Tomasz Jastrzębski*

Zastosowanie symulacji Monte Carlo z korektą Imana-Conovera w pomiarze ryzyka systemowego

Wstęp

Ryzyko systemowe może być rozumiane jako możliwość wystąpienia wielu jednoczesnych nieprawidłowości w funkcjonowaniu dużych instytucji finansowych [Huang i inni, 2009]. Kwestia jego definiowania oraz pomiaru nabrała szczególnego znaczenia w okresie ostatniego kryzysu finansowego w latach 2007–2009. Jako główne źródło tego kryzysu wskazuje się między innymi na rosnący poziom zadłużenia państw, zarówno na poziomie makro-, jak i mikroekonomicznym. W związku z powyższym pierwszą reakcją Parlamentu Europejskiego było rozpoczęcie prac nad zmianą uregulowań związanych z funkcjonowaniem sektora finansowego [Basel Committee on Banking Supervision, 2011]. Efektem tych prac jest wprowadzony 26 czerwca 2013 r. (a obowiązujący od 1 stycznia 2014 r.) pakiet CDR IV/CRR, składający się z dyrektywy Capital Requirements Directive IV oraz rozporządzenia Capital Requirements Regulation, mający za zadanie zwiększenie bezpieczeństwa systemu finansowego, zarówno na poziomie całego systemu, jak i indywidualnego podmiotu. W związku z wprowadzeniem nowych regulacji ostrożnościowych nasuwa się więc pytanie: jak zmiana tych uwarunkowań prawnych wpłynie na poziom wrażliwości ekspozycji na ryzyko podmiotów z sektora bankowego?

Złożoność i zmienność ram teoretycznych i sposobu pomiaru ryzyka systemowego powoduje, że niezwykle trudne jest określenie i kwantyfikowanie czynników ryzyka systemowego w sektorze bankowym[1]. Dodatkowo w swej istocie ryzyko to ma naturę zdarzenia rzadkiego i tym samym nie mają zastosowania miary klasyczne. Uzupełniając to spostrzeżenie o fakt braku danych oraz ich niską częstotliwość, można dojść do wniosku o konieczności zastosowania metod symulacyjnych, których zaletą jest możliwość projektowania różnych scenariuszy wydarzeń.

* Mgr, Katedra Ekonometrii, Wydział Zarządzania, Uniwersytet Gdański, ul. Armii Krajowej 101, 81-824 Sopot, tomasz.jastrzebski@ug.edu.pl

[1] Ryzyko systemowe – mimo że może być spowodowane przez inne rodzaje ryzyka, np. kredytowe lub płynności – różni się od innych rodzajów ryzyka, ponieważ identyfikowane jest poprzez skutki, a nie źródło [Kabza, 2012, s. 3]. Jest dynamiczne i ewoluuje, co z kolei wynikać może ze zmieniających się regulacji prawnych sektora bankowego.

Celem artykułu jest przeprowadzenie symulacji mierników ryzyka systemowego zdefiniowanych jako odległość między różnymi stanami wartości wskaźników a ich wartościami wzorcowymi i antywzorcowymi. W związku z tak sformułowanym celem postawiono hipotezę badawczą, iż wraz ze wzrostem poziomu ryzyka systemowego obserwowana jest większa wrażliwość wartości oczekiwanych wskaźników niż ich wariancji. Jako narzędzie w procesie weryfikacji hipotezy badawczej w zaprojektowanym eksperymencie użyta została symulacja Monte Carlo z korektą Imana-Conovera.

1. Problemy pomiaru ryzyka systemowego

System bankowy od zawsze był ważnym sektorem uzupełniającym gospodarkę, gdyż główną rolą systemu bankowego jest pośrednictwo finansowe między podmiotami gospodarczymi. Umożliwiając alokację środków podmiotom posiadającym nadwyżki finansowe przy jednoczesnym udostępnianiu tych środków podmiotom mającym problemy płynnościowe, system bankowy przyczynia się do znacznego zwiększenia efektywności wykorzystania zasobów gospodarki jako całości. Jednak system bankowy nie jest tworem idealnym i co pewien czas można zaobserwować efekty nasileń nieprawidłowości w jego działaniu, które nazywamy mianem kryzysów finansowych. Te anomalie w ciągu ostatnich kilkudziesięciu lat przybierały coraz większe rozmiary, doprowadzając do tak zwanego efektu przelewania (*spillover effect*), czyli transmisji kryzysu z sektora finansowego na pozostałe sektory gospodarki, a w dobie globalizacji również na gospodarki innych krajów [Hellwig, 2009]. Mając na uwadze powyższe przesłanki, organy nadzoru finansowego i banki centralne zaczęły skupiać swoją uwagę na monitorowaniu i regulowaniu sektora bankowego jako całości. Ich rozporządzenia były w przeszłości skupione na zapewnieniu stabilności poszczególnych banków, natomiast po kryzysie na rynku dot-com pojawiły się tendencje do koncentrowania się na zapewnieniu stabilności całego systemu bankowego, które w literaturze przedmiotu są znane jako perspektywy makroostrożnościowe regulacji bankowych [Borio, 2003]. Wskaźniki dedykowane pomiarowi ryzyka systemowego zaczęły być konstruowane zarówno na poziomie indywidualnym, jak i zagregowanym, przy czym uwzględnia się również korelacje pomiędzy portfelami aktywów banków [Lehar, 2005]. Spotykane są też konstrukcje wskaźników opartych nie o dane z bilansów banków, ale o dane z rynku, takie jak *credit default swaps* (CDS) i ceny akcji banków [Huang i inni, 2009]. Prowadzone są również badania nad wpływem niepokojów na rynkach finansowych na sferę gospodarki realnej [Acharya i inni, 2010]. Konstruowane są wskaźniki ryzyka systemowego, które agregują informacje dotyczące recesji spośród

indywidualnych wskaźników pochodzących z rynku w oparciu o regresję kwantylową [Giglio i inni, 2016]. W literaturze przedmiotu można znaleźć przykłady badań poświęconych ryzyku systemowemu, w których wykorzystano metody symulacyjne. Przykładowo w opracowaniu [Brämer i inni, 2014] przedstawiono zastosowanie modelu sieciowego, w którym zależności między instytucjami finansowymi wyrażone są przez wielkość wzajemnych zobowiązań i kolejno przeprowadzono symulacje polegające na eksperymentalnym wprowadzeniu szoku obejmującego jedną instytucję i badaniu, jak wpływa to na poziom wrażliwości całego systemu w postaci bankructwa pozostałych instytucji w następnych okresach.

2. Symulacje

Metody symulacyjne są szeroko stosowaną grupą narzędzi służących do badania złożonych związków między zmiennymi, także w naukach ekonomicznych. Ich niewątpliwą zaletą jest bezkosztowa możliwość odtworzenia warunków charakterystycznych dla danego zjawiska lub obiektu przy użyciu modelu matematycznego z wykorzystaniem programu komputerowego. Można wskazać jedną z definicji, w której eksponowana jest jej rola w procesie modelowania: „podstawą jej (metody symulacyjnej – przyp. autora) jest modelowanie statystycznego eksperymentu za pomocą środków techniki obliczeniowej i rejestracja charakterystyk liczbowych otrzymanych z tego eksperymentu" [Buslenko i inni, 1967, s. 5]. Symulacje dają zatem nie tylko możliwość analizy badanego zjawiska bez ingerencji w jego stan, ale również wirtualnego projektowania skutków odejścia od typowego przebiegu danego zjawiska i analizy różnych wariantów jego przebiegu.

Podejmując się próby klasyfikacji metod symulacyjnych, można wskazać, iż najważniejszym kryterium ich podziału jest występowanie elementu losowości w modelu przedstawiającym dane zjawisko. W związku z powyższym można wyróżnić:

1. Metody deterministyczne, w których stan symulowanego zjawiska jest w sposób jednoznaczny i powtarzalny przypisany do wartości zmiennych danych na wejściu, pozyskanych empirycznie lub podlegających regułom założonych teoretycznych scenariuszy, co oznacza że nie zawiera elementu losowości. W naukach ekonomicznych są one rzadko wykorzystywane ze względu na dużą złożoność systemów ekonomicznych i występujących w nich elementów losowych.
2. Metody stochastyczne, w których uwzględnia się składnik losowy wraz z właściwościami jego rozkładu, bądź jakiś inny element losowości (metody repróbkowania). Są to metody najczęściej

wykorzystywane, głównie ze względu na fakt, że wiele zjawisk jest niezwykle złożona. Do stochastycznych metod symulacyjnych zaliczamy:

– metody nieparametryczne (np. *jackknife*, *bootstrap*), używane gdy nie mamy pewności co do rozkładu prawdopodobieństwa badanych zmiennych, na przykład z powodu dysponowania małą próbą. Wnioskowanie statystyczne jest wtedy przeprowadzane nie na próbie, ale na sztucznie utworzonej populacji generalnej, której elementy są w określony sposób wylosowywane ze znanej próby;
– metody parametryczne, które określa się mianem metod Monte Carlo [Jermakow, 1976]. Można je określić jako metody polegające na generowaniu zmiennych losowych o założonym rozkładzie prawdopodobieństwa w celu oszacowania parametrów rozkładów uzależnionych od nich zmiennych losowych. Użycie tej metody polega zazwyczaj na konstrukcji takiego procesu losowego, którego parametry rozkładu równe są szukanym wielkościom dla danego zagadnienia. Metoda ta, rozwijana od 1949 r.[2], znalazła wiele zastosowań, takich jak: numeryczne obliczanie całek (w tym wielokrotnych), czy rozwiązywanie zadań masowej obsługi i wiele innych. Istnieją różnorodne rozwinięcia tej metody poprawiające jej właściwości w określonych przypadkach. Są to między innymi: próbkowanie warstwowe stosowane w przypadku populacji charakteryzującej się dużym zróżnicowaniem oraz jej rozwinięcie na przypadek wielowymiarowy, czyli próbkowanie hipersześcianu łacińskiego, korekta Imana-Conovera [Iman, Conover, 1982] pozwalająca wprowadzić do wygenerowanego wektora losowego pożądaną macierz korelacji przy zachowaniu rozkładów brzegowych zmiennych losowych będących jego składowymi, czy metody wykorzystujące teorię kopuł [Haas, 1999].

3. Metodyka badania

3.1. Definicja zmiennych kontrolnych, miary ryzyka

Niech $X = (X_1, X_2, X_3, X_4)$ będzie wektorem losowym o składowych będących zmiennymi kontrolnymi procesu ekspozycji na ryzyko systemowe. Składowymi tego wektora są zmienne dobrane w taki sposób, aby możliwe było przy ich użyciu monitorowanie ekspozycji danego obiektu na ryzyko systemowe.

Miarami ryzyka w proponowanym podejściu do pomiaru ryzyka systemowego będą: wartość oczekiwana wektora losowego, którego składowymi

[2] Metoda Monte Carlo została opracowana w latach 1943–1945 przez Stanisława Ulama i zastosowana do modelowania wyniku zderzenia cząstki o wysokiej energii z jądrem złożonym, przyczyniając się tym samym do konstrukcji bomby atomowej.

są zmienne losowe reprezentowane przez wybrane wskaźniki, czyli $E(X) = (E(X_1), E(X_2),\ldots, E(X_N))$, gdzie $E(X_i)$ są całkami jednowymiarowego rozkładu brzegowego w granicach $\langle d_i, g_i\rangle$, $i = 1, 2,\ldots, N$, oraz wariancja wektora losowego X, będąca wektorem wariancji każdego z tych wskaźników czyli $Var(X) = (Var(X_1), Var(X_2),\ldots, Var(X_N))$, gdzie $Var(X_i)$ są całkami jednowymiarowego rozkładu brzegowego w granicach $\langle d_i, g_i\rangle$, $i = 1, 2,\ldots, N$ [Zemke, 2009].

3.2. Stany ryzyka, unormowane stany ryzyka, konstrukcja wektora ryzyka

Niech dla każdego $\langle d_i, g_i\rangle$, $i = 1, 2,\ldots, N$ przedział $\langle d_i^w, g_i^w\rangle$ oznacza wzorcowy, czyli pożądany przez decydenta przedział zmienności i-tej zmiennej kontrolnej. Natomiast $\langle d_i^{aw}, g_i^{aw}\rangle$ niech oznacza dla każdego $i = 1, 2,\ldots, N$ antywzorcowy, czyli uznany przez decydenta za zagrażający realizacji celów strategicznych przedział zmienności i-tej zmiennej kontrolnej. Wtedy wzorzec wektora wartości oczekiwanych $E^w(X)$ jest wektorem składowych $E^w(X_i)$, będących całkami jednowymiarowego rozkładu brzegowego w granicach $\langle d_i^w, g_i^w\rangle$ dla $i = 1, 2,\ldots, N$. Podobnie definiowany jest wzorzec wektora wariancji $Var^w(X)$ jako wektor składowych $Var^w(X_i)$. Analogicznie skonstruowane są $E^{aw}(X)$, $Var^{aw}(X)$, czyli odpowiednio antywzorzec wektora wartości oczekiwanych oraz antywzorzec wektora wariancji.

Aby zbudować wektor ryzyka, należy skonstruować miarę informującą, w jakim stopniu realizowane są założenia strategiczne w danej fazie kontroli. Oznaczmy zatem $E^{(t)}(X)$, $Var^{(t)}(X)$ jako odpowiednio wartość oczekiwaną i wariancję w t-tej fazie kontroli. Wtedy odległość $d^wE^{(t)} = d_M(E^{(t)}(X), E^w(X))$[3] mierzy stan poziomu wartości oczekiwanych zmiennych kontrolnych w t-tej fazie kontroli względem ich wzorca. Przez analogię odległość $d^{aw}E^{(t)} = d_M(E^{(t)}(X), E^{aw}(X))$ mierzy stan poziomu wartości oczekiwanych zmiennych kontrolnych w t-tej fazie kontroli względem ich antywzorca.

Podobnie odległości $d^wVar^{(t)} = d_M(Var^{(t)}(X), Var^w(X))$ oraz $d^{aw}Var^{(t)} = d_M(Var^{(t)}(X), Var^{aw}(X))$ mierzą stan poziomu wariancji zmiennych kontrolnych w t-tej fazie kontroli względem ich wzorca i antywzorca.

Następnie zdefiniowane zostają unormowane miary ryzyka. Niech:

- $R_E^{(t)} = \dfrac{d^{aw}E^{(t)}}{d^wE^{(t)} + d^{aw}E^{(t)}}$ oznacza stopień realizacji założeń wzorcowych wartości oczekiwanej w t-tej fazie kontroli.
- $R_{Var}^{(t)} = \dfrac{d^{aw}Var^{(t)}}{d^wVar^{(t)} + d^{aw}Var^{(t)}}$ oznacza stopień realizacji założeń wzorcowych wariancji w t-tej fazie kontroli [Jastrzębski, 2015, s. 53–54].

[3] Odległością w przestrzeni probabilistycznej (Ω, F, P) dwóch wektorów $X = (X_1, X_2,\ldots, X_N)$ oraz $Y = (Y_1, Y_2,\ldots, Y_N)$ w sensie Mahalanobisa nazywamy $d_M(X,Y) = \sqrt{(X-Y)\cdot C^{-1}\cdot(X-Y)^T}$, gdzie C jest macierzą kowariancji wektorów losowych X i Y.

Należy zauważyć, że miary $R_E^{(t)}$ oraz $R_{Var}^{(t)}$ przyjmują wartości z przedziału $\langle 0,1 \rangle$. Wektor $[R_E^{(t)}, R_{Var}^{(t)}]$ jest unormowanym wektorem ryzyka w t-tej fazie kontroli, który znajduje się w kwadracie $\langle 0,1 \rangle \times \langle 0,1 \rangle$. Wartości kolejnych współrzędnych tego wektora bliskie kresu górnego poszczególnych przedziałów określoności świadczą o dobrej sytuacji badanego podmiotu w kontekście ekspozycji na ryzyko systemowe, wartości bliskie dolnego kresu świadczą o wysokim poziomie ryzyka systemowego.

3.3. Symulacje Monte Carlo, korekta Imana-Conovera

Dobrze znane metody symulacji Monte Carlo, wraz z ich rozszerzeniami, takimi jak próbkowanie warstwowe czy próbkowanie metodą hipersześcianu łacińskiego, przy generowaniu wektora losowego nie uwzględniają zależności pomiędzy zmiennymi losowymi. Procedurą eliminującą tę niedoskonałość jest podejście zaproponowane przez Imana i Conovera [1982], będące szeregiem przekształceń algebraicznych, stanowiących uzupełnienie dowolnego ze schematów próbkowania o algorytm wprowadzania do wygenerowanego uprzednio wektora losowego zadanych korelacji między zmiennymi losowymi, będącymi składowymi tego wektora, przy zachowaniu ich rozkładów brzegowych.

Algorytm postępowania można przedstawić następująco [Iman, Conover, 1982]:

1) generowanie wektora losowego X dowolną metodą generowania danych losowych taką, że zmienne losowe tego wektora są nieskorelowane i cechują się pożądanymi rozkładami brzegowymi;
2) dobór macierzy C będącej pożądaną macierzą korelacji, którą powinna cechować się transformacja macierzy X;
3) wyznaczenie macierzy P, takiej że $C = P \cdot P^T$[4];
4) wykonanie przekształcenia $X \cdot P^T$, w wyniku którego otrzymywana jest poszukiwana transformacja macierzy X, mająca oczekiwaną macierz korelacji C.

4. Symulacje modelu ryzyka systemowego – badanie empiryczne

4.1. Materiał badania

Przeprowadzone badanie objęło trzy obiekty: Alior Bank, BZ WBK oraz PKO BP. Są to banki z pierwszej dziesiątki polskich banków ze względu na wartość aktywów. Obiekty badania są zróżnicowane pod względem:

– aktywów (największy z nich, a zarazem największy bank działający na polskim rynku, PKO BP ma aktywa około dwa razy większe niż BZ WBK i ponad czterokrotnie większe niż Alior Bank),

[4] Ponieważ macierz C jest dodatnio określona i symetryczna, zatem istnieje taka dolna trójkątna macierz P, że $C = P \cdot P^T$. Macierz P można uzyskać na przykład przy użyciu rozkładu Choleskiego.

– doświadczenia w działalności na rynku polskim (najstarszym jest PKO BP, którego korzenie sięgają 1919 r., najmłodszym Alior Bank działający od końca 2008 r.),
– struktury własnościowej (PKO BP i Alior są w ok. 30% w posiadaniu Skarbu Państwa, BZ WBK należy do hiszpańskiej grupy Santander).

Szeregi czasowe mają częstotliwość kwartalną i obejmują okres 2014Q1 – 2016Q3. Dane pochodzą ze sprawozdań kwartalnych banków oraz raportów ich adekwatności kapitałowej.

4.2. Założenia modelu

Prezentowany model ryzyka wymaga przyjęcia następujących założeń:

1. Matematycznym modelem ryzyka jest wektor losowy $X = (X_1, X_2, X_3, X_4)$ zmiennych kontrolnych procesu ekspozycji na ryzyko systemowe. Składowymi tego wektora są:
   – X_1 – współczynnik wypłacalności CET1, zdefiniowany w pakiecie CDR IV / CRR [Basel Committee on Banking Supervision, 2011]. Jest on jednym z podstawowych wskaźników sygnalizujących złą sytuację instytucji finansowej z punktu widzenia ekspozycji na ryzyko. Komisja ustaliła poziom 4,5% jako wartość graniczną, poniżej której stan kapitałów najwyższej jakości postrzegany jest jako zagrażający możliwości danego podmiotu do sprostania warunkom kryzysu na rynku finansowym i w konsekwencji umożliwia efekt przelewania. Dlatego w badaniu przedział ⟨0 ; 0,045⟩ uznano za przedział antywzorca. Zgodnie z zaleceniami Komisji Nadzoru Finansowego w sprawie polityki dywidendowej [Komisja Nadzoru Finansowego, 2014] banki ze znaczącym udziałem w rynku depozytów sektora niefinansowego mogą wypłacać dywidendę do 100% zysku wypracowanego, gdy poziom współczynnika CET1 jest wyższy od 12%, tj. 9% wymaganego przez KNF minimalnego poziomu powiększonego o 3% buforu ryzyka systemowego. Można by zatem uznać, że poziom zwiększony o kolejne 3 p.p. byłby poziomem bardzo bezpiecznym, który w tym badaniu jest definiowany jako wzorcowy. Z tej przyczyny w badaniu przyjęto przedział ⟨0,15 ; 0,2⟩ jako przedział wzorca;
   – X_2 – relacja kredytów do depozytów jest jednym z najprostszych wskaźników określających płynność banku i prowadzoną przez bank politykę kredytową[5]. Wartość 100% i więcej jest osiągana podczas prowadzenia agresywnej polityki kredytowej, która obarczona jest większym ryzykiem niewypłacalności banku

[5] Zdecydowanie lepszymi miarami płynności byłyby wskaźniki narzucone przez Bazyleę III, tzn. LCR i NSFR. Wskaźniki te nie zostały wykorzystane w tym badaniu, ze względu na brak dostępu do tych danych.

związanym ze zwiększoną wrażliwością danej instytucji na nieprzewidziane zjawiska zewnętrzne (np. masowe wycofywanie depozytów przez Greków podczas kryzysu zadłużenia w Grecji w 2009 r.). W badaniu przedział ⟨1 ; 1,1⟩ uznano za przedział antywzorca, gdyż z punktu widzenia ekspozycji na ryzyko osiąganie takich wartości przez ten wskaźnik jest niekorzystne. Przyjmuje się, że poziom wskaźnika poniżej 80% należy uznać za bezpieczny z punktu widzenia ryzyka systemowego. KNF w Raporcie o Sytuacji Banków za I kwartał 2017 r. [Komisja Nadzoru Finansowego, 2017] poziom 96,7% tego wskaźnika dla sektora bankowego ocenia jako zadowalający w zakresie bieżącej płynności i dlatego w badaniu przyjęto przedział ⟨0,7 ; 0,8⟩ jako przedział wzorca;

– X_3 – udział kredytów zagrożonych, który jest miernikiem jakości portfela kredytowego i pozwala na ocenę ryzyka znacznej części prowadzonej przez bank działalności. Nie ma sformułowanej teorii, z której wynikałoby, jakie wartości należy uznać za oznaczające wysoki poziom ryzyka systemowego, a jakie oznaczają jego brak. Z części Raportu o Sytuacji Banków za I kwartał 2017 r. [Komisja Nadzoru Finansowego, 2017] dotyczącej jakości portfela kredytowego wynika, że poziom tego wskaźnika w wysokości 6% dla całego sektora bankowego Komisja Nadzoru Finansowego uznaje za sytuację zadowalającą. W związku z tym w badaniu przyjęto przedział ⟨0 ; 0,05⟩ za przedział wzorca, natomiast ⟨0,15 ; 0,2⟩ za przedział antywzorca;
– X_4 – pokrycie kredytów zagrożonych rezerwami, które jest miarą określającą, w jakim stopniu dokonane odpisy pokrywają kredyty zagrożone. Im wskaźnik jest wyższy, tym mniej dotkliwe jest urzeczywistnienie ryzyka kredytowego na sytuację finansową banku. W literaturze nie występuje pojęcie poziomu bezpiecznego dla tego wskaźnika [Rogowska, 2009]. Na potrzeby tego badania przyjęto przedział ⟨0,7 ; 1⟩ za wzorcowy, a ⟨0 ; 0,3⟩ za antywzorcowy.

2. Funkcją gęstości jest funkcja gęstości 4-wymiarowego rozkładu normalnego wektora losowego X, tzn. $f(X) = \frac{1}{\sqrt{(2\pi)^4 |\Sigma|}} e^{-\frac{1}{2}(X-\mu)^T \Sigma^{-1} (X-\mu)}$,

gdzie μ jest wektorem wartości oczekiwanych, natomiast Σ jest macierzą wariancji i kowariancji.

4.3. Wyniki empiryczne

Ze względu na krótkie szeregi czasowe oraz zamiar zbadania różnych scenariuszy przebiegu badanego zjawiska dokonano symulacji. Jak już wspomniano w poprzednich częściach, w przypadku jednoczesnego symulowania większej ilości zmiennych metodą Monte Carlo pojawia się problem ich wzajemnych powiązań, których ta metoda nie uwzględnia. Dlatego otrzymaną metodą Monte Carlo realizację wektora losowego poddano transformacji metodą Imana-Conovera, dzięki której otrzymano zmienne losowe skorelowane ze sobą w ustalony przez badacza sposób. Ze względu na krótką próbę bezzasadna jest weryfikacja typu rozkładu zmiennych. Będzie to możliwe wraz z upływem czasu, kiedy będą napływać nowe obserwacje. Przyjęto założenie, że zmienne mają rozkład normalny. Następnie dokonana została symulacja Monte Carlo zgodnie z otrzymanymi uprzednio rozkładami, a na koniec przeprowadzona została transformacja według metody Imana-Conovera, gdzie za macierz korelacji przyjęto macierz korelacji z próby. Wyniki symulacji przedstawione są na rysunkach 1, 2 i 3, gdzie linie ciągłe reprezentują wysymulowaną wartość zmiennej, końce słupków natomiast wartość powiększoną oraz pomniejszoną o odchylenie standardowe. W ten sposób dla każdej ze zmiennych i dla każdego obiektu uzyskano trzy scenariusze: neutralny, optymistyczny i pesymistyczny. Na rysunkach zaznaczone zostały również przedziały uznane za wzorcowe i antywzorcowe dla kolejnych zmiennych.

Rysunek 1. Wyniki symulacji dla poszczególnych zmiennych kontrolnych wraz z ich poziomami wzorcowymi i antywzorcowymi – Alior Bank

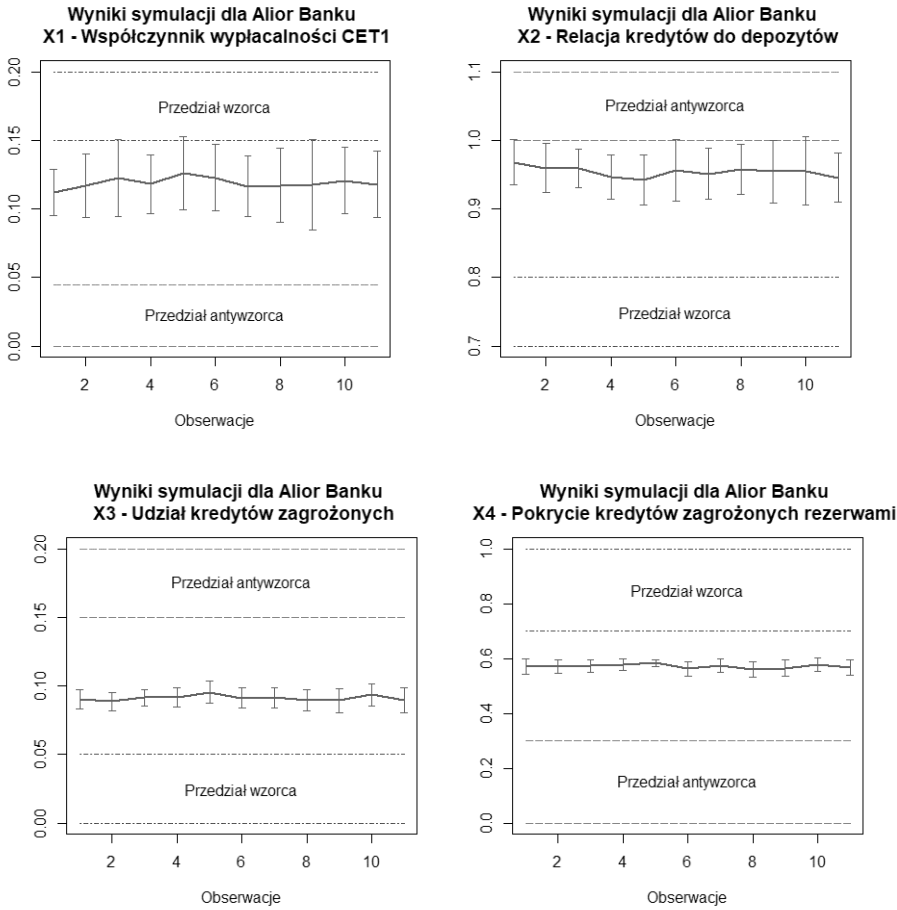

Źródło: Opracowanie własne przy użyciu programu Statistica i środowiska R.

Rysunek 2. Wyniki symulacji dla poszczególnych zmiennych kontrolnych wraz z ich poziomami wzorcowymi i antywzorcowymi – BZ WBK

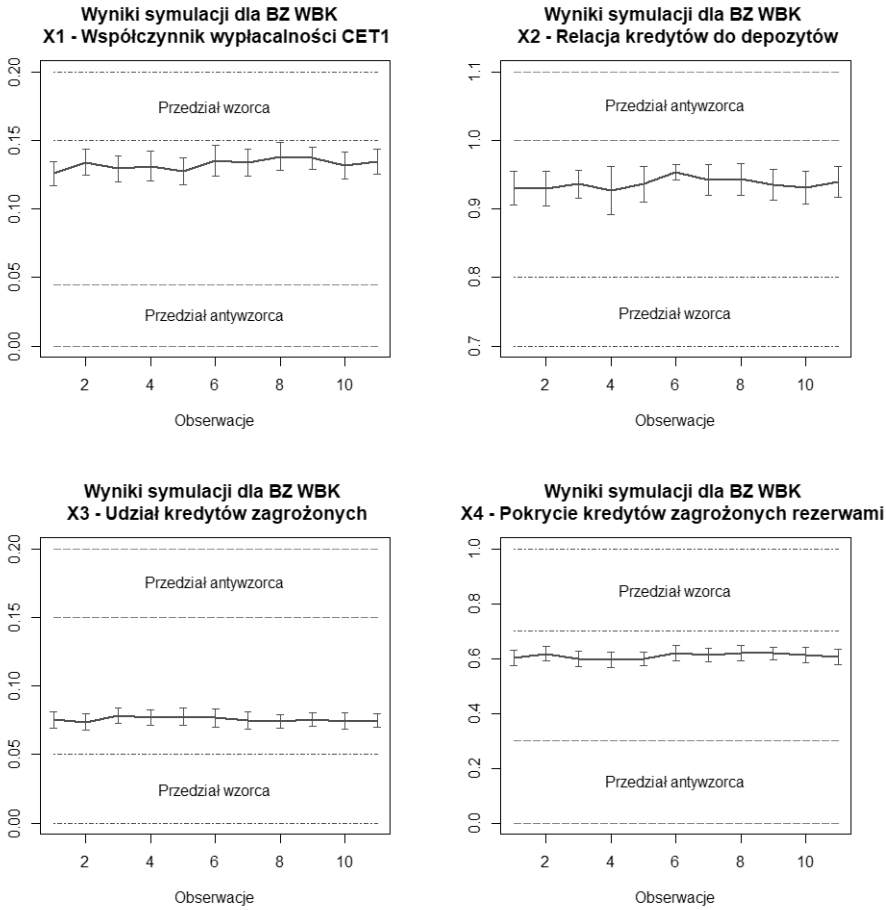

Źródło: Opracowanie własne przy użyciu programu Statistica i środowiska R.

Rysunek 3. Wyniki symulacji dla poszczególnych zmiennych kontrolnych wraz z ich poziomami wzorcowymi i antywzorcowymi – PKO BP

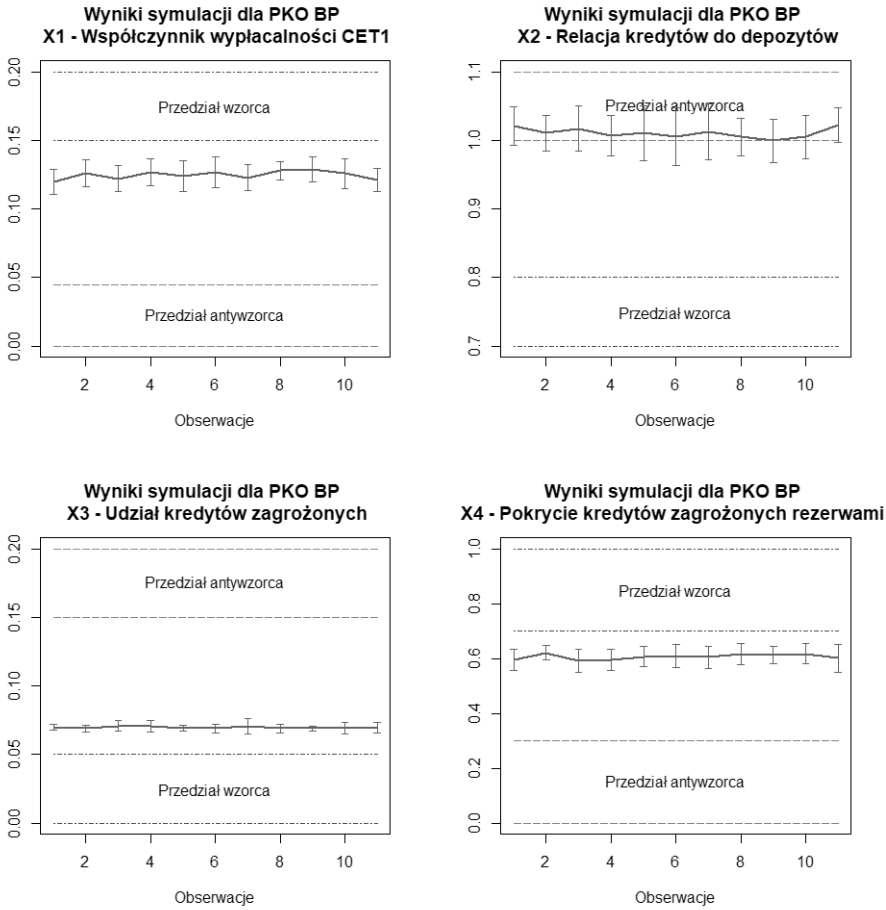

Źródło: Opracowanie własne przy użyciu środowiska programu Statistica i R.

Rysunki 4, 5 i 6 przedstawiają syntetyczny wskaźnik ryzyka, jakim są stopnie realizacji założeń wzorcowych dla wartości oczekiwanej oraz stopnie realizacji założeń wzorcowych dla wariancji dla kolejnych banków.

Rysunek 4. Syntetyczny wskaźnik ryzyka, porównanie scenariuszy – Alior

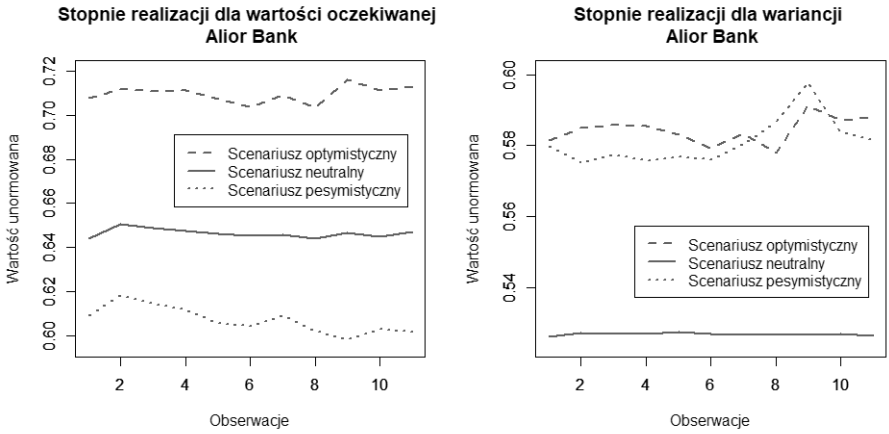

Źródło: Opracowanie własne przy użyciu środowiska R.

Rysunek 5. Syntetyczny wskaźnik ryzyka, porównanie scenariuszy – BZ WBK

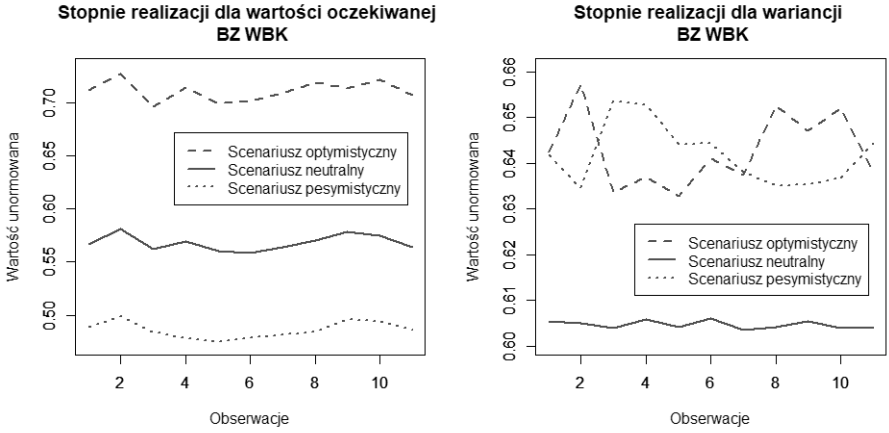

Źródło: Opracowanie własne przy użyciu środowiska R.

Rysunek 6. Syntetyczny wskaźnik ryzyka, porównanie scenariuszy – PKO BP

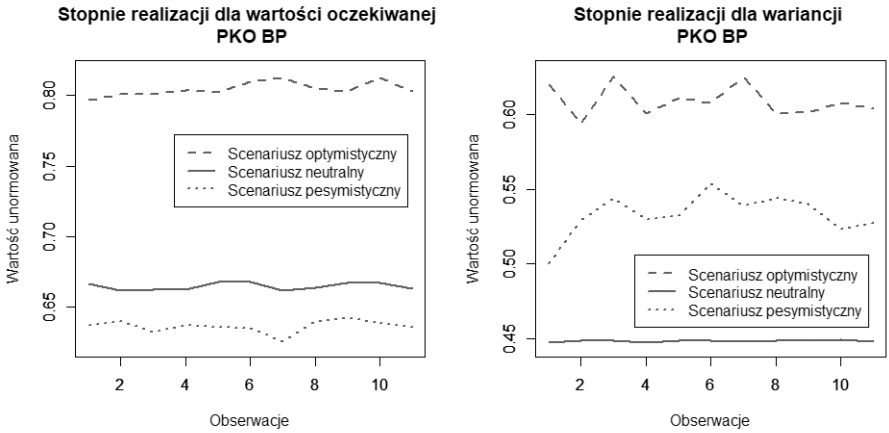

Źródło: Opracowanie własne przy użyciu środowiska R.

5. Wnioski

Analizując otrzymane wartości stopni realizacji dla wartości oczekiwanej przedstawionych na rysunkach 4, 5 i 6, można wnioskować, że w najlepszej sytuacji spośród badanych obiektów jest PKO BP, dla którego w scenariuszu optymistycznym wartość stopni realizacji dla wartości oczekiwanej oscylują wokół wartości 0,81, a w scenariuszu pesymistycznym powyżej 0,62. Alior Bank i BZ WBK również mają dość wysokie wartości analizowanego wskaźnika: Alior od około 0,60 do 0,72, BZ WBK od około 0,48 do 0,73 w zależności od przyjętego scenariusza. Ponieważ omawiany wskaźnik jest unormowany i przyjmuje wartości od 0 (w przypadku sytuacji skrajnie niekorzystnej ze względu na występujące ryzyko) do 1 (w przypadku występowania uwarunkowań wzorcowych), należy uznać powyższe wyniki jako wskazujące na występowanie niewielkiego ryzyka systemowego u badanych obiektów. Należy również zauważyć, że narzędzie jest wrażliwe na zmianę uwarunkowań ryzyka. Dla Alior Banku w scenariuszu optymistycznym wartości wszystkich zmiennych kontrolnych dla obserwacji od 9 do 11 zbliżają się wyraźnie w stronę wzorca ze względu na fakt, że wysymulowana wariancja dla tych obserwacji była relatywnie duża, co znajduje swoje odzwierciedlenie w zauważalnie większych wartościach stopni realizacji dla wartości oczekiwanej. Z analogicznych przyczyn w scenariuszu pesymistycznym dla tych samych obserwacji stopnie realizacji założeń wzorcowych dla wartości oczekiwanej przyjmują wyraźnie mniejsze wartości. Podobnie dla BZ WBK w ścieżce optymistycznej dla obserwacji 2, 4 i 8 kolejne zmienne kontrolne zbliżają się do wzorca, a za nimi rosną zauważalnie wartości stopni realizacji dla wartości oczekiwanej,

natomiast w scenariuszu pesymistycznym dla obserwacji 5, 6 i 7 zmienne kontrolne podążają w kierunku antywzorca (w szczególności zmienne X_1 i X_2), a wartości stopni realizacji dla wartości oczekiwanej wyraźnie osiągają dołek. Dla PKO BP w scenariuszu optymistycznym dla obserwacji 6, 7 i 10 wartości stopni realizacji dla wartości oczekiwanej ulegają wzrostowi, w ślad za zmianą wartości zmiennych kontrolnych, w szczególności zmiennej X_2, której wartości w tym scenariuszu w sposób znaczący przybliżyły się w stronę wzorca. Z kolei w scenariuszu pesymistycznym stopnie realizacji założeń wzorcowych dla wartości oczekiwanej maleją dla 3, 7 i 11 obserwacji, dla których można zaobserwować istotne zmiany wartości zmiennych kontrolnych w stronę ich wartości antywzorcowych (w szczególności zmienne X_2 i X_4).

Analiza stopni realizacji dla wariancji również wskazuje na występowanie niewielkiego ryzyka systemowego u badanych obiektów. W zależności od przyjętego wariantu wskaźnik ten przyjmował: dla Alior Banku wartości od 0,53 do 0,60, dla BZ WBK od 0,60 do 0,66, dla PKO BP od 0,45 do 0,63. Wrażliwość stopni realizacji dla wariancji na zmianę uwarunkowań nie zawsze jest taka sama jak stopni realizacji dla wartości oczekiwanej. Można jednak dostrzec dużo podobieństw, przede wszystkim w ścieżce optymistycznej dla Alior Banku oraz dla BZ WBK, gdzie kształt wykresu obu wskaźników względem kolejnych obserwacji jest niemal identyczny.

Podsumowując analizę wartości unormowanego wektora ryzyka, można wyciągnąć następujące wnioski:

1. Stopnie realizacji założeń wzorcowych dla wartości oczekiwanej okazały się wrażliwe na wahania zmiennych kontrolnych w każdym z wysymulowanych scenariuszy i były one bardziej wrażliwe na zmianę uwarunkowań niż stopnie realizacji założeń wzorcowych dla wariancji.
2. Dla scenariuszy w których zmienne kontrolne przyjmują wartości bliżej wzorca sposoby przebiegu stopni realizacji dla wartości oczekiwanej i stopni realizacji dla wariancji są bardziej zgodne.
3. Koncepcja budowy syntetycznej unormowanej miary ryzyka uwzględniającej korelacje między zmiennymi kontrolnymi umożliwiło sformułowanie problemu mierzenia ryzyka w sposób kompleksowy i upraszcza interpretację uzyskanych wyników.
4. Poziom ryzyka badanych obiektów w wysymulowanych wariantach wydarzeń nie jest wysoki, nawet w scenariuszu pesymistycznym.

Zakończenie

Miara ryzyka została ujęta jako wektor losowy o składowych będących zmiennymi kontrolnymi procesu mierzenia ryzyka systemowego dla

wybranych banków. Wprowadzenie pojęcia wartości wzorca i antywzorca oraz podstawowych charakterystyk statystycznych pozwoliło na zdefiniowanie unormowanych stanów ryzyka w oparciu o odległości wektorów wartości oczekiwanych i wariancji od ich wartości wzorca i antywzorca. Tak skonstruowane miary są łatwe do zrozumienia i interpretacji.

Celem artykułu było przeprowadzenie symulacji mierników ryzyka systemowego zdefiniowanych jako odległość między różnymi stanami wartości wskaźników a ich wartościami wzorcowymi i antywzorcowymi. I tak sformułowany cel zrealizowany został na podstawie metody Monte Carlo z uwzględnieniem korekty Imana-Conovera. Otrzymane wyniki badań potwierdziły stawianą hipotezę badawczą, iż wraz ze wzrostem poziomu ryzyka systemowego obserwowana jest większa wrażliwość wartości oczekiwanych wskaźników niż ich wariancji. Jest to zbieżne z założeniami wprowadzonego pakietu CDR IV/CRR, którego głównym celem jest wprowadzenie takich wskaźników, które zwiększają poziom wrażliwości na zmianę poziomu ekspozycji na ryzyko systemowe.

Kierunkami przyszłych badań jest uzupełnienie proponowanego narzędzia do pomiaru ryzyka systemowego o analizę jego wrażliwości na odstępstwa pojedynczych wskaźników od ścieżki neutralnej, czyli zaplanowanie takich symulacji, których jeden ze wskaźników w danym okresie odchyla się od antywzorca, natomiast pozostałe wskaźniki realizują scenariusz neutralny.

Literatura

Acharya V.V., Pedersen L.H., Philippon T., Richardson M. (2010), *Measuring Systemic Risk*, „Review of Financial Studies", Vol. 30, No. 1.

Basel Committee on Banking Supervision (2011), *Basel III: A global regulatory framework for more resilient banks and banking systems.*

Borio C. (2003), *Towards a macroprudential framework for financial supervision and regulation?*, BIS Working Paper No. 128.

Brämer P., Gischer H., Lücke C. (2014), *A simulation approach to evaluate systemic risk*, „European Journal of Political Economy", Vol. 34.

Buslenko N.P., Golenko D.I., Sobol I.M., Sragowicz W.G., Szrejder J.A. (1967), *Metoda Monte Carlo*, PWN, Warszawa.

Giglio S., Kelly B., Pruitt S. (2016), *Systemic risk and the macroeconomy: An empirical evaluation*, „Journal of Financial Economics", Vol. 119, No. 3.

Haas C. (1999), *On Modeling Correlated Random Variables in Risk Assesment*, „Risk Analysis", Vol. 10, No. 6.

Hellwig M.F. (2009), *Systemic Risk in the Financial Sector: An Analysis of the Subprime--Mortgage Financial Crisis*, „De Economist", Vol. 157, No. 2.

Huang X., Zhou H., Zhu H. (2009), *A Framework for Assessing the Systemic Risk of Major Financial Institutions*, „Journal of Banking & Finance", Vol. 33, No. 11.

Iman R.L., Conover W.J. (1982), *A distribution-free approach to including rank correlation among input variables*, „Communications in Statistics", Vol. 11, No. 3.

Informacja o sytuacji banków w I kwartale 2017 r. (2017), Komisja Nadzoru Finansowego, Warszawa, https://www.knf.gov.pl/knf/pl/komponenty/img/RAPORT_O_SYTUACJI_BANKOW_Ikw_2017_58291.pdf, dostęp: 11.09.2017.

Jastrzębski T. (2015), *Ryzyko obsługi zobowiązań długoterminowych gminy Sopot w świetle perspektywy budżetowej Unii Europejskiej na lata 2007–2013*, „Współczesna Gospodarka", Uniwersytet Gdański, Gdańsk.

Jermakow S.M. (1976), *Metoda Monte Carlo i zagadnienia pokrewne*, PWN, Warszawa.

Kabza M. (2012), *Ryzyko systemowe – cecha współczesnych rynków finansowych*, „Studia Ekonomiczne", nr 3, INE PAN, Warszawa.

Lehar A. (2005), *Measuring systemic risk: A risk management approach*. „Journal of Banking and Finance", Vol. 29, No. 10.

Rogowska E. (2009), *Rezerwy na ryzyko związane z działalnością banków*, „Studia i Prace Wydziału Nauk Ekonomicznych i Zarządzania", nr 24, Wydawnictwo Uniwersytetu Szczecińskiego, Szczecin.

Stanowisko KNF w sprawie polityki dywidendowej instytucji finansowych (2014), Komisja Nadzoru Finansowego, Warszawa, https://www.knf.gov.pl/knf/pl/komponenty/img/knf_123947_knf_123947_KNF_polityka_dywidendowa_2_12_2014_39873.pdf, dostęp: 10.09.2017.

Zemke J. (2009), *Ryzyko zarządzania kapitałem organizacji gospodarczej*, „Zeszyty Naukowe", nr 4, t. 4, Wydawnictwo Uniwersytetu Gdańskiego, Gdańsk.

Streszczenie

Ryzyko systemowe może być rozumiane jako możliwość wystąpienia wielu jednoczesnych nieprawidłowości w funkcjonowaniu dużych instytucji finansowych. Kwestia jego definiowania oraz pomiaru nabrała szczególnego znaczenia w okresie ostatniego kryzysu finansowego lat 2007–2009. Złożoność i zmienność ram teoretycznych i sposobu pomiaru ryzyka systemowego powoduje, że niezwykle trudne jest określenie i kwantyfikowanie czynników ryzyka systemowego w sektorze bankowym . Dodatkowo w swej istocie ryzyko to ma naturę zdarzenia rzadkiego i tym samym nie mają zastosowania miary klasyczne. Uzupełniając to spostrzeżenie o fakt braku danych oraz ich niską częstotliwość, można dojść do wniosku o konieczności zastosowania metod symulacyjnych, których zaletą jest możliwość projektowania różnych scenariuszy wydarzeń.

Celem artykułu jest przeprowadzenie symulacji mierników ryzyka systemowego zdefiniowanych jako odległość między różnymi stanami wartości wskaźników a ich wartościami wzorcowymi i antywzorcowymi. W związku z tak sformułowanym celem postawiono hipotezę badawczą, iż wraz ze wzrostem poziomu ryzyka systemowego obserwowana jest większa wrażliwość wartości oczekiwanych wskaźników niż ich wariancji. Jako narzędzie w procesie weryfikacji hipotezy badawczej w zaprojektowanym eksperymencie użyta została symulacja Monte Carlo z korektą Imana-Conovera.

Słowa kluczowe
ryzyko systemowe, Monte Carlo, korekta Imana-Conovera

Application of Monte Carlo simulations with Iman-Conover correcion in systemic risk measurement (Summary)

Systemic risk can be defined as the possibility of multiple simultaneous irregularities in the functioning of large financial institutions. The issue of its definition and measurement has become particularly important during the last financial crisis of 2007–2009. The complexity and variability of the theoretical framework and the methods of measuring systemic risk made it extremely difficult to identify and quantify systemic risk factors in the banking sector. In addition nature of this kind of risk is a rare occurrence and hence application of classical measures are not effective. In addition data are often of low frequency or there is no data available at all. Therefore one can conclude that simulations should be used to carry out such a research. This approach has the advantage that researcher is able to design different scenarios of events.

The purpose of this article is to simulate systemic risk measures defined as the distance between different quantity of indicator values and their ideal and anti-ideal levels. As a result of this formulation, the research hypothesis has been expressed that with increased systemic risk, the sensitivity of the expected values of indicators to the variance if indicators is higher. As a tool for the verification of the research hypothesis in the designed experiment Monte Carlo simulation with the Iman-Conover correction was used.

Keywords
systemic risk, Monte Carlo, Iman-Conover correction