

Marek Karwański

SAS Polska

Piotr Jałowiecki, Arkadiusz Orłowski

Katedra Informatyki

Szkoła Główna Gospodarstwa Wiejskiego w Warszawie

System pomiaru ryzyka rynkowego w długim horyzoncie czasowym EAR

Wstęp

Proces zarządzania ryzykiem w instytucjach finansowych jest zazwyczaj zdeterminowany przez zestaw podstawowych wytycznych, których realizacja umożliwia bezpieczny, zrównoważony, a przede wszystkim przewidywalny wzrost zgodnie z założonymi celami strategicznymi [Riehl 2001]. Do najważniejszych z nich należą:

1. Zapewnienie wypełnienia przez instytucję (bank) określonych wymagań nakładanych przez nadzór bankowy, przede wszystkim dotyczących odpowiedniego poziomu adekwatności kapitałowej.
2. Ograniczenie całkowitej ekspozycji instytucji na ryzyko, w tym na poszczególne jego składniki, do poziomu akceptowanego z punktu widzenia konkretnej instytucji.
3. Optymalizacja ekspozycji na ryzyko w stosunku do realizowanego wyniku finansowego.

System zarządzania ryzykiem w instytucjach finansowych powinien umożliwiać realizację wymienionych celów, zapewniając w zakresie każdego z nich właściwy zakres funkcjonalności biznesowej. Musi on umożliwiać przede wszystkim pomiar poszczególnych rodzajów ryzyka: rynkowego, kredytowego oraz płynności, zgodnie z przyjętą metodologią, odzwierciedlając charakterystykę banku, praktykę branżową oraz uwarunkowania nadzoru w tym zakresie. Podejmowanie przez bank ekspozycji na ryzyko powinno mieć uzasadnienie w oczekiwanym wyniku finansowym, mierzonym w adekwatnym do natury inwestycji czasie. W związku z tym istnieje konieczność symulowania skutków określonych zmian portfeli i towarzyszących tym portfelom czynników ryzyka oraz ustalania i monitorowania celów finansowych w kategoriach wiążących wynik finansowy instytucji z generowanym przez nią ryzykiem. Zazwyczaj zaj-

muje się tym system zarządzania ryzykiem, dając możliwość prezentacji analiz wynikających z miar dochodowości korygowanych ryzykiem oraz symulowania zmienności wyniku, w konsekwencji rzeczywistych lub hipotetycznych zmian warunków na rynku, w którego realiach funkcjonuje bank [Bessis 1998].

Cele i metody badawcze

W celu oszacowywania ryzyka rynkowego stosowana jest obecnie metodologia wartości zagrożonej VaR (ang. Value at Risk), w ramach której można budować modele deterministyczne i stochastyczne pozwalające estymować z zadowalającą dokładnością wielkość ryzyka rynkowego. W niniejszym artykule przedstawiono modele analityczne umożliwiające symulowanie przyszłych zmian rynku. Tradycyjnie metodologia VaR stosowana jest do modelowania rynkowych czynników ryzyka modelami opartymi na procesach błędzenia przypadkowego w krótkim horyzoncie czasowym rzędu jednego dnia do jednego roku, bez zwracania uwagi na wewnętrzne zmiany portfela. Jest to uzasadnione w przypadku pomiaru ryzyka dla produktów bankowych, które można stosunkowo szybko sprzedać lub kupić, dopasowując strukturę ryzyka do założeń biznesowych (tzw. portfel inwestycyjny oparty na wyliczonych wartościach ryzyka). Część produktów ma jednak inny charakter, dotyczy to w szczególności mało płynnych aktywów i pasywów, jak np. kredyty. Takie instrumenty finansowe, nazywane w banku „portfelem bankowym”, wymagają stosowania zupełnie innych modeli.

Optymalizacja ekspozycji na ryzyko wymaga zapewnienia przez system sprawnego narzędzia do kalkulacji miar dochodowości korygowanych ryzykiem. Miary te powstają przez zestawienie zgodnie ze zdefiniowanymi algorytmami obliczeniowymi wyniku generowanego przez poszczególne portfele czy też grupy portfeli (obszary działania, departamenty itp.) z parametrami odzwierciedlającymi ryzyko wynikające z tych portfeli. Dobór tych miar oraz ich struktury jest bardzo ważny z punktu widzenia wyniku finansowego banku. Nowoczesne systemy pomiaru ryzyka oparte są na generatorach Monte Carlo umożliwiającich symulację rynkowych czynników ryzyka [RiskMetrics Group 1999].

Celem niniejszej pracy jest zaprezentowanie nowego algorytmu, który może być wykorzystany do pomiaru ryzyka rynkowego, czyli podstawowej części systemu zarządzania ryzykiem. W pracy przedstawiono elementy modelu wykorzystywanego do estymowania rozkładu gęstości wartości portfela oraz wstępne wyniki uzyskane za pomocą tego algorytmu jako pierwszą część systemu reali-

zującego metodologię EaR. Modele rynkowe zostały zbudowane na podstawie teorii modeli kointegracyjnych, natomiast część portfelowa została oparta na modelu symulującym scenariusze wzrostu i wypalania się portfela na podstawie prognozowanych przepływów pieniężnych. Uwzględniając praktyczne aspekty stosowania tej aplikacji, część mechanizmów budowy scenariuszy ma charakter stochastyczny, oparty na algorytmach Monte Carlo, część zaś została zbudowana jako deterministyczne testy odpornościowe (ang. Stress-test).

Z reguły analiza ryzyka dla portfela bankowego koncentruje się zazwyczaj na badaniu zachowań rynkowych stóp procentowych, które stanowią najważniejszy czynnik ryzyka rynkowego w długim okresie. Badanie ryzyka stóp procentowych polega na oszacowaniu rozkładu wartości portfela w zadanym punkcie czasowym i wyznaczeniu odpowiednich wartości strat na określonym poziomie ufności.

Zgodnie z obowiązującymi przepisami prawnymi, bank powinien mieć rezerwy pozwalające pokryć straty. Zadany horyzont czasowy, jak i poziom ufności określone są w uchwałach NBP. Z pewnym uproszczeniem możemy wyobrazić sobie portfel jako zbiór przepływów pieniężnych w określonych punktach czasowych. Przepływy mogą być dodatnie i ujemne, co odpowiada tzw. pozycjom krótkim lub długim. W celu obliczenia wartości portfela musimy wszystkie przepływy pieniężne przenieść do jednego punktu czasowego, czyli zdyskontować je za pomocą odpowiednich czynników dyskontujących, a następnie zsumować. Zmianom mogą podlegać zarówno wartości przepływów pieniężnych, jak i czynników dyskontujących.

W niniejszej pracy wykorzystano tylko modele zmian czynników dyskontujących. Pełny system zarządzania ryzykiem stopy procentowej, który powinien umożliwić przewidywanie zmian obydwu wielkości, zostanie zaprezentowany w kolejnej pracy.

Najczęściej wykorzystywanym w praktyce algorytmem szacowania rozkładów czynników dyskontujących jest metoda symulacji Monte Carlo. W pracy zbudowano scenariusze zmian czynników dyskontujących, a następnie za pomocą mechanizmu losowego przypisano każdemu scenariuszowi pewne prawdopodobieństwo wystąpienia [Campbell, MacKinlay 1997].

Czynnikami dyskontującymi zazwyczaj są stopy procentowe, które nie są bezpośrednio obserwowane na rynku, niemniej można obliczyć ich wartość na podstawie wycen różnych instrumentów finansowych dostępnych na giełdzie. Należy podkreślić, że wiele serwisów informacyjnych publikuje wartości stóp procentowych dla standardowych okresów zapadalności od 1 dnia do 20 lat.

Dane badawcze

W pracy przedstawiono modelowanie stóp procentowych dla złotych (PLN), dla różnych okresów zapadalności: 1 miesiąc, 3 miesiące, 6 miesięcy, 3 lata, które stanowią część krzywej dochodowości wykorzystywanej podczas dyskontowania portfela.

W tabeli 1 przedstawiono wartości stóp procentowych dla różnych dat w rozbiciu na okresy zapadalności.

Tabela 1

Wartości różnych stóp procentowych w rozbiciu na okresy zapadalności

| DATA | | PLNS__1M | PLNS__3M | PLNS__6M | | PLNS__3Y |
|------------|-------|----------|----------|----------|-------|----------|
| 2002-06-28 | ... | 0,1916 | 0,1782 | 0,1634 | | 0,0898 |
| 2002-06-29 | ... | 0,1923 | 0,1788 | 0,1605 | | 0,0900 |
| 2002-06-30 | ... | 0,1918 | 0,1784 | 0,1602 | | 0,0897 |
| 2002-07-01 | ... | ... | ... | ... | ... | ... |
| 2002-07-02 | ... | ... | ... | ... | ... | ... |
| 2002-07-03 | ... | 0,1911 | 0,1781 | 0,1605 | | 0,0905 |
| 2002-07-04 | ... | 0,1908 | 0,1787 | 0,1612 | | 0,0937 |
| 2002-07-05 | ... | 0,1906 | 0,1789 | 0,1610 | | 0,0939 |
| 2002-07-06 | ... | 0,1914 | 0,1794 | 0,1615 | | 0,0939 |
| 2002-07-07 | .. | 0,1899 | 0,1790 | 0,1609 | | 0,0934 |

Źródło: Opracowanie własne.

W pracy wykorzystano dzienne dane publikowane przez serwis Reuters za okres luty 2002 do stycznia 2004. Ponieważ w tym okresie występowały dni świąteczne i wolne od handlu, w szeregach czasowych występowały braki danych. Dla potrzeb księgowych braki danych uzupełnia się ostatnimi dostępnymi wartościami, natomiast przy liczeniu ryzyka usuwa się wolne dni tak jakby ich nie było, co pozwala na zachowanie naturalnych zmienności (wolatylności) szeregów. Długość danych wykorzystanych do kalibracji modelu wynosiła 500 obserwacji (około dwóch lat). Zazwyczaj używa się krótszych okresów – 6 miesięcy do 1 roku, chcieliśmy jednak, aby dane historyczne były porównywalnej długości z okresem prognozowanym, na który budowaliśmy scenariusze. Z drugiej strony, użycie zbyt „długiego okna” mogłoby spowodować zaburzenia związane z okresowością tzw. cyklu biznesowego.

W niniejszej pracy nie wykorzystano danych o zmianach portfela, ponieważ pierwszym etapem jest uzyskanie symulacji danych rynkowych. W praktyce do liczenia ryzyka wykorzystuje się symulacje stochastyczne stóp procentowych, natomiast kursy walut modeluje się poprzez deterministyczne scenariusze, np. liniowy wzrost lub skokowa zmiana wartości w połowie badanego okresu.

Modele analityczne symulowania scenariuszy

Pomiar ryzyka rynkowego jest procesem obejmującym wiele modeli dla danych rynkowych i zmian portfela. W naszej pracy zajęliśmy się modelowaniem zmian stóp procentowych, ponieważ z praktycznego punktu widzenia jest to najważniejszy czynnik wpływający na wynik finansowy banku.

W celu zbudowania generatora pozwalającego symulować automatycznie scenariusze musimy obliczyć następujące parametry stóp procentowych dla każdego okresu zapadalności:

- wartość średnią prognozy,
- błąd standardowy prognozy,
- macierz kowariancji (dla różnych okresów zapadalności),
- macierz autokorelacji (dla kolejnych dat).

Na podstawie tych wielkości można będzie zbudować generator [Kim i in. 1999], a następnie wyliczyć wartość portfela wzdłuż każdego scenariusza. Stąd krytycznym punktem jest uzyskanie odpowiednich scenariuszy stóp procentowych.

Wartość średnia prognozy i błąd standardowy prognozy

Do prognozowania ekonomicznych szeregów czasowych wykorzystuje się wielowymiarowe modele kointegracyjne [Hamilton 1994]. Wiadomo, że w długim okresie między wartościami stóp procentowych o różnych terminach realizacji występują pewne zależności. Ich odzwierciedleniem w szeregach czasowych powinny być równania kointegracyjne. Ponieważ celem niniejszej pracy jest badanie mechanizmu losowego stóp procentowych (tzw. wolatylności), nie będziemy skupiali zbyt wiele uwagi nad modelami VAR (ang. – Vector ARIMA). Proces kointegracyjny można przedstawić w postaci wielowymiarowego równania liniowego VAR:

$$y_t = \beta_1 \cdot y_{t-1} + \beta_2 \cdot y_{t-2} + \dots + \beta_k \cdot y_{t-k} + u_t$$

$n \times 1 \quad n \times n \quad n \times 1 \quad n \times n \quad n \times 1 \quad n \times n \quad n \times 1 \quad n \times 1$

Po przekształceniu do postaci VECM otrzymujemy:

$$\Delta y_t = \Pi y_{t-k} + \Gamma_1 \Delta y_{t-1} + \Gamma_2 \Delta y_{t-2} + \dots + \Gamma_{k-1} \Delta y_{t-(k-1)} + u_t$$

Gdzie: $\Pi = \left(\sum_{j=1}^k \beta_j \right) - I_n$ oraz $\Gamma_i = \left(\sum_{j=1}^i \beta_j \right) - I_n$

Można pokazać, że gdy rząd macierzy Π jest równy r ($r > 0$ i $r < n$), to macierz można faktoryzować w postaci:

$$\Pi = \beta \alpha'$$

$$n \times n \quad n \times r \quad r \times n$$

gdzie wektor β jest wektorem kointegracyjnym odpowiedzialnym za długoterminową relację. W literaturze spotyka się doniesienia, że modele kointegracyjne można stosować do prognozowania stóp procentowych dla horyzontu od 1 roku do 3 lat. Estymatory można wyznaczyć metodą największej wiarygodności ML (ang. – Maximum-Likelihood). Prognozę wylicza się standardową metodą rekurencyjną ze wzorów:

$$y_{t+m|t} = \sum_{j=1}^k \beta_j y_{t+m-j|t} + \sum_{j=m}^q \theta_j \varepsilon_{t+m-j|t} \quad \text{dla } m < q$$

$$y_{t+m|t} = \sum_{j=1}^k \beta_j y_{t+m-j|t} \quad \text{dla } m > q$$

Z tego samego równania można wyznaczyć błąd prognozy jako propagację błędów uzyskanych z metody ML – jest to tzw. metoda delta.

Macierz kowariancji

Do estymacji macierzy kowariancji można użyć różnych metod. Najprostszą wydawałaby się estymacja bezpośrednio z metody największej wiarygodności, jednakże z uwagi na fakt, że rozkłady stóp procentowych nie są normalne naturalnym wyborem jest metoda funkcji kopułowych [Li 2005].

Funkcja kopuły łączy jednowymiarowe rozkłady brzegowe z rozkładem wielowymiarowym. Możemy ją zdefiniować w taki sposób, że funkcja C jest funkcją kopułową wówczas, gdy spełniony jest warunek:

$$C(F_1(y_1), F_2(y_2), \dots, F_n(y_n)) = F(x_1, x_2, \dots, x_n)$$

gdzie: $F_1(y_1), F_2(y_2), \dots, F_n(y_n)$ – jednowymiarowe rozkłady brzegowe, $F(x_1, x_2, \dots, x_n)$ – rozkład wielowymiarowy.

Sklar wykazał twierdzenie odwrotne, które stało się podstawą do stosowania kopuł w statystyce. Pokazał on, że dla dowolnego rozkładu $F(x_1, x_2, \dots, x_n)$ (oczywiście spełniającego pewne warunki regularności, które w praktyce zawsze można przyjąć za obowiązujące) istnieje jednoznacznie wyznaczona funkcja C , zwana funkcją kopułową, taka, że

$$F(x_1, x_2, \dots, x_n) = C(F_1(y_1), F_2(y_2), \dots, F_n(y_n))$$

Stąd funkcja kopuł jest odpowiedzialna za strukturę korelacyjną/kowariacyjną. W przypadku stóp procentowych za rozkłady brzegowe przyjmuje się najczęściej rozkłady log-normalne, natomiast funkcję kopułową można przyjąć z szerokiej gamy rodzin, np. rodziny kopuł normalnych.

Kopuły normalne spełniają następujący warunek:

$$C(u_1, u_2, \dots, u_n, \rho) = \Phi[\Phi^{-1}(u_1), \Phi^{-1}(u_2), \dots, \Phi^{-1}(u_n)]$$

gdzie:


$\Phi()$ jest dystrybuantą rozkładu normalnego,

ρ jest macierzą korelacji.

Do symulowania scenariuszy, które miałyby strukturę kowariacyjną zadaną przez funkcję kopuły normalnej, użyto jako miary korelacji współczynników tau-Kendalla. Współczynniki te mają tę własność, że są niezmiennicze ze względu na transformacje ściśle rosnące. Do tej klasy należy zarówno $\text{Log}()$ jak i $\Phi()$.

Macierz autokorelacji

Do zbudowania kompletnego generatora scenariuszy potrzebna jest również macierz autokorelacji, która zapewniłaby zgodność uzyskanych scenariuszy z własnościami rzeczywistych szeregów. W tym celu algorytm generowania scenariuszy został podzielony na dwa poziomy. Na poziomie pierwszym zakładamy, że macierze autokorelacji są równe zero. Takie założenie wydaje się sensowne, gdy krok czasowy pomiędzy kolejnymi punktami generowanego scenariusza na skali czasowej jest dostatecznie długi. W niniejszej pracy przyjęty został odstęp równy jednemu kwartałowi. Założenie to wymagałoby sprawdzenia i w kolejnych pracach będzie dokładniej przedyskutowane. Autokorelacje pomiędzy wartościami rynkowych stóp procentowych maleją bardzo szybko – zakłada się, że są one procesami martyngałowymi, ale autokorelacje pomiędzy kwadratami przyrostów wykazują długą pamięć (long-memory) i są modelowane za pomocą procesów IGARCH [Zumbach 2007]. Niemniej jednak wydaje się, że okres rzędu 50 dni powinien wytłumić wszystkie relacje. Dlatego można użyć elementów modelu opisanych powyżej do zbudowania generatora dla dużych kroków czasowych. Na drugim poziomie uzupełniamy generowany szereg czasowy z krokiem równym 1 dzień [Kim i in. 1997]. Można to zrobić za pomocą procesu „błądzenia przypadkowego” z zadanymi więzami na końcach, tzw. most Wienera przedstawiony na rysunku 1.



Rysunek 1

Ilustracja procesu błędzenia przypadkowego (mostu Wienera)

Źródło: Opracowanie własne.

Dla czasów t w przedziale $[T_0, T_1]$ możemy wykreślić trajektorię q zgodnie z równaniem:

$$Factor_{T_p+t}^q = \frac{T_p-t}{T_k-T_p} Fac_{T_p}^q + \frac{t-T_p}{T_k-T_p} Fac_{T_k}^q + \sum_{l=T_p}^t \varepsilon_l^q - \frac{t-T_p}{T_k-T_p} \sum_{l=T_p}^{T_k} \varepsilon_l^q$$

Oczywiście zmienna losowa ε może pochodzić z różnych rozkładów, niekoniecznie rozkładu normalnego, co pozwoliłoby uwzględnić pewne własności scenariusza związane z „długą pamięcią” obserwowane w danych rzeczywistych. Oddzielnym problemem jest wyliczenie bezwarunkowej wariancji procesu po uwzględnieniu zmienności występujących na obu poziomach symulacji.

Wyniki badań

Do budowy modelu użyto szeregu czasowego dla zmiennych: stopy procentowe 1-miesięczne, 3-miesięczne, 6-miesięczne i 6-letnie. Przed analizą zmienne zostały poddane transformacji logarytmicznej.

W pierwszym etapie zbudowano model VECM (ang. – Vector Error Correction Model) o parametrach przedstawionych w tabeli 2:

- liczba członów opóźnionych $p = 2$ wybrana na podstawie miar dopasowania modelu AIC,
- rząd kointegracji $r = 2$.


Na rysunku 2 przedstawiono prognozę i błąd prognozy dla złotówkowej stopy procentowej o okresie zapadalności 1 miesiąca. Na wykresie linią pogrubioną zaznaczono dane rzeczywiste, linią jaśniejszą zaznaczono średnią wartość prognozy, natomiast liniami przerywanymi zaznaczono błąd średniej.

Tabela 2

Parametry modelu VECM wykorzystanego w badaniach

| Cointegration Rank Test | | | | |
|-------------------------|--------------|------------|----------|--------------------|
| H0: Rank = r | H1: Rank > r | Eigenvalue | Trace | 5% Critical Value |
| 0 | 0 | 0,1013 | 102,7787 | 62,61 (reject) |
| 1 | 1 | 0,0533 | 49,6142 | 42,40 (reject) |
| 2 | 2 | 0,0359 | 22,3397 | 25,47 (not reject) |
| 3 | 3 | 0,0083 | 4,1350 | 12,39 |

Źródło: Opracowanie własne.

**Rysunek 2**

Scenariusz wygenerowany dla 1-miesięcznej stopy procentowej

Źródło: Opracowanie własne.

Głównym celem uzyskania prognoz była nie tylko wartość średnia, ale również przedział ufności. W następnym kroku oszacowana została „korelacja” pomiędzy seriami (stopy procentowe dla różnych okresów zapadalności), które zostały użyte do budowy kopuł, a których parametry przedstawiono w tabeli 3.

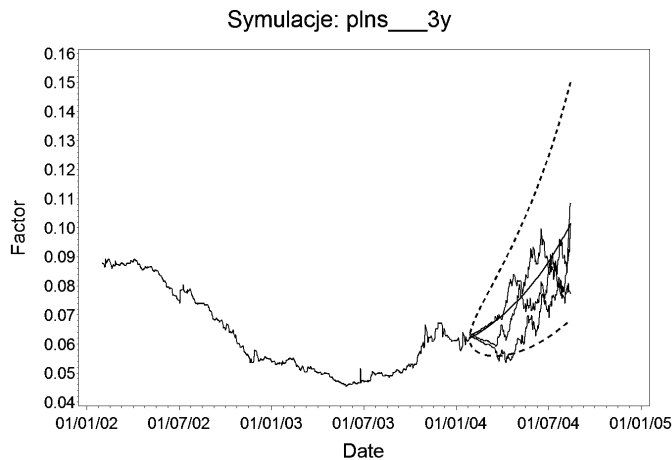
Następnie wygenerowano wielowymiarowe scenariusze dla wszystkich serii stóp procentowych. Przykładowy scenariusz przedstawiono na rysunku 3.

Tabela 3

Parametry wykorzystane w badaniach do budowy kopuł

| Kendall Tau b Correlation Coefficients, N = 500 | | | | |
|---|----------|----------|----------|----------|
| Prob > r under H0: Rho = 0 | | | | |
| | PLNS__1M | PLNS__3M | PLNS__6M | PLNS__3Y |
| PLNS__1M | 1,000 | 0,427 | 0,347 | 0,141 |
| PLNS__3M | 0,427 | 1,000 | 0,683 | 0,185 |
| PLNS__6M | 0,347 | 0,683 | 1,000 | 0,297 |
| PLNS__3Y | 0,141 | 0,185 | 0,297 | 1,000 |

Źródło: Reuters.



Rysunek 3

Scenariusz wygenerowany dla 3-letniej stopy procentowej
 Źródło: Opracowanie własne.

Tak uzyskane scenariusze zostały wykorzystane po obliczeniu dyskonta przepływów pieniężnych generowanych przez portfel do wyestymowania rozkładu zysków i strat, a następnie ustalenia niezbędnej rezerwy, zgodnie z obowiązującymi przepisami prawnymi.

Podsumowanie

W pracy przedstawiono jeden element systemu zarządzania ryzykiem – mechanizm generowania scenariuszy Monte Carlo uwzględniający praktyczne aspekty stosowania metodologii Value-at-Risk. W ramach dalszej realizacji funkcji tego systemu musi być on zaopatrzony w specyficzną funkcjonalność związaną z pomiarem ryzyka:

- a) rozszerzenie mechanizmu gromadzenia danych o elementy nieobjęte podobnym procesem w ramach realizacji wymagań wobec utrzymania adekwatności kapitałowej wraz z uzupełnieniami w dodatkowym procesie walidacji danych;
- b) mechanizm kalkulacji parametrów ryzyka zgodnie z przyjętymi metodami, które obejmują w zakresie:
 - i. ryzyka kredytowego:
 - kalkulację ekwiwalentów kredytowych według przyjętej metody, np. bieżącego zaangażowania lub potencjalnego zaangażowania,

- szacowanie straty oczekiwanej oraz wartości zagrożonej portfela kredytowego z uwzględnieniem struktury ratingowej i scoringowej zaangażowań,
 - szacowanie potencjalnych strat na podstawie testu warunków skrajnych,
 - szacowanie koncentracji zaangażowań na podstawie zdefiniowanych klasyfikacji;
- ii. w zakresie ryzyka rynkowego:
- szacowanie wrażliwości portfeli na podstawie metody wartości punktu bazowego (BPV) oraz wartości zagrożonej,
 - szacowanie potencjalnych strat na podstawie testu warunków skrajnych,
 - szacowanie ryzyka na podstawie tradycyjnych metod pomiarowych, takich jak analiza luki, analiza duration;
- iii. w zakresie ryzyka płynności:
- analiza luki płynnościowej na podstawie przyjętego modelu urealniania,
 - analiza przepływów pieniężnych,
 - analiza ryzyka płynności metodą testu warunków skrajnych (np. na podstawie scenariuszy zmiany wartości portfeli, utraty depozytów itp.);
- c) aplikacje umożliwiające definiowanie struktury limitów oraz rejestrację ich wartości na użytek monitorowania;
- d) system dystrybucji informacji oparty na standardowych raportach, aplikacjach ekranowych wraz z mechanizmem tworzenia zadań ad hoc specyficzny dla tej funkcji.

Literatura

- KIM J., MALZ A., MINA J. *LongRun Technical Document*. RiskMetrics Group. *Risk Management: A Practical Guide*, RiskMetrics Group, 1999.
- CAMPBELL J., LO A., MACKINLAY C. *The Econometrics of Financial Markets*. Princeton University Press, New Jersey 1997.
- ZUMBACH G. *The RiskMetrics 2006 Methodology*, Risk Metrics Group, 2007.
- HAMILTON J.D. *Time series analysis*. Princeton University Press, Princeton, NJ 1994.
- BESSIS J. *Risk Management in Banking*. John Wiley&Sons, Cichester, 1998.
- RIEHL H. *Zarządzanie ryzykiem*. WIB, Warszawa 2001.
- LI J. *Modelling Dependency Between Different Lines of Business with Copulas*. University of Melbourne, 2005.

MARKET RISK ASSESSMENT SYSTEM FOR LONG-TERM HORIZON EAR

Abstract

Risk assessment methods are one of the most significant components of risk management systems used in financial institutions. Risk factors are assessed with using of VaR (Value at Risk) methodology based on stochastic models. These methods are used only for short-term wallets. More significant there are EaR (Earning at Risk) models enabling long-term analysis of traditional wallets. These models consists of simulation models of market data and evolution models of wallet structure and wallet volume. In this paper the first part of EaR methodology – long-term simulation models of risk factors is studied. Using of EaR methodology is presented for real risk management system from one of the commercial banks.