

KOMPARATIVNA ANALIZA VAR METODA S OSVRTOM NA IZAZOVE PRIMJENE U BANKARSKOM SEKTORU ZEMLJAMA U RAZVOJU I TRANZICIJI

COMPARATIVE ANALYSIS OF VAR METHODS WITH REFERENCE TO THE CHALLENGES OF THEIR AP- PLICATION WITHIN THE BANKING SECTOR IN DE- VELOPING AND TRANSITION COUNTRIES

DR. SC. ARMINA HUBANA, VANREDNI PROFESOR
Univerzitet „Džemal Bijedić u Mostaru“- Ekonomski fakultet

EDNA VOLODER, MA
Univerzitet “Džemal Bijedić” u Mostaru

DR. SC. AZRA BAJRAMOVIĆ, VANREDNI PROFESOR
Univerzitet „Džemal Bijedić u Mostaru“- Ekonomski fakultet

DR. SC. GORAN ĆURIĆ, VANREDNI PROFESOR
Univerzitet „Džemal Bijedić u Mostaru“- Ekonomski fakultet

Sažetak: Cilj ovog rada je analizirati i uporediti glavne value at risk (var) metode, s naglaskom na izazove primjene u finansijskom sektoru zemalja u razvoju i tranziciji, kakva je i bosna i hercegovina. U radu se razmatraju tri najčešće korištene metode: historijska simulacija, parametarska metoda i monte carlo simulacija, njihove prednosti i nedostaci te mogućnosti primjene. Komparativna analiza pokazuje da performanse metoda u nerazvijenim ili „emerging“ tržištima često odstupaju od standardnih pretpostavki.

Ključne riječi: tržišni rizik, rizična vrijednost, value at risk, var, historijska simulacija, monte carlo simulacija, parametarska metoda, riskmetrics

Abstract: The aim of this paper is to analyze and compare the main Value at Risk (VaR) methods, with an emphasis on the challenges of application within the financial sector of developing and transition countries such as Bosnia and Herzegovina. The paper focuses on the three most commonly used methods: historical simulation, parametric method and Monte Carlo simulation, their advantages and disadvantages, and their application possibilities. Comparative

analysis shows that the performance of methods in underdeveloped or “emerging” markets often deviates from standard assumptions.

Key words: *Market risk, Value at Risk, historical simulation, Monte Carlo simulation, Parametric VaR, RiskMetrics*

UVOD

Stabilnost bankarskog sistema jedan je od ključnih preduvjeta za održivi ekonomski razvoj. Globalna finansijska kriza iz 2008. godine pokazala je značaj adekvatnog upravljanja rizicima, a naročito tržišnim rizikom, koji nastaje uslijed promjena kamatnih stopa, deviznih kurseva i cijena finansijskih instrumenata. Upravo iz tog razloga međunarodni regulatorni okvir, kroz Bazelske sporazume, postavlja standarde za mjerenje i kontrolu rizika u bankama. U okviru tih standarda razvijene su brojne kvantitativne metode, od kojih se posebno ističe Value at Risk (VaR) metoda. Ona omogućava procjenu maksimalnog očekivanog gubitka u datom vremenskom horizontu i na određenom nivou pouzdanosti, čime pruža bankama i regulatorima praktičan alat za planiranje kapitala potrebnog za pokriće tržišnog rizika. Jorion (2007) navodi da VaR sažima najgori gubitak tokom ciljanog perioda posmatranja koji neće biti premašen s datim nivoom pouzdanosti.¹

Uz pojednostavljene pretpostavke korištene u izračunu, VaR agregira sve rizike u portfoliju u jedan broj pogodan za izvještavanje.² Taj broj može biti netačan, ali u situacijama koje zahtijevaju barem procjenu reda veličine potencijalnog gubitka portfolija ili u kojima se mora napraviti brza komparacija koji je od dva portfolija rizičniji, teško je izbjeći korištenje neke vrste VaR procjene.³

Iako je primjena VaR modela razvijena u finansijskim institucijama u stabilnim i visokolikvidnim tržištima, njihova upotreba u zemljama u razvoju i tranziciji suočava se s brojnim izazovima. Ove zemlje karakterišu niska likvidnost, ograničena dostupnost i kvalitet podataka, te sporija implementacija međunarodnih regulatornih standarda, što sve zajedno može smanjiti pouzdanost i efektivnost VaR metoda.

U radu se daje pregled i komparativna analiza tri najčešće korištene VaR metode – parametarske metode, historijske simulacije i Monte Carlo simulacije. Cilj je ukazati na njihove teorijske osnove, prednosti i ograničenja, te posebno naglasiti kako se navedene metode primjenjuju u bankarskom sektoru manje razvijenih zemalja, odnosno zemalja u razvoju i tranziciji.

1 Jorion, P., (2007), „Value at Risk: The New Benchmark for Managing Financial Risk“, 3rd edition, McGraw-Hill Education, SAD, str. 17

2 Linsmeier, T.J., Pearson N.D, (1996), “Risk Measurement: An Introduction to Value at Risk”, Mimeo, University of Illionis at Urbana-Champaign, str. 3

3 Malz, Allan M., (2011), „Financial Risk Management: Models, History, and Institution“, John Wiley & Sons, New Jersey str. 93

MODELI IZRAČUNA RIZIČNE VRIJEDNOSTI

Modeli za izračunavanje rizične vrijednosti mogu se razvrstati, s obzirom na pretpostavku vjerovatnoće distribucije faktora rizika na kojoj se zasniva i s obzirom na način vrednovanja. S obzirom na vjerovatnoću, u prvu grupu spadaju modeli koji su zasnovani na pretpostavci da su vrijednosti faktora rizika normalno distribuirane, a u drugu grupu metode koje proizilaze iz drugih vrsta distribucije.⁴

Postoje tri glavna pristupa izračunavanju VaR-a: analitični pristup, također poznat kao matrica varijanse-kovarijanse ili korelacijska matrica, i dvije tehnike simulacije, historijska simulacija i Monte Carlo simulacija. Svaka ima posebne snage i slabosti, te ih treba ispravno promatrati, ne kao konkurentne metodologije, već kao alternative koje bi mogle biti prikladne u određenim okolnostima.⁵

Historijska simulacija

Ideja metode historijske simulacije je procjena rizične vrijednosti bez stvaranja ozbiljnih pretpostavki o raspodjeli prinosa. Za procjenu VaR vrijednosti koristi se nedavna empirijska raspodjela prinosa. Zasniva se na pretpostavci da se historija uvijek ponavlja s aspekta rizika, te da će bliska budućnost biti veoma slična nedavnoj prošlosti. Stoga se u ovaj model mogu uključiti i rijetki događaji i finansijske krize.⁶

Ova metoda je konceptualno jednostavna, pružajući rezultate koje je lahko prenijeti višim menadžerima ili regulatorima, te agencijama za rejting. Koristi podatke koji su dostupni, bilo iz javnih izvora ili iz internih skupova podataka.⁷

Historijska simulacija zasniva se na naknadnom vrednovanju trenutnog portfolija uz pomoć historijskih mjera i cijena. Prvo se određuje trenutna vrijednost izabranog portfolija koja se potom vrednuje na izabrane datume u prošlosti po važećim tržišnim cijenama. Zatim se računa razlika između trenutne vrijednosti portfolija i njegove ocijenjene vrijednosti na svaki izabrani datum u prošlosti. Tako se dobiju promjene njegove vrijednosti. Sve te promjene se rangiraju od najvećeg gubitka do najvećeg dobitka. Rizična vrijednost je jednaka onoj promjeni (najvećem gubitku) koja odgovara izabranoj signifikanci.⁸

Pri korištenju historijske simulacije javlja se problem izbora optimalnog

4 Obradović, B., Aureo, B., Miljković, M. (2018), „VaR analiza u cilju identifikovanja finansijskih rizika“, *Oditor*, godina 4, broj 3, str. 49

5 Stambaugh, F., (1996), „Risk and Value at Risk“, *European Management Journal*, Vol. 14., No. 6, Elsevier Science Ltd, str. 614

6 Abdić, Adem, Abdić, Ademir, (2010), „Value-at-Risk metoda za upravljanje tržišnim rizicima“, *Zbornik radova-Sarajevo Business and Economics Review (SBER)*, 30, str. 23

7 Obadović M., Maksimović R., Obadović M., (2010), „The Estimate of the Market Risk by the Application of Historical Simulation Method in the Period of Growth of Stock Exchange Indices on Belgrade Stock Exchange“, *Ekonomika istraživanja*, Vol. 23, No 3., str. 84

8 Obradović, Aureo, Miljković, (2018), „VaR analiza u cilju identifikovanja finansijskih rizika“, *Oditor*, god. 4, br. 3, 41-61

vremenskog perioda. Ako se vrijednosti određenog faktora promatraju daleko u prošlost, postavlja se pitanje kako vrlo staro zapažanje može biti relevantno za trenutno mjerenje izloženosti rizicima. Ako je izabrani period prekratak, postavlja se pitanje da li broj izmjerenih vrijednosti predstavlja dovoljno reprezentativnu vremensku seriju podataka na osnovu koje se prognoziraju potencijalni gubici zauzete pozicije.

Osnovna prednost historijske metode je jednostavnost izračuna, pa su rezultati pogodni za daljnja modifikiranja i usavršavanja. Prednost je i u tome što je metoda potpuno neparametarska i ne ovisi ni o kakvim pretpostavkama o raspodjeli faktora rizika.

Važni nedostaci su nepostojanje dovoljno bogate baze podataka kao i činjenica da ova metoda daje podjednaku važnost historijskim podacima od prošle sedmice i prošle godine. Također, metoda pretpostavlja da se historija ponavlja, odnosno da će budućnost biti podjednako volatilna. Međutim, historijski promatrani period može obuhvatati događaje, poput pada tržišta ili, obrnuto, periode iznimno niske volatilnosti cijena, koji se vjerovatno neće ponoviti u budućnosti.

Korištenje malih uzoraka historijskih podataka neizbježno ostavlja praznine u distribucijama faktora rizika i obično potcenjuje repove distribucija - tj. pojavu malo vjerovatnih, ali ekstremnih događaja.⁹

Parametarska metoda

Parametarska metoda izračuna VaR-a u literaturi se nalazi pod brojnim nazivima, od kojih su najčešći: metoda varijanse-kovarijanse, „delta-normal“ metoda, analitični VaR ili RiskMetrics. Zasniva se na pojednostavljenim pretpostavkama kretanja tržišnih cijena i karakteristika portfolija.¹⁰

Pretpostavka primjene ove metode je da tržišni faktori imaju normalnu distribuciju.¹¹ Ovaj pristup je relativno jednostavan i široko se koristi i uključuje dijelove moderne teorije portfolija Harryja Markowitza, uzimajući u obzir koeficijente korelacije između imovine.¹²

Rizična vrijednost može se izračunati za portfolio procjenjujući očekivane vrijednosti i standardne devijacije svake dionice (na osnovu historijskih podataka), ali pri tome uvažavajući korelaciju dobitaka ili povrata među dionicama procjenom matrice korelacije ili matrice varijansi/kovarijansi.¹³

9 Crouhy, M., Galai D., Mark, R. (2014), „The Essentials of Risk Management“, 2nd, McGraw-Hill Education, eBook, str. 250-254

10 Miloš Sprčić, D., Radić, D., (2011), „Kvantifikacija izloženosti rizicima – usporedba i ocjena metoda VaR i CfaR“, Zbornik radova Ekonomskog fakulteta u Zagrebu, god. 9, br. 1, str. 55

11 Megla, I., Kurnoga, N., Dolinar, D., (2017), „Primjena Value-at-Risk metode u analizi sastavnica indeksa CROBEX10, Zbornik Ekonomskog fakulteta u Zagrebu, godina 15, br. 2, str. 19

12 Čorkalo, Š. (2011), „Comparison of Value at Risk Approaches on a Stock Portfolio“, Croatian Operational Research Review (CRORR), Vol. 2, str. 82

13 Mundar, D., Zemljak, A., (2016), „Izračun rizične vrijednosti – VaR“, Poučak: časopis za metodiku i nastavu matematike, Vol. 17, No. 68, str. 72-73

Opća formula za izračunavanje VaR-a portfolija ovom metodom glasi:

$$VaR_p = \sqrt{\sum_{i=1}^n w_i^2 \sigma_i^2 + \sum_{i=1}^n \sum_{\substack{j=1 \\ i \neq j}}^n w_i w_j \sigma_i \sigma_j \rho_{i,j}}$$

gdje je:

- i – vrijednost stavki pozicije portfolija
- i – promjenljivost stavki pozicije portfolija
- koeficijent korelacije između stavki portfolija

Komercijalizirani programi poput J.P. Morganovog RiskMetricsa pojednostavljaju proces mapiranja rizika jer koriste vlastite skupove korelacija i volatilnosti. Stoga, menadžeri moraju jednostavno identificirati relevantne faktore rizika koje će uključiti u model.

RiskMetrics model u praksi pokazuje i neke slabosti. Prvo, pretpostavka o normalnosti distribucije dnevnih dobitaka i gubitaka portfolija za neke je finansijske instrumente veoma diskutabilna. Istraživanja pokazuju da tržišna kretanja često odstupaju od matematičkog ideala normalne distribucije. Drugo, problematična je i pretpostavka o linearnosti portfolija koja podrazumijeva linearnu povezanost stopa instrumenata i promjene vrijednosti portfolija. Ova pretpostavka vrijedi u slučaju portfolija s jednostavnijim finansijskim instrumentima, a gubi vrijednost za portfolio koji uključuje opcije i/ili druge finansijske derivate, te neke vrste finansijskih instrumenata zbog toga što cijene tih instrumenata linearno ne prate promjene kamatnih stopa ili deviznih kurseva.

Zbog toga se kaže da RiskMetrics (RM) model neadekvatno mjeri rizik kompleksnih, nelinearnih finansijskih instrumenata. Dalje, RM model pretpostavlja strukturalnu nepromijenjenost portfolija u toku promatranog perioda, najčešće jednog radnog dana, te pokazuje slabost funkcioniranja u trenucima finansijskih kriza i na nelikvidnim tržištima.

Uprkos svim nedostacima, RM model je relativno jednostavna i brza metoda izračunavanja VaR, a samim tim i brza aproksimacija dnevnog tržišnog rizika pojedinog portfolija.¹⁴

Monte Carlo simulacija

Temeljna pretpostavka RiskMetrics modela jeste da se dobiti i gubici portfolija distribuiraju normalnom krivom. Pođe li se od toga da ovakva pretpostavka nije realna, može se razviti historijski model, koji se zasniva na historijskim podacima, tj. na pretpostavci da će se buduće promjene kretati baš kao u prošlosti. Međutim, ako se uzme da ni to predviđanje nije dovoljno

¹⁴ Šverko, I., (2002), „Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima”, Ekonomski pregled 53, str. 651

realno, dolazi se do Monte Carlo simulacije čiji je zadatak statističko generiranje slučajnih scenarija na osnovu kojih se može odrediti VaR.

Kod Monte Carlo simulacije za VaR korisnik sam bira teorijsku statističku distribuciju koja prema njegovim spoznajama najbolje opisuje kretanja temeljnih faktora rizika, ili, pak kreira tu distribuciju na osnovu podataka o historijskoj volatilnosti temeljnih faktora rizika. Zatim, korištenjem generatora „pseudo-slučajnih“ brojeva vrši pseudo slučajno uzorkovanje iz te distribucije, odnosno simulira stotine ili hiljade promjena temeljnih faktora rizika.

Na osnovu realizacija tih promjena utvrđuje simulirane buduće vrijednosti, a kada od njih oduzme sadašnje tržišne vrijednosti, kreira jedan broj hipotetičkih dobitaka ili gubitaka portfolija, odnosno njihovim rangiranjem distribuciju dobitaka i gubitaka. Konačno, na osnovu analize ovako dobivene distribucije korisnik može doći do VaR mjere.¹⁵ Pristup Monte Carlo zahtijeva izradu pretpostavki o strukturi tržišta, stohastičke procese kretanja cijena, korelaciju između faktora rizika i volatilnost tih faktora.¹⁶

Metodologija Monte Carlo sastoji se od tri glavna koraka:¹⁷

1. Generiranje scenarija, korištenjem procjena volatilnosti i korelacije za osnovnu imovinu u portfoliju, izrađuje se veliki broj scenarija budućih cijena u skladu s log normalnim modelima.
2. Za svaki scenarij izračunava se vrijednost portfolija.
3. Izvještavanje o rezultatima simulacije, bilo kao distribuciju portfolija ili kao određenu mjeru rizika.


U slučaju da u portfoliju ima više faktora rizika, potrebno je kreirati matricu kovarijansi. Dekompozicija matrice se radi da bi faktori rizika bili međusobno korelirani u svakom generiranom scenariju. Slika prikazuje postupak Monte Carlo simulacije u ovom slučaju.

15 Kozarević, E., (2009), „Analiza i upravljanje finansijskim rizicima“, CPA, Tojšići str. 219

16 Miloš Sprčić, D., Radić, D., (2011), op. cit., str. 58

17 Bohdalova, M., (2007), „A Comparison of Value at Risk Methods for Measurement of the Financial Risk“, Faculty of Management, Comenius University, Bratislava, Slovakia, vol. 10, str. 5

Slika 1. Postupak izračuna VaR-a pomoću Monte Carlo simulacije



Izvor: Marrison, C. (2002), „*The Fundamentals of Risk Measurement*“, McGraw Hill, New York, str: 119

Monte Carlo simulacija, poput historijske simulacije, omogućuje analitičaru izračun intervala pouzdanosti VaR-a, tj. raspona vjerovatnih vrijednosti koje bi VaR mogao poprimiti ako bismo simulaciju ponovili više puta. Što je ovaj interval pouzdanosti uži, to je procjena VaR-a preciznija. Monte Carlo simulacija ovdje ima posebnu prednost: lahko je provesti analize osjetljivosti promjenom tržišnih parametara korištenih u analizi, kao što je struktura ročnosti kamatnih stopa.

Jedan nedostatak Monte Carlo pristupa je taj što analitičar mora biti u mogućnosti procijeniti parametre distribucija, kao što su srednje vrijednosti, varijanse i kovarijanse. Glavno ograničenje pristupa, međutim, je pragmatičnije: količina resursa koje troši. Monte Carlo simulacija ostaje vrlo kalkulatorski intenzivna i ne može se koristiti za izračun VaR-a vrlo velikih i složenih portfolija.¹⁸

Ovaj model je najzahtjevniji u pogledu potrebnog hardvera i intelektualnog know-how-a. Nedostatak proizilazi i iz toga što se ona oslanja na specifičan slučajni proces koji definira buduća kretanja faktora rizika, kao i na modele za određivanje cijena takvih vrsta finansijskih instrumenata kao što su opcije ili pak hipotekarni finansijski instrumenti, pa je podložna ozbiljnom riziku modela. Ako je odabran neadekvatan slučajni model kojim bi trebala biti opisana dinamika osnovnih faktora rizika, to znači da će biti pogrešna i procjena VaR.¹⁹

¹⁸ Crouhy, M., Galai D., Mark, R., (2014), op. cit., str. 254-256

¹⁹ Kozarević, E., (2009), op. cit., str. 221

KOMPARACIJA VAR MODELA

S obzirom na tri metode koje se mogu koristiti, postavlja se pitanje koja je metoda izračuna rizične vrijednosti najbolja, a za to nema jednostavnog odgovora. Metode se razlikuju po svojoj sposobnosti da obuhvate rizike opcija i instrumenata sličnih opcijama, jednostavnosti implementacije, jednostavnosti objašnjenja višem menadžmentu, fleksibilnosti u analizi učinka promjena u pretpostavkama i pouzdanosti rezultata. Najbolji izbor odredit će se prema tome koje dimenzije menadžer rizika smatra najvažnijima.²⁰

Dvije metode simulacije dobro funkcioniraju bez obzira na prisutnost opcija i instrumenata sličnih opcijama u portfoliju. Nasuprot tome, standardna parametarska metoda dobro funkcionira za instrumente i portfolija s malim sadržajem opcija, ali ne tako dobro kao dvije metode simulacije kada su opcije i instrumenti slični opcijama značajni u portfoliju.

Osnovna razlika između historijske i Monte Carlo simulacije je u tome što historijska simulacija pristupa generiranju distribucije dobitaka i gubitaka portfolija na temelju historijskih podataka, npr. podataka o tržišnim cijenama dijelova portfolija u n posljednjih radnih dana (obično se n kreće u rasponu od 100 do 500), a Monte Carlo simulacija na temelju slučajnog izvlačenja iz slučajnog (stohastičkog) procesa za finansijske varijable.²¹

Što se tiče jednostavnosti primjene, historijska simulacija lahko se implementira za portfolije za koje su dostupni podaci o prošlim vrijednostima temeljnih tržišnih faktora. Glavna poteškoća u implementaciji historijske simulacije je ta što zahtijeva od korisnika da posjeduje vremenski niz relevantnih tržišnih faktora koji pokrivaju posljednjih N dana, što može predstavljati problem.

Za Monte Carlo simulaciju i parametarsku metodu dostupan je i odgovarajući softver, tako da je ovu metodu lahko implementirati za portfolija s tržišnim faktorima i vrstama instrumenata koje pokrivaju dostupni sistemi. Međutim, navedene metode mogu biti teške za implementaciju u portfolijima koji uključuju tržišne faktore i vrste instrumenata koje ne pokrivaju dostupni sistemi.

Konceptualna jednostavnost historijske simulacije olakšava prezentiranje podataka višim menadžerima. Parametarsku metodu teško je objasniti onima kojima nedostaje tehnička obuka jer je ključni korak, matematika normalne distribucije u izračunavanju standardne devijacije portfolija i VaR-a. Monte Carlo simulaciju još je teže objasniti. Odabir statističke distribucije za predstavljanje promjena tržišnih faktora i korištenje pseudo-slučajnog uzorkovanja iz te distribucije jednostavno su strani većini ljudi.²²

²⁰ Ibidem, 222

²¹ Kozarević, E., (2009), op. cit., str. 214

²² Linsmeier, Thomas J., Pearson, Neil D., (2000), op. cit., str. 57-59

Glavna razlika u odnosu na historijsku simulaciju je u tome što se umjesto provođenja simulacije korištenjem opaženih promjena tržišnih faktora tokom posljednjih N razdoblja za generiranje N hipotetskih dobitaka ili gubitaka portfolija, odabire statistička distribucija za koju se vjeruje da adekvatno obuhvata ili aproksimira moguće promjene tržišnih faktora. Zatim se koristi generator pseudoslučajnih brojeva za generiranje hiljada ili možda desetaka hiljada hipotetskih promjena tržišnih faktora.

One se zatim koriste za konstruiranje hiljada hipotetskih dobitaka i gubitaka portfolija na trenutnom portfoliju i distribucije moguće dobiti ili gubitka portfolija. Konačno, rizična vrijednost se zatim određuje iz ove distribucije.²³

Prednost parametarske metode je u jednostavnoj implementaciji, te niskim troškovima implementacije, što je važno za banke, odnosno finansijske institucije s ograničenim resursima. Glavni nedostatak ove metode je u pretpostavci o normalnosti distribucije podataka, koja često adekvatno ne odražava realne tržišne uvjete karakteristične za volatilna i slabo likvidna tržišta zemalja u razvoju i tranziciji.

IZAZOVI PRIMJENE VAR METODA U BANKARSKOM SEKTORU ZEMALJA U RAZVOJU – PRIMJER BIH

Primjena VaR metoda u bankarskom sektoru nerazvijenih zemalja suočava se sa nizom specifičnih izazova koji utječu na pouzdanost i efektivnost ovih modela. Dok razvijene zemlje imaju stabilne, diverzificirane i digitalizirane bankarske sektore koji su povezani sa globalnim finansijama, u zemljama u razvoju bankarstvo ostaje tradicionalnije, oslonjeno na kredite i depozite, sa većim rizicima i slabijom digitalnom infrastrukturom.

Poseban izazov predstavlja mogućnost primjene VaR-a na finansijskim tržištima u zemljama u razvoju. Primjena VaR metoda na tržištima u nastajanju zahtijeva posebnu pažnju, posebno u pogledu nedovoljne likvidnosti, malog obima trgovanja i historijski gledano, asimetričnog i malog broja dana trgovanja s određenim vrijednosnim papirima.

Finansijska teorija ukazuje na činjenicu da veća volatilnost koja je karakteristična za prinose tržišta u razvoju odgovara većim očekivanjima prinosa na tim tržištima. Također, u poređenju s razvijenim tržištima, tržišta u razvoju karakteriziraju reforme finansijskog tržišta, česti unutarnji i vanjski finansijski šokovi, visok nivo rizika zemlje (tj. politički rizik, ekonomski rizik i finansijski rizik), promjene kreditnog rejtinga, nivo trgovanja povlaštenim informacijama itd.

Navedeni faktori utječu na rast volatilnosti tržišta u nastajanju i posljedično na rast odstupanja od normalne distribucije, što rezultira nemogućnošću adekvatnog predviđanja tržišnog rizika u investicijskim procesima. Također,

²³ Ibidem, str. 15

metode kvantifikacije tržišnog rizika koje kao temelj imaju pretpostavku normalne distribucije manje su pouzdane na tržištima u nastajanju.²⁴

Parametarska metoda kao što je ranije naglašeno se oslanja na normalnu raspodjelu prinosa i korelacije između finansijskih instrumenata. Tržišta zemalja u razvoju su često nelikvidna, dok prinosi imaju asimetričnu raspodjelu i debele repove, iz kojeg razloga ova metoda ima potencijal potcjenjivanja rizika, iako je s aspekta primjene vrlo jednostavna.

Historijska simulacija je zbog jednostavnosti primjene metoda koja bi bila primjerena tržištima zemalja u razvoju, zbog toga što ne zahtijeva pretpostavke o distribuciji niti koeficijente korelacije između finansijskih instrumenata. Također i njena primjena na tržištu može biti otežana zbog niskog obima trgovanja i nepostojanja dovoljno kontinuirane serije podataka koja bi bila javno dostupna.

Monte Carlo simulacija se smatra tehnički najnaprednijom VaR metodom iz razloga što omogućava da se u izračun VaR-a uključe volatilnosti na tržištu, specifični stres scenariji i debeli repovi distribucije. Dakle, ova metoda može kreirati scenarije koji u historiji nisu zabilježeni, što je značajno u ekonomskim sistemima koji prolaze kroz tranziciju i strukturalne promjene. Međutim, za većinu finansijskih institucija zemalja u razvoju primjena ove metode je izazovna zbog zahtjevnije informacijsko-tehničke infrastrukture i potrebe za specijaliziranim kadrom, odnosno zahtijeva resurse koji nisu uvijek na raspolaganju.

U kontekstu analize domaćeg bankarskog sektora treba istaći da je isti u 2024. godini ostao stabilan i otporan na rizike u nešto povoljnijem makroekonomskom okruženju u odnosu na prethodnu godinu. Sveukupna ocjena indikatora finansijskog zdravlja ukazuje da je otpornost bankarskog sektora povećana u odnosu na prethodnu godinu budući da su vrijednosti indikatora kapitaliziranosti zabilježile rast, zadržan je trend postepenog poboljšanja kvaliteta aktive, indikator u segmentima profitabilnosti su poboljšani, te je očuvana visoka likvidnost. Ukupna izloženost riziku svih banaka u sistemu na kraju 2024. godine iznosi 25,6 milijardi KM, što predstavlja rast od 3,6 milijardi KM ili 16,2%. Na nivou sistema, struktura ukupne izloženosti riziku se nije značajnije promijenila u odnosu na kraj prethodne godine, te su banke najviše izložene kreditnom riziku (91,5%), dok izloženosti operativnom i tržišnom riziku čine 7,8% i 0,7% ukupne izloženosti riziku.²⁵ Banke u BiH kao važan dio u procesu upravljanja tržišnim rizikom izdvajaju testiranje otpornosti na stres portfolija banke u odnosu na ekstremne promjene tržišnih uvjeta i izračun osjetljivosti portfolija prema kriznim scenarijima, kao i eventualni utjecaj istih na finansijski rezultat.²⁶

24 Anđelić, G., Đaković, V., Radišić, S., (2017), Application of VaR in Emerging Markets: A Case of Selected Central and Eastern European Countries, International Journal of Management and Business Studies, Vol 7, str. 2

25 Izvještaj o finansijskoj stabilnosti, (2024), Centralna banka CBBIH, str. 49

26 Raiffeisen Bank BiH d.d., Godišnji izvještaj za 2024. Godinu., str. 85, dostupno na: <https://www.raiffeisenbank.ba/bs/o-nama/publikacije-izvjestaji/finansijski-izvjestaji/finansijski-izvje-taji.html>

Historijska simulacija, kao jedna od metoda izračuna VaR-a, je odabrana za vrednovanje deviznog rizika u ovom radu zbog jednostavnosti primjene, te zbog činjenice da se ne zasniva na koeficijentima korelacije koji nisu dostupni na bh. tržištu kapitala.

Izračun VaR-a za potrebe empirijskog dijela rada baziran je na metodologiji prema kojoj model historijske simulacije prolazi kroz četiri koraka²⁷:

1. Izračun ekvivalenta,
2. Izračun delta pozicije,
3. Izračun ukupnog rizika,
4. Rangiranje rizika, te pronalaženje rizične vrijednosti.

Primjenom historijske simulacije za izračun VaR-a na tržištu kapitala Bosne i Hercegovine, odnosno na primjeru Raiffiesen Bank BiH d.d. analizirati će se vrednovanje deviznog rizika. Na dan 31.12.2024. godine Raiffeisen Bank d.d. BiH ima kratku deviznu poziciju u vrijednosti od -5.019.000 USD (američki dolar).²⁸ Navedeni iznos je dobiven kao razlika imovine i obaveza denominiranih u američkom dolaru.

Korak 1:

Ako se uzme u obzir kurs USD u odnosu na BAM (konvertibilna marka) na dan 31.12.2024. godine, prema srednjem kursu Centralne banke Bosne i Hercegovine²⁹, može se dobiti ekvivalent pozicije na način kako je prikazano u tabeli:

Tabela 1. Izračun ekvivalenta pozicije u BAM

Valuta	Nominalni iznos pozicije na dan 31.12.2024.	Kurs BAM prema USD na dan 31.12.2024.	Ekvivalent u BAM na dan 31.12.2024.
USD	-5.019.000,00	0,533993	-9.398.999,61

Izvor: Izračun autora

Dakle, -5.019.000,00 USD na dan 31.12.2024. godine vrijedilo je -9.398.999,61 BAM, odnosno banka ima kratku deviznu poziciju u navedenom iznosu.

Korak 2:

U drugom koraku računa se delta pozicija, uz pretpostavljenu jednopostotnu deprecijaciju dolara u odnosu na BAM. Delta pozicija se dobije kao razlika

²⁷ Šverko, I., (2001), „Moguća primjena povijesne metode rizične vrijednosti (value at risk) pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj“, Financijska teorija i praksa, 25, (4), str. 611-615, a prema Saunders A., Cornett, M.M., “Financial Institutions Management: A Risk Management Approach”, fourth edition, McGraw-Hill/Irwin, 2003, New York, str. 244-246

²⁸ Ibidem, str. 86

²⁹ Dostupno na: <https://www.cbbh.ba/currencyexchange/?lang=bs>

originalne vrijednosti u BAM i pretpostavljene vrijednosti u BAM.

Tabela 2. Izračun delta pozicije u BAM

Datum	Nominalni iznos pozicije u USD na dan 31.12.2024.	Kurs BAM prema USD	Ekvivalent u BAM na dan 31.12.2024.	1,01*kurs	Pretpostavljeni iznos uz deprecijaciju dolara	Delta (razlika)
31.12.2024	-5.019.000,00	0,533993	-9.398.999,61	0,539333	-9.305.936,61	93.059,37

Izvor: Izračun autora

Izračun delta pozicije je potrebno ponoviti za svaki od promatranih dana.

Korak 3:

Treći korak podrazumijeva izračun deviznog rizika. Za ovu analizu uzet je uzorak od 366 dana, odnosno period od 01.01.2024. do 31.12.2024. godine, za koji su postojali javno objavljeni i dostupni podaci o promjenama kursa USD prema BAM. Potrebno je utvrditi dnevne promjene deviznog kursa USD u odnosu na BAM i pomnožiti te promjene deltama koje su već ranije izračunate u prethodnoj fazi.

Tabela 3. Izračun ukupnog rizika u BAM

Datum	Kurs BAM/USD	Promjena kursa	Delta	Rizik (delta * promjena)
31.12.2024	0,533993	0,086166%	93.059,37	8.018,52
30.12.2024	0,533533	0,000000%	85.033,94	0,00
29.12.2024	0,533533	0,000000%	85.033,94	0,00
28.12.2024	0,533533	0,383309%	85.033,94	32.594,29
27.12.2024	0,531488	0,000000%	49.195,29	0,00
26.12.2024	0,531488	0,000000%	49.195,29	0,00
25.12.2024	0,531488	0,019236%	49.195,29	946,33
24.12.2024	0,531386	0,028899%	47.396,40	1.369,71
23.12.2024	0,531232	0,000000%	44.693,10	0,00
22.12.2024	0,531232	0,000000%	44.693,10	0,00
21.12.2024	0,531232	-0,048153%	44.693,10	-2.152,10
20.12.2024	0,531488	-0,971608%	49.195,29	-47.798,56
19.12.2024	0,536652	-0,009500%	139.164,60	-1.322,01
...	...	...	...	...
...	...	...	...	...
...	...	...	...	...

Izvor: Izračun autora

Ako je 31.12.2024. godine USD deprecirao u odnosu na BAM za 0,086166%, te ako je delta pozicije BAM 93.059,37, tada je ukupan rizik na promatrani datum 8.018,52 BAM. Radi ograničenosti prostora i preglednosti podataka, u tabeli nisu dati izračuni za svaki od navedenih dana promatranja, ali metoda izračuna je ista.

Korak 4:

Završni korak podrazumijeva redanje rizika i pronalaženje rizične vrijednosti odnosno VaR-a. U promatranom uzorku potrebno je poredati rizik od najvećeg gubitka prema najvećoj dobiti. Rizik se reda za sve dane iz uzorka, a redanje rizika prikazano je u tabeli samo za prvih 15 dana poredanih po najvećem gubitku:

Tabela 4. Redanje rizika u BAM

Rb.	Datum	Rizik (delta * promjena)
1.	02.10.2024	-627.055,30
2.	04.01.2024	-597.332,14
3.	07.11.2024	-588.272,43
4.	11.6.2024	-479.224,30
5.	06.02.2024	-452.070,21
6.	12.04.2024	-415.462,48
7.	23.03.2024	-325.138,26
8.	10.09.2024	-324.824,69
9.	12.11.2024	-311.186,50
10.	15.06.2024	-278.606,91
11.	24.09.2024	-278.134,95
12.	17.01.2024	-270.715,85
13.	29.08.2024	-265.718,92
14.	15.02.2024	-243.985,25
15.	27.9.2024	-239.887,46

Izvor: Izračun autora

Ukoliko se na promatrani uzorak od 366 radnih dana primijeni interval povjerenja od 99%, odnosno 1% najgoreg scenarija (1% od 366 dana) dobije se iznos od 3,66 što zaokruživanjem predstavlja četvrti najveći gubitak.

Iznos od -479.224,30 KM je iznos VaR-a za naredni radni dan pri 99% nivou pouzdanosti. U prevodu, devizne pozicije u banci u 99% slučajeva neće premašiti iznos gubitka od 479.224,30 KM (četvrti najveći gubitak).

Uvidom u Godišnji izvještaj Raiffeisen banke d.d. BiH za 2024. godinu, ukupni regulatorni kapital iznosi 601.679.000,00 KM³⁰, dok je sama banka na kraju 2024. godine imala kapitaliziranost od 17,3% što je značajno iznad minimalnih zakonskih zahtjeva. Za utvrđivanje internog kapitalnog zahtjeva za devizni rizik, Raiffeisen bank d.d. BiH koristi regulatornu metodu koja se koristi

30 Raiffeisen BANK d.d. Bosna i Hercegovina, Godišnji izvještaj za 2024. godinu, str. 88

za utvrđivanje minimalnih kapitalnih zahtjeva za valutni rizik, bez modifikacija regulatorne metode. Kapitalni zahtjev za devizni rizik Raiffeisen bank d.d. BiH postavljen je u iznosu od 11.948.000 KM.³¹

Primjenom VaR metode historijskom simulacijom za navedenu banku izračunat je iznos VaR-a od 479.224,30 KM uz nivo pouzdanosti od 99%, što znači da devizne pozicije u banci u 99% slučajeva neće premašiti iznos gubitka od 479.224,30 KM. To znači da iznos CaR-a (Capital at Risk)³² mora biti na nivou od najmanje 479.224,30, odnosno biti najmanje na nivou mjere VaR-a. CaR je samo jedan od dijelova ili slojeva regulatornog kapitala. Na primjeru promatrane banke, a na osnovu kvantifikacije tržišnog rizika korištenjem historijske simulacije kao VaR koncepta, moguće je zaključiti da je postavljeni kapitalni zahtjev za devizni rizik u iznosu od 11.948.000 KM i više nego dovoljan.

Na osnovu analize rezultata može se zaključiti da metoda historijske simulacije pruža stabilne i realne procjene mogućih gubitaka uslijed promjena kretanja deviznih kurseva, te je pouzdana metoda pri procjeni deviznog rizika. Rezultati analize promatrane banke pokazuju da primjena VaR metode može dati korisnu kvantifikaciju tržišnog rizika i pomoći u procjeni kapitalne potrebe, ali pouzdanost procjene zavisi o izboru metode, vremenskom horizontu i backtestingu.

ZAKLJUČAK

U savremenom finansijskom okruženju, adekvatno upravljanje finansijskim rizicima je temelj stabilnosti bankarskog sektora, a pogotovo u ekonomijama zemalja u razvoju koje su izložene volatilnosti, slaboj likvidnosti i ograničenosti dostupnih podataka. Banke su izložene tržišnim rizicima, te je primjena pouzdanih savremenih kvantitativnih metoda za ocjenu rizika od ključne važnosti kako bi se osigurala stabilnost i profitabilnost. U tom kontekstu Value at Risk (VaR), odnosno metoda rizične vrijednosti je pronašla svoje mjesto kao najrasprostranjeniji i najjednostavniji alat za kvantifikaciju potencijalnih gubitaka u definiranom vremenskom periodu uz utvrđen nivo pouzdanosti, te je također osnova regulatornih i internih procesa upravljanja rizikom. Komparativna analiza VaR metoda pokazuje da svaka ima svoje prednosti i nedostatke, te mogućnosti primjene.

Parametarska metoda ostaje privlačna zbog jednostavnosti primjene i niskih troškova, ali pretpostavka metode o normalnoj raspodjeli prinosa i stabilnih tržišnih uvjeta često nije ispunjena u plitkim i nelikvidnim tržištima. Historijska

31 Objavljivanje podataka i informacija banke, Raiffeisen BANK d.d. BiH na izvještajni datum 31.12.2024. godine, str. 102

32 CaR (Capital at Risk – kapital pod rizikom) je vrlo značajan koncept koji definiše iznos kapitala banke koji je potreban da bi banka pokrila iznos potencijalnih gubitaka u narednom periodu pri odabranom nivou tolerancije

simulacija može ponuditi realniji prikaz tržišnih kretanja, međutim ograničena dostupnost podataka umanjuje njenu pouzdanost. Monte Carlo simulacija pruža najveću sposobnost modeliranja ekstremnih scenarija, ali zahtijeva visoku tehničku obučenosť i naprednu infrastrukturu što mnoge banke na tržištima zemalja u razvoju još uvijek nemaju.

Empirijska analiza ukazuje da VaR omogućava adekvatnu kvantifikaciju tržišnog rizika i pruža relativno preciznu osnovu za predviđanje potrebnog kapitala. Rezultati su pokazali da su procijenjeni gubici u skladu sa regulatornim zahtjevima. Istraživanje, međutim, ima određena ograničenja. VaR ne daje informacije o veličini gubitaka izvan praga pouzdanosti, pa se njegova primjena preporučuje uz dopunu drugim metodama poput stres testiranja i mjere očekivanog gubitka (Expected Shortfall).

Optimalan pristup pri upravljanju tržišnim rizikom na tržištima poput BiH bi bio kombinacija više VaR metoda, uz testiranje otpornosti na stres i backtesting, uz stalno unapređenje podataka, modela i regulatornog okvira. Jačanje kapaciteta bankarskog sektora i harmonizacija s međunarodnim standardima ključni su koraci ka pouzdanijem upravljanju tržišnim rizikom u zemljama u razvoju.

LITERATURA

1. Abdić, Adem, Abdić, Ademir, (2010), „Value-at-Risk metoda za upravljanje tržišnim rizicima“, Zbornik radova-Sarajevo Business and Economics Review (SBER), 30
2. Anđelić, G., Đaković, V., Radišić, S., (2017), Application of VaR in Emerging Markets: A Case of Selected Central and Eastern European Countries, International Journal of Management and Business Studies, Vol 7
3. Bohdalova, M., (2007), „A Comparison of Value at Risk Methods for Measurement of the Financial Risk“, Faculty of Management, Comenius University, Bratislava, Slovakia, vol. 10
4. Crouhy, M., Galai D., Mark, R. (2014), „The Essentials of Risk Management“, 2nd, McGraw-Hill Education, eBook
5. Čorkalo, Š. (2011), „Comparison of Value at Risk Approaches on a Stock Portfolio“, Croatian Operational Research Review (CRORR), Vol. 2
6. <https://www.cbbh.ba/currencyexchange/?lang=bs>
7. Izvještaj o finansijskoj stabilnosti (2024), Centralna banka CBBIH
8. Jorion, P., (2007), „Value at Risk: The New Benchmark for Managing Financial Risk“, 3rd edition, McGraw-Hill Education, SAD
9. Kozarević, E., (2009), „Analiza i upravljanje finansijskim rizicima“, CPA, Tojšići
10. Linsmeier, T.J., Pearson N.D, (1996), “Risk Measurement: An Introduction to Value at Risk”, Mimeo, University of Illinois at Urbana-Champaign

11. Linsmeier, Thomas J., Pearson, Neil D., (2000), Value at Risk, Financial Analysts Journal, Vol 56, No. 2
12. Malz, Allan M., (2011), „Financial Risk Management: Models, History, and Institution“, John Wiley & Sons, New Jersey
13. Marrison, C. (2002), „The Fundamentals of Risk Measurement“, McGraw Hill, New York
14. Megla, I., Kurnoga, N., Dolinar, D., (2017), „Primjena Value-at-Risk metode u analizi sastavnica indeksa CROBEX10, Zbornik Ekonomskog fakulteta u Zagrebu, godina 15, br. 2
15. Miloš Sprčić, D., Radić, D., (2011), „Kvantifikacija izloženosti rizicima – usporedba i ocjena meoda VaR i CfaR“, Zbornik radova Ekonomskog fakulteta u Zagrebu, god. 9, br. 1
16. Munđar, D., Zemljak, A., (2016), „Izračun rizične vrijednosti – VaR“, Poučak: časopis za metodiku i nastavu matematike, Vol. 17, No. 68
17. Obadović M., Maksimović R., Obadović M., (2010), „The Estimate of the Market Risk by the Application of Historical Simulation Method in the Period of Growth of Stock Exchange Indices on Belgrade Stock Exchange“, Ekonomska istraživanja, Vol. 23, No 3
18. Obradović, B., Aureo, B., Miljković, M. (2018), „VaR analiza u cilju identifikovanja finansijskih rizika“, Oditor, godina 4, broj 3
19. Raiffeisen Bank BIH d.d., Godišnji izvještaj za 2024. godinu, dostupno na: <https://www.raiffeisenbank.ba/bs/o-nama/publikacije-izvjestaji/finansijski-izvjestaji/finansijski-izvje-taji.html>
20. Stambaugh, F., (1996), „Risk and Value at Risk“, European Management Journal, Vol. 14., No. 6, Elsevier Science Ltd
21. Šverko, I., (2002), „Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima“, Ekonomski pregled 53
22. Stambaugh, F., (1996), „Risk and Value at Risk“, European Management Journal, Vol. 14., No. 6, Elsevier Science Ltd
23. Šverko, I., (2002), „Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima“, Ekonomski pregled 53