ANALIZA TRŽIŠNOG RIZIKA NA HRVATSKOM I NJEMAČKOM TRŽIŠTU KAPITALA PRIMJENOM VaR-a

Lukin, Frane

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:365799

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

ANALIZA TRŽIŠNOG RIZIKA NA HRVATSKOM I NJEMAČKOM TRŽIŠTU KAPITALA PRIMJENOM VaR-a

Mentor: **Student:**

izv.prof.dr.sc. Branka Marasović **Frane Lukin**

Split, lipanj, 2017.

SADRŽAJ:

1. UVOD 3

1.1. Problem istraživanja 3

1.2. Predmet istraživanja 6

1.3. Istraživačke hipoteze 7

1.4. Ciljevi istraživanja 8

1.5. Metode istraživanja 8

1.6. Struktura rada 9

1.7. Doprinos istraživanja 10

2. RIZIK, VRSTE RIZIKA I PREGLED TRŽIŠNOG RIZIKA 11

2.1. Definicija i vrste rizika 11

2.2. Definicija i osnove tržišnog rizika 12

2.3. Vrste tržišnog rizika 14

2.4. Načini mjerenja tržišnog rizika 16

3. VaR kao mjera tržišnog rizika 18

3.1. Definicija i osnove VaR-a 18

3.2. Povijesni pregled upotrebe VaR-a 20

3.3. Prednosti i nedostatci VaR-a 22

3.4. CVaR - Uvjetna rizičnost vrijednosti 23

4. Metode izračuna VaR-a 25

4.1. Povijesna metoda 25

4.1.1. Prednosti i nedostatci povijesne metode 26

4.2. Parametarska metoda 28

4.2.1. Prednosti i nedostatci parametarske metode 30
4.3. Monte Carlo simulacija 31
4.3.1. Prednosti i nedostatci Monte Carlo simulacije 32
4.4. Osvrt na metode izračuna VaR-a 33
4.5. Testiranje točnosti VaR modela backtestingom 34
5. PRIMJENA METODA IZRAČUNA VaR-a NA IZABRANIM PORTFELJIMA 35
5.1. Formiranje portfelja 35
5.2. Usporedba prosječnog prinosa i standardne devijacije dvaju portfelja 37
5.3. Izračun VaR-a povijesnom metodom 38
5.3.1. Provjera valjanosti načela subaditivnosti 43
5.3.2. Backtesting rezultata povijesne metode 43
5.3.3. Izračun CVaR-a povijesnom metodom 46
5.4. Izračun VaR-a parametarskom metodom 47
.4.1. Backtesting rezultata parametarske metode 53
5.5. Monte Carlo simulacija 55
5.5.1. Backtesting rezultata Monte Carlo simulacije 56
ZAKLJUČAK 59
LITERATURA 61
PRILOZI 63
SAŽETAK 65
SUMMARY 65

1. UVOD

1.1. Problem istraživanja

Rizik kao vjerojatnost odstupanja stvarnih od očekivanih ishoda svojstven je svakom ulaganju, štoviše prožima svaku ljudsku djelatnost. Ovisno u kontekstu u kojem se nalazi različito ga se definira. Postoje mnogobrojne podjele rizika, a u ekonomiji je jedna od najvažnijih ona na: poslovne rizike kao što su operativni i pravni rizik te financijske rizike u koje spadaju tržišni rizik, kreditni rizik i rizik likvidnosti. Među navedenima, u poslovanju s vrijednosnicama najvažniji je tržišni rizik.[1]

Tržišni rizik je sustavni, nediverzificirajući rizik, a javlja se zbog promjena u kamatnim stopama, deviznim tečajevima, promjene cijena dionica i promjene cijena roba.[2] Svakim je danom sve važniji jer je globalizacija tržišta kapitala uzrokovala prelijevanje krize iz jednog u drugo područje ili u drugi segment tržišta, a uz to je došlo do deregulacije, liberalizacije financijskog tržišta te pojave novih financijskih instrumenata uslijed čega je tržišni rizik porastao. Kao posljedica toga u zadnjim desetljećima se povećala učestalost izbijanja financijskih kriza kao i njihova snaga. Stoga se nametnula potreba za boljim mjerenjem i kontrolom tržišnog rizika.[3] S obzirom na to da je tržišni rizik vrlo zahtjevno i široko područje ne čudi postojanje mnogobrojnih metoda za njegovo mjerenje i upravljanje, a pet ih je najvažnijih: analiza osjetljivosti, stress testing, testiranje scenarija, CAPM model i Value at Risk (rizičnost vrijednosti) koja je predmetom interesa ovog rada i većina upućenih je smatra najboljom među navedenima.[4]

Rizičnost vrijednosti (VaR) daje odgovor na pitanje koliki je najveći mogući gubitak nekog financijskog instrumenta ili portfelja koji se može ostvariti u promatranom razdoblju uz određenu vjerojatnost.[5]

Iz prethodne definicije slijedi da je VaR određen s dva parametra:[6]

---

[1] Udovičić, A., Kadlec, Ž. (2013): Analiza rizika upravljanja poduzećem, Praktični menadžment: stručni časopis za teoriju i praksu menadžmenta, Vol.4 No.1, str. 51-52.
[2] Tuškan, B. (2009): Upravljanje rizicima upotrebom financijskih derivata u RH, Zbornik Ekonomskog fakulteta u Zagrebu, Vol.7 No.1, str. 111.
[3] Latković, M. (2002): Upravljanje rizicima: identifikacija, mjerenje i kontrola, Financijska teorija i praksa, Vol.26 No.2, str. 464.
[4] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 68.
[5] Novak, B., Sajter, D. (2007): VaR dioničkih i mješovitih investicijskih fondova u Republici Hrvatskoj, Ekonomski fakultet u Osijeku, str. 3.
[6] Abdić, A., Abdić, A., Kanlić, F. (2009): Primjena Value-at-risk metode na tržištu kapitala Bosne i Hercegovine, Zbornik radova ICEI, Sarajevo, str. 204-205.

- razina pouzdanosti
- vremenski period za koji se računa

Razina pouzdanosti (α) se uobičajeno kreće u rasponu između 90% i 99% čime se čitava distribucija podataka, najčešće prinosa, dijeli počevši s lijeve strane distribucije na dva dijela od kojih prvi obuhvaća (1-α)% najvećih gubitaka, dok su u drugom dijelu svi preostali podatci iz distribucije.

Vremenski period može biti dan, tjedan, mjesec ili neki drugi proizvoljni vremenski interval. Njegov odabir će ovisiti o profilu investitora pa će tako oni koji aktivno trguju vrijednosnicama kao što su investicijske banke, razni institucionalni investitori odabrati što kraći period vjerojatno na razini dana, dok će pasivni investitori poput mnogih pojedinaca računati VaR za duži period u kojem njihov portfelj ostaje fiksan. Postoji izvjesna zakonomjernost u veličini VaR-a za različite vremenske periode po kojoj VaR raste proporcionalno kvadratnom korijenu vremenskog razdoblja za koje se računa.

Sada kada je poznata definicija VaR-a i njegove odrednice može se uzeti konkretan primjer za interpretaciju VaR-a u praksi. Primjerice, ukoliko mjesečni VaR neke dionice iznosi 4% uz razinu pouzdanosti od 95%, investitor može biti siguran da unutar mjesec dana neće izgubiti više od 4% ulaganja uz vjerojatnost od 95%, odnosno, postoji mogućnost od 5% da će u tom mjesecu izgubiti više od 4% ulaganja.

Svrha VaR-a je maksimalni gubitak iskazati u jednoj brojci. Predstavlja značajno poboljšanje u upravljanju rizikom, nasuprot konvencionalnim mjerama rizika zbog mogućnosti kontrole rizika različitih vrsta imovine poput strane valute, dionica, obveznica, roba te kontrole rizika kamatnih stopa i kreditnog rizika.[7] Važan je za portfelj menadžere kojima omogućuje pronalaženje optimalnog odnosa rizika i prinosa, a regulatornim tijelima izračun i praćenje rizičnosti poslovanja financijskih institucija.[8]

VaR se pojavio krajem 80-ih ili početkom 90-ih godina 20. stoljeća, a prvi ga je popularizirao Dennis Weatherstone, nekadašnji glavni izvršni direktor banke J.P. Morgan. On je tražio da mu se svakodnevno na kraju poslovnog dana dostavlja izvještaj od jedne stranice koji će

[7] Aljinović, Z., Marasović, B., Šego, B. (2011): Financijsko modeliranje, Ekonomski fakultet u Splitu, Split, str. 161.
[8] Šverko, I. (2002): Rizična vrijednost (Value at risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, Vol. 53 No.7-8, str. 641.

prikazivati izloženost tvrtke kretanjima na tržištu i koji će pružati procjenu potencijalnih gubitaka tijekom sljedeća 24 sata, a ta je procjena bila rizičnost vrijednosti.[9]

Sljedeća tri događaja su važna za daljnju popularizaciju VaR-a:

- Bazelski dogovor iz 1995. godine
- objava na Internetu sustava RiskMetrics od strane banke J.P. Morgan
- zahtjev komisije za vrijednosne papire SAD-a (SEC) da kompanije objave svoju rizičnu vrijednost u godišnjim izvješćima.

Donošenje amandmana Bazelskih dogovora o rezervama kapitala banaka omogućeno je bankama da na osnovi svojih internih modela, i to ponajprije rizičnosti vrijednosti, odrede svoje kapitalne rezerve za tržišni rizik. Javno dostupan sustav RiskMetrics pružio je teorijske postavke metodologije rizičnosti vrijednosti i koeficijente korelacije među najvažnijim fin. instrumentima, kao i online VaR kalkulator. Time je VaR postao jednostavniji za korištenje mnogim investitorima što je dovelo do njegove veće upotrebe. Odlukom SEC-a sve financijske kompanije s tržišnom kapitalizacijom većom od 2,5 milijardi USD morale su u svojim godišnjim financijskim izvještajima navesti podatke o svojoj rizičnosti vrijednosti.[10]

VaR svoju privlačnost duguje svojim dvjema osnovnim karakteristikama. Prva je da nudi jednostavnu i konzistentnu mjeru rizika za različite pozicije i faktore rizika što je omogućilo usporedbu rizika vezanih uz investiranje u npr. obveznice i dionice ili usporedbu instrumenata koji do pojave VaR-a nisu bili usporedivi. Druga karakteristika je da uzima u obzir koeficijente korelacije između različitih faktora rizika.[11]

VaR ima brojne kritičare koji sumnjaju u valjanost statističkih i drugih pretpostavki vezanih uz VaR koje su uglavnom preuzete iz fizike i primijenjene na financije jer teoremi iz fizike ne razmatraju važne osobine društvenih sustava poput sposobnosti učenja i prilagođavanja sudionika na financijskim tržištima. Daljnje kritike idu u smjeru da su izračuni neprecizni te da nisu korisni budući da različiti modeli daju različite procjene rizika koristeći iste podatke. Najveća zamjerka odnosi se na nezadovoljavanje subaditivnosti, to jest, ne postoji sigurnost da će iznos VaR-a portfelja biti manji od zbroja VaR-a samostalnih pozicija koje čine taj portfelj. Također, problem se može javiti kod izbora vremenskog perioda iz kojeg se uzimaju

[9] Mikulčić, D. (2001): Value at Risk (Rizičnost vrijednosti), Hrvatska narodna banka, Zagreb, str. 1.
[10] Šverko, I. (2002): Rizična vrijednost (Value at risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, Vol. 53 No.7-8, str. 645.
[11] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 80.

podaci o cijenama zbog nemogućnosti istovremenog zadovoljenja dvaju uvjeta. Prvi uvjet je da se uključi dovoljno dugo razdoblje tako da podaci u sebi sadržavaju rijetke i ekstremne događaje, dok je drugi uvjet taj da se koriste podaci koji reflektiraju najnovija kretanja na tržištu jer se VaR-om želi predvidjeti buduća distribucija prinosa.

Kao pokušaj poboljšanja VaR-a nastala je uvjetna rizična vrijednost (CVaR) koja se definira kao prosječna vrijednost gubitka većeg od VaR-a. Važna je u situacijama kada distribucija prinosa nije normalna pa se tada CVaR i VaR mogu značajno razlikovati i za razliku od VaR-a zadovoljava načelo subaditivnosti.[12]

1.2. Predmet istraživanja

VaR se može izračunati primjenom povijesne metode, parametarske metode i Monte Carlo simulacije. Povijesna metoda je najjednostavnija, ne podrazumijeva određenu distribuciju prinosa, a zasniva se na pretpostavci da će se prinosi iz prošlosti ponoviti u budućnosti.

Parametarska metoda je najčešće korištena metoda, a polazi od pretpostavke da distribucija prinosa odgovara nekoj od teorijskih distribucija poput normalne distribucije. Naziv je dobila zbog izračuna VaR-a na osnovi dva parametra:

- prosječnog prinosa
- standardne devijacije prinosa.

Kada se računa za portfelj potrebno je pored očekivane vrijednosti i standardne devijacije prinosa svake dionice u obzir uzeti i korelaciju prinosa među dionicama izračunom matrice varijanci/kovarijanci.

Monte Carlo simulacija je najsloženija, vremenski najzahtjevnija, ali ujedno i najpreciznija metoda koja koristi slučajne brojeve i simulira prinos portfelja generiranjem slučajnih scenarija na osnovi kojih se određuje rizična vrijednost. Slična je povijesnoj metodi s razlikom u tome što se hipotetske promjene tržišnih faktora ne stvaraju na temelju prošlih opaženih promjena već se statističkom simulacijom na adekvatan način generiraju povrati slični onima iz prošlosti.[13]

[12] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 81-82.
[13] Munđar, D., Zemljak, A. (2016): Izračun rizične vrijednosti-VaR, Poučak: časopis za metodiku i nastavu matematike, str. 71-75.

Postupak utvrđivanja valjanosti VaR metode naziva se backtesting, a sastoji se od broja prekoračenja iznosa VaR-a u određenom razdoblju čime se donosi zaključak o reprezentativnosti određene metode na određenom tržištu kapitala.[14]

U empirijskom dijelu rada razmatrat će se portfelji od po 10 dionica s najvećom tržišnom kapitalizacijom na hrvatskom, odnosno njemačkom tržištu kapitala (takozvane blue-chip dionice) pod uvjetom da su ti portfelji diverzificirani. To znači da će broj dionica iz pojedinog sektora biti ograničen na najviše tri u svakom portfelju, ali dionice mogu biti iz različitih gospodarskih grana u portfeljima. Ulog u oba portfelja će biti u novčanim jedinicama s obzirom na različite valute u kojima kotiraju dionice iz oba portfelja. Podatci o cijenama dionica bit će uzeti iz istog vremenskog perioda i relativno su recentni jer najstariji podatak datira s početka 2016. godine, a najnoviji je zabilježen zadnjeg dana travnja ove godine. To bi trebalo osigurati relevantnost rezultatima istraživanja. Među odabranim dvama tržištima postoje brojne razlike jer je njemačko gospodarstvo mnogo snažnije od hrvatskog pa je samim tim njemačko tržište kapitala mnogo razvijenije i likvidnije što znači da je kao takvo manje sklono poremećajima. S druge strane, obično je na volatilnijim tržištima moguće ostvariti bolje prinose.

Za svaki portfelj izračunat će se VaR primjenom sve tri metode da bi se utvrdilo razlikuju li se značajno rezultati među različitim metodama, kolike su razlike u iznosu VaR-a između dvaju tržišta te na kojem tržištu je on manji. Nadalje, pratit će se odnos prosječnog prinosa i VaR-a što bi trebalo pomoći u donošenju zaključka koje je tržište pogodnije za konzervativnije, a koje za riziku sklonije investitore. Osim navedenog, testirat će se jesu li metode izračuna rizičnosti vrijednosti reprezentativne na oba tržišta, je li VaR kao mjera tržišnog rizika prikladnija za njemačko u odnosu na hrvatsko tržište kapitala te kreće li se VaR u istom smjeru na ovim dvama tržištima.

1.3. Istraživačke hipoteze

Nakon izlaganja problema i predmeta istraživanja postavlja se sljedeća glavna istraživačka hipoteza.

1. Value-at-risk (rizičnost vrijednosti) je manji na hrvatskom tržištu iz razloga što se BDP u Hrvatskoj kretao na znatno višim razinama od BDP-a u Njemačkoj u odabranom razdoblju

[14] Latković, M. (2002): Upravljanje rizicima: identifikacija, mjerenje i kontrola, Financijska teorija i praksa, Vol.26 No.2, str. 472.

Pomoćne hipoteze su:

1. Hrvatsko tržište kapitala je preporučljivo za investitore sklone riziku jer pruža mogućnost ostvarivanja većeg prosječnog prinosa i ima bolji omjer očekivanog prosječnog prinosa i potencijalnog gubitka mjerenog VaR-om
2. Različite metode izračuna VaR-a nisu jednako reprezentativne za hrvatsko i njemačko tržište kapitala.
3. VaR kao mjera tržišnog rizika je prikladnija za upotrebu na njemačkom nego na hrvatskom tržištu kapitala.
4. VaR se na oba tržišta kretao u istom smjeru u godinama obuhvaćenima promatranim razdobljem

1.4. Ciljevi istraživanja

Ciljevi ovog istraživanja se izvode iz prihvaćanja ili odbijanja glavne i pomoćnih hipoteza čime će se putem izračuna VaR-a dobiti jasna slika o rizičnosti ulaganja na hrvatskom, odnosno, njemačkom tržištu kapitala.

Također, ispitat će se na kojem tržištu je isplativije ulagati gledajući odnos potencijalnog prosječnog prinosa i očekivanog maksimalnog gubitka. Dodatno, potrebno je testirati jesu li metode izračuna VaR-a reprezentativne mjere tržišnog rizika na oba tržišta kako bi se dobiveni rezultati istraživanja mogli smatrati relevantnima. Osim navedenih empirijskih spoznaja, u teorijskom dijelu rada kao ciljevi se ističu predstavljanje samog VaR-a, svake metode za njegov izračun kao i prednosti i nedostataka pri upotrebi istih.

1.5. Metode istraživanja

Nakon proučavanja domaće i strane literature, stručnih i znanstvenih članaka, a u svrhu postizanja ciljeva istraživanja i donošenja zaključka, u teorijskom dijelu rada koristit će se sljedeće metode istraživanja:[15]

- metoda deskripcije – služi za jednostavno opisivanje ili očitavanje činjenica, procesa i predmeta te potvrđivanje njihovih odnosa i veza
- induktivna metoda – kojom se na temelju pojedinačnih činjenica dolazi do općeg zaključka
- deduktivna metoda – kojom se iz općih stavova izvode pojedinačni

[15] Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog rada, IV. izdanje, Ekonomski fakultet u Rijeci, Rijeka

- metoda analize – rastavljanje cjeline na dijelove
- metoda sinteze – spajanje dvaju ili više dijelova u cjelinu
- metoda klasifikacije – sistemska i potpuna podjela općeg pojma na posebne koje taj pojam obuhvaća
- metoda kompilacije – preuzimanje tuđih rezultata znanstveno-istraživačkog rada, opažanja, zaključaka i spoznaja
- metoda komparacije – uspoređivanje istih ili srodnih činjenica, odnosno utvrđivanje njihovih sličnosti i razlika
- metoda dokazivanja – sveobuhvatni misaono – sadržajni postupak kojim se utvrđuje istinitost pojedinih spoznaja, stavova ili teorija.

U empirijskom dijelu rada, na prikupljenim burzovnim podatcima o kretanju cijena izabranih dionica koristit će se matematičko - statističke metode i modeli. Svi izračuni će biti izvršeni u programu Microsoft Excel, dok će se testiranje normalnosti distribucije prinosa portfelja izvesti u programu STATISTICA.

1.6. Struktura rada

U prvom, uvodnom poglavlju će biti izneseni problem i predmet istraživanja što je ključno za razumijevanje ovog rada i na osnovi kojih će se postaviti istraživačke hipoteze i ciljevi istraživanja. Zatim će se navesti metode istraživanja upotrijebljene u izradi rada kao i doprinos istraživanja te sama struktura diplomskog rada.

Drugo poglavlje pod nazivom *Rizik, vrste rizika i pregled tržišnog rizika* započet će definiranjem rizika i navođenjem vrsta rizika. Budući da je tržišni rizik najvažnija vrsta rizika za predmet ovog rada o njemu će se detaljno govoriti nastavku poglavlja. Najprije će ga se definirati, potom će se navesti njegova temeljna obilježja i vrste, dok je kraj poglavlja rezerviran za najvažnije načine mjerenja tržišnog rizika.

U trećem poglavlju koje se bavi VaR-om kao jednom od mjera tržišnog rizika prvo će se definirati VaR i prikazati njegova svojstva, nakon čega slijedi povijesni pregled razvoja i upotrebe VaR-a. Poglavlje se dalje bavi navođenjem prednosti i nedostataka VaR-a, a završit će odlomkom o uvjetnoj rizičnoj vrijednosti kao mjerom koja nadilazi neka ograničenja VaR-a, a čuva njegova dobra svojstva.

U četvrtom poglavlju red će doći na pregled osobina, ali i specifičnosti triju metoda izračuna VaR-a . Za svaku od metoda prikazat će se postupak izračuna VaR-a dotičnom metodom uz

nabrajanje prednosti i nedostataka primjene iste. Nakon predstavljanja svih metoda pravi je trenutak osvrnuti se na bitne razlike među njima. Kraj poglavlja je ostavljen za odlomak o testiranju točnosti VaR modela.

Peto poglavlje rezervirano je za će praktični dio diplomskog rada u kojem će se nakon formiranja odgovarajućih portfelja, izračunati rizičnosti vrijednosti portfelja dionica s hrvatskog, odnosno njemačkog tržišta kapitala putem svih triju metoda. Dobiveni rezultati potom će se usporediti te će se testirati adekvatnost primjene dotičnih metoda. Tek nakon toga bit će moguće donijeti zaključak u kojem će se prihvatiti ili odbaciti hipoteze postavljene još u uvodnom dijelu rada. Na kraju rada će se navesti popis literature, prilozi i sažetak na hrvatskom i engleskom jeziku.

1.7. Doprinos istraživanja

VaR kao mjera tržišnog rizika svakim je danom sve popularnija zbog stalnog razvoja financijskih tržišta i instrumenata te veće dostupnosti istih zbog mogućnosti trgovanja putem Interneta. Uz to, jednostavno ju je interpretirati pa je mogu koristiti i investitori početnici, iako je primarno bila namijenjena portfelj menadžerima, a sve je više koriste i regulatori. Usprkos nizu prednosti i postojanju dužem od 30 godina, literatura na hrvatskom jeziku je još uvijek oskudna i često nepotpuna za razumijevanje svih aspekata VaR-a.

Ovaj rad može biti od pomoći svima onima koji nisu vični ulaganju, a namjeravaju se upustiti u to ili onima koji žele osvježiti ili produbiti svoje znanje iz financija. Budući da rad objedinjuje teorijski i praktični dio za mnoge zainteresirane će on biti dovoljan za stjecanje nužnih znanja o VaR-u pa dodatnu literaturu neće morati konzultirati. Uspoređujući VaR na hrvatskom s njemačkim tržištem kapitala domaći investitori će moći pored apsolutnog percipirati i relativni rizik na domaćem tržištu. Iako većina domaćih investitora nema pristup njemačkom tržištu kapitala, oni mogu uložiti u investicijski fond s njemačkim dionicama ukoliko na temelju rezultata ovog istraživanja procijene da to tržište više odgovara njihovom profilu. Osim usporedbe tržišta, uspoređivat će se i metode izračuna VaR-a kao i njihova reprezentativnost iz čega proizlazi preporuka koju metodu koristiti.

2. RIZIK, VRSTE RIZIKA I PREGLED TRŽIŠNOG RIZIKA

2.1. Definicija i vrste rizika

Rizici prate svaku ljudsku aktivnost, a svima je poznata uzrečica: „Tko ne riskira, taj ne profitira.“ Pojam rizik se mijenja ovisno o djelatnosti u kojoj se javlja te se kao takav različito definira. U ekonomiji, rizik se definira kao vjerojatnost nastanka nekog nepovoljnog ili štetnog događaja koju je moguće odrediti i izmjeriti. Ne može se poistovjetiti s neizvjesnosti jer je ona okolnost u kojoj ne postoji dovoljno točna spoznaja o vjerojatnosti nastanka štetnog događaja. Za rizik nije samo važna vjerojatnost nastupanja nekog događaja, nego i visina štete ako takav događaj nastupi. Stoga se rizik iskazuje umnoškom vjerojatnosti i vrijednosti štetnog događaja.[16] Svaki rizik ima tri nužna elementa: percepciju da bi se neki štetan događaj zaista mogao dogoditi, vjerojatnost da će se on zaista dogoditi i posljedice štetnog događaja koji bi se mogao dogoditi. Iz ovoga slijedi da svaki rizik uključuje tri neizostavne komponente: izloženost, neizvjesnost i vrijeme.[17] Brojni su načini na koji se rizik može podijeliti, a temeljna podjela je na unutarnje i vanjske rizike. Ovakva podjela je zastupljena na sljedećoj slici.



Slika 1: Vrste rizika

Izvor: Drljača, M., Bešker, M. (2010): Održivi uspjeh i upravljanje rizicima poslovanja, Centar za kvalitet Crne Gore, Tivat, str.

[16] Sabolić, D. (2013): Rizik i nesigurnost I., bilješke s predavanja, Fakultet elektrotehnike i računarstva, Zagreb, str.206.

[17] Drljača, M., Bešker, M. (2010): Održivi uspjeh i upravljanje rizicima poslovanja, Centar za kvalitet Crne Gore, Tivat, str. 3.

U daljnjoj podjeli, unutarnji rizici se mogu podijeliti na: strategijske rizike, rizike upravljanja, operativne i financijske rizike, dok su vanjski rizici: tržišni rizik, politički rizik, društveni rizik i elementarne nepogode.[18]

Drugi način na koji možemo podijeliti rizike je na: poslovne i opće rizike. Poslovni rizici su oni koje tvrtke samovoljno preuzimaju na sebe kako bi ostvarile profit, dok se rizici nad kojima tvrtke nemaju izravnu kontrolu nazivaju opći rizici. Može se reći da se ova podjela podudara s prethodnom pa bi se poslovni rizici mogli poistovjetiti s unutarnjim, a opći s vanjskim rizicima.

Postoji i podjela na: poslovne i financijske rizike pri čemu u poslovne rizike spadaju: operativni rizik, pravni rizik, rizik zakonodavstva, rizik ugleda, a financijske rizike čine: tržišni rizik, kreditni rizik i rizik likvidnosti.[19]

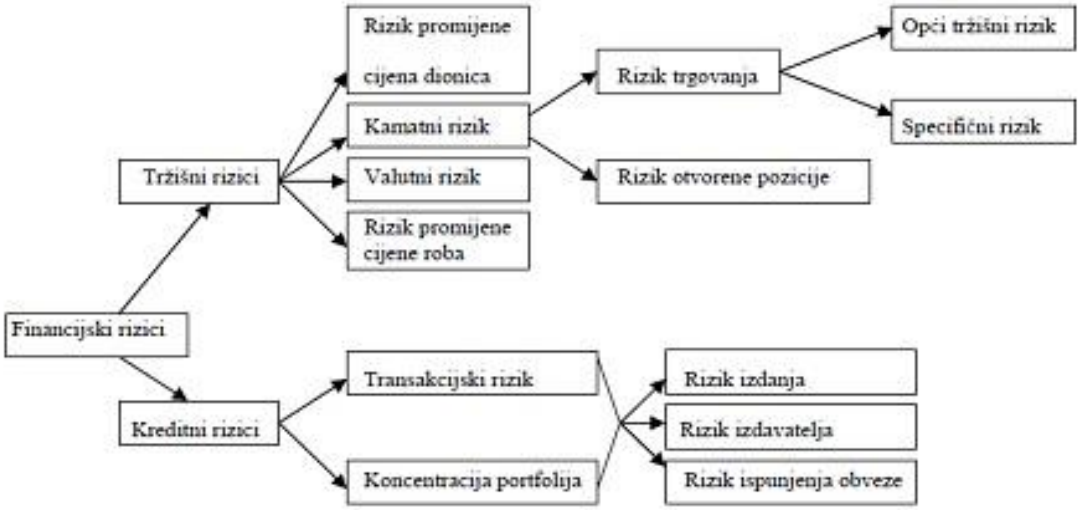
S obzirom na brojnost i važnost različitih rizika u današnjem svijetu postojanje sustava upravljanja rizicima kao cjelovitog procesa obuhvaćanja, mjerenja i nadziranja relevantnih i potencijalnih rizika te analize s tim u vezi potencijalnih gubitaka je ključno za investitore, a osnovni cilj tog procesa bi trebala biti optimizacija odnosa rizika i prinosa.[20]

2.2. Definicija i osnove tržišnog rizika

Tržišni rizik spada u grupu financijskih rizika i predstavlja promjenu tržišne vrijednosti portfelja zbog promjena u kamatnim stopama, deviznim tečajevima, cijenama vrijednosnica (uglavnom dionica) i cijenama roba. Najlakše ga je identificirati i kvantificirati od svih vrsta rizika jer se cijene vrijednosnica bilježe pri svakoj transakciji.[21]

Donja shema prikazuje podjelu financijskog rizika i njegovih podvrsta među kojima je tržišni rizik.

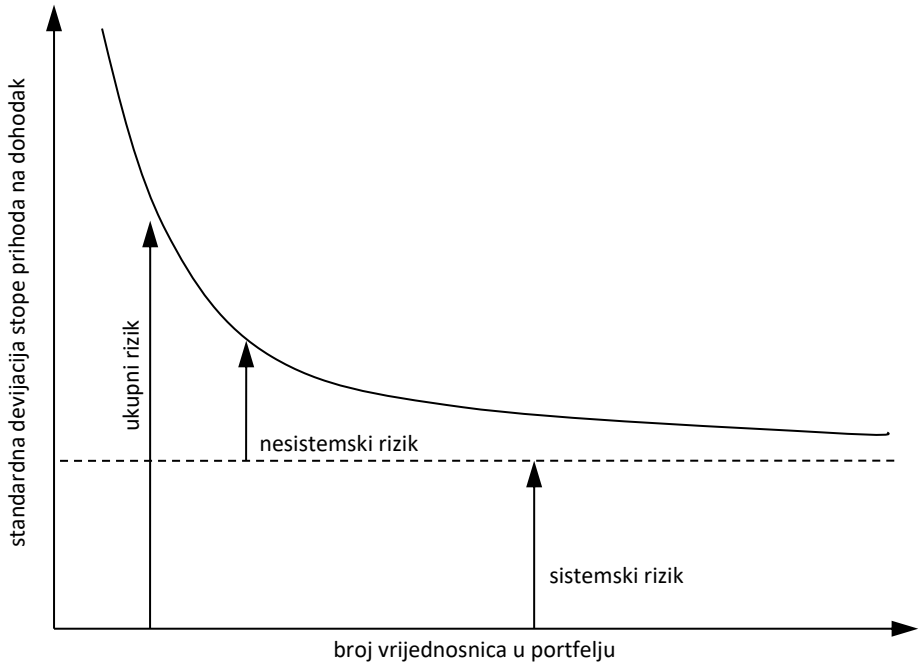
[18] Ibid., str. 4.
[19] Udovičić, A., Kadlec, Ž. (2013): Analiza rizika upravljanja poduzećem, Praktični menadžment: stručni časopis za teoriju i praksu menadžmenta, Vol. 4 No. 1, str. 51-52
[20] Drljača, M., Bešker, M. (2010): Održivi uspjeh i upravljanje rizicima poslovanja, Centar za kvalitet Crne Gore, Tivat, str. 5
[21] Šverko, I. (2002): Rizična vrijednost (Value at risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, Vol. 53 No.7-8, str. 641



Slika 2: Podjela financijskog i tržišnog rizika

Izvor: Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 51

Tržišni rizik ima svoja dva sastavna dijela: specifični(nesistemski) i sustavni rizik, iako mnogi autori samo za sustavni rizik rabe naziv tržišni rizik. Specifičan rizik je karakterističan za svaku pojedinu vrijednosnicu pa se može smanjiti povećanjem broja vrijednosnica u portfelju, to jest, diverzifikacijom. Sustavan rizik se odnosi na cijelo tržište i preostaje čak i nakon ekstenzivne diverzifikacije.[22] Grafički se tržišni rizik može prikazati kao na donjoj slici.



Slika 3: Sastavnice tržišnog rizika

Izvor: Šverko, I. (2002): Rizična vrijednost (Value at risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, Vol. 53 No.7-8, str. 642

[22] Ibid., str. 641-642

Na tržištu se svakodnevno događaju promjene cijena, no moraju se razlikovati situacije kada su te promjene uobičajene i odgovaraju određenim povijesnim prosjecima od situacija kada su te promjene mnogo izraženije nego što bi se to moglo očekivati temeljem povijesnih pokazatelja. Primjera radi, u nastavku je naveden popis nekoliko posljednjih potresa na financijskim tržištima koji su prouzročili promjene veće od 3 povijesne standardne devijacije:

1987. - slom tržišta,

1990. - slom japanskog tržišta,

1992. - kriza Europske monetarne unije,

1994. - promjena kamatnih stopa na američkom tržištu,

1994/1995. - kriza meksičke valute,

1995. - kriza u Latinskoj Americi,

1997. - azijska kriza,

1998. - ruska kriza i slom LTCM,

1999. - brazilska kriza,

2000. - slom američkog tehnološkog tržišta,

2001. - argentinska kriza,

2007/2008. - svjetska financijska kriza.

Ono što je zajedničko ovim događajima bila je nenadanost pojave krize, veličina gubitaka, ali i brzina oporavka u nekim slučajevima. Zbog sve veće učestalosti velikih lomova na tržištima kapitala, ali i težnji ka globalizaciji i deregulaciji tržišta mjerenje i upravljanje tržišnim rizikom postaje sve važnije.[23]

2.3. Vrste tržišnog rizika

Kamatni rizik nastaje promjenom tržišnih kamatnih stopa čime se mijenjaju kamatne stope na pojedinim pozicijama aktive i pasive svake financijske institucije što može negativno utjecati na buduće gotovinske tijekove i financijski rezultat. Promjena kamatne stope utječe kako na cijenu financijskog instrumenta (najčešće obveznica) tako i na ostvarene prinose od reinvestiranja koji se

[23] Latković, M. (2002): Upravljanje rizicima: identifikacija, mjerenje i kontrola, Financijska teorija i praksa, Vol.26 No.2, str. 466-467

kreću u suprotnom smjeru od cijena obveznica. Primjerice, porast tržišnih kamatnih stopa utjecat će na pad cijene financijskog instrumenta, dok će prinosi od reinvestiranja porasti. Ova vrsta tržišnog rizika najvažnija je za banke budući da njihova potraživanja i obaveze nemaju iste rokove dospijeća pa utjecaj kamatnog rizika nije neutralan. Kamatni rizik je uglavnom nediverzificirani rizik budući da razina svih kamatnih stopa teži da se mijenja zajedno i utječe na vrijednost svih vrijednosnih papira istovremeno. Manifestira se kroz svoja 4 temeljna oblika:[24]

1. rizik ročne neusklađenosti
2. rizik krivulje prihoda
3. temeljni rizik
4. rizik opcije

Rizik ročne neusklađenosti predstavlja rizik kojem je kreditna institucija izložena zbog vremenske neusklađenosti dospijeća (za fiksne kamatne stope) i ponovnog vrednovanja kamatnih stopa (za promjenjive kamatne stope) pozicija banke.

Rizik krivulje prihoda je rizik kojem je kreditna institucija izložena zbog promjene oblika i nagiba krivulje prinosa, a djeluje negativno na zaradu ili vrijednost banke. Dugoročne kamatne stope u pravilu će biti više od kratkoročnih kako bi se kompenziralo kreditora za vezivanje sredstava i kreditni rizik u dužem razdoblju, no u vrijeme velikih financijskih kriza može doći do inverzije krivulje prihoda i posljedično do gubitaka za financijske institucije.

Temeljni rizik ili rizik razlike je rizik od mogućih promjena u razlici između aktivnih i pasivnih kamatnih stopa. Može se javiti kada je banka zbog pojačane konkurencije prisiljena smanjiti aktivnu kamatu na kredit, a pritom povećati pasivnu kamatu na depozit.

Rizik opcije jest oblik rizika koji se ogleda u postojanju mogućnosti korištenja prava opcije na imovinu kupovinom ili prodajom novčanih tijekova vezanih za pojedine financijske instrumente ili ugovore (npr. obveznice s opcijom, krediti s opcijom prijevremene oplate, depoziti s mogućnošću povlačenja). Postoji mogućnost da će u slučaju promjene kamatne stope imatelj opcije istu iskoristiti. Na taj način banke mogu više izgubiti nego li su uprihodile od vlasnika opcije prilikom prodaje.

Valutni rizik pojavljuje se ukoliko promjene intervalutnih tečajeva svjetskih valuta prouzroče nepovoljne učinke na račun dobiti i gubitka i novčane tijekove poslovnog subjekta. Financijska institucija je izložena valutnom riziku u situaciji kada ima pozicije u aktivi i

[24] Živko, I. (2006): Kamatni rizik u bankarstvu-izvori i učinci, Ekonomski fakultet, Sveučilište u Mostaru, str.202-203.

pasivi koje su u različitim valutama. Ona ima kratku deviznu poziciju u situaciji kada su njene devizne obveze veće u odnosu na deviznu aktivu, a dugu deviznu poziciju kada je njena devizna aktiva veća od devizne pasive. Valutni rizik najčešće se pojavljuje kao:

1. obračunski (računovodstveni) rizik,
2. ekonomski rizik
3. transakcijski rizik.

Obračunski rizik se javlja kod poduzeća koja imaju svoje podružnice u inozemstvu prilikom iskazivanja poslovanja poduzeća u valuti zemlje gdje je sjedište matičnog poduzeća. Ekonomska izloženost može se definirati kao potencijalna promjena u budućim zaradama i novčanom tijeku koje su posljedica kretanja međunarodne vrijednosti domaće valute. Transakcijska izloženost mjeri utjecaj promjene tečaja na novčani tok kompanije, odnosno na njena potraživanja vezano za ugovore o uvozu i izvozu.

Rizik promjene cijena vrijednosnica (dionica) proizlazi iz volatilnosti dionica zbog utjecaja tržišta, odnosno, gospodarskih kretanja, solventnosti i financijske pozicije poduzeća te karakteristika konkurencije, a očituje se u porastu ili padu cijena dionica.

Rizik cijena roba odnosi se na oscilacije u vrijednosti sirovina poput nafte, zemnog plina, pšenice, zlata, srebra ... Usko je vezan uz valutni rizik. Volatilnost cijena roba je načelno veća nego volatilnost ostalih faktora tržišnog rizika. Čimbenici koji na to utječu mogu biti: političke i regulatorne promjene, sezonske varijacije, tehnologija, vrijeme i tržišni uvjeti.[25]

2.4. Načini mjerenja tržišnog rizika

Tržišni rizik je veoma zahtjevno i široko područje, pa ne čudi postojanje mnogobrojnih metoda za njegovo mjerenje i upravljanje od kojih se sljedećih pet najviše koristi: analiza osjetljivosti, testiranje ekstremnih događaja, testiranje scenarija, CAPM model i Value at Risk.

Analiza osjetljivosti prati promjenu vrijednosti portfelja ukoliko dođe do male promjene određenog faktora rizika koji mogu biti: valutni tečajevi, kamatne stope, tržišni indeksi, cijene roba, volatilnost, itd. Matematički izraz za analizu osjetljivosti je : $\frac{P(f+\varepsilon)-P(f)}{\varepsilon}$ (1)

gdje su:

[25] Tuškan, B. (2009): Upravljanje rizicima upotrebom financijskih derivata u RH, Zbornik Ekonomskog fakulteta u Zagrebu, Vol.7 No.1, str. 112-113

P - vrijednost portfelja,

f - faktor rizika,

ε – mala promjena faktora rizika.

Analiza osjetljivosti daje dobre aproksimacije vrijednosti portfelja u slučaju malih promjena faktora rizika, no ako su te promjene velike kao što je slučaj u financijskim krizama tada analiza osjetljivosti neće dati zadovoljavajuće rezultate.

Kod metode testiranja ekstremnih događaja simuliraju se velike promjene faktora rizika te se pri svakoj promjeni faktora rizika vrši potpuno vrednovanje portfelja i bilježe se procijenjeni gubitci. Pri provođenju testiranja utvrđuje se koji faktori se kreću samostalno, a koji ovise jedan o drugom kako bi testiranja bila što realnija. Nedostaci metode su:

- testovi ne ukazuju na to koja od testiranih promjena predstavlja najveći problem za financijsku instituciju,
- smjer i jakost promjena rizičnih faktora nisu nužno vezani uz vjerojatnost nastanka takvih događaja
- testovi se zasnivaju na pretpostavci da je korelacija između pojedinih faktora rizika nula ili jedan što može značajno iskriviti sliku stvarne izloženosti riziku.

Testiranje scenarija je slično testiranju ekstremnih događaja s razlikom u tome što su promjene u faktorima rizika subjektivno određene i oblikovane kako bi opisivale određeni razvoj događaja na financijskom tržištu. Za modeliranje scenarija najčešće se koriste događaji iz prošlosti te se, putem testiranja, daje odgovor na pitanje što bi se dogodilo s vrijednošću portfelja ukoliko bi se ti događaji ponovili danas. Nedostatci metode su:

- testiranje zahtijeva puno vremena,
- moguće je testirati samo ograničen broj scenarija,
- veličine promjena se određuju subjektivno,
- postoji mogućnost da ista osoba unutar tvrtke sudjeluje u trgovanju i na testiranju scenarija.

CAPM model proizlazi iz moderne teorije portfelja i opisuje odnos između rizika i očekivanog prinosa. To je linearni ravnotežni model prinosa na investicije koji objašnjava prinose iznad nerizične stope pomoću kovarijanci prinosa na pojedine investicije jedino kroz njihove kovarijance s cjelokupnim tržištem. Uvođenje nerizične investicije u model implicira da svaki racionalni investitor bira linearnu kombinaciju tržišnog portfelja i nerizične

investicije, ovisno o njegovim preferencijama prema riziku. Ovaj model polazi od pretpostavke da je očekivani prinos određene vrijednosnice (i), E(ri) funkcija sljedećih stavki: bezrizičnog prinosa (rf), očekivanog prinosa na tržištu E(Rm) i korelacije između vrijednosnog papira i tržišta (βi), što je prikazano u sljedećoj formuli:

$$E(Ri)= rf+ \beta i\ (E(Rm)-rf) \quad (2)$$

β tržišnog portfelja iznosi 1, dok vrijednosnice koje više osciliraju od prosjeka tržišta imaju betu veću od 1, a one s manjim pomacima od tržišta imaju betu manju od 1.Tako će vrijednosnica s β =0,5 u slučaju da tržište padne 4% zabilježiti pad od 2%, ali će u slučaju porasta cijena dvostruko sporije rasti.

Value at Risk predstavlja napredak na polju upravljanja tržišnim rizicima u posljednjim desetljećima, trenutačno je najbolja dostupna tehnika mjerenja tržišnog rizika i biti će iscrpno predstavljena u nastavku rada.[26]

3. VAR KAO MJERA TRŽIŠNOG RIZIKA

3.1. Definicija i osnove VaR-a

Value at Risk (VaR) ili rizičnost vrijednost je mjera koja daje najveći mogući gubitak koji se može ostvariti od određene investicije, u promatranom razdoblju, uz određenu vjerojatnost. To je jedinstvena, sumarna, statistička mjera mogućih gubitaka portfelja. Razvijen je kao odgovor na potrebe da se različiti izvori tržišnog rizika kvantificiraju u jednoj mjeri. Ranije je postojao i pod drugim nazivima kao što su Capital at Risk, Dollars at Risk i Money at Risk. Matematički se prikazuje na sljedeći način:

$$VaR_{\alpha}(x) = \inf \{x: P(X > x) \leq 1 - \alpha.^{27} \quad (3)$$

Vrijednost VaR-a ovisi o dva unaprijed definirana parametra:[28]

- razini pouzdanosti
- vremenskom periodu tijekom kojeg se mjeri VaR.

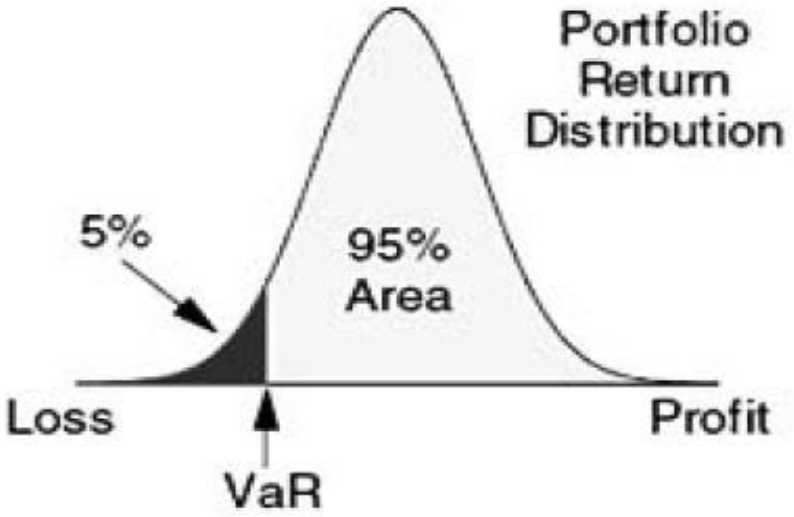
Ne postoji standardizirana razina pouzdanosti koja bi bila obavezna za sve, već se upotrebljavaju vrijednosti u rasponu od 90% do 99%, a najčešće one od 95% i 99%. Korištenje razine pouzdanosti veće od 99% se ne preporučuje jer rezultat može stvoriti osjećaj lažne sigurnosti.

[26] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 60-62.
[27] Ibid., str. 62
[28] Abdić, A., Abdić, A., Kanlić, F. (2009): Primjena Value-at-risk metode na tržištu kapitala Bosne i Hercegovine, Zbornik radova ICEI, Sarajevo, str. 204-205.

Što se tiče vremenskog perioda, on ovisi o osobinama samog investitora pa tako svi oni koji aktivno trguju financijskim instrumentima poput banaka upotrebljavaju period od jednog dana jer na dnevnoj bazi mijenjaju svoje tržišne pozicije, dok poduzeća i razni privatni investitori čiji portfelj ostaje relativno fiksan koriste duže vremenske periode poput tjedna ili mjeseca. Idealno bi bilo kad bi razdoblje držanja odgovaralo najdužem razdoblju potrebnom za urednu likvidaciju portfelja. S porastom vremenskog perioda raste vrijednost VaR-a i to za faktor približno jednak kvadratnom korijenu dotičnog perioda.

Ukoliko se za razinu pouzdanosti izabere 95%, a za vremenski period jedan dan i da hipotetski VaR iznosi 1 000 € onda se očekuje da gubitak portfelja premaši 1 000 € samo jednom u 20 radnih dana. VaR se izražava bilo kao postotak od tržišne vrijednosti ili u apsolutnom iznosu, i to u valuti u kojoj institucija prikazuje svoje financijske izvještaje.[29]

Grafički se VaR može predočiti na način prikazan donjom slikom.



Slika 4: Grafički prikaz VaR-a
Izvor: Cvetinović, M. (2008): Upravljanje rizicima u financijskom poslovanju, Univerzitet Singidunum, Beograd, str. 51.

Informacije koje pruža VaR mogu se koristiti na više načina:[30]

- viši menadžment koristi se tim informacijama kako bi postavio sveukupni profil rizika svoje institucije te postavljao limite za maksimalni rizik i izloženost po organizacijskoj jedinici svoje organizacije

[29] Cvetinović, M. (2008): Upravljanje rizicima u financijskom poslovanju, Univerzitet Singidunum, Beograd, str. 51-52.
[30] Ibid., str.98.

- budući da VaR pruža informacije o maksimalnom iznosu koji se može izgubiti tijekom određenog narednog razdoblja banke ga mogu koristiti kao mjeru za izdvajanje rezervi za tržišne rizike
- VaR na razini pojedinih investicijskih bankara i brokera može poslužiti umjesto klasičnih mjera efikasnosti investiranja kao što su: Sharpov, Treynor i Jansenov omjer
- VaR se sve više prikazuje u godišnjim izvješćima velikih tvrtki kako bi se investitorima predočio rizični profil tvrtke
- VaR se može koristiti kako bi se unaprijed ocijenile pojedine investicijske prilike
- informacije dobivene iz VaR-a mogu se koristiti u implementaciji hedging strategija koje obuhvaćaju cjelokupni portfelj institucije

VaR daje preciznu statističku ocjenu maksimalno vjerojatnog gubitka na nekom portfelju u slučaju da se tržište ponaša normalno. Međutim, tržište se u mnogim situacijama ne ponaša normalno te se na njemu događaju ekstremne promjene cijena pa u takvim vremenima nije uputno koristiti VaR kao mjeru tržišnog rizika.[31]

3.2. Povijesni pregled upotrebe VaR-a

Rizičnost vrijednosti je relativno nova mjera tržišnog rizika jer je nastala tek početkom 90-ih godina prošlog stoljeća, dok drugi izvori kažu da je postojala već u 80-ima, no sigurno je da je vrlo brzo nakon nastanka postala popularna u investicijskim krugovima. Za to su zaslužna tri najvažnija događaja:

- amandmani na Bazelski dogovor iz 1995. godine
- objava RiskMetrics sustava od strane J.P. Morgana
- zahtjev SEC-a da kompanije iz SAD-a objavljuju svoju rizičnu vrijednost u godišnjim financijskim izvještajima

Bazelski dogovor je donesen 1988. godine s ciljem boljeg upravljanja rizicima u bankama povezivanjem kreditnog rizika s propisanim kapitalnim rezervama i koeficijentima adekvatnosti kapitala. 1995. godine doneseni su amandmani na prvotni dogovor kojim se dopušta bankama da na osnovi svojih internih modela (ponajprije rizičnosti vrijednosti) odrede svoje kapitalne rezerve za tržišni rizik. Da bi banke mogle koristiti svoje interne modele moraju zadovoljiti različite kvalitativne zahtjeve. One moraju pokazati da imaju

[31] Ibid., str. 52.

čvrsto razvijen sistem za upravljanje rizicima, potrebno je da provode redovita testiranja i da imaju nezavisnu kontrolu rizika, kao što je eksterna revizija.

Popularizaciji VaR-a znatno je pridonijela investicijska banka J.P. Morgan. Najprije je njihov bivši glavni izvršni direktor Dennis Weatherstone početkom 90-ih zahtijevao da mu se svakog dana u 16:15 uruči izvještaj o visini maksimalnog gubitka portfelja koji se može očekivati u sljedeća 24 sata. Analitičari koji su osmislili takav model procjene rizika potencijalnog gubitka u sljedeća 24 sata nazvali su ga RiskMetrics te je on javno objavljen 1994. godine na Internetu i u njemu su bile iznesene teorijske postavke rizičnosti vrijednosti.
RiskMetrics sustav temelji se na modernoj portfolio teoriji, a to znači da uzima u obzir standardnu devijaciju i koeficijente korelacije vrijednosnica pri procjeni njihova rizika. Uvođenje RiskMetrics sustava zahtijevalo je mnogo napora jer je trebalo odrediti standard i konvencije ulaznih podataka, stvoriti bazu podataka, usuglasiti statističke pretpostavke i proceduru za mjerenje volatilnosti i korelacija te riješiti mnoga druga tehnička i teorijska pitanja. Do 1994. svi interni modeli su bili čuvani u strogoj tajnosti kako ih se konkurencija ne bi dokopala, no onda je J.P. Morgan napravio radikalan zaokret i javno objavio svoj sustav mjerenja rizika što je korisnicima dalo pristup i do njihovih baza podataka.
U svom osnovnom obliku objavljeni RiskMetrics podaci su obuhvaćali:

- „jednostavnu“ metodologiju za izračun rizične vrijednosti,
- podatke o financijskim instrumentima (standardne devijacije i koeficijenti korelacije),
- tehnički instrument koji objašnjava ukupnu metodologiju
- online kalkulator.

Nakon javne objave uslijedilo je naglo širenje VaR modela koje su osim investicijskih banaka počele koristiti i komercijalne banke, mirovinski fondovi, osiguravajuća društva, pa čak i nefinancijske organizacije. J.P. Morgan je, nakon što je 1994. godine učinio javno dostupnim RiskMetrics sustav temeljen na VaR metodologiji, 1997. godine razvio CreditMetrics sustav za mjerenje kreditnog rizika, a 1999. CorporateMetrics sustav koji primjenjuje RiskMetrics sustav na duži rok te je prikladniji za nefinancijske institucije.
Treći ključan događaj za razvoj rizičnosti vrijednosti je odluka SEC-a (američke komisije za vrijednosne papire) da financijske kompanije s tržišnom kapitalizacijom većom od 2,5 milijarde USD obavezno navedu podatak o rizičnosti vrijednosti u svojim godišnjim

financijskim izvješćima i prve kompanije su počele primjenjivati to pravilo već 1994. godine.[32]

3.3. Prednosti i nedostatci VaR-a

Glavna prednost VaR-a jest to da je on jedina mjera tržišnog rizika koja može biti primijenjena na sve financijske instrumente kojima se trguje pa omogućava usporedbu rizika koji nastaje u različitim područjima poslovanja. Velika zasluga koja se može pripisati VaR-u je ta da je viši menadžment postao svjesniji odnosa između preuzetih rizika i ostvarenih profita što je dovelo do mnogo efikasnije alokacije sredstava.

Dva su najvažnija razloga velike popularnosti VaR-a: nudi jednostavnu i konzistentnu mjeru rizika za različite pozicije i faktore rizika pa se mogu uspoređivati rizici između različitih financijskih instrumenata što ranije nije bilo moguće i uzima u obzir koeficijente korelacije između različitih faktora rizika.[33]

Međutim, VaR ne predstavlja cjelovit odgovor na problem upravljanja rizicima. Najbolji način primjene VaR-a je uz puno razumijevanje svih njegovih nedostataka i ograničenja. VaR je nužan, ali ne i dovoljan oblik mjerenja i upravljanja tržišnim ili bilo kojim drugim rizikom.

Iako nam VaR govori da će se neki gubitak veći od određenog iznosa javiti jednom u 20 dana (uz pouzdanost od 95%), on nam ne može reći koliki će taj gubitak zapravo biti. Stoga, VaR nije dovoljan sam po sebi za efikasno upravljanje rizikom. U slučaju izrazito turbulentnih financijskih tržišta kada se javljaju ekstremne promjene cijena VaR neće biti primjeren kao mjera tržišnog rizika. Negativna strana usredotočenja na samo jednu vrstu rizika (tržišnog rizika) kao što je slučaj kod VaR-a jest u tome što će institucije početi seliti svoje investicije iz područja tržišnog rizika u druga područja koja je puno teže kontrolirati i mjeriti.

Kritičari VaR-a sumnjaju u primjenjivost i valjanost statističkih i drugih pretpostavki vezanih za VaR, a koje su uglavnom preuzete iz fizike i izravno primijenjene na financije. Po mišljenju kritičara, teoremi iz fizike ne uzimaju u obzir važne osobne društvenih sustava kao što su: sposobnost učenja i prilagođavanja sudionika na financijskim tržištima te nestacionarna i dinamička ovisnost mnogih tržišnih procesa. Ovo su neki od čimbenika koji mogu srušiti neke od osnovnih teorijskih pretpostavki VaR modela i rezultirati potpuno pogrešnom mjerom rizika.

[32] Šverko, I. (2002): Rizična vrijednost (Value at risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, Vol. 53 No.7-8, str. 645-646.
[33] Cvetinović, M. (2008): Upravljanje rizicima u financijskom poslovanju, Univerzitete Singidunum, Beograd, str. 98.

Također, kao kritika navodi se nepreciznost jer različiti VaR modeli daju različite procjene rizika koristeći iste podatke pa investitori mogu dobiti osjećaj lažne sigurnosti. Znakovita je izjava investitora Nassima Taleba: „Puno je opasnije oslanjati se na pogrešne informacije nego ne imati nikakve. Ukoliko pilotu date navigacijske instrumente koji ponekad pogriješe sigurno će doći do avionske nesreće. Ukoliko mu ne date ništa, bit će prisiljen sam gledati kroz prozor.“ Moguće je da zbog manjkavosti VaR-a kada pokaže manji rizik u odnosu na stvarni dođe do seljenja većih iznosa novca u rizičniju imovinu o kojoj VaR modeli ne daju pravu predodžbu rizika.

Problem kod VaR-a može predstavljati njegovo preveliko usredotočenje na kratkoročnost. Iako je VaR-om moguće izračunati rizik i u dužem vremenskom periodu, u praksi je to rijetkost. Razlozi za to su višestruki poput potrebe financijskih institucija da na dnevnoj razini obavljaju hedging rizika i manje se obaziru na dugoročne prijetnje, financijski regulatori nameću zahtjev za redovitim izvještavanjem o kratkoročnom riziku i najvažnije od svega inputi u izračunu VaR poput matrice varijanci i kovarijanci postojani su u kratkom roku.[34]

Još jedna zamjerka u prilog VaR-a je nezadovoljavanje načela subaditivnosti, to jest, postojanje mogućnosti da iznos VaR-a ukupnih pozicija portfelja bude veći od zbroja VaR-a samostalnih pozicija koje čine taj portfelj. Zbog toga se često kao nadopuna VaR-a koristi uvjetna rizičnost vrijednost, odnosno, CVaR koji je očekivana vrijednost gubitaka koji premašuju VaR. I na njega se odnose iste kritike, ali za razliku od VaR-a zadovoljava uvjet subaditivnosti. U nastavku je pobliže objašnjena ova modifikacija VaR-a zajedno sa svojim prednostima i nedostatcima.[35]

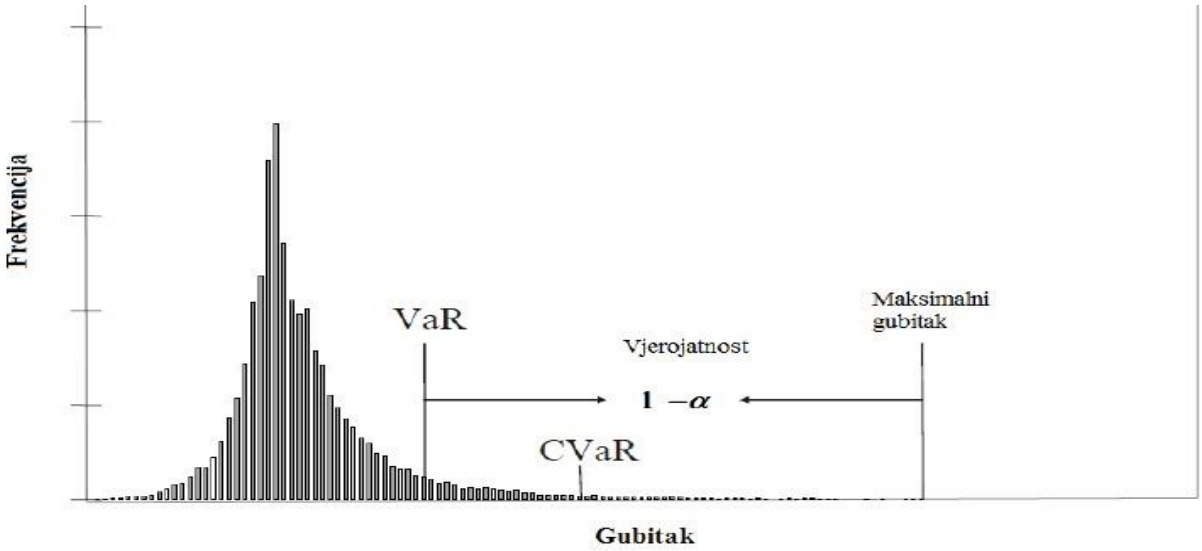
3.4. CVaR - Uvjetna rizičnost vrijednosti

Mjera rizika koja nadilazi neka ograničenja VaR-a, a zadržava njegova dobra svojstva je uvjetna rizičnost vrijednosti ili CVaR. CVaR se definira kao uvjetno očekivanje gubitaka koji premašuju VaR, ili, drugim riječima, to je prosjek gubitaka većih od VaR-a. Stoga, za razliku od VaR-a, CVaR pruža dodatne informacije o gubicima u repu distribucije koji premašuju VaR. Matematički se izražava kao: $CVaR\alpha = E[x|x \leq VaR\alpha]$. (4)

[34] Damodar, A. (2005): Value at risk (VaR), NYU Stern school of business, str. 24.
[35] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 73-74.

CVaR je očekivani gubitak ako se događaj u repu distribucije dogodi te se stoga nalazi na lijevoj strani od VaR-a. Može biti CVaR+ kada očekivana vrijednost *X* strogo prelazi VaR, ili CVaR-kada očekivana vrijednost *X* slabo prelazi VaR.[36]

Grafički prikaz CvaR-a u odnosu na VaR je dan na donjoj slici.



Slika 5: Odnos CVaR-a i VaR-a
Izvor: Uryasev, S. (2000): Conditional Value-at-Risk (CVaR): Algorithms and applications, Financial Engineering News, No. 14

Glavna prednost CVaR-a u odnosu na VaR je zadovoljavanje načela subaditivnosti po kojem je VaR portfelja uvijek manji od zbroja VaR-ova njegovih sastavnih dijelova.

Druge prednosti upotrebe CvaR-a su:[37]

- jednostavan i brz prikaz rizika u jednom broju
- mjeri rizik velikih gubitaka
- primjenjiv je i na nesimetrične distribucije gubitaka
- mjeri rizike koji prelaze VaR
- konveksan je
- $VaR \leq CVaR- \leq CVaR \leq CVaR+$
- daje stabilne statističke procjene
- kontinuiran je obzirom na razinu pouzdanosti α, konzistentan na različitim razinama pouzdanosti za razliku od VaR-a
- za normalne distribucije gubitaka optimalna varijanca i CVaR se podudaraju
- CVaR-om je lako kontrolirati (optimizirati) distribucije koje nisu normalne

[36] Uryasev, S., Serraino, G., Sarykalin, S.: „Value-at-Risk vs. Conditional Value-at-Risk in Risk managment and optimization, Tutorials in Operations Research. INFORMS, Hanover, MD, 270-294
[37] Uryasev, S. Conditional Value-at-Risk (2000): Algorithms and applications, Financial Engineering News, No. 14, 1-5

Kritike CVaR-a polaze od činjenice da su izračuni VaR-a statistički stabilniji od CVaR izračuna. Npr. portfelj koji uključuje instrumente s jakom tendencijom prema srednjoj vrijednosti, VaR neće penalizirati instrumente s ekstremno visokim gubicima. Izračuni temeljeni na VaR-u su robusni i mogu automatski zanemariti ekstreme - vrijednosti koje jako odstupaju ili velike gubitke.

CVaR je osjetljiviji od VaR-a na greške u izračunu. Ako ne postoji dobar model za „rep" distribucije CVaR izračuni mogu biti poprilično krivi. Točnost CVaR izračuna značajno ovisi o točnosti modeliranja repa distribucije. Osim toga, backtesting CVaR-a je kompleksniji nego backtesting VaR-a.[38]

4. METODE IZRAČUNA VAR-A

Tri su glavne metode za izračun rizičnosti vrijednosti: povijesna metoda, parametarska metoda i Monte Carlo simulacija. Svaka od njih će biti onoliko korisna i primjenjiva koliko se točnima pokažu rezultati koje su predviđale. U tu svrhu važno je provesti backtesting - postupak naknadne usporedbe stvarnih gubitaka s očekivanim gubitcima na temelju izračunatog VaR-a. U nastavku poglavlja će biti navedena temeljna obilježja svih metoda sa sličnostima i razlikama u odnosu na druge metode kao i prednosti i nedostatci istih.

4.1. Povijesna metoda

Povijesna metoda spada među neparametrijske metode izračuna VaR-a jer ne postavlja pretpostavku o distribuciji prinosa, već se ona određuje empirijski tako da se podatci iz nedavne prošlosti koriste za prognoziranje rizika u bliskoj budućnosti.[39]

Svoju popularnost može zahvaliti sljedećim činjenicama: konceptualno je jednostavna, jednostavna je za primjenu, široko je rasprostranjena i prema mnogim istraživanjima daje zadovoljavajuće rezultate.

Preferiraju je investitori u odnosu na parametarsku metodu kada:

- investiraju na tržištima na kojima je volatilnost dionica promjenjiva,
- korelacije između dionica se značajno mijenjaju u relativno kratkim vremenskim razmacima,

[38] Uryasev, S., Serriano, G., Sarykalin, S. (2008): Value-at-Risk vs. Conditional Value-at-Risk in risk managment and optimization, Tutorials in Operations Research. INFORMS, Hanover, MD, 270-294

[39] Munđar, D., Zemljak, A. (2016): Izračun rizične vrijednosti-VaR, Poučak: časopis za metodiku i nastavu matematike, str. 73.

- distribucija prinosa na optimalni portfelj i na tržišni indeks pokazuje povećanu asimetričnost i zaobljenost u odnosu na normalnu distribuciju.[40]

Problematičan može biti izbor vremenskog perioda iz kojeg se crpe podaci. S jedne strane nastoji se u izračun rizične vrijednosti uzeti što dulje povijesno vremensko razdoblje tako da dobiveni rezultat u sebi sadrži i one rijetke, ekstremne događaje koji najčešće i jesu glavni uzročnici velikih gubitaka. S druge pak strane, kako rizična vrijednost koristeći povijesne podatke implicira buduće distribucije prinosa, katkad se smatra primjerenijim računati ju na temelju novijih podataka o promjenama cijena, jer oni najbolje prikazuju posljednje trendove na tržištu.[41]

VaR se primjenom povijesne metode računa provedbom sljedećih koraka:[42]

1. Za svaku dionicu u portfelju računa se postotna promjena njene vrijednosti (prinos) između uzastopnih razdoblja (dana, tjedana ...) u izabranom vremenskom periodu,
2. Prinosi se pomnože sa cijenom svake dionice da bi se kvantificirao dobitak ili gubitak svake pozicije i čitavog portfelja,
3. Iznosi iz 2. koraka se poredaju od najmanjeg prema najvećem,
4. Ovisno o izabranoj razini pouzdanosti iz niza poredanih iznosa odabire se vrijednost koja se nalazi 1% ili 5% uzorka udaljena od početka niza (na primjer, ukoliko je razina pouzdanosti 95%, a uzorak ima 500 podataka onda će za VaR biti uzet 25. najveći gubitak).

4.1.1. Prednosti i nedostatci povijesne metode

Glavna prednost povijesne metode je što ne postavlja pretpostavku u vezi oblika distribucije faktora rizika koji utječu na vrijednost portfelja. Budući da većina vrijednosnica ima distribuciju sa zadebljanim repovima, povijesna metoda nudi bolje rješenje od parametarskih metoda koje pretpostavljaju teorijske distribucije, to jest, najčešće normalnu distribuciju, a to može drastično podcijeniti mogućnost nastanka ekstremnih događaja zbog čega će izračunati VaR biti niži od stvarnog.

U prilog povijesne metode govori i empirijski dokaz da volatilnost u vremenu nije konstantna. To je u skladu s teorijom efikasnog tržišta po kojoj cijene dionica u sadašnjem trenutku

[40] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 74.
[41] Ibid., str. 63.
[42] 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.608.

odražavaju sve informacije relevantne za tu dionicu, a promjene cijena ovise samo o novim informacijama pa se kretanje cijena dionica smatra slučajnim hodom i slično je Brownovom gibanju u fizici.[43]

Druge prednosti upotrebe povijesne metode su:

a) u teoriji je jednostavna,
b) jednostavno ju je provesti u praksi,
c) potrebni podaci se pribavljaju lako s burze,
d) rezultate je jednostavno prikazati višem menadžmentu i regulatoru,
e) uključuje u izračun zadebljane repove distribucije, asimetričnost i ostale karakteristike distribucija koje ne odgovaraju normalnoj distribuciji,
f) nema potrebe za računanjem matrice varijanci i kovarijanci što pojednostavljuje i ubrzava proceduru za izračun VaR-a,
g) pogodna je za izračun VaR-a različitih vrsta vrijednosnica,
h) jednostavno ju je izračunati pri različitim razinama vjerojatnosti,
i) pogodna je za daljnja modificiranja i usavršavanja.

Povijesna metoda je bez rizika modela jer ne pretpostavlja određenu distribuciju prinosa, nego se temelji na empirijskoj distribuciji.[44]

Glavni nedostatak povijesne metode je da svakom opažanju daje isti ponder jednak omjeru 1/broj opažanja što zadaje pretpostavku da su faktori rizika, a time i povijesno simulirani povrati nezavisni i jednako distribuirani kroz vrijeme. Ta pretpostavka ne vrijedi na neefikasnim tržištima gdje postoji autokorelacija volatilnosti (grupiranje razdoblja niske i visoke volatilnosti) i autokorelacije prinosa. Prisutnost autokorelacije najčešće je rezultat sljedećih pojava: povremenog trgovanja određenim vrijednosnim papirima (dionicama manjih tvrtki se rjeđe trguje pa se nove informacije najprije odraze na dionice velikih tvrtki, a zatim na dionice malih tvrtke što uvjetuje autokorelaciju), trgovanja iz potrebe u svrhu likvidnosti, a ne zarade i brzog rasta tranzicijskih tržišta.

Problem se javlja i kada se povećava razdoblje za koje treba izračunati VaR jer broj opažanja naglo pada (npr. 100 dnevnih opažanja daje samo 20 tjednih) i može ih ne biti dovoljno za svrsishodnu analizu. Dodatni nedostatci upotrebe povijesne metode su: rezultati u potpunosti

[43] Ibid., str.610.
[44] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 83.

ovise o opažanjima iz promatranog razdoblja te na nerazvijenim tržištima može biti teško prikupiti dovoljan broj opažanja za izračun VaR-a za razdoblja duža od jednog dana.

Više nedostataka povijesne metode kao zajednički nazivnik imaju vremenski period iz kojeg se crpe podaci. Ako u njemu nije zabilježena nijednom povećana razina volatilnosti rezultirajući VaR može ispasti prenizak ili obratno, ako je registrirana povećana razina volatilnosti VaR će biti previsok u odnosu na stvarno stanje. Povijesna metoda loše reagira na jednokratne promjene koje se dogode tijekom dotičnog vremenskog razdoblja kao i na nagle i velike promjene na tržištu. Ukoliko se u izabranom vremenskom razdoblju nalaze ekstremni gubici, za koje nije vjerojatno da će se ponoviti, oni i dalje mogu nepotrebno povećavati iznos VaR-a. Gubici koji su se dogodili u daljoj prošlosti kontinuirano utječu na visinu VaR-a, a zatim naglo nestaju kada ispadnu iz promatranog razdoblja.

Povijesna metoda ne uzima u obzir moguće događaje koji su se mogli, ali se nisu dogodili. Iznos VaR-a izračunat putem povijesne metode je ograničen na najveći gubitak koji se je dogodio u izabranom razdoblju.[45]

Postoje određeni načini kojima se povijesna metoda može poboljšati poput pridavanja recentnijim događajima (prinosima) višeg težinskog koeficijenta jer je logično da su nedavni prinosi bolji pokazatelji potencijalnih budućih prinosa. Uvođenjem faktora zastarijevanja moguće je odrediti vjerojatnost pojavljivanja bilo kojeg prinosa. Primjerice, ukoliko posljednji prinos portfelja ima vjerojatnost da se pojavi jednaku p, a faktor zastarijevanja je 0,9 onda će predzadnji prinos imati vjerojatnost nastupa od 0,9 p.[46]

4.2. Parametarska metoda

Parametarska metoda se temelji na pretpostavci da distribucija prinosa odgovara nekoj od teorijskih distribucija, najčešće normalnoj distribuciji. Pretpostavke distribucije podrazumijevaju rizik modela, odnosno rizik da postoji nerazmjer između pretpostavljene distribucije povrata i prave temeljne distribucije vjerojatnosti. VaR se ovom metodom izračunava na osnovi dva parametra: srednje vrijednosti dobitaka/gubitaka (stope povrata) portfelja i standardne devijacije istog. Parametarska metoda poznata je i po drugim nazivima kao što su: linearni VaR, metoda varijance i kovarijance, analitička metoda, delta normalan VaR i delta-gama normalan VaR.

[45] Cvetinović, M. (2008): Upravljanje rizicima u financijskom poslovanju, Univerzitet Singidunum, Beograd, str. 76.
[46] Damodar, A. (2005): Value at risk (VaR), NYU Stern school of business, NYC, str. 14.

Normalna distribucija se najčešće koristi jer je određuju samo dva podatka: aritmetička sredina i standardna devijacija što pojednostavljuje računanje VaR-a.

Karakteristike normalne distribucije su:[47]

- ima zvonoliki oblik
- unimodalna je
- proteže se od -∞ do +∞
- aritmetička sredina je jednaka medijanu i modu
- simetrična je
- mjera zaobljenosti je jednaka 3

Ukoliko dođe do promjene aritmetičke sredine, krivulja distribucije pomaknut će se horizontalno, to jest, u lijevo ukoliko se aritmetička sredina smanjila, odnosno u desno ukoliko se povećala. Ako se vrijednost standardne devijacije poveća smanjit će se vrh distribucije, a proširiti će se repovi. Obrnuto, smanjenjem standardne devijacije krivulja će se suziti i povećat će se njen vrh.

Važan parametar normalne distribucije je i standardizirano obilježje *z* koje se definira kao odstupanje vrijednosti varijable *x* od svoje aritmetičke sredine izraženo u jedinicama standardne devijacije što matematički se zapisuje kao:

$z_\alpha = (x_\alpha - \mu_\pi) / \sigma_\pi$ iz čega proizlazi da je $x_\alpha = \mu_\pi + z_\alpha * \sigma_\pi$ (5)

Simboli μ_π i σ_π označavaju prosječan prinos i standardnu devijaciju portfelja, dok je x_α je vrijednost koja se nalazi α% od kraja lijevog repa normalne distribucije.

U većini postojećih sustava, vrijednosti numeričkih varijabli se nalaze unutar tri standardne devijacije s lijeve ili desne strane od aritmetičke sredine te se u tom rasponu nalaze gotovo sve vrijednosti slučajne varijable. Za krivulju normalne distribucije, uz razinu vjerojatnosti od 99% standardizirano obilježje z iznosi 2.326 standardne devijacije što znači da postoji šansa od samo 1% vjerojatnosti da se ostvare gubici veći od 2.326 standardne devijacije. Analogno tome, za razinu pouzdanosti od 95% standardizirano obilježje z iznosi 1.65. VaR (u%) dionice pri toj razini pouzdanosti izračunava se sljedećom formulom:$VaR = -1.65 * \sigma + \mu$. (6)

[47] Žiković, S.,:“ Formiranje optimalnog portfelja hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode“, Magistarski rad, Sveučilište u Ljubljani, Ekonomski fakultet, Ljubljana, 2005. str. 64

Primjerice, ako je prosječan tjedni prinos dionice 1%, a njena tjedna standardna devijacija 2%, onda VaR dionice iznosi -1.65 * 2% + 1% = - 2.3% što znači da postoji vjerojatnost od 5% da se u jednom tjednu na toj dionici izgubi više od 2.3% njezine trenutne vrijednosti.[48]

Rizična vrijednost se može izračunati za portfelj procjenjujući očekivane vrijednosti i standardne devijacije svake dionice, ali pri tome uvažavajući korelaciju dobitaka ili povrata među dionicama procjenom matrice korelacije ili matrice varijanci/kovarijanci.

Princip izračuna VaR-a portfelja parametarskom metodom je složeniji od povijesne metode i sastoji se od sljedećih koraka:

1. izračunati prinos svake dionice portfelja u određenim uzastopnim razmacima za odabrano razdoblje
2. izračunati prosječan prinos svake dionice portfelja
3. napraviti matricu A u kojoj se nalaze vrijednosti izračunate tako da se od svakog pojedinog prinosa neke dionice u portfelju oduzme prosječni prinos iste dionice
4. napraviti matricu varijanci i kovarijanci množenjem matrice A s transponiranom matricom A i dijeljenjem s brojem opažanja
5. izračunati sljedeće parametre: varijancu i standardnu devijaciju portfelja, prosječan prinos portfelja i standardizirano obilježje z
6. dobivene vrijednosti iz prethodnog koraka unijeti u formulu za izračun VaR-a

Formula za izračun VaR-a parametarskom metodom na odabranom portfelju glasi:

$$VaR_{1-\alpha} = -(\mu_\pi + z_\alpha \cdot \sigma_\pi) \cdot P. \qquad (6)$$

Simboli μ_π i σ_π su prosječan prinos i standardna devijacija portfelja u vremenskom periodu za koji se računa VaR (najčešće jedan dan), z_α je standardizirano obilježje pri razini pouzdanosti α, a P je iznos ulaganja u portfelj.

4.2.1. Prednosti i nedostatci parametarske metode

Prednosti parametarske metode su: jednostavnost izračuna i nije vremenski zahtjevna, iako je po tom pitanju povijesna metoda zahvalnija, no fleksibilnija je od nje i brže reagira na iznenadne šokove. K tome, ona omogućava preračunavanje iz rizičnosti vrijednosti za kraće u rizičnost vrijednost dužeg razdoblja tako da se dnevni VaR pomnoži sa kvadratnim korijenom

[48] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 64-68.

broja radnih dana razdoblja za koje želimo izračunati VaR. Također, vrlo jednostavno je iz podatka o VaR-u uz određenu pouzdanost od, primjerice, 95% izračunati VaR pri razini pouzdanosti od 99% tako da se standardizirano obilježje *z* kod pouzdanosti od 99% (2.33) podijeli sa standardiziranim obilježjem kod pouzdanosti od 95% (1.65) i pomnoži s već poznatim VaR-om.

Nedostatci proizlaze iz činjenice da normalna distribucija može podcijeniti rizik kojem je izložen portfelj u rubnim dijelovima distribucije pa je potrebno u procjenu rizika uključiti i druge momente oko sredine kao što su mjera asimetrije i zakrivljenosti. Mnoge empirijske studije pokazuju da pretpostavka normalno distribuiranih financijskih povrata podcjenjuje VaR. Podcjenjivanje postaje značajnije kada se proučavaju vrijednosni papiri s velikim repovima distribucija i visokim potencijalom za velike gubitke. Drugi problem normalne distribucije je da varijabla može poprimiti bilo koju vrijednost od -∞ do +∞, a to onda znači da bi investitor mogao izgubiti više, nego što je uložio što je nemoguće. Budući da normalna distribucija nije ograničena maksimalno mogućim gubitkom izračunati VaR može uvelike precijeniti stvarni iznos VaR-a.

Još jedan nedostatak je problem statističke valjanosti prihvaćanja normalne distribucije za opisivanje rubnih dijelova distribucije prinosa jer se normalna distribucija temelji na teoremu centralne tendencije koji nije pogodan za ocjenu rubova statističkih distribucija. Nadalje, koeficijenti korelacije se u kriznim situacijama drastično mijenjaju konvergirajući prema vrijednosti 1 pa bi procjena VaR-a u kriznim situacijama parametarskom metodom bila pogrešna, no čak i u situacijama koje nisu krizne koeficijenti korelacije se mijenjaju pa VaR uvijek sadrži određenu veću ili manju grešku. Ukoliko se broj opažanja približava beskonačnosti i distribucija teži normalnoj to još uvijek ne znači da je distribucija prinosa jednaka normalnoj. Parametarska metoda nije prikladna za portfelje u čijem su sastavu opcije i drugi slični financijski derivati i to zbog njezine pretpostavke o linearnosti stopa povrata portfelja i faktora rizika, a u slučaju opcija ta veza je nelinearna.[49]

4.3. Monte Carlo simulacija

Monte Carlo simulacija je vremenski najzahtjevnija metoda izračuna VaR-a, ali se smatra i najpreciznijom. Primjenom ove metode rizična vrijednost se računa na način da se simuliraju promjene vrijednosti imovine (ili promjene vrijednosti prinosa) pojedinih financijskih

[49] Cvetinović, M. (2008): Upravljanje rizicima u financijskom poslovanju, Univerzitet Singidunum, Beograd, str. 64-65.

instrumenata u portfelju. Zatim se na temelju njih računaju promjene vrijednosti portfelja kao linearne kombinacije simuliranih prinosa financijskih instrumenata i udjela financijskih instrumenata u portfelju. Proces se ponavlja velik broj puta kako bi se generirala reprezentativna distribucija. Nakon što se dobije veliki broj simuliranih vrijednosti promjene vrijednosti portfelja, rizična vrijednost se dobiva na isti način kao i kod povijesne metode, to jest, mjera rizičnosti vrijednosti jednaka je određenom postotku distribucije (odnosno određenom percentilu distribucije) promjene vrijednosti portfelja. Primjerice, ako se generiralo 10.000 mogućih scenarija, a potrebno je odrediti rizičnu vrijednost pri razini pouzdanosti od 99%, njezina vrijednost je jednaka vrijednosti stotog najvećeg gubitka od svih simuliranih scenarija. Simulacija zahtjeva unos očekivanih prinosa, standardnih devijacija i korelacija za svaki element portfelja.[50]

Koraci Monte Carlo simulacije su sljedeći:[51]

1. utvrđivanje tržišnih faktora,
2. definiranje formule koja će izraziti vrijednost portfelja u obliku jednostavnih pozicija koje ovise o tržišnom faktoru,
3. odabiranje odgovarajuće distribucije za povrate po tržišnim faktorima,
4. procjenjivanje parametara (promjenjivost i korelacija) navedene distribucije,
5. pomoću generatora slučajnih brojeva stvara se veliki broj hipotetičkih povrata po tržišnim faktorima,
6. izračun hipotetičkih tržišnih faktora pomoću njihovih aktualnih vrijednosti i simuliranih povrata,
7. podvrgavanje aktualnog portfelja tim hipotetičkim tržišnim faktorima,
8. oduzimanje vrijednosti aktualnog portfelja od hipotetičkih tržišnih faktora da bi se dobili hipotetički dobitci i gubitci,
9. iskazivanje tih vrijednosti redom od najvećeg gubitka do najveće dobiti,
10. odabir gubitka koji je jednak ili premašen *x* posto vremena kako bi se dobila rizična vrijednost.

4.3.1. Prednosti i nedostatci Monte Carlo simulacije

Dvije prednosti Monte Carlo simulacije u odnosu na ostale metode su: nasuprot parametarskom načinu izračuna VaR-a koristi nelinearne metode vrednovanja portfelja te

[50] Novak, B., Sajter, D. (2007): VaR dioničkih i mješovitih investicijskih fondova u Republici Hrvatskoj, Ekonomski fakultet u Osijeku, Osijek, str. 5-6.
[51] Mikulčić, D. (2001): Value at Risk (Rizičnost vrijednosti), Hrvatska narodna banka, Zagreb, str. 6-7.

uzima u obzir nelinearnost promjena vrijednosti, dok za razliku od povijesne metode može generirati beskonačan broj scenarija i testirati mnogobrojne moguće događaje. Pored ovoga, Monte Carlo simulacija omogućava dobivanje potpune distribucije vrijednosti portfelja i može koristiti razne pretpostavke o obliku distribucije, a ne samo normalan oblik. Također, omogućuje uključivanje nelinearnih instrumenata poput opcija u portfelj.

Monte Carlo simulacija ima dva nedostatka u odnosu na ostale metode izračuna VaR-a: vrijeme potrebno za izračun VaR-a pomoću Monte Carlo simulacije može biti i do 1000 duže od vremena za izračun parametarskog VaR-a, a za razliku od povijesne metode koja ne pretpostavlja niti jednu teorijsku distribuciju nego koristi empirijske vrijednosti, Monte Carlo simulacija podrazumijeva da su prinosi normalno distribuirani ili na neki drugi u teoriji poznat način. Još jedan nedostatak se sastoji u tom što ova metoda jednom unesene volatilnosti i korelacije između pojedinih vrijednosnica smatra stalnima te zbog toga ne reagira na promjene na tržištu i tada ne ocrtava stvarnu razinu rizika. Točnost Monte Carlo modela se povećava u ovisnosti o koeficijentu $1/\sqrt{N}$, gdje je N broj simulacija pa dvostruko veća točnost zahtijeva četverostruko veći broj simulacija što može biti vremenski zahtjevno. Potencijalna slabost ove metode je također rizik modela koji proizlazi iz krivih pretpostavki o modelima cijena i stohastičkom procesu na kojem se temelji. Ako oni nisu dobro specificirani izračuni VaR će biti „iskrivljeni“.[52]

4.4. Osvrt na metode izračuna VaR-a

Tri metode izračuna VaR-a se bitno razlikuju u 4 dimenzije:[53]

- Sposobnost da izračunaju (obuhvate) rizik opcija i drugih nelinearnih instrumenata
- Jednostavnost implementacije i jednostavnost objašnjenja metode višem managementu
- Fleksibilnost uključivanja različitih pretpostavki
- Pouzdanost rezultata

Nelinearnost instrumenata uzrokuje probleme korisnicima parametarske metode pa ukoliko su u portfelju sadržani derivati bolje je koristiti metodu Monte Carlo simulacije u odnosu na parametarsku metodu.

Povijesna i parametarska metoda su jednostavne za provedbu, dok, s druge strane, Monte Carlo simulacija ima najsloženiji proces provedbe. Ova razlika postaje bitna u trenutku

[52] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani, str. 70-71.

[53] Linsmeier T. J., Pearson N. D. (1996): Risk Measurment: An Introduction to Value at Risk, Working Paper 96-04, University of Ilinois at Urbana-Champaign

upoznavanja višeg menadžmenta s načinom izračuna VaR-a. Dok Monte Carlo metodu može biti teško shvatiti, povijesnu metodu je, naprotiv, jednostavno razumjeti, a parametarska metoda u tom pogledu spada između druge dvije metode.

Fleksibilnost VaR modela je prednost uvijek kada povijesni izračuni i standardne devijacije i korelacije ne predstavljaju dobru podlogu za buduća očekivanja, to jest, ako se ponavljanje prošlosti ne može očekivati u budućnosti. U Monte Carlo simulaciji i parametarskoj metodi lako je unijeti subjektivnu dimenziju u izračun, dok je povijesna metoda nefleksibilna budući da se procjena rizika temelji na prinosima iz prošlosti.

Pouzdanost rezultata je vjerojatno najvažnije pitanje kada se uspoređuju različite metode. Istraživanja su pokazala da parametarska metoda daje prilično točne izračune VaR, ali samo u slučaju kada je mali udio nelinearnih derivata u portfelju. Mont Carlo simulacija daje superiorne rezultate u odnosu na linearne modele kada se povećaju razina pouzdanosti i vremenski period. Druga istraživanja su otkrila da parametarska metoda ima sklonost podcijeniti VaR, pogotovo kod visokih razina pouzdanosti, a povijesna metoda je, s druge strane, pouzdana kod viših razina pouzdanosti. Kasnije će se pokazati da se prethodno navedena činjenica potvrdila i u praktičnom dijelu ovog rada.[54]

4.5. Testiranje točnosti VaR modela backtestingom

Backtesting je statistički postupak kojim se utvrđuje jesu li stvarni gubitci ili dobitci u skladu s procjenama metoda rizične vrijednosti. Dotična tehnika pomaže u otkrivanju situacija kada je vrijednost VaR-a i CVaR-a podcijenjena, odnosno, slučajeva u kojima je portfelj pretrpio veće gubitke nego što je VaR predvidio. Rezultat backtestinga se može koristiti da bi se promijenili modeli korišteni za predviđanje VaR-a u svrhu povećanja preciznosti kako bi se smanjio rizik neočekivanih gubitaka. Postoji nekoliko mogućih načina za backtesting VaR modela, a najčešće se izračunava broj puta koliko gubitak portfelja prelazi VaR za svako backtesting razdoblje. Prilikom izbora veće razine pouzdanosti se očekuje manji broj iznimaka, što znači da će biti teže ocijeniti model. Prema tome, postupak se svodi na analizu je li broj odstupanja očekivan ili ne i sukladno tome model će biti prihvaćen ili odbačen. Rizik je podcijenjen ako je više dana od dopuštenog broja u kojima se dogodio gubitak veći od procijenjenog. Također, ako se broj koji premašuje rizičnu vrijednost pojavljuje u manje dana nego što ukazuje odabrana razina povjerenja, model precjenjuje rizik.[55]

[54] Linsmeier T. J., Pearson N. D. (1996): Risk Measurment: An Introduction to Value at Risk, Working Paper 96-04, University of Ilinois at Urbana-Champaign

[55] Cvetinović, M.,: „Upravljanje rizicima u finansijskom poslovanju“, Univerzitet Singidunum, Beograd, 2008.,

5. PRIMJENA METODA IZRAČUNA VaR-A NA IZABRANIM PORTFELJIMA

5.1. Formiranje portfelja

Budući da se u ovom radu naglasak stavlja na usporedbu rizičnosti vrijednosti između portfelja dionica s hrvatskog i njemačkog tržišta kapitala najprije će se formirati odgovarajući portfelji. Portfelj dionica hrvatskih poduzeća istovjetan je indeksu Crobex10 Zagrebačke burze, a radi se o indeksu 10 dionica iz šireg indeksa Crobex s najvećom free float tržišnom kapitalizacijom i prometom. Free float tržišna kapitalizacija određene dionice računa se kao umnožak broja izdanih dionica, free float faktora i zadnje cijene dionice. Udio free float tržišne kapitalizacije pojedine dionice u ukupnoj tržišnoj kapitalizaciji indeksa CROBEX10 na dan redovne revizije, ne može preći 20%.

Crobex10 postoji od 2009. godine, a njegova zadnja revizija je bila 10.03.2017. i od tada se u njegovom sastavu nalaze sljedeće dionice navedene abecednim redom, a u zagradama je sektor kojem pripadaju:[56]

1) AD Plastik d.d. (industrija)
2) Adris grupa d.d. (upravljačke djelatnosti)
3) Atlantic Grupa d.d. (hrana i piće)
4) Atlantska plovidba d.d. (transport)
5) Ericsson Nikola Tesla d.d. (industrija)
6) HT d.d. (telekomunikacije)
7) Končar - Elektroindustrija d.d. (industrija)
8) Ledo d.d. (hrana i piće)
9) Podravka d.d. (hrana i piće)
10) VALAMAR RIVIERA d.d. (turizam).

Važno je napomenuti da u ovom portfelju nema više od 3 dionice iz istog sektora koliko ih je u sektoru hrane i pića (Atlantic Grupa d.d., Ledo d.d. i Podravka d.d.) i industrije (AD Plastik, Ericsson Nikola Tesla, Končar-Elektroindustrija) pa se portfelj može smatrati diverzificiranim. Iako se radi o najlikvidnijim dionicama na Zagrebačkoj burzi samo se dionicama HT-a d.d. i Valamar Riviere d.d. trgovalo apsolutno svakog dana u promatranom

str. 93

[56] http://zse.hr/default.aspx?id=44101&index=CROBEX10

razdoblju što je jasan dokaz slabe aktivnosti na hrvatskom tržištu kapitala. Za one dane u kojima nije bilo trgovanja pojedinim dionicama uzeta je cijena iz prethodnog dana.

Na njemačkom tržištu kapitala, referentni indeks je DAX30 Frankfurtske burze kojeg čine 30 najjačih njemačkih kompanija, dok će se za potrebe ovog istraživanja sastaviti portfelj od 10 dionica najvećih poduzeća pod uvjetom da iz istog sektora ne dolazi više od 3 dionice kako što je slučaj s portfeljem hrvatskih dionica. Odabrane su sljedeće dionice koje su ujedno 10 njemačkih kompanija s najvećom tržišnom kapitalizacijom:[57]

1) SAP AG (tehnologija)
2) Siemens AG (industrija)
3) Bayer AG (kemijski sektor)
4) BASF SE (kemijski sektor)
5) Allianz (osiguranje)
6) Deutsche Telekom (telekomunikacije)
7) Volkswagen vz (automobilski sektor)
8) Daimler (automobilski sektor)
9) BMW (automobilski sektor)
10) Henkel (kemijski sektor).

I u ovom portfelju nema više od 3 dionice iz istog sektora, a toliko ih je u automobilskom sektoru koji obuhvaća: Volkswagen vz, Daimler i BMW i u kemijskom sektoru kojeg sačinjavaju: Bayer, BASF i Henkel. Za razliku od hrvatskog tržišta, u slučaju portfelja njemačkih dionica postojali su podaci za svaki dan trgovanja pojedine dionice čime razlika u likvidnosti postaje zorna. Njemačka ima manje nacionalnih praznika od Hrvatske pa se u istom promatranom razdoblju prikupilo više opažanja za portfelj dionica iz te zemlje.

Udio svake dionice u prvom i u drugom portfelju je jednak iz razloga da ne bi postojala veća ili manja sklonost prema određenim dionicama i iznosi 10%. Budući da se uspoređuju dva tržišta s različitim valutama pretpostavit će se da je u svaki portfelj uloženo 100 000 novčanih jedinica. Razdoblje za koje se računa rizičnost vrijednosti počinje prvim danom trgovanja u 2016. godini, konkretnije 04.01.2016., a završava zadnjim danom trgovanja u travnju 2017. godine, to jest, 28.04.2017. Za portfelj dionica hrvatskih poduzeća je prikupljeno 333 podataka o dnevnim cijenama, odnosno, 338 podataka za portfelj njemačkih dionica.

[57] http://www.boerse-frankfurt.de/aktien

5.2. Usporedba prosječnog prinosa i standardne devijacije dvaju portfelja

Prije prelaska na izračun VaR-a što je predmet ovog rada, dobro je usporediti prosječne dnevne prinose i standardnu devijaciju kao mjeru rizika obaju portfelja i dionica koje ih sačinjavaju. Ove vrijednosti mogu se staviti u omjer kako bi se spoznao odnos rizika i prinosa na različitim tržištima. Donja tablica sadrži podatke o prosječnom dnevnom prinosu svake dionice kao i portfelja te dnevnu standardnu devijaciju istih u odabranom razdoblju.

Tablica 1: Prosječan dnevni prinos i prosječna dnevna standardna devijacija portfelja hrvatskih i njemačkih dionica

	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP	Portfelj
Prosječan dnevni prinos	0,155%	0,072%	-0,013%	0,376%	0,082%	0,070%	0,057%	-0,289%	0,012%	0,171%	0,069%
Standardna devijacija	1,650%	1,126%	1,052%	3,513%	1,349%	0,891%	1,475%	2,802%	1,402%	1,231%	0,781%
	SAP	SIEMENS	Bayer	BASF	Allianz	D.Telekom	Volkswagen	Daimler	BMW	Henkel	Portfelj
Prosječan dnevni prinos	0,078%	0,128%	0,007%	0,082%	0,035%	0,000%	0,042%	-0,024%	-0,016%	0,069%	0,040%
Standardna devijacija	1,208%	1,477%	1,491%	1,354%	1,538%	1,237%	2,207%	1,619%	1,738%	1,127%	1,194%

Izvor: prikaz autora

U promatranom razdoblju u portfelju dionica hrvatskih poduzeća samo dvije dionice su imale negativan prosječan dnevni prinos, a to su bile: Ledo i Atlantic Grupa, dok najveći prosječni dnevni prinos su imale: Atlantska plovidba i Valamar Riviera. Prosječan dnevni prinos portfelja je iznosio 0,069%. Najveću volatilnost mjerenu standardnom devijacijom imale su dionice Atlantske plovidbe i Leda koja je dnevno iznosila 3,5%, odnosno 2.8%. Zanimljivo je da je dionica s najvećim prosječnim dnevnim prinosom ujedno ona s najvećom dnevnom st. devijacijom. Prosječna dnevna standardna devijacija portfelja je bila 0,78%.

S druge strane, u portfelju njemačkih dionica su također dvije dionice imale negativan prosječan dnevni prinos, i to BMW i Daimler, a najveći su imale Siemens i BASF. Prosječan dnevni prinos portfelja iznosio je 0,04%. To je samo 58% prinosa koji se mogao ostvariti na portfelju hrvatskih dionica. Najveću volatilnost su imale dionice Volkswagena i BMW-a s 2,2% i 1,73%. Prosječna dnevna standardna devijacija portfelja je iznosila 1.19% što je 52,5% više od prosječne dnevne st. devijacije portfelja dionica hrvatskih poduzeća.

Iz ovih podataka može se izvući zaključak da je portfelj hrvatskih dionica imao ne samo veći prosječan dnevni prinos, nego i manju dnevnu standardnu devijaciju u promatranom razdoblju što ga čini boljim i po pitanju prinosa i rizika u odnosu na portfelj njemačkih dionica. U pravilu bi manja standardna devijacija trebala značiti i manji VaR ako distribucija podataka nalikuje normalnoj distribuciji.

5.3. Izračun VaR-a povijesnom metodom

Kako je već navedeno u teorijskom dijelu rada, povijesna metoda pretpostavlja da će se prinosi iz prošlosti ponoviti u budućnosti. U nastavku će se detaljno prikazati procedura izračuna VaR-a povijesnom metodom na portfelju hrvatskih dionica, dok će se za portfelj njemačkih dionica samo navesti konačan rezultat.

Najprije je potrebno prikupiti i sistematizirati podatke o cijenama dionica iz odabranog razdoblja kao što je učinjeno na donjoj slici. Izostavljen je prikaz podataka iz sredine vremenskog perioda kako bi tablica bila što preglednija.

Tablica 2: Cijena dionica portfelja dionica hrvatskih poduzeća u kunama

DATUM	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP
28.4.2017	164,65	458,4	784,01	433,66	1.340,00	178,7	800	3.450,00	338	42
27.4.2017	162,01	450,02	795,06	419,9	1.270,00	175	790	3.450,00	347	41,8
26.4.2017	160	466,99	811	425	1.345,18	176,84	785	3.640,00	365	42,5
25.4.2017	157,1	467	804,01	438,99	1.350,00	174,8	773	3.645,00	370	42,5
24.4.2017	158,5	468	805,05	449,99	1.350,00	174,22	773	3.799,00	370	42,3
21.4.2017	159	463,2	818,05	438,79	1.341,01	174,51	773	3.778,99	367	42,4
20.4.2017	157,6	464,49	817,19	425	1.350,01	174,7	794	3.560,00	364,21	42,5
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
15.1.2016	96,73	342,55	806	120	989	139	630	8.970,00	310,22	22,86
14.1.2016	94	353	813,1	124,95	992	139,5	637	9.060,00	318	23,25
13.1.2016	97,69	360,01	820,05	127	1.000,00	141	645	9.000,06	329	23,66
12.1.2016	96,5	358,5	819,08	127	990	140,95	650,1	9.000,06	323,01	23,72
11.1.2016	95,03	361,66	821,01	130	994	142,3	652	9.000,06	329,99	23,66
8.1.2016	95	361,02	822,21	130	1.014,00	140,6	650,1	9.000,00	327,1	23,82
7.1.2016	93,61	360	822,21	130	1.001,00	141,01	662	9.000,00	333,99	23,63
5.1.2016	95,5	371	822,12	132,95	1.005,00	141,02	662	8.951,01	333,99	23,76
4.1.2016	98,4	361	818	124,51	1.021,14	141,74	662	9.000,00	325,19	23,78

Izvor: prikaz autora prema podatcima preuzetim sa Zagrebačke burze

U sljedećem koraku, iz cijena dionica se izračunaju dnevni prinosi za svaku dionicu pomoću formule za kontinuirani prinos: $R_X(t) = ln\frac{P_x(t)}{P_x(t-1)}$, (7)

pri čemu su: $R_X(t)$ – prinos dionice X u vremenu t,

$P_x(t)$ – cijena dionice X u vremenu t,

$P_x(t-1)$ – cijena dionice X u vremenu t-1.[58]

Razvidno je da će broj podataka o prinosima biti za 1 manji od broja podataka o cijenama dionica. Neće se moći izračunati prinos za zadnji datum u tablici cijena dionica jer nije obuhvaćena cijena dionice iz prethodnog dana ovim istraživanjem. Sljedeća tablica prikazuje dnevne prinose dionica zaokružene na dvije decimale.

Tablica 3: Dnevni prinosi dionica u portfelju hrvatskih poduzeća

DATUM	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP
28.4.2017	1,62%	1,85%	-1,40%	3,22%	5,37%	2,09%	1,26%	0,00%	-2,63%	0,48%
27.4.2017	1,25%	-3,70%	-1,99%	-1,21%	-5,75%	-1,05%	0,63%	-5,36%	-5,06%	-1,66%
26.4.2017	1,83%	0,00%	0,87%	-3,24%	-0,36%	1,16%	1,54%	-0,14%	-1,36%	0,00%
25.4.2017	-0,89%	-0,21%	-0,13%	-2,47%	0,00%	0,33%	0,00%	-4,14%	0,00%	0,47%
24.4.2017	-0,31%	1,03%	-1,60%	2,52%	0,67%	-0,17%	0,00%	0,53%	0,81%	-0,24%
21.4.2017	0,88%	-0,28%	0,11%	3,19%	-0,67%	-0,11%	-2,68%	5,97%	0,76%	-0,24%
20.4.2017	0,00%	2,06%	-1,07%	-2,55%	-0,48%	-1,03%	-1,38%	-9,76%	-1,04%	0,00%
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
13.1.2016	1,23%	0,42%	0,12%	0,00%	1,01%	0,04%	-0,79%	0,00%	1,84%	-0,25%
12.1.2016	1,54%	-0,88%	-0,24%	-2,33%	-0,40%	-0,95%	-0,29%	0,00%	-2,14%	0,25%
11.1.2016	0,03%	0,18%	-0,15%	0,00%	-1,99%	1,20%	0,29%	0,00%	0,88%	-0,67%
8.1.2016	1,47%	0,28%	0,00%	0,00%	1,29%	-0,29%	-1,81%	0,00%	-2,08%	0,80%
7.1.2016	-2,00%	-3,01%	0,01%	-2,24%	-0,40%	-0,01%	0,00%	0,55%	0,00%	-0,55%
5.1.2016	-2,99%	2,73%	0,50%	6,56%	-1,59%	-0,51%	0,00%	-0,55%	2,67%	-0,08%

Izvor: izrada autora

Dobivene prinose izražene u postotcima je potrebno pomnožiti s iznosom ulaganja u svaku dionicu koji su jednaki i iznose 10 000 novčanih jedinica. Na taj način dobijemo iznose dnevnih dobitaka ili gubitaka svake dionice. Primjera radi, dana 28. 04. ove godine 10 000 n. j. uloženih u dionice AD Plastika je generiralo na kraju tog dana prinos od 161,64 novčanih jedinica. Ukoliko se određenom dionicom nije trgovalo, prepisana je cijena iz prethodnog dana pa je prinos jednak nuli. Prinos portfelja na određeni dan se dobije zbrajanjem novčanih prinosa dionica koje tvore portfelj ili se postotni prinosi dionica pomnože s iznosom ulaganja u svaku od dionica u portfelju.

[58] Aljinović, Z., Marasović, B., Šego, B. (2011): Financijsko modeliranje, Ekonomski fakultet u Splitu, Split, str. 161.

U sljedećoj tablici se nalaze dnevni novčani dobitci i gubitci svake dionice u portfelju tijekom odabranog vremenskog razdoblja.

Tablica 4: Dnevni dobitci i gubitci portfelja hrvatskih dionica

DATUM	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP
28.4.2017	161,64	184,50	-139,96	322,44	536,53	209,22	125,79	0,00	-262,79	47,73
27.4.2017	124,84	-370,16	-198,50	-120,73	-575,11	-104,59	63,49	-536,09	-505,73	-166,08
26.4.2017	182,91	-0,21	86,56	-323,87	-35,77	116,03	154,05	-13,73	-136,06	0,00
25.4.2017	-88,72	-21,39	-12,93	-247,49	0,00	33,24	0,00	-413,82	0,00	47,17
24.4.2017	-31,50	103,09	-160,19	252,04	66,82	-16,63	0,00	52,81	81,41	-23,61
21.4.2017	88,44	-27,81	10,52	319,32	-66,89	-10,88	-268,04	596,96	76,31	-23,56
20.4.2017	0,00	206,43	-107,35	-255,30	-47,96	-102,51	-137,59	-976,06	-103,79	0,00
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
13.1.2016	122,56	42,03	11,84	0,00	100,50	3,55	-78,76	0,00	183,74	-25,33
12.1.2016	153,50	-87,76	-23,54	-233,47	-40,32	-95,32	-29,18	0,00	-213,79	25,33
11.1.2016	3,16	17,71	-14,61	0,00	-199,21	120,19	29,18	0,07	87,96	-67,40
8.1.2016	147,40	28,29	0,00	0,00	129,03	-29,12	-181,39	0,00	-208,45	80,08
7.1.2016	-199,89	-300,98	1,09	-224,39	-39,88	-0,71	0,00	54,58	0,00	-54,86
5.1.2016	-299,15	273,24	50,24	655,87	-159,32	-50,93	0,00	-54,58	267,01	-8,41

Izvor: prikaz autora

Potom se poredaju rezultati portfelja od najvećeg gubitka do najvećeg dobitka iz čega se vidi koliko je raspon distribucije podataka.

Najveći dnevni gubitak portfelja hrvatskih dionica iznosio je 3.148,7 n.j. i zabilježen je 30. 03. ove godine, dok je najveći dobitak bio 2 461,51 n.j. iz travnja ove godine. Indikativno je da prvih nekoliko najvećih gubitaka datira iz posljednja dva mjeseca razmatranja, kao što je i slučaj s najvećim dobitcima pa iz toga proizlazi da je portfelj doživio najveće oscilacije upravo u tom periodu. U portfelju njemačkih dionica najveći gubitak je iznosio 7099,65 n.j. u lipnju prošle godine, međutim radi se o iznimno rijetkom događaju jer je prvi sljedeći najveći gubitak gotovo dvostruko manji. Najveći dobitak je bio 3380,57 n. j. iz ožujka ove godine i viši je za skoro 1000 n. j. od najvećeg dobitka portfelja hrvatskih dionica.

Tablica 5: Poredani prinosi od najvećeg gubitka do najvećeg dobitka portfelja hrvatskih dionica (lijevo) i portfelja njemačkih dionica (desno)

DATUM	Portfelj
30.3.2017	-3148,72
4.4.2017	-2936,27
29.3.2017	-2815,29
12.4.2017	-2773,34
15.3.2017	-2487,86
27.4.2017	-2388,65
⋮	⋮
7.9.2016	1403,04
3.1.2017	1643,49
7.4.2017	1682,91
19.7.2016	2123,55
24.3.2017	2426,58
3.4.2017	2449,7
18.4.2017	2461,51

DATUM	Portfelj
24.6.2016	-7099,65
8.2.2016	-3571,74
15.1.2016	-3412,58
10.3.2016	-2928,25
7.1.2016	-2869,59
⋮	⋮
1.3.2016	2816,071
24.4.2017	2959,423
15.2.2016	3108,877
20.6.2016	3242,649
11.3.2016	3380,557

Izvor: prikaz autora

Nakon toga se VaR izračuna primjenom Excelove funkcije PERCENTILE u kojoj je prvi argument raspon dobitaka i gubitaka portfelja, dok se za drugi argument k odabire n-ti percentil ovisno o odabranoj razini pouzdanosti. Ukoliko se računa VaR uz pouzdanost od 95% potrebno je za argument k navesti 0,05 i time će se dobit rezultat koji se nalazi 5% od lijevog repa distribucije prinosa, to jest, od najvećeg gubitka portfelja. Pored ukupnog VaR koji se odnosi na cjelokupno razdoblje, izračunat je VaR za cijelu 2016. godinu kao i VaR koji se odnosi na prva četiri mjeseca 2017. godine. S lijeve strane se nalaze rizičnosti vrijednosti portfelja hrvatskih dionica, dok su zdesna isti pokazatelji za portfelj njemačkih dionica.

Tablica 6: Ukupni VaR i godišnji VaR-ovi pri razini pouzdanosti od 95% za portfelj hrvatskih dionica (lijevo) i portfelj njemačkih dionica (desno)

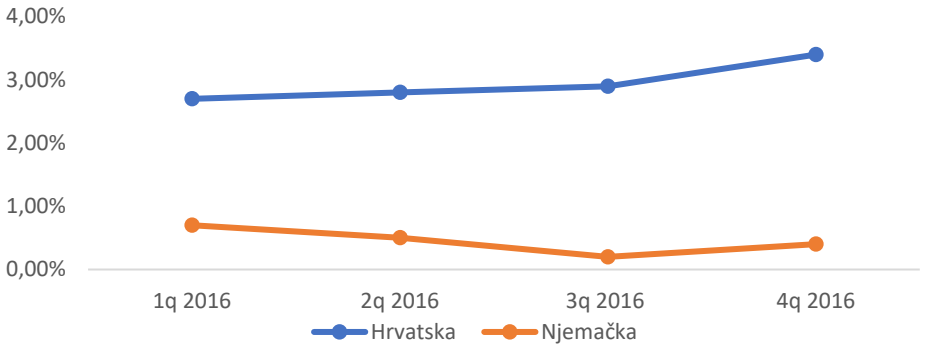
VaR_{ukupno}	-1234,23
VaR_{2017}	-2482,9
VaR_{2016}	-806,34

VaR_{ukupno}	-1934,48
VaR_{2017}	-1023,8
VaR_{2016}	-2231,72

Izvor: izrada autora

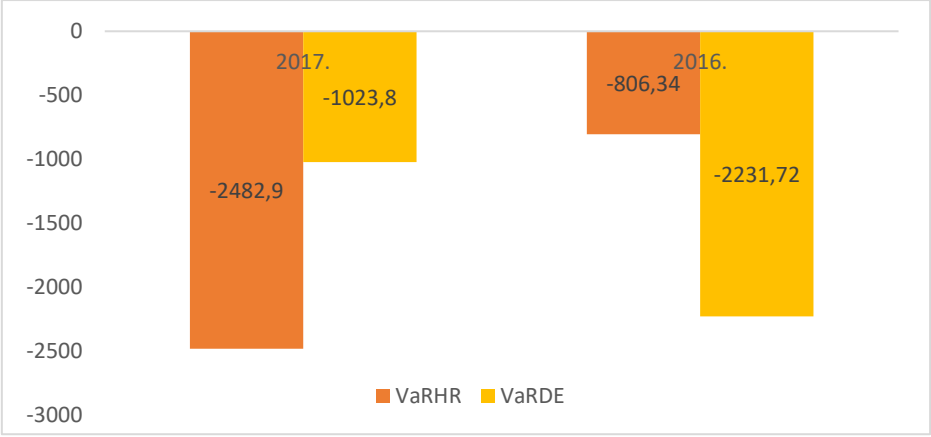
Ukupni VaR za portfelj njemačkih dionica iznosio je -1 934,48 novčanih jedinica. Taj iznos predstavlja granicu gubitaka koja se ne očekuje da bude premašena više od 5 puta u sljedećih 100 radnih dana. VaR portfelja hrvatskih dionica bio je 36,2% niži i iznosio je -1 234,23. Vjerojatno razlog ovakvih rezultata leži u činjenici da je u odabranom vremenskom razdoblju Hrvatska bilježila osjetno veće stope rasta BDP-a što je izazvalo zamah na tržištu kapitala koji je osigurao veći prinos uz niži rizik zahvaljujući vraćanju optimizma na hrvatsko tržište.

Donji grafikon sadrži stope rasta BDP-a u Hrvatskoj i Njemačkoj tijekom 2016. godine iz kojeg se vidi da se prosječna kvartalna stopa rasta BDP-a u Hrvatskoj kretala oko 3%, a u Njemačkoj oko 0,5%.



Slika 6: Kretanje stopa BDP-a u 2016. godini u Hrvatskoj i Njemačkoj
Izvor: prikaz autora

Međutim, trendovi se počinju mijenjati u ovoj godini o čemu svjedoči podatak da je u prvih 4 mjeseca 2017. godine VaR portfelja njemačkih dionica iznosio -1023,8 n. j. i bio je više nego dvostruko niži od VaR-a portfelja hrvatskih dionica. Ova činjenica nije promijenila ukupnu percepciju da je rizik manji na hrvatskom tržištu kapitala zato što se manji udio opažanja odnosi na 2017. godinu. Dakle, rizičnosti vrijednosti portfelja hrvatskih i njemačkih dionica se kreću u suprotnim smjerovima jer se VaR u portfelju njemačkih dionica smanjio u 2017. godini, dok je suprotan slučaj s portfeljem hrvatskih dionica. Donji graf prikazuje kretanje VaR-a izabranih portfelja kroz dvije godine.



Slika 7: Kretanje VaR-a oba portfelja po godinama: hrvatski portfelj (lijevo), njemački portfelj (desno)
Izvor: izrada autora

Povijesna metoda otkriva da se je u proteklih 16 mjeseci moglo manje očekivane gubitke ostvariti na hrvatskom tržištu kapitala koje je uz to imalo veći prosječan dnevni očekivani prinos na uloženo. Iz toga proizlazi da je hrvatsko tržište u tom razdoblju bilo atraktivnije za

investitore, no situacija se mijenja u tekućoj godini kada je VaR portfelja hrvatskih dionica bio 2,425 puta veći od VaR-a portfelja njemačkih dionica. Ovakvi podaci kod kojih je recentni trend različit od ukupnog trenda zahtijevaju opreznost prilikom tumačenja dobivenih rezultata. Mogu li se navedeni rezultati prihvatiti kao mjerodavni bit će poznato nakon backtestinga.

5.3.1. Provjera valjanosti načela subaditivnosti

Načelo subaditivnosti koje nalaže da je VaR portfelja manji od zbroja VaR-ova njegovih sastavnih dijelova je zadovoljeno u oba portfelja kao što se zorno može vidjeti u sljedećim tablicama.

Tablica 7: VaR pojedinačne dionice i VaR portfelja hrvatskih dionica

ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP	Portfelj
-246,052	-177,222	-143,554	-465,187	-187,203	-112,35	-219,843	-358,739	-215,9494	-169,966	-1234,2332

Izvor: prikaz autora

Pojedinačni VaR-ovi zbrojeni iznose -2 296,07 n. j., dok je VaR portfelja 1 234,23 što je 46,2 % manje zahvaljujući efektu diverzifikacije. Dionice s najvećom rizičnosti vrijednosti su Atlantska Plovidba i Ledo. Očekivano je da su dvije dionice s najvećom standardnom devijacijom ujedno one s najvećim VaR-om.

Tablica 8: VaR pojedinačne dionice i VaR portfelja istih dionica s njemačkog tržišta

SAP	SIEMENS	Bayer	BASF	Allianz	D.Telekom	Volkswagen	Daimler	BMW	Henkel	Portfelj
-198,43	-203,32	-235,39	-221,16	-222,72	-176,95	-328,89	-266,99	-282,52	-180,35	-1934,48

Izvor: prikaz autora

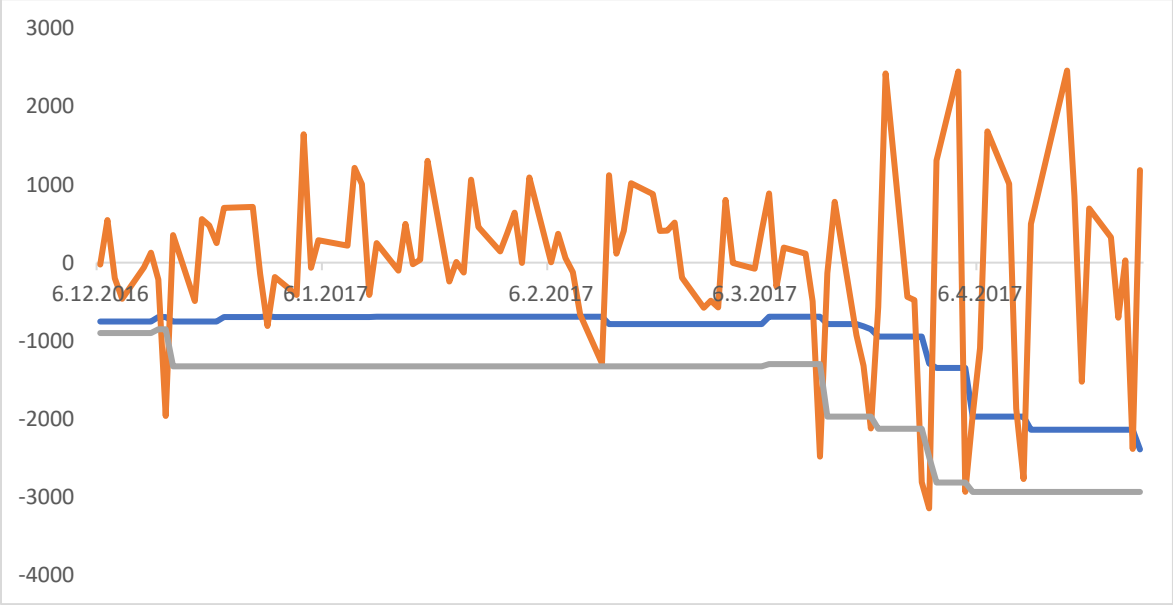
U portfelju njemačkih dionica zbrojeni VaR-ovi pojedinačnih dionica iznose – 2 316,72 n. j., dok je VaR tog portfelja -1 934,38 n.j. pa je vidljivo da je efekt diverzifikacije manji u ovom slučaju, a kasnije u istraživanju lako će se moći uočiti razlog za to jer u matrici varijanci i kovarijanci portfelja njemačkih dionica nije postojala nijedna negativna korelacija među dionicama što je presudno za diverzifikaciju i smanjenje rizika. I u ovom portfelju dionice s najvećom dnevnom standardnom devijacijom Volkswagen i BMW imaju najveći VaR.

5.3.2. Backtesting rezultata povijesne metode

Procesom backtestinga se provjerava primjerenost upotrebe pojedine metode izračuna VaR-a tako da se zabilježi koliko puta je prekoračen VaR za određenu razinu pouzdanosti. Ukoliko se radi o razini pouzdanosti od 95% VaR ne bi smio biti premašen više od 5 puta u 100 dana.

Analogno tome, pri razini pouzdanosti od 99% očekuje se samo 1 prebačaj VaR-a u sljedećih 100 dana. Backtesting će se provesti na isti način za svaku metodu izračuna tako da se usporede prinosi portfelja svakog dana od posljednjih 100 dana u odabranom razdoblju s VaR-om iz tog dana izračunatim na temelju podataka o prinosima portfelja iz 100 dana koji su prethodili tom danu.

Sljedeća slika prikazuje backtesting rezultata povijesne metode za portfelj hrvatskih dionica u zadnjih 100 dana za dvije razine pouzdanosti.



Slika 8: Backtesting rezultata povijesne metode portfelja hrvatskih dionica
Izvor: prikaz autora

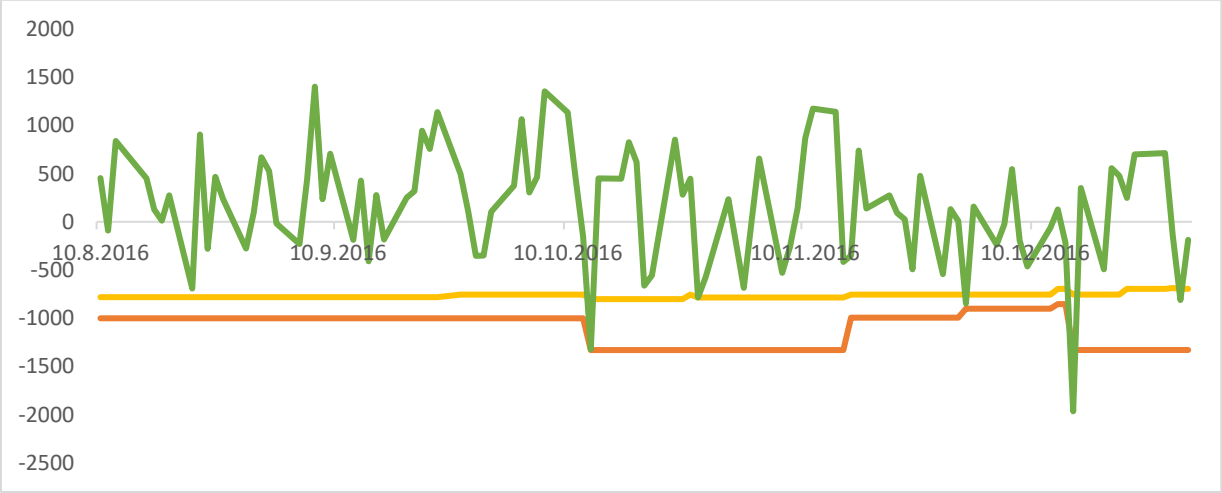
Sa slike je vidljivo da je VaR pri razini pouzdanosti od 95% označen plavom linijom premašen više od 5 puta, od čega najviše u posljednjim tjednima kada portfelj doživljava značajne oscilacije. Tome je najviše pridonijela dionica Ledo kao član koncerna Agrokor koji se našao u financijskim teškoćama i prijetio mu je bankrot baš u vrijeme najvećih oscilacija ovog portfelja. Ukoliko bi se iz razmatranja isključila dionica Leda to ne bi dovelo do drugačijeg rezultata backtestinga jer među ostalim dionicama u portfelju ima važnih dobavljača Agrokora kao što su Atlantic Grupa i Podravka čije su dionice također doživjela teške udarce zbog krize u Agrokoru pa su i one odgovorne za dobar dio oscilacija u vrijednosti portfelja. Sve navedeno je potvrda činjenice da VaR vrijedi samo u normalnim tržišnim uvjetima.

Ukupno je u zadnjih 100 dana bilo čak 12 prekoračenja pa se povijesna metoda pri razini pouzdanosti od 95% ne može smatrati reprezentativnom za hrvatsko tržište kapitala. Ipak,

uočljivo je da se VaR (95%) povećava u zadnjim tjednima sukladno sve većim gubicima u vrijednosti portfelja, ali taj je pomak preblag pa stvarni rizik biva drastično podcijenjen što znači da se dobiveni rezultat ne može smatrati relevantnim.

VaR pri razini pouzdanosti od 99% označen sivom bojom bio je premašen čak 6 puta u zadnjih 100 dana. Dopušteno je samo jedno prekoračenje pa se ni on ne može smatrati reprezentativnom mjerom rizika na hrvatskom tržištu kapitala. Već iz običnog pogleda na gornji graf je jasno zašto je bolje upotrebljavati VaR (99%) od VaR-a (95%). Vidljivo je da on opada strmije čime se povećava potencijalni gubitak kada se na tržištu događaju veliki gubitci u vrijednosti portfelja, a to znači da brže reagira na drastične promjene u riziku.

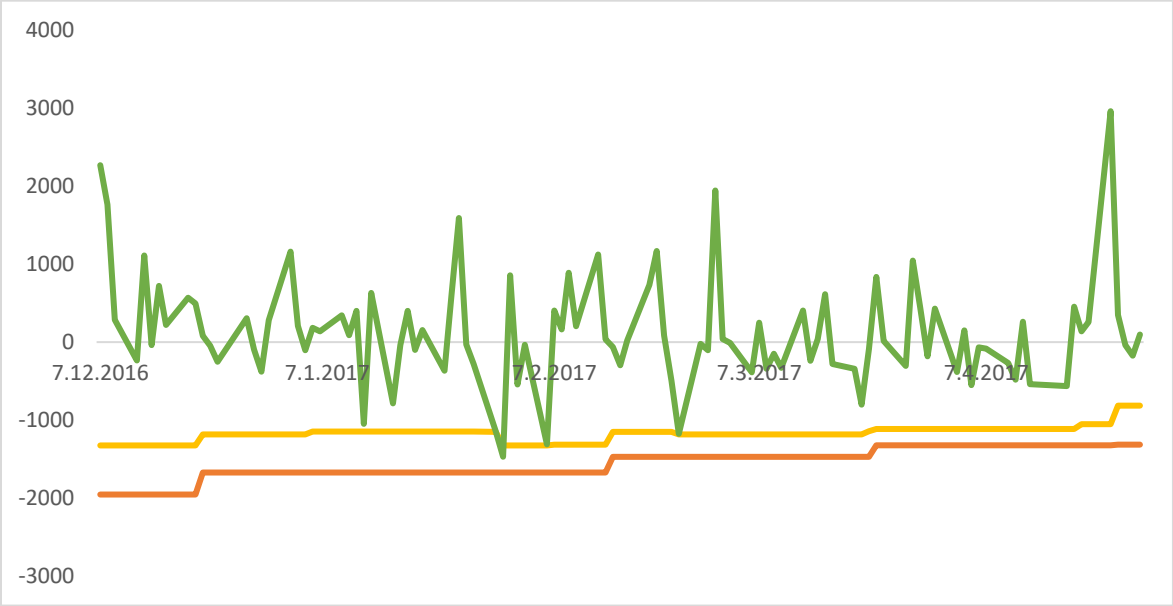
Rezultati backtestinga otkrivaju da povijesna metoda podcjenjuje rizik na hrvatskom tržištu kapitala zbog toga što nije obuhvaćeno dovoljno dugo razdoblje u kojem je bilo velikih fluktuacija, nego se one javljaju samo krajem promatranog vremenskog perioda pa to nije u dovoljnoj mjeri utjecalo na ukupni VaR koji bi dao realnu sliku tržišnog rizika na hrvatskom tržištu kapitala. Ukoliko bi se iz razmatranja isključilo razdoblje krize najveće domaće kompanije i uzeli podatci samo za cijelu 2016. godinu kada su na oba tržišta vladali normalni uvjeti backtesting rezultata bi pokazao kako je povijesna metoda reprezentativna na hrvatskom tržištu kapitala što bi značilo da se može prihvatiti kao činjenica da se u 2016. godini na hrvatskom tržištu kapitala mogao zaraditi veći prinos (u tom periodu prosječan dnevni prinos portfelja hrvatskih dionica u koji je uloženo 100 000 n. j. iznosio je 100,99 n. j., a u portfelju njemačkih dionica s istim ulogom samo 28,38 n. j.) uz niži rizik (VaR portfelja dionica hrvatskih poduzeća u 2016. iznosio je -806 n. j., a drugog portfelja -2 231 n. j). Na sljedećoj slici je prikazan backtesting samo za 2016. godinu portfelja hrvatskih dionica.



Slika 9: Backtesting rezultata povijesne metode portfelja hrvatskih dionica za 2016. g.
Izvor: prikaz autora

Rezultati backtestinga samo za 2016. godinu pokazuju da je VaR (95%) premašen 4 puta, a VaR (99%) je premašen jednom što oboje upućuje na to da je VaR izračunat povijesnom metodom reprezentativna mjera tržišnog rizika na hrvatskom tržištu kapitala u normalnim tržišnim uvjetima.

Na sljedećoj slici je prikazan backtesting rezultata dobivenih povijesnom metode za portfelj dionica njemačkih poduzeća u zadnjih 100 dana za dvije razine pouzdanosti.



Slika 10: Backtesting rezultata povijesne metode portfelja njemačkih dionica
Izvor: prikaz autora

Kao što se vidi na grafu, VaR je prekoračen jednom za razinu pouzdanosti od 95% , dok u zadnjih 100 dana nije bilo prekoračenja za razinu pouzdanosti od 99% što znači da je povijesna metoda reprezentativna za njemačko tržište kapitala. Zaključno, nije moguće usporediti rezultate VaR-a na hrvatskom i njemačkom tržištu kapitala jer povijesna metoda nije reprezentativna na oba tržišta.

5.3.3. Izračun CVaR-a povijesnom metodom

Nakon što je izračunat VaR, poželjno je izračunati CVaR koji će dati više saznanja o gubitcima u repu distribucije, to jest, o raspodjeli unutar 5% najvećih gubitaka. Budući da portfelj hrvatskih dionica ima 332 podatka o dnevnim dobitcima i gubitcima portfelja, a 5% od tog broja iznosi 16,6, onda će se uzeti 17 najvećih gubitaka vrijednosti portfelja i izračunati će se njihov prosjek. Isti postupak se provodi za njemački portfelj dionica s tom razlikom što postoji više podataka o dnevnim dobitcima i gubitcima portfelja, točnije njih 337, ali kako je

5% od tog broja 16,85 i ovdje će se uzeti 17 najvećih gubitaka vrijednosti portfelja i izračunati njihov prosjek.

Za portfelj hrvatskih dionica CVaR (95%) iznosi – 2 059,21 n. j., a za portfelj njemačkih dionica CVaR (95%) je – 2 901,07. Omjer CVaR-a i VaR-a hrvatskog portfelja iznosi 1,67, a kod njemačkog portfelja je 1,5. Manji omjer kod portfelja njemačkih dionica znači da su njegovi gubitci viši od VaR-a gušće raspoređeni oko VaR-a.

5.4. Izračun VaR-a parametarskom metodom

Prije nego se krene s provođenjem parametarske metode bilo bi dobro testirati jesu li distribucije dobitaka i gubitaka normalno raspoređene. To je testiranje obavljeno u programu STATISTICA. U sljedećim tablicama su navedeni neki parametri distribucija dobitaka i gubitaka obaju portfelja poput aritmetičke sredine, medijana, moda, donjeg i gornjeg kvartila.

Tablica 9: Parametri distribucije dobitaka i gubitaka portfelja hrvatskih dionica

	Descriptive Statistics (HRV DIONICE)											
Variable	Valid N	Mean	Median	Mode	Frequency of Mode	Minimum	Maximum	Lower Quartile	Upper Quartile	Std.Dev.	Skewness	Kurtosis
Portfelj	332	69,29218	116,0364	Multiple	1	-3148,72	2461,510	-282,730	498,2847	781,7178	-0,788392	2,976735

Izvor: prikaz autora

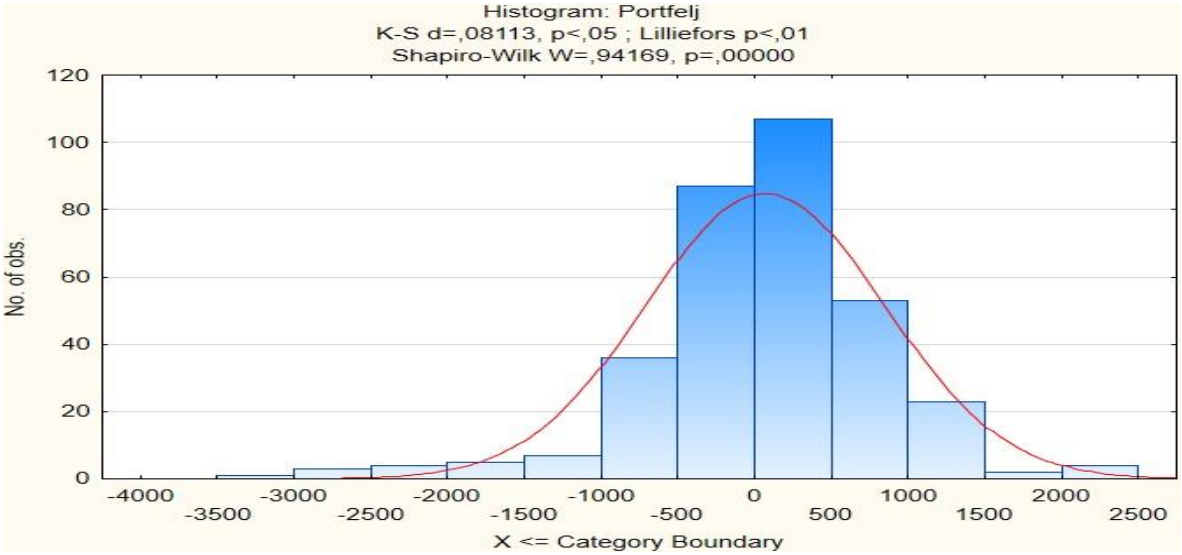
Distribucija dobitaka i gubitaka portfelja hrvatskih dionica ima parametar zakrivljenosti (skewness) jednak – 0,788 koji je u normalnoj distribuciji jednak 0, a budući da je negativan distribucija prinosa portfelja je nagnuta ulijevo. Zaobljenost (kurtosis) iznosi 2,976 što se gotovo pa podudara s normalnom distribucijom kod koje taj parametar iznosi 3.

Tablica 10: Parametri distribucije dobitaka i gubitaka portfelja njemačkih dionica

	Descriptive Statistics (njem dionice)											
Variable	Valid N	Mean	Median	Mode	Frequency of Mode	Minimum	Maximum	Lower Quartile	Upper Quartile	Std.Dev.	Skewness	Kurtosis
Portfelj	338	34,24091	35,91847	Multiple	1	-7099,65	3380,557	-563,473	630,3770	1198,585	-0,655835	3,879897

Izvor: prikaz autora

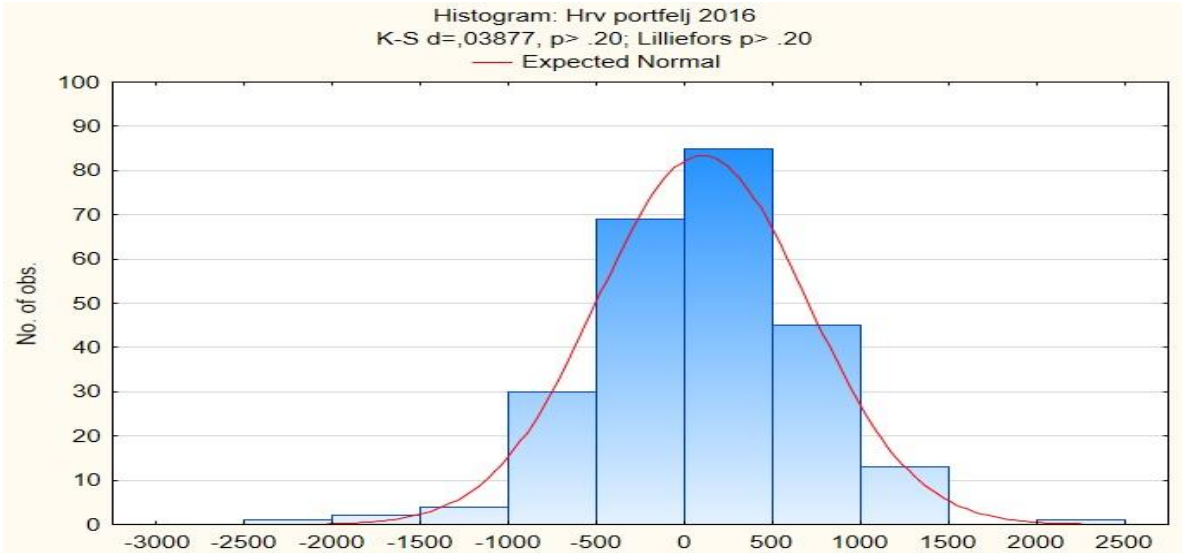
Distribucija dobitaka i gubitaka njemačkog portfelja dionica je također nagnuta ulijevo jer joj mjera zakrivljenosti (skewness) iznosi -0,655, no manje od prethodne distribucije. Njena mjera zaobljenosti (kurtosis) je 3,88 što je čini šiljastijom od krivulje normalne distribucije i distribucije prinosa portfelja hrvatskih dionica. Ono po čemu je ova distribucija slična normalnoj distribuciji jest činjenica da se aritmetička sredina i medijan distribucije međusobno neznatno razlikuju, a u normalnoj distribuciji oni su jednaki.U nastavku je prikazane slika s histogramom stvarne distribucije prinosa portfelja hrvatskih dionica na koji je superponirana normalna distribucija zajedno s Kolmogorov-Smirnovim testom u zaglavlju.



Slika 11: Krivulja stvarne i normalne distribucije prinosa portfelja hrvatskih dionica
Izvor: prikaz autora

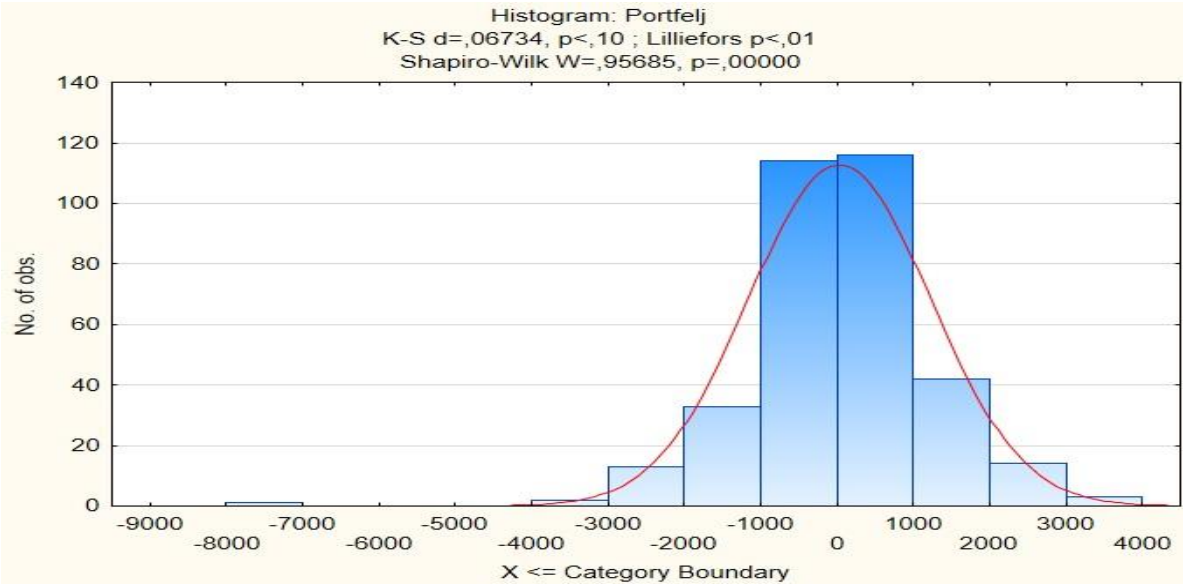
Iz slike je uočljiv problem zadebljanih repova distribucije dobitaka i gubitaka hrvatskog portfelja dionica jer su rubne frekvencije s lijeve strane veće nego što bi se očekivalo u normalnoj distribuciji. Vrijednost *p* Kolmogorov-Smirnovog testa je manja od 0,05 što znači da treba odbaciti nultu hipotezu da je distribucija normalno raspoređena.

Ukoliko se distribucija prinosa testira za razdoblje u kojem nije bilo krize s Agrokorom, a to znači uzimanje u obzir samo prinosa iz 2016. godine dobiju se drugačiji rezultati Kolmogorov-Smirnovog testa, to jest, *p* je veći od 0,2 dok je granica 0,05 zbog čega se može prihvatiti hipoteza da je distribucija normalno raspoređena. Odnos distribucije prinosa iz 2016. god. i normalne distribucije zajedno s rezultatima Kolmogorov-Smironovog testa je prikazan na sljedećoj slici.



Slika 12: Krivulja stvarne i normalne distribucije prinosa iz 2016. godine
Izvor: prikaz autora

Na sljedećoj slici je histogram prinosa portfelja njemačkih dionica s grafom normalne distribucije i rezultatom Kolmogorov- Smirnovog testa.



Slika 13: Krivulja stvarne i normalne distribucije prinosa portfelja njemačkih dionica
Izvor: prikaz autora

Iz slike se vidi da distribucija dobitaka i gubitaka portfelja njemačkih dionica vjernije slijedi normalnu distribuciju nego distribucija prinosa portfelja hrvatskih dionica bez obzira na postojanje izuzetka u intervalu od -7000 do -8000 n. j. koji je daleko udaljen od cijele distribucije.

Kolmogorov-Smirnov test (K-S) daje vrijednost $p < 0,1$ što je više od 0,05 i može se prihvatiti hipoteza da je dotična distribucija normalno raspoređena.

Parametarska metoda koristi iste početne podatke kao i povijesna metoda prikazane na stranici broj 3 u tablici 1., a radi se o cijenama dionica iz portfelja u odabranom vremenskom razdoblju. Uz to, prvi korak provođenja parametarske metode je isti kao kod povijesne metode jer je potrebno izračunati dnevne prinose za svaku dionicu u promatranom razdoblju. Budući da je to već napravljeno za povijesnu metodu, ovdje se neće ponavljati.

U drugom koraku je nužno izračunati prosječan prinos svake dionice u portfelju što je jednostavno napraviti u Excelu upotrebom funkcije AVERAGE čiji je argument raspon svih dnevnih prinosa pojedine dionice.

Prosječan prinos portfelja je moguće dobiti kao zbroj umnožaka prosječnog prinosa dionice s udjelom iste u portfelju. Na donjoj slici je prikazan prosječan dnevni prinos svake dionice iz portfelja hrvatskih dionica.

Tablica 11: Prosječan dnevni prinos portfelja hrvatskih dionica

Dionica	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP
Prosječan dnevni prinos	0,16%	0,07%	-0,01%	0,38%	0,08%	0,07%	0,06%	-0,29%	0,01%	0,17%

Izvor: prikaz autora

Zatim se računa matrica A u kojoj svaki element je razlika između svakog pojedinog dnevnog prinosa dionice i prosječnog prinosa iste. U matematičkom obliku to se može zapisati na sljedeći način:

$$A = \begin{bmatrix} R_{1,1} - E(R_1) & \cdots & R_{1,n} - E(R_n) \\ \vdots & \ddots & \vdots \\ R_{m,1} - E(R_1) & \cdots & R_{m,n} - E(R_n) \end{bmatrix} \quad (8)$$

Pritom je $R_{1,1}$ prvi dnevni prinos prve dionice u portfelju, a $E(R_1)$ je prosječni dnevni prinos prve dionice.

Sljedeća tablica predstavlja matricu A portfelja hrvatskih dionica. Element B2 u tablici se dobije kao razlika između 1.62% koliki je prinos dionice AD Plastik tog dana i 0,16% koliki je prosječni dnevni prinos iste.

Tablica 12: Matrica A portfelja hrvatskih dionica

DATUM	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP
28.4.2017	1,461%	1,773%	-1,387%	2,849%	5,283%	2,022%	1,201%	0,289%	-2,640%	0,306%
27.4.2017	1,093%	-3,774%	-1,972%	-1,583%	-5,833%	-1,116%	0,578%	-5,072%	-5,069%	-1,832%
26.4.2017	1,674%	-0,074%	0,878%	-3,615%	-0,440%	1,090%	1,483%	0,152%	-1,372%	-0,171%
25.4.2017	-1,042%	-0,286%	-0,116%	-2,851%	-0,082%	0,263%	-0,057%	-3,849%	-0,012%	0,300%
24.4.2017	-0,470%	0,959%	-1,589%	2,145%	0,586%	-0,236%	-0,057%	0,817%	0,802%	-0,407%
21.4.2017	0,729%	-0,350%	0,118%	2,817%	-0,751%	-0,179%	-2,737%	6,258%	0,751%	-0,407%
20.4.2017	-0,155%	1,992%	-1,061%	-2,929%	-0,561%	-1,095%	-1,433%	-9,472%	-1,050%	-0,171%
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
12.1.2016	1,380%	-0,950%	-0,223%	-2,711%	-0,485%	-1,023%	-0,349%	0,289%	-2,150%	0,082%
11.1.2016	-0,123%	0,105%	-0,133%	-0,376%	-2,074%	1,132%	0,235%	0,289%	0,868%	-0,845%
8.1.2016	1,319%	0,211%	0,013%	-0,376%	1,208%	-0,361%	-1,871%	0,289%	-2,096%	0,630%
7.1.2016	-2,154%	-3,082%	0,024%	-2,620%	-0,481%	-0,077%	-0,057%	0,835%	-0,012%	-0,720%
5.1.2016	-3,147%	2,660%	0,515%	6,183%	-1,675%	-0,579%	-0,057%	-0,257%	2,659%	-0,255%

Izvor: prikaz autora

Nakon izračuna matrice A moguće je izračunati matricu varijanci i kovarijanci primjenom formule: $S = \frac{A^T \cdot A}{M}$, pri čemu je značenje simbola sljedeće:

S - matrica varijanci i kovarijanci,

A^T - transformirana matrica A,

M - broj opažanja.

Ova formula se u Excelu zapisuje kao: S= MMULT (TRANSPOSE(A); A) / broj opažanja. Dimenzije matrice su $n \times n$ gdje je n broj dionica u portfelju. Elementi na dijagonali matrice su varijance svake dionice u portfelju.

Sljedeća tablica je matrica varijanci i kovarijanci portfelja hrvatskih dionica. Negativna korelacija je utvrđena između dionica AD Plastika i Adrisa, AD Plastika i Končar Elektroindustrije te između Atlantske Plovidbe i Podravke. Ona je bitna za postizanje efekta diverzifikacije.

Tablica 13: Matrica varijanci i kovarijanci portfelja hrvatskih dionica

	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP
ADPL	0,0002723	-0,0000056	0,0000031	0,0000030	0,0000151	0,0000256	-0,0000091	0,0000460	0,0000074	0,0000076
ADRS	-0,0000056	0,0001267	0,0000202	0,0000345	0,0000163	0,0000185	0,0000160	0,0000360	0,0000460	0,0000353
ATGR	0,0000031	0,0000202	0,0001107	0,0000225	0,0000153	0,0000062	0,0000308	0,0001418	0,0000495	0,0000433
ATPL	0,0000030	0,0000345	0,0000225	0,0012344	0,0000178	0,0000041	0,0000406	0,0000496	-0,0000104	0,0000267
ERNT	0,0000151	0,0000163	0,0000153	0,0000178	0,0001820	0,0000202	0,0000182	0,0000293	0,0000226	0,0000172
HT	0,0000256	0,0000185	0,0000062	0,0000041	0,0000202	0,0000793	0,0000087	0,0000207	0,0000193	0,0000137
KOEI	-0,0000091	0,0000160	0,0000308	0,0000406	0,0000182	0,0000087	0,0002174	0,0000800	0,0000484	0,0000309
LEDO	0,0000460	0,0000360	0,0001418	0,0000496	0,0000293	0,0000207	0,0000800	0,0007850	0,0001482	0,0000805
PODR	0,0000074	0,0000460	0,0000495	-0,0000104	0,0000226	0,0000193	0,0000484	0,0001482	0,0001966	0,0000566
RIVP	0,0000076	0,0000353	0,0000433	0,0000267	0,0000172	0,0000137	0,0000309	0,0000805	0,0000566	0,0001516

Izvor: prikaz autora

Nakon izračuna matrice varijanci i kovarijanci moguće je izračunati standardnu devijaciju portfelja jer postoje svi podaci koje je potrebno unijeti u sljedeću formulu: $\sigma_\pi = \sqrt{\pi^T \cdot S \cdot \pi}$ gdje je π vektor udjela svake dionice u portfelju. U Excelu ista formula glasi: $\sigma_\pi = SQRT$(MMULT(MMULT(TRANSPOSE(π); S; π)). Standardna devijacija portfelja hrvatskih dionica iznosila je 0,78%.

Sljedeći korak je izračun standardiziranog obilježja z za definiranu razinu pouzdanosti. U Excelu se za tu svrhu koristi funkcija NORMSINV(α) kojoj je jedini parametar razina pouzdanosti. Pri razini pouzdanosti od 95% z iznosi 1,645.

Tek sada je moguće izračunati VaR primjenom sljedeće formule:

$$VaR_{1-\alpha} = -(\mu_\pi + z_\alpha \cdot \sigma_\pi) \cdot P.$$

Svi parametri u zagradama formule su izračunati u prethodnim koracima, a P se odnosi na iznos ulaganja u portfelj. Uvrštavanjem podataka u formulu dobije se $VaR_{0,95}$ = - (0,0069 + 1.645 * 0,0078) * 100 000 n. j. = - 1.283,87 n. j.

Iznos koji se dobije za VaR portfelja hrvatskih dionica uz razinu pouzdanosti od 95% je -1283,87 n. j. što je neznatno više od iznosa VaR-a dobivenog povijesnom metodom.

Matrica varijanci i kovarijanci portfelja njemačkih dionica ne sadrži nijednu negativnu korelaciju što se vidi u sljedećoj tablici.

Tablica 14: Matrica varijanci i kovarijanci njemačkog portfelja dionica

	SAP	SIEMENS	Bayer	BASF	Allianz	D.Telekom	olkswage	Daimler	BMW	Henkel
SAP	0,000146	0,000102	9,42E-05	9,92E-05	0,000109	9,75E-05	0,000144	0,000119	0,000122	6,62E-05
Siemens	0,000102	0,000218	0,000119	0,000139	0,000151	9,82E-05	0,000194	0,000153	0,000168	7,27E-05
Bayer	9,42E-05	0,000119	0,000222	0,000126	0,000127	0,0001	0,000159	0,000145	0,000145	7,31E-05
BASF	9,92E-05	0,000139	0,000126	0,000183	0,000132	0,000102	0,000184	0,000153	0,000157	6,3E-05
Allianz	0,000109	0,000151	0,000127	0,000132	0,000236	0,000115	0,000213	0,000164	0,000188	6,93E-05
D.Telekom	9,75E-05	9,82E-05	0,0001	0,000102	0,000115	0,000153	0,000138	0,000117	0,000118	6,65E-05
Volkswagen	0,000144	0,000194	0,000159	0,000184	0,000213	0,000138	0,000487	0,000259	0,000306	9,5E-05
Daimer	0,000119	0,000153	0,000145	0,000153	0,000164	0,000117	0,000259	0,000262	0,000238	6,98E-05
BMW	0,000122	0,000168	0,000145	0,000157	0,000188	0,000118	0,000306	0,000238	0,000302	8,55E-05
Henkel	6,62E-05	7,27E-05	7,31E-05	6,3E-05	6,93E-05	6,65E-05	9,5E-05	6,98E-05	8,55E-05	0,000127

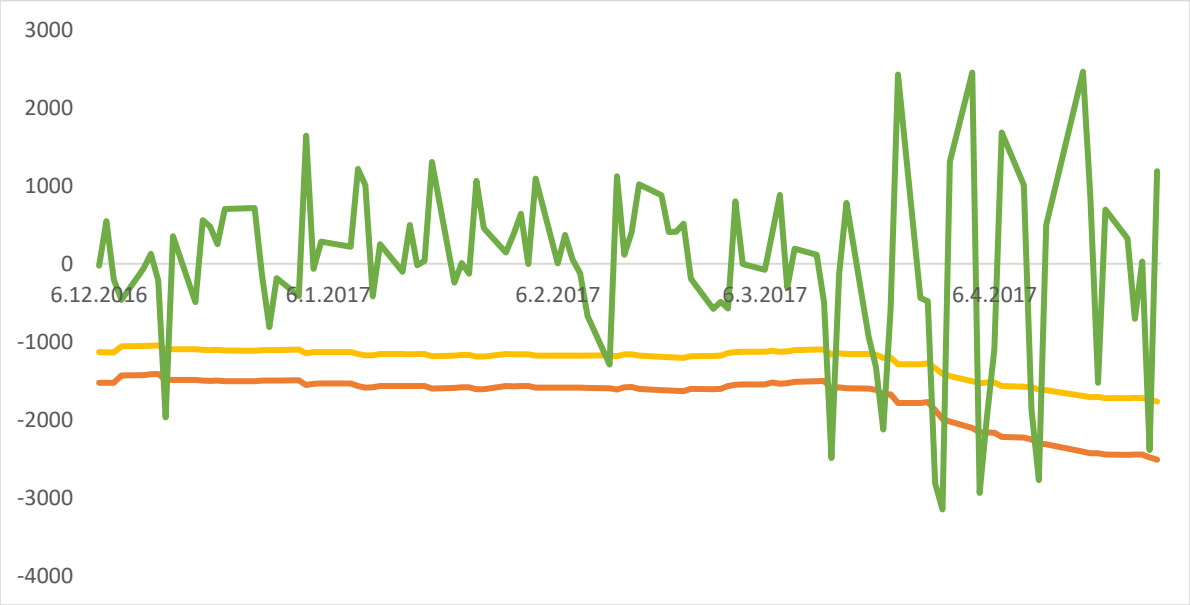
Izvor: prikaz autora

VaR portfelja njemačkih dionica je veći od portfelja hrvatskih dionica i iznosi -1963,57. To znači da na razini jednog dana gubitak portfelja veći od 1.963,57 n. j. se može očekivati samo u 5% slučajeva, odnosno jedanput u 20 radnih dana.

Primjenom parametarske metode došlo se do istih zaključaka kao i kod povijesne metode, a to je da je VaR portfelja njemačkih dionica veći od VaR-a portfelja hrvatskih dionica. U nastavku je proveden backtesting kako bi se utvrdilo mogu li se takvi rezultati prihvatiti.

.4.1. Backtesting rezultata parametarske metode

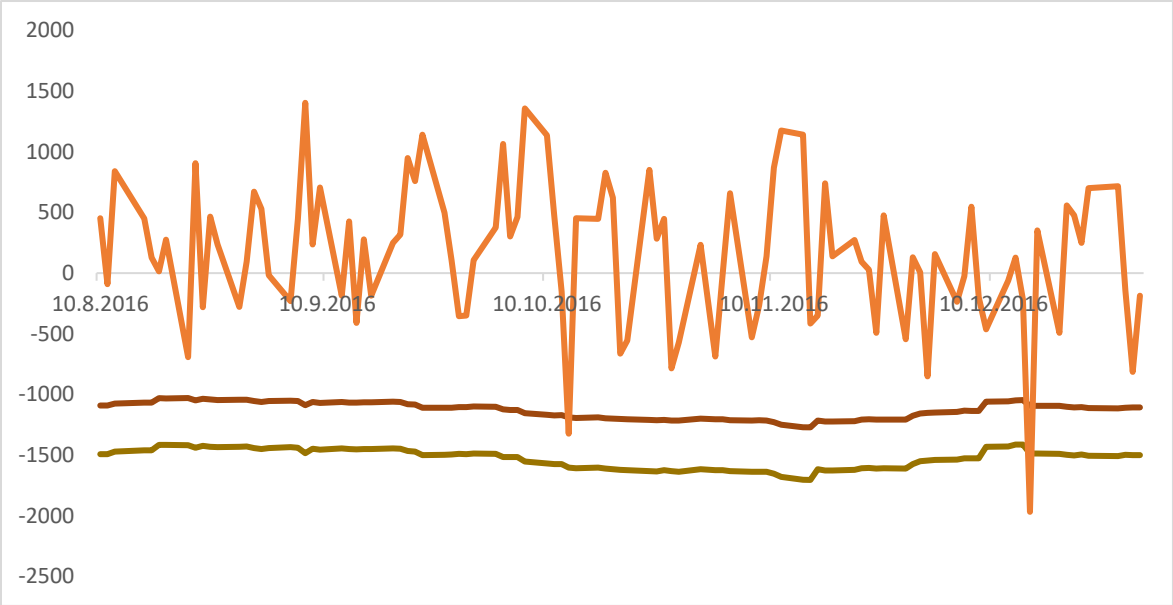
Na sljedećoj slici grafički je prikazan backtesting rezultata parametarske metode za portfelj hrvatskih dionica u zadnjih 100 dana.



Slika 14: Backtesting rezultata parametarske metode portfelja hrvatskih dionica
Izvor: prikaz autora

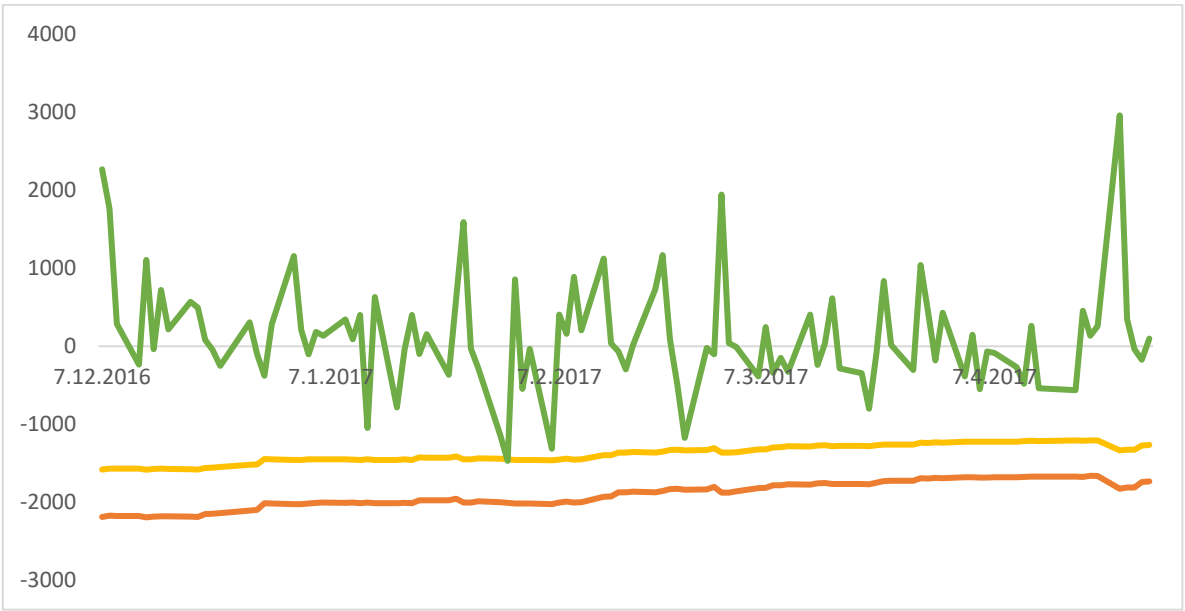
Backtestingom je utvrđeno da je VaR portfelja hrvatskih dionica premašen 12 puta u zadnjih 100 dana pri razini pouzdanosti od 95%, dok je dopušteno najviše 5 prekoračenja. VaR za razinu pouzdanosti od 99% je bio premašen 7 puta u zadnjih 100 dana pa se parametarska metoda ne može smatrati reprezentativnom na hrvatskom tržištu kapitala. Iako su se i povijesna i parametarska metoda pokazale neprimjerenima, ipak je parametarska metoda inferiorna povijesnoj u ovom primjeru jer puno blaže reagira na iznenadne promjene u tržišnom riziku kao što se može vidjeti na gornjoj slici gdje ne postoje veliki skokovi u vrijednosti VaR-a kao što je bio slučaj kod povijesne metode.

Nije zgoreg provesti dodatni backtesting za razdoblje u kojem su na tržištu vladali normalni uvjeti, a odnosi se na cijelu 2016. godinu jer je samo u takvim okolnostima VaR kao mjera tržišnog rizika primjenjiv. I zaista, rezultati backtestinga pokazuju da je parametarska metoda reprezentativna mjera na hrvatskom tržištu kapitala u tom razdoblju budući da je pri obje razine pouzdanosti bilo manje prekoračenja VaR-a od dopuštenih što se vidi na narednoj slici.



Slika 15: Backtesting rezultata parametarske metode za 2016. godinu na hrvatskom tržištu kapitala
Izvor: prikaz autora

Na sljedećoj slici je prikazan backtesting rezultata VaR-a dobivenih parametarskom metodom za portfelj njemačkih dionica u zadnjih 100 dana.



Slika 16: Backtesting rezultata parametarske metode portfelja njemačkih dionica
Izvor: prikaz autora

Vidljivo je da VaR (95%) premašen jednom u zadnjih 100 dana, a VaR (99%) nijednom što se slaže s rezultatima backtestinga za povijesnu metodu pa je stoga i parametarska metoda reprezentativna na njemačkom tržištu kapitala. Krivulje VaR-a imaju blagu uzlaznu putanju

što znači da se tržišni rizik u posljednih 100 dana postupno smanjivao na njemačkom tržištu kapitala za razliku od hrvatskog tržišta kapitala.

5.5. Monte Carlo simulacija

Prvih nekoliko koraka ove metode identično je parametarskoj metodi, a obuhvaćaju:

1. prikupljanje podataka o cijenama dionica u portfelju za odabrano razdoblje
2. izračun dnevnih prinosa svake dionice u portfelju
3. izračun prosječnog prinosa i standardne devijacije svake dionice u portfelju
4. izračun matrice varijanci i kovarijanci dionica u portfelju
5. izračun očekivanog prinosa i standardne devijacije portfelja

Nakon toga vrši se simulacija prinosa svake dionice i ukupnog portfelja, i to za najčešće 1 000 ili 10 000 scenarija koliko je napravljeno u ovom radu. U Excelu je to omogućeno upotrebom funkcije NORMINV(RAND(); μ; σ) koja ima tri argumenta: RAND () koji generira slučajan broj između 0 i 1 , a odnosi se na vjerojatnost, μ je srednja vrijednost distribucije podataka iz odabranog razdoblja, a σ je standardna devijacija distribucije podataka. Ova funkcija vraća inverznu vrijednost kumulativne normalne distribucije za navedenu srednju vrijednost i standardnu devijaciju.

Tako izračunata vrijednost se pomnoži s ulogom u pojedinu dionicu kako bi se dobili dnevni dobitci i gubitci. Konkretno, dnevni dobitci i gubitci portfelja hrvatskih dionica se dobiju upisivanjem formule NORMINV(RAND(); 0,0069; 0,0078) * 10 000 u ćeliju te ju potom razvučemo na 10 000 redaka zbog kreiranja mnogobrojnih scenarija. Važno je napomenuti da ovo nije jedini način na koji se može izračunati VaR Monte Carlo metodom, ali se pokazao najjednostavnijim.

U nastavku je prikazano nekoliko prvih i posljednjih od ukupno 10 000 simuliranih scenarija dobitaka i gubitaka pojedine dionice i čitavog portfelja.

Tablica 15: Tablica provedenih simulacija na portfelju hrvatskih dionica

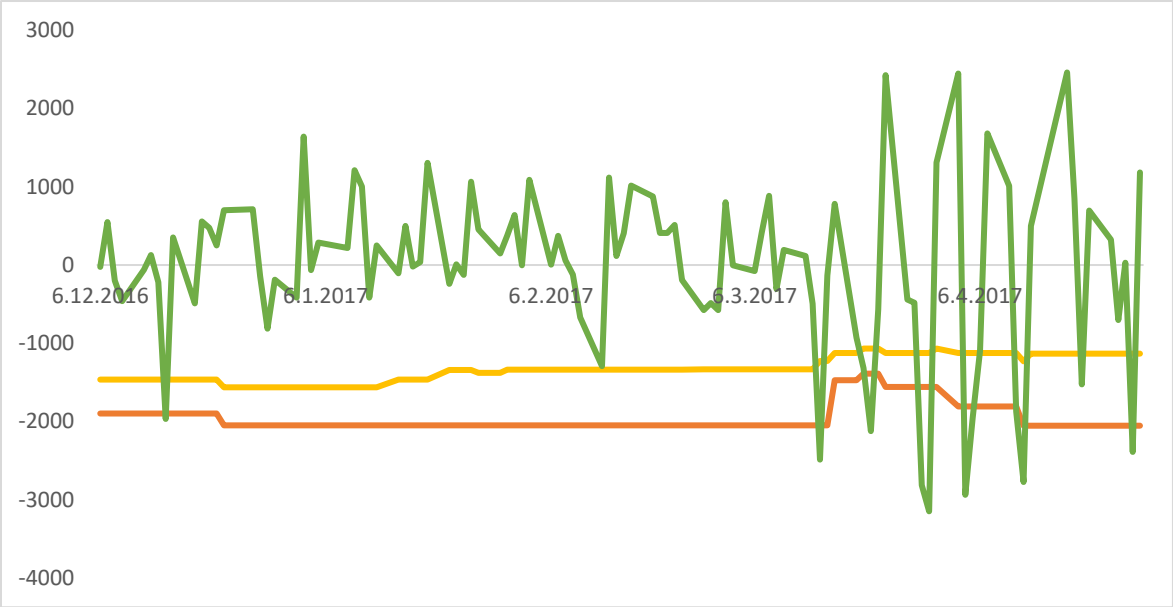
Scenarij	ADPL	ADRS	ATGR	ATPL	ERNT	HT	KOEI	LEDO	PODR	RIVP	Portfelj
1	-114,63	-36,93	50,88	550,09	86,59	-82,96	51,24	127,84	50,75	96,90	-980,18
2	240,75	-111,26	157,14	-263,22	74,50	42,94	-106,15	46,35	69,66	103,67	702,72
3	-145,05	49,21	-120,89	67,93	-13,31	108,73	217,82	-147,84	-80,69	76,35	-1002,42
4	173,66	15,03	118,40	-217,08	-44,26	-63,38	56,09	6,98	-178,69	82,48	-129,98
5	90,49	-246,81	-154,32	-227,27	-161,37	104,26	-129,51	-346,50	-168,20	-66,32	270,98
6	332,36	-38,29	-132,84	431,14	-143,33	42,94	-162,75	44,13	-7,76	199,71	663,17
7	-91,23	-12,93	-120,51	342,08	-76,10	-50,12	226,79	444,61	182,42	147,49	-1004,52
8	207,44	-22,03	-265,13	387,54	96,92	35,37	-54,46	-254,53	74,12	71,76	868,26
9	148,82	54,30	178,05	-184,21	256,95	-142,90	174,00	456,79	98,66	-12,93	850,21
10	-73,45	121,98	-53,94	216,88	109,08	69,40	203,31	412,48	8,53	109,95	515,21
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
9994	-79,59	56,96	-87,67	-312,04	34,10	12,21	-32,82	-51,86	-238,04	29,83	155,04
9995	35,97	93,04	130,23	236,13	-122,57	27,68	145,38	-340,42	7,26	50,80	991,95
9996	-219,85	133,00	-64,33	-45,36	23,02	-3,19	30,61	-102,31	107,87	214,07	-107,29
9997	-46,37	219,99	-6,26	-246,62	-207,98	34,87	-302,39	175,59	96,58	53,72	-1390,01
9998	242,17	18,68	209,25	517,52	-74,88	-79,11	75,26	51,51	-177,07	-105,03	-230,29
9999	-264,77	-79,06	111,70	-486,93	162,32	-39,04	186,22	-314,13	171,86	-3,49	1596,41
10000	-47,23	-123,84	262,50	-238,91	107,18	-16,37	179,74	111,05	110,51	-52,74	243,82

Izvor: prikaz autora

Nakon toga, procedura je identična kao kod povijesne metode. Upotrebom funkcije PERCENTILE na stupac sa simuliranim dobicima i gubicima portfelja uz parametar α od 0,05 koji se odnosi na razinu pouzdanosti od 95% dobije se VaR Monte Carlo metodom koji u slučaju portfelja hrvatskih dionica iznosi -1193 n. j. Taj rezultat ne odstupa značajno od vrijednosti dobivenih drugim metodama izračuna VaR-a. Isto vrijedi i za VaR portfelja njemačkih dionica koji je i u ovom slučaju viši nego u drugom portfelju te iznosi -1940 n. j. što se također ne razlikuje osjetno od rezultata dobivenih drugim metodama.

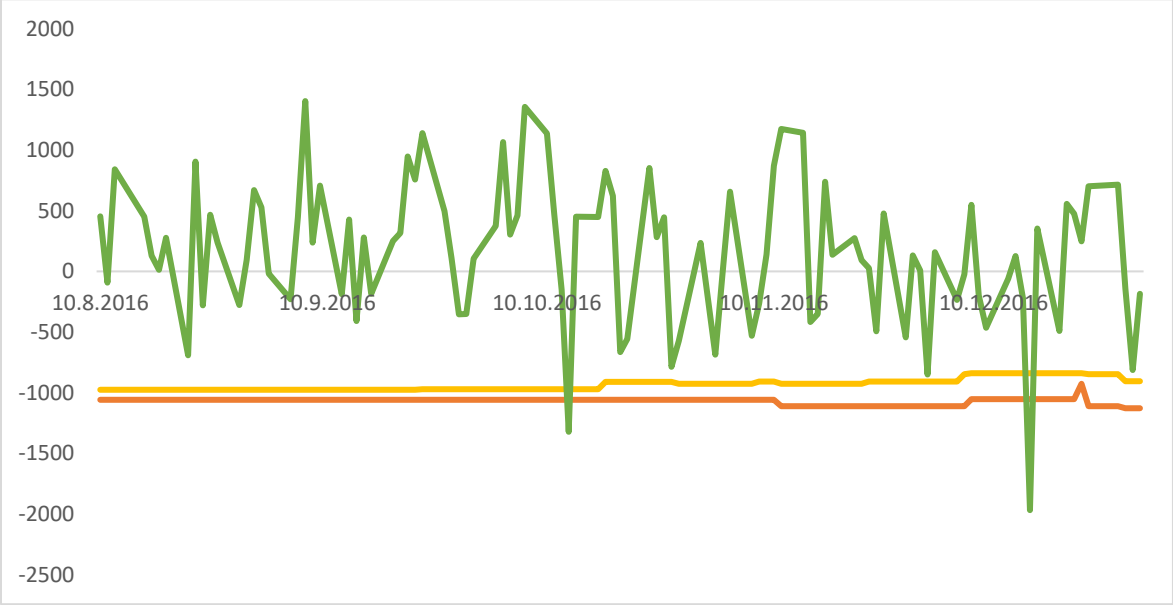
5.5.1. Backtesting rezultata Monte Carlo simulacije

Na sljedećoj slici je prikazan backtesting rezultata Monte Carlo simulacije za portfelj hrvatskih dionica u 100 radnih dana pri razinama pouzdanosti od 95% i 99%.



Slika 17: Backtesting rezultata Monte Carlo simulacije portfelja hrvatskih dionica
Izvor: prikaz autora

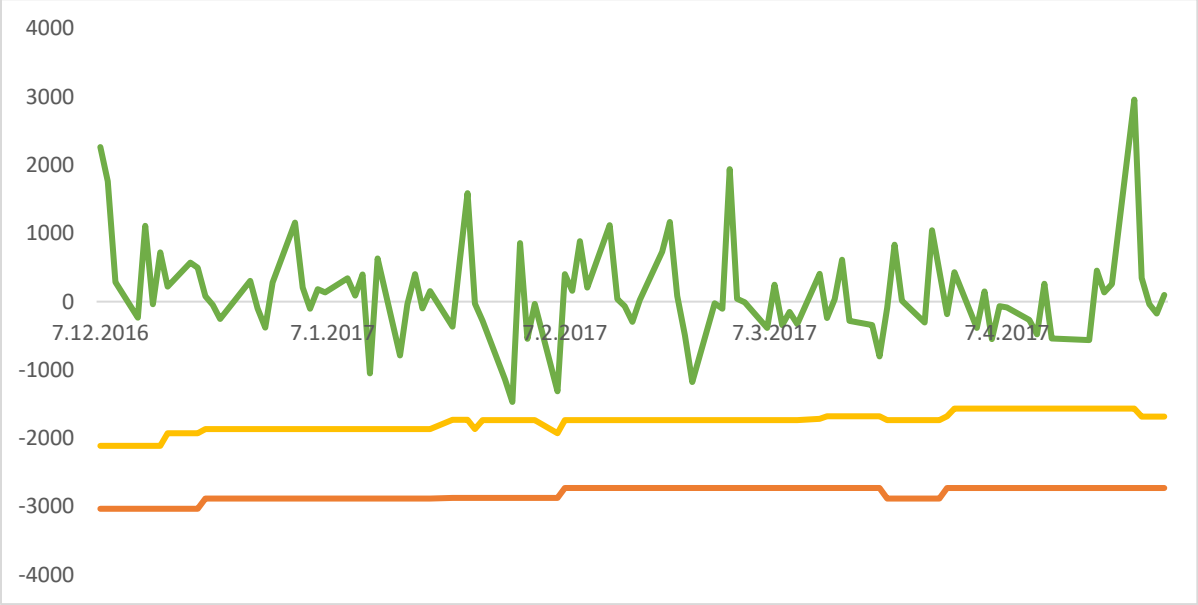
Rezultati backtestinga nisu iznenađujući jer kako VaR (95%) tako i VaR (99%) su se pokazali neprimjenjivi na hrvatskom tržištu baš kao i povijesna i parametarska metoda zbog prevelikog broja prebačaja VaR-a. I u ovom slučaju se ponavlja isti obrazac višestrukog prekoračenja VaR-a na kraju testnog razdoblja. Monte Carlo uvelike podcjenjuje rizik na hrvatskom tržištu kapitala i jako slabo reagira na promjene u tržišnom riziku. U nastavku je napravljen backtesting, ali na rezultatima koji proizlaze iz podataka iz 2016. godine kako bi se neutralizirao efekt krize Agrokora.



Slika 18: Backtesting rezultata Monte Carlo simulacije samo za 2016. godinu
Izvor: prikaz autora

Bactesting rezultata u normalnim tržišnim uvjetima pokazuju da je VaR (95%) premašen manje od 5 puta u zadnjih 100 dana po čemu je on reprezentativna mjera tržišnog rizika na hrvatskom tržištu kapitala, dok je VaR (99%) premašen 2 puta pa se ne može smatrati adekvatnim za primjenu na hrvatskom tržištu kapitala. S druge strane, povijesna i parametarska metoda su se pokazale reprezentativnima za obje razine pouzdanosti.

U nastavku je napravljen backtesting rezultata Monte Carlo simulacije za portfelj njemačkih dionica u posljednih 100 dana i predočen je na sljedećoj slici.



Slika 19: Backtesting Monte Carlo simulacije portfelja njemačkih dionica
Izvor: prikaz autora

Monte Carlo simulacija je reprezentativna na njemačkom tržištu kapitala baš kao povijesna i parametarska metoda jer VaR pri obje razine pouzdanosti nije premašen nijednom.

ZAKLJUČAK

Sve veća globalizacija i liberalizacija u sferi financija dovela je do većeg obujma trgovanja, dok je konstantni porast financijskih inovacija rezultirao pojavom novih financijskih proizvoda na tržištu. Ovakvi trendovi su pospješili globalni gospodarski razvoj, ali za negativnu posljedicu imaju porast tržišnog rizika. To se manifestira sve učestalijim, jačim i raširenijim financijskim krizama pa u takvim okolnostima mjerenje tržišnog rizika postaje sve važnije. Zbog obuhvata i slojevitosti tržišnog rizika danas postoje brojne metode za njegovo mjerenje, ali najpopularnijom među njima se smatra Value at Risk (rizičnost vrijednosti). Više je razloga za to, od činjenice da se VaR izražava jednim jedinim brojem koji je potencijalni gubitak uz određenu razinu vjerojatnosti zbog čega je prikladan i za laike, njime se mogu služiti kako portfelj menadžeri, obični investitori ili pak financijski regulatori do toga da se može primijeniti na bilo koji financijski instrument. Međutim, VaR ima i stanovitih ograničenja pa bi svaki investitor trebao zapamtiti da je VaR nužan, ali ne i dovoljan oblik upravljanja i mjerenja tržišnog rizika. Neki od nedostataka VaR-a su da ne otkriva nikakve informacije o gubitcima iznad svoje vrijednosti, a oni mogu biti neznatno viši ili mnogostruko viši od njega, dok je drugi važan nedostatak taj da VaR vrijedi samo u normalnim tržišnim uvjetima, a ako tome nije tako moguće je da drastično podcijeni rizik pogotovo ako postoje zadebljani krajevi u repu distribucije. Bogatstvo VaR-a leži i u postojanju triju metoda kojima se može izmjeriti, a to su: povijesna metoda, parametarska metoda i Monte Carlo simulacija. Svaka od njih ima svoje prednosti i nedostatke, pa se ne može tvrditi da postoji najbolja među njima, iako će se ovisno o svakom konkretnom slučaju i tržišnim uvjetima koji prevladavaju iskristalizirati koja je najpogodnija za upotrebu. Ono po čemu se metode izračuna VaR-a međusobno razlikuju su: sposobnost obuhvata nelinearnih financijskih instrumenata, jednostavnost implementacije, fleksibilnost uključivanja različitih pretpostavki i pouzdanost rezultata.

Fokus ovo rada je bio na usporedbi i analizi tržišnog rizika primjenom VaR-a na portfelju dionica hrvatskih, odnosno, njemačkih poduzeća kako bi se pružio uvid u razlike na tržištu kapitala između zemalja koje se uvelike razlikuju jer je njemačko gospodarstvo najsnažnije u Europi, dok je hrvatsko gospodarstvo samo djelić toga i još uvijek je u tranziciji. Postupak formiranja portfelja trebao je zadovoljiti dva uvjeta: prvi je da se u portfelju nalaze najlikvidnije dionice te da u portfelju najviše 3 dionice dolaze iz istog sektora kako bi stupanj diverzifikacije bio što veći i kako bi se portfelj u što većoj mjeri kretao kao tržišni indeks. Zbog kotiranja dionica u različitim valutama na dvama tržištima, a da bi se izbjeglo

preračunavanje među valutama, ulog je izražen u novčanim jedinicama. Sve tri korištene metode za izračun VaR-a su dale međusobno gotovo podudarne rezultate iako nije rijetkost da bude značajnih odstupanja među istima. Rezultati su pokazali da je u odabranom razdoblju VaR portfelja hrvatskih dionica bio niži od VaR-a portfelja njemačkih dionica i to otprilike za trećinu, dok se istovremeno viši prinos mogao ostvariti na hrvatskom tržištu kapitala. Površan pogled na te podatke naveo bi na zaključak da se na hrvatskom tržištu kapitala mogao ostvariti viši prinos uz manji rizik. Međutim, naknadno testiranje dobivenih rezultata backtestingom je pokazalo da je rizik na hrvatskom tržištu znatno podcijenjen. Razlog za to je što je potkraj promatranog razdoblja došlo do naglih promjena u vrijednosti portfelja izazvanih prijetnjom bankrota najvećoj domaćoj kompaniji Agrokoru. To je izazvalo burnu reakciju na čitavom tržištu zbog čega tržišni uvjeti nisu bili normalni, a to je preduvjet da bi VaR kao mjera tržišnog rizika bio valjan. Ukoliko bi se iz razmatranja isključilo razdoblje krize Agrokora koja je započela početkom 2017. godine, onda, gledajući cijelu 2016.godinu, proizlazi da su metode izračuna VaR-a reprezentativne na oba tržišta i da se na hrvatskom tržištu kapitala mogao ostvariti veći prinos uz manji rizik mjeren VaR-om što je najvjerojatnije bilo povezano s rastom BDP-a u Hrvatskoj iznad očekivanja koji se kretao se na kvartalnoj razini između 2.5% i 3%, dok je istovremeno u Njemačkoj iznosio tek oko 0,5%. Upravo iz razloga što je testiranje rezultata svih metoda izračuna VaR-a pokazalo da VaR nije reprezentativan za hrvatsko tržište kapitala pri uvjetima koji su vladali u odabranom periodu ne može se prihvatiti hipoteza da je tržišni rizik manji na hrvatskom nego na njemačkom tržištu kapitala. Iako su se sve metode pokazale nereprezentativnima na hrvatskom tržištu kapitala među rezultatima backtestinga postoje izvjesne razlike koje pokazuju da je najbolje na hrvatskom tržištu koristiti povijesnu simulaciju, jer je puno realnije ocijenila rizik u odnosu na parametarsku metodu i Monte Carlo simulaciju što posebno vrijedi za višu razinu pouzdanosti. Istraživanje je također pokazalo da se VaR na dvama tržištima kretao u suprotnim smjerovima u 2017. u odnosu na 2016. godinu. Za očekivati je bilo da korelacija bude pozitivna jer su oba tržišta dobro povezana budući da egzistiraju unutar istog okvira Europske Unije, no odgovor leži u činjenici da se najveća hrvatska kompanija Agrokor borila za opstanak pa je svaka dobra ili loša vijest bila pokretačem velikih skokova ili padova na tržištu kapitala. Iz toga proizlazi da je većina tržišnog rizika u Hrvatskoj nije bila sustavnog, nego specifičnog karaktera. S druge strane, backtesting rezultata dobivenih svim trima metodama za portfelj dionica njemačkih poduzeća je pokazao da su sve metode reprezentativne za njemačko tržište kapitala što znači da je VaR kao mjera rizika prikladna za njemačko tržište kapitala i mogu se primijeniti sve tri metode za izračun VaR-a.

LITERATURA

1. Abdić, A., Abdić, A., Kanlić, F. (2009): Primjena Value-at-risk metode na tržištu kapitala Bosne i Hercegovine, Zbornik radova ICEI, Sarajevo, str. 201-212.
2. Aljinović, Z., Marasović, B., Šego, B. (2011): Financijsko modeliranje, Ekonomski fakultet u Splitu, Split
3. Cvetinović, M. (2008): Upravljanje rizicima u financijskom poslovanju, Univerzitet Singidunum, Beograd, str. 51-52
4. Damodar, A. (2005): Value at risk (VaR), NYU Stern school of business, NYC
5. Drljača, M., Bešker, M. (2010): Održivi uspjeh i upravljanje rizicima poslovanja, Centar za kvalitet Crne Gore, Tivat
6. Latković, M. (2002): Upravljanje rizicima: identifikacija, mjerenje i kontrola, Financijska teorija i praksa, Vol.26 No.2, str. 463.-477.
7. Linsmeier T. J., Pearson N. D. (1996): Risk Measurment: An Introduction to Value at Risk, Working Paper 96-04, University of Ilinois at Urbana-Champaign
8. Mikulčić, D. (2001): Value at Risk (Rizičnost vrijednosti), Hrvatska narodna banka, Zagreb
9. Munđar, D., Zemljak, A. (2016): Izračun rizične vrijednosti-VaR, Poučak: časopis za metodiku i nastavu matematike, str. 71.-79.
10. Novak, B., Sajter, D. (2007): VaR dioničkih i mješovitih investicijskih fondova u Republici Hrvatskoj, Ekonomski fakultet u Osijeku, Osijek
11. Sabolić, D. (2013): Rizik i nesigurnost I., bilješke s predavanja, Fakultet elektrotehnike i računarstva, Zagreb
12. 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).
13. Šverko, I. (2002): Rizična vrijednost (Value at risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, Vol.53 No.7-8, str. 640.-657.
14. Tuškan, B. (2009): Upravljanje rizicima upotrebom financijskih derivata u RH, Zbornik Ekonomskog fakulteta u Zagrebu, Vol.7 No.1, str. 107.-120.
15. Udovičić, A., Kadlec Ž. (2013): Analiza rizika upravljanja poduzećem, Praktični menadžment: stručni časopis za teoriju i praksu menadžmenta, Vol.4 No.1, str. 50.-60.
16. Uryasev, S. (2000): Conditional Value-at-Risk: Algorithms and applications, Financial Engineering News, No. 14, 1-5.

17. Uryasev, S., Serraino, G., Sarykalin, S. (2008): Value-at-Risk vs. Conditional Value-at-Risk in Risk Management and Optimization, University of Florida
18. Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, IV. izdanje, Ekonomski fakultet u Rijeci, Rijeka
19. Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, magistarski rad, Ekonomski fakultet u Ljubljani
20. Živko, I. (2006): Kamatni rizik u bankarstvu-izvori i učinci, Ekonomski fakultet, Sveučilište u Mostaru, Mostar

Izvori s Interneta

1. http://zse.hr/default.aspx?id=44101&index=CROBEX10
2. http://www.boerse-frankfurt.de/aktien

PRILOZI

Popis slika

Slika 1: Vrste rizika 11

Slika 2: Podjela financijskog i tržišnog rizika 13

Slika 3: Sastavnice tržišnog rizika 13

Slika 4: Grafički prikaz VaR-a 19

Slika 5: Odnos CVaR-a i VaR-a 24

Slika 6: Kretanje stopa BDP-a u 2016. godini u Hrvatskoj i Njemačkoj 42

Slika 7: Kretanje VaR-a oba portfelja po godinama: hrvatski portfelj (lijevo), njemački portfelj (desno) 42

Slika 8: Backtesting rezultata povijesne metode portfelja hrvatskih dionica 44

Slika 9: Backtesting rezultata povijesne metode portfelja hrvatskih dionica za 2016. g. 45

Slika 10: Backtesting rezultata povijesne metode portfelja njemačkih dionica 46

Slika 11: Krivulja stvarne i normalne distribucije prinosa portfelja hrvatskih dionica 48

Slika 12: Krivulja stvarne i normalne distribucije prinosa iz 2016. godine 48

Slika 13: Krivulja stvarne i normalne distribucije prinosa portfelja njemačkih dionica 49

Slika 14: Backtesting rezultata parametarske metode portfelja hrvatskih dionica 53

Slika 15: Backtesting rezultata parametarske metode za 2016. godinu na hrvatskom tržištu kapitala 54

Slika 16: Backtesting rezultata parametarske metode portfelja njemačkih dionica 54

Slika 17: Backtesting rezultata Monte Carlo simulacije portfelja hrvatskih dionica 57

Slika 18: Backtesting rezultata Monte Carlo simulacije samo za 2016. godinu 57

Slika 19: Backtesting Monte Carlo simulacije portfelja njemačkih dionica 58

Popis tablica

Tablica 1: Prosječan dnevni prinos i prosječna dnevna standardna devijacija portfelja hrvatskih i njemačkih dionica 37

Tablica 2: Cijena dionica portfelja dionica hrvatskih poduzeća u kunama 38

Tablica 3: Dnevni prinosi dionica u portfelju hrvatskih poduzeća 39

Tablica 4: Dnevni dobitci i gubitci portfelja hrvatskih dionica 40

Tablica 5: Poredani prinosi od najvećeg gubitka do najvećeg dobitka portfelja hrvatskih dionica (lijevo) i portfelja njemačkih dionica (desno) 41

Tablica 6: Ukupni VaR i godišnji VaR-ovi pri razini pouzdanosti od 95% za portfelj hrvatskih dionica (lijevo) i portfelj njemačkih dionica (desno) 41

Tablica 7: VaR pojedinačne dionice i VaR portfelja hrvatskih dionica 43

Tablica 8: VaR pojedinačne dionice i VaR portfelja istih dionica s njemačkog tržišta 43

Tablica 9: Parametri distribucije dobitaka i gubitaka portfelja hrvatskih dionica 47

Tablica 10: Parametri distribucije dobitaka i gubitaka portfelja njemačkih dionica 47

Tablica 11: Prosječan dnevni prinos portfelja hrvatskih dionica 50

Tablica 12: Matrica A portfelja hrvatskih dionica 50

Tablica 13: Matrica varijanci i kovarijanci portfelja hrvatskih dionica 51

Tablica 14: Matrica varijanci i kovarijanci njemačkog portfelja dionica 52

Tablica 15: Tablica provedenih simulacija na portfelju hrvatskih dionica 56

SAŽETAK

Value at risk (rizičnost vrijednosti) je mjera tržišnog rizika koja pokazuje potencijalni gubitak koji se može ostvariti na nekom financijskom instrumentu ili portfelju u promatranom razdoblju uz definiranu razinu pouzdanosti. Iskazuje se jednim brojem i vrijedi samo u normalnim tržišnim uvjetima. VaR se pojavio krajem 80-tih godina prošlog stoljeća i do danas je ostao popularan, a koriste ga kako različiti investitori tako i financijski regulatori. Uz brojne prednosti VaR posjeduje i određene nedostatke pa se smatra nužnim, ali ne i dovoljnim načinom mjerenja tržišnog rizika. Tri su metode kojima je moguće izračunati VaR: povijesna metoda, parametarska metoda i Monte Carlo simulacija. U provedenom istraživanju uspoređivao se VaR portfelja dionica s hrvatskog tržišta kapitala s onim s njemačkog tržišta kapitala. Cilj istraživanja je bilo uvidjeti kolike su razlike u tržišnom riziku između dviju zemalja, a uz to se utvrdilo razlikuju li se rezultati među različitim metodama izračuna VaR-a, jesu li te metode reprezentativne na oba tržišta i kakav je odnos rizika i prinosa na tim tržištima. Rezultati istraživanja su otkrili da se na portfelju dionica hrvatskih poduzeća mogao ostvariti veći prinos i to uz manji VaR. Međutim, naknadnim testiranjem je utvrđeno da je VaR podcijenjen na hrvatskom tržištu kapitala prvenstveno zbog krize u najvećoj domaćoj kompaniji Agrokoru krajem promatranog perioda koja se prelila na čitavo tržište. Budući da VaR vrijedi samo pri normalnim tržišnim uvjetima sve metode izračuna VaR-a su se pokazale nereprezentativnima na hrvatskom tržištu kapitala za razliku od njemačkog tržišta kapitala. Stoga je upotreba VaR-a primjerenija na njemačkom tržištu kapitala. Ukoliko bi se promatrao period u kojem nije bilo krize najveće hrvatske kompanije, to jest, cijela 2016. godina, tada bi se metode izračuna VaR-a pokazale reprezentativnima i na hrvatskom tržištu kapitala i uvidjelo bi se da se tamo mogao ostvariti veći prinos uz manji VaR zbog čega je ono bilo privlačnije za investitore.

Ključne riječi: tržišni rizik, rizičnost vrijednost (VaR), metode izračuna VaR-a

SUMMARY

Value at risk is a measure of the market risk that indicates potential loss generated by security or portfolio in given period of time with the level of probability defined in advance. It is expressed by a single number and is valid only in normal circumstances. VaR emerged in 1980s but it is popular even nowdays being used by different investors as well as financial regulators. It has many advantages as well as couple of disadvantages so that it is considered neccessary but not an integral way of measuring market risk. There are three methods of

calculating VaR: the historical method, the variance-covariance method and the Monte Carlo simulation. This research was about comparing VaR of portfolios coming from Croatia's and German's capital markets respectively. The aim of the research was to determine the difference in market risk between those two countries while at the same time checking if there are differencies in results obtained by different computation methods, if methods are representative on each capital market and what is the ratio between yield and risk. The results of the research showed that an investor with portfolio of stocks from Croatia's capital market could have made more money while the VaR being lower. However, backtesting the results it became clear that VaR of portfolio of Croatia's stocks was undervalued predominantly due to the crisis in the biggest Croatian private company Agrokor which occurred in the late stage of the testing period and spilled over the whole market. Having in mind that VaR is valid only in normal circumstances all computation methods proved not to be representative on Croatian capital market which was not the case with German capital market. Hence, VaR is more applicable there. If the research is to be done only for year 2016 thus excluding the period of great turbulences in the Croatian capital market it will turn out that all computations methods are representative on Croatian capital market and that there is a chance to earn higher yield while the overall risk being lower which are the reasons that make this market more attractive for investors.

Key words: market risk, value at risk, computation methods