

Analiza porównawcza kształtowania się indeksów akcji na świecie po kryzysie finansowym¹

Ryszard Węgrzyn*

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

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

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

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

Słowa kluczowe: indeks giełdowy, zmienność, model GARCH

Wprowadzenie

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

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

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

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

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

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

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

1. Przegląd literatury

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

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

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

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

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

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

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

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

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

2. Zastosowane metody badawcze oraz charakterystyka danych

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

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

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

gdzie:

P_t – poziom określonego indeksu w momencie t .

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

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

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

gdzie:

r_t – logarytmiczna stopa zwrotu,

a_0, a_j i b_j – parametry modelu,

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

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

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

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

gdzie:

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

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

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

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

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

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

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

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

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


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

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

3. Wyniki analizy długookresowych zmian wybranych indeksów giełdowych

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

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




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

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

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

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



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

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

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

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

Tabela 1

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

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

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

4. Wyniki analizy zmienności stóp zwrotu indeksów giełdowych

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

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

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

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

Tabela 2

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

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

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

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

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

Tabela 3

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

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

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

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

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

Tabela 4

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

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

Źródło: obliczenia własne.

5. Porównanie oczekiwanych stóp zwrotu i ryzyka wybranych indeksów

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

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

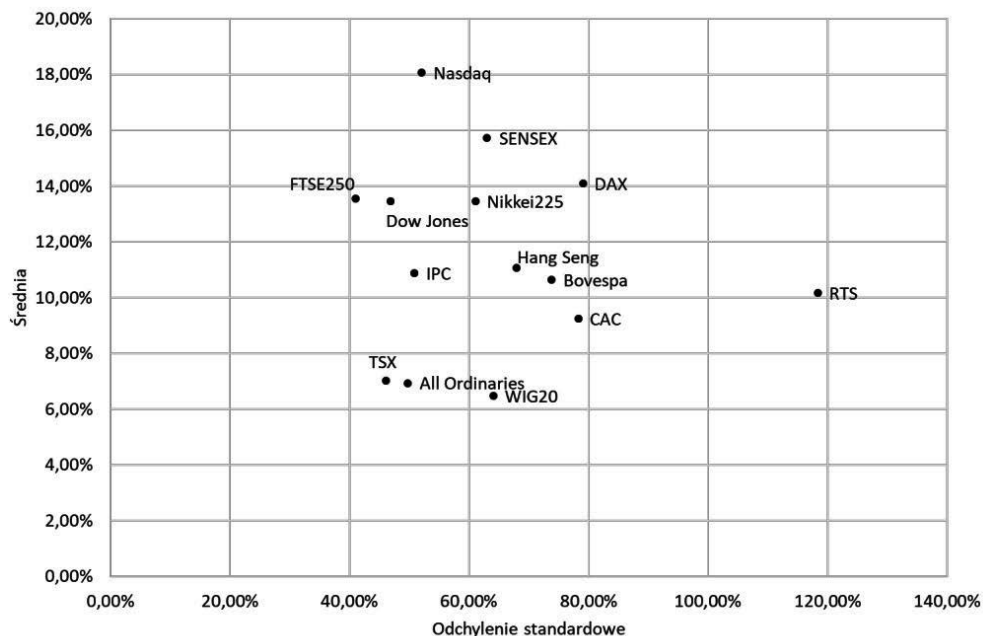
Tabela 5

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

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

Źródło: obliczenia własne.

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



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

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

Uwagi końcowe

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

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

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

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

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

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

Literatura

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

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

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

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

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

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

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

Keywords: stock market index, volatility, GARCH model

Cytowanie

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