commerce Research*, 16, 2230-2240. <https://doi.org/10.3390/jtaer16060123>
- Cerda, G. C. i Reutter, J. L. (2019). Bitcoin Price Prediction Through Opinion Mining. W: *Companion Proceedings of The 2019 World Wide Web Conference (WWW '19)*. Association for Computing Machinery, New York, USA, 755–762. <https://doi.org/10.1145/3308560.3316454>
- Chahooki, M. A. Z., Jahanbin, K. i Sutikno, T. (2023). Cryptocurrencies investment framework using sentiment analysis of Twitter influencers. *Indonesian Journal of Electrical Engineering and Computer Science*, 30(2), 1068–1079. <http://doi.org/10.11591/ijeecs.v30.i2.pp1068-1079>
- Chalmers, J., Kaul, A. i Phillips, B. (2013). The wisdom of crowds: Mutual fund investors' aggregate asset allocation decisions. *Journal of Banking and Finance*, 37 (9): 3318–33. <https://doi.org/10.1016/j.jbankfin.2013.05.004>
- Chan, L. K. C., Jegadeesh, N. i Lakonishok, J. (1996). Momentum Strategies. *The Journal of Finance*, 51(5), 1681-1713. <https://doi.org/10.2307/2329534>
- Chan, K. C., Gup, B. E. i Pan, M.-S. (1997). International Stock Market Efficiency and Integration: A Study of Eighteen Nations. *Journal of Business Finance & Accounting*, 24: 803-813. <https://doi.org/10.1111/1468-5957.00134>
- Chan, W. S., Frankel, R. M. i Kothari, S. P. (2003). *Testing Behavioral Finance Theories Using Trends and Sequences in Financial Performance* (MIT Sloan School of Management Working Paper 4375-02). Pobrane z <http://dx.doi.org/10.2139/ssrn.316999>

- Charfeddine, L. i Khediri, K. B. (2016). Time varying market efficiency of the GCC stock markets. *Physica A: Statistical Mechanics and its Applications*, 444, 487-504. <https://doi.org/10.1016/j.physa.2015.09.063>.
- Charles, A., Darné, O. i Kim, J. K. (2017). Adaptive Markets Hypothesis for Islamic Stock Portfolios: Evidence from Dow Jones Size and Sector-Indices. *International Economics*, 151(C), 100-112. <https://doi.org/10.1016/j.inteco.2017.05.002>
- Cheah, E. i Fry, J. (2015). Speculative bubbles in Bitcoin markets? An empirical investigation into the fundamental value of Bitcoin. *Economics Letters*, 130, 32-36. <https://doi.org/10.1016/j.econlet.2015.02.029>
- Chen, G., Kim, K. A., Nofsinger, J. R. i Rui, O. M. (2007). Trading performance, disposition effect, overconfidence, representativeness bias, and experience of emerging market investors. *Journal of Behavioral Decision Making*, 20, 425-451. <https://doi.org/10.1002/bdm.561>
- Chen, F. (2016). The wealth effects of dividend announcements on bondholders: New evidence from the over-the-counter market. *Journal of Economics and Business*, 86, 52–75. <https://doi.org/10.1016/j.jeconbus.2016.04.003>
- Chen, Q., Hua, X. i Jiang, Y. (2018). Contrarian strategy and herding behaviour in the Chinese stock market. *The European Journal of Finance*, 24(16), 1552-1568. <https://doi.org/10.1080/1351847X.2015.1071715>
- Chen, C. Yi-H., Després, R., Guo, L. i Renault, T. (2019). What makes cryptocurrencies special? Investor sentiment and return predictability during the bubble. *IRTG 1792 Discussion Paper*, No. 2019-016, Humboldt-Universität zu Berlin, International Research Training Group 1792. Pobrane z <https://www.wiwi.hu-berlin.de/de/forschung/irtg/results/discussion-papers/discussion-papers-2017-1/irtg1792dp2019-016.pdf>
- Chen, C., Liu, L. i Zhao, N. (2020). Fear Sentiment, Uncertainty, and Bitcoin Price Dynamics: The Case of COVID-19. *Emerging Markets Finance and Trade*, 56(10), 2298-2309. <https://doi.org/10.1080/1540496X.2020.1787150>
- Cheng, H.-P. i Yen, K.-C. (2020). The relationship between the economic policy uncertainty and the cryptocurrency market. *Finance Research Letters*, 35(C). <https://doi.org/10.1016/j.frl.2019.101308>

- Chicago Booth Review. (2017). *What's the Fundamental Value of a Bitcoin?* Pobrane [19.01.2023] z <https://www.chicagobooth.edu/review/whats-fundamental-value-bitcoin>
- Choi, I. (1999). Testing the random walk hypothesis for real exchange rates. *Journal of Applied Econometrics*, 14, 293-308. [https://doi.org/10.1002/\(SICI\)1099-1255\(199905/06\)14:3%3C293::AID-JAE503%3E3.0.CO;2-5](https://doi.org/10.1002/(SICI)1099-1255(199905/06)14:3%3C293::AID-JAE503%3E3.0.CO;2-5)
- Choi, S. i Shin, J. (2022). Bitcoin: An inflation hedge but not a safe haven. *Finance Research Letters*, 46, 102379. <https://doi.org/10.1016/j.frl.2021.102379>
- Choi, K.-H., Kang, S. H. i Yoon, S.-M. (2022). Herding behaviour in Korea's cryptocurrency market. *Applied Economics*, 54, 2795-2809. <https://doi.org/10.1080/00036846.2021.1998335>
- Christie, W. G. i Huang, R. D. (1995). Following the Pied Piper: Do Individual Returns Herd around the Market?. *Financial Analysts Journal*, 51(4), 31-37. <https://doi.org/10.2469/faj.v51.n4.1918>
- Chu, J., Zhang, Y. i Chan, S. (2019). The adaptive market hypothesis in the high frequency cryptocurrency market. *International Review of Financial Analysis*, 64, 221-231. <https://doi.org/10.1016/j.irfa.2019.05.008>
- Ciołek, M. (2019). *Efektywność informacyjna polskiego rynku akcji* (wyd. 2). Warszawa: Wydawnictwo CeDeWu Sp. z o.o.
- Cleveland, R. B., Cleveland, W. S., McRae, J.E. i Terpenning, I. (1990). STL: A Seasonal-Trend Decomposition Procedure Based on LOESS. *Journal of Official Statistics*, 6, 3-73. Pobrane z <https://www.wessa.net/download/stl.pdf>
- CME. (2016). *CME Group and Crypto Facilities Announce Launch of Bitcoin Reference Rate and Real-Time Index*. <https://investor.cmegroup.com/news-releases/news-release-details/cme-group-and-crypto-facilities-announce-launch-bitcoin?>
- Cohen, L., Malloy, C. J. i Pomorski, L. (2012). Decoding inside information. *The Journal of Finance*, 67(3), 1009–1043. <https://doi.org/10.1111/j.1540-6261.2012.01740.x>
- Cohen, G. (2023). Intraday algorithmic trading strategies for cryptocurrencies. *Review of Quantitative Finance and Accounting*, 61, 395–409. <https://doi.org/10.1007/s11156-023-01139-2>
- Coinbase. (b.d.). *Co to jest fork?* Pobrane 30 grudnia 2022 z <https://www.coinbase.com/pl/learn/crypto-basics/what-is-a-fork>

- Coinbase. (b.d.). *Co to jest halving bitcoina?* Pobrane 9 stycznia 2023 z <https://www.coinbase.com/pl/learn/crypto-basics/what-is-a-bitcoin-halving>
- CoinDesk. (2016). *Digital currency exchange gatecoin offline after loss of funds*. Pobrane 20 października 2025 z <https://www.coindesk.com/markets/2016/05/13/digital-currency-exchange-gatecoin-offline-after-loss-of-funds>
- Colon, F., Kim, C., Kim, H. i Kim, W. (2021). The effect of political and economic uncertainty on the cryptocurrency market. *Finance Research Letters*, 39(C). <https://doi.org/10.1016/j.frl.2020.101621>
- Cootner, P. H. (1962). Stock Prices: Random vs. Systematic Changes. *Industrial Management Review*, 3(2), 24–45. Pobrane z <http://www.e-m-h.org/Coot62.pdf>
- Corbet, S., Larkin, C., Lucey, B. M., Meegan, A. i Yarovaya, L. (2020b). The impact of macroeconomic news on Bitcoin returns. *The European Journal of Finance*, 26(14), 1396-1416. <https://doi.org/10.1080/1351847X.2020.1737168>
- Corbet, S., Hou, Y. G., Hu, Y., Larkin, C. i Oxley, L. (2020a). Any port in a storm: Cryptocurrency safe-havens during the COVID-19 pandemic. *Economics Letters*, 194, 109377. <https://doi.org/10.1016/j.econlet.2020.109377>.
- Cowles, A. i Jones, H.E. (1937). Some A Posteriori Probabilities in Stock Market Action. *Econometrica*, 5(3), 280–294. <https://doi.org/10.2307/1905515>
- Czekaj, J., Woś, M., Żarnowski, J. (2001). *Efektywność giełdowego rynku akcji w Polsce. Z perspektywy dziesięciolecia*. Warszawa: Wydawnictwo Naukowe PWN.
- Cziraki, P., Lyandres, E. i Michaely, R. (2021). What do insiders know? Evidence from insider trading around share repurchases and SEOs. *Journal of Corporate Finance*, 66. <https://doi.org/10.1016/j.jcorpfin.2019.101544>
- Da, Z., Engelberg, J. i Gao, P. (2011), In Search of Attention. *The Journal of Finance*, 66, 1461-1499. <https://doi.org/10.1111/j.1540-6261.2011.01679.x>
- Da, Z., Engelberg, J. i Gao, P. (2015). The sum of all fears investor sentiment and asset prices. *Review of Financial Studies*, 28(1), 1-32. <https://doi.org/10.1093/rfs/hhu072>
- Dale, C. i Workman, R. (1980). The Arc Sine Law and the Treasury Bill Futures Market. *Financial Analysts Journal*, 36(6), 71–74. Pobrane z <http://www.jstor.org/stable/4478403>

- Daniel, K., Hirshleifer, D. i Subrahmanyam, A. (1998). Investor Psychology and Security Market Under- and Overreactions. *The Journal of Finance*, 53, 1839-1885. <https://doi.org/10.1111/0022-1082.00077>
- Das, S., Ahmed, S. S. i Pachoni, P. (2022). Behavioral finance in cryptocurrency market: an integrated and empirical investigation. *Central European Management Journal*, 30(3), ISSN: 2336-2693. Pobrane z https://journals.kozminski.cemj.com/index.php/pl_cemj/pdf/Dr.%20Sanjib%20Das.pdf
- Dash, C.S., Behera, A.K., Dehuri, S. i Ghosh, A. (2023). An outliers detection and elimination framework in classification task of data mining. *Decision Analytics Journal*, 6. <https://doi.org/10.1016/j.dajour.2023.100164>
- De Bondt, W. F. M. i Thaler, R. (1985). Does the Stock Market Overreact? *The Journal of Finance*, 40(3), 793–805. <https://doi.org/10.2307/2327804>
- Demir, E., Gozgor, G., Lau, M. C. K. i Vigne, S. (2018). Does economic policy uncertainty predict the Bitcoin returns? An empirical investigation. *Finance Research Letters*. <https://doi.org/10.1016/j.frl.2018.01.005>
- Demir, E., Bilgin, M.H., Karabulut, G. i Doker, A. C. (2020). The relationship between cryptocurrencies and COVID-19 pandemic. *Eurasian Economic Review*, 10, 349–360. <https://doi.org/10.1007/s40822-020-00154-1>
- Dickason, Z. i Ferreira, S. (2018). Establishing a link between risk tolerance, investor personality and behavioural finance in South Africa. *Cogent Economics & Finance*, 6(1), 1519898. <https://doi.org/10.1080/23322039.2018.1519898>
- Dickey, D. A. i Fuller, W. A. (1981). Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica*, 49(4), 1057–1072. <https://doi.org/10.2307/1912517>
- Dimson, E. i Marsh, P. (1984). An Analysis of Brokers' and Analysts' Unpublished Forecasts of UK Stock Returns. *The Journal of Finance*, 39: 1257-1292. <https://doi.org/10.1111/j.1540-6261.1984.tb04907.x>
- Ding, L., Luo, Y., Lin, Y. i Huang, Y. (2021). Revisiting the relations between Hurst exponent and fractional differencing parameter for long memory. *Physica A: Statistical Mechanics and its Applications*, 566. <https://doi.org/10.1016/j.physa.2020.125603>
- Dinz-Maganini, N., Rasheed, A. A. i Sheng, H. H. (2023). Price efficiency of the foreign exchange rates of BRICS countries: A comparative analysis. *Latin American Journal of Central Banking*, 4(1). <https://doi.org/10.1016/j.latcb.2022.100081>

- Duan, K., Li, Z., Urquhart, A. i Ye, J. (2021). Dynamic efficiency and arbitrage potential in Bitcoin: A long-memory approach. *International Review of Financial Analysis*, 75. <https://doi.org/10.1016/j.irfa.2021.101725>
- Dwyer, G. P. (2015). The economics of Bitcoin and similar private digital currencies. *Journal of Financial Stability*, 17, 81-91. <https://doi.org/10.1016/j.jfs.2014.11.006>
- Eksi, Z. i Schreidl, D. (2022). Closing a Bitcoin Trade Optimally under Partial Information: Performance Assessment of a Stochastic Disorder Model. *Mathematics*, 10, 157. <https://doi.org/10.3390/math10010157>
- Elton, E. J., Gruber, M. J. i Grossman, S. (1986). Discrete Expectational Data and Portfolio Performance. *The Journal of Finance*, 41, 699-713. <https://doi.org/10.1111/j.1540-6261.1986.tb04534.x>
- Eom, C., Kaizoji, T., Kang, S. H. i Pichl, L. (2019). Bitcoin and investor sentiment: Statistical characteristics and predictability. *Physica A: Statistical Mechanics and its Applications*, 514, 511-521. <https://doi.org/10.1016/j.physa.2018.09.063>
- Fama, E. F. (1965a). Random Walks in Stock Market Prices. *Financial Analysts Journal*, 21(5), 55–59. Pobrane z <http://www.jstor.org/stable/4469865>
- Fama, E. F. (1965b). The Behavior of Stock-Market Prices. *The Journal of Business*, 38(1), 34-105. Pobrane z <http://www.jstor.org/stable/2350752>
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
- Fama, E. F. i Blume, M. E. (1966). Filter Rules and Stock-Market Trading. *The Journal of Business*, 39(1), 226–241. <http://www.jstor.org/stable/2351744>
- Fama, E. F., Fisher, L., Jensen, M. C. i Roll, R. (1969). The Adjustment of Stock Prices to New Information. *International Economic Review*, 10(1), 1–21. <https://doi.org/10.2307/2525569>
- Fama, E. F. i French, K. R. (1992). The Cross-Section of Expected Stock Returns. *The Journal of Finance*, 47, 427-465. <https://doi.org/10.1111/j.1540-6261.1992.tb04398.x>
- Fang, J., Zhang, X., Tong, Y., Xia, Y., Liu, H. i Wu, K. (2021). Baidu Index and COVID-19 Epidemic Forecast: Evidence From China. *Front Public Health*, 5(9), 685141. <https://doi.org/10.3389/fpubh.2021.685141>

- Fernandes, L. H. S., Bouri, E., Silva, J. W.L., Bejan L. i de Araujo, F. H. A. (2022). The resilience of cryptocurrency market efficiency to COVID-19 shock. *Physica A: Statistical Mechanics and its Applications*, 607. <https://doi.org/10.1016/j.physa.2022.128218>
- Festinger, L. (1962). Cognitive Dissonance. *Scientific American*, 207(4), 93–106. Pobrane z <http://www.jstor.org/stable/24936719>
- Finucane, M. L., Alhakami, A., Slovic, P. i Johnson, S. M. (2000). The affect heuristic in judgments of risks and benefits. *Journal of Behavioral Decision Making*, 13, 1-17. [https://doi.org/10.1002/\(SICI\)1099-0771\(200001/03\)13:1<1::AID-BDM333>3.0.CO;2-S](https://doi.org/10.1002/(SICI)1099-0771(200001/03)13:1<1::AID-BDM333>3.0.CO;2-S)
- Fisher, K. L. i Statman, M. (2000). Investor Sentiment and Stock Returns. *Financial Analysts Journal*, 56(2), 16–23. Pobrane z <http://www.jstor.org/stable/4480229>
- Foley, S., Frijns, B., Garel, A. i Roh, T-Y. (2022). Who buys Bitcoin? The cultural determinants of Bitcoin activity. *International Review of Financial Analysis*, 84, 1-15. <https://doi.org/10.1016/j.irfa.2022.102385>
- Fonseca, V., Pacheco, L. i Lobão, J. (2020). Psychological barriers in the cryptocurrency market. *Review of Behavioral Finance*, 12(2), 151-169. <https://doi.org/10.1108/RBF-03-2019-0041>
- French, K. R. (1980). Stock Returns and the Weekend Effect. *Journal of Financial Economics*, 8(1), 55-69. [https://doi.org/10.1016/0304-405X\(80\)90021-5](https://doi.org/10.1016/0304-405X(80)90021-5)
- French, K. R. i Poterba, J. M. (1991). *Investor Diversification and International Equity Markets*. (NBER Working Paper No. 3609). Pobrane z <https://ssrn.com/abstract=471553>
- Ganzach, Y. (2000). Judging risk and return of financial assets. *Organizational Behavior and Human Decision Processes*, 83(2), 353–370. <https://doi.org/10.1006/obhd.2000.2914>
- Gao, Z., Ren, H. i Zhang, B. (2020). Googling Investor Sentiment around the World. *Journal of Financial and Quantitative Analysis*, 55(2), 549–580. [doi:10.1017/S0022109019000061](https://doi.org/10.1017/S0022109019000061)
- Garcia, D., Tessone, C. J., Mavrodiev, P. i Perony, N. (2014). The digital traces of bubbles: feedback cycles between socioeconomic signals in the Bitcoin economy. *Journal of the Royal Society Interface*, 11(99). <http://dx.doi.org/10.1098/rsif.2014.0623>
- George, T. J. i Hwang, C.-Y. (2004). The 52-Week High And Momentum Investing. *The Journal of Finance*, 59, 2145-2176. <https://doi.org/10.1111/j.1540-6261.2004.00695.x>

- Geweke, J. i Porter-Hudak, S. (1983). The estimation and application of long memory time series models. *Journal of Time Series Analysis*, 4, 221-238. <https://doi.org/10.1111/j.1467-9892.1983.tb00371.x>
- Giudici P. (2003). *Applied Data Mining: Statistical Methods for Business and Industry*. New York: John Wiley & Sons.
- Gloudeman, L. (2014). *Bitcoin's uncertain future in China* (USCC Economic Issue Brief No. 4). U.S.-China Economic and Security Review Commission. <https://www.uscc.gov/sites/default/files/Research/USCC%20Economic%20Issue%20Brief%20-%20Bitcoin%20-%2005%2012%2014.pdf>
- Google Trends. (2024). <https://trends.google.pl/>
- Granger, C. W. J. i Joyeux, R. (1980). An introduction to long-memory time series models and fractional differencing. *Journal of Time Series Analysis*, 1(1), 15-29. <https://doi.org/10.1111/j.1467-9892.1980.tb00297.x>
- Grau-Carles, P. (2000). Empirical evidence of long-range correlations in stock returns. *Physica A*, 287, 396–404. [https://doi.org/10.1016/S0378-4371\(00\)00378-2](https://doi.org/10.1016/S0378-4371(00)00378-2)
- Grech, D. i Mazur, Z. (2004). Can one make any crash prediction in finance using the local Hurst exponent idea?. *Physica A*, 336, 133-145. <https://doi.org/10.1016/j.physa.2004.01.018>
- Griffin, D. i Tversky, A. (1992). The weighing of evidence and the determinants of confidence. *Cognitive Psychology*, 24(3), 411-435. [https://doi.org/10.1016/0010-0285\(92\)90013-R](https://doi.org/10.1016/0010-0285(92)90013-R)
- Griffin, J.M., Kelly, P.J. i Nardari, F. (2010). Do Market Efficiency Measures Yield Correct Inferences? A Comparison of Developed and Emerging Markets. *The Review of Financial Studies*, 23(8), 3225–3277. <https://doi.org/10.1093/rfs/hhq044>
- Grinblatt, M. i Keloharju, M. (2001). How Distance, Language, and Culture Influence Stockholdings and Trades. *The Journal of Finance*, 56, 1053-1073. <https://doi.org/10.1111/0022-1082.00355>
- Grossman, S. J. i Stiglitz, J. E. (1980). On the Impossibility of Informationally Efficient Markets. *The American Economic Review*, 70(3), 393–408. Pobrane z <http://www.jstor.org/stable/1805228>
- Gruszczyński, M. (2013). Ekonometria w rachunkowości. *Studia i Prace Kolegium Zarządzania i Finansów*, 161-177.

- Gruszczyński, M., Kuszewski, T. i Podgórska, M. (2009). *Ekonometria i badania operacyjne*. Warszawa: Wydawnictwo Naukowe PWN, 497 s. ISBN 978-83-01-15784-5
- Górecki, B. R. (2013). *Ekonometria. Podstawy teorii i praktyki*. Red. Wydawnictwo Key Text. ISBN 978-83-87251-13-0
- Guégan, D. i Renault, T. (2021). Does investor sentiment on social media provide robust information for Bitcoin returns predictability? *Finance Research Letters*, 38, 101494. doi: 10.1016/j.frl.2020.101494
- Gulich, D. i Zunino, L. (2014). A criterion for the determination of optimal scaling ranges in DFA and MF-DFA. *Physica A: Statistical Mechanics and its Applications*, 397, 17-30. <https://doi.org/10.1016/j.physa.2013.11.029>
- Gurdgiev, C. i O'Loughlin, D. (2020). Herding and anchoring in cryptocurrency markets: Investor reaction to fear and uncertainty. *Journal of Behavioral and Experimental Finance*, 25. <https://doi.org/10.1016/j.jbef.2020.100271>
- Gurgul, H., Kłęk, K. i Syrek, R. (2009). Długookresowe własności kursów walutowych - podwójna długa pamięć. *Managerial Economics*, 5, 63-79. Pobrane z https://bazhum.muzhp.pl/media/texts/managerial-economics/2009-tom-5/managerial_economics-r2009-t5-s63-79.pdf
- Güler, D. (2023). The Impact of Investor Sentiment on Bitcoin Returns and Conditional Volatilities during the Era of Covid-19. *Journal of Behavioral Finance*, 24(3), 276-289. <https://doi.org/10.1080/15427560.2021.1975285>
- Güngör, S., Küçün, N. T. i Erol, K. (2022). Fear of Missing Out Reality in Financial Investments. *International Journal of Business & Management Studies*, 2694-1449, 3(10). <https://doi.org/10.56734/ijbms.v3n10a4>
- Hadi, F. (2017). Impact of Biases on Perceived Market Efficiency: Case of Pakistani Financial Market. *Research Journal of Finance and Accounting*, 8, 1-8. Pobrane z <https://core.ac.uk/download/pdf/234631911.pdf>
- Hafez, H. M. (2021). Investigating the psychological factors that affect Egyptian investors' behaviour and decisions before and after the pandemic. *Journal of Governance & Regulation*, 10(4), 113–129. <https://doi.org/10.22495/jgrv10i4art10>
- Hamrick, J. T., Rouhi, F., Mukherjee, A., Feder, A., Gandal, N., Moore, T. i Vasek, M. (2021). An examination of the cryptocurrency pump-and-dump ecosystem. *Information Processing & Management*, 58(6), 102506. <https://doi.org/10.1016/j.ipm.2021.102506>

- Han, L., Li, Z. i Yin, L. (2018). Investor attention and stock returns: International evidence. *Emerging Markets Finance and Trade*, 54(14), 3168e3188. <https://doi.org/10.1080/1540496X.2017.1413980>
- Harshita, Singh, S. i Yadav, S. S. (2018). Post-earnings-announcement drift anomaly in India: A test of market efficiency. *Theoretical Economics Letters*, 8(14), 3178-3195. <https://doi.org/10.4236/tel.2018.814197>
- Haryanto, S., Subroto, A. i Ulpah, M. (2020). Disposition effect and herding behavior in the cryptocurrency market. *Journal of Industrial and Business Economics*, 47, 115–132. <https://doi.org/10.1007/s40812-019-00130-0>
- Hayes, A. S. (2019). Bitcoin price and its marginal cost of production: support for a fundamental value. *Applied Economics Letters*, 26(7), 554-560. <https://doi.org/10.1080/13504851.2018.1488040>
- Hileman, G. i Rauchs, M. (2017). *Global cryptocurrency benchmarking study*. Cambridge Centre for Alternative Finance. Pobrane z <https://www.jbs.cam.ac.uk/wp-content/uploads/2020/08/2017-04-20-global-cryptocurrency-benchmarking-study.pdf>
- Hincapié-Salazar, J. i Agudelo, D. A. (2020). Is the Disposition Effect in Bonds As Strong As in Stocks? Evidence from an emerging market. *Global Finance Journal*, 46. <https://doi.org/10.1016/j.gfj.2019.100508>
- Hkiri, B., Bejaoui, A., Gharib, C. i Al Nemer H. A. (2021). Revisiting efficiency in MENA stock markets during political shocks: evidence from a multi-step approach. *Heliyon*, 7(9). <https://doi.org/10.1016/j.heliyon.2021.e08028>
- Hosking, J. R. M. (1981). Fractional differencing. *Biometrika*, 68(1), 165–176. <https://doi.org/10.1093/biomet/68.1.165>
- Hu, B., McInish, T., Miller, J. i Zeng, L. (2019). Intraday price behavior of cryptocurrencies. *Finance Research Letters*, 28(C), 337-342. <https://doi.org/10.1016/j.frl.2018.06.002>
- Huang, J., Sialm, C. i Zhang, H. (2011). Risk shifting and mutual fund performance. *Review of Financial Studies*, 24(8), 2575–616. <https://doi.org/10.1093/rfs/hhr001>
- Huang, X., Lin, J. i Wang, P. (2022). Are institutional investors marching into the crypto market? *Economics Letters*, 220. <https://doi.org/10.1016/j.econlet.2022.110856>
- Huberman, G. (2001). Familiarity Breeds Investment. *The Review of Financial Studies*, 14 (3), 659–680. <https://doi.org/10.1093/rfs/14.3.659>

- Hull, M. i McGroarty, F. (2014). Do emerging markets become more efficient as they develop? Long memory persistence in equity indices. *Emerging Markets Review*, 18, 45-61. <https://doi.org/10.1016/j.ememar.2013.11.001>
- Hung, M., Li, X. i Wang, S. (2015). Post-Earnings-Announcement Drift in Global Markets: Evidence from an Information Shock. *The Review of Financial Studies*, 28(4), 1242–1283. <https://doi.org/10.1093/rfs/hhu092>
- Hurst, H.E. (1951). Long-term storage capacity of reservoirs. *Transactions of the American Society of Civil Engineers*, 116, 770. <https://doi.org/10.1061/TACEAT.0006518>
- Huynh, T. L. D. (2021). Does Bitcoin React to Trump’s Tweets?. *Journal of Behavioral and Experimental Finance*, 31(C). <https://doi.org/10.1016/j.jbef.2021.100546>
- Huynh, T. L. D. (2022). When Elon Musk Changes his Tone, Does Bitcoin Adjust Its Tune?. *Computational Economics*. <https://doi.org/10.1007/s10614-021-10230-6>
- Ito, M. i Sugiyama, S. (2009). Measuring the degree of time varying market inefficiency. *Economics Letters*, 103(1), 62-64. <https://doi.org/10.1016/j.econlet.2009.01.028>
- Ito, M., Noda, A. i Wada, T. (2016). The evolution of stock market efficiency in the US: a non-Bayesian time-varying model approach. *Applied Economics*, 48(7), 621-635. <https://doi.org/10.1080/00036846.2015.1083532>
- Jaffe, J. F. (1974). Special Information and Insider Trading. *The Journal of Business*, 47(3), 410–428. Pobrane z <http://www.jstor.org/stable/2352458>
- Jahanshahloo, H., Irresberger, F. i Urquhart, A. (2023). Bitcoin under the microscope. *The British Accounting Review*. <https://doi.org/10.1016/j.bar.2023.101237>
- Jalal, R.N.U.D., Sargiacomo, M., Sahar, N.U. i Fayyaz, U.-E.-R. (2020). Herding Behavior and Cryptocurrency: Market Asymmetries, Inter-Dependency and Intra-Dependency. *The Journal of Asian Finance, Economics and Business*, 7, 27–34. <https://doi.org/10.13106/jafeb.2020.vol7.no7.027>
- Jalal, R.N.U.D. i Leonelli, S. (2021). Does Self-attribution Impact on Investor Perception About Cryptocurrency Market Efficiency? The Mediating Role of Overconfidence. W: Ceci, F., Prencipe, A., Spagnoletti, P. (eds), *Exploring Innovation in a Digital World. Lecture Notes in Information Systems and Organisation*, 51. Springer, Cham. https://doi.org/10.1007/978-3-030-87842-9_11
- James, F. (1968). Monthly Moving Averages—An Effective Investment Tool? *Journal of Financial and Quantitative Analysis*, 3(3), 315-326. <https://doi.org/10.2307/2329816>

- Javed, H., Bagh, T. i Razzaq. S. (2017). Herding Effects, Over Confidence, Availability Bias and Representativeness as Behavioral Determinants of Perceived Investment Performance: An Empirical Evidence from Pakistan Stock Exchange (PSX). *Journal Global Economics*, 6, 275. <https://doi.org/10.4172/23754389.1000275>
- Jegadeesh, N. (1990). Evidence of Predictable Behavior of Security Returns. *The Journal of Finance*, 45(3), 881–898. <https://doi.org/10.2307/2328797>
- Jegadeesh, N. i Titman, S. (1993). Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency. *The Journal of Finance*, 48(1), 65-91. <https://doi.org/10.2307/2328882>
- Jegadeesh, N. i Titman, S. (2001). Profitability of Momentum Strategies: An Evaluation of Alternative Explanations. *Journal of Finance*, 56(2), 699-720. Pobrane z <http://www.jstor.org/stable/222579>
- Jeng, L. A., Metrick, A. i Zeckhauser, R. (2003). Estimating the Returns to Insider Trading: A Performance-Evaluation Perspective. *The Review of Economics and Statistics*, 85(2), 453–471. <http://www.jstor.org/stable/3211592>
- Jensen, M. C. (1968). The Performance of Mutual Funds in the Period 1945-1964. *The Journal of Finance*, 23(2), 389–416. <https://doi.org/10.2307/2325404>
- Jiang, Y., Nie, H. i Ruan, W. (2018). Time-Varying Long-Term Memory in Bitcoin Market. *Finance Research Letters*, 25, 280-284. <https://doi.org/10.1016/j.frl.2017.12.009>
- Kahneman, D. i Tversky, A. (1979). Prospect Theory: An Analysis of Decision under Risk. *Econometrica*, 47(2), 263–291. <https://doi.org/10.2307/1914185>
- Kallinterakis, V. i Wang, Y. (2019). Do investors herd in cryptocurrencies – and why?. *Research in International Business and Finance*, 50, 240–245. <https://doi.org/10.1016/j.ribaf.2019.05.005>
- Kandi, U., Gujjula, S., Buddha, V. i Bhagavan, S. (2021). Visualizing the Financial Impact of Presidential Tweets on Stock Markets. *ArXiv, q-fin.ST*. <https://doi.org/10.48550/arXiv.2101.03205>
- Kantelhardt, J.W., Koscielny-Bunde, E., Rego, H.H., Havlin, S., i Bunde, A. (2001). Detecting long-range correlations with detrended fluctuation analysis. *Physica A-statistical Mechanics and Its Applications*, 295, 441-454. [https://doi.org/10.1016/S0378-4371\(01\)00144-3](https://doi.org/10.1016/S0378-4371(01)00144-3)

- Kantelhardt, J. W., Zschiegner, S. A., Koscielny-Bunde, E., Havlin, S., Bunde, A. i Stanley, H. E. (2002). Multifractal detrended fluctuation analysis of nonstationary time series. *Physica A-statistical Mechanics and Its Applications*, 316, 87–114. [https://doi.org/10.1016/s0378-4371\(02\)01383-3](https://doi.org/10.1016/s0378-4371(02)01383-3)
- Karalevicius, V., Degrande, N. i De Weerd, J. (2018). Using sentiment analysis to predict interday Bitcoin price movements. *Journal of Risk Finance*, 19(1), 56-75. <https://doi.org/10.1108/JRF-06-2017-0092>
- Keim, D. B. (1983). Size-Related Anomalies and Stock Return Seasonality: Further Empirical Evidence. *Journal of Financial Economics*, 12(1), 13-32. [https://doi.org/10.1016/0304-405X\(83\)90025-9](https://doi.org/10.1016/0304-405X(83)90025-9)
- Kellner, T. (2024). The impact of M&A announcements on stock returns in the European Union. *International Review of Economics & Finance*, 89, 843–862. <https://doi.org/10.1016/j.iref.2023.10.034>
- Kemp, A. G. i Reid, G. C. (1971). The Random Walk Hypothesis and the Recent Behaviour of Equity Prices in Britain. *Economica*, 38(149), 28–51. <https://doi.org/10.2307/2551749>
- Kendall, M. G. i Hill, A. B. (1953). The Analysis of Economic Time-Series-Part I: Prices. *Journal of the Royal Statistical Society. Series A*, 116(1), 11–34. <https://doi.org/10.2307/2980947>
- Khorana, A., Chang, E. C. i Cheng, J.W. (2000). An Examination of Herd Behavior in Equity Markets: An International Perspective. *Journal of Banking & Finance*, 24(10), 1651-1679. [https://doi.org/10.1016/S0378-4266\(99\)00096-5](https://doi.org/10.1016/S0378-4266(99)00096-5)
- Khuntia, S. i Pattanayak, J. (2018). Adaptive market hypothesis and evolving predictability of Bitcoin. *Economics Letters*, 167, 26-28. <https://doi.org/10.1016/j.econlet.2018.03.005>
- Khuntia, S. i Pattanayak, J. (2020). Adaptive Long Memory in Volatility of Intra-day Bitcoin Returns and the Impact of Trading Volume. *Finance Research Letters*, 32, 101077. <https://doi.org/10.1016/j.frl.2018.12.025>
- Kian-Ping, L., Weiwei, L. i Jae, H. K. (2013) Are US stock index returns predictable? Evidence from automatic autocorrelation-based tests. *Applied Economics*, 45(8), 953-962. <https://doi.org/10.1080/00036846.2011.613782>
- Kim, J. H. (2009). Automatic variance ratio test under conditional heteroskedasticity. *Finance Research Letters*, 6(3), 179–185. <https://doi.org/10.1016/j.frl.2009.04.003>

- Kim, J. H., Shamsuddin, A. i Kian-Ping, L. (2011). Stock return predictability and the adaptive markets hypothesis: Evidence from century-long U.S. data. *Journal of Empirical Finance*, 18(5), 868-879. <https://doi.org/10.1016/j.jempfin.2011.08.002>
- Kim, H. J., Hong, J. S., Hwang, H. C., Kim, S. M., i Han, D. H. (2020). Comparison of Psychological Status and Investment Style Between Bitcoin Investors and Share Investors. *Frontiers in Psychology*, 11, 502295. <https://doi.org/10.3389/fpsyg.2020.502295>
- Kinyua, J. D., Mutigwe, C., Cushing, D. J. i Poggi, M. (2021). An analysis of the impact of President Trump's tweets on the DJIA and S&P 500 using machine learning and sentiment analysis. *Journal of Behavioral and Experimental Finance*, 29(C). <https://doi.org/10.1016/j.jbef.2020.100447>
- Kołatka, M. (2020). Testing the Adaptive Market Hypothesis on the WIG Stock Index: 1994-2019. *Research Papers of Wrocław University of Economics*, 1(64), 131-142. <http://dx.doi.org/10.15611/pn.2020.1.11>
- Köchling, G., Müller, J. i Posch, P. N. (2019a). Does the introduction of futures improve the efficiency of Bitcoin? *Finance Research Letters*, 30(C), 367-370. <https://doi.org/10.1016/j.frl.2018.11.006>
- Köchling, G., Müller, J. i Posch, P. N. (2019b). Price delay and market frictions in cryptocurrency markets. *Economics Letters*, 174(C), 39-41. <https://doi.org/10.1016/j.econlet.2018.10.025>
- Kraaijeveld, O. i Smedt, J. D. (2020). The predictive power of public Twitter sentiment for forecasting cryptocurrency prices. *Journal of International Financial Markets, Institutions and Money*, 65. <https://doi.org/10.1016/j.intfin.2020.101188>
- Kraus, A. i Stoll, H.R. (1972). Price Impacts Of Block Trading On The New York Stock Exchange. *The Journal of Finance*, 27, 569-588. <https://doi.org/10.1111/j.1540-6261.1972.tb00985.x>
- Kristoufek, L. (2010). Rescaled Range Analysis and Detrended Fluctuation Analysis: Finite Sample Properties and Confidence Intervals. *Czech Economic Review*, Charles University Prague, Faculty of Social Sciences, Institute of Economic Studies, 4(3), 315–329. Pobrane z https://www.researchgate.net/profile/LadislavKristoufek/publication/227360892_Rescaled_Range_Analysis_and_Detrended_Fluctuation_Analysis_Finite_Sample_Propertie

s_and_Confidence_Intervals/links/0fcfd50ddb6e3bdcf5000000/Rescaled-Range-Analysis-and-Detrended-Fluctuation-Analysis-Finite-Sample-Properties-and-Confidence-Intervals.pdf

- Kristoufek, L. (2013). BitCoin meets Google Trends and Wikipedia: Quantifying the relationship between phenomena of the Internet era. *Scientific Reports*, 3, 3415. <https://doi.org/10.1038/srep03415>
- Kristoufek, L. i M. Vosvrda (2013). Measuring capital market efficiency: Global and local correlations structure. *Physica A*, 392, 184–193. <https://doi.org/10.1016/j.physa.2012.08.003>
- Kristoufek, L. (2018). On Bitcoin markets (in)efficiency and its evolution. *Physica A: Statistical Mechanics and Its Applications*, 503, 257-262. <https://doi.org/10.1016/j.physa.2018.02.161>
- Kumar, R. i Makhija, A. K. (1986). Volatility of Stock Prices and Market Efficiency. *Managerial and Decision Economics*, 7(2), 119–122. Pobrane z <http://www.jstor.org/stable/2487167>
- Kurt Gümüş, G., Gümüş, Y. i Çimen, A. (2019). Herding Behaviour in Cryptocurrency Market: CSSD and CSAD Analysis. W: Hacıoglu, U. (red.), *Blockchain Economics and Financial Market Innovation: Financial Innovations in the Digital Age, Contributions to Economics*. Springer International Publishing, Cham, 103–114. doi: 10.1007/978-3-030-25275-5_6
- Lakonishok, J., Shleifer, A. i Vishny, R.W. (1992). The Impact of Institutional Trading on Stock Prices. *Journal of Financial Economics*, 32, 23-43. [https://doi.org/10.1016/0304-405X\(92\)90023-Q](https://doi.org/10.1016/0304-405X(92)90023-Q)
- Lakonishok, J., Shleifer, A. i Vishny, R. W. (1994). Contrarian Investment, Extrapolation, and Risk. *The Journal of Finance*, 49, 1541-1578. <https://doi.org/10.1111/j.1540-6261.1994.tb04772.x>
- Lakonishok, J. i Lee, I. (2001). Are insider trades informative? *The Review of Financial Studies*, 14(1), 79–111. <https://doi.org/10.1093/rfs/14.1.79>
- Lee, C. I., Gleason, K. C. i Mathur, I. (2000). Efficiency tests in the French derivatives market. *Journal of Banking & Finance*, 24(5), 787–807. [https://doi.org/10.1016/S0378-4266\(99\)00067-9](https://doi.org/10.1016/S0378-4266(99)00067-9)

- Lee, A. D., Li, M. i Zheng, H. (2020). Bitcoin: Speculative asset or innovative technology?. *Journal of International Financial Markets, Institutions & Money*, 67, 101209. <https://doi.org/10.1016/j.intfin.2020.101209>
- Lehmann, B. N. (1990). Fads, Martingales, and Market Efficiency. *The Quarterly Journal of Economics*, 105, 1-28. <https://doi.org/10.2307/2937816>
- Lennart, A. (2023). How Elon Musk's Twitter activity moves cryptocurrency markets. *Technological Forecasting and Social Change*, 186(PA). <https://doi.org/10.1016/j.techfore.2022.122112>
- Li, J. i Yu, J. (2012). Investor attention, psychological anchors, and stock return predictability. *Journal of Financial Economics*, 104(2), 401-419. <https://doi.org/10.1016/j.jfineco.2011.04.003>
- Li, X. i Wang, C. (2017). The Technology and Economic Determinants of Cryptocurrency Exchange Rates: The Case of Bitcoin. *Decision Support Systems*, 95, 49-60. <https://doi.org/10.1016/j.dss.2016.12.001>
- Li, X., Li, S. i Xu, C. (2020). Price clustering in Bitcoin market—An extension. *Finance Research Letters*, 32(C). <https://doi.org/10.1016/j.frl.2018.12.020>
- Li, Y., Goodell, J. W. i Shen, D. (2021). Comparing search-engine and social-media attentions in finance research: Evidence from cryptocurrencies. *International Review of Economics & Finance*, 75(C), 723-746. <https://doi.org/10.1016/j.iref.2021.05.003>
- Lim, K.-P. (2007). Ranking market efficiency for stock markets: A nonlinear perspective. *Physica A*, 376, 445-454. <https://doi.org/10.1016/j.physa.2006.10.013>
- Lim, K.-P. i Brooks, R. (2011). The evolution of stock market efficiency over time: a survey of the empirical literature. *Journal of Economic Surveys*, 25, 69-108. <https://doi.org/10.1111/j.1467-6419.2009.00611.x>
- Lin, W. T., Tsai, S.-C. i Lung, P.-Y. (2013). Investors' Herd Behavior: Rational or Irrational?. *Asia-Pacific Journal of Financial Studies*, 42, 755-776. <https://doi.org/10.1111/ajfs.12030>
- Liu, C. i Wang, H. (2019). Initial Coin Offerings: What Do We Know and What Are the Success Factors? W: Goutte, S., Guesmi, K., Saadi, S. (red.), *Cryptofinance and Mechanisms of Exchange*. Contributions to Management Science. Springer, Cham. https://doi.org/10.1007/978-3-030-30738-7_9

- Liu, Y. i Tsyvinski, A. (2021). Risks and Returns of Cryptocurrency. *The Review of Financial Studies*, 34(6), 2689–2727. <https://doi.org/10.1093/rfs/hhaa113>
- Lo, A. W. i Mackinlay, A. C. (1988). Stock Market Prices Do Not Follow Random Walks: Evidence from a Simple Specification Test. *The Review of Financial Studies*, 1, 41-66. <https://doi.org/10.1093/rfs/1.1.41>
- Lo, A. W. (2004). The Adaptive Markets Hypothesis: Market Efficiency from an Evolutionary Perspective. *The Journal of Portfolio Management*, 30 (5), 15-29. https://www.researchgate.net/publication/228183756_The_Adaptive_Markets_Hypothesis_Market_Efficiency_from_an_Evolutionary_Perspective
- Loughran, T. i McDonald, B. (2011). When is a Liability Not a Liability? Textual Analysis, Dictionaries, and 10-Ks. *The Journal of Finance*, 66(1), 35–65. <https://doi.org/10.1111/j.1540-6261.2010.01625.x>.
- Lowies, G. A., Hall, J. H. i Cloete, C. E. (2014). The evolution of property investment decision-making: the influence of behavioural approaches. *Journal of Construction*, 6(2), 18-39. Pobrane z <https://hdl.handle.net/11541.2/141115>
- López-Cabarcos, M. A., Pérez-Pico, A. M., Piñeiro-Chousa, J. i Šević, A. (2021). Bitcoin volatility, stock market and investor sentiment. Are they connected?. *Finance Research Letters*, 38. <https://doi.org/10.1016/j.frl.2019.101399>
- Łęt, B., Sobański, K., Świder, W. i Włosik, K. (2023). Investor sentiment and efficiency of the cryptocurrency market: The case of the Crypto Fear & Greed Index. W: M. H. Bilgin, H. Danis, E. Demir, L. Wincenciak, & S. T. Er (red.), *Eurasian Business and Economics Perspectives: Proceedings of the 38th Eurasia Business and Economics Society Conference* (Vol. 25, pp. 271–287). https://doi.org/10.1007/978-3-031-36286-6_16
- Maddala, G. S. (2008). *Ekonometria*. Warszawa: Wydawnictwo Naukowe PWN, współautorzy przekładu z j. angielskiego: M. Gruszczyński, E. Tomczyk, B. Witkowski.
- Malkiel, B. G. (2005). Reflections on the Efficient Market Hypothesis: 30 Years Later. *Financial Review*, 40, 1-9. <https://doi.org/10.1111/j.0732-8516.2005.00090.x>
- Manahov, V. (2024). The great crypto crash in September 2018: why did the cryptocurrency market collapse?. *Annals of Operations Resesearch*, 332, 579–616. <https://doi.org/10.1007/s10479-023-05575-0>

- Mandelbrot, B. i J. van Ness. (1968). Fractional Brownian Motions, Fractional Noises and Applications. *Society for Industrial and Applied Mathematics Journal*, 10(4), 422-437. <https://doi.org/10.1137/1010093>
- Marley, R. (2020, 2 stycznia). Initial Exchange Offerings (IEOs) – A Detailed Insight [wpis na blogu]. Pobrane z <https://shuftipro.com/blog/initial-exchange-offerings-ieos-a-detailed-insight/>
- Matta, M., Lunesu, I. i Marchesi, M. (2015). The predictor impact of Web search media on Bitcoin trading volumes. W: *7th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management (IC3K)*, Lisbon, Portugal, 620-626. <https://doi.org/10.5220/0005618606200626>
- Mbanga, C. L. (2019). The day-of-the-week pattern of price clustering in Bitcoin. *Applied Economics Letters*, 26(10), 807-811. <https://doi.org/10.1080/13504851.2018.1497844>
- Mensi, W., Sensoy, A., Vo, X. V. i Kang, S. H. (2022). Pricing efficiency and asymmetric multifractality of major asset classes before and during COVID-19 crisis. *The North American Journal of Economics and Finance*, 62(C). <https://doi.org/10.1016/j.najef.2022.101773>
- Metta, S., Madhavan, N. i Krishnamoorthy, N. (2022). Power of 280: Measuring the Impact of Elon Musk's Tweets on the Stock Market. *Ushus-Journal of Business Management*, 21(1), 17-43. <https://doi:10.12725/ujbm.58.2>
- Meynkhard, A. (2019). Fair market value of bitcoin: halving effect. *Investment Management and Financial Innovations*, 16(4), 72-85. [http://dx.doi.org/10.21511/imfi.16\(4\).2019.07](http://dx.doi.org/10.21511/imfi.16(4).2019.07)
- Mizerka, J., Stróżyńska-Szajek, A. i Mizerka, P. (2020). The role of Bitcoin on developed and emerging markets - on the basis of a Bitcoin users graph analysis. *Finance Research Letters*, 35. <https://doi.org/10.1016/j.frl.2020.101489>
- Mokni, K., El Montasser, G., Ajmi, A. N. i Bouri, E. (2024). On the efficiency and its drivers in the cryptocurrency market: the case of Bitcoin and Ethereum. *Financial Innovation*, 10, 39. <https://doi.org/10.1186/s40854-023-00566-3>
- Momtaaz, P. P. (2020). Initial Coin Offerings. *PLOS ONE*, 15(5), 1-30. <https://doi.org/10.1371/journal.pone.0233018>
- Money. (2016). *Rok 2016 rozpoczął się od krachu*. Pobrane 20 października 2025 z <https://www.money.pl/pieniadze/komentarze/artykul/rok-2016-rozpoznal-sie-od-krachu,80,0,1991248.html>

- Mushinada, V. N. C. (2020). Are individual investors irrational or adaptive to market dynamics? *Journal of Behavioral and Experimental Finance*, 25. <https://doi.org/10.1016/j.jbef.2019.100243>
- Nadarajah, S. i Chu, J. (2017). On the inefficiency of Bitcoin. *Economics Letters*, 150, 6–9. <https://doi.org/10.1016/j.econlet.2016.10.033>
- Naeem, M. A., Mbarki, I. i Shahzad, S. J. H. (2021). Predictive role of online investor sentiment for cryptocurrency market: Evidence from happiness and fears. *International Review of Economics & Finance*, 73(C), 496-514. <https://doi.org/10.1016/j.iref.2021.01.008>
- Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. Pobrane 30 grudnia 2022 z bitcoin.org/bitcoin.pdf
- Narayanan, A., Bonneau, J., Felten, E., Miller, A. i Goldfeder, S. (2016). *Bitcoin and Cryptocurrency Technologies: A Comprehensive Introduction*. Princeton University Press. ISBN: 9780691171692
- Newey, W. K. i West, K. D. (1987). A Simple, Positive Semi-Definite, Heteroskedasticity and Autocorrelation Consistent Covariance Matrix. *Econometrica*, 55(3), 703–708. <https://doi.org/10.2307/1913610>
- Nęcka, E., Orzechowski, J. i Szymura, B. (2006). *Psychologia poznawcza*. Warszawa: Wydawnictwo Naukowe PWN-Academica Wydawnictwo SWPS.
- Nickerson, R. S. (1998). Confirmation bias: A ubiquitous phenomenon in many guises. *Review of General Psychology*, 2(2), 175–220. <https://doi.org/10.1037/1089-2680.2.2.175>
- Niederhoffer, V. i Osborne, M. F. M. (1966). Market Making and Reversal on the Stock Exchange. *Journal of the American Statistical Association*, 61(316), 897-916. <https://doi.org/10.2307/2283188>
- Noda, A. (2016). A test of the adaptive market hypothesis using a time-varying AR model in Japan. *Finance Research Letters*, 17, 66-71. <https://doi.org/10.1016/j.frl.2016.01.004>
- Noda, A. (2021). On the evolution of cryptocurrency market efficiency. *Applied Economics Letters*, 28, 6, 433-439. <https://doi.org/10.1080/13504851.2020.1758617>
- Nofsinger, J. R. i Varma, A. (2013). Availability, recency, and sophistication in the repurchasing behavior of retail investors. *Journal of Banking & Finance*, 37(7), 2572-2585. <https://doi.org/10.1016/j.jbankfin.2013.02.023>

- Nurbarani, B. S. i Soepriyanto, G. (2022). Determinants of Investment Decision in Cryptocurrency: Evidence from Indonesian Investors. *Universal Journal of Accounting and Finance*, 10(1), 254-266. <https://doi.org/10.13189/ujaf.2022.100126>
- OECD. (2023). *Consumer confidence index (CCI)* (indicator). <https://doi.org/10.1787/46434d78-en>
- Okorie, D. I. i Lin, B. (2021). Adaptive market hypothesis: The story of the stock markets and COVID-19 pandemic. *The North American Journal of Economics and Finance*, 57. <https://doi.org/10.1016/j.najef.2021.101397>
- Omane-Adjepong, M., Alagidede, I. P., Lyimo, A. G. i Tweneboah, G. (2021). Herding behaviour in cryptocurrency and emerging financial markets. *Cogent Economics & Finance*, 9. <https://doi.org/10.1080/23322039.2021.1933681>
- Oprea, D. S. (2014). Does Investor Sentiment Matter in Post-Communist East European Stock Markets? *International Journal of Academic Research in Business and Social Sciences*, 4(8), 356-366. <https://doi.org/10.6007/IJARBS/v4-i8/1104>
- Osborne, M. F. M. (1959). Brownian Motion in the Stock Market. *Operations Research*, 7(2), 145-173. Pobrane z <http://www.jstor.org/stable/167153>
- Osińska, M. (2006). *Ekonometria finansowa*. Warszawa: Polskie Wydawnictwo Ekonomiczne.
- Oswiecimka, S. Drozd, J. Kwapien i A. Górski (2013). Effect of detrending on multifractal characteristics. *Acta Physica Polonica A*, 123(3), 597–603. Pobrane z <http://przyrbwn.icm.edu.pl/APP/ABSTR/123/a123-3-18.html>
- Otto, F., Sampaio, J. O. i Silva, V. A. B. (2020). Domestic and cross-border effect of acquisition announcements: A short-term study for developed and emerging countries. *Finance Research Letters*, 34. <https://doi.org/10.1016/j.frl.2020.101501>
- Panagiotidis, T., Stengos, T. i Vravosinos, O. (2019). The effects of markets, uncertainty and search intensity on bitcoin returns. *International Review of Financial Analysis*, 63(C), 220-242. <https://doi.org/10.1016/j.irfa.2018.11.002>
- Peng, C. K., Havlin, S., Stanley, H. E. i Goldberger, A. L. (1995). Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series. *Chaos* (Woodbury, N.Y.), 5(1), 82–87. <https://doi.org/10.1063/1.166141>

- Perez, K. i Urbaniak, M. (2013). Bitcoin – wirtualny eksperyment czy waluta przyszłości? *Ruch Prawniczy, Ekonomiczny i Socjologiczny*, 75(4), 163–180. <https://doi.org/10.14746/rpeis.2013.75.4.13>
- Peters, E. (1994). *Fractal Market Analysis*. New York: John Wiley & Sons.
- Philippas, D., Rjiba, H., Guesmi, K. i Goutte, S. (2019). Media attention and Bitcoin prices. *Finance Research Letters*, 30(C), 37-43. <https://doi.org/10.1016/j.frl.2019.03.031>
- Pham, R. i Ausloos, M. (2022). Insider trading in the run-up to merger announcements. Before and after the UK's Financial Services Act 2012. *International Journal of Finance & Economics*, 27(4), 2373–3385. <https://doi.org/10.1002/ijfe.2325>
- Phiri, A. (2022). Can wavelets produce a clearer picture of weak-form market efficiency in Bitcoin? *Eurasian Economic Review. Eurasia Business and Economics Society*, 12(3), 373-386. <https://doi.org/10.1007/s40822-022-00214-8>
- Piech, K. (2016). *Leksykon pojęć na temat technologii blockchain i kryptowalut*. Pobrane z https://www.gov.pl/documents/31305/0/leksykon_pojec_na_temat_tehnologii_bloc_kchain_i_kryptowalut.pdf/77392774-1180-79ab-4dd5-089ffab37602
- Plastun, A., Kozmenko, S., Plastun V. i Filatova, H. (2019). Market anomalies and data persistence: The case of the day-of-the-week effect. *Journal of International Studies*, 12(3), 122-130. <https://doi.org/10.14254/2071-8330.2019/12-3/10>
- Polanco-Martínez, J. M. (2019). Dynamic relationship analysis between NAFTA stock markets using nonlinear, nonparametric, non-stationary methods. *Nonlinear Dynamics*, 97, 369–389. <https://doi.org/10.1007/s11071-019-04974-y>
- Polasik, M., Piotrowska, A. I., Wisniewski, T. P., Kotkowski, R. i Lightfoot, G. (2015). Price Fluctuations and the Use of Bitcoin: An Empirical Inquiry. *International Journal of Electronic Commerce*, 20, 9-49. <https://doi.org/10.1080/10864415.2016.1061413>
- Poterba, J. i Summers, L. (1988). Mean reversion in stock prices: Evidence and Implication. *Journal of Financial Economics*, 22, (1), 27-59. [https://doi.org/10.1016/0304-405X\(88\)90021-9](https://doi.org/10.1016/0304-405X(88)90021-9)
- Pouget, S. i Villeneuve, S. (2011). *A Mind is a Terrible Thing to Change: Confirmation Bias in Financial Markets*. National Bureau Of Economic Research, Behavioral Economics Working Group, November 5, 2011. Pobrane z https://users.nber.org/~confer/2011/BEf11/Pouget_Villeneuve.pdf

- Qin, J., Lu, X., Zhou, Y. i Qu, L. (2015). The effectiveness of China's RMB exchange rate reforms: An insight from multifractal detrended fluctuation analysis. *Physica A: Statistical Mechanics and its Applications*. <https://doi.org/10.1016/j.physa.2014.11.053>
- Razali, N. i Wah, Y. (2011). Power Comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. *Journal of Statistical Modeling and Analytics*, 2, 21-33. <https://www.nrc.gov/docs/ml1714/ml17143a100.pdf>
- Ready, M. J. (2002). Profits from Technical Trading Rules. *Financial Management*, 31(3), 43–61. <https://doi.org/10.2307/3666314>
- Rebman, C., Sargent, C., Breese, J. i Booker, Q. (2022). An exploratory study in blockchain knowledge, perceptions, overconfidence, and optimism. *Issues in Information Systems*, 23(4), 243-253. https://doi.org/10.48009/4_iis_2022_121
- Reinganum, M. R. (1981). A Misspecification of Capital Asset Pricing: Empirical Anomalies Based on Earnings Yields and Market Values. *Journal of Financial Economics*, 9, 19-46. [https://doi.org/10.1016/0304-405X\(81\)90019-2](https://doi.org/10.1016/0304-405X(81)90019-2)
- 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*, 12, 89-104. [https://doi.org/10.1016/0304-405X\(83\)90029-6](https://doi.org/10.1016/0304-405X(83)90029-6)
- Ren, B. i Lucey, B. (2022). Do clean and dirty cryptocurrency markets herd differently? *Finance Research Letters*, 47. <https://doi.org/10.1016/j.frl.2022.102795>
- Ren, X., Xiao, Y., Duan, K. i Urquhart, A. (2024). Spillover effects between fossil energy and green markets: Evidence from informational inefficiency. *Energy Economics*, 131. <https://doi.org/10.1016/j.eneco.2024.107317>
- Reuters. (2014). Pobrane z <https://www.reuters.com/article/us-bitcoin-mtgox-bankruptcy-idUSBREA1R0FX20140228>
- Reuters. (2024). Pobrane z <https://www.reuters.com/plus/why-central-banks-buy-gold>
- Ritter, J. R. (2003). Behavioral Finance. *Pacific-Basin Finance Journal*, 11(4), 429-437. [https://doi.org/10.1016/S0927-538X\(03\)00048-9](https://doi.org/10.1016/S0927-538X(03)00048-9)
- Rodriguez, E., Aguilar-Cornejo, M., Femat, R. i Alvarez-Ramirez, J. (2014). US stock market efficiency over weekly, monthly, quarterly and yearly time scales. *Physica A: Statistical Mechanics and its Applications*. 413, 554-564. <https://doi.org/10.1016/j.physa.2014.07.036>

- Rognone, L., Hyde, S. i Zhang, S. S. (2020). News sentiment in the cryptocurrency market: An empirical comparison with Forex. *International Review of Financial Analysis*, 69. <https://doi.org/10.1016/j.irfa.2020.101462>
- Rozeff, M. S. i Kinney Jr, W. R. (1976). Capital market seasonality: the case of stock returns, *Journal of Financial Economics*, 3, 379-402. [https://doi.org/10.1016/0304-405X\(76\)90028-3](https://doi.org/10.1016/0304-405X(76)90028-3)
- Rozeff, M. S. i Zaman, M. A. (1988). Market Efficiency and Insider Trading: New Evidence. *The Journal of Business*, 61(1), 25–44. Pobrane z <http://www.jstor.org/stable/2352978>
- Samuelson, P. (1965). Proof that properly anticipated prices fluctuate randomly. *Industrial Management Review*, 6, 41-9. Pobrane z <https://capital-gain.ru/wp-content/uploads/Proof-that-properly-anticipated-prices-fluctuate-randomly.pdf>
- Samuelson, W. i Zeckhauser, R. (1988). Status quo bias in decision making. *Journal of Risk and Uncertainty*, 1, 7–59. <https://doi.org/10.1007/BF00055564>
- Schabek, T. (2016). *Czynniki behawioralne i fundamentalne a stopy zwrotu z akcji rynków wschodzących. Polska i Brazylia*. Łódź: Wydawnictwo Uniwersytetu Łódzkiego. ISBN 978-83-8088-343-7
- Scharnowski, S. i Shi, Y. (2021). Bitcoin Blackout: Proof-of-Work and the Centralization of Mining. *SSRN Electronic Journal*, 1–2. <https://dx.doi.org/10.2139/ssrn.3936787>
- Schatzmann, J. E. i Haslhofer, B. (2023). Exploring investor behavior in Bitcoin: a study of the disposition effect. *Digital Finance*, 5, 581-612. <https://doi.org/10.1007/s42521-023-00086-w>
- Schmeling, M. (2009). Investor sentiment and stock returns: Some international evidence. *Journal of Empirical Finance*, 16(3), 394-408. <https://doi.org/10.1016/j.jempfin.2009.01.002>
- Scholes, M. S. (1972). The Market for Securities: Substitution Versus Price Pressure and the Effects of Information on Share Prices. *The Journal of Business*, 45(2), 179–211. Pobrane z <http://www.jstor.org/stable/2352030>
- Sensoy, A. (2013). Generalized Hurst exponent approach to efficiency in MENA markets. *Physica A: Statistical Mechanics and its Applications*, 392(20), 5019-5026. <https://doi.org/10.1016/j.physa.2013.06.041>.
- Shah, S. Z. A., Ahmad, M. i Mahmood, F. (2018). Heuristic biases in investment decision-making and perceived market efficiency: A survey at the Pakistan stock exchange.

- Qualitative Research in Financial Markets*, 10(1), 85-110.
<https://doi.org/10.1108/QRFM-04-2017-0033>
- Shahzad, S. J. H., Anas, M. i Bouri, E. (2022). Price explosiveness in cryptocurrencies and Elon Musk's tweets. *Finance Research Letters*, 47, 102695.
<https://doi.org/10.1016/j.frl.2022.102695>.
- Shaikh, I. (2020). Policy uncertainty and Bitcoin returns. *Borsa Istanbul Review*, 20(3), 257-268. <https://doi.org/10.1016/j.bir.2020.02.003>
- Sharpe, W. F. (1966). Mutual Fund Performance. *The Journal of Business*, 39(1), 119–138.
 Pobrane z <http://www.jstor.org/stable/2351741>
- Shefrin, H. M. i Statman, M. (1984). Explaining investor preference for cash dividends. *Journal of Financial Economics*, 1984, 13(2), 253-282. [https://doi.org/10.1016/0304-405X\(84\)90025-4](https://doi.org/10.1016/0304-405X(84)90025-4)
- Shefrin, H. i Statman, M. (1985). The Disposition to Sell Winners Too Early and Ride Losers Too Long: Theory and Evidence. *The Journal of Finance*, 40(3), 777–790.
<https://doi.org/10.2307/2327802>
- Shi, H.-L., Jiang, Z.-Q. i Zhou, W.-X. (2017). Time-varying return predictability in the Chinese stock market. *Reports in Advances of Physical Sciences*, 1.
<https://doi.org/10.1142/S2424942417400023>
- Shiller, R. J. (1981). Do Stock Prices Move Too Much to be Justified by Subsequent Changes in Dividends? *The American Economic Review*, 71(3), 421–436. Pobrane z <http://www.jstor.org/stable/1802789>
- Shiller, R. J. (2003). From Efficient Markets Theory to Behavioral Finance. *The Journal of Economic Perspectives*, 17(1), 83–104. Pobrane z <http://www.jstor.org/stable/3216841>
- Shin, Y., Kwiatkowski, D., Schmidt, P. i Phillips, P. C. B. (1992). Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root: How Sure Are We That Economic Time Series Are Nonstationary? *Journal of Econometrics*, 54(1-3), 159-178.
[https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Shleifer, A. (2000). *Inefficient Markets: An Introduction to Behavioral Finance*. New York: Oxford University Press. <https://doi.org/10.1093/0198292279.001.0001>
- Simon, H. A. (1955). A Behavioral Model of Rational Choice. *The Quarterly Journal of Economics*, 69(1), 99-118. <https://doi.org/10.2307/1884852>

- Smales, L. A. (2022). Investor attention in cryptocurrency markets. *International Review of Financial Analysis*, 79. <https://doi.org/10.1016/j.irfa.2021.101972>
- Smith, G. (2012). The changing and relative efficiency of European emerging stock markets. *The European Journal of Finance*, 18(8), 689-708. <https://doi.org/10.1080/1351847X.2011.628682>
- Smuts, N. (2019). What Drives Cryptocurrency Prices? An Investigation of Google Trends and Telegram Sentiment. *ACM SIGMETRICS Performance Evaluation Review*, 46, 131–134. <https://doi.org/10.1145/3308897.3308955>
- Sood, K., Pathak, P., Jain, J. i Gupta, S. (2023). Gauging investors' investment decisions in the crypto market through the PRISM of behavioral biases: a fuzzy AHP approach. *International Journal of Emerging Markets*. <https://doi.org/10.1108/IJOEM-02-2022-0263>
- Sornette, D. i Zhang, Y. (2025). Transaction flows and holding time scaling laws of bitcoin. *Physica A: Statistical Mechanics and its Applications*, 658. <https://doi.org/10.1016/j.physa.2024.130294>
- StatCounter. (2024, 12 February). Market share of leading search engines worldwide from January 2015 to January 2024. W: *Statista*. Pobrane z <https://www-1statista-1com-1s8fui2yj001f.han3.ue.poznan.pl/statistics/1381664/worldwide-all-devices-market-share-of-search-engines/>
- Statista. (2021, March 9). *Number of businesses that either have a cryptocurrency ATM or offer crypto as an in-store payment method as of March 9, 2021, by territory*. <https://www-1statista-1com-1s8fui2d30043.han3.ue.poznan.pl/statistics/1222684/firms-with-crypto-payment-solution-country/>
- Statista. (2022, January 12). *Bitcoin mining by country*. <https://www.statista.com/statistics/1200477/bitcoin-mining-by-country/>
- Stickel, S. E. (1985). The effect of value line investment survey rank changes on common stock prices. *Journal of Financial Economics*, 14(1), 121-143. [https://doi.org/10.1016/0304-405X\(85\)90046-7](https://doi.org/10.1016/0304-405X(85)90046-7)
- Subramaniam, S. i Chakraborty, M. (2020). Investor Attention and Cryptocurrency Returns: Evidence from Quantile Causality Approach. *Journal of Behavioral Finance*, 21(1), 103-115. <https://doi.org/10.1080/15427560.2019.1629587>

- Sudzina, F., Dobes, M. i Pavlicek, A. (2023). Towards the psychological profile of cryptocurrency early adopters: Overconfidence and self-control as predictors of cryptocurrency use. *Current Psychology*, 42, 8713–8717. <https://doi.org/10.1007/s12144-021-02225-1>
- Sukpitak, J. i Hengpunya, V. (2016). Efficiency of Thai stock markets: Detrended fluctuation analysis. *Physica A: Statistical Mechanics and its Applications*, 458(C), 204–209. <https://doi.org/10.1016/j.physa.2016.03.076>
- Sweeney, R. J. (1988). Some New Filter Rule Tests: Methods and Results. *The Journal of Financial and Quantitative Analysis*, 23(3), 285–300. <https://doi.org/10.2307/2331068>
- Szczygielski, J. J., Charteris, A., Bwanya, P. R. i Brzeszczyński, J. (2023). Google search trends and stock markets: Sentiment, attention or uncertainty? *International Review of Financial Analysis*. <https://doi.org/10.1016/j.irfa.2023.102549>
- Szyska, A. (2003). *Efektywność giełdy papierów wartościowych w Warszawie na tle rynków dojrzałych*. Poznań: Wydawnictwo Akademii Ekonomicznej w Poznaniu.
- Szyska, A. (2009). *Finanse Behawioralne*. Poznań: Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu.
- Takaishi, T. i Adachi, T. (2020). Market Efficiency, Liquidity, and Multifractality of Bitcoin: A Dynamic Study. *Asia-Pacific Financial Markets*, 27, 145–154. <https://doi.org/10.1007/s10690-019-09286-0>
- Tandon, C., Revankar, S., Palivela, H. i Parihar, S.S. (2021). How can we predict the impact of the social media messages on the value of cryptocurrency? Insights from big data analytics. *International Journal of Information Management Data Insights*, 1(2), 100035. <https://doi.org/10.1016/j.jjime.2021.100035>
- Tantaopas, P., Padungsaksawasdi, C. i Treepongkaruna, S. (2016). Attention effect via internet search intensity in Asia-Pacific stock markets. *Pacific Basin Finance Journal*, 38, 107-124. <https://doi.org/10.1016/j.pacfin.2016.03.008>
- Thaler, R. (1985). Mental Accounting and Consumer Choice. *Marketing Science*, 4(3), 199–214. Pobrane z <http://www.jstor.org/stable/183904>
- Thaler, R.H. (1999). Mental accounting matters. *Journal of Behavioral Decision Making*, 12, 183-206. [https://doi.org/10.1002/\(SICI\)1099-0771\(199909\)12:3<183::AID-BDM318>3.0.CO;2-F](https://doi.org/10.1002/(SICI)1099-0771(199909)12:3<183::AID-BDM318>3.0.CO;2-F)

- Thaler, R. H. i Johnson, E. J. (1990). Gambling with the House Money and Trying to Break Even: The Effects of Prior Outcomes on Risky Choice. *Management Science*, 36(6), 643–660. Pobrane z <http://www.jstor.org/stable/2631898>
- Thaler, R. H., Tversky, A., Kahneman, D. i Schwartz, A. (1997). The Effect of Myopia and Loss Aversion on Risk Taking: An Experimental Test. *The Quarterly Journal of Economics*, 112(2), 647–661. Pobrane z <http://www.jstor.org/stable/2951249>
- Thomas, D. i Sabater, A. (2022). *Private Equity and Institutional Investors Back Away from Crypto and DeFi*, S&P Global. Pobrane [26.09.2024] z <https://www.spglobal.com/marketintelligence/en/news-insights/latest-news-headlines/private-equity-and-institutional-investors-back-away-from-crypto-and-defi-73627011>
- Tiwari, A., Debojyoti, D., Jana, R. K. i Roubaud, D. (2018). Informational efficiency of Bitcoin - An extension. *Economics Letters*, 163(C), 106-109. <https://doi.org/10.1016/j.econlet.2017.12.006>
- Todea, A., Ulici, M. i Silaghi, S. (2009). Adaptive market hypothesis: Evidence from AsiaPacific financial markets. *The Review of Finance and Banking*, 1(1), 7-13. Pobrane z <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=21d740ef04d916d6dafcd71517b8e00a155586f8>
- Tovanich, N., Soulié, N. i Isenberg, P. (2021, April). *Visual analytics of bitcoin mining pool evolution: on the road toward stability?* 3rd International Workshop on Blockchains and Smart Contracts held in conjunction with the 11th IFIP International Conference on New Technologies, Mobility and Security, France, Paris, 1–5. <https://doi.org/10.1109/NTMS49979.2021.9432675>
- Tran, V. L. i Leirvik, T. (2020). Efficiency in the markets of crypto-currencies. *Finance Research Letters*, 35. <https://doi.org/10.1016/j.frl.2019.101382>
- Tripathi, A., Vipul, V. i Dixit, A. (2020). Adaptive market hypothesis and investor sentiments: global evidence. *Managerial Finance*, 46(11), 1407-1436. <https://doi.org/10.1108/MF-08-2019-0396>
- Tversky, A. i Kahneman, D. (1973). Availability: A heuristic for judging frequency and probability. *Cognitive Psychology*, 5(2), 207-232. [https://doi.org/10.1016/0010-0285\(73\)90033-9](https://doi.org/10.1016/0010-0285(73)90033-9)

- Tversky, A. i Kahneman, D. (1974). Judgment under Uncertainty: Heuristics and Biases. *Science*, 185(4157), 1124–1131. Pobrane z <http://www.jstor.org/stable/1738360>
- Tversky, A. i Kahneman, D. (1992). Advances in prospect theory: Cumulative representation of uncertainty. *Journal of Risk and Uncertainty*, 5, 297–323. <https://doi.org/10.1007/BF00122574>
- Urquhart, A. i Hudson, R. (2013) Efficient or adaptive markets? Evidence from major stock markets using very long run historic data. *International Review of Financial Analysis*, 28, 130-142. ISSN 1057-5219. <https://doi.org/10.1016/j.irfa.2013.03.005>
- Urquhart, A. i McGroarty, F. (2014). Calendar effects, market conditions and the Adaptive Market Hypothesis: Evidence from long-run U.S. data. *International Review of Financial Analysis*, 35, 154-166. <https://doi.org/10.1016/j.irfa.2014.08.003>
- Urquhart, A. (2016). The inefficiency of Bitcoin. *Economics Letters*, 148, 80-82. <https://doi.org/10.1016/j.econlet.2016.09.019>
- Urquhart, A. i McGroarty, F. (2016). Are stock markets really efficient? Evidence of the adaptive market hypothesis. *International Review of Financial Analysis*, 47, 39-49. <https://doi.org/10.1016/j.irfa.2016.06.011>
- Urquhart, A. (2017). Price clustering in Bitcoin. *Economics letters*, 159, 145–48. <https://doi.org/10.1016/j.econlet.2017.07.035>
- Urquhart, A. (2018). What causes the attention of Bitcoin? *Economics Letters*, 166, 40–44. <https://doi.org/10.1016/j.econlet.2018.02.017>
- Wang, Y., Liu, L. i Gu, R. (2009). Analysis of efficiency for Shenzhen stock market based on multifractal detrended fluctuation analysis. *International Review of Financial Analysis*, 18(5), 271-276. <https://doi.org/10.1016/j.irfa.2009.09.005>
- Wang, C., Chu, X. i Yang, Q. (2019). Measurement and Analysis of the Bitcoin Networks: A View from Mining Pools. *ArXiv*. <https://doi.org/10.48550/arXiv.1902.07549>
- Wang, P., Li, X., Shen, D. i Zhang, W. (2020). How does economic policy uncertainty affect the bitcoin market?. *Research in International Business and Finance*, 53(C). <https://doi.org/10.1016/j.ribaf.2020.101234>
- Wang, J. i Wang, X. (2021). COVID-19 and financial market efficiency: Evidence from an entropy-based analysis. *Finance Research Letters*, 42(C). <https://doi.org/10.1016/j.frl.2020.101888>

- Wang, Z., Wu, K. i Wang, Z. (2023). The Role of Anchoring on Investors' Gambling Preference: Evidence from China. *Pacific-Basin Finance Journal*, 80, 102054. <https://doi.org/10.1016/j.pacfin.2023.102054>
- Waweru, N. M., Munyoki, E. i Uliana, E. (2008). The effects of behavioural factors in investment decision-making: a survey of institutional investors operating at the Nairobi Stock Exchange. *International Journal of Business and Emerging Markets*, 1(1), 24-41. <https://doi.org/10.1504/IJBEM.2008.019243>
- Wei, W. C. (2018). Liquidity and market efficiency in cryptocurrencies. *Economics Letters*, 168, 21-24. <https://doi.org/10.1016/j.econlet.2018.04.003>
- Welfe, A. (2014). *Ekonometria. Metody i ich zastosowanie*. Warszawa: PWE, s. 9-411. ISBN 978-83-208-2152-9
- Wen, F., Xu, L., Ouyang, G. i Kou, G. (2019). Retail investor attention and stock price crash risk: Evidence from China. *International Review of Financial Analysis*, 65. <https://doi.org/10.1016/j.irfa.2019.101376>
- Wen, Z., Bouri, E., Xu, Y. i Zhao, Y. (2022). Intraday Return Predictability in the Cryptocurrency Markets: Momentum, Reversal, or Both. *The North American Journal of Economics and Finance*, 62, 101733. <https://doi.org/10.1016/j.najef.2022.101733>
- Weron R. (2002). Estimating long-range dependence: finite sample properties and confidence intervals. *Physica A: Statistical Mechanics and its Applications*, 312, 285-299. [https://doi.org/10.1016/S0378-4371\(02\)00961-5](https://doi.org/10.1016/S0378-4371(02)00961-5)
- Włosik, K. (2021). *Rynek kryptowalut i tokenów z perspektywy inwestycyjnej*. Poznań: Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu. <https://doi.org/10.18559/978-83-8211-081-4>
- Womack, K. L. (1996). Do Brokerage Analysts' Recommendations Have Investment Value? *The Journal of Finance*, 51, 137-167. <https://doi.org/10.1111/j.1540-6261.1996.tb05205.x>
- Working, H. (1934). A Random-Difference Series for Use in the Analysis of Time Series. *Journal of the American Statistical Association*, 29(185), 11-24. <https://doi.org/10.2307/2278456>
- Worthington, A. C. i Higgs, H. (2004). Random walks and market efficiency in European equity markets. *Global Journal of Finance and Economics*, 1 (1), 59-78. Pobrane z <https://eprints.qut.edu.au/2319/1/2319.pdf>

- Wu, W., Tiwari, A. K., Gozgor, G. i Leping, H. (2021). Does economic policy uncertainty affect cryptocurrency markets? Evidence from Twitter-based uncertainty measures. *Research in International Business and Finance*, 58(C). <https://doi.org/10.1016/j.ribaf.2021.101478>
- Vandewalle, N., Ausloos, M. i Boveroux, P. (1997). Detrended Fluctuation Analysis of the Foreign Exchange Market. W: *Proceedings of Econophysic Workshop*. Budapest, Hungary. <https://newton.phy.bme.hu/~kullmann/Egyetem/Uj/vandewalle.pdf>
- Vidal-Tomás, D. i Ibañez, A. (2018). Semi-strong efficiency of Bitcoin. *Finance Research Letters*, 27, 259-265. <https://doi.org/10.1016/j.frl.2018.03.013>
- Vidal-Tomás, D., Ibañez, A. M. i Farinós, J. E. (2019). Herding in the cryptocurrency market: CSSD and CSAD approaches. *Finance Research Letters*, 30, 181–186. <https://doi.org/10.1016/j.frl.2018.09.008>
- Von Neumann, J. i Morgenstern, O. (1944). *Theory of games and economic behavior*. Princeton University Press.
- Vozlyublennaia, N. (2014). Investor attention, index performance, and return predictability. *Journal of Banking & Finance*, 41(C), 17-35. <https://doi.org/10.1016/j.jbankfin.2013.12.010>
- Xiong X., Yongqiang, M., Xiao, L. i Dehua, S. (2019). An empirical analysis of the Adaptive Market Hypothesis with calendar effects: Evidence from China. *Finance Research Letters*, 31. <https://doi.org/10.1016/j.frl.2018.11.020>
- Yahoo. (2022). *Why twitter is banned in china*. Pobrane z https://au.finance.yahoo.com/news/why-twitter-is-banned-in-china-232110891.html?guccounter=1&guce_referrer=aHR0cHM6Ly93d3cuZ29vZ2xlLmNvbS8&guce_referrer_sig=AQAAANTgGi9z9tVQ3o8kwUI_9q5Kb9BP46fmJU8-3PSS3sdO8gC-FLp4WUTbjSC5Mcy01MquE_c8WpYJAtaGyJb910nYp2f8t8tr1puh789vvkPPbxqbQQjvMgRx7NiVicOXLTDXGamSYCP3_C8x0BtcZhXFWBSE1Zdyi6w-_TmAhW1d
- Yen, K.-C. i Cheng, H.-P. (2021). Economic policy uncertainty and cryptocurrency volatility. *Finance Research Letters*, 38(C). <https://doi.org/10.1016/j.frl.2020.101428>
- Zahera, S. A. i Bansal, R. (2018). Do investors exhibit behavioral biases in investment decision making? A systematic review. *Qualitative Research in Financial Markets*, 10(2), 210-251. <https://doi.org/10.1108/QRFM-04-2017-0028>

- Zargar, F. N. i Kumar, D. (2019). Informational inefficiency of Bitcoin: A study based on high-frequency data. *Research in International Business and Finance*, 47, 344-353.
<https://doi.org/10.1016/j.ribaf.2018.08.008>
- Zhu, P., Zhang, X., Wu, Y., Zheng, H. i Zhang Y. (2021). Investor attention and cryptocurrency: Evidence from the Bitcoin market. *PLoS One*, 16(2), e0246331.
<https://doi.org/10.1371/journal.pone.0246331>.
- Zielonka P. (2003). Czym są finanse behawioralne, czyli krótkie wprowadzenie do psychologii rynków finansowych. *Materiały i Studia*, 158. Narodowy Bank Polski.
Pobrane z https://www.nbp.pl/publikacje/materiały_i_studia/ms158.pdf
- Zielonka, P. (2017). Framing, czyli efekt sformułowania. *Decyzje*, 27, 41-68.
<https://doi.org/10.7206/DEC.1733-0092.85>

Wykaz tabel

| | |
|---|-----|
| Tabela 1. Metody weryfikacji słabej efektywności rynku | 22 |
| Tabela 2. Znaczenie poszczególnych wartości parametru „d” i wykładnika Hursta dla procesu stacjonarnego | 31 |
| Tabela 3. Metody weryfikacji pól silnej efektywności rynku | 32 |
| Tabela 4. Metody weryfikacji silnej efektywności rynku..... | 33 |
| Tabela 5. Ocena przydatności testów efektywności rynku | 35 |
| Tabela 6. Porównanie przydatności testów słabej formy efektywności rynku..... | 37 |
| Tabela 7. Porównanie przydatności testów pól silnej formy efektywności rynku..... | 38 |
| Tabela 8. Porównanie przydatności testów silnej formy efektywności rynku..... | 39 |
| Tabela 9. Badania efektywności rynku kryptowalut | 56 |
| Tabela 10. Podział badań efektywności rynku kryptowalut ze względu na źródła danych i wykorzystywane metody..... | 57 |
| Tabela 11. Badania czynników efektywności rynku kryptowalut | 58 |
| Tabela 12. Systematyka przejawów nieracjonalnego zachowania inwestorów na rynku finansowym | 74 |
| Tabela 13. Czynniki behawioralne i ich pomiar | 78 |
| Tabela 14. Wyniki badań nad występowaniem czynników behawioralnych na rynku kryptowalut | 95 |
| Tabela 15. Wyniki testów stacjonarności dla zmiennych objaśniających i zmiennej objaśnianej | 132 |
| Tabela 16. Macierz korelacji pomiędzy zmiennymi w badaniu..... | 137 |
| Tabela 17. Statystyki opisowe dla zmiennej zależnej i zmiennych objaśniających..... | 141 |
| Tabela 18. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina..... | 149 |
| Tabela 19. Długoterminowe mnożniki dla poszczególnych zmiennych | 153 |
| Tabela 20. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina – model ARMA..... | 155 |
| Tabela 21. Charakterystyki rozkładu zmiennych zależnych zastosowanych w ramach testów odporności..... | 158 |
| Tabela 22. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina obliczoną z wykorzystaniem testu ilorazu wariancji | 160 |
| Tabela 23. Oszacowania parametrów modelu związku między czynnikami behawioralnymi a dynamiką efektywności rynku Bitcoina obliczoną z wykorzystaniem modelu rzędu integracji ułamkowej GPH | 162 |

Spis wykresów

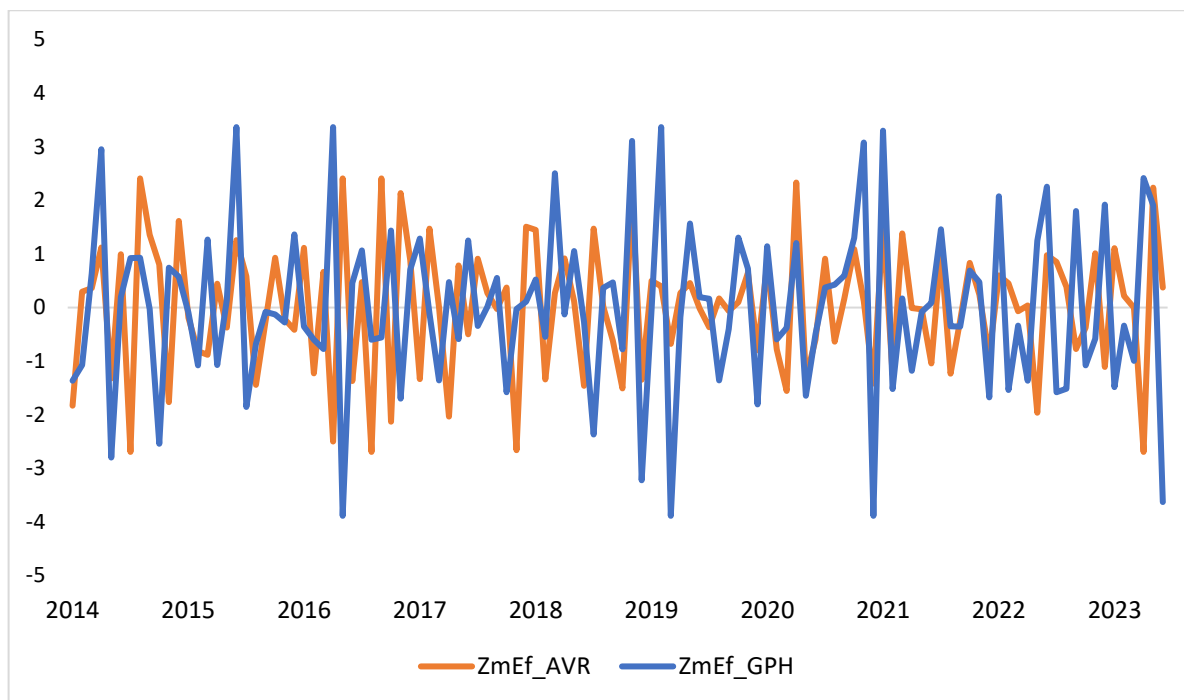
| | |
|---|-----|
| Wykres 1. Udział kapitalizacji Bitcoina w rynku kryptowalut (stan na dzień 26.04.2025 r.) ... | 41 |
| Wykres 2. Udział obrotów poszczególnych giełd w rynku Bitcoina | 47 |
| Wykres 3. Porównanie teorii oczekiwanej użyteczności z teorią perspektywy pod względem funkcji ważenia prawdopodobieństwa..... | 63 |
| Wykres 4. Przykład wyznaczania wykładnika Hursta (H) na podstawie długości okresów próbkowania (n) i odpowiednich wartości miary zmienności (F(n))..... | 117 |
| Wykres 5. Liczba godzin w kolejnych miesiącach, podczas których doszło do transakcji na rynku Bitcoina | 140 |
| Wykres 6. Miesięczne zmiany poziomu efektywności rynku Bitcoina | 143 |

Spis schematów

| | |
|---|-----|
| Schemat 1. Etapy badania empirycznego..... | 8 |
| Schemat 2. Oddziaływanie zmieniających się warunków rynkowych na dynamikę efektywności rynku kapitałowego | 105 |
| Schemat 3. Ogólny schemat szacowania wykładnika Hursta..... | 114 |
| Schemat 4. Schemat szacowania wartości wykładnika Hursta na potrzeby badania | 120 |

Załączniki

Załącznik 1:



Wykres A. Miesięczne zmiany efektywności rynku Bitcoina wyznaczone na podstawie statystyki testu ilorazu wariancji i oszacowań parametru rzędu integracji ułamkowej

Uwaga: Dane obejmują okres od 1.01.2014 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Załącznik 2:

Tabela A1. Wyniki testów stacjonarności dla kapitalizacji rynku Bitcoina

| Zmienna | Statystyka testu ADF | Statystyka testu KPSS |
|--|----------------------|-----------------------|
| <i>testy przeprowadzone na wartościach zmiennych (grupa 1)</i> | | |
| MC_t | -2,4611 | 1,7942* |
| <i>testy przeprowadzone na przyrostach logarytmów wartości zmiennych (grupa 2)</i> | | |
| ΔMC_t | -4,0498* | 0,1079 |

Uwaga: “***”, “**”, “*” oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. KPSS oznacza Kwiatkowski–Phillips–Schmidt–Shin, skrót “ADF” należy czytać jako Augmented Dickey-Fuller. Dane dotyczą okresu od 1.12.2013 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Tabela A2. Wyniki testów stacjonarności dla poziomu płynności na rynku Bitcoina

| Zmienna | Statystyka testu ADF | Statystyka testu KPSS |
|--|----------------------|-----------------------|
| <i>testy przeprowadzone na wartościach zmiennych (grupa 1)</i> | | |
| $ILLIQ_t$ | -5,7298* | 0,3004 |
| <i>testy przeprowadzone na przyrostach logarytmów wartości zmiennych (grupa 2)</i> | | |
| $\Delta ILLIQ_t$ | -6,236* | 0,2796 |

Uwaga: “***”, “**”, “*” oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. KPSS oznacza Kwiatkowski–Phillips–Schmidt–Shin, skrót “ADF” należy czytać jako Augmented Dickey-Fuller. Dane dotyczą okresu od 1.12.2013 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Tabela A3. Wyniki testów stacjonarności dla wolumenu obrotu na rynku Bitcoina

| Zmienna | Statystyka testu ADF | Statystyka testu KPSS |
|--|----------------------|-----------------------|
| <i>testy przeprowadzone na wartościach zmiennych (grupa 1)</i> | | |
| Vol_t | -2,648 | 1,322* |
| <i>testy przeprowadzone na przyrostach logarytmów wartości zmiennych (grupa 2)</i> | | |
| ΔVol_t | -5,2573* | 0,0708 |

Uwaga: "****", "***", "**" oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. KPSS oznacza Kwiatkowski–Phillips–Schmidt–Shin, skrót "ADF" należy czytać jako Augmented Dickey-Fuller. Dane dotyczą okresu od 1.12.2013 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Tabela A4. Wyniki testów stacjonarności dla zmienności na rynku Bitcoina

| Zmienna | Statystyka testu ADF | Statystyka testu KPSS |
|--|----------------------|-----------------------|
| <i>testy przeprowadzone na wartościach zmiennych (grupa 1)</i> | | |
| Sd_t | -7,1315* | 0,0737 |
| <i>testy przeprowadzone na przyrostach logarytmów wartości zmiennych (grupa 2)</i> | | |
| ΔSd_t | -6,9347* | 0,0636 |

Uwaga: "****", "***", "**" oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. KPSS oznacza Kwiatkowski–Phillips–Schmidt–Shin, skrót "ADF" należy czytać jako Augmented Dickey-Fuller. Dane dotyczą okresu od 1.12.2013 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Tabela A5. Wyniki testów stacjonarności dla indeksu VIX

| Zmienna | Statystyka testu ADF | Statystyka testu KPSS |
|--|----------------------|-----------------------|
| <i>testy przeprowadzone na wartościach zmiennych (grupa 1)</i> | | |
| VIX_t | -3,1681*** | 0,9627* |
| <i>testy przeprowadzone na przyrostach logarytmów wartości zmiennych (grupa 2)</i> | | |
| ΔVIX_t | -5,9836* | 0,0920 |

Uwaga: "****", "***", "**" oznaczają istotność statystyczną na poziomie odpowiednio 10%, 5%, 1%. KPSS oznacza Kwiatkowski–Phillips–Schmidt–Shin, skrót "ADF" należy czytać jako Augmented Dickey-Fuller. Dane dotyczą okresu od 1.12.2013 r. do 30.06.2023 r.

Źródło: Opracowanie własne

Załącznik 3:

Tabela B1. Oszacowania parametrów modelu związku między uwagą inwestorów skierowaną na Bitcoina a dynamiką efektywności rynku Bitcoina

| Zmienna | Współczynnik (Błąd standardowy) |
|---|------------------------------------|
| Zm_ef_(t-1) | -0,58099*** (0,07726) |
| Zm_ef_(t-2) | -0,42267*** (0,07051) |
| Δ ILLIQ_t | 0,00966*** (0,00361) |
| Δ ILLIQ_(t-1) | 0,00314 (0,00334) |
| Δ Vol_t | 0,01079 (0,00670) |
| Δ MC_t | 0,00424 (0,01296) |
| Δ GSV_t | -0,00272 (0,00988) |
| Δ VIX_t | -0,00678 (0,01287) |
| Stała | -0,00029 (0,00191) |
| Liczba obserwacji | 112 |
| Skorygowany R ² | 0,32463 |
| Błąd standardowy reszt | 0,02582 (df = 103) |
| Statystyka F | 7,66921 *** (df = 8; 103) |
| Statystyka testu Durбина-Watsona (p-value) | 2,20859 (0,22) |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%, Zastosowano odporne błędy standardowe na heteroskedastyczność i autokorelację reszt (Newey-West).

Tabela B2. Oszacowania parametrów modelu związku między uwagą inwestorów aproksymowaną za pomocą „ważonego” indeksu GSV a dynamiką efektywności rynku Bitcoina

| Zmienna | Współczynnik (Błąd standardowy) |
|---|------------------------------------|
| Zm_ef_(t-1) | -0,58809*** (0,07656) |
| Zm_ef_(t-2) | -0,43569*** (0,07227) |
| Δ ILLIQ_t | 0,00738* (0,00381) |
| Δ ILLIQ_(t-1) | 0,00135 (0,00343) |
| Δ MC_t | 0,00886 (0,01126) |
| Δ GSVw_t | 0,00075 (0,00673) |
| Δ VIX_t | -0,00386 (0,01249) |
| Stała | -0,00027 (0,00190) |
| Liczba obserwacji | 112 |
| Skorygowany R ² | 0,3140 |
| Błąd standardowy reszt | 0,0260 (df = 104) |
| Statystyka F | 8,2570*** (df = 7; 104) |
| Statystyka testu Durbina-Watsona (p-value) | 2,2477 (0,17) |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%, Zastosowano odporne błędy standardowe na heteroskedastyczność i autokorelację reszt (Newey-West).

Tabela B3. Oszacowania parametrów modelu związku między natężeniem negatywnego sentymentu inwestorów a dynamiką efektywności rynku Bitcoina

| Zmienna | Współczynnik (Błąd standardowy) |
|---|------------------------------------|
| Zm_ef_(t-1) | -0,57554*** (0,07568) |
| Zm_ef_(t-2) | -0,42969*** (0,06900) |
| Δ ILLIQ_t | 0,00992*** (0,00355) |
| Δ ILLIQ_(t-1) | 0,00300 (0,00337) |
| Δ Vol_t | 0,01050 (0,00655) |
| Δ MC_t | 0,00499 (0,01122) |
| FEARS_t | 0,00091 (0,00576) |
| Stała | -0,00024 (0,00187) |
| Liczba obserwacji | 112 |
| Skorygowany R ² | 0,32961 |
| Błąd standardowy reszt | 0,02572 (df = 104) |
| Statystyka F | 8,79640*** (df = 7; 104) |
| Statystyka testu Durbina-Watsona (p-value) | 2,2259 (0,248) |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%, Zastosowano odporne błędy standardowe na heteroskedastyczność i autokorelację reszt (Newey-West).

Tabela B4. Oszacowania parametrów modelu związku między natężeniem pozytywnego sentymentu inwestorów a dynamiką efektywności rynku Bitcoina

| Zmienna | Współczynnik (Błąd standardowy) |
|---|------------------------------------|
| Zm_ef_(t-1) | -0,57542*** (0,07749) |
| Zm_ef_(t-2) | -0,43171*** (0,07186) |
| Δ ILLIQ_t | 0,00894** (0,00378) |
| Δ ILLIQ_(t-1) | 0,00231 (0,00328) |
| Δ Vol_t | 0,00983 (0,00613) |
| Δ VIX_t | -0,00505 (0,01187) |
| GREED_t | 0,01116* (0,00622) |
| Stała | -0,00049 (0,00181) |
| Liczba obserwacji | 112 |
| Skorygowany R ² | 0,34975 |
| Błąd standardowy reszt | 0,02533 (df = 104) |
| Statystyka F | 9,52917*** (df = 7; 104) |
| Statystyka testu Durbina-Watsona (p-value) | 2,1993 (0,266) |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%, Zastosowano odporne błędy standardowe na heteroskedastyczność i autokorelację reszt (Newey-West).

Tabela B5. Oszacowania parametrów modelu związku między skłonnością inwestorów do ulegania heurystyce zakotwiczenia a dynamiką efektywności rynku Bitcoina

| Zmienna | Współczynnik (Błąd standardowy) |
|---|------------------------------------|
| Zm_ef_(t-1) | -0,58801*** (0,07698) |
| Zm_ef_(t-2) | -0,42645*** (0,07193) |
| Δ ILLIQ_t | 0,00944** (0,00386) |
| Δ ILLIQ_(t-1) | 0,00325 (0,00340) |
| Δ Vol_t | 0,01086 (0,00680) |
| Δ MC_t | 0,00188 (0,01282) |
| Δ W52_t | 0,00586 (0,01562) |
| Δ VIX_t | -0,00635 (0,01313) |
| Stała | -0,00021 (0,00190) |
| Liczba obserwacji | 112 |
| Skorygowany R ² | 0,32494 |
| Błąd standardowy reszt | 0,02581 (df = 103) |
| Statystyka F | 7,67873*** (df = 8; 103) |
| Statystyka testu Durbina-Watsona (p-value) | 2,1976 (0,238) |

Uwaga: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%, Zastosowano odporne błędy standardowe na heteroskedastyczność i autokorelację reszt (Newey-West).

Załącznik 4:

Tabela C1. Oszacowania parametrów modelu związku między uwagą inwestorów a dynamiką efektywności rynku Bitcoina – model ARMA

| Zmienna | Współczynnik | Błąd standardowy |
|--------------------------------------|--------------|------------------|
| Zm_ef_(t-1) | -0,24796** | 0,11552 |
| Zm_ef_(t-2) | -0,42442*** | 0,10816 |
| Zm_ef_(t-3) | -0,23075** | 0,11652 |
| Zm_ef_(t-4) | -0,27435** | 0,11269 |
| Zm_ef_(t-5) | -0,24782** | 0,10036 |
| Zm_ef_(t-6) | -0,28472*** | 0,09913 |
| MA(1) | -0,71162*** | 0,08734 |
| Stała | -0,00003 | 0,00029 |
| Δ GSV_t | 0,00036 | 0,00557 |
| Δ ILLIQ_t | 0,00771** | 0,00351 |
| Δ ILLIQ_(t-1) | -0,00664* | 0,00340 |
| Δ Vol_t | 0,00723* | 0,00433 |
| Δ MC_t | -0,00143 | 0,00612 |
| Δ VIX_t | 0,00720 | 0,00986 |
| Wartość kryterium informacyjnego AIC | -522,30 | |
| Wartość kryterium informacyjnego BIC | -481,39 | |

Uwagi: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%. MA(1) oznacza średnią ruchomą rzędu 1 dla składnika losowego.

Tabela C2. Oszacowania parametrów modelu związku między uwagą inwestorów aproksymowaną za pomocą „ważonego” indeksu GSV a dynamiką efektywności rynku Bitcoina – model ARMA

| Zmienna | Współczynnik | Błąd standardowy |
|--------------------------------------|--------------|------------------|
| Zm_ef_(t-1) | -0,25520** | 0,11771 |
| Zm_ef_(t-2) | -0,40651*** | 0,11071 |
| Zm_ef_(t-3) | -0,23909** | 0,11889 |
| Zm_ef_(t-4) | -0,23714** | 0,11340 |
| Zm_ef_(t-5) | -0,24182** | 0,10194 |
| Zm_ef_(t-6) | -0,27971*** | 0,10022 |
| MA(1) | -0,70615*** | 0,09185 |
| Stała | -0,00009 | 0,00028 |
| Δ GSVw_t | 0,00335 | 0,00409 |
| Δ ILLIQ_t | 0,00794** | 0,00347 |
| Δ ILLIQ_(t-1) | -0,00749** | 0,00339 |
| Δ MC_t | 0,00514 | 0,00408 |
| Δ VIX_t | 0,01230 | 0,00948 |
| Wartość kryterium informacyjnego AIC | -522,06 | |
| Wartość kryterium informacyjnego BIC | -483,88 | |

Uwagi: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%. MA(1) oznacza średnią ruchomą rzędu 1 dla składnika losowego.

Tabela C3. Oszacowania parametrów modelu związku między natężeniem negatywnego sentymentu inwestorów a dynamiką efektywności rynku Bitcoina – model ARMA

| Zmienna | Współczynnik | Błąd standardowy |
|--------------------------------------|--------------|------------------|
| Zm_ef_(t-1) | -0,24844** | 0,11632 |
| Zm_ef_(t-2) | -0,42651*** | 0,10875 |
| Zm_ef_(t-3) | -0,22882* | 0,11689 |
| Zm_ef_(t-4) | -0,28016** | 0,11233 |
| Zm_ef_(t-5) | -0,24345** | 0,10086 |
| Zm_ef_(t-6) | -0,27976*** | 0,09913 |
| MA(1) | -0,70552*** | 0,08894 |
| Stała | -0,00004 | 0,00028 |
| FEARS_t | 0,00090 | 0,00215 |
| Δ ILLIQ_t | 0,00763** | 0,00344 |
| Δ ILLIQ_(t-1) | -0,00642* | 0,00338 |
| Δ Vol_t | 0,00843** | 0,00390 |
| Δ MC_t | -0,00283 | 0,00526 |
| Wartość kryterium informacyjnego AIC | -523,94 | |
| Wartość kryterium informacyjnego BIC | -485,76 | |

Uwagi: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%. MA(1) oznacza średnią ruchomą rzędu 1 dla składnika losowego.

Tabela C4. Oszacowania parametrów modelu związku między natężeniem pozytywnego sentymentu inwestorów a dynamiką efektywności rynku Bitcoina – model ARMA

| Zmienna | Współczynnik | Błąd standardowy |
|--------------------------------------|--------------|------------------|
| Zm_ef_(t-1) | -0,18872 | 0,12469 |
| Zm_ef_(t-2) | -0,37378*** | 0,11364 |
| Zm_ef_(t-3) | -0,18824 | 0,11898 |
| Zm_ef_(t-4) | -0,23637** | 0,11319 |
| Zm_ef_(t-5) | -0,22494** | 0,10175 |
| Zm_ef_(t-6) | -0,27693** | 0,10037 |
| MA(1) | -0,77367*** | 0,09616 |
| Stała | -0,00024 | 0,00026 |
| GREED_t | 0,00507 | 0,00418 |
| Δ ILLIQ_t | 0,00803** | 0,00342 |
| Δ ILLIQ_(t-1) | -0,00688** | 0,00335 |
| Δ Vol_t | 0,00629*** | 0,00213 |
| Δ VIX_t | 0,00846 | 0,00794 |
| Wartość kryterium informacyjnego AIC | -525,78 | |
| Wartość kryterium informacyjnego BIC | -487,60 | |

Uwagi: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%. MA(1) oznacza średnią ruchomą rzędu 1 dla składnika losowego.

Tabela C5. Oszacowania parametrów modelu związku między skłonnością inwestorów do ulegania heurystyce zakotwiczenia a dynamiką efektywności rynku Bitcoina – model ARMA

| Zmienna | Współczynnik | Błąd standardowy |
|--------------------------------------|--------------|------------------|
| Zm_ef_(t-1) | -0,24573** | 0,11527 |
| Zm_ef_(t-2) | -0,42365*** | 0,10787 |
| Zm_ef_(t-3) | -0,22923** | 0,11574 |
| Zm_ef_(t-4) | -0,27548** | 0,11179 |
| Zm_ef_(t-5) | -0,24728** | 0,10028 |
| Zm_ef_(t-6) | -0,28427*** | 0,09918 |
| MA(1) | -0,71532*** | 0,08766 |
| Stała | -0,00002 | 0,00027 |
| $\Delta W52_t$ | 0,00136 | 0,00460 |
| $\Delta ILLIQ_t$ | 0,00765** | 0,00342 |
| $\Delta ILLIQ_{(t-1)}$ | -0,00662** | 0,00338 |
| ΔVol_t | 0,00755* | 0,00427 |
| ΔMC_t | -0,00185 | 0,00606 |
| ΔVIX_t | 0,00718 | 0,00981 |
| Wartość kryterium informacyjnego AIC | -522,39 | |
| Wartość kryterium informacyjnego BIC | -481,47 | |

Uwagi: ***, **, * oznaczają istotność statystyczną na poziomie odpowiednio 1%, 5%, 10%. MA(1) oznacza średnią ruchomą rzędu 1 dla składnika losowego.