

Prognozowanie stanu turbulencji dla instrumentu finansowego w perspektywie dziennej na podstawie modeli dla binarnej zmiennej zależnej

Mgr Marcin Chlebus*

Abstrakt

W artykule przedstawiono propozycję modeli prognozowania stanów dla instrumentu finansowego w horyzoncie jednodniowym. W badaniu poddano analizie modele zakładające: jeden z trzech modeli dla zmiennej binarnej (logitowy, probitowy oraz cloglog), cztery definicje zmiennej zależnej (20%, 10%, 5% oraz 1% najgorszych realizacji stopy zwrotu) oraz trzy różne zbiory zmiennych niezależnych (dane nieprzekształcone, główne składowe z analizy PCA oraz czynniki z analizy czynnikowej). Ponadto w badaniu przeprowadzono analizę wyboru optymalnego punktu odcięcia. Ocena modeli została wykonana na podstawie testów LR i Hosmera-Lemeshowa oraz analizy parametru GINI i kryterium KROC.

Na podstawie wyników badania empirycznego ustalono dziewięć kombinacji założeń, dla których modele stanu turbulencji spełniają określone w badaniu wymogi formalne oraz charakteryzują się wysoką zdolnością prognostyczną i dyskryminacyjną.

Słowa kluczowe: prognozowanie, stan turbulencji, modele zmiany stanu, modele dla zmiennej binarnej (logitowy, probitowy, cloglog), ryzyko rynkowe.

JEL Code: C53, C58, G17.

* (mchlebus@wne.uw.edu.pl)

Katedra Statystyki i Ekonometrii Wydział Nauk Ekonomicznych Uniwersytetu Warszawskiego

Wstęp

W niniejszym badaniu przedstawiona zostanie propozycja modeli służących do prognozowania stanu turbulencji dla szeregu czasowego danych finansowych. Modele tego typu mogą być wykorzystywane w instytucjach finansowych na wiele sposobów. Mogą one wspierać proces zarządzania ryzykiem na przykład poprzez generowanie sygnału uruchamiającego bardziej restrykcyjne procesy kontrolne lub zwiększające zabezpieczenia na wypadek wystąpienia nadzwyczajnych strat. Modele stanu turbulencji mogą również być uwzględnione w pomiarze ryzyka rynkowego w instytucji finansowej. Możliwość rozpoznania stanu pozwala mierzyć niezależnie poziom ryzyka w stanie spokoju, jak i w stanie turbulencji, co może się przekładać na dokładniejszy jego pomiar.

Głównym celem stawianym wobec proponowanych modeli jest przewidzenie, na podstawie dzisiejszej i historycznej sytuacji gospodarczej, jutrzejszego stanu, w którym znajdzie się analizowany szereg czasowy danych finansowych.

Dalsza część artykułu została opracowana w następujący sposób: na początku przedstawiona zostanie koncepcja modeli prognozowania stanu turbulencji, następnie omówione zostaną szczegółowe założenia i proces testowania, w dalszej kolejności zaprezentowane zostaną wyniki analizy empirycznej jakości proponowanych modeli, na końcu natomiast przedstawione zostanie podsumowanie wyników uzyskanych w badaniu empirycznym.

Koncepcja modelu

Opracowywana koncepcja modelu prognozy stanów (stanu turbulencji) dla szeregu czasowego danych finansowych wywodzi się z szerszego zagadnienia – prognozowania stanu gospodarki (prognozowania kryzysu). W związku z tym, na początku omawiania budowanej koncepcji podjęto się analizy literatury dotyczącej metod przewidywania stanu kryzysu. Na podstawie wniosków płynących z analizy tej literatury ustalone zostały potencjalne ramy takiego modelu.

Prognozowanie stanu gospodarki jest tematem szeroko dyskutowanym wśród ekonomistów zajmujących się makroekonomią. Umiejętność przewidywania nadchodzącego kryzysu (negatywnego stanu gospodarki – stanu turbulencji) mogłoby pomagać w podjęciu odpowiednich czynności zaradczych przyczyniających się do jego uniknięcia. W związku z tym wielu badaczy podjęło próbę budowy modeli, które mogłyby przewidywać nadchodzący kryzys. Modele te nazywane są modelami EWS (*Early Warning Systems*).

Modele EWS na podstawie informacji sprzed kryzysu mają przewidywać prawdopodobieństwo jego wystąpienia w ciągu określonego czasu od momentu, w którym stan gospodarki był analizowany. Modele tego typu budowane są w oparciu o informacje historyczne dotyczące obserwowanych już kryzysów.

Opierają się one na założeniu, że kryzysy, mimo różnic, posiadają cechy wspólne, które pozwalają je traktować jako (w wymiarze wystarczającym do modelowania) homogeniczne zjawiska. Próbę weryfikacji takiej hipotezy podejmuje w swoim badaniu Kamin (1999). Porównuje on jedynie trzy przypadki (kryzys lat 80 XX wieku, kryzys meksykański lat 1994-95 (tzw. *Tequila Crisis*) oraz kryzys azjatycki lat 1997-98), które nie oddają w pełni całego obrazu. W rzeczywistości można wyróżnić kilka rodzajów kryzysów (np. bankowe, walutowe), które nie tylko nie są podobne, ale również bardzo często nie są zjawiskami niezależnymi i często następują po sobie. W związku z tym, badacze proponując swoje modele EWS najczęściej wybierają jeden z typów kryzysów i próbują modelować specyficzny dla niego system wczesnego ostrzegania (np. kryzysu bankowego m.in. Barrell *i in.* (2010) lub walutowego m.in. Eichengreen *i in.* (1995)). Definicje i klasyfikacje kryzysów nie mają znaczenia z perspektywy budowy modelu przewidywania stanu turbulencji, ponieważ proponowany model ma działać w znacznie krótszym horyzoncie czasowym, dla którego stan turbulencji nie powinien być utożsamiany z kryzysem, a raczej z okresem zwiększonego ryzyka. Ważne jest jednak, aby zapewnić właściwą homogeniczność okresu turbulencji. Tylko wtedy możliwe jest skuteczne prognozowanie wystąpienia tego okresu.

Pomimo różnicy w horyzoncie czasowym między klasycznymi modelami EWS, a modelami proponowanymi w tej pracy, możliwe jest wykorzystanie wiedzy dotyczącej metodyki przewidywania kryzysów za pomocą modelu EWS w trakcie opracowywania modeli stanu turbulencji. Najczęściej stosowanymi do przewidywania kryzysu modelami są modele sygnałów oraz modele regresji logistycznej. Modele te stosowane są między innymi przez Kaminsky *i in.* (1998), Beckmanna *i in.* (2006), Davisa i Karim (2008) oraz Barrella *i in.* (2010).

Na podstawie analizy literatury przedmiotu nie można jednoznacznie stwierdzić, które z proponowanych podejść jest skuteczniejsze w prognozowaniu kryzysu. Każde z nich ma swoje wady i zalety, które sprawiają, że w zależności od okoliczności każde z nich może mieć większą lub mniejszą użyteczność. Można uznać, że model logitowy jest skuteczniejszy w prognozowaniu kryzysu w przypadku rozpatrywania problemów mniej specyficznych, kiedy najważniejsze jest wychwycenie ogólnej zależności między wystąpieniem zdarzenia, a rozpatrywanymi zmiennymi. Natomiast modele sygnałów uznawane są za lepsze, gdy rozpatrywany jest problem bardziej specyficzny. Takie wnioski płyną z badania Davisa i Karim (2008).

Jednym z celów projektowanego modelu jest dostarczenie uniwersalnego narzędzia do przewidywania wystąpienia stanu turbulencji. W tym świetle bardziej użytecznym modelem w tym aspekcie powinien być model ekonometryczny oparty o regresję logistyczną. Wybór modelu logitowego uzasadnia również fakt, że najczęściej wskazywane w literaturze wady tych modeli przedstawione m. in. w Kaminsky *i in.* (1998), czyli brak możliwości określenia relatywnej jakości

isiły wpływu zmiany pojedynczej zmiennej na prawdopodobieństwo pojawienia się kryzysu oraz trudność w określeniu jednoznacznych limitów wskazujących, że zmienna osiąga wartość „podejrzaną” nie mają kluczowego znaczenia dla funkcji jaką ma pełnić model przewidywania stanu turbulencji. Poza tym podejście oparte o model ekonometryczny ma charakter bardziej obiektywny niż podejście sygnałów, ponieważ wybór istotności poszczególnych zmiennych jest niezależny od badacza (z dokładnością do określenia zbioru potencjalnych zmiennych i poziomu istotności testów).

Przy okazji omawiania modeli EWS opartych o modele logitowe warto również opisać jeden z kluczowych problemów związanych z prognozowaniem tego typu modelami. Wynikiem modelu logitowego jest prawdopodobieństwo pojawienia się kryzysu. W celu przejścia z prognozy prawdopodobieństwa wystąpienia kryzysu, na prognozę jego wystąpienia, przyjmuje się określony próg odcięcia dla prawdopodobieństwa wystąpienia kryzysu (*cut-off*), powyżej którego uznaje się, że model prognozuje kryzys. Im wyższy próg odcięcia tym mniej okresów będzie uznane za kryzysowe, co powinno zwiększać udział prawidłowo przewidzianych okresów kryzysowych i jednocześnie ograniczać liczbę okresów fałszywie uznanych za kryzys. Z drugiej jednak strony, im wyższy próg odcięcia, tym częściej okresy kryzysowe zostaną uznane za okresy spokoju. Wybór progu odcięcia jednocześnie determinuje poziom błędu I i II rodzaju prognozy modelu. Z tego powodu wybór optymalnego punktu odcięcia jest bardzo ważnym elementem budowy modelu EWS. Bussiere i Fratzscher (2008) podkreślają, że w modelach wczesnego ostrzegania próg odcięcia powinien być wybierany z uwzględnieniem wysokich kosztów fałszywych sygnałów oraz jeszcze wyższych kosztów wystąpienia kryzysu. Wybór optymalnego progu odcięcia jest problemem niezależnym od horyzontu czasowego, dlatego będzie on również przedmiotem analizy w modelu przewidywania stanu turbulencji.

Podstawowe modele wczesnego ostrzegania mają służyć przewidzeniu kryzysu, z tego powodu najczęstszą perspektywą analizy jest perspektywa roczna lub dwuletnia. Budowany model przewidywania stanu turbulencji ma mieć perspektywę dzienną, czyli przewidywać na podstawie dzisiejszej i historycznej sytuacji gospodarczej jutrzejszy stan, w którym znajdzie się analizowany szereg danych finansowych. Ta różnica w horyzoncie sprawia, że w proponowanym modelu nie ma użytku ze zmiennych, które są wykorzystywane przez poszczególnych badaczy do modeli EWS. Wykorzystywane dane dotyczą zjawisk, które zmieniają się w perspektywie miesięcznej, kwartalnej, a czasami nawet rocznej. Użyteczność takich zmiennych w modelu dla danych dziennych jest bardzo ograniczona, ponieważ rzadko obserwowana byłaby zmiana ich wartości, którą można by tłumaczyć zmienność stanów.

Informacje o możliwych do wykorzystania danych w budowanym modelu prognozowania stanów można pozyskać z badań przedstawionych przez Kim *i in.*

(2004) oraz Oh *i in.* (2006). W swoich badaniach autorzy postulują, że współczesne kryzysy są zbyt dynamiczne, żeby korzystać z danych kwartalnych (lub rzadszych), dlatego modele EWS należy budować w oparciu o dane dzienne. Według nich najlepszą miarą określającą zmienność gospodarki jest indeks giełdowy. Dodatkowo proponują uwzględnić dane dotyczące stóp procentowych oraz kursów walutowych. W badaniach poza szeregi wartości poszczególnych zmiennych, uwzględniane są również szeregi ich stóp zwrotu, średnich kroczących oraz kroczącej wariancji. Proponowany zbiór danych wydaje się być adekwatny do modelowania stanu turbulencji, dlatego na jego podstawie budowany będzie zbiór danych w modelu przewidywania stanów.

Przedstawione badania dotyczące modeli dziennego EWS są mniej użyteczne w trakcie formułowania definicji stanu turbulencji. Wynika to z różnicy w specyfice modelowania prognozy stanu turbulencji dla gospodarki oraz dla analizowanego szeregu czasowego danych finansowych. W przypadku modeli dziennego EWS definicja stanu turbulencji dotyczy ogólnego stanu gospodarki. W modelu prognozowania stanu turbulencji dla szeregu danych finansowych definicja tego stanu powinna być bardziej specyficzna dla analizowanego instrumentu finansowego. Powinna identyfikować okresy, w których sytuacja gospodarki (wyrażona przedstawionymi powyżej zmiennymi niezależnymi) wskazuje na wystąpienie stanu turbulencji dla danego szeregu czasowego danych finansowych.

Z perspektywy zarządzania ryzykiem, najbardziej problematyczne są okresy, w których występują największe straty. Zabezpieczenie się przed ich realizacją wymaga dodatkowych działań, dlatego system zarządzania ryzykiem rynkowym powinien umożliwiać identyfikację okresów o wysokim prawdopodobieństwie wystąpienia największych strat. W związku z tym, rozsądne wydaje się przyjęcie założenia, że okres turbulencji dla danego szeregu danych finansowych powinien identyfikować okresy charakteryzujące się największymi stratami. Wtedy, za pomocą modeli prognozy stanu, powinno być możliwe przewidzenie niekorzystnego okresu i podjęcie odpowiednich czynności w celu zabezpieczenia się przed nadzwyczajnymi stratami.

Przedstawiona powyżej analiza pozwala określić podstawowe ramy modelu przewidywania stanu turbulencji. Na podstawie literatury dotyczącej modeli EWS określony został możliwy do zastosowania model (logitowy) oraz zbiór zmiennych niezależnych. Na jej podstawie należy również podkreślić znaczenie wyboru odpowiedniej definicji stanu turbulencji (homogeniczność zmiennej zależnej w stanie turbulencji) oraz wyboru optymalnego punktu odcięcia. Ponadto, w trakcie powyższej analizy zaproponowana została koncepcja definiowania stanu turbulencji dla projektowanych modeli. Omówione kwestie nie wyczerpują spektrum złożoności problemu, ale pozwalają ustalić podstawowy zbiór założeń, który w trakcie budowy modelu będzie można poszerzyć i uszczegółwić w celu optymalnego wyboru modelu do przewidywania stanu turbulencji.

Założenia modelu

Rozkłady zmiennej zależnej

Zgodnie z wnioskami płynącymi z analizy literatury przedmiotu uznano, że pierwszym z modeli, którego można użyć w celu przewidywania stanu turbulencji jest model regresji logistycznej. Model logitowy można zdefiniować w następujący sposób:

$$y_i^* = \beta * X_i + \varepsilon_i \quad (1)$$

$$y_i = \begin{cases} 1 & \text{jeżeli } y_i^* > 0 \\ 0 & \text{w przeciwnym przypadku} \end{cases} \quad (2)$$

gdzie:

y_i^* – nieobserwowalna zmienna zależna dla obserwacji i ,

β – wektor parametrów opisujących zależność między zmiennymi niezależnymi, a zmienną zależną,

X_i – wektor zmiennych niezależnych dla obserwacji i ,

ε_i – błąd losowy dla obserwacji i pochodzący z rozkładu logistycznego o parametrach (0; 1),

y_i – obserwowalny wynik zjawiska dla obserwacji i .

W przypadku modeli dla zmiennej binarnej równie często zakładane jest, że błąd losowy pochodzi z rozkładu normalnego, wtedy model ten nazywany jest modelem probitowym. Modele logitowe i probitowe są najczęściej stosowanymi modelami dla zmiennej binarnej. Istnieją różne inne modele, które pozwalają rozwiązywać pojawiające się w trakcie analiz problemy, dla których modele logitowy i probitowy mogą być niewystarczające.

Często istotną kwestią w modelowaniu zmiennej binarnej jest brak równomiernego rozłożenia liczebności obserwacji, dla których obserwowana zmienna zależna przyjmuje wartość 1 oraz obserwacji, dla których zmienna przyjmuje wartość 0. Dzieje się tak, ponieważ obserwowane zjawisko jest z natury rzadkie (np. wojna, kryzys). W takim przypadku modele logitowy i probitowy mogą nie opisywać we właściwy sposób zależności między zmienną zależną i zmiennymi niezależnymi (King i Langche 2001).

W badaniu ze względu na nierównowagę liczby obserwacji stanu spokoju i stanu turbulencji zdecydowano się uwzględnić model cloglog. Model cloglog można definiować analogicznie do poprzednich dwóch modeli z tą różnicą, że błąd losowy pochodzi z rozkładu Gomperta.

Wybór tych trzech modeli nie wyczerpuje wszystkich możliwości modelowania zmiennej binarnej, ale powinien być wystarczający do uzyskania odpowiedniej jakości prognoz stanu turbulencji.

Dla opisanych powyżej modeli należy zdefiniować próg odcięcia, który umożliwi podzielenie prognoz prawdopodobieństwa, na prognozy stanu turbulencji oraz prognozy stanu spokoju. W badaniu przyjęto, że analiza optymalnego progu odcięcia będzie przeprowadzona z dokładnością do 0,01. W związku z tym, analizę optymalnego progu odcięcia przeprowadzono dla wartości należących do następującego zbioru:

$$po_i = 0.01 * i, \text{ dla } i = 1, 2, \dots, 100 \quad (3)$$

gdzie:

po_i – wartość i -tego punktu odcięcia.

Wybór optymalnego progu odcięcia przeprowadzono na podstawie kryterium odległości punktu na krzywej ROC od punktu idealnego (kryterium KROC), które opisano w dalszej części pracy.

Powyżej omówiono założenia dotyczące modeli dla zmiennej binarnej, które zostaną rozpatrzone w badaniu. Równie ważna dla wyników modelu (prognoz) jest jakość i adekwatność analizowanego zbioru danych. Dotyczy to zarówno zmiennej zależnej, jak i zmiennych niezależnych. Rozpatrywane w badaniu założenia dotyczące zmiennych przedstawiono w dalszej części artykułu.

Definicja zmiennej zależnej

Celem budowanego modelu jest przewidywanie stanu turbulencji. Aby móc właściwie przewidywać ten stan trzeba go najpierw odpowiednio zdefiniować. Opracowywany model ma przewidywać możliwe realizacje najgorszego scenariusza związanego ze zmianą wartości instrumentu finansowego z perspektywy zarządzania ryzykiem, czyli największego spadku jego wartości. Dlatego stan turbulencji utożsamiany jest z grupą największych spadków ceny danego instrumentu finansowego. W związku z tym, że zmiana ceny ma charakter nieznormalizowany (zależy od aktualnej wartości instrumentu finansowego), bardziej uniwersalną zmienną jest stopa zwrotu z danego instrumentu finansowego. Dla każdego z instrumentów finansowych zdefiniowano cztery różne binarne zmienne zależne. Przyjęto założenie, że zmienna zależna przyjmuje wartość 1, dla 1%, 5%, 10% lub 20% najniższych stóp zwrotu i 0 w pozostałych przypadkach (odpowiednio zmienne zależne P1, P5, P10, P20).

Wybór zmiennych niezależnych

Kolejnym elementem budowy modelu przewidywania stanu turbulencji jest wybór zestawu zmiennych niezależnych. Zestaw zmiennych, który powinien prawidłowo opisywać aktualny stan gospodarki zaproponowali w swoich badaniach Oh *i in.* (2006) oraz Kim *i in.* (2008). Opierając się na przedstawionych przez

autorów założeniach oraz korzystając z wiedzy na temat specyfiki rynku polskiego w badaniu uwzględniono następujące zmienne: indeks giełdowy WIG, kursy euro, dolara i franka szwajcarskiego w stosunku do złotego, a także wysokość stóp procentowych overnight i 3-miesięcznej stopy WIBOR.

Zastosowanie powyższych zmiennymi wyłącznie w postaci nieprzekształconej może nie oddawać pełnej dynamiki aktualnej sytuacji gospodarczej. Korzystając z sugestii przedstawionych przez Kim *i in.*(2008), dla każdej z analizowanych w badaniu zmiennych zdecydowano się uwzględnić dodatkowo następujące wartości: stopę zwrotu, 15-dniową średnią kroczącą ceny i stopy zwrotu oraz 15-dniową wariancję kroczącą ceny i stopy zwrotu.

Wybór 15-dniowego okresu dla wartości kroczących wynikał z jednej strony z chęci zachowania jak największej dynamiki zmian analizowanych elementów, a z drugiej strony z chęci uchwycenia możliwe stabilnych relacji. Uwzględnienie wszystkich przekształceń zmiennych sprawia, że w modelu należy rozpatrzyć 30 potencjalnych zmiennych niezależnych.

Warto zwrócić uwagę na fakt, że część z nich może być silnie współliniowa, co może mieć negatywny wpływ na jakość modelu. W badaniu postanowiono rozpatrzyć trzy możliwe zbiory zmiennych niezależnych: w pierwszym zbiorze uwzględniono wszystkie opisane powyżej zmienne (pomimo potencjalnego problemu współliniowości), w drugim zbiorze uwzględniono główne składowe uzyskane w trakcie analizy PCA (jedno z możliwych rozwiązań problemu współliniowości), a w trzecim zbiorze czynniki uzyskane w trakcie analizy czynnikowej (drugie z możliwych rozwiązań problemu współliniowości).

Przedstawione zbiory proponowanych zmiennych niezależnych mają charakter uniwersalny i mają na celu opisywać aktualny stan gospodarki. Odwrotne założenie zostało przyjęte w przypadku zmiennej zależnej, która dla każdego instrumentu finansowego ma być specyficzna. W związku z tym w modelowaniu należy uwzględnić fakt, że aktualny stan gospodarki (reprezentowany przez zbiór zmiennych niezależnych) może w różny sposób wpływać na prognozę stanu turbulencji dla różnych instrumentów finansowych. Uwzględnienie tej specyfiki polega na możliwości dopasowania się parametrów opisujących zależność między zbiorem zmiennych niezależnych i zmiennej zależnej dla każdego z instrumentów finansowych osobno. Dzięki temu możliwe jest uwzględnienie uniwersalności wynikającej z jednolitego zbioru zmiennych niezależnych oraz specyfiki problemu wynikającej z definicji zmiennej zależnej.

Testowanie modelu

Przedstawiony zbiór możliwych założeń sprawia, że modele przewidywania stanu turbulencji mogą różnić się od siebie w czterech elementach: wyborze rozkładu zmiennej ukrytej (modele logitowy, probitowy, cloglog), definicji zmiennej zależnej

(zmiennie P1, P5, P10, P20), wyborze typu danych wykorzystanych do analizy (dane nieprzekształcone, dane z analizy PCA, dane z analizy czynnikowej) oraz wyborze progu odcięcia (rozpatrzenie 100 możliwych wartości).

Ta różnorodność sprawia, że dla każdego z instrumentów finansowych rozpatrywane jest 3600 różnych kombinacji założeń. W związku z tym zbiór testów powinien być zbudowany w taki sposób, by wychwytywał niedoskonałości maksymalnie dużej liczby kombinacji założeń. W tym celu w badaniu przeprowadzone zostały cztery różne analizy mające ocenić ich jakość: test jakości dopasowania danych do rozkładów ukrytej zmiennej zależnej – test Hosmera-Lemeshowa, test łącznej nieistotności parametrów przy zmiennych niezależnych – test LR, analiza zdolności dyskryminacyjnej modelu – analiza parametru GINI, analiza zdolności prognostycznych modelu – analiza odległości punktu na krzywej ROC od punktu idealnego (kryterium KROC).

Proponowany zbiór analiz pozwoli ocenić poszczególne kombinacje założeń (modele) zarówno z perspektywy spełnienia założeń formalnych (test istotności zmiennych oraz test jakości dopasowania), jak i własności dyskryminacyjnych i prognostycznych (analiza parametru GINI oraz kryterium KROC). Testy LR oraz Hosmera-Lemeshowa są standardowo stosowane do oceny jakości modeli dla zmiennych binarnych. Proponowane miary analizy zdolności dyskryminacyjnej i prognostycznej nie zawsze są stosowane przy takiej ocenie, jednak zyskują na swoim znaczeniu i często stosowane są (na przykład) dla modeli prognozy prawdopodobieństw niewyłącalności.

Parametr GINI służy do analizy zdolności dyskryminacyjnej modelu. Umożliwia analizę na ile stosowany model pozwala rozróżnić rozkłady sukcesów (stanu turbulencji) i porażek (stanu spokoju). Skutecznie działający model, średnio rzecz biorąc, powinien przypisywać duże prawdopodobieństwo sukcesu obserwacjom, które w rzeczywistości są sukcesami i małe prawdopodobieństwo sukcesu obserwacjom, które w rzeczywistości są porażkami.

Kryterium służące do analizy zdolności prognostycznej opiera się na analizie krzywej ROC, która wyznacza relację między dwoma niezależnymi rozkładami. Wyznaczana jest na podstawie warunkowych rozkładów prognozy sukcesu pod warunkiem sukcesu i pod warunkiem porażki. Analizę krzywej ROC (najczęściej) łączy się z dwoma miarami: wrażliwością i specyficnością. Wrażliwość mierzy zdolność modelu do prawidłowego przewidywania sukcesu. Specyficzność definiowana jest natomiast jako stosunek dobrze zaprognozowanych porażek do wszystkich porażek. Miary te wyznaczane są dla obserwacji, które mogą przyjmować wartość 0 lub 1. Oznacza to, że aby móc je wyliczyć, konieczne jest przejście z prognoz prawdopodobieństwa wystąpienia sukcesu na prognozy sukcesu (i porażki). Miary te mogą być określone dla każdego progu odcięcia.

Niezależnie porównywanie modeli na podstawie tych dwóch miar zazwyczaj jest niekonkluzywne, ponieważ jeden z modeli może być lepszy pod względem

wrażliwości, a drugi pod względem specyficzności. W celu uzyskania miary umożliwiającej jednoznaczne porównanie modeli na podstawie tych miar, tworzone są indeksy ważące ich znaczenie. W badaniu zdecydowano się zastosować kryterium minimalizacji odległości między punktem idealnym, a punktem na krzywej ROC (kryterium KROC). Punktem idealnym nazywany jest punkt w górnym prawym rogu wykresu krzywej ROC. W tym punkcie wrażliwość i specyficzność wynoszą 1.

Konstrukcja tej miary opiera się na minimalizacji sumy kwadratów błędów I i II rodzaju. Wartość kryterium KROC można wyliczyć na podstawie następującego wzoru:

$$KROC = \sqrt{\left(\frac{FN}{TP + FN}\right)^2 + \left(\frac{FP}{TN + FP}\right)^2} \quad (5)$$

TP – liczba dobrze zaprognozowanych sukcesów,

TN – liczba dobrze zaprognozowanych porażek,

FP – liczba porażek zaprognozowanych jako sukces,

FN – liczba sukcesów zaprognozowanych jako porażka.

Wybór kryterium KROC jako miary zdolności prognostycznej wynika z faktu, że przy określonej sumie specyficzności i wrażliwości, rozwiązania pośrednie są preferowane względem rozwiązań skrajnych. Z perspektywy celu modelu przewidywania stanów turbulencji, model przewidujący wyłącznie stan turbulencji lub wyłącznie stan spokoju jest mniej atrakcyjny niż model, który przewiduje oba stany.

Zarówno parametr GINI, jak i kryterium KROC nie mają określonych wartości granicznych, które rozdzielałyby modele o wysokiej jakości prognostycznej od modeli o niskiej jakości prognostycznej. Parametr GINI oraz kryterium KROC służą do relatywnego porównania modeli między sobą.

Przedstawiony powyżej zbiór testów formalnych oraz miar dyskryminacji i jakości prognostycznej powinien pozwolić wybrać najlepsze założenia dla modelu przewidywania stanu turbulencji. Opisana procedura testowania składa się z dwóch etapów. Najpierw na podstawie testów formalnych mogą zostać określone zbiory założeń, które mogą być rozpatrywane w dalszej analizie. Następnie na podstawie kryteriów dyskryminacji i jakości prognostycznej mogą zostać wybrane możliwe najlepsze założenia modelu przewidywania stanu turbulencji. Parametr GINI i kryterium KROC mają charakter uniwersalny i pozwalają porównywać modele różniące się dowolnymi założeniami, dlatego na ich podstawie można wskazać możliwie najlepsze zbiory założeń modelu przewidywania stanu turbulencji.

Wyniki badania empirycznego

Badanie empiryczne dotyczące modeli przewidywania stanu turbulencji zostało wykonane dla szeregów stóp zwrotu z pojedynczych akcji. Analizowane były akcje spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie. W ramach badania, weryfikacji empirycznej poddano zdolność opisanych powyżej modeli do przewidywania stanu turbulencji w zależności od przyjętych założeń. W badaniu przeprowadzona została analiza opierająca się na wynikach prognoz stanu turbulencji dla obserwacji, na których model był estymowany (analiza *in-sample*).

Zbiory zmiennych niezależnych i wybór zmiennych zależnych

W badaniu rozpatrzono trzy zbiory zmiennych niezależnych: zbiór danych nieprzekształconych, główne składowe uzyskane z analizy PCA oraz czynniki z analizy czynnikowej. W związku z tym, że zbiór nieprzekształconych zmiennych niezależnych, dla każdego z rozpatrywanych instrumentów finansowych jest taki sam oraz że wszystkie modele budowane były w oparciu o dane z tego samego okresu, zarówno sam zbiór danych nieprzekształconych, jak i wyniki metod redukcji macierzy obserwacji (analiza PCA i analiza czynnikowa) są takie same dla każdego z rozpatrywanych instrumentów finansowych.

Analiza PCA oraz analiza czynnikowa zostały wykonane na wszystkich 30 zmiennych niezależnych. W analizie PCA, na podstawie wykresu osuwiska oraz kryterium Kaisera, zdecydowano się na uwzględnienie 6 głównych składowych. W analizie czynnikowej, na podstawie wykresu osuwiska oraz kryterium wyjaśnienia wariacji, zdecydowano się na uwzględnienie 5 czynników.

Badanie przeprowadzono na 43 różnych zbiorach danych dla zmiennej zależnej. Każdy z nich składał się z obserwacji dotyczących stóp zwrotu z akcji innej spółki notowanej na Giełdzie Papierów Wartościowych w Warszawie (GPW). Spółki zostały dobrane losowo. Na losowanie nałożono jedynie warunek, aby akcje były notowane na GPW co najmniej od stycznia 2006 roku. Badanie dotyczyło okresu od 1 stycznia 2006 roku do 31 stycznia 2012 roku. Spółki, których stopy zwrotu z akcji zostały uwzględnione w badaniu przedstawia tabela 1.

Tabela 1. Spółki, których akcje zostały rozpatrzone w badaniu dotyczącym prognozowania stanu turbulencji.

Lp	Nazwa spółki	Lp	Nazwa spółki	Lp	Nazwa spółki
1	Asseco poland s.A.	16	Ferrum s.A.	31	Projprzem s.A.
2	Ampli s.A.	17	Famur s.A.	32	Opakowania plast-box s.A.
3	Betacom s.A.	18	Instal kraków s.A.	33	Polnord s.A.
4	Bre bank s.A.	19	Kci s.A.	34	Sopharma ad
5	Ceramika nowa gala s.A.	20	Kghm s.A.	35	Stalexport autostrady s.A.
6	Cognor s.A.	21	Kogeneracja s.A.	36	Swissmed centrum zdrowia s.A.
7	Centrozap s.A.	22	Lpp s.A.	37	Tell s.A.
8	Dom development s.A.	23	Mclogic s.A.	38	Trion s.A.
9	Echo investment s.A.	24	Mennica polska s.A.	39	Telekomunikacja polska s.A.
10	Efekt s.A.	25	Mostostal płock s.A.	40	Vistula group s.A.
11	Elektro budowa s.A.	26	Mostostal warszawa s.A.	41	Wasko s.A.
12	Elzab s.A.	27	Mostostal-export s.A.	42	Wilbo s.A.
13	Energomontaż-południe s.A.	28	Mostostal zabrze – holding s.A.	43	Żywiec s.A.
14	Fam gk s.A.	29	Muza s.A.		
15	Farmacol s.A.	30	Nordea bp s.A.		

W tabeli przedstawiono nazwy spółek, których dane o stopach zwrotu z akcji zostały wykorzystane do analizy modeli prognozy stanu turbulencji dla pojedynczych instrumentów finansowych.

Źródło: Opracowanie własne.

Wybór szerokiej gamy instrumentów finansowych, na podstawie których przeprowadzono badanie, powinien umożliwić szczegółową weryfikację poprawności analizowanych zbiorów założeń. Analiza zasadności założeń przyjętych w modelach prognozy stanu turbulencji została wykonana zgodnie z procesem testowania opisanym powyżej. Wyniki przedstawione są w sposób zagregowany, to znaczy jako średni wynik dla wszystkich rozpatrywanych 43 instrumentów finansowych.

Testy formalne

Proces testowania rozpoczęto od przeprowadzenia testu Hosmera-Lemeshowa. Wyniki tego testu wskazują, że w modelu przewidywania stanu turbulencji stosowane mogą być wszystkie z analizowanych rozkładów teoretycznych błędu losowego. Ponadto dla zmiennych P5, P10 i P20 najlepsze wyniki osiągają modele budowane na danych nieprzekształconych. Jedynym wyjątkiem jest zmiennazależna P1, dla której nieznacznie lepsze wyniki osiągają modele oparte o dane z analizy czynnikowej. Test Hosmera-Lemeshowa nie dyskwalifikuje żadnej ze zmiennych zależnych, chociaż najslabsze wyniki uzyskiwane są dla zmiennej P1.

Następnym etapem procesu testowania założeń modelu przewidywania stanu turbulencji była analiza wyników testu LR. Na ich podstawie zauważono, że zestawy zmiennych niezależnych otrzymanych w trakcie analizy PCA oraz analizy czynnikowej są znacznie częściej nieistotne niż zestaw zmiennych nieprzekształconych. Ponadto, wyniki testu LR dla poszczególnych definicji zmiennej zależnej wskazują, że analizowane zestawy zmiennych niezależnych mają najczęściej łączny istotny wpływ w przypadku zmiennych zależnych P5 oraz P10. Zauważono również, że wyniki testu LR, podobnie jak wyniki testu Hosmera-Lemeshowa nie wskazują w istotny sposób wyższości któregoś z rozkładów błędu losowego. Wszystkie modele (logitowy, probitowy i cloglog) są równie dobre w ocenie tego testu.

W dalszej części badania poddano analizie zdolność dyskryminacyjną oraz prognostyczną modelu stanu turbulencji.

Analiza parametru GINI

Wyniki analizy parametru GINI zawiera tabela 2. Przedstawiono w niej średnie wartości tego parametru dla modeli prognozowania stanu turbulencji opartych o dane nieprzekształcone, różne rozkłady błędu losowego oraz różne definicje zmiennej zależnej. W tabeli pominięto wyniki dla modeli estymowanych na zbiorach głównych składowanych oraz czynników. Wynika to z faktu, że ocena zdolności dyskryminacyjnej dla modeli opartych o różne typy danych wyraźnie wskazuje, że zdolność dyskryminacji dla danych nieprzekształconych jest istotnie większa niż dla danych uzyskanych przy użyciu metod redukcji wymiaru zbioru zmiennych niezależnych.

Na podstawie tych wyników można wyciągnąć wniosek, że wykorzystanie głównych składowych lub czynników do budowy modelu prognozy stanu turbulencji pogarsza jego zdolność dyskryminacyjną. Można przypuszczać, że mimo rozwiązania problemu współliniowości między zmiennymi niezależnymi, zastosowanie metod redukcji wymiaru zbioru zmiennych niezależnych, prowadzi do pogorszenia jakości informacji przechowywanej w tym zbiorze.

Na podstawie wyników przedstawionych w tabeli 2 można stwierdzić, że modele charakteryzują się tym większą zdolnością dyskryminacyjną, im mniejszy jest obszar definiujący stan turbulencji. Zdecydowanie największą zdolność dyskryminacyjną mają modele dla zmiennej zależnej P1, modele dla zmiennych P5 i P10 charakteryzują się umiarkowaną, a modele dla zmiennej P20 zdecydowanie najniższą zdolnością dyskryminacyjną. Można z tego wyciągnąć wniosek, że im bardziej skrajne realizacje stóp zwrotu tym sytuacja na rynku w dniu poprzedzającym jest bardziej do siebie podobna i istotnie różni się od warunków w zdefiniowanym stanie spokoju. Na podstawie informacji o sytuacji rynkowej łatwiej jest rozpoznać skrajne realizacje stóp zwrotu, co oznacza, że rozszerzanie definicji stanu turbulencji zwiększa szum informacyjny. Warto jednak pamiętać również o ryzyku, które niesie zbyt wąskie definiowanie stanu turbulencji. Może się okazać, że tak wysoka wartość parametru GINI dla zmiennej P1 nie wynika z odtworzenia faktycznej zależności między sytuacją w gospodarce a realizacją stanu turbulencji, a jedynie ze zbyt dobrego dopasowania się wyników do obserwowanego zbioru. W takim wypadku może się okazać, że model, który na podstawie analizy *in-sample* działa poprawnie, w rzeczywistości będzie działał znacznie gorzej. W celu weryfikacji poziomu dopasowania się modelu do danych, stosowana jest weryfikacja próby *out-of-sample*. Przeprowadzenie analizy tego typu może być ciekawym rozszerzeniem opisywanego badania.

Podobnie jak w przypadku testów formalnych, parametr GINI przyjmuje zbliżone wartości dla wszystkich trzech rozpatrywanych założeń dotyczących rozkładu błędu losowego. Zależność ta jest potwierdzona dla każdej z definicji zmiennej zależnej. Co prawda, we wszystkich przypadkach średnia wartość parametru GINI jest największa dla modelu probitowego, ale różnice są bardzo niewielkie. Ostatecznie należy uznać, że z perspektywy oceny zdolności dyskryminacyjnej, każdy z zakładanych rozkładów błędów losowych jest równie dobry.

Tabela 2. Analiza parametru GINI dla modeli opartych o dane nieprzekształcone, różne rozkłady błędu losowego oraz różne definicje zmiennej zależnej.

Zm. Zal.	Model	Rodzaj danych	GINI
P1	CLOGLOG	Nieprzekształcone	0.853
P1	LOGIT	Nieprzekształcone	0.859
P1	PROBIT	Nieprzekształcone	0.877
P5	CLOGLOG	Nieprzekształcone	0.521
P5	LOGIT	Nieprzekształcone	0.526
P5	PROBIT	Nieprzekształcone	0.536
P10	CLOGLOG	Nieprzekształcone	0.379
P10	LOGIT	Nieprzekształcone	0.384

P10	PROBIT	Nieprzekształcone	0.388
P20	CLOGLOG	Nieprzekształcone	0.245
P20	LOGIT	Nieprzekształcone	0.248
P20	PROBIT	Nieprzekształcone	0.249

W tabeli przedstawiono średnią wartość parametru GINI dla modeli prognozy stanu turbulencji różniących się zakładanym rozkładem błędu losowego, zbiorem zmiennych niezależnych oraz definicją zmiennej zależnej. W tabeli zastosowano następujące skróty: nieprzekształcone – zbiór nieprzekształconych zmiennych niezależnych, Zm. Zal. – definicja zmiennej zależnej, P1 – stan turbulencji definiowany jest jako 1% najgorszych realizacji stóp zwrotu z analizowanego instrumentu finansowego, P5 – stan turbulencji definiowany jest jako 5% najgorszych realizacji stóp zwrotu z analizowanego instrumentu finansowego, P10 – stan turbulencji definiowany jest jako 10% najgorszych realizacji stóp zwrotu z analizowanego instrumentu finansowego, P20 – stan turbulencji definiowany jest jako 20% najgorszych realizacji stóp zwrotu z analizowanego instrumentu finansowego.

Źródło: Opracowanie własne.

Na podstawie wyników uzyskanych w trakcie przeprowadzania testów formalnych oraz analizy zdolności dyskryminacyjnej wyciągnięto następujące wnioski:

Wszystkie rozkłady teoretyczne błędu losowego mogą być stosowane do budowy modelu prognozowania stanu turbulencji – jakość modeli logitowego, probitowego i cloglog (*ceteris paribus*) nie różnią się znacząco,

Dane nieprzekształcone osiągają zdecydowanie lepsze wyniki niż dane z analizy czynnikowej i analizy PCA, w związku z tym w dalszej analizie uwzględniane będą jedynie dane nieprzekształcone,

Modele, w których zmienna zależna zdefiniowana jest jako 20% najgorszych realizacji stóp zwrotu osiąga zdecydowanie gorsze wyniki powyższych analiz niż modele dla pozostałych rozpatrywanych zmiennych zależnych. Z tego powodu modele dla zmiennej zależnej P20 zostaną wyłączone z dalszej analizy.

Proces testowania jakości modeli prognozy stanu turbulencji zakończony został analizą zdolności prognostycznej, która oceniona była na podstawie opisanego powyżej kryterium KROC.

Analiza kryterium KROC

Podstawowym celem stawianym przed proponowanymi modelami jest jak najlepsza prognoza stanu turbulencji. Analiza kryterium KROC ma kluczowe znaczenie, ponieważ pozwala ocenić, dla jakiego progu odcięcia definiującego

prognozy stanu turbulencji, model charakteryzuje się największą zdolnością prognostyczną (dla testów formalnych oraz wartości parametru GINI wybór punktu odcięcia nie ma znaczenia, ponieważ analizy te odbywają się przed etapem określenia jego optymalnej wartości).

Wyniki analizy kryterium KROC w rozbiciu na modele estymowane na zbiorze danych nieprzekształconych dla poszczególnych rozkładów teoretycznych błędu losowego przy założonej definicji stanu turbulencji oraz założonym punkcie odcięcia przedstawia tabela 3. Zawiera ona średnie odległości punktu na krzywej ROC od punktu idealnego dla modeli w zależności od przyjętych założeń. Im wartość kryterium KROC niższa tym lepsza ocena zdolności prognostycznej. W poniższych tabelach przedstawiono wyniki dla punktów odcięcia, dla których kryterium KROC przyjmuje średnio najmniejsze wartości.

Analizując zawarte w tabeli wartości można zauważyć, że średnia wartości kryterium KROC w optymalnym punkcie odcięcia jest istotnie mniejsza (lepsza) dla zmiennej zależnej P1 (0.185-0.203) niż średnia wartość dla zmiennych P5 (0.412-0.418) i P10 (0.482-0.487). Ponadto, wartości dla zmiennych P5 i P10 są do siebie bardzo zbliżone.

Wyniki dla poszczególnych rozkładów teoretycznych błędu losowego nie różnią się od siebie w sposób istotny, mimo, że dla optymalnych punktów odcięcia zawsze minimalnie najlepszy wynik osiąga model probitowy. Rozpatrując średnie wyniki kryterium KROC dla różnych rozkładów teoretycznych błędu losowego należy uznać, że wyniki dla modeli cloglog, logitowego i probitowego są w zasadzie nierozróżnialne.

Na podstawie uzyskanych wyników kryterium KROC można zauważyć ciekawą prawidłowość. Najniższe wartości tego kryterium osiągane są, gdy próg odcięcia definiujący prognozę stanu turbulencji równy jest progowi definiującemu zmienną zależną. Oznacza to, że średnio rzecz biorąc, dla zmiennej zależnej P1 optymalny próg odcięcia równa się 0,01, dla zmiennej P5 równa się 0,05, a dla zmiennej P10 równa się 0,1.

Tabela 3. Wybór optymalnego punktu odcięcia dla modeli opartych o dane nieprzekształcone oraz 1%, 5% i 10% definicję stanu turbulencji.

Typ danych	Zmienna Zależna	Próg Odcięcia	KROC CLOGLOG	KROC LOGIT	KROC PROBIT
Nieprzekształcone	P1	0.01	0.203	0.202	0.185
Nieprzekształcone	P1	0.02	0.245	0.236	0.205
Nieprzekształcone	P1	0.03	0.307	0.294	0.246
Nieprzekształcone	P1	0.04	0.326	0.320	0.293
Nieprzekształcone	P1	0.05	0.369	0.363	0.345
Nieprzekształcone	P1	0.06	0.404	0.388	0.377

Nieprzekształcone	P1	0.07	0.417	0.409	0.413
Nieprzekształcone	P1	0.08	0.438	0.426	0.434
Nieprzekształcone	P1	0.09	0.469	0.449	0.455
Nieprzekształcone	P1	0.1	0.490	0.476	0.497
Nieprzekształcone	P5	0.01	0.817	0.809	0.782
Nieprzekształcone	P5	0.02	0.639	0.634	0.622
Nieprzekształcone	P5	0.03	0.510	0.506	0.503
Nieprzekształcone	P5	0.04	0.438	0.433	0.432
Nieprzekształcone	P5	0.05	0.418	0.414	0.412
Nieprzekształcone	P5	0.06	0.436	0.432	0.424
Nieprzekształcone	P5	0.07	0.468	0.462	0.449
Nieprzekształcone	P5	0.08	0.501	0.493	0.486
Nieprzekształcone	P5	0.09	0.537	0.534	0.530
Nieprzekształcone	P10	0.06	0.637	0.633	0.631
Nieprzekształcone	P10	0.07	0.571	0.569	0.569
Nieprzekształcone	P10	0.08	0.523	0.521	0.522
Nieprzekształcone	P10	0.09	0.496	0.493	0.493
Nieprzekształcone	P10	0.1	0.487	0.482	0.482
Nieprzekształcone	P10	0.11	0.500	0.496	0.492
Nieprzekształcone	P10	0.12	0.524	0.519	0.515
Nieprzekształcone	P10	0.13	0.547	0.544	0.540
Nieprzekształcone	P10	0.14	0.577	0.573	0.567
Nieprzekształcone	P10	0.15	0.609	0.599	0.599

W tabeli przedstawiono analizę wyboru optymalnego punktu odcięcia ze względu na wartości kryterium KROC. Ocena została wykonana dla modeli prognozy stanu turbulencji z 1% , 5% oraz 10% definicją stanu turbulencji, budowanych na danych nieprzekształconych i różniących się zakładanym rozkładem błędu losowego. Prezentowane wyniki dotyczą progów odcięcia w okolicy minimum średniej wartości kryterium KROC.

Źródło: Opracowanie własne.

Podsumowanie

W powyższym badaniu rozpatrzono wiele możliwych kombinacji założeń dotyczących modelu przewidywania stanu turbulencji. Badano jaki wpływ na jakość modelu mają założenie o rozkładzie teoretycznym błędu losowego, definicja zmiennej zależnej, grupa analizowanych zmiennych niezależnych oraz wybór progu odcięcia definiującego stan turbulencji.

Na podstawie uzyskanych wyników ustalono, że wybór teoretycznego rozkładu błędu losowego spośród rozkładu normalnego, logistycznego i Gompertza nie ma znaczenia dla jakości modelu (wszystkie założenia są równie dobre). Pokazano również, że wyraźnie słabsze wyniki osiągają modele oparte o zmienną zależną P20 oraz modele budowane na głównych składowych pochodzących z analizy PCA lub czynnikach pochodzących z analizy czynnikowej. Zauważono również, że przeciętnie rzecz biorąc optymalny próg odcięcia jest równy procentowemu udziałowi obserwacji definiujących stan turbulencji.

Na podstawie wyników procesu testowania wykonanej na próbie *in-sample* dla modeli opartych o pojedyncze instrumenty finansowe, zbiór 3600 różnych kombinacji założeń modelu prognozy stanu turbulencji został ograniczony do 9 możliwych kombinacji, które dostarczają relatywnie najlepszych modeli prognozy stanu turbulencji według rozpatrywanych kryteriów. Przedstawiono je w tabeli 4.

Tabela 4. Zbiór optymalnych założeń modelu przewidywania stanu turbulencji. Analiza dla pojedynczych instrumentów finansowych.

Zmienna zależna	Próg odcięcia	Rozkład błędu	Typ danych
P10	10%	LOGIT	Nieprzekształcone
P10	10%	PROBIT	Nieprzekształcone
P10	10%	CLOGLOG	Nieprzekształcone
P5	5%	LOGIT	Nieprzekształcone
P5	5%	PROBIT	Nieprzekształcone
P5	5%	CLOGLOG	Nieprzekształcone
P1	1%	LOGIT	Nieprzekształcone
P1	1%	PROBIT	Nieprzekształcone
P1	1%	CLOGLOG	Nieprzekształcone

W tabeli przedstawiono 9 kombinacji założeń, które na podstawie wyników przeprowadzonego badania, powinny definiować wysokiej jakości modele prognozowania stanów turbulencji.

Źródło: Opracowanie własne.

Ze względu na różnice w horyzoncie analizy oraz istotnie różną specyfikę analizowanego modelu przewidywania stanu turbulencji i modeli opracowywanych przez autorów w omówionych wcześniej badaniach, trudno bezpośrednio porównywać uzyskane wyniki z wynikami uzyskanymi dla modeli EWS. Mimo to, warto odnieść ogóle wnioski uzyskane w badaniu do wniosków płynących z przytoczonych badań.

Po pierwsze warto zauważyć, że wyniki badania potwierdzają wnioski płynące z badań Eichengreena *i in.* (1995), Kaminsky *i in.* (1998) Beckmanna *i in.* (2006)

Davisa i Dilurby (2008), Bussiere i Fratzschera (2008) oraz Barreła *i in.* (2010), w których modele dla binarnej zmiennej zależnej uznawane są jako adekwatne do prognozowania stanu turbulencji (stanu kryzysu). Istotne znaczenie ma również wybór optymalnego punktu odcięcia definiującego w modelu stan turbulencji, podobnie jak w badaniu Bussiere i Fratzschera (2008).

Po drugie w badaniu potwierdzono również wnioski płynące z badań Oh *i in.* (2006) oraz Kim *i in.* (2008) dotyczące zbioru zmiennych niezależnych, który może służyć do przewidywania stanu turbulencji. Uwzględnienie zmiennych opisujących sytuację na rynku akcji, kursów walutowych oraz stóp procentowych powinno umożliwić skuteczne prognozowanie stanu turbulencji.

Wydaje się, że modele prognozy stanu turbulencji zbudowane zgodnie z opisanym w badaniu schematem mogą dostarczać prognozy stanu turbulencji o wysokiej jakości i dzięki temu umożliwiać wykorzystanie ich w procesie zarządzania ryzykiem w instytucji finansowej. Modele, określone w tabeli 4, nie tylko spełniają wymogi formalne, ale również charakteryzują się relatywnie wysoką zdolnością prognostyczną oraz dyskryminacyjną. Jakość uzyskiwanych na ich podstawie prognoz stanu turbulencji pozwala wierzyć, że mogą one być skutecznym narzędziem do generowania sygnałów uruchamiających bardziej restrykcyjne procesy kontrolne lub zwiększające zabezpieczenia na wypadek wystąpienia nadzwyczajnych strat.

Bibliografia

- Anderson R. (2007) *Module C Stats and maths*, [w:] *The Credit Scoring Toolkit: Theory and Practice for Retail Credit Risk Management and Decision Automation*, Oxford University Press.
- Barrell R., Davis P., Karim D., Liadze I. (2010) Bank regulation, property prices and early warning systems for banking crises in OECD countries, *Journal of Banking & Finance* 34(9), s. 2255-2264.
- Beckmann D., Menkhoff L., Sawischlewski K. (2006) Robust lessons about practical early warning systems, *Journal of Policy Modeling* 28(2), s. 163-193.
- Bussiere M., Fratzscher M. (2008) Low probability, high impact: Policy making and extreme events, *Journal of Policy Modeling* 30(1), s. 111-121.
- Davis P., Karim D. (2008) Comparing early warning systems for banking crises, *Journal of Financial Stability* 4(2), s. 89-120.
- Eichengreen B., Rose A., Wyplosz Ch., Dumas B., Weber A. (1995) Exchange Market Mayhem: The Antecedents and Aftermath of Speculative Attacks, *Economic Policy* 10(21), s. 249-312.
- Hosmer D., Hosmer T., Lemeshow S. (1997) A Comparison Of Goodness-Of-Fit Tests For The Logistic Regression Model, *Statistics in Medicine* 16(9), s. 965-980.

- Hosmer D., Lemeshow S. (2000) Chapter 5. Assessing the Fit of the Model, [w:] *Applied Logistic Regression*. Second Edition, John Wiley & Sons.
- Kaiser H. (1970) A Second Generation Little Jiffy, *Psychometrika* 35(4), s. 401-415.
- Kamin S. (1999) The current international financial crisis: how much is new?, working paper, Board of Governors of the Federal Reserve System International Finance.
- Kaminsky G., Lizondo S., Reinhart C. (1998) Leading indicators of currency crises, working paper, IMF Staff Papers.
- Kim H.-J. (2008) Common Factor Analysis Versus Principal Component Analysis: Choice for Symptom Cluster Research, *Asian Nursing Research* 2(1), s. 17–24.
- Kim T.Y., Hwang Ch., Lee J. (2004) Korean Economic Condition Indicator Using a Neural Network Trained on the 1997 Crisis, *Journal of Data Science* 2, s. 371-381.
- King G., Langche Z. (2001) Logistic Regression in Rare Events Data, *Political Analysis* 9, s. 137–163.
- Oh K.J., Kim T.Y., Kim Ch. (2006) An early warning system for detection of financial crisis using financial market volatility, *Expert Systems* 23, s. 83-98.
- Steyerberg E., Van Calster B., Pencina M. (2011) Performance Measures for Prediction Models and Markers: Evaluation of Predictions and Classifications, *Revista Espanola de Cardiologia (English Edition)* 64(9), s. 788-794.
- Tasche D. (2008) Validation of internal rating systems and PD estimates. [w:] *The Analytics of Risk Model Validation*, Academic Press.

One-day prediction of state of turbulence for financial instrument based on models for binary dependent variable

Abstract

This paper proposes an approach to predict states (states of tranquility and turbulence) for a financial instrument in a one-day horizon. The prediction is made using 3 different models for a binary variable (LOGIT, PROBIT, CLOGLOG), 4 definitions of a dependent variable (1%, 5%, 10%, 20% of worst realization of returns), 3 sets of independent variables (untransformed data, PCA analysis and factor analysis). Additionally an optimal cut-off point analysis is performed. The evaluation of the models was based on the LR test, Hosmer-Lemeshow test, GINI coefficient analysis and KROC criterion based on the ROC curve.

Nine combinations of assumptions have been chosen as appropriate (any model for a binary variable, the dependent variable defined as 1%, 5% or 10% of worst realization of returns, untransformed data, 1%, 5% or 10% cut-off point respectively). Models built on these assumptions meet all the formal requirements and have a high predictive and discriminant ability.

Key words: forecasting, state of turbulence, state switching models, binary dependent variable models (LOGIT, PROBIT, CLOGLOG), market risk.

