UVJETNA RIZIČNOST VRIJEDNOSTI (CVaR) U PROCJENI RIZIKA NA HRVATSKOM TRŽIŠTU KAPITALA

Trgo, Andrea

Professional thesis / Završni specijalistički

2015

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:124:218437

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

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 SPLIT

POSLIJEDIPLOMSKI SPECIJALISTIČKI STUDIJ
POSLOVNA EKONOMIJA

Andrea Trgo

''UVJETNA RIZIČNOST VRIJEDNOSTI (CVaR) U PROCJENI RIZIKA NA HRVATSKOM TRŽIŠTU KAPITALA“

ZAVRŠNI RAD

Mentor: Prof.dr.sc. Zdravka Aljinović

Split, 2015.

Sadržaj

1. Uvod 4
1.1. Problem istraživanja 4
1.2. Predmet istraživanja 7
1.3. Hipoteze istraživanja 8
1.4. Ciljevi istraživanja 8
1. 5. Metode istraživanja 9
1.6. Struktura rada 10
2. Osnovni rizici u financijskom poslovanju 11
2.1. Definicija i značaj rizika u financijskom poslovanju 11
2.2. Vrste rizika u financijskom poslovanju 14
2.2.1. Kreditni rizik 15
2.2.2. Tržišni rizik 20
2.2.3. Kamatni rizik 25
2.2.4. Valutni rizik 27
2.2.5. Operativni rizik 29
2.2.6. Rizik likvidnosti 30
2.3. Važnost upravljanja rizicima u poslovanju 32
3. Rizičnost vrijednosti (VaR) i uvjetna rizičnost vrijednosti (CVaR) kao mjere rizika 34
3.1. Definicija i osnovne karakteristike rizičnosti vrijednosti (VaR) 34
3.2. Rizičnost vrijednosti (VaR) kao regulatorni instrument u Bazelskom sporazumu 39
3.3. Prednosti i nedostaci rizičnosti vrijednosti 42
3.4. Definicija i osnovne karakteristike uvjetne rizičnosti vrijednosti (CVaR) 44
3.5. Prednosti i nedostaci uvjetne rizičnosti vrijednosti CVaR 48
4. Metode izračuna rizičnosti vrijednosti (VaR) i uvjetne rizičnosti vrijednosti (CVaR) 50
4.1. Povijesna metoda 51
4.1.1. Prednosti povijesnog modela 54
4.1.2. Nedostaci povijesnog modela 55
4.2. Parametarska metoda 56
4.3. Monte Carlo metoda 58
4.4. Usporedba metoda izračuna rizičnosti vrijednosti (VaR) i uvjetne rizičnosti vrijednosti (CVaR) 60
4.5. Testiranje (backtesting) VaR i CVaR 62
4.5.1. Backtesting VaR 62
4.5.2. Backtesting CVaR 63

5. Izračun uvjetne rizičnosti vrijednosti (CVaR) dionica koje kotiraju na Zagrebačkoj burzi 65
5.1. Kretanje gospodarstva Hrvatske u razdoblju od 2006.-2014.g. 65
5.2. Zagrebačka burza 68
5.2.1 Indeksi na Zagrebačkoj burzi 69
5.3. Opis uzorka 72
5.4. Metodologija istraživanja 76
5.5. Rezultati i analiza kvantitativnog istraživanja 80
6. Usporedba i testiranje točnosti dobivenih rezultata 84
7. ZAKLJUČAK 90
LITERATURA 93
OSTALI IZVORI 97
POPIS SLIKA 97
POPIS TABLICA 97
POPIS GRAFIKONA 98

1. Uvod

1.1. Problem istraživanja

Povećanje aktivnosti trgovanja i velikih portfelja u posjedu sudionika na financijskim tržištima napravili su mjerenje tržišnog rizika primarnom brigom za regulatore i upravljanje rizicima. Kriza na financijskom tržištu je naglasila i ključni značaj efikasnog sistema upravljanja kreditnim rizikom te značaj koji taj sistem ima u očuvanju financijske stabilnosti. Ujedno, pružen je snažan podsjetnik na potrebu da financijske institucije efikasno identificiraju, mjere, prate i kontroliraju sistem upravljanja kreditnim rizikom, kao i da razumiju kako kreditni rizik funkcionira u interakciji sa drugim vrstama rizika (uključujući tržišni, likvidnosni i reputacijski rizik).

U Načelima za upravljanje kreditnim rizikom, Bazelski odbor za superviziju banaka, Bazel, 2000.g., ističe se važnost upravljanja rizikom koncentracije budući da nedovoljno upravljanje rizikom koncentracije zna često dovesti do velikih problema u poslovanju banke.

Rizik koncentracije predstavlja bilo koji vid izlaganja prema jednoj ili grupi sličnih izloženosti (npr. prema istom dužniku ili pak različitim pravnim subjektima u okviru jednog geografskog područja, sektora djelatnosti i sl.) s potencijalom da proizvodi:

(i) gubitke u poslovanju (u odnosu na zaradu banke, kapital, ukupnu aktivu ili ukupni nivo rizika) i ugrozi banku ili njenu kreditnu sposobnost ili mogućnost da održi svoj „core biznis“ ili (ii) značajne promjene u svom profilu rizika.[1]

Ponavljajuća priroda problema koncentracije kredita, posebno u pogledu konvencionalnih koncentracija kredita, postavlja pitanje zašto banke dopuštaju stvaranje koncentracija. Kao prvo, u razvoju svoje poslovne strategije, većina se banaka suočava s odlukom o specijalizaciji u nekoliko ključnih područja s ciljem postizanja vodećeg položaja na tržištu i diversifikacije svojih dohodovnih tokova, posebno kad se radi o poslovanju u volatilnim tržišnim segmentima. Ovu odluku otežava pojačana konkurencija među bankama i među nebankarskim institucijama u području tradicionalnih bankovnih aktivnosti, poput davanja kredita tvrtkama s investicijskom ocjenom. Čini se da se koncentracije najčešće pojavljuju jer

[1] Načela za upravljanje kreditnim rizikom, Bazelski odbor za superviziju banaka, Bazel, 2000.g.

banke prepoznaju "vruće" i brzo rastuće djelatnosti te se koriste previše optimističnim pretpostavkama o budućim izgledima te djelatnosti, posebice u pogledu aprecijacije imovine i mogućnosti ostvarivanja iznadprosječnih kamatnih naknada i/ili marži. U težnji da ostvare rast imovine ili tržišnog udjela, banke se čine izrazito sklone previđanju opasnosti u takvim situacijama.

Osim toga u mnogim slučajevima, zbog trgovinskog područja u kojem banka djeluje, geografskog položaja ili nedostatka pristupa gospodarski različitim zajmoprimcima ili drugim ugovornim stranama, izbjegavanje ili smanjivanje koncentracija može biti iznimno teško. Uz to banke nastoje kapitalizirati svoju stručnost u određenoj djelatnosti ili gospodarskom sektoru.

Očekuje se da banke posjeduju efikasne unutarnje politike, sisteme i kontrole identifikacije, mjerenja, praćenja, upravljanja, i umanjenja rizika koncentracije. Osim toga, ne samo da banka treba uzeti u obzir normalne tržišne uvjete, nego i potencijalno povećanje koncentracije u stresnim tržišnim okolnostima, ekonomskim poremećajima i periodima opće tržišne nelikvidnosti. Pored toga, banka treba procijeniti scenarije s obzirom na moguću koncentraciju, koja proizlazi iz ugovora i uvjetnih obaveza. Scenarija trebaju kombinirati potencijalnu izloženost banke zajedno s gubitkom tržišta i likvidnosti te značajnim padom ili smanjenjem vrijednosti imovine.

Kao reakcija na velike financijske krize tijekom dvadesetog stoljeća, koje su rezultirale bankrotom mnogih financijskih institucija, posljednjih dvadeset godina u suvremenim financijama razvijeni su brojni koncepti za upravljanje i mjerenje rizika. Glavna metoda za upravljanje rizikom je metoda rizičnosti vrijednosti (Value at risk - VaR), koja se u praksi kombinira s drugim tehnikama za minimiziranje rizika u poslovanju, kako bi se postigli optimalni poslovni rezultati. Rizičnost vrijednosti[2] (Value at risk - VaR) predstavlja najveći gubitak portfelja koji se može očekivati u promatranom razdoblju uz danu razinu pouzdanosti. Ova vrijednost je jednostavan, lako razumljiv broj, koji predstavlja rizik kojem je institucija izložena na financijskom tržištu. U okviru postupka upravljanja rizicima definiran je minimalni zahtijevani kapital neophodan za zaštitu od rizika. Princip računanja spomenutog kapitala se zasniva upravo na VaR metodologiji.

Važan korak u razvoju VaR modela je JPMorganova odluka iz 1994. godine da svoj VaR sustav, RiskMetrics, napravi dostupnim na Internetu. U sljedećim godinama RiskMetrics

[2] Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd

sustav u biti je stekao status gotovo standarda u financijskoj industriji za mjerenje tržišnog rizika. Međutim, u financijskoj literaturi, proučavane su dodatne mjere tržišnog rizika osim VaR. Artzner i dr[3]. su istaknuli neke teorijske nedostatke VaR kao mjere za tržišni rizik. Na primjer to što ne uzima u obzir veličinu gubitaka kad oni premašuju vrijednost VaR. VaR također ne ispunjava svojstvo subaditivnosti, odnosno rizik portfelja u smislu VaR-a može biti veći od zbroja rizika svojih dijelova. Artzner i dr. predložili su alternativnu mjeru rizika definiranu kao očekivana vrijednost gubitaka iznad VaR-a. Ova nova mjera rizika ima bolja teoretska svojstva npr. ispunjava uvjet subaditivnosti te se obično naziva uvjetna rizičnost vrijednosti (Conditional Value at Risk - CVaR).

Pod utjecajem Baselskog odbora VaR je prihvaćen kao glavna mjera tržišnog rizika. Ipak VaR kao mjera rizika je privukao mnoge kritike. Jedan od razloga je da VaR ako se koristi kao kontrolni mehanizam može dovesti do nepovoljnih efekata. Drugi razlozi su da korištenje VaR kao mjere rizika može ne poticati diversifikaciju zbog svoje karakteristike da ne ispunjava uvjet subaditivnosti te razlog da VaR daje procjenu gubitka distribucije do određene točke. Izračun VaR ne daje nikakvu informaciju o gubicima u repu distribucije koji premašuju VaR. Informacije o neočekivanim događajima za tvrtku (mala vjerojatnost, veliki gubici) nisu obuhvaćeni s VaR modelom[4]. Povijest i nedavna globalna financijska previranja su pokazali da takvi događaji predstavljaju pravu opasnost bankovnim sistemima. Iz navedenih razloga CVaR postaje u posljednje vrijeme iznimno popularna metoda za mjerenje tržišnog i kreditnog rizika. U kontekstu kontinuirane distribucije, za danu razinu pouzdanosti i razdoblje držanja t, CVaR se definira kao uvjetno očekivanje gubitaka koji premašuju VaR[5]. Stoga, za razliku od VaR, CVaR pruža dodatne informacije o gubicima u repu distribucije koji premašuju VaR.

[3] Artzner, P., Delbaen, F., Eber, J., & Heath, D. (1999). Coherent Measures of Risk, Mathematical Finance, 9, 203-228.

[4] Rootzen H., Kluppelberg C., (1999): A single number can't hedge against economic catastrophes, Ambio 28 (6), 550-555

[5] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

1.2. Predmet istraživanja

Iz prethodno opisanog problema istraživanja slijedi i predmet istraživanja ovog rada:
Razumijevanje rizičnosti pojedinog sektora djelatnosti bitno je bankama da bi osigurali da ne postoji prevelika koncentracija kreditnog rizika u određenoj djelatnosti. Rizičnost pojedinih sektora bitna je i ulagačima na financijskom tržištu da bi osigurali optimalnu alokaciju sredstava u portfelju. U radu će se primijeniti CVaR metoda na istraživanju rizičnosti pojedinih sektora djelatnosti na primjeru dionica koje kotiraju na Zagrebačkoj burzi te će se usporediti rizičnost pojedinih sektora u kontekstu CVaR za vrijeme financijske krize te u periodu koji prethodi/slijedi krizi.
Dionice iz uzorka bit će razvrstane u 10 osnovnih sektora: Diversificirano, Energetika, Financijske usluge, Građevina, Hotelijerstvo i turizam, Industrija, Poljoprivreda, Prehrana i maloprodaja, Telekomunikacije, Transport. Sektorska podjela je obavljena prema „Global Industry Classification Standard"-u (GICS) koji su razvili investicijska kompanija Morgan Stanley Capital International i bonitetna kuća Standard & Poor's i kojim se koriste na razvijenim tržištima kapitala. Taj standard dijeli kompanije po glavnim djelatnostima na 10 sektora, 24 industrijske grupe, 68 industrija i 154 pod-industrije. Za formiranje osnovnih sektora koristiti će se kombinacija GICS-ovih sektora i industrijskih grupa. Takva podjela je nužna budući Republika Hrvatska nema razvijene sektore informatičkih tehnologija, farmacije i biotehnologije, te materijala (osim papira i cementa), dok su neke industrijske grupe (niža hijerarhijska razina) od strateške važnosti i praktično na razini najviših sektora, primjerice turizam i hotelijerstvo, poljoprivreda, i brodski transport. Kao dodatni sektor uvedena je i kategorija „Diversificirano" gdje se nalaze holding kompanije koje imaju značajne i ravnopravne prihode iz više različitih sektora, te ih je teško svrstati u jedan od standardnih sektora.[6]

[6] Jerončić, M., Aljinović, Z. (2011), Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Ekonomski pregled: mjesečnik Hrvatskog društva ekonomista Zagreb, 62 (2011), 9-10; 583-606.

1.3. Hipoteze istraživanja

Nakon što je opisana problematika i predmet istraživanja moguće je postaviti hipoteze rada.

Temeljna radna hipoteza:

Sektori djelatnosti koji su rizični u periodu financijske krize nisu isti sektori koji su rizični u periodu koji prethodi krizi ili slijedi nakon krize.

Pomoćne hipoteze:

1) CVaR daje dobru procjenu rizičnosti pojedinog sektora
2) CVaR daje preciznije i pouzdanije procjene rizičnosti pojedinog sektora od VaR

1.4. Ciljevi istraživanja

U skladu s prethodno navedenim određeni su temeljni cilj i svrha rada:
Primjenom CVaR metode ispitati utjecaj krize na promjenu rizičnosti pojedinih sektora djelatnosti te istražiti da li su sektori koji su rizični u periodu financijske krize isti sektori koji su rizični i u periodu koji prethodi ili slijedi nakon financijske krize. Uz prethodno navedeno, može se još istaknuti cilj da se ukaže na značajnost vremena u kojem se investira, pomoću usporedbe CVaR u vremenu krize te u vremenu uobičajenih tržišnih uvjeta, ukazat će se na razlike u CVaR-u za isti sektor, na istom tržištu, samo u različito vrijeme.
Ostali ciljevi rada su:

- objasniti vrste rizika u financijskom poslovanju,
- analizirati CVaR mjeru rizika, njene osobine, metode za njeno izračunavanje, kao i metode za procjenu točnosti CVaR modela,
- ukazati na prednost i nedostatke CVaR metode.

Svrha rada je dati uvid u rizičnost pojedinih sektora djelatnosti u različitim ekonomskim okolnostima, odnosno u periodu krize te u periodima koji joj prethode ili slijede. Razumijevanje rizičnosti pojedinog sektora bitno je bankama i investitorima na financijskim tržištima da bi osigurali da ne postoji prevelika koncentracija rizika u određenim sektorima.

1. 5. Metode istraživanja

U skladu s uvodno opisanim problemom i predmetom istraživanja, a kako bi se došlo do postavljenih ciljeva istraživanja, uz proučavanje prikupljene strane i domaće literature, te podataka prikupljenih na internetu, koriste se i različite znanstvene metode koje su primjerene društvenim znanostima. U prvom, teorijskom dijelu rada, koji za cilj ima sistematizirati i konceptualno izložiti teorijske spoznaje o riziku, rizičnoj vrijednosti, koriste se sljedeće metode znanstveno-istraživačkog rada[7]:

Metoda analize - analiza je osnovna znanstvena metoda istraživanja, predstavlja rastavljanje cjeline na dijelove.

Metoda sinteze - sinteza je suprotna analizi, predstavlja spajanje dvaju ili više dijelova u cjelinu.

Induktivna metoda - metoda kojom se na temelju pojedinačnih činjenica dolazi do općeg zaključka.

Deduktivna metoda – njome se iz općih stavova izvode pojedinačni.

Metoda klasifikacije - metoda putem koje se vrši podjela općeg pojma na posebne, koje taj pojam uključuje.

Metoda dokazivanja - koja predstavlja sveobuhvatni misaono-sadržajni postupak kojim se utvrđuje istinitost pojedinih spoznaja, stavova ili teorija.

Metoda deskripcije - koristi se za jednostavno opisivanje ili očitavanje činjenica, procesa i predmeta te potvrđivanje njihovih odnosa i veza.

Komparativna metoda - metoda kojim se uspoređuju iste ili srodne činjenice kako bi se utvrdile njihove sličnosti ili razlike.

Metoda kompilacije - preuzimanje tuđih rezultata znanstveno-istraživačkog rada, odnosno tuđih zapažanja, stavova i zaključaka.

U drugom, empirijskom dijelu rada, prikupljeni su podaci o vrijednostima dionica sa Zagrebačke burze, koji su prikazani tablično i grafički, s ciljem što veće preglednosti i usporedivosti podataka. U ovom dijelu rada koriste se matematičko-statističke metode i modeli. Izračuni matematičkih vrijednosti napravljeni su u Microsoft Excel-u.

[7] Zelenika, R. (2000): Metodologija i tehnike izrade znanstvenog i stručnog djela, četvrto izdanje, Ekonomski fakultet u Rijeci.

1.6. Struktura rada

Rad je koncipiran na način da se sastoji od sedam poglavlja, a u nastavku je prikazan kratak sadržaj svakog poglavlja.

U uvodnom dijelu rada definira se problematika i daje kratak opis predmeta istraživanja, potom slijedi postavljanje hipoteza te se definiraju svrha i ciljevi rada. Navode se i znanstveno – istraživačke metode koje se koriste u radu. Na kraju poglavlja daje se kratak prikaz strukture rada.

U sljedećem, drugom dijelu rada pobliže će se upoznati s rizicima u financijskom poslovanju. Prvo će se definirati rizik i objasniti njegova važnost, zatim će se navesti vrste rizika, i objasniti detaljnije kreditni, tržišni, kamatni, valutni, operativni i rizik likvidnosti.

U trećem dijelu rada se detaljnije objašnjava VaR i CVaR. U početnom dijelu trećeg poglavlja će se definirati VaR, zatim će se nešto reći o povijesti nastanka i razvoja VaR-a, te mogućnostima primjene. Nadalje, izložit će se uloga VaR u Baselskom sporazumu te prednosti i nedostatci primjene VaR-a. Poglavlje završava definicijom CVaR te mogućom primjenom uvjetne rizičnosti vrijednosti (CVaR) kao i njenim prednostima i nedostacima kao mjere rizika.

U četvrtom poglavlju pobliže će se upoznati s tri osnovna modela izračuna CVaR-a: parametarskom metodom, povijesnom metodom i Monte-Carlo simulacijom, te će se navesti prednosti i nedostatci svake od njih.

U petom poglavlju će se izračunavati CVaR na temelju podataka sa Zagrebačke burze; u prvom dijelu poglavlja reći će se nešto o Zagrebačkoj burzi te izdvojiti sektori djelatnosti i odabrane dionice za koje će se računati i uspoređivati CVaR.

U pretposljednjem, šestom poglavlju, usporedit će se rezultati te testirati točnost dobivenih vrijednosti CVaR-a.

U zaključku rada iznijet će se konačna razmatranja, izložiti spoznaje i zaključci stečeni tijekom izrade rada do kojih se došlo istraživanjem, te dokazati ili opovrgnuti hipoteze na kojima se rad temeljio.

2. Osnovni rizici u financijskom poslovanju

2.1. Definicija i značaj rizika u financijskom poslovanju

Rizik je prisutan u svim područjima ljudskog života, ali uobičajeno je da se promatra određena definicija rizika ovisno o području interesa. Oxford English Dictionary definira riječ rizik kao:

„(Izloženost) mogućnosti gubitka, ozljede, ili druge nepovoljne ili nepoželjne okolnosti; prilika ili situacija koja uključuje takvu mogućnost."

Pojam rizika mijenja se i varira ovisno o segmentu ljudskog života i djelatnosti te se kao takav različito definira i vrednuje. Prema internacionalnom standardu ISO 31000:2009 rizik je definiran kao efekt neizvjesnosti na ciljeve. Ova definicija uključuje i pozitivan i negativan utjecaj na ostvarenje ciljeva. S druge strane, s vremenskog aspekta imamo i definiciju u kojoj rizik predstavlja „probleme u budućnosti koji se mogu izbjeći ili ublažiti za razliku od sadašnjih na koje se odmah mora odgovoriti".[8] U informacijskim znanostima faktor rizika se odnosi na vjerojatnost neizvjesnih budućih događaja i definiran je kao „ moguća frekvencija i moguća magnituda budućeg gubitka".[9] Dakle, definiranje rizika u direktnom je odnosu i u ovisnosti o području ljudske djelatnosti.

Suvremena teorija u najširem i najopćenitijem definiranju rizika, nalazi da pojam rizika uvijek sadrži dva osnovna elementa: izloženost i neizvjesnost.

Rizik općenito definiramo kao neizvjesnost budućeg ishoda ili izloženost neizvjesnosti.[10] Čine ga dvije komponente: neizvjesnost i izloženost toj neizvjesnosti. Neizvjesnost je stanje kada ne postoji znanje o tome je li neka pretpostavka istinita ili ne, ili kada postoji nepotpuno poznavanje pretpostavki u vezi s nekom pojavom. Biti izložen neizvjesnosti znači da postoje materijalne posljedice, dok stupanj neizvjesnosti nije isti što i stupanj izloženosti njoj.

U poslovnoj ekonomiji rizik u užem smislu je opasnost gubitka ili štete, a u širem mogućnost drugačijeg ishoda od očekivanog.[11] Ovako shvaćen rizik ima štetne posljedice, pa otuda ekonomski i financijski racionalni sudionici u poslovnim i financijskim transakcijama izražavaju averziju prema riziku i teže njegovom uklanjanju ili minimiziranju.

[8] Technical standard risk Taxonomy (2009), The Open Group, UK, C081, str. 2.
[9] Jones J. (2006) An introduction to Factor analysis of information risk, Risk managemet insight LLC
[10] Cvetinović, M (2008)., Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd
[11] Drljača, M., Bešker M. (2010): Održivi uspjeh i upravljanje rizicima poslovanja, Poslovna politika, Beograd

Rizik još možemo definirati i kao: vjerojatnost nastanka događaja koji će imati negativne posljedice na pojedinca, organizaciju ili društvo u cjelini; nemogućnost predviđanja ishoda budućih događaja s potpunom sigurnošću; koncept koji se koristi kako bi se izrazila vjerojatnost nastupanja određenih događaja i njihovih nepovoljnih učinaka koji mogu imati materijalne posljedice na ciljeve neke organizacije.[12] Rizik je rezultat interakcije intenziteta opasnosti, izloženosti, otpornosti, vjerojatnosti i nastanka ugrožavanja zajedno s posljedicama.[13]

Rizik se pažljivo procjenjuje u bitnim situacijama za organizaciju, koje mogu odrediti tijekove njezina poslovanja i kvalitetu odvijanje njezinih poslovnih procesa, naročito kada se: ukaže nova rizična situacija, promijeni stupanj poznatog rizika i kad nastupi novo shvaćanje rizične situacije.[14]

Rizici mogu biti različiti, a jedna od širih podjela je na poslovne i neposlovne rizike. Poslovni rizici su posljedica faktora poslovnog okruženja, dok su neposlovni rizici vezani za ekonomsko i političko okruženje, pa ih financijske institucije ne mogu kontrolirati. Dakle, u financijskom poslovanju, rizik bi se mogao definirati kao mogućnost da plasirana sredstva neće zaraditi očekivanu stopu prinosa, odnosno da će nastati gubitak u konkretnom poslu.

Očekivani gubici su kolebanja u vrijednosti, koja se mogu predvidjeti na osnovu raspoloživih informacija, dok su neočekivani gubici moguća odstupanja od očekivanih gubitaka i oni su razlog nastajanja rizika.

Na financijskom tržištu postoji potreba za rješavanjem problema optimalnog ulaganja u odabrana dobra, pod određenim rizikom. Moguća ulaganja čine portfelj, pa zapravo treba riješiti problem optimizacije portfelja koji uključuje mjeru rizika ulaganja. Prilikom ulaganja u određeni portfelj nisu poznati podaci o prinosu koji će donijeti taj portfelj, tako da pri svakom ulaganju postoji rizik. Rizik se može procijeniti koristeći različite mjere rizika. Prve ideje za procjenjivanje rizika portfelja potječu od Markowitz-a, koji je mjerio rizik varijancom prinosa. Kasnije su se pojavile i VaR (Value at Risk), CVaR (Conditional Value at Risk) mjere rizika.

[12] Miloš Sprčić, D. (2013): Upravljanje rizicima, Sveučilište u Zagrebu, Zagreb.
[13] Bešker, M. (2006): Izvori ugrožavanja i procjena stanja sigurnosti-rizika-ugroženosti, Oskar, Zagreb
[14] Regester, M., Larkin, J.(1997): Risk issues and crisis managment, Kogan P. Limited, London.

U kontekstu financijske literature, izraz rizik odnosi se na promjenu povezanu s varijabilnošću buduće vrijednosti [15]

Pojam financijskog rizika označava negativna odstupanja od očekivanih rezultata zbog varijabilnosti mogućih ishoda. [16]Financijski rizici se najčešće odnose na moguće gubitke na financijskim tržištima, zbog npr. promjene kamatnih stopa ili valutnih tečajeva.

Mjerenje rizika je značajno evoluiralo tijekom posljednjih tridesetak godina. Razvilo se od jednostavnih indikatora kao što je tržišna vrijednost vrijednosnice, kroz složenije mjere osjetljivosti vrijednosnica na promjene kao što su duration (trajanje) i konveksnost, do suvremene metodologije izračunavanja VaR-a.[17] Svaki novi način mjerenja rizika prvo se je primjenjivao na pojedine vrijednosnice, a onda na cijele portfelje. Potraga za boljim i preciznijim načinima mjerenja rizika nije pri kraju. Svaka nova kriza ili propast financijske institucije otkriva ograničenja i pogreške najmodernijih načina upravljanja rizicima.

[15] Artzner, P., Delbaen, F., Eber, J.M., Heath, D.: „Coherent measures of risk, Math finance, 9 (3), 1999, 203-228

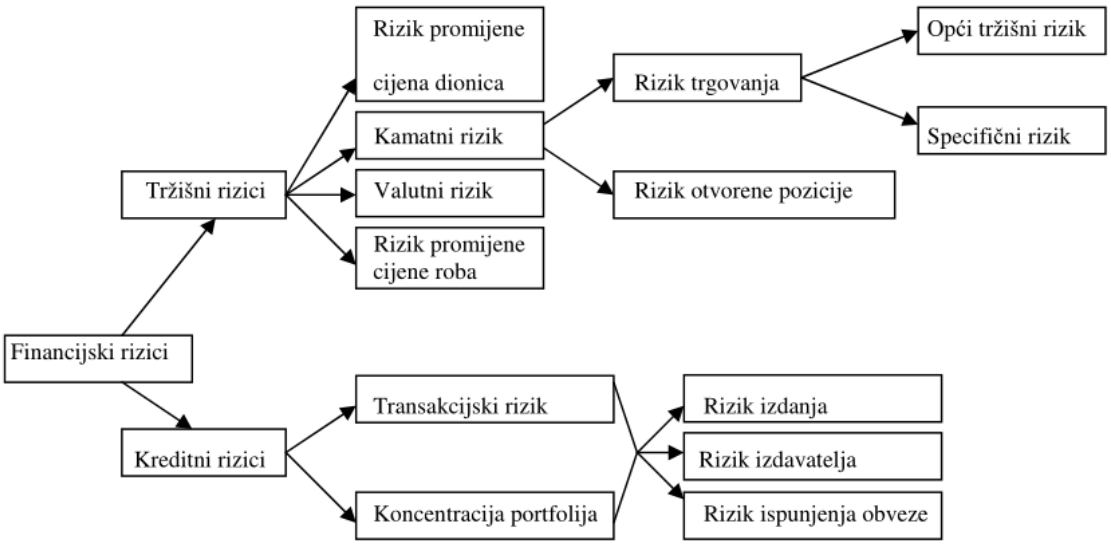
[16] Crouhy, M., Galai, D., Mark, R. (2001): „Risk management, McGraw-Hill Education, New York

[17] Fabozzi, F., Konishi, A. (1995): „The Handbook of Asset/Liability Management: State-of-the-Art Investment Strategies, Risk Controls and Regulatory Requirements“, McGraw-Hill

2.2. Vrste rizika u financijskom poslovanju

Na suvremenim financijskim tržištima financijske institucije izložene su brojnim rizicima. Tržišni rizik, kreditni rizik, valutni rizik, rizik kamatnih stopa, rizik sektora, rizik likvidnosti, svi ti rizici u većem ili manjem obimu postoje u financijskom poslovanju. Zbog raznovrsnosti i složenosti financijskih rizika u modernom poslovanju u stručnoj literaturi se pojavljuje mnoštvo klasifikacija i vrsta financijskih rizika, Jedna od u svijetu šire prihvaćenih podjela financijskih rizika prikazana je na slici br. 1.

Slika 1. Podjela financijskih rizika



Izvor: Crouhy M., Galai D., Mark R. (2001): Risk Managment, McGraw-Hill Education, New York

Među najznačajnije rizike koji se javljaju u poslovanju financijskih institucija spadaju tržišni rizici (rizik promjene kamatne stope, valutni rizik…), kreditni rizik, operativni rizik i rizik likvidnosti. Stoga su navedeni rizici detaljnije obrađeni u nastavku.

2.2.1. Kreditni rizik

Kreditni rizik je vezan uz kvalitetu plasmana banke, odnosno predstavlja rizik da plasmani neće biti vraćeni banci. Banka ne može predvidjeti koji će krediti biti vraćeni, a koji ne, nego daje kredite na određeni rok, ali ponekad krediti koje je banka plasirala klijentu neće biti vraćeni zbog nemogućnosti klijenta.

Mnoga financijska potraživanja koja su izdali pojedinci ili korporacije, a čuva ih financijska institucija, imaju veliku vjerojatnost da će biti vraćeni, tj. da će pružiti fiksnu dobit, ali pritom imaju i znatno manju vjerojatnost da će njihov rezultat biti gubitak glavnice i kamata.

Primjeri takvih financijskih potraživanja su obveznice s fiksnim kuponom te krediti banaka. Kreditni rizik banke ovisi o dvije vrste čimbenika: eksternim (stanje ekonomije, prirodne okolnosti i sl.) i drugo, internim čimbenicima (upravljačka filozofija banke). Menadžment se treba koncentrirati na interne faktore, budući da na eksterne nema direktan utjecaj. Ključni čimbenici kreditnog rizika banke su: obujam kredita (ako on raste, raste i rizik), kreditna politika (provjerava se preko koeficijenta „ratio“, tj. odnosa ukupnih kredita prema ukupnoj aktivi, veći ratio – veći rizik) i kreditni miks (mjeri se odnosom komercijalnih i industrijskih kredita prema ukupnim kreditima, veća koncentracija ovih kredita – veći rizik).

Pozajmljivanje novca drugoj ugovornoj strani uvijek je sa sobom nosilo opasnost da pozajmljena sredstva neće biti vraćena, pa se može reći da je ovaj rizik star koliko i samo bankarstvo. Još tada je prepoznata potreba za upravljanjem ovim rizikom. Naravno složenost mehanizama uz pomoć kojih se tada upravljalo kreditnim rizikom bila je daleko jednostavnija nego što je danas. Ova vrsta rizika je najznačajniji pojedinačni uzrok stečajeva banaka (više od 80% bilance banke odnosi se na ovu vrstu upravljanja rizicima).[18]

Postoje tri osnovne vrste kreditnog rizika[19]:

- Pojedinačni (osobni) ili potrošački rizik
- Korporativni ili rizik poduzeća
- Državni ili rizik zemlje

Postoje različiti izvori nastanka kreditnog rizika, od odobravanja kredita stanovništvu i malim poduzećima, sekjuritiziranih, hipotekarnih kredita, preko trgovine korporativnim ili državnim obveznicama, do trgovine derivatima na financijskim tržištima. Visina kreditnog rizika ovisi o

[18] Greuning H., Bratanović S.B. (2006): Analiza i upravljanje bankovnim rizicima, 2. Izdanje, Mate, Zagreb
[19] Greuning H., Bratanović S.B. (2006): Analiza i upravljanje bankovnim rizicima, 2. Izdanje, Mate, Zagreb

strukturi ugovora između banke i njenih klijenata. Kreditni rizik je moguće diverzificirati, ali teško se može potpuno pokriti (izvršiti headging). Razlog je što najveći dio rizika neizvršenja obveze može biti rezultat sistemskog rizika. S obzirom na konkretan izvor nastanka kreditnog rizika možemo razlikovati tri tipa ovog rizika: rizik naplativosti (default risk), rizik kreditne premije i rizik pogoršanja kreditnog rejtinga.

Rizik naplativosti (default risk) je rizik koji postoji još u trenutku kada je kredit odobren odnosno instrument emitiran, jer već tada svaki klijent/emitent ima neki kreditni rejting, a svakom kreditnom rejtingu je moguće pripisati određenu vjerojatnost defaulta odnosno neizvršenja.

Rizik kreditne premije je rizik da će se kreditna premija promijeniti i utjecati na pogoršanje performansi klijenta/emitenta te potencijalno stvoriti probleme u otplati kredita.

Rizik kreditnog rejtinga je rizik da će doći do pogoršanja kreditnog rejtinga klijenta u periodu kada je kredit aktivan tj. u periodu njegove otplate.

Kreditni rizik je, više od svih ostalih, određen neizvjesnim okolnostima vezanim za poslovanje klijenta. Zato je potrebna kontrola velikog broja parametara poslovanja i klijenta i banke. Banka mora imati predodžbu o rizicima s kojima se klijent susreće u svom poslovanju, polazeći od karaktera njegovog poslovanja i tržišta u kojem posluje. Izloženost kreditnom riziku se u suvremenom bankarskom poslovanju mjeri procjenom očekivanog gubitka po određenoj investiciji na osnovu kvantitativne analize. Pri tome, očekivani gubitak ovisi o tri činitelja:[20]

- Vjerojatnost da suprotna strana neće podmiriti obveze na ugovoreni način i u ugovoreno vrijeme
- Iznos gubitka koji bi se ostvario u slučaju nepoštovanja ugovora od suprotne strane
- Potencijalna izloženost banke neplaćanju na određeni datum u budućnosti

Osim okolnosti koje uvjetuju rizik klijenta, i sama struktura kredita koje banka odobrava uvjetuje stupanj njene izloženosti riziku, a kvaliteta pojedinih kredita utječe na različite razine rizika. S obzirom da je ciljna funkcija banke stvaranje dobiti (profita), kvaliteta aktive će biti jedna od osnova za određivanje stupnja prihvatljivosti rizika, kako ciljna funkcija banke ne bi bila ugrožena.

[20] Basel Committee of Banking Supervision (2004): Settlement risk in foreign exchange transactions: Report prepared for the committee on payment and settlement systems of central banks of group the of ten countries

Kreditni rizik može se promatrati i u bankarskoj knjizi i u knjizi trgovanja. U bankarskoj knjizi je nastanak kreditnog rizika jedna od ključnih opasnosti po bankarski portfelj, jer ukoliko dođe do nemogućnosti naplate potraživanja od nekoliko ključnih klijenata banka može doći u problem nesolventnosti. Ipak, kreditni rizik u ovom slučaju ne odnosi se samo na nemogućnost naplate potraživanja uslijed bankrota dužnika već i na nekoliko dodatnih događaja kao što su kašnjenje u naplati potraživanja i restrukturiranje kredita uslijed pogoršanja kreditne sposobnosti dužnika. Prvi razlog nije toliko opasan jer se većina problema ove prirode rješava na adekvatan način. Mnogo veća opasnost leži u restrukturiranju kredita jer taj čin jasno oslikava pad kreditnog rejtinga i samim tim opasnost od nemogućnosti povrata uloženih sredstava za banku. Kreditni rizik se kod instrumenata u knjizi trgovanja ocjenjuje kroz cijene vrijednosnih papira kojima se trguje na tržištu kapitala. Indirektno se rizik ocjenjuje i kroz kreditni spread u zahtijevanom prinosu pojedinih instrumenata, koji između ostalih rizika ocrtava i kreditni rizik. Ključna razlika u odnosu na vrstu rizika iz bankarske knjige jest u tome što je moguće prodati vrijednosni papir i prije roka dospijeća na sekundarnom tržištu kapitala i u tom smislu ograničiti potencijalni gubitak. Ovdje se kao potencijalni rizik javlja (ne)likvidnost tržišta.

S obzirom da je banka od depozitara primila sredstva, ona ima obvezu ta sredstva i vratiti. Budući da loši plasmani smanjuju dobit banke, dioničari traže od uprave i menadžmenta uspostavu mehanizama kojima bi se osigurao povrat plasmana banke. Sukladno tome, banka nastoji osigurati povrat sljedećim načinima:

1. Statističkim praćenjem i modeliranjem karakteristika pojedinih klijenata
2. Diferencijacijom proizvoda
3. Elementima osiguranja pojedinih plasmana

Kako bi banka bila što sigurnija u vraćanje kredita, poseže za rigoroznom politikom odabira klijenata i uvjeta koji su potrebni da bi odobrila kredit. Banka u svojem kreditnom poslovanju nastoji subjektivnu distribuciju vjerojatnosti povrata kredita što više približiti objektivnoj. Kako bi usuglasila te dvije distribucije oslanja se na statistiku i elemente osiguranja kredita.

Banka traži veliku količinu podataka od klijenata iz sljedeća dva razloga: upoznavanje individualnog klijenta te usporedba klijenta sa sličnom skupinom klijenata. Ne temelju statističkih kategorija banka nastoji procijeniti kolika je vjerojatnost vraćanja kredita.

Sljedeći način na koji banka nastoji osigurati povrat je diferencijacijom proizvoda. Banka nastoji putem individualnih proizvoda osigurati što veći povrat. Svaki kredit izravno ovisi o bonitetu klijenta. Isto tako, procedure za različite vrste kredita se uvelike razlikuju. Dok su za neke procesi odobravanja vrlo brzi, za druge vrste kredita trebaju se proći dugotrajne procedure.

Ako banka procjeni da je rizičan kredit, ona će nametnuti i veće mjere osiguranja. Koga smatra rizičnijim klijentom, teže će mu odobriti kredit. Banka koristeći elemente osiguranja nastoji smanjiti kreditni rizik kada kreditira klijente te na taj način implicitno jamči deponentima vraćanje sredstava. U slučaju nevraćanja kredita, banka će upotrijebiti elemente osiguranja plasmana te naplatiti svoje potraživanje.

2.2.1.1. Rizik koncentracije

Nedovoljno upravljanje rizikom koncentracije zna često dovesti do velikih problema u poslovanju banke.

Banka treba agregirati sve slične direktne i indirektne izloženosti, bez obzira na to gdje je izloženost uočena. Rizik koncentracije predstavlja bilo koji vid izlaganja prema jednoj ili grupi sličnih izloženosti (npr. prema istom dužniku ili pak različitim pravnim subjektima u okviru jednog geografskog područja, djelatnosti i sl.) sa potencijalom da proizvodi:[21]

(i) gubitke u poslovanju (u odnosu na zaradu banke, kapital, ukupnu aktivu ili ukupni nivo rizika) i ugrozi banku ili njenu kreditnu sposobnost ili mogućnost da održi svoj „core biznis“ ili (ii) značajne promjene u svom profilu rizika.

Kod rizika koncentracije bitno je analizirati izloženost banke na konsolidiranoj osnovi, što znači uključiti upravljanje koncentracijom i na nivou filijale banke, s obzirom da se može pojaviti značajna izloženost koja može predstavljati opasnost za opstanak i održivost filijale, a samim time i banke.

Rizik koncentracije treba promatrati u kontekstu jednog ili grupe blisko povezanih uzročnika rizika, koji mogu imati različite utjecaje na banku. Ove koncentracije trebaju biti integrirane prilikom procjene ukupne izloženosti banke riziku.

[21] Mahmutović H., Ćesić A., Mahmutović A., „Efikasno upravljanje rizicima financijskih institucija uz primjenu II Baselskog sporazuma“, Tranzicija, 12 (2011), 25-26 ; 75-83.

Banka treba razmotriti koncentracije koje se zasnivaju na zajedničkim ili korelacijskim faktorima rizika, koji odražavaju suptilnije ili specifičnije faktore koncentracije od tradicionalnih, kao što su korelacije između tržišnog, kreditnog rizika i rizika likvidnosti.
Dinamizacija prilika na financijskim tržištima utemeljena na produbljivanju financijskog posredovanja utjecala je svakako na povećanu izloženost banaka zajedničkom setu proizvoda, rizičnih faktora i sl. Ovo je stvorilo nove izazove za agregiranje i koncentraciju upravljanja rizicima.

Tipične situacije u kojima može nastati koncentracija rizika obuhvaća slijedeće[22]:

- izloženost prema drugom pravnom subjektu, dužniku ili grupi povezanih osoba ili dužnika,
- izloženost u okviru industrijskog ili ekonomskog sektora, uključujući izloženost prema reguliranim i nereguliranim financijskim institucijama kao što su hedge fondovi i private equity fondovi;
- izloženost u okviru jedne geografske regije na uštrb drugih regija,
- izloženost koja nastaje na osnovi upotrebe instrumenata za umanjenje kreditnog rizika, uključujući slične vrste kolaterala,
- izloženost kod trgovanja vrijednosnim papirima / tržišni rizik;
- izloženost prema drugom pravnom subjektu (npr. hedge fondovi i ugovorne strane kod hedge fondova),
- izloženost prema jednom izvoru financiranja,
- izloženost prema financijskoj imovini koja se drži u knjigama banke ili knjizi trgovanja, kao što su krediti, derivati i strukturirani financijski proizvodi;
- izloženost prema vanbilančnim stavkama, uključujući garancije, prema linijama za podršku likvidnosti banke i drugim obavezama.

Imajući u vidu brojnost spomenutih slučajeva očekuje se da banka posjeduje efikasne unutarnje politike, sisteme i kontrole identifikacije, mjerenja, praćenja, upravljanja, i umanjenja rizika koncentracije. Osim toga, ne samo da banka treba uzeti u obzir normalne tržišne uvjete, nego i potencijalno povećanje koncentracije u stresnim tržišnim okolnostima, ekonomskim poremećajima i periodima opće tržišne nelikvidnosti. Pored toga, banka treba

[22] Mahmutović H., Ćesić A., Mahmutović A., „Efikasno upravljanje rizicima financijskih institucija uz primjenu II Baselskog sporazuma“, Tranzicija, 12 (2011), 25-26 ; 75-83.

procijeniti scenarije s obzirom na moguću koncentraciju, koja proizlazi iz ugovora i uvjetnih obaveza.

Scenariji trebaju kombinirati potencijalnu izloženost banke zajedno sa gubitkom tržišta i likvidnosti te značajnim padom ili smanjenjem vrijednosti imovine.

2.2.2. Tržišni rizik

Tržišni rizik jest rizik da uslijed promjena na tržištu dođe do gubitka na vrijednosti investicije. Među tržišne rizike ubrajaju se: rizik promjene cijena vrijednosnih papira, kamatni rizik, valutni rizik te rizik promjene cijena roba. Doduše, neki autori pod pojmom tržišnog rizika smatraju samo rizik promjene cijena vrijednosnih papira, dok kamatni i valutni rizik zbog njihove važnosti tretiraju zasebno.[23]

Tržišno orijentiranim ekonomijama tržišna vrijednost aktive, pasive, i neto vrijednost banke i drugih financijskih institucija konstantno su u nestabilnom stanju stvarajući tržišni rizik. Tržišni rizik je rizik koji neka banka može snositi uslijed nepovoljnih kretanja tržišnih cijena. Izloženost takvom riziku može nastati uslijed bančinog poduzimanja namjernih špekulativnih pozicija ili može proizaći iz bančine aktivnosti trgovanja devizama.[24] Tržišni rizici proizlaze iz nestabilnosti pozicija u četiri osnovna ekonomska tržišta: kamatno osjetljivom tržištu dužničkih vrijednosnih papira, tržištu dionica, valuta i roba. Nestalnost svakog od navedenih tržišta izlaže banku kolebanjima cijena ili vrijednosti financijskih instrumenta. U razvijenom tržišnom okruženju, banke se sa evidentnom likvidnošću mogu normalno zaštititi od kolebljivosti tržišta. Rezultirajuća neto efektivna otvorena pozicija određuje iznos portfelja koji ostaje izložen tržišnom riziku.

Kapital se mora zadržati kao zaštita za potencijalne gubitke uslijed tržišnog rizika. Takav kapital naziva se dodatni kapital II.

Najvažniji indikatori tržišnog rizika u upravljanju bankarskim i financijskim institucijama su [25]:

- Odnos knjigovodstvene vrijednosti aktive i procjene tržišne vrijednosti iste aktive,

[23] Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd.
[24] Greuning H., Bratanović S. (2006): Analiza i upravljanje bankarskim rizicima, 2. Izdanje, Mate, Zagreb
[25] Greuning H., Bratanović S. (2006): Analiza i upravljanje bankarskim rizicima, 2. Izdanje, Mate, Zagreb

- Odnos knjigovodstvene vrijednosti dioničkog kapitala i procjene tržišne vrijednosti tog istog dioničkog kapitala,
- Tržišna vrijednost obveznica i druga fiksna prihodovna aktiva u relativnom odnosu prema njihovoj vrijednosti, zabilježena u knjigovodstvu banaka ili drugih financijskih institucija,
- Tržišna vrijednost obične i prioritetne dionice po jedinici, koja odražava percepciju investitora o izloženosti riziku banke ili druge financijske institucije, kao i potencijal zarade.

Tržišni rizik rezultira iz promjene cijena dionica, robe, kamatnih stopa i valuta. Stoga njegovi najvažniji dijelovi su rizik vlasničke pozicije, robni, kamatni i valutni rizik. Svaki sastavni dio rizika uključuje opći tržišni rizik i specifični rizik koji nastaje uslijed specifične strukture portfelja neke banke. Osim standardnih instrumenata, tržišni rizik se odnosi i na derivativne instrumente, kao što su opcije, dionički derivati ili derivati vezani za valutu i kamatne stope. Uslijed globalizacije i deregulacije tržišta, utjecaj ovih rizika na novčane tokove i vrijednost poduzeća je značajan, stoga poduzeća sve više pažnje posvećuju njihovom upravljanju.
Tržišni rizik se ne može eliminirati diversifikacijom, jer prema teoriji diversifikacije preostaje i nakon ekstenzivne diversifikacije. No, pored te činjenice, postoje i drugi razlozi analize ovog rizika, od kojih su najznačajniji[26]:
1. Sekuritizacija (izdavanje vrijednosnih papira osiguranih aktivom) - koja je u velikom broju slučajeva popraćena izdavanjem derivativnih instrumenata. Derivati su izloženi većem tržišnom riziku, pa posredno dovode i do intenzivnijeg proučavanja tih kretanja.

2. Učinkovitost - koja je postala važan element ocjenjivanja uspješnosti i poslovanja portfelj menadžmenta. No, pored rezultata valja ispitati i rizike koje menadžeri preuzimaju u poslovanju.

[26] Riskmetrics-Tehnical document, (1996); J.P. Morgan/Reuters, New York, str. 25

2.2.2.1. Mjerenje tržišnog rizika

Budući je mjerenje tržišnih rizika veliko i široko područje, razvile su se i mnogobrojne metode njegovog mjerenja i upravljanja njime. Pet najpoznatijih i najrasprostranjenijih metoda su[27]:

Analiza osjetljivosti

Analiza osjetljivosti jest promatranje promjene vrijednosti portfelja (P) ukoliko dođe do male promjene određenog faktora rizika (f). Faktori rizika su tržišne promjene iz kojih se mogu dobiti vrijednosti svih vrijednosnica na tržištu; a glavni su: valutni tečajevi, kamatne stope, tržišni indeksi, cijene roba, volatilnost, te forward cijene svakog od ovih faktora.

Osjetljivost se može mjeriti relativnom promjenom vrijednosti portfelja (P) prilikom male promjene faktora rizika (ε), podijeljeno s promjenom u faktoru rizika, tako da vrijedi:

$$Osjetljivost = \frac{P\ (f + \varepsilon) - \ P(f)}{\varepsilon} \tag{2.1}$$

Ukoliko su promjene u faktorima rizika velike, kao u financijskim krizama, linearna mjera osjetljivosti ne daje zadovoljavajuće rezultate i potrebno ju je izbjegavati.

Testiranje ekstremnih događaja

Ovim načinom mjerenja tržišnog rizika vrši se ocjena potencijalnih ekonomskih gubitaka na tržištu koje se ne ponaša normalno.

Pri testiranju ekstremnih događaja simuliraju se velike promjene faktora rizika, te se pri svakoj promjeni faktora rizika vrši potpuno vrednovanje portfelja i evidentiranje procijenjenih gubitaka. Pri testiranju važno je utvrditi koji faktori se individualno mijenjaju, a koji se mijenjaju u grupama, kako bi se dobili što realniji rezultati. Testiranje ekstremnih događaja, u kombinaciji s VaR-om, koriste mnoge banke. Na taj se način stvara portfelj koji je dovoljno diversificiran i koji će omogućiti bankama prihod, kako u situacijama normalnih tržišnih promjena, tako i u situacijama kada su promjene ekstremne.

[27] Marrison, C. (2002): The Fundamentals of Risk measurement, McGraw-Hill Education, New York.

Kao neke od nedostataka ovog pristupa moglo bi se navesti: testovi ne pokazuju gdje je najveći problem za financijsku instituciju, smjer i jačina promjena rizičnih faktora nisu nužno vezani uz vjerojatnost nastanka tih događaja te u konačnici, testovi se zasnivaju na pretpostavci da je korelacija među faktorima rizika nula ili jedan, što može iskriviti sliku stvarnog rizika.

Testiranje scenarija

Testiranje scenarija vrlo je slično testiranju ekstremnih događaja budući oba pristupa koriste promjene faktora rizika, a zatim ocjenjuju promjene vrijednosti promatranog portfelja. No, za razliku od testiranja ekstremnih događaja, pri stvaranju scenarija se koriste subjektivna mišljenja kako bi se testirao skup najgorih scenarija.

Za izradu scenarija najčešće se koriste povijesni događaji, te se postavlja pitanje što bi se danas dogodilo da se ti događaji ponove.

Neka od ograničenja ovog pristupa su: testiranje je zahtjevno te se može testirati samo određen broj scenarija, promjene se subjektivno određuju, a moguć je i sukob interesa jer osoba koja trguje je ista osoba koja sudjeluje u testiranju scenarija.

CAPM model

Capital Asset Pricing Model (CAPM) se koristi u financijskom poslovanju za određivanje odgovarajuće stope prinosa. U modelu se koriste očekivani prinos tržišta, beta (β), te očekivani prinos teoretski bezrizičnog sredstva.

CAPM se drži Markowitzeve suvremene teorije portfelja i polazi od pretpostavke da je očekivani prinos određene vrijednosnice (i), E(r_i) funkcija sljedećih stavki: bezrizičnog prinosa (r_f), očekivanog prinosa na tržištu E(R_m) i korelacije između vrijednosnog papira i tržišta, što je prikazano u sljedećoj formuli:

$$E(R_i) = r_f + \beta_i \left(E(R_m) - r_f\right) \tag{2.2}$$

$$\beta_i = \frac{Cov_{i,m}}{\sigma_m^2} = \frac{\rho_{i,m}\sigma_i}{\sigma_m} \tag{2.3}$$

Gdje je:

β_i– osjetljivost prinosa vrijednosnice na prinos tržišta

$Cov_{i,m}$- kovarijanca vrijednosnice i tržišta

σ_m^2 - varijanca tržišta

$\rho_{i,m}$– koeficijent korelacije prinosa vrijednosnice i tržišta

σ_i – standardna devijacija vrijednosnice

σ_m– standardna devijacija tržišta

Tržište ima beta koeficijent 1, vrijednosnice koje više osciliraju od tržišta vrijednost veću od 1, a one koje manje osciliraju vrijednost manju od 1.

Uzmimo za primjer vrijednosnicu koja ima beta koeficijent 2, što znači da je dva puta rizičnija od tržišta, dakle ako tržište padne za 5%, ta vrijednosnica će pasti 10%. Isto tako, u slučaju rasta, rasti će dva puta brže. Moguć je i slučaj da je beta koeficijent negativan, tada se vrijednosnica kreće u suprotnom smjeru od tržišta.

Rizičnost vrijednosti (VaR)

VaR je trenutno najpopularnija tehnika mjerenja rizika. Kreirana je da bi mjerila i upravljala rizikom čitave financijske organizacije. Bazelski odbor za superviziju banaka je u Bazel II standardima VaR postavio kao ključni faktor pri upravljanju rizikom, te je postala industrijski standard za mjerenje tržišnih rizika.

Uvjetna rizičnost vrijednosti (CVaR)

CVaR je mjera rizika koja nadilazi nedostatke VaR-a, a čuva njegova dobra svojstva. Uvjetna rizičnost vrijednosti nekog portfelja je očekivani prinos, prinosa manjih od rizičnosti vrijednosti. Ako VaR i CVaR definiramo preko funkcije gubitka, mogli bismo reći da je CVaR prosječna vrijednost gubitka većeg od VaR.

2.2.3. Kamatni rizik

Kamatni rizik jedan je od najvažnijih financijskih (tržišnih) rizika za banku. On predstavlja rizik da tržišna vrijednost portfelja padne ukoliko dođe do promjene kamatnih stopa. Ukoliko se kamatne stope promijene to će imati utjecaj na prihode banke zbog promjena neto kamatnih prihoda, kamatno osjetljive aktive i operativnih troškova.

Izloženost banaka ovoj vrsti rizika proizlazi iz toga što većina njihovih bilančnih stavki generira prihode i troškove koji se usklađuju sa kamatnim stopama. Kamatni rizik predstavlja osjetljivost kapitala i prihoda na promjene u kamatnim stopama. Npr. banka koja ima zaključen ugovor o kreditu sa klijentom po varijabilnoj kamatnoj stopi izložena je riziku da zabilježi pad prihoda ako nastupi pad tržišta kamatnih stopa. Suprotno tome, korisnik kredita dolazi u nepovoljnu poziciju, odnosno ima veće troškove, ukoliko dođe do skoka kamatnih stopa na tržištu. Osnovna mjera osiguranja od ovakve vrste rizika je utvrđivanje koeficijenta koji pokazuje odnos između stavki aktive i pasive koje su osjetljive na promjene kamatnih stopa. On predstavlja spremnost banke da prihvati rizik u pogledu predviđanja budućeg kretanja kamatnih stopa na tržištu.

Kada na tržištu dođe do promjena u kamatnim stopama, izvor prihoda banaka i njihovih konkurenata (posebno prihodi od kamata po zajmovima i vrijednosnim papirima) kao i najvažniji izvori troškova (troškovi kamata po nedepozitima i drugim zaduživanjima) također moraju pretrpjeti promjenu. Promjenjive tržišne kamatne stope također mijenjaju tržišnu vrijednost aktive i pasive i time mijenjaju neto vrijednost financijske institucije, tj. vrijednost investicija vlasnika kompanije. Promjenjive tržišne kamatne stope utječu i na bilancu stanja i račun dobiti i gubitka i drugih financijskih institucija.

Glavni oblici rizika kamatnih stopa kojima su banke izložene su:[28]

Rizik ročne neusklađenosti

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 knjige banke.

[28] Živko, I. (2006): Kamatni rizik u bankarstvu – izvori i učinci, Ekonomski fakultet, Sveučilište u Mostaru

Ako banka financira portfelj dugoročnih kredita kratkoročnim depozitima, rast kamatnih stopa će uzrokovati pad zarade. Budući banka deponentima plaća više kamate, što uzrokuje rast troškova, a pritom zbog većih kamatnih stopa se umanjuje vrijednost dugoročnih kredita.

Rizik krivulje prihoda

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. Kamatne stope formiraju se na tržištu, a krivulja prihoda je obično pozitivne ili uzlazna, odnosno normalna.

Temeljni rizik

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

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 nju iskoristiti. Na taj način banke mogu više izgubiti nego li su uprihodile od vlasnika opcije prilikom prodaje.

Cilj upravljanja kamatnim rizikom je održavanje izloženosti po kamatnim stopama unutar dopuštenih okvira. Visoke kamatne stope dovode do smanjivanja cijene dionica. One stimuliraju investitore da slobodna novčana sredstva preusmjeravaju u bankarski sistem što dovodi do smanjene potražnje na tržištu dionica i pada njihove cijene. Obrnut proces se dešava u slučaju pada kamatnih stopa. Također niske kamatne stope, odnosno jeftin novac, stvaraju slobodna sredstva za nastup špekulanata na tržištu kapitala što dovodi do rasta

cijena dionica.[29] U suprotnom oskudica novčanih sredstava generiranih iz bankarskog sektora smanjuje špekulativnu potražnju na burzi što dovodi do pada cijena dionica. Također visoke kamatne stope predstavljaju problem poduzećima koji se financiraju kreditima. Zbog toga nemaju dovoljno sredstava za ulaganje i povećavanje vrijednosti poduzeća, a samim time i cijene njenih dionica.

Rizik kamatne stope nastaje uslijed promjena u razini kamatne stope na tržištu i on je uglavnom nediverzificirani rizik budući razina svih kamatnih stopa teži da se mijenja zajedno i utječe na vrijednost svih vrijednosnih papira istovremeno.

Kamatne stope za svaki pojedinačni zajam ili vrijednosni papir određuje financijsko tržište na kojem davatelji sredstava zajma (kredita) dolaze u kontakt s onima kojima su ta sredstva potrebna. Tako kamatne stope (cijena kredita) imaju tendenciju da dosegnu razinu na kojoj dolazi do izjednačavanja iznosa sredstava kredita koji se traže i iznosa sredstava koja su na raspolaganju.[30]

Bankari pokušavaju predvidjeti buduća kretanja na tržištu kamatnih stopa radi uklanjanja kamatnog rizika. Međutim činjenica da se kamatne stope formiraju na osnovu interakcija tisuće zajmodavaca i zajmoprimaca čini predviđanje preciznih kamatnih stopa gotovo nemogućim. Dakle bankari moraju prihvatiti kamatne stope kao takve i na osnovu toga praviti svoje planove.

2.2.4. Valutni rizik

Valutni rizik predstavlja izloženost banke promjenama valutnih tečajeva, tj. mogućnost da promjena tečajeva prouzroči gubitak banci. Nastaje zbog valutne neusklađenosti aktive i pasive.[31]

Šire promatrano, valutni rizik mogao bi se definirati i kao rizik od promjena u imovini, prihodima i konkurentskoj poziciji banke zbog oscilacija u visinama deviznih tečajeva.[32]

Banka je izložena valutnom riziku u situaciji kada ima pozicije u aktivi i pasivi koje su u različitim valutama.

[29] Jazić V. (2008): Rizici u bankarskom poslovanju, Stubovi kulture, Beograd
[30] Rose S.P., Hudgins S.C. (2005): Bankarski menadžment i finansijske usluge, Data status, Beograd
[31] Benazić, M. (2010): Izloženost hrvatskih banaka valutnom riziku, Ekonomski fakultet u Zagrebu, Zagreb
[32] Živković, A., Ristić, Ž. (2000): Upravljanje financijskim i deviznim poslovanjem, Ekonomski fakultet, Beograd

Banka 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.[33]

Tri su osnovne vrste izloženosti banaka valutnom riziku:

Transakcijska izloženost valutnom riziku

Nastaje kada prodajna cijena i troškovi nisu u istoj valuti, zbog promjena deviznog tečaja između vremena utvrđivanja cijene i naplata usluga, tj. on podrazumijeva vremensku razliku između preuzimanja obveza i njihovog podmirenja. Rizik je u svakom deviznom plaćanju ili naplati, te uključuje devizno potraživanje ili dugovanje za neki posao ili ugovor o namjeri u nekom deviznom poslu. Uključuje i planirane, ali neugovorene tijekove deviznih sredstava, kada se garantira cijena proizvoda kroz duže vrijeme, a rizik nastaje ukoliko bi se ugovor potpisao.

Obračunska izloženost valutnom riziku

Nastaje u situaciji kada poduzeća imaju svoje organizacijske dijelove u inozemstvu, manifestira se prilikom iskazivanja poslovanja podružnica u sklopu i u valuti matičnog poduzeća. Također, nastaje i u situacijama kada poduzeća dio poslovanja vode u domaćoj a dio u stranoj valuti, a na kraju mjeseca poslovanje prikazuju u domaćoj valuti.[34]

Ekonomska izloženost valutnom riziku ili buduća izloženost

Nastaje kada, kao posljedica promjena vrijednosti intervalutnih tečajeva i domaće valute, dolazi do promjena vrijednosti budućih prihoda, troškova i konkurentnosti subjekta.

Ekonomska izloženost je najznačajnija izloženost valutnom riziku budući da ju je najteže otkriti i spriječiti. Sastoji se od operativne izloženosti (obujma u kojem fluktuacije valute može promijeniti buduće novčane tijekove tvrtke) i transakcijske izloženosti.

Jednostavnije rečeno, ekonomska izloženost je rizik od promjene vrijednosti tvrtke uslijed promjene valutnih tečajeva.

[33] Ivaniš, M. (2012): Rizici u bankarskom poslovanju, Pravno-Ekonomski pogledi, br.3, Beograd, str. 9.
[34] Jurman, A. (2001): Valutni rizik u poslovnim bankama, Zbornik radova Ekonomskog fakulteta u Rijeci, Časopis za ekonomsku teoriju i praksu, volumen 19, svezak 2, 153-168

2.2.5. Operativni rizik

Prema Bazel II definiciji operativni rizik je rizik gubitka koji je rezultat neadekvatnih ili pogrešnih internih procesa, ljudi, sustava ili vanjskog događaja.

Iako postoji od samog početka bankarskog poslovanja, operativnom riziku se nije oduvijek pridavala velika pažnja. Tek s pojavom suvremenog načina poslovanja (automatizacija poslovanja, e-bankarstvo, novi bankarski proizvodi, globalizacija bankarske industrije) počeo se ozbiljnije izučavati.[35]

Operativni rizici nastaju kao posljedica[36]:

1. Prijevare (pogrešno izvještavanje, krađe zaposlenih itd.)
2. Radnih navika i sigurnosti na radnom mjestu (pravo zaposlenika na odštetu, povreda prava zaposlenika i opća odgovornost)
3. Postupaka vezanih za klijente, proizvode i poslovnu aktivnost (zloupotreba informacija, pranje novca, šteta na materijalnoj imovini)
4. Prekida poslovanja i grešaka unutar sistema (hardver, softver i telekomunikacijski problemi)
5. Upravljanja procesima (ulazne greške, nepotpuna dokumentacija itd.)

Među mogućim alatima za utvrđivanje i procjenjivanje operativnog rizika su:[37]

1. Samoprocjenjivanje ili procjenjivanje rizika – banka procjenjuje svoje aktivnosti i operacije s obzirom na katalog potencijalnih osjetljivosti na operativni rizik. Često se prilikom ovog procesa utvrđuju jake i slabe strane okruženja glede operativnog rizika.
2. Razvrstavanje rizika – različite poslovne jedinice, organizacijske funkcije ili poslovni tokovi se razvrstavaju prema vrsti rizika. Može otkriti slabosti i pomoći pri utvrđivanju prioriteta.
3. Pokazatelji rizika – statistički ili metrički podatci koji mogu dati uvid u rizičnu poziciju banke. Ovi se pokazatelji (npr. broj propalih transakcija, promet po zaposleniku, učestalost pogrešaka itd.) redovno kontroliraju kako bi banke uvidjele promjene vezane uz rizik.
4. Mjerenje – neke banke su počele kvantificirati svoju izloženost operativnom riziku.

[35] Šarlija, N. (2008): Kreditna analiza, Ekonomski fakultet u Osijeku, Osijek, str. 82-86.
[36] Bazelski odbor za superviziju banaka, (2003): Dobre prakse za upravljanje i nadzor nad operativnim rizikom.
[37] Bazelski odbor za superviziju banaka (2003): Dobre prakse za upravljanje i nadzor nad operativnim rizikom.

Povijesni podatci o gubitku mogu dati značajne informacije za procjenu izloženosti i razvijanje politike za smanjivanje operativnog rizika. Isto tako banke uspoređuju interne podatke o gubitcima s eksternim.

Operativnim rizikom bankama je teško upravljati budući da ne postoji dugogodišnja praksa upravljanja njime.

2.2.6. Rizik likvidnosti

Likvidnost predstavlja sposobnost banke da u svakom trenutku raspolaže adekvatnim iznosom sredstava neophodnim za financiranje rasta aktive i pravovremeno pokriće svih obveza koje dospijevaju. Likvidnost je bankama potrebna za kompenzaciju očekivanih i neočekivanih nestabilnosti u bilancama i za osiguranje sredstava za rast. Preko likvidnosti se održava povjerenje depozitara, čime se izbjegava „domino efekt“ što omogućuje opstanak banke u neizvjesnim tržišnim uvjetima.[38]

Bazelski odbor za superviziju banaka u svom radu o nadgledanju likvidnosti navodi da je likvidnost, ili sposobnost da se financiraju povećanja u aktivi i podmiruju obaveze kada dođu na naplatu, bitna za održavanje na životu bilo koje financijske situacije. Štoviše, važnost likvidnosti nadmašuje pojedinačnu financijsku instituciju, budući da manjak likvidnosti u jednoj instituciji može imati posljedice za cijeli bankarski sustav određene zemlje.[39]

Rizik likvidnosti je vjerojatnost da financijska institucija raspoloživim novčanim sredstvima neće biti u stanju podmiriti obveze prema vjerovnicima (pasiva), kao ni obveze po odobrenim kreditima, izdanim jamstvima, garancijama, itd., (aktiva).[40]

Vlasnici depozita mogu prije dogovorenog roka povući svoja sredstva, dok banka nema mogućnost da zatraži prijevremeno vraćanje kredita od zajmoprimca. Iz tog razloga banka je podložna napadu na banku, ili „eng. Run on the bank“.[41]

Kada veliki broj financijskih institucija dođe u sličnu situaciju, trošak kupljenih ili posuđenih sredstava postaje veći i ponuda takvih sredstava postaje ograničena. Navedeno rezultira

[38] Jović, S. (1990): Bankarstvo, Naučna knjiga, Beograd
[39] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Ekonomski fakultet u Ljubljani
[40] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Ekonomski fakultet u Ljubljani, Ljubljana.
[41] Gregurek, M., Vidaković, N. (2011): Bankarsko poslovanje, RRIF, Zagreb

ozbiljnim rizikom likvidnosti, budući da financijska institucija mora prodati dio svoje manje likvidne imovine, a to će morati obaviti po nižoj cijeni nego da je imala dovoljno vremena za pregovaranje, budući joj novac treba odmah.[42]

Transakcije banke, gledane iz perspektive likvidnosti, mogu se podijeliti na tri vrste:[43]

1. Transakcije u kojima banka prima svježa sredstva
2. Transakcije u kojima banka gubi sredstva
3. Neutralne transakcije

Neutralne transakcije nemaju utjecaj na likvidnost banke i odnose se na protok na računima banke, kada i nalogodavac i nalogoprimatelj imaju račune kod iste banke.
Transakcije koje uzrokuju priljeve i odljeve sredstava su značajnije za banku. Da bi banka pravilno upravljala likvidnošću ona svaki dan mora zadovoljiti uvjet da je ulaz sredstava veći od izlaza. Ukoliko banka nije u stanju zadovoljiti navedeni uvjet, mora pronaći dodatna sredstva iz kratkoročnih sekundarnih izvora.

Kako bi smanjili rizik likvidnosti banka se koristi različitim tehnikama koje se mogu podijeliti na:[44]
1. Jasno određenu kreditnu politiku – prvi i najbolji način zaštite od nelikvidnosti je da banka ima jasno određenu politiku kreditiranja i prikupljanja depozita (npr. male banke ne daju stambene kredite i općenito kredite na dugi rok).
2. Zalihe likvidnosti u aktivi – drugi način zaštite je da banka ima zalihe likvidnosti u aktivi i dugoročne sekundarne izvore financiranja u pasivi (npr. banka će dio prikupljenih sredstava preusmjeriti u kratkoročne visoko likvidne plasmane kao što su blagajnički zapisi ili depoziti kod drugih banaka). Uz propisane obvezne pričuve banka bi trebala izdvojiti i dodatna sredstva kako bi stvorila zalihe likvidnosti, koje bi onda mogla iskoristiti kada se za to ukaže potreba.

[42] Saunders, A., Millon Cornett, M. (2010): Financijska tržišta i institucije, Drugo izdanje, Masmedia, Zagreb.
[43] Gregurek, M., Vidaković, N. (2011): Bankarsko poslovanje, RRIF, Zagreb
[44] Gregurek, M., Vidaković, N. (2011): Bankarsko poslovanje, RRIF, Zagreb

Isto tako banka može i pokušati uskladiti ročnu strukturu na način da nađe sekundarne izvore sredstava s jednakom ročnošću. Dva su načina na koji banka dolazi do sekundarnih izvora sredstava; izdavanjem vlastitih dužničkih papira, te dizanjem kredita od većih banaka.

3. Kratkoročni izvori likvidnosti putem tržišta novca i derivatski poslovi – najgori način uspostavljanja likvidnosti i morao bi se koristiti samo za „krpanje“, a nikako dugoročno. U ovaj način ostvarivanja likvidnosti ubrajaju se: posuđivanje od drugih banaka na rok manji od jednog mjeseca, REPO poslovi te SWAP transakcije.

2.3. Važnost upravljanja rizicima u poslovanju

Općenito promatrano upravljanje rizikom može se definirati kao životna disciplina koja podrazumijeva mogućnosti da budući događaji mogu izazvati suprotne efekte. [45]Rizik ipak ne mora u potpunosti biti promatran kao izbjegavajuća kategorija.

Bankarski odnos prema riziku nije ni pasivan ni defanzivan, banke aktivno i voljno preuzimaju rizik jer očekuju povrat, što se ne može dogoditi bez rizika. U stvari upravljanje rizikom se može promatrati kao centralna osnova konkurencije osiguravajuće kompanije ili banke. Financijska institucija može koristeći svoju ekspertizu, tržišnu poziciju i strukturu kapitala i upravljati rizikom transformirajući ga i transferirajući ga na tržište uobičajenim putem. Upravljanje rizikom je prema tome upravljanje imovinom koja potječe iz obaveza tako da se uspije ostvariti adekvatna zarada na investirana sredstva i zadrži dovoljan višak te da imovina bude uvijek malo veća od obaveza.[46]

Prema ISO 31000 standardu upravljanje rizikom predstavlja identifikaciju, ocjenu, izdvajanje prioriteta, zatim koordiniranje i ekonomično primjenjivanje resursa kako bi se minimizirala, pratila i kontrolirala mogućnost ili utjecaj neželjenih događaja i maksimizirala realizacija očekivanih uspjeha.

Upravljanje rizikom predstavlja složen i permanentan proces. U ovisnosti o djelatnosti i način upravljanja rizikom se razlikuje. Strategija upravljanja rizikom ovisi u suštini o ciljevima koji se žele postići.

[45] Jovanović, M. (2011): Pojam rizika i upravljanje rizikom u ekonomiji, Pravno-ekonomski pogledi br.3, Beograd

[46] Jovanović, M. (2011): Pojam rizika i upravljanje rizikom u ekonomiji, Pravno-ekonomski pogledi br.3, Beograd

Upravljanje rizicima je postalo neizostavan dio financijskog poslovanja. To je proces u kojem se identificira, mjeri i kontrolira izloženost riziku. Osnovni ciljevi upravljanja rizikom su optimizacija odnosa rizika i prinosa, da bi se izbjegla nesolventnost financijske institucije i da bi se maksimizirala stopa prinosa na kapital, uz korekciju rizika. Reguliranje rizika, kao krajnji cilj cijelog procesa proučavanja rizika, zahtjeva poznavanje faktora koji određuju visinu i prirodu rizika sa kojim se u svom poslovanju susreću financijske institucije.

U svom poslovanju, financijske institucije se u današnje vrijeme suočavaju s dva velika izazova: upravljanje rizicima i maksimizacija profita. Ovo predstavlja težak zadatak, budući da su rizici brojni i teško se identificiraju, a još teže kontroliraju.

Upravljanje rizikom ima dva glavna cilja:[47]

- poboljšati financijske performanse institucije, i
- osigurati da jedna institucija ne pretrpi neprihvatljive gubitke.

Financijske institucije uvećavaju prihode preuzimanjem rizika i upravljanjem njime. Stoga, za profitabilnost institucije od presudnog je značaja upravljanje odnosom rizika i prihoda.

Premije rizika, koje se ostvare u svakodnevnom poslovanju, služe za amortiziranje očekivanih gubitaka, dok vlastiti kapital služi za pokrivanje neočekivanih gubitaka.

Financijski rizik se odražava na dva načina, u materijalnom i nematerijalnom obliku. Materijalna komponenta predstavlja gubitak dijela ili cijelog iznosa ulaganja, a nematerijalna predstavlja gubitak poslovnog ugleda.

[47] Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd

3. Rizičnost vrijednosti (VaR) i uvjetna rizičnost vrijednosti (CVaR) kao mjere rizika

3.1. Definicija i osnovne karakteristike rizičnosti vrijednosti (VaR)

U posljednjih nekoliko godina, akademici i praktičari intenzivno su proučavali mjeru rizika koja se zove Value-at-Risk (VaR) – rizičnost vrijednosti. VaR je razvijen kao odgovor na potrebe da se različiti izvori tržišnog rizika kvantificiraju u jednoj mjeri. Prvi je promjene u internom nadzoru investicijskog poslovanja pokrenuo čelnik poznate američke banke JP Morgan – Dennis Weatherstone, koji je želio postaviti „radarski" sustav za promatranje tržišnog rizika kojem je njegova tvrtka bila svakodnevno izložena. Dajući analitičarima zadatak da izgrade takav sustav, postavio je uvjet da mu se svaki dan podnosi izvještaj u kojem će stajati samo jedan broj. S obzirom na nepregledan broj vrijednosnica koje su činile JP Morganov portfelj, zadatak se činio iznimno teškim, no Til Guildimann i Jacques Longerstaey rješenje su pronašli u Markowitzevoj teoriji portfelja i hipotezi o efikasnosti tržišta (JP Morgan, 1996).[48]

Računajući rizičnost portfelja prema Markowitzu, a na osnovi rizika pojedinih vrijednosnica u portfelju, te njihovih međusobnih korelacija, može se doći do postotka rizičnosti cijelog portfelja, tj. do njegove volatilnosti:

$$\sigma_P^2 = \sum_{i,j=1}^{N} w_i w_j \sigma_{i,j}^2 \tag{3.1}$$

Pritom su w_i udjeli vrijednosnica u portfelju, a $\sigma_{i,j}$ kovarijance (varijance) između prinosa vrijednosnica. S obzirom na to da su prinosi portfelja slučajni, raspodjela prinosa je Gaussova. Na osnovu toga može se postaviti pitanje koliko investitor najviše može izgubiti u 19 tjedana od 20 ako posjeduje npr. portfelj vrijedan 1.000.000 kuna? Ako je riječ o slučajnoj (Gaussovoj) raspodjeli, odgovor je da najmanji iznos prinosa (u odnosu prema prosječnom prinosu) može iznositi 1,65 standardnih devijacija σ. Na kraju je dovoljno pomnožiti $1{,}65\sigma$

[48] Mikuličić, D. (2001): Value at Risk (Rizičnost vrijednosti) Teorija i primjena na međunarodni portfelj instrumenata s fiksnim prihodom, Hrvatska Narodna Banka

trenutačnom novčanom vrijednošću portfelja M te tako dobiti iznos koji govori koliko se najviše imovine može izgubiti:

$$VaR = 1{,}65\sigma_P\, M \tag{3.2}$$

Guildmann i Longerstaey nazvali su taj broj Value-at-Risk (VaR). Odabir omjera od „19 od 20“ zadaje razinu pouzdanosti od 95%. Izbor razine pouzdanosti varira među različitim managerima rizika. Razina pouzdanosti uglavnom se kreće između 90% i 99% (RiskMetrics u izračunu uzima razinu pouzdanosti od 95% kao referentni nivo, Bankers Trust uzima 99%, Chemical and Chase 97,5%, Citybank 95,4%).

Na primjer, ako je prosječna tjedna rizičnost portfelja 4,96%, kao u slučaju predviđanja za rizičnost indeksa CROBEX, onda je $1{,}65\sigma = 8{,}2\%$, te dolazimo do iznosa koji govori da u idućih 19 tjedana od 20 investitor koji je uložio 1.000.000,00 kuna u portfelj sastavljen od dionica koje čine indeks CROBEX vjerojatno neće gubiti tjedno više od 82.000 kuna.

Paralelno s istraživanjima J.P.Morgana i druge institucije su razvijale svoje interne modele. Modeli koje su te tvrtke razvile međusobno se značajno razlikuju iako se temelje na sličnim teorijskim postavkama. Većina razlika među modelima nalazi se u pristupu obrade ulaznih podataka, postupcima predviđanja volatilnosti i korelacije, pretpostavki teorijskih distribucija itd. Usporedo s ovim parametarskim pristupima procjeni VaR pojavili su se i modeli koji se ne temelje na modernoj teoriji portfelja kao što je procjena VaR povijesnom simulacijom ili Monte Carlo simulacijama. Do 1994. godine svi interni modeli bili su čuvani u strogoj tajnosti kako konkurencija ne bi mogla koristiti rezultate istraživanja. J.P.Morgan se 1994. godine odlučio na drastičan potez i javno objavio način funkcioniranja svog sustava za mjerenje tržišnih rizika te je omogućio slobodan pristup putem interneta do svojih baza podataka i sustava. Nakon toga slijedilo je naglo širenje VaR modela te se danas mnoge banke, brokerske kuće i fondovi koriste sličnim metodama za mjerenje svoje tržišne izloženosti. Regulatorna tijela mogu nametnuti provedbu tog sustava, s obzirom na to da mogu određivati potrebnu razinu adekvatnosti kapitala na osnovi rizičnosti vrijednosti banaka. U Sjedinjenim Američkim Državama agencije za rangiranje, poput Moody’s i Standard and Poor’s (S&P) te Odbor za financijske računovodstvene standarde i Komisija za vrijednosnice i burze poduprli su sustav rizičnosti vrijednosti.

Rizičnost vrijednosti je jedinstvena, sažeta, statistička mjera mogućih portfeljnih gubitaka. *Rizičnost vrijednosti izražava očekivani maksimalni gubitak (ili najgori gubitak) tijekom određenog razdoblja unutar statistički definiranog područja prihvaćanja*.[49] Uz određena matematička pojednostavnjenja pri izračunu, rizičnost vrijednosti zbraja sve rizike određenog portfelja u jedinstven broj primjeren za upotrebu na razini uprave, radi izvješćivanja regulatornih tijela ili objavljivanja u godišnjim izvješćima.

VaR se fokusira na rizik gubitka portfelja i definira se kao maksimalni očekivani gubitak uz određenu razinu pouzdanosti (npr 95%) u odnosu na određeni vremenski horizont (npr. deset dana). Na primjer, ako je VaR - 100 kuna za portfelj uz razinu pouzdanosti od 95% i vremenski horizont od tjedan dana, može se tvrditi da "s 95% sigurnošću nećemo izgubiti više od 100 kuna tijekom sljedećeg tjedna". Ili pretpostavimo banku koja izračunava VaR uz pretpostavku zadržavanja za razdoblje od jednog dana i 99% razinu pouzdanosti. Banka može očekivati da će, u prosjeku, gubici trgovanja premašiti VaR jednom prigodom u sto dana trgovanja.

Izbor razine pouzdanosti varira među različitim managerima rizika. Na primjer, Baselski odbor predlaže 99,9% razinu pouzdanosti za svrhe adekvatnosti kapitala. Za unutarnju uporabu, niže razine pouzdanosti se često koriste. Na primjer, JPMorgan koristi razinu od 99%, Citibank koristi razinu pouzdanosti od 95,4% i Goldman Sachs koristi razinu od 95%.[50]

Drugi parametar koji varira među menadžerima rizika je razdoblje držanja (vremenski period) tijekom kojeg VaR se procjenjuje. Vrlo je vjerojatno da se povrat portfelja mijenja više za period od mjesec dana nego za jedan dan. Duljina razdoblja držanja ovisi o prirodi portfelja i tipično se kreće od jednog dana do jednog mjeseca. Baselski odbor predlaže razdoblje držanja od deset dana za većinu transakcija na tržištu kapitala.

Matematička definicija VaR je[51]

$$\int_{-\infty}^{VaR_\alpha} f_X(x)dx = 1 - \alpha \tag{3.3}$$

[49] Mikuličić, D. (2001): Value at Risk (Rizičnost vrijednosti) Teorija i primjena na međunarodni portfelj instrumenata s fiksnim prihodom, Hrvatska Narodna Banka

[50] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

[51] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

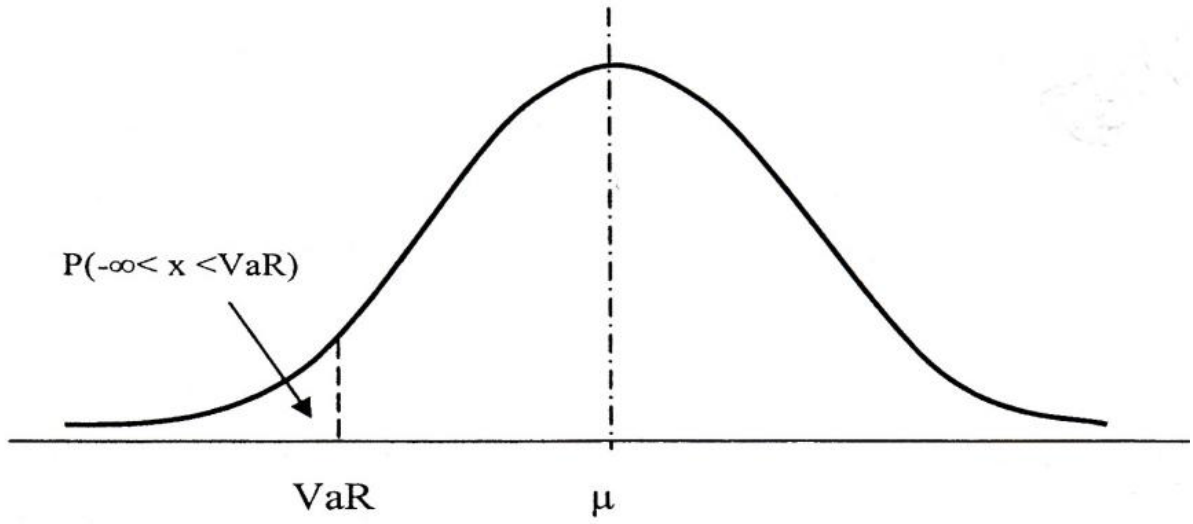
ili

$$P[x \leq VaR_{\alpha}] = 1 - \alpha \qquad (3.4)$$

gdje je f (x) granična funkcija vjerojatnosti povrata portfelja x u određenom razdoblju držanja i uz razinu pouzdanosti $\alpha \in [0,1]$.

Grafičko tumačenje VaR je ilustrirano na grafikonu 1. VaR je točka (cut-off point) koja razdvaja distribuciju povrata od svog „repa“.

Grafikon 1. Krivulja normalne distribucije i površina VaR



Izvor: Ercegovac, R.: „Politika kamatnih stopa u bankama u kontekstu rizika“, Sveučilište u Splitu, Ekonomski fakultet, Doktorska disertacija

Osnovni parametri koji definiraju VaR i koja su nužni za njegov izračun su:

- Razina pouzdanosti α
- Razdoblje držanja t

Razina pouzdanosti (alternativno: razina povjerenja, interval povjerenja, nivo povjerenja) - Osnovna razlika između VaR modela i ostalih tehnika za mjerenje rizika odnosi se na osnovni

koncept VaR-a, a to je „koliko je vjerojatno“ da ćemo izgubiti. Druge tehnike govore samo „koliko možemo izgubiti“. Razina pouzdanosti uglavnom se kreće između 90% i 99%. VaR modeli imaju tendenciju gubitka pouzdanosti pri razinama ispod 95% i iznad 99%. Iznad 99% rizik menadžerima može davati osjećaj lažne sigurnosti, pa ne bi ozbiljno shvaćali toliki iznos VaR-a, a i zbog česte karakteristike „zadebljanih krajeva“ tržišnih povrata, visoku razinu VaR-a je teško modelirati i statistički verificirati.

Učešće pozicija u promatranom vremenskom periodu u portfelju je fiksno, što znači da nam VaR daje mogućnost samo da procijenimo potencijalni gubitak, ukoliko se struktura portfelja ne bude mijenjala. VaR se uvijek računa s obzirom na neki vremenski period i onda nam sama vrijednost govori o potencijalnom gubitku, u danom vremenskom periodu. Budući da je u pitanju ocjena koja se računa uz određenu razinu pouzdanosti, o procijenjenom gubitku možemo govoriti samo kao o potencijalnom, a nikako ne možemo reći da je to broj koji nam pokazuje koliki je maksimalno moguć i siguran gubitak. Dakle, VaR ne prikazuje potencijalne gubitke u slučaju nekih izvanrednih okolnosti. Na primjer, ako je razina pouzdanosti zadana na nivou od 95%, izračunati pokazatelj nam govori o tome da ne bi trebalo da izgubimo više od navedenog iznosa u 95% slučajeva, ali nam ne kaže što bi se moglo dogoditi u preostalih 5% slučajeva.

Pošto smo pokazali koje su varijable važne za izračun rizičnosti vrijednosti, možemo dati formalnu definiciju tog pojma. Uz vjerojatnost od x posto i razdoblje držanja od v dana, rizičnost vrijednosti određenog entiteta gubitak je za koji se očekuje da će biti premašen s vjerojatnošću od samo x posto tijekom idućeg razdoblja držanja od v dana.[52]

U tumačenju vrijednosti rizičnosti vrijednosti vrlo je važno imati na umu vjerojatnost x i razdoblje držanja v. Bez njih su vrijednosti rizičnosti vrijednosti bez značenja. Na primjer, dva poduzeća koja posjeduju identične portfelje, imat će različite procjene rizičnosti vrijednosti ukoliko odaberu različite x i v. Očito je gubitak pretrpljen s 1-postotnom vjerojatnošću veći od gubitka pretrpljenog s vjerojatnošću od 5 posto. Pod pretpostavkama koje se rabe u pojedinim sustavima rizičnosti vrijednosti, on je 1,41 puta veći. Izbor razdoblja držanja može imati još veću ulogu, s obzirom na to da je rizičnost vrijednosti izračunata pomoću v dana

[52] Mikuličić, D. (2001): Value at Risk (Rizičnost vrijednosti) Teorija i primjena na međunarodni portfelj instrumenata s fiksnim prihodom, Hrvatska Narodna Banka

držanja približno $\sqrt{v}$ puta veća od rizičnosti vrijednosti izračunate na temelju jednodnevnog razdoblja držanja. Ukoliko faktori vjerojatnosti i razdoblja držanja nisu usklađeni, brojke rizičnosti vrijednosti među entitetima (portfeljima) nisu usporedive.

U usporedbi s konvencionalnim mjerama rizika poput ročnosti, prosječnog vremena vezivanja (duration) ili analize jaza (gap analysis), rizičnost vrijednosti golem je korak naprijed jer ujedinjuje izloženost različitim izvorima rizika. Ona omogućuje investitorima uključivanje raznih vrsta imovine poput strane valute, robe i dionica, koji su izloženi ostalim vrstama rizika, različitima od kretanja kamatnih stopa.

To objašnjava zašto se rizičnost vrijednosti brzo prihvaća u institucijama koje se suočavaju s financijskim rizicima.

3.2. Rizičnost vrijednosti (VaR) kao regulatorni instrument u Bazelskom sporazumu

Tijekom sedamdesetih i osamdesetih godina prošlog stoljeća mnogi događaji su utjecali na nestabilnost financijskog tržišta. Ustaljen sistem deviznih tečajeva je narušen 1971. godine i zamijenjen je fleksibilnim i promjenjivim tečajevima. Cijena nafte je narasla 1973. godine praćena visokom inflacijom i velikim oscilacijama u kamatnim stopama. Na tzv. Crni ponedjeljak, 19. listopada 1987. godine cijene američkih dionica su pale za 23%, što je uzrokovalo smanjenje kapitala za 1 bilijun dolara.[53] Svi ovi i slični događaji motivirali su Bazelsku komisiju za nadzor banaka da 1988. godine sastavi i objavi međunarodni sporazum o kapitalu banaka (Basel Capital Accord) poznat kao Bazel I. Svrha Bazel I standarda bila je uvođenje uniformnog načina za računanje adekvatnosti kapitala, a u cilju jačanja financijske stabilnosti. Jedan od razloga za uvođenje ovog sporazuma bio je da se izjednače uvjeti po kojima banke posluju na globalnom tržištu. Sporazum je zaključen 15. srpnja 1988. godine između centralnih banaka iz Grupe 10 zemalja (Belgija, Kanada, Francuska, Njemačka, Italija, Japan, Nizozemska, Švedska, Velika Britanija i SAD). U njemu su definirani jedinstveni principi i standardi koji se odnose na sigurnost poslovanja banaka. Najvažnija primjena ovog sporazuma je jačanje stabilnosti međunarodnog bankarskog sustava uvođenjem minimalnog zahtijevanog kapitala koji mora biti ispunjen kako bi se banke zaštitile od rizika.

[53] Jorion, P. (2001): Value at Risk: The New Benchmark for Managing Financial Risk, McGraw–Hill, New York

Prema Bazelskom sporazumu pokazatelj adekvatnosti kapitala banke, odnosno zahtijevani kapital za zaštitu od rizika, treba iznositi najmanje 8% od ukupne rizične aktive banke,

$$\frac{K}{A_r} \geq 8\% \tag{3.5}$$

Cijena kreditnog rizika (credit risk charge) je definirana na sljedeći način:[54]

$$C_C = 8\% \cdot A_r = 8\% \cdot \sum_i w_i \cdot A_i \tag{3.6}$$

gde je w_i ponder rizika za aktivu i. Da bi se dobila ukupna cijena rizika (total risk charge), potrebno je da banka cijeni kreditnog rizika doda i cijenu tržišnog rizika (market risk charge).

$$C_t = C_C + C_m \tag{3.7}$$

Bazel II predlaže dvije metode za mjerenje rizika i računanje zahtijevanog kapitala:[55]

1) Standardiziranu metodu (the standardized method – STD) – obično je koriste male i srednje banke koje maju nedostatak složene tehnološke infrastrukture potrebne za dnevno praćenje i računanje izloženosti riziku,
2) Interna metoda (internal models aproach – IMA) – koristi se ukoliko je regulatorno tijelo dozvolilo banci da koristi vlastite modele za mjerenje rizika.

Tržišni rizik se računa za portfelj koji je izložen riziku kamatnih stopa, promjene tečaja, riziku kapitala i riziku cijene robe. Prema standardiziranoj metodi cijena tržišnog rizika je zbroj svih individualnih cijena tržišnog rizika u portfelju:

$$C_m^{STD} = \sum_i C_{m,i} \tag{3.8}$$

[54] Basel Committee on Banking Supervision (2006): International Convergence of Capital Measurement and Capital Standards, Bank for International Settlements, Press & Communications
[55] Basel Committee on Banking Supervision (2006): International Convergence of Capital Measurement and Capital Standards, Bank for International Settlements, Press & Communications

Sumiranjem svih ovih različitih kategorija rizika dobiva se ukupni rizik banke. Dakle, zahtijevani kapital se računa za svaku pojedinačnu jedinicu rizika, a njihov zbroj predstavlja ukupan zahtijevani kapital za zaštitu od rizika. Osnovna ideja za računanje mogućih gubitaka se dobiva pretpostavljajući linearnu zavisnost između faktora rizika i financijskih instrumenata. Kretanje aktive odgovara umnošku vrijednosti aktive, osjetljivosti aktive na faktore rizika i mogućih promjena u faktorima rizika:

$$\Delta_w = W \cdot W_s \cdot \Delta_s \tag{3.9}$$

gdje je Δ_w promjena u vrijednosti aktive, W vrijednost aktive, W_S osjetljivost aktive na faktor rizika i Δ_S promjena u faktoru rizika.

Ovdje se javlja problem kada je portfelj izložen nekim nestandardnim uvjetima (refinanciranje, produženje roka dospijeća, itd.). Također, ova metoda se ne primjenjuje kada postoji diversifikacija između rizika - zamjena pojedinačnog rizika većim brojem manjih nepovezanih rizika. Mala korelacija (nepovezanost) je znak da rizik portfelja može biti mnogo manji nego zbroj individualnih pojedinačnih rizika.

Kao odgovor na kritike standardizirane metode, Bazelska komisija je kasnije ponudila alternativnu metodu, dopustila je bankama da koriste svoje vlastite modele za mjerenje rizika kako bi odredile cijenu kapitala - pristup internih modela (internal models aproach – IMA). Da bi banke mogle koristiti svoje interne modele moraju zadovoljiti različite kvalitativne zahtjeve. One moraju pokazati da imaju čvrsto razvijen sistem za upravljanje rizicima, potrebno je da provode redovita testiranja i da imaju nezavisnu kontrolu rizika, kao što je eksterna revizija. Ovaj pristup je zasnovan na formiranju parametara koji su osnova za računanje zahtijevanog kapitala.

Za određivanje cijene kapitala interni modeli banke koriste VaR metodologiju. VaR (Value at Risk – rizičnost vrijednosti) je mjera za procjenu rizika, odnosno statistička procjena vrijednosti, sa danom određenom vjerojatnosti, koju bi banka mogla izgubiti u određenom vremenskom periodu zbog promjena na financijskim tržištima. VaR sumira sve najveće gubitke u promatranom periodu sa danom razinom povjerenja. Za izračunavanje VaR-a su prema Bazelskom sporazumu u osnovi potrebni jedinstveni parametri:

a) vremenski period od 10 radnih dana ili dva kalendarska tjedna

b) razina povjerenja od 99%

c) povijesni podaci za jednu godinu koji su ažurirani najmanje svakog kvartala.

Za cijenu tržišnog rizika može se uzeti najveća vrijednost VaR-a za prethodni dan ili prosječna vrijednost VaR-a za najmanje 60 radnih dana unazad pomnožena koeficijentom k koji služi kao dodatna zaštita u slučaju da dođe do lošijih uvjeta na financijskom tržištu u odnosu na povijesne podatke. Cijena tržišnog rizika prema pristupu internih modela na bilo koji dan t određuje se prema sljedećoj formuli:[56]

$$C_{m,t}^{IMA} = \max\left(k\frac{1}{60}\sum_{i-1}^{60} VaR_{t-i,}VaR_{t-1}\right) + C_{s,t} \qquad (3.10)$$

gdje je C_S specifična cijena rizika (specific risk charge). Bazelska komisija je predložila da se za koeficijent dodatne zaštite uzme k = 3.

Prednosti internog pristupa su u tome što on dozvoljava diversifikaciju između izvora rizika, mjeri rizik cijelog portfelja banke, uzima u obzir nestabilnost kapitala i može se koristiti za računanje zahtijevanog kapitala.

3.3. Prednosti i nedostaci rizičnosti vrijednosti

Prednosti rizičnosti vrijednosti

Činjenica da je viši menadžment postao svjesniji odnosa između poduzetih rizika i ostvarenih profita je jedna od najvećih zasluga VaR-a. To je u konačnici dovelo do efikasnije alokacije sredstava.[57]

Dvije su osnovne karakteristike koje VaR čine tako privlačnim i rasprostranjenim:[58]

Prva je ta da on nudi jednostavnu i konzistentnu mjeru rizika za različite pozicije i faktore rizika. Na ovaj se način omogućava uspoređivanje rizika vezanih za investiranje u npr.

[56] Basel Committee on Banking Supervision,(2006): International Convergence of Capital Measurement and Capital Standards, Bank for International Settlements, Press & Communications
[57] Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd.
[58] Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd

obveznice i dionice, tj. VaR predstavlja mjeru rizika kojom možemo usporediti instrumente koji prije primjene VaR-a nije bilo moguće usporediti.

Druga karakteristika je ta da on uzima u obzir koeficijente korelacije među različitim faktorima rizika. U slučaju kada se dva faktora poništavaju, VaR to uzima u obzir te u konačnici pokazuje da je nivo ukupnog rizika nizak.

Informacije koje pruža VaR mogu se koristiti na sljedeće načine:[59]

1. Viši menadžment ih može koristiti kako bi postavio opći profil rizika institucije, te postavio limite za maksimalni rizik i izloženost po organizacijskoj jedinici svoje organizacije.
2. Banke ga mogu koristiti kao mjeru za izdvajanje rezervi za tržišne rizike, budući on pruža informaciju o maksimalnom iznosu koji se može izgubiti tijekom određenog perioda uz određenu vjerojatnost.
3. Investicijski bankari i brokeri ga mogu koristiti umjesto uobičajenih mjera efikasnosti investiranja.
4. U godišnjim izvješćima velikih poduzeća kako bi se investitorima prikazao rizik poduzeća.
5. Kako bi se unaprijed ocijenile investicijske prilike.
6. Za implementaciju hedging strategija koje obuhvaćaju cjelokupni portfelj institucije.

Iz prethodno navedenog možemo zaključiti da VaR nudi konzistentan i integriran pristup upravljanju tržišnim rizicima, što vodi cjelokupno boljem i sigurnijem poslovanju. Samim time ne treba čuditi što je opće prihvaćena, standardizirana mjera tržišnog rizika čiju primjenu pri izračunavanju zahtijevanog kapitala koriste i regulatorne institucije.

Nedostaci rizičnosti vrijednosti

Većina se znanstvenih diskusija vezanih za VaR bavi empirijskim i teoretskim prednostima jednog pristupa nad drugim. No, nisu svi financijski stručnjaci bili zadovoljni prihvaćanjem VaR-a kao industrijskog standarda, neki od njih upozoravaju na probleme vezane uz sam koncept VaR-a. Kritičari VaR-a sumnjaju u primjenjivost i valjanost statističkih i drugih pretpostavki koje su uglavnom preuzete iz fizike i izravno primijenjene na financije. Smatraju kako su doslovne primjene zakonitosti iz fizike na društvene sustave nevažeće, budući da ne

[59] Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd

uzimaju u obzir važne osobine društvenih sustava; sposobnost učenja i prilagođavanja sudionika financijskih tržišta, nestacionarna i dinamička ovisnost mnogih tržišnih procesa.[60]

Uz prethodno navedeno kritičari smatraju i da su izračuni VaR-a neprecizni, iz razloga što različiti VaR modeli daju različite rezultate, samim time nisu od posebne koristi.[61] Isto tako smatraju da bi moglo doći do velikih gubitaka ako ih investitori shvate kao jedino mjerilo rizika, a pri tome imaju krive izračune VaR-a.

Najveća zamjerka koja se pripisuje VaR-u jest nezadovoljavanje subaditivnosti, tj. nije sigurno da iznos VaR-a ukupnih pozicija portfelja neće biti veći od sume VaR-a samostalnih pozicija koje čine taj portfelj. [62]

Kao još neke od mogućih nedostataka VaR-a možemo istaknuti:[63]

1. VaR metode slabije funkcioniraju na nelikvidnim tržištima i temelje se na povijesnim podacima, koji se ne moraju nužno ponavljati u budućnosti.
2. VaR procjenjuje mogući gubitak na kraju razdoblja, a ne prikazuje rizik tijekom razdoblja držanja.
3. Nije pogodan za procjenu rizika u slučaju ekstremnih pomaka, budući pretpostavlja normalnu distribuciju rizičnih događaja.
4. Ne daje nam informacije koliki bi gubitak mogao nastati izvan granica VaR-a.

Iz navedenog se može zaključiti da VaR nije idealno rješenje u svim situacijama, ali svakako je efikasna mjera tržišnog rizika u normalnim uvjetima.

3.4. Definicija i osnovne karakteristike uvjetne rizičnosti vrijednosti (CVaR)

VaR je često kritiziran zato što ne uzima u obzir veličinu gubitaka koji premašuju VaR. Na primjer, VaR ne daje uvid u ono što bi se dogodilo da se u banci dogodi događaj koji ima vjerojatnost 1 na 1000. CVaR (Conditional Value at Risk) ili uvjetna rizičnost vrijednosti je često predlagana kao alternativa VaR. CVaR je također poznat pod nazivima expected shortfall, tail VaR i mean shortfall. U kontekstu kontinuirane distribucije, za danu razinu

[60] Nassim, T. (1997): Dynamic hedging: Managing vanilla anda exotic options, Wiley New York
[61] Beder, S. T. (1995): *VaR: Seductive but dangerous*, Financial Analyst Journal, Vol 51 (5)
[62] Dowd, K. (2002): Measuring market risk, John Wiley and Sons, New York
[63] Masinović, I. (2013): Rizična vrijednost (VaR) kao mjera tržišnog rizika, Diplomski rad, Ekonomski fakultet u Splitu.

povjerenja i razdoblje držanja t, CVaR se definira kao uvjetno očekivanje gubitaka koji premašuju VaR. Stoga, za razliku od VaR, CVaR pruža dodatne informacije o gubicima u repu distribucije koji premašuju VaR.

Matematički CVaR je definiran:[64]

$$CVaR_\alpha = \frac{1}{1-\alpha}\int_{-\infty}^{VaR_\alpha} x f_X(x)dx \tag{3.11}$$

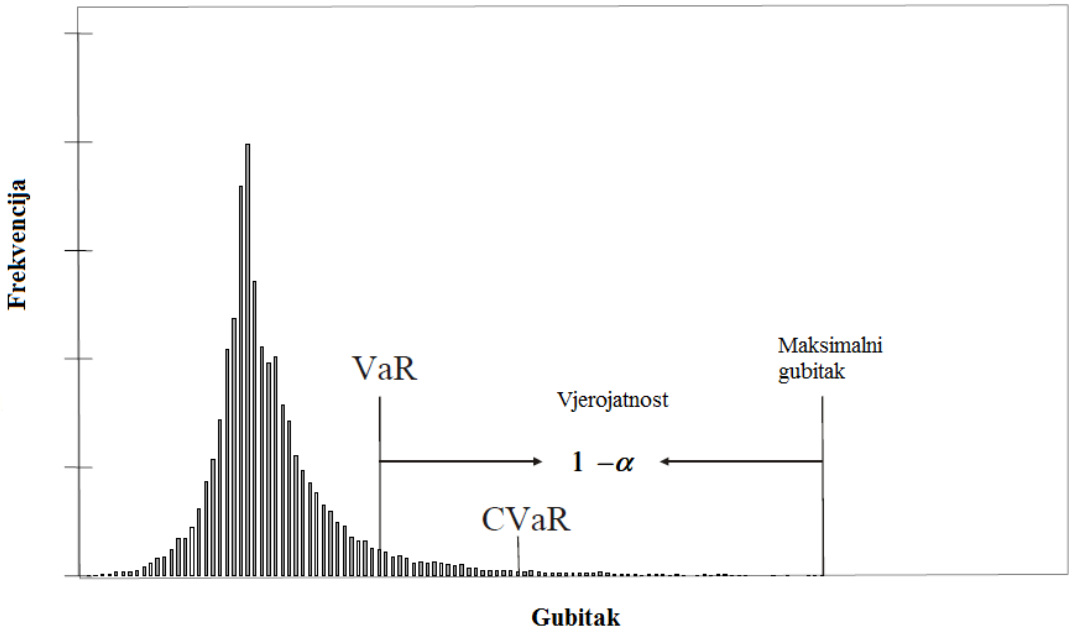
Ili ekvivalentno

$$CVaR_\alpha = E[x|x \leq VaR_\alpha] \tag{3.12}$$

gdje je f (x) granična funkcija vjerojatnosti povrata portfelja x za određeni vremenski period te je i VaR je izračunat za isti vremenski period uz razinu pouzdanosti α.

Grafičko tumačenje CVaR je prikazano na grafikonu 2.

Grafikon 2. CVaR i VaR



Izvor: Uryasev, S. (2000): Conditional Value-at-Risk (CVaR): Algorithms and applications, Financial Engineering News, No. 14

[64] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

CVaR je očekivani gubitak ako se događaj u repu distribucije dogodi, te se stoga grafički nalazi na lijevoj strani od VaR.

Za slučajne varijable sa stalnom distribucijom funkcija, CVaR (X) je jednak subjektu X za koji vrijedi da je X veći ili jednak od VaR (X). CVaR može biti CVaR+ kada očekivana vrijednost X strogo prelazi VaR, ili CVaR- kada očekivana vrijednost X slabo prelazi VaR.[65]

CVaR+ - (poznata i kao: Mean Excess Loss, Expected Shortfall) - očekivana vrijednost X striktno prelazi VaR

$$CVaR_{\propto}^{+} = E\ (X|X > VaR_{\alpha}(X)) \tag{3.13}$$

CVaR- - (poznata i kao: Tail VaR) – očekivana vrijednost X slabo prelazi VaR

$$CVaR_{\alpha}^{-} = E(X|X \geq VaR_{\alpha}(X)) \tag{3.14}$$

Za razliku od VaR, CVaR ima neke poželjne osobine. U svom radu, Artzner, Delbaen, Eber, i Heath [66]predstavili su koncept koherentne mjere rizika i pokazali da je od konvencionalnih mjera rizika kao što su VaR, varijanca i CVaR samo CVaR koherentna mjera rizika. Oni tvrde da koherentna mjera rizika treba zadovoljiti četiri uvjeta:

1) Monotonost: $\rho(X) \leq \rho(Y), ako\ je\ X \geq Y$
2) Subaditivnost $\rho(X + Y) \leq \rho(X) + \rho(Y)$
3) Pozitivna homogenost: *Za bilo koji pozitivni realni broj* $c,\ \rho\ (cX) = c\rho(X)$
4) Translacijska nepromjenjivost: *Za bilo koji realni broj c*, $\rho(c + X) \leq \rho(X) - c$

Gore navedeni uvjeti mogu se tumačiti na sljedeći način: Monotonost: kada je povrat portfelja X veći od povrata portfelja Y tada rizik portfelja Y ne može biti niži od rizika portfelja X. Subaditivnost se odnosi na učinak diversifikacije kod dodavanja još jedne imovine u portfelj i efekt smanjenja rizika uvođenjem nove imovine. Pozitivna homogenosti znači da ako ulaganje u imovinu raste "c" puta, rizik se također treba povećati "c" puta. Translakcijska

[65] 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

[66] Artzner, P.; Delbaen, F.; Eber, J.; Heath, D (1999): Coherent measures of risk, Math Finance, 9 (3), 203-208

nepromjenjivost znači da dodavanje nerizične imovine u portfelj ne bi trebalo povećati rizik portfelja.

VaR unatoč svojoj širokoj prihvaćenosti ne zadovoljava sve uvjete koherentnosti. Odnosno, VaR ne zadovoljava uvjet subaditivnosti, što znači da rizik portfelja u smislu VaR može biti veći od zbroja rizika svojih komponenti. Uvjet subaditivnosti ima značajnu ulogu kod mjera rizika. Budući da ne zadovoljava uvjet subaditivnosti može se dogoditi da dobro diversificiran portfelj zahtjeva više regulatornog kapitala od lošije diversificiranog. Tako upravljanje rizikom u smislu VaR može destimulirati diversifikaciju portfelja. Druga kritika VaR temelji se na njegovoj karakteristici ne-konveksnosti što ograničava njegovu upotrebu kao mjere rizika u izboru optimalnog portfelja za investicijske svrhe. Pokazano je da uključivanjem VaR u optimizacijske okvire, VaR risk menadžeri se suočavaju s većim gubicima nego menadžeri koji ne koriste VaR u različitim zemljama svijeta. [67]Dapače, Basak i Shapiro su pokazali da agent koji se suočava s ograničenjem VaR može izabrati veću izloženost rizičnoj imovini nego kada ne postoji VaR ograničenje. Također je pokazano da problem minimiziranja VaR portfelja derivatnih ugovora može imati više lokalnih minimuma, što vodi do nepouzdanog rangiranja rizika. [68]

Acerbi i Tasche pokazuju da CVaR zadovoljava četiri aksioma koherentnosti, što posljedično, kvalificira CVaR kao koherentnu mjeru rizika. U stvari, pokazuje da se svaka koherentna mjera rizika može prikazati kao konveksna kombinacija CVaR-ova s različitim razinama povjerenja. Osim toga, CVaR je konveksna funkcija s obzirom na pozicije portfelja, čime je omogućena izgradnja efikasnih algoritama za optimizaciju. Konkretno, dokazano je da se CVaR može smanjiti primjenom tehnika linearnog programiranja, što ga čini prilikom velikih izračuna praktičnim, efikasnim i stabilnim.[69]

[67] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

[68] Basak, S.; Shapiro, A. (2001): Value-at-Risk Based Risk Management: Optimal Policies and Asset Prices, Review of Financial Studies, Vol. 14, 371-405,

[69] Acerbi, C.; Tasche, D.(2002): On the coherence of Expected Shortfall, Journal of Banking & Finance, 26 (7), 1487-1503

3.5. Prednosti i nedostaci uvjetne rizičnosti vrijednosti CVaR

Prednosti

Jedna od glavnih prednosti očituje se u činjenici da za CVaR vrijedi načelo subaditivnosti. Uz to VaR nam ne daje nikakve informacije o gubicima koji prelaze VaR, dok nam CVaR daje prosječnu vrijednost gubitka većeg od VaR.

Definicija CVaR-a garantira da je CVaR ≥ VaR, te iz tog razloga portfelj koji ima nizak CVaR će imati i nizak VaR. U općem slučaju CVaR je konveksna funkcija i koherentna mjera rizika, pa se može optimizirati koristeći tehnike linearnog programiranja.[70]

Možemo istaknuti još nekoliko prednosti CVaR mjere rizika:[71]

1. Jednostavan i brz prikaz rizika u jednom broju
2. Mjeri rizik velikih gubitaka
3. Primjenjiv je i na nesimetrične distribucije gubitaka
4. Mjeri rizike koji prelaze VaR
5. Konveksan je
6. VaR ≤ CVaR- ≤ CVaR ≤ CVaR +
7. Daje stabilne statističke procjene
8. Kontinuiran je obzirom na razinu pouzdanosti α, konzistentan na različitim razinama pouzdanosti za razliku od VaR-a
9. Za normalne distribucije gubitaka optimalna varijanca i CVaR se podudaraju
10. CVaR-om je lako kontrolirati (optimizirati) distribucije koje nisu normalne

Mnoge studije slučaja su pokazale da se optimizacija rizika CVaR metodom može provesti za velike portfelje i veliki broj scenarija s relativno malim računalnim zahtjevima. Isto tako ovaj se pristup može koristiti kako bi se maksimizirali očekivani povrati ograničavajući CVaR, a ne minimizirajući ga. Osim toga, moguće je i nametnuti mnoga ograničenja CVaR-u na različitim razinama pouzdanosti i oblikovati distribuciju gubitaka prema preferencijama donositelja odluka. Tako na primjer možemo zahtijevati da središnje vrijednosti najgorih 1%, 5% ili 10%

[70] Marina, E. (2014): Evaluacija VaR mere rizika, Master rad, Univerzitet u Novom Sadu
[71] Uryasev, S. Conditional Value-at-Risk (2000): Algorithms and applications, Financial Engineering News, No. 14, 1-5

gubitaka su ograničene na određene vrijednosti. Ovaj pristup nam pruža nov, učinkovit i fleksibilan alat za upravljanje rizikom.[72]

Nedostaci

VaR izračuni su statistički stabilniji od CVaR izračuna. Ovo može dovesti do superiornih rezultate iz uzorka za VaR u odnosu na CVaR za određene aplikacije. Npr.za portfelj koji uključuje instrumente s jakim karakteristikama okretanja srednjoj vrijednosti, VaR neće penalizirati instrumente s ekstremno velikim gubicima. U statistici je jasno razumljivo da su izračuni temeljeni na VaR robusni i mogu automatski zanemariti ekstreme - vrijednosti koje jako odstupaju ili velike gubitke, koji mogu „zbuniti“ proceduru statističkog izračuna. Neosjetljivost VaR na ekstremne repove može biti i poprilično neželjena karakteristika koja dopušta da se poduzmu visoki nekontrolirani rizici.[73]

CVaR je osjetljiviji od VaR 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.[74]

Backtesting CVaR je kompleksniji nego backtesting VaR, te se smatra da je to jedan od razloga isključivanja CVaR iz okvira Baselskog odbora.

[72] Krokhmal, P., Palmquist, J., Uryasev, S. (2002): Portfolio optimization with Conditional Value-at-Risk objective and constraints. The Journal of Risk, Vol. 4, No. 2, 11-27

[73] 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

[74] 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

4. Metode izračuna rizičnosti vrijednosti (VaR) i uvjetne rizičnosti vrijednosti (CVaR)

Postoje mnogi načini izračuna rizičnosti vrijednosti VaR. Uz danu distribuciju prinosa, izračun VaR je jednostavan te uz dati VaR, izračun CVaR je jednostavan. Dakle, izazovi procjene VaR i CVaR uglavnom se odnose na procjenu distribucije prinosa. Pristupi se mogu svrstati na parametarske i neparametarske metode. Parametarski pristup ima određene pretpostavke o distribuciji povrata, npr. pretpostavka normalnosti.

Pretpostavke distribucije podrazumijevaju rizik modela, odnosno rizik da postoji nerazmjer između pretpostavljene distribucije povrata i prave temeljne distribucije vjerojatnosti. Neparametarske metode temelje procjene VaR isključivo na empirijskim distribucijama povrata. Nedostatak je da su procjene potpuno ovisne o određenom skupu podataka. Najjednostavnija neparametarska metoda se zove povijesna metoda simulacije.[75]

Na slici br. 2 prikazana su tri glavna načina mjerenja VaR-a:

Slika 2. Metode izračuna rizičnosti vrijednosti



Izvor: Saunders, A. (2000): Financial institutions management: a modern perspective, McGraw-Hill, Boston

[75] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

1. Parametarski model (poznat i kao; delta/normal model, model varijance i kovarijance ili kao RiskMetrics model)

2. Povijesni model

3. Monte Carlo simulacija

Praćenjem kretanja malog broja faktora rizika, kao što su kamatna stopa, intervalutni tečajevi i volatilnost, moguće je izračunati vrijednosti tisuća vrijednosnica koje se nalaze na tržištima kapitala. Sva tri pristupa izračuna VaR-a i CVaR koriste povijesnu distribuciju promjena cijena na tržištu kako bi odredili odgovarajuću distribuciju za dobivene podatke. Zbog ovog pristupa sve tri metode se suočavaju s problemom izbora vremenskog horizonta iz kojeg će koristiti povijesne podatke. Problem se javlja zbog nemogućnosti istovremenog zadovoljenja dva ekstrema kojima se teži. S jedne strane želi se uzeti dovoljno dugo povijesno razdoblje, tako da dobiveni podaci u sebi sadrže rijetke i ekstremne događaje, a s druge strane, budući da se VaR-om želi predvidjeti buduća distribucija povrata, potrebno je koristiti najnovije tržišne podatke koji ocrtavaju najnovija kretanja na tržištima.

4.1. Povijesna metoda

Najčešća i vjerojatno najjednostavnija neparametarska metoda za procjenu VaR (i CVaR) jest povijesna metoda. Pretpostavka je da će se trendovi posljednjih promjena cijena nastaviti i u budućnosti. VaR (i CVaR) portfelja onda se izračunava pomoću percentila empirijske distribucije koji odgovara odabranoj razini pouzdanosti. Nema potrebe za procjenu parametara distribucije, kao što su volatilnosti i koeficijenti korelacije. Povijesna metoda simulacije je relativno jednostavna za implementaciju, treba samo imati povijesne podatke od prošlih prinosa. Metoda je također bez rizika modela i omogućava da se opišu ne-normalne distribucije s debelim repovima koje se često nalaze u financijskim podacima.[76]
Povijesna metoda pripada grupi neparametarskih metoda za izračunavanje VaR-a. Zajednička karakteristika svih neparametarskih metoda jest ta da koriste empirijske raspodjele, za razliku od parametarskog pristupa gdje se pretpostavlja teorijska raspodjela prinosa.

[76] Goorbergh, R., Vlaar, P. (1999): Value-at-Risk Analysis of Stock Returns Historical Simulation, Variance Techniques or Tail Indeks Estimation?, De Nederlandsche Bank Staff Reports, No.40

Pretpostavka modela je da će bliska budućnost biti vrlo slična nedavnoj prošlosti te da se pomoću podataka iz bliske prošlosti može procijeniti rizik u skoroj budućnosti. [77]

Da bi se primijenio povijesni model potrebno je uzeti odgovarajući vremenski horizont od npr. 100, 250 ili 500 dana povijesnih podataka, izračunati dnevne prinose te odrediti VaR iz iscrtanog histograma gubitaka i dobitaka.

Izbor vremenskog horizonta ima značajan utjecaj na VaR mjeru, pogotovo kada se koristi povijesni model. Dugi vremenski horizont može uključivati podatke koje nisu relevantni za trenutnu situaciju i može pretpostavljati prilično konstantnu VaR mjeru. Kratki vremenski horizont čini izračune osjetljive s obzirom na abnormalne rezultate u nedavnoj prošlosti, te može ukazivati na visoka odstupanja u VaR mjeri.[78]

Mnoge velike financijske institucije i menadžeri rizika pri izračunu VaR njihovih trgovačkih portfelja koriste pristup povijesne simulacije, npr Goldman Sachs.

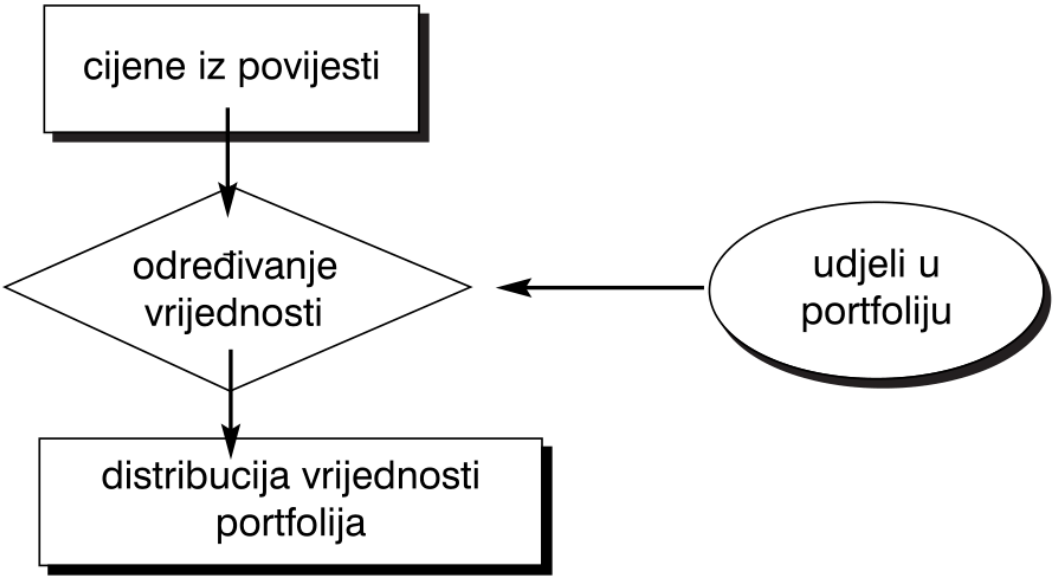
Povijesna metoda izračuna rizične vrijednosti svakako je najprivlačnija metoda sa stajališta teoretičara i praktičara u Republici Hrvatskoj zbog činjenice da se, za razliku od RiskMetrics modela, ne zasniva na koeficijentima korelacije među dijelovima portfelja.[79] Tom se metodom ocjenjuje tržišna vrijednost portfelja s obzirom na tržišne cijene dijelova portfelja u n posljednjih dana. Osnovna ideja tog koncepta je uzimanje u obzir trenutačnog portfelja te ponovna ocjena njegove vrijednosti na osnovi tržišnih cijena iz prethodnih dana. Ta metoda se može prikazati sljedećom slikom:

[77] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

[78] Goorbergh, R., Vlaar, P. (1999): Value-at-Risk Analysis of Stock Returns Historical Simulation, Variance Techniques or Tail Indeks Estimation?, De Nederlandsche Bank Staff Reports, No.40

[79] Šverko, I. (2001): Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj, Riječka banka, Rijeka

Slika 3. Povijesna metoda



Izvor: Jorion, P. (1995): Value at Risk: the new benchmark for controlling market risk, Irwin, Chicago

Kao što možemo vidjeti iz slike 3, prvi korak je da se na osnovi cijena iz prošlosti i udjela u portfelju, određuje „pretpostavljena“ tržišna vrijednost trenutačnog portfelja u *n* posljednjih dana. Nakon toga se tako dobivene tržišne vrijednosti poredaju od onih koje daju najveće gubitke do onih koji nose najveće dobitke, te se tako dolazi do rizičnosti vrijednosti. U praksi se pokazalo da je povijesna metoda pogodnija za primjenu od parametarske metode na tržištima kapitala zemalja u tranziciji. Razlozi za ovaj navod leže u volatilnosti dionica, promjenjivosti korelacije između dionica, te činjenici da tržišni indeksi zemalja u tranziciji pokazuju veću asimetričnost i zaobljenost u odnosu na normalnu raspodjelu.

Prilikom izračuna VaR-a korištenjem povijesne metode koristi se povijest postotnih promjena cijena te se povijesna metoda izračuna VaR primjenjuje na postojeći portfelj na sljedeći način:[80]

1. Treba naći postotne promjene cijena za svako sredstvo ili faktor rizika,

2. Primijeniti cjenovne promjene na portfelj radi generiranja povijesne serije promjena vrijednosti portfelja,

[80] Šverko, I. (2001): Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicimafinancijskih institucija u Republici Hrvatskoj, Riječka banka, Rijeka

3. Sortirati serije promjena vrijednosti portfelja u postotcima,

4. VaR portfelja je promjena vrijednosti koja odgovara zahtijevanoj razini pouzdanosti.

Postavljaju se dva ključna pitanja na koja treba odgovoriti u pogledu određivanja potrebnih serija povijesnih cijena:

1. Koju dužinu trajanja serije cijena treba koristiti?
2. Što treba raditi za proizvode za koje ne postoji povijest cijena?

Izbor dužine povijesti perioda promatranja predstavlja jednu od najvažnijih odluka koje se donose pri implementiranju VaR-a. Ponašanje VaR modela značajno se razlikuje pri izboru različitih perioda promatranja. U praksi, vrijeme promatranja značajno varira; dok neke banke koriste samo 100 dana, druge koriste 3 i više godina. [81]

Za proizvode za koje ne postoji povijest cijena postoji problem koji se ne odnosi samo na povijesnu simulaciju, jer neće biti moguće izračunati ni volatilnost ni korelacije između novog sredstva i ostalih sredstava. U praksi, serija cijena se može pozajmiti od postojećeg sredstva sličnih karakteristika sve dok se ne prikupi neka adekvatna serija podataka.

4.1.1. Prednosti povijesnog modela

Kao glavne prednosti povijesnog modela pred ostalim metodama mogu se istaknuti sljedeće:[82]

1. Metoda je teorijski jednostavna

2. Jednostavno ju je provesti u praksi

3. Pri izračunu VaR-a koriste se podaci koji se mogu jednostavno dobiti na burzi

4. Daje rezultate koji se mogu jednostavno prezentirati regulatorima i višem menadžmentu

5. Lako se uključuju zadebljani repovi, asimetričnosti i ostale karakteristike koje ne odgovaraju normalnoj distribuciji, budući da ne ovisi o parametarskim postavkama o distribuciji povrata.

[81] Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd.
[82] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Ekonomski fakultet u Ljubljani, Ljubljana

6. Nema potrebe za računanjem matrice varijanci-kovarijanci

7. Pogodna je za izračun VaR-a različitih vrsta vrijednosnica, uključujući i financijske derivate

8. Jednostavno je izračunati VaR pri različitim razinama vjerojatnosti

9. Pogodna je za daljnja modificiranja i usavršavanja

Povijesni model je vrlo koristan kada je količina ulaznih podataka manja, te kada ne postoji dovoljno informacija o distribuciji dnevnih dobitaka ili gubitaka.[83]
Odsustvo pretpostavke o normalnosti raspodjele prinosa portfelja znači da se povijesni model može primijeniti na svaki portfelj, pod uvjetom da su poznati svi faktori rizika koji determiniraju vrijednost portfelja. Isto tako, budući da se zasniva na aktualnim cijenama, ona dopušta nelinearnost, kao i raspodjele koje su različite od normalne.

4.1.2. Nedostaci povijesnog modela

Povijesni se model rizičnosti vrijednosti temelji na nekim problematičnim pretpostavkama. Navodimo najčešće spominjane:
Pretpostavka da će buduće distribucije imati točno isti oblik kao i one iz prošlosti ne mora se nužno pokazati točnom. Pokazalo se da ti modeli slabije funkcioniraju u kriznim situacijama. Takvi, naime, modeli pokazuju očekivane maksimalne gubitke, a krizne se situacije ipak u većini slučajeva ne očekuju. Tako su neka istraživanja pokazala loše funkcioniranje modela rizičnosti vrijednosti u uvjetima ruske financijske krize iz 1998. godine. U tom smislu mnogi kritičari smatraju da su takvi modeli rizičnosti vrijednosti potencijalni uzroci cjelokupne krize jer se pretpostavlja da su svi dali jednake savjete portfelj menadžerima: smanjiti rizičnost prodajom investicija, a to dovodi do pada cijena i da ukupne krize.
Pretpostavka da svaki promatrani dan jednakim intenzitetom utječe na promatranu rizičnu vrijednost je problematična, budući da pretpostavlja identičan utjecaj svih dnevnih promjena cijena. Međutim, baš su zbog problematičnosti te pretpostavke razvijeni i neki drugi oblici povijesnog modela. Takve pretpostavke o većem utjecaju promjena iz bliže prošlosti pridonijela je tome da ti modeli daju bolje rezultate.

[83] Šverko, I. (2001): Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj, Riječka banka, Rijeka.

Problem odabira broja promatranih dana - koji se najčešće kreće između 100 i 500. Statistička promatranja ukazuju na to da je ponekad i uzorak od 500 promatranja premalen. Ako je u modelu previše ili premalo promatranja, model je manje precizan. Provjeravanje se provodi radi pronalaženja odgovarajućeg broja promatranih dana. Provjeravanje se temelji na uspoređivanju očekivanih maksimalnih gubitaka sa stvarnima.

4.2. Parametarska metoda

Parametarski model poznat je u praksi i kao delta/normal model, model varijance i kovarijance ili kao RiskMetrics model. Najčešće je korišten model izračuna rizičnosti vrijednosti. Zasniva se na metodologiji koju je početkom devedesetih godina razvila američka investicijska banka JP Morgan. Navedeni model se temelji na postavkama moderne portfelj teorije Harrya Martkowitza, te uvodi koeficijente korelacije među financijskim instrumentima.[84]

U ovom modelu pretpostavlja se da tržišne varijable imaju normalnu distribuciju, te se koriste njene karakteristike za određivanje VaR-a. Glavna karakteristika normalne distribucije je ta da je njena krivulja distribucije simetrična i da je u potpunosti određena ako su poznata dva parametra: srednja vrijednost μ i standardna devijacija σ.

Karakteristike normalne krivulje su:[85]

- 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, 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

[84] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

[85] Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Ekonomski fakultet u Ljubljani, Ljubljana

proširiti će se repovi, a smanjenjem standardne devijacije krivulja će se suziti i povećat će se njen vrh.

Najjednostavniji parametarski pristup je Delta-normalni (analitički) pristup. Prema ovom pristupu, pretpostavlja se da su svi povrati imovine normalno distribuirani. Kako je povrat portfelja linearna kombinacija normalnih varijabli, također je normalno distribuiran. VaR portfelja onda se izračunava koristeći povijesne (ex ante) aritmetičke sredine, varijance i kovarijance komponenti iz portfelja.

Navedeno može biti napisano kao:[86]

$$VaR_{\alpha} = \mu - {}^{z_{\alpha}}\sqrt{\sum_{i=1}^{n}\sum_{j=1}^{n} w_i w_j \sigma_{i,j}} = \mu - z_{\alpha}\sigma_p \tag{4.1}$$

gdje w_i i w_j označavaju udio imovine *i* i *j* u portfelju od *n* imovina, $\sigma_{i,j}$ označava kovarijance između prinosa imovine *i* i prinosa imovine *j*, μ je aritmetička sredina (srednja vrijednost) prinosa portfelja i σ_p je standardna devijacija ukupnih prinosa portfelja. Parametar z_{α} je vrijednost kumulativne normalne distribucije koja odgovara određenoj razini povjerenja α, npr za 95% -nu razinu povjerenja $z_{95\%}$ = 1,64, a za 99% razinu povjerenja $z_{99\%}$ = 2,33. Budući da je rok držanja obično kratak (npr deset dana) pretpostavka nulte srednje vrijednosti ($\mu = 0$) se često rabi. Tako, VaR portfelja je jednostavni umnožak standardne devijacije portfelja. Nakon izračuna VaR, izračun CVaR je jednostavan kao očekivana vrijednost gubitaka portfelja iznad VaR. Glavni nedostatak parametarskog pristupa je izlaganje modelskom riziku.

Iako normalna distribucija prilično dobro izračunava središte istinskih distribucija, problemi nastaju kada je riječ o procjeni repova distribucija. 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, odnosno kada pokazuju višak kurtosisa. Na sličan način, Andersen i dr. ukazuju da kada računamo unaprijed na debele repove distribucija možemo povećati prinos, uz smanjenje velikih rizika.[87]

[86] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

[87] Andersen, J.V., Sornette, D. (2001) "Have Your Cake and Eat It, Too: Increasing Returns While Lowering Large Risks!", The Journal of Risk Finance, Vol. 2 Iss: 3, 70 - 82

Ove empirijski nalazi su intuitivni, jer „debeli repovi“ distribucija znače da su ekstremni rezultati češći nego što upotreba normalne distribucije pretpostavlja i stoga će „debeli repovi“ dovesti do podcijenjene vrijednosti VaR.

Unatoč svojim nedostacima, delta-normalan pristup se naširoko koristi među menadžerima rizika. Na primjer, RiskMetrics sustav temelji se na parametarskom delta-normalnom modelu.

4.3. Monte Carlo metoda

Monte Carlo metoda je metoda za generiranje slučajnih brojeva. Pomoću slučajnih brojeva se mogu rješavati različiti problemi simulacijom. Ideja Monte-Carlo simulacije je da se napravi simulacija pojave koja se promatra, sa svrhom dobivanja realizacije pojave koju nije moguće dobiti na drugi način. Nakon svakog ponavljanja postupka, u rezultatu se dobiva po jedna realizacija proučavane slučajne pojave. Simulacija se izvodi određeni broj puta, a skup dobivenih realizacija predstavlja statistički skup podataka, koji se određenim statističkim metodama obrađuje i interpretira.[88]

Monte Carlo metoda je našla široku primjenu u financijama, a koristi se i za određivanje VaR-a.

Naime, ova metoda za dobivanje VaR-a aproksimira kretanje cijena korištenjem kompjuterskih simulacija za generiranje kretanja cijena. Na taj način se dobivaju različiti mogući scenariji za portfelj, za promatrani dan. Kao što je navedeno u odjeljku o povijesnoj simulaciji, metoda povijesne simulacije je efikasan način za ocjenjivanje VaR-a, ali su potrebni povijesni podaci cijena aktive u dugom vremenskom periodu. Također, smatra se da su povijesni podaci o stvarnim kretanjima cijena ograničen skup ishoda. Ovaj posljednji argument je definitivno prevladan pomoću Monte Carlo simulacije, jer ona omogućava generiranje velikog broja hipotetičkih ishoda.[89]

Osnovna ideja Monte Carlo metode je da se bira statistička raspodjela (za koju se smatra da adekvatno aproksimira moguće promjene u tržišnim faktorima) te se zatim generira N hipotetičkih prinosa portfelja. Nakon toga se koristi generator slučajnih brojeva da generira

[88] Marina, E. (2014): Evaluacija VaR mere rizika, Master rad, Univerzitet u Novom Sadu
[89] Marina, E. (2014): Evaluacija VaR mere rizika, Master rad, Univerzitet u Novom Sadu

tisuće ili desetke tisuća hipotetičkih promjena tržišnih faktora. Ove se, zatim, koristi da se konstruiraju tisuće hipotetičkih prinosa portfelja na trenutni portfelj, kao i raspodjela mogućih prinosa portfelja.

Konačno, VaR je određen ovom raspodjelom.

Prednost Monte Carlo simulacije je da se ne rade pretpostavke o normalnoj distribuciji prinosa. Iako se parametri računaju iz povijesnih podataka, mogu se unijeti subjektivne procjene i druge informacije da bi se poboljšala predviđena simulacija prinosa. Ova metoda je također u mogućnosti da uključi nelinearne instrumente poput opcija.[90] Osim ovih prednosti Jorion podsjeća da Monte Carlo simulacija generira cijelu distribuciju i tako se može koristiti, na primjer, da se izračunaju gubici koji premašuju VaR.[91]

Najvažniji problem povezan s Monte Carlo simulacijom je vrijeme izračuna. Ova metoda zahtjeva mnogo resursa, pogotovo kada se radi o velikim portfeljima. Naime Monte Carlo simulacija teži pravoj vrijednosti VaR kao $\frac{1}{\sqrt{N}}$, gdje je N broj simulacija. Da bi se povećala točnost modela za 10 puta mora se provesti 100 puta više simulacija.[92] Stoga, Monte Carlo simulacija je podložna varijaciji uzorka što je uzrokovano ograničenim brojem ponavljanja simulacije. Na primjer, VaR portfelja linearnih instrumenata može se lako izračunati koristeći pristup varijanci-kovarijanci. Monte Carlo simulacija temeljena na istoj matrici varijanci i kovarijanci daje samo aproksimaciju te je zato pristrana. Točnost se povećava samo kada se rade dodatne „runde“ simulacija. Kao posljedica provedba metode može ispasti preskupa.[93]

Unatoč tome, Monte Carlo simulacija sigurno će povećati svoju popularnost u budućnosti budući se troškovi kompjuterskog hardvera kontinuirano smanjuju.

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“.

[90] Nieppola, O. (2009): Backtesting Value at Risk models, Master's Thesis in Economics, Helsinki School of Economics

[91] Jorion, P. (2001), Value at Risk, The new Benchmark for Managing Financial Risk, 2nd Edition, McGraw-Hill, United States

[92] Wiener, Z. (1999), Introduction to VaR (Value-at-Risk), Risk Management and Regulation in Banking, Kluwer Academic Publishers, Boston

[93] Jorion, P. (2001), Value at Risk, The new Benchmark for Managing Financial Risk, 2nd Edition, McGraw-Hill, United States

4.4. Usporedba metoda izračuna rizičnosti vrijednosti (VaR) i uvjetne rizičnosti vrijednosti (CVaR)

Linsmeier and Pearson (1996) ističu da se navedene tri metode bitno razlikuju u 4 dimenzije:[94]

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

Izbor metode mora se napraviti u skladu s važnosti svake od ovih dimenzija i gledajući na zadatak na licu mjesta.

Nelinearnost instrumenata uzrokuje probleme korisnicima pristupa varijanci-kovarijanci. To znači da kada se u portfelj uključe derivati bolje je koristiti metode simulacije u odnosu na metode varijance-kovarijance (delta-normal).[95] Ipak, Dowd tvrdi da kada imamo jednostavni portfelj koji uključuje samo linearne instrumente, nema smisla koristiti Monte Carlo simulaciju budući metoda varijance-kovarijance daje isti rezultat samo jeftinije i s manje truda.[96]

Metoda varijance-kovarijance i povijesni model su jednostavni za provedbu. S druge strane, Monte Carlo simulacija ima najkompliciraniju proceduru provedbe. Ovaj problem je usko vezan s pitanjem jednostavnosti objašnjenja metode višem menadžmentu. Dok Monte Carlo metoda može biti teška za shvatiti povijesna metoda je jednostavna za razumjeti. Metoda varijance-kovarijance spada negdje između ove dvije metode. [97]

[94] 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
[95] 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
[96] Dowd, K. (1998), Beyond Value at Risk, The New Science of Risk Management, John Wiley & Sons, England
[97] 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

Fleksibilnost VaR modela je prednost kadgod povijesni izračuni i standardne devijacije i korelacije ne predstavljaju adekvatno pripadajuće parametre u budućnosti. U Monte Carlo simulaciji i modelu varijanci-kovarijanci lako je unijeti subjektivna mišljenja u kalkulaciju. Povijesna metoda je slaba u tome budući su procjene rizika direktno izvedene iz povrata iz prošlosti.[98]

Pouzdanost rezultata je vjerojatno najvažnije pitanje kada se uspoređuju različite metode. Nekoliko studija je provedeno da bi se usporedila točnost ova tri pristupa. Ammann i Reich proučavali su točnost modela linearne aproksimacije (delta-normalni pristup) u odnosu na Monte Carlo simulaciju. Pokazali su da linearna aproksimacija daje prilično točne izračune VaR, ali samo u slučaju kada je mali udio nelinearnih derivata u portfelju. Njihova istraživanja također su pokazala da Mont Carlo simulacija daje superiorne rezultate u odnosu na linearne modele kada se povećaju razina pouzdanosti i vremenski horizont.[99] Hendricks je proučavao portfelje s linearnim instrumentima koristeći delta normalnu i povijesnu metodu. Otkrio je da delta normalna varijanca-kovarijanca metoda ima sklonost da podcijeni VaR, pogotovo kod visokih razina pouzdanosti. Povijesna metoda, s druge strane, je pouzdana također i kod viših razina pouzdanosti.[100] Ova opservacija je očekivana budući metode varijance-kovarijance pretpostavljaju normalnu distribuciju, a većina imovine ima distribucije povrata s „debelim repovima“.

[98] 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

[99] Ammann, M., Reich, C. (2001): Value-at-Risk for Nonlinear Financial Instruments– Linear Approximation or Full Monte-Carlo?, University of Basel, Department of Finance, Working Paper No. 8/01

[100] Hendricks, D. (1996), Evaluation of Value-at-Risk Models Using Historical Data, Economic Policy Review

4.5. Testiranje (backtesting) VaR i CVaR

Budući se „prave“ VaR mjere ne mogu promatrati, ocjenjivanje (evaluacija) VaR modela mora se verificirati pomoću backtestinga. To znači da za određeni backtesting period, izračunate VaR mjere moraju se usporediti s promatranim prinosima. Baselski odbor definira backtesting kako slijedi:

Backtesting je ex-post usporedba risk mjera generiranih risk modelom sa stvarnim dnevnim promjenama u vrijednosti portfelja kroz duže vremenske periode, kao i hipotetske promjene temeljene na statičnim pozicijama.

Backtesting je tehnika koju se koristi da bi se usporedila predviđena vrijednost VaR-a i CVaR-a sa stvarnim gubitcima koji su se dogodili na kraju promatranog razdoblja. Navedena tehnika nam pomaže u otkrivanju slučajeva kada je vrijednost VaR-a i CVaR-a podcijenjena, tj. 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, te pritom učinili preciznijima i smanjili rizik neočekivanih gubitaka

4.5.1. Backtesting VaR

Regulatorni zahtjevi utjecali su na razvoj backtesting teorija za VaR modele. Postoji nekoliko mogućih načina za backtesting VaR modela, uobičajeno se izračunava broj puta kod kojeg gubitak portfelja prelazi VaR za svako backtesting razdoblje.

Osnovni postupak backtestinga ispituje učestalost pojave premašivanja procijenjenog VaR-a. Tu učestalost nazivamo još i stopom neuspjeha, a ona bi se trebala slagati sa izabranom razinom pouzdanosti. Tako u slučaju da je dnevni VaR procijenjen na razini od 95%, u cijeloj godini – periodu od 250 dana, očekuje se da će doći do 12.5 slučajeva u kojima će vrijednost VaR-a biti premašena.[101]

Prilikom izbora veće razine pouzdanosti se očekuje manji broj iznimaka, samim time, biti će teže ocijeniti model. Ukoliko se izabere 95%-tna razina pouzdanosti, to znači da će se moći promatrati veći broj iznimaka nego prilikom odabira 99%-tne razine, i pritom će se moći napraviti bolji test preciznosti modela.

[101] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

Ukoliko je broj odstupanja manji od praga za određenu razinu pouzdanosti, model je dobro procijenio rizik. U suprotnom slučaju, velik broj premašivanja VaR-a znači da je rizik podcijenjen. Dakle, postupak se svodi na analizu da li je broj odstupanja realan ili ne, i sukladno tome model će biti prihvaćen ili odbačen.

Najčešće korišteni test je razvijen od strane Kupiec, P.H.[102] On ispituje je li promatrana stopa kršenja statistički jednaka očekivanoj. Pod nultom hipotezom da je model primjeren, odgovarajući omjer vjerojatnosti statistički je:

$$L = 2\ln\left(\left(1-\frac{n}{T}\right)^{T-n}\left(\frac{n}{T}\right)^{n}\right) - 2\,ln((1-q)^{T-n}q^{n}) \sim X_1^2 \tag{4.2}$$

gdje je n broj dana tijekom razdoblja T u kojem se dogodilo kršenje i q je očekivana stopa kršenja. Dakle, model rizika je odbijen, ako stvara previše ili premalo kršenja.

4.5.2. Backtesting CVaR

Unatoč bliskoj teoretskoj vezi sa VaR, backtesting napravljen za VaR ne može se koristiti direktno za backtesting CVaR. Yamai i Yoshiba smatraju backtesting CVaR kompleksnijim nego backtesting VaR, te smatraju da je to jedan od razloga isključivanja CVaR iz okvira Baselskog odbora.[103]

Za provedbu postupka backtestinga za CVaR, moramo odrediti funkciju gubitka ρ. Niz različitih funkcija gubitka je predložen u literaturi. Jednostavna i lako razumljiva funkcija gubitka usporedila bi izračunati CVaR sa stvarnim prinosom r u slučajevima gdje r premašuje VaR, odnosno prinose u repu distribucije koji su uključeni u izračun CVaR:[104]

$$\rho = \begin{cases} r\ ako\ je\ r < VaR \\ 0\ ako\ je\ r \geq VaR \end{cases} \tag{4.3}$$

[102] Kupiec, P.H.(1995); Techniques for Verifying the Accuracy of Risk Mesaurement Models, Journal of Derivatives, Vol 3, 73-84

[103] Yamai, Y.; Yoshiba, T. (2002): Comparative Analysis of Expected Shortfall and Value-at-Risk: Their Validity Under Market Stress, Monetary and Economic Studies 20 (3), 181–237

[104] Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm

Funkcija (4.3) daje svakoj opservaciji gubitka u repu ponder (težinu) 1, a pripadajuća referentna vrijednost je jednostavno CVaR.

Normaliziranu mjeru relativne performanse koja se može koristiti za backtesting različitih vrsta imovine predložili su Blanco i Nihle:[105]

$$\rho = \begin{cases} \dfrac{r - VaR}{VaR} & akoje\ r\ < VaR\ \ ) \\ 0\ ako\ \ je\ r\ \geq VaR & \end{cases} \tag{4.4}$$

Predložena funkcija daje svakoj opservaciji gubitka u repu distribucije težinu jednaku gubitku u repu distribucije podijeljenom s VaR, odnosno mjera je normalizirana za VaR određene imovine. Referentna mjera je jednaka razlici između CVaR i VaR podijeljenoj s VaR. Ipak potencijalni problem postoji budući je VaR u nazivniku, stoga nije definiran ako je VaR 0. Može također dati nesuvisli odgovor ako je VaR blizu nule ili promjeni predznak.

[105] Blanco, C., Nihle, G. (1998): How good is Your VaR? Using backtesting to assess system performance, Financial Engineering News, August 1998

5. Izračun uvjetne rizičnosti vrijednosti (CVaR) dionica koje kotiraju na Zagrebačkoj burzi

5.1. Kretanje gospodarstva Hrvatske u razdoblju od 2006.-2014.g.

Između 1994. i 2008. hrvatsko gospodarstvo je iskazalo relativno visoke stope ekonomskog rasta. Jedan od glavnih pokretača rasta nacionalne ekonomije predstavljala je domaća potražnja, koja je u periodu između 2001. i 2008. rasla po stopi višoj od šest postotnih poena godišnje (odnosno brže od rasta BDP-a). Početkom 2008. problemi koji su nastali na tržištu nekretnina i s time povezanim drugorazrednim kreditima proširili su se i na ostatak gospodarstva SAD-a, a iz SAD-a i na ostatak svijeta. Krajem 2008. svjetska ekonomska kriza manifestirala se u Hrvatskoj, prvotno zaustavljanjem gospodarskog rasta, zatim smanjenjem proizvodnje i potrošnje, te naposljetku padom BDP-a. [106]

Prvi utjecaj financijske krize na zemlje s tržištima u nastajanju raširio se financijskim tržištima zajedno s povećanjem nesklonosti prema riziku. Tržišta dionica po cijelom svijetu obilježio je pad, a priljevi kapitala zemljama s tržištima u nastajanju su smanjeni. To je povećalo troškove inozemnog zaduživanja za mnoga tržišta u nastajanju unatoč tome što je ublažavanje monetarne politike koje su proveli FED i ECB dovelo do smanjenja kamata u zemljama s razvijenim tržištima. Povećanje troškova zaduživanja najsnažnije je bilo nakon rujna 2008. Suočena s rastućim troškovima zaduživanja, gospodarska aktivnost u Hrvatskoj počela se usporavati sredinom 2008. U Tablici 1 vidljivo je da su gospodarske aktivnosti dodatno usporene do kraja 2008. godine, a početkom 2009. započelo je razdoblje velike recesije. Ostvarena je dvoznamenkasta stopa smanjenja industrijske proizvodnje i maloprodaje na godišnjoj razini. Isto tako, rast BDP-a i osobne potrošnje usporen je u drugoj polovini 2008., a u prvoj polovici 2009. Hrvatska je ušla u recesiju. Sa širenjem financijske krize na realni sektor u razvijenim zemljama došlo je do smanjenja finalne potražnje. Stoga se od sredine 2008. počela smanjivati i potražnja za hrvatskim izvozom. To je dodatno utjecalo na već oslabljenu potražnju za gotovim i intermedijarnim proizvodima te se i robni uvoz smanjio. Zbog oslabljene domaće potrošnje uvoz je smanjen više nego izvoz, što je neznatno poboljšalo kronični manjak u robnoj razmjeni. U financijskom je sektoru, zahvaljujući

[106] Benolić M. (2012): Svjetska ekonomska kriza: razvoj, utjecaj na Republiku Hrvatsku i subjektivni stavovi studenata, Pravnik: časopis za pravna i društvena pitanja, (46) 2012, 1 (92), 119-137

mjerama HNB-a, zadržan nominalni godišnji rast domaćih kredita na oko 12% u posljednjih nekoliko godina. Ipak, od sredine 2008. odobravanje kredita stanovništvu gotovo je zaustavljeno, a rast ukupnih kredita privatnom sektoru dodatno usporen.

Tablica 1. Izabrani makroekonomski pokazatelji za razdoblje od 2006.-2014.g.

	2006	2007	2008	2009	2010	2011	2012	2013	2014
BDP,tekuće cijene (mil. HRK)	294.437	322.310	347.685	330.966	328.041	332.587	330.456	330.135	328.927
BDP, tekuće cijene (mil. USD)	50.424	60.065	70.461	62.679	59.644	62.241	56.480	57.859	57.211
BDP, po stanovniku, USD	11.350	13.530	15.880	14.150	13.500	14.540	13.240	13.600	13.480
BDP, realne stope rasta u %	4,8	5,2	2,1	-7,4	-1,7	-0,3	-2,2	-0,9	-0,4
INDUSTRIJSKA PROIZVODNJA stopa rasta u %	4,1	4,9	1,2	-9,2	-1,4	-1,2	-5,5	-1,8	1,2
Saldo VTR , mil. USD	-11.112,00	-13.474,90	-16.603,30	-10.728,90	-8.247,00	-9.350,70	-8.465,40	-9.190,40	-9.063,00
CIJENE, prosječna godišnja stope rasta u %	3,2	2,9	6,1	2,4	1,1	2,3	3,4	2,2	-0,2
PROMET U TRGOVINI NA MALO realne stope rasta u %	2,2	5,3	-0,5	-15,3	-1,8	1	-4,2	-0,6	0,4
NETO PLAĆA , u HRK	4.603	4.841	5.178	5.311	5.343	5.441	5.478	5.515	5.533
BROJ ZAPOSLENIH, godišnji prosjek	1.467.876	1.516.909	1.554.805	1.498.784	1.432.454	1.411.237	1.377.153	1.357.705	1.333.468
DEVIZNI PRIHOD OD TURIZMA, mil. EUR	6.293,30	6.752,60	7.459,40	6.379,70	6.230,00	6.616,90	6.858,70	7.202,80	7.402,30
DRŽAVNI PRORAČUN mil.HRK	95.235,60	108.320,60	115.772,70	110.257,90	107.466,40	107.069,70	109.558,90	108.585,00	114.044,50
KREDITI POSLOVNIH BANAKA stope rasta u %	23	14,2	14,5	2,2	7,2	6,1	-2,4	0,9	-3,1

Izvor: HGK (http://www.hgk.hr/sektor-centar/centar-makroekonomija/gospodarska-kretanja-122014)

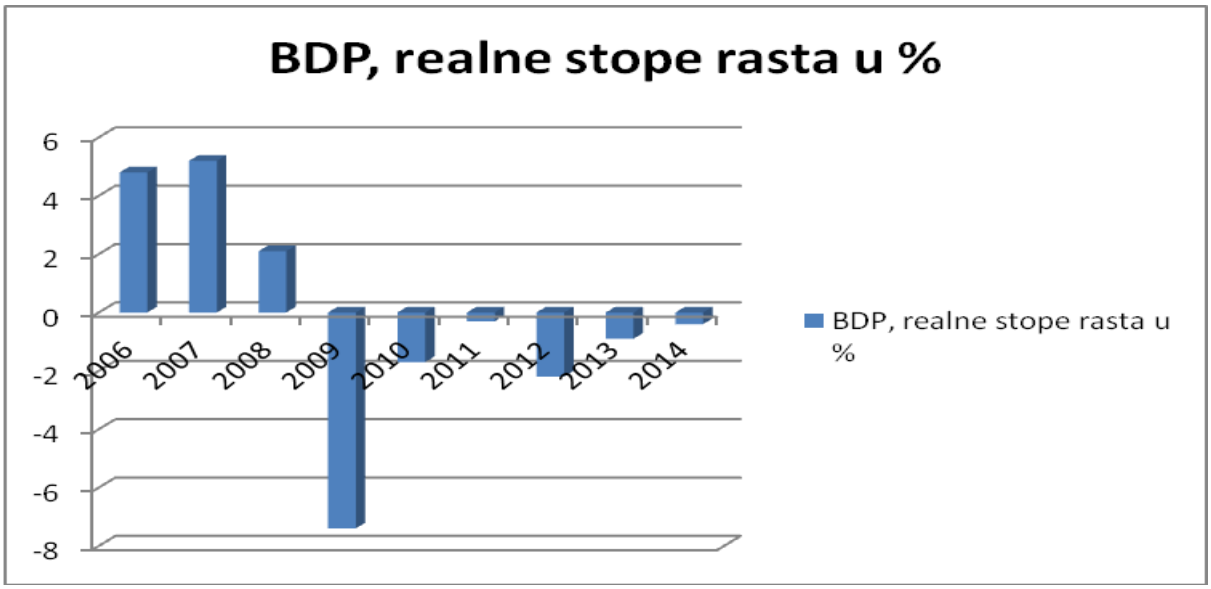
Rast cijena velikog broja dionica prije krize na Zagrebačkoj burzi bio je nerealan i potaknut rastom tržišta, a ne rastom vrijednosti samih tvrtki. Pad cijena za takve dionice predstavlja svođenje na njihovu stvarnu vrijednost. Crobex je tijekom razdoblja snažnog povećanja vrijednosti bio jedan od najbrže rastućih indeksa na svijetu što nije pratilo realni rast domaćeg gospodarstva i rast poslovnih rezultata domaćih tvrtki. Naime, godišnji rast prihoda od prodaje kompanija koje su sastavnice Crobexa u 2006. i 2007. godini iznosio je 8,91% odnosno 8,43%, a rast neto dobiti 13,35% odnosno 39,46%. Međutim, dionički indeks Crobex u isto vrijeme rastao je mnogo intenzivnije, 61% odnosno 63%. 12.10.2007. Crobex indeks je iznosio čak 5.355. [107]Takav rast dugoročno nije bio održiv, a ukazivao je na izrazito visoka i nerealna očekivanja u pogledu ostvarenja nadprosječnih budućih rezultata kompanija. Krajem 2007. godine počele su korekcije na burzi i mnogi ulagači počeli su sa rasprodajom svojih dionica i udjela u fondovima. Fondovi su počeli s rasprodajom najlikvidnijih dionica

[107] Matas, A. (2012): Aktualna svjetska financijska kriza i njene posljedice na Hrvatsku, diplomski rad, Ekonomski fakultet Split, Sveučilište u Splitu

zbog povlačenja udjela, a ponuda na burzi premašivala je potražnju i Crobex je počeo tonuti. 23.11.2007. Crobex je iznosio 4.685. Strani investitori počeli su povlačiti udjele zbog nesigurnosti. Do kraja 2007. godine Crobex se donekle oporavio i 27.12.2007. je iznosio 5.129, ali u 2008. godini pad se intenzivirao i počeo je padati sve intenzivnije, da bi 28.11.2008. iznosio 1.607. Mali investitori, veliki (institucionalni) i strani investitori koji su potpomognuti visokom likvidnošću i lako dostupnom novcu posljednjih godina neopravdano dizali cijene domaćih dionica u zonu precijenjenosti, strmoglavi pad cijena iskoristili su za povlačenje s burze. Većina dionica je postala nelikvidna i brojni investitori su postali žrtve klopke likvidnosti. Promet na burzi se prepolovio, prepolovila se burzovna kapitalizacija, a tržište je postalo vrlo volatilno. Nesigurnost na burzama smanjila je sklonost ulagača prema riziku, a investitori su povukli svoje uloge s burze. U ožujku 2009. godine Crobex je dotaknuo dno i zabilježio svoj minimum od 1.239 bodova. Do kraja iste godine Crobex se ponešto oporavio, popevši se na 2.004 boda.

Nakon 2009. godine usporile su se stope pada BDP-a, ali je 2014. godina šesta godina neprekidnog pada, zbog čega će realna vrijednost BDP-a biti oko 13% niža nego u pretkriznoj 2008. godini. Usporedba s drugim članicama EU-a pokazuje da je samo Grčka u istom razdoblju imala veći pad BDP-a, a po dužini krize ističu se još Portugal i Španjolska.

Grafikon 3. BDP u Hrvatskoj od 2006-2014, realne stope rasta



Izvor: HGK (http://www.hgk.hr/sektor-centar/centar-makroekonomija/gospodarska-kretanja-122014)

5.2. Zagrebačka burza

Burza vrijednosnih papira predstavlja organizirano tržište vrijednosnica. To je mjesto gdje se susreću kupci, posrednici te prodavatelji vrijednosnih papira. Na domaćim burzama se trguje državnim i korporacijskim obveznicama, dionicama i komercijalnim zapisima. Cijena se formira pod utjecajem ponude i potražnje za vrijednosnicama, a samo trgovanje je organizirano u skladu s pravilima burze i državnom regulacijom.[108]

Zagrebačka burza osnovana je 1907. godine, kada je savez industrijalaca i trgovaca Hrvatske i Slavonije otvorio Sekciju za robu i vrednote. Na burzi se trgovalo svakovrsnom robom, dionicama, mjenicama, stranim novcem, te plemenitim metalima. Kako se bližio Drugi svjetski rat, tako je značenje Zagrebačke burze opadalo u korist one Beogradske. Od godine 1945. pa sve do 1991., burza nije poslovala budući da kao špekulantska ustanova nije imala mjesta u socijalističkom društvu. Obnova Burze u Hrvatskoj uslijedila je tek 1991. godine, kada je 25 banaka i 2 osiguravajuća društva utemeljilo Zagrebačku burzu kao centralno mjesto trgovine vrijednosnim papirima u Republici Hrvatskoj. Tu funkciju Zagrebačka burza ima i danas. U samim počecima trgovalo se na velikim dražbama koje su organizirane u sjedištu Burze na Ksaveru i na kojima su svi brokeri bili fizički prisutni. 1994. godine, uveden je elektronički sustav trgovanja, koji je kasnije dodatno moderniziran. Koliko se brzo razvijalo dioničarstvo i burzovna trgovina u Hrvatskoj najbolje je vidljivo iz podatka da je u prvih pet godina nakon uvođenja elektroničkog sustava trgovanja, dakle od 1995. pa do 2000. godine, vrijednost tržišta Zagrebačke burze narasla gotovo 10 puta (982.6%). 2007. godine Zagrebačkoj se pripaja i Varaždinska burza, tako se formiralo jedinstveno tržište kapitala u Hrvatskoj.[109]

Zagrebačka burza jedina je hrvatska burza vrijednosnih papira te je jedna od najznačajnijih burzi vrijednosnih papira u Jugoistočnoj Europi. U financijskom izvješću Zagrebačke burze za 2014. godinu može se vidjeti da je na dan 31.12.2014. godine na Zagrebačkoj burzi kotiralo ukupno 179 dionica, ukupan redovni promet dionicama iznosio je 2,71 mlrd. HRK, a tržišna kapitalizacija, tj. ukupna vrijednost dionica kompanija koje su kotirale na burzi iznosila je 126,22 mlrd. HRK

[108] http://limun.hr/main.aspx?id=12382
[109] http://zse.hr/default.aspx?id=26

5.2.1 Indeksi na Zagrebačkoj burzi

Burzovni indeks skup je pomno odabranih vrijednosnih papira koji predstavljaju čitavo tržište.[110] Na Zagrebačkoj burzi postoje dvije vrste indeksa: dionički i obveznički.
Dionički indeksi zagrebačke burze su:[111]

1. CROBEX – službeni je indeks Zagrebačke burze. Počeo se objavljivati 1. rujna 1997. godine. Bazni datum je 1. srpnja 1997. godine, a bazna vrijednost je 1000. Prilikom odabira dionica koje će ući u sastav indeksa CROBEX®, u obzir se uzimaju samo dionice uvrštene na uređeno tržište kojima se trgovalo više od 80% ukupnog broja trgovinskih dana u šestomjesečnom razdoblju koje prethodi reviziji. Ako je podnesen prijedlog za otvaranje postupka predstečajne nagodbe, stečajnog postupka ili postupka likvidacije nad izdavateljem, dionice ne mogu ući u sastav indeksa CROBEX®. Rang svake dionice koja ispunjava navedene uvjete određuje se na osnovi dva kriterija:
a) udjel u free float tržišnoj kapitalizaciji
b) udjel u prometu ostvarenom unutar knjige ponuda u šestomjesečnom razdoblju koje prethodi reviziji
Svakom od navedenih kriterija pripisuje se težina 50% te se izračunava srednjak udjela odnosno vagani tržišni udjel. U sastav indeksa CROBEX® ulazi 25 dionica s najvećim srednjakom udjela. Ako izdavatelj ima više rodova dionica koje ispunjavaju uvjete za ulazak u sastav indeksa CROBEX®, u indeks će se uključiti samo jedan rod dionica i to onaj s većim rangom.
Indeks CROBEX® se računa kao omjer free float tržišne kapitalizacije i free float tržišne kapitalizacije na bazni datum. Free float tržišna kapitalizacija određene dionice računa se kao umnožak broja izdanih dionica, free float faktora i zadnje cijene dionice. Udjel free float tržišne kapitalizacije pojedine dionice u ukupnoj tržišnoj kapitalizaciji indeksa CROBEX®, na dan redovne revizije, ne može preći 10%.

[110] http://www.ericsson.com/hr/etk/novine/kom0906/trziste_kapitala.shtml
[111] http://zse.hr/default.aspx?id=43538

Indeks se računa kontinuirano tijekom trgovine prema sljedećoj formuli:[112]

$$I_t^j = \frac{\sum_{i=1}^{n} p_{i,t}^j . q_{i,T} \cdot f_{i,T}}{K_T . \sum_{i=1}^{n} p_{i,T} . q_{i,T} . f_{i,T}} \cdot B \qquad (5.1)$$

I_t^j - vrijednost indeksa CROBEX® na dan t i vrijeme j

$p_{i,t}^j$ - zadnja cijena dionica i na dan t i vrijeme j

$q_{i,T}$ - broj izdanih dionica i ili njihov dio na dan revizije T

$f_{i,T}$ - free float faktor dionica i na zadnji dan mjeseca koji prethodi danu revizije T

B - bazna vrijednost indeksa, iznosi 1000 na dan 1. srpnja 1997. g.

$p_{i,T}$ - zadnja cijena dionica i na bazni datum ili na dan koji prethodi uključenju u indeks CROBEX® (u slučaju da su uključene kasnije)

K_T - koeficijent prilagođavanja baze indeksa na dan revizije T

2. CROBEX10 – u sastav indeksa ulazi 10 dionica s najvećim srednjakom udjela, a da pritom jedan dioničar ne smije imati više od 75% udjela u temeljnom kapitalu društva. Računa se na isti način kao i CROBEX. Udio free float tržišne kapitalizacije pojedine dionice u ukupnoj tržišnoj kapitalizaciji indeksa ne može preći 20%.[113]

3. CROBEXplus – u sastav navedenog indeksa ulaze dionice uvrštene na uređeno tržište koje zadovoljavaju sljedeća dva kriterija: broj trgovinskih dana veći od 70% ukupnog broja trgovinskih dana, te free float tržišna kapitalizacija mora biti veća od 10 milijuna kuna. Indeks Crobexplus i sektorski indeksi su indeksi u kojem svaka dionica ima jednaku težinu. Indeks CROBEXplus, kao i ostali sektorski indeksi koji će se naknadno spomenuti računaju se prema sljedećoj formuli:[114]

$$I_t = I_{t-1} \cdot \frac{1}{n} \sum_{i=1}^{n} \frac{p_{i,t}}{p_{i,t-1}} \qquad (5.2)$$

[112] http://zse.hr/default.aspx?id=44101&index=CROBEX
[113] http://zse.hr/default.aspx?id=44101&index=CROBEX10
[114] http://zse.hr/default.aspx?id=44101&index=CROBEXplus

I_t- vrijednost indeksa na dan t

I_{t-1}- vrijednost indeksa na dan t-1

$p_{i,t}$ - zadnja cijena dionica i na dan t

$p_{i,t-1}$ - zadnja cijena dionica i na dan t-1

n – broj dionica u sastavu indeksa

I_0 - bazna vrijednost indeksa, iznosi 1000 na dan 21. veljače 2013.g.

4. Sektorski indeksi Zagrebačke burze:

Da bi pojedina dionica ušla u sastav sektorskog indeksa, ona mora biti uključena u indeks CROBEXplus. Izračunavaju se na jednak način kao i indeks CROBEXplus. Sljedećih pet indeksa ubrajamo u sektorske indekse Zagrebačke burze:[115]

- CROBEXnutris – Proizvodnja i prerada hrane
- CROBEXindustrija – Industrijska proizvodnja
- CROBEXkonstrukt – Građevnarstvo
- CROBEXtransport – Transport
- CROBEXturist – Turizam

5. CROBEXtr – postojeći indeks CROBEX ne uzima u obzir prinos od isplate dividende dionica u njegovom sastavu, već isključivo prati promjenu cijene dionica. Za razliku od njega novi indekse CROBEXtr je indeks ukupnog prinosa, koji uključuje i isplatu dividende dionica iz svog sastava. Predstavlja tzv. Market capitalization weighted indeks, u kojem će težina svake dionice biti određena sukladno njenoj tržišnoj kapitalizaciji. Ovo je ujedno i najnoviji indeks, koji se počeo objavljivati 24. veljače 2014. Bazna vrijednost mu je 1000, na dan 21. veljače 2014. godine. Ovaj indeks daljnji je korak u nastojanju Zagrebačke burze da ulagateljima ponudi veći broj obradivih podataka kako bi im omogućila lakše donošenje investicijskih odluka.

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

Računa se prema sljedećoj formuli:[116]

$$I_t^j = \frac{\sum_{i=1}^{n}(p_{i,t}^j + d_{i,t}) \cdot q_{i,r} \cdot f_{i,r}}{K_r \cdot \sum_{i=1}^{n} p_{i,r} \cdot q_{i,r} \cdot f_{i,r}} \cdot B \qquad (5.3)$$

I_t^j - vrijednost indeksa CROBEXtr na dan t i vrijeme j

$p_{i,t}^j$ - zadnja cijena dionica i na dan t i vrijeme j

$d_{i,t}$ - dividenda dionica i na dan t ili u razdoblju od prethodne revizije

$q_{i,r}$ - broj izdanih dionica i ili njihov dio na dan revizije T

$f_{i,r}$ - free float faktor dionica i na zadnji dan mjeseca koji prethodi danu revizije T

B - bazna vrijednost indeksa, iznosi 1000 na dan 1. srpnja 1997. g.

$p_{i,r}$ - zadnja cijena dionica i na bazni datum ili na dan koji prethodi uključenju u indeks CROBEX® (u slučaju da su uključene kasnije)

K_r - koeficijent prilagođavanja baze indeksa na dan revizije T

5.3. Opis uzorka

Likvidnost dionice je glavni kriterij pri formiranju početnog uzorka dionica. Likvidnost dionice bi u pravilu trebala osigurati fer vrednovanje same dionice, jer veliki broj transakcija, barem u teoriji, osigurava konvergenciju cijene dionice ka ravnotežnoj cijeni ponude i potražnje, koje su pak uvjetovane tržišnim silama i očekivanjima investitora. Likvidnost dionice je bitna jer se u radu računaju dnevni prinosi dionica te je za ispravnost rezultata bitno da se s dionicama aktivno trguje.

Sukladno tome pri odabiru dionica u uzorak krenulo se od dionica uvrštenih u indeks Crobex plus na dan 14.08.2015.g. Uvjet za uvrštenje dionice u indeks Crobex plus je 70% dana trgovanja i free float tržišna kapitalizacija > 10 mil HRK. Na dan 14.08.2015.g. indeks se sastojao od 41 dionice. Uz navedene dionice u uzorak je uvršteno i 12 dionica čiji promet je u 2014.g. prelazio 10 milijuna kuna, te se početni uzorak sastojao od 53 dionice navedene u tablici 2.

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

Tablica 2. Dionice izabrane u uzorak

R.b.	Simbol	Izdavatelj	R.b.	Simbol	Izdavatelj
1	ADPL-R-A	AD Plastik d.d.	28	LKPC-R-A	Luka Ploče d.d.
2	ADRS-P-A	Adris grupa d.d.	29	LKRI-R-A	Luka Rijeka d.d.
3	ARNT-R-A	Arenaturist d.d.	30	LPLH-R-A	Lošinjska plovidba - holding d.d.
4	ATGR-R-A	Atlantic Grupa d.d.	31	LRH-R-A	Liburnia Riviera Hoteli d.d.
5	ATLN-R-A	Excelsa nekretnine d.d.	32	MAIS-R-A	Maistra d.d.
6	ATPL-R-A	Atlantska plovidba d.d.	33	OPEK-R-A	Opeka d.d.
7	BLJE-R-A	Belje d.d.	34	OPTE-R-A	OT-Optima Telekom d.d.
8	CKML-R-A	Čakovečki mlinovi d.d.	35	PBZ-R-A	Privredna banka Zagreb d.d.
9	CROS-R-A	Croatia osiguranje d.d.	36	PLAG-R-A	Plava laguna d.d.
10	DDJH-R-A	Đuro Đaković Holding d.d.	37	PODR-R-A	Podravka d.d.
11	DLKV-R-A	Dalekovod d.d.	38	PTKM-R-A	Petrokemija d.d.
12	ERNT-R-A	Ericsson Nikola Tesla d.d.	39	RIVP-R-A	Valamar Riviera d.d.
13	HIMR-R-A	Imperial d.d.	40	RIZO-R-A	RIZ-odašiljači d.d.
14	HMST-R-A	Hoteli Maestral d.d.	41	SAPN-R-A	Saponia d.d.
15	HT-R-A	Hrvatski Telekom d.d.	42	SNHO-R-A	SN Holding d.d.
16	HUPZ-R-A	HUP - Zagreb d.d.	43	THNK-R-A	Tehnika d.d.
17	IGH-R-A	Institut IGH d.d.	44	TUHO-R-A	Turisthotel d.d.
18	INA-R-A	INA-industrija nafte d.d.	45	ULPL-R-A	Uljanik Plovidba d.d.
19	INGR-R-A	Ingra d.d.	46	VART-R-1	Varteks d.d.
20	JDBA-R-A	Jadranska banka d.d.	47	VDKT-R-A	Viadukt d.d.
21	JDPL-R-A	Jadroplov d.d.	48	VERN-R-A	Genera d.d.
22	JDRA-R-A	Jadranka d.d.	49	VIRO-R-A	Viro tvornica šećera d.d.
23	JMNC-R-A	Jamnica d.d.	50	VLHO-R-A	Valamar grupa d.d.
24	KOEI-R-A	Končar - Elektroindustrija d.d.	51	VPIK-R-A	Vukovarski poljoprivredno industrijski kombinat d.d.
25	KORF-R-A	Valamar Adria Holding d.d.	52	ZABA-R-A	Zagrebačka banka d.d.
26	KRAS-R-A	Kraš d.d.	53	ZVZD-R-A	Zvijezda d.d.
27	LEDO-R-A	Ledo d.d.			

Izvor: prikaz autora

Budući da se dionice promatraju u 3 vremenska perioda: u periodu od 2006.-2007 g., u periodu od 2008-2009.g. te u periodu od 2013-2014.g. iz početnog uzorka isključene su dionice koje nisu zadovoljavale uvjet da imaju podatke o cijeni dionica za svaki od 24 mjeseca u svakom od tri vremenska perioda (ATGR-R-A, ATLN-R-A, HIMR-R-A, HMST-R-A, HT-R-A, INA-R-A, OPTE-R-A, PLAG-R-A, RIVP-R-A, RIZO-R-A, VART-R-A, VERN-R-A, VPIK-R-A, VIRO-R-A, JDBA-R-A, JDRA-R-A, JMNC-R-A, KORF-R-A, SAPN-R-A, OPEK-R-A,VLHO-R-A).

Iz uzorka su također isključene dionice kod kojih je došlo do podjele dionica i smanjenja nominalne vrijednosti dionice (INGR-R-A, ZABA-R-A) jer je u tom slučaju došlo do ekstremnih vrijednosti izračunatih prinosa što daje krivu sliku o rizičnosti pojedinog sektora.

Po isključenju navedenih dionica uzorak se sastoji od 30 dionica podijeljenih u 9 sektora. Budući da se sektor telekomunikacija sastojao od samo jedne dionice ERNT-R-A on je isključen iz uzorka te je u finalnom uzorku ostalo 29 dionica podijeljenih u 8 sektora.

Kompanije dijelimo po sektorima ovisno o tome koja je njihova glavna djelatnost. Međutim, često se događa da kompanije u svoje statute uključe jako veliki broj različitih djelatnosti kako bi bile što fleksibilnije u svom poslovanju, tim više što svaka promjena djelatnosti iziskuje odobrenje skupštine dioničkog društva, te promjenu statuta, što je svakako dugotrajan, a ponekad i skup proces. Stoga kompanije preventivno uključuju mnoge djelatnosti u svoje statute, čak iako znaju da se neće tako skoro tim djelatnostima baviti. Zbog toga je ponekad teško jasno razlučiti osnovnu djelatnost s obzirom da u statutima postoji jako veliki broj navedenih djelatnosti kompanija. U načelu, ako postoji dvojba, kompanija se svrstava u onaj sektor u kojem ostvaruje najveći prihod od prodaje, odnosno najveći prihod od poslovanja općenito. Tim načelom se vodilo pri klasifikaciji kompanija iz početnog uzorka.

Državni zavod za statistiku provodi svoju sektorsku klasifikaciju, međutim ona je sklona vrlo detaljnim podjelama na podsektore i nije prikladna za primjenu kod relativno malih uzoraka kao što je naš. Osim toga, ta je podjela osmišljena prvenstveno za statističke svrhe i zbog toga zanemaruje neka načela koja se koriste za klasifikaciju u financijskoj industriji.

Sektorska podjela je u ovom slučaju obavljena prema „Global Industry Classification Standard“-u (GICS)[117] koji su razvili investicijska kompanija Morgan Stanley Capital International i bonitetna kuća Standard & Poor’s i kojim se koriste na razvijenim tržištima kapitala. Taj standard dijeli kompanije po glavnim djelatnostima na 10 sektora, 24 industrijske grupe, 68 industrija i 154 pod-industrije.

Za formiranje osnovnih kategorija koristilo se kombinacijom GICS-ovih sektora i industrijskih grupa. Takva podjela je bila nužna s obzirom da Republika Hrvatska nema razvijene sektore informatičkih tehnologija, farmacije i biotehnologije, te materijala (osim papira i cementa), dok su neke industrijske grupe (niža hijerarhijska razina) od strateške važnosti i praktično na razini najviših sektora, primjerice turizam i hotelijerstvo, poljoprivreda, i brodski transport. Kao dodatni sektor uvedena je i kategorija „Diverzificirano“ gdje se nalaze holding kompanije koje imaju značajne i ravnopravne prihode iz više različitih sektora, te ih je teško svrstati u jedan od standardnih sektora. Primjeri takvih kompanija su Adris grupa d.d. koja se bavi

[117] https://www.msci.com/gics

turizmom, duhanskom i prehrambenom industrijom, te SN Holding d.d.koji se bavi turizmom, i energetikom.

Sukladno tome imamo 8 osnovnih sektora po kojima dijelimo 29 kompanija iz uzorka: Diversificirano, Financijske usluge, Građevina, Hotelijerstvo i turizam, Industrija, Poljoprivreda, Prehrana i maloprodaja, Telekomunikacije i Transport.

Kompanije iz uzorka su razvrstane po sektorima, a podjela je prikazana u slijedećoj tablici:

Tablica 3. Dionice iz uzorka razvrstane prema sektorskoj pripadnosti

Sektor	Dionica	Sektor	Dionica
Diversificirano (2)	ADRS-P-A		DDJH-R-A
	SNHO-R-A		PTKM-R-A
Financijske usluge (2)	CROS-R-A	Poljoprivreda (2)	BLJE-R-A
	PBZ-R-A		CKML-R-A
Građevina (4)	DLKV-R-A	Prehrana i maloprodaja (4)	KRAS-R-A
	IGH-R-A		PODR-R-A
	THNK-R-A		LEDO-R-A
	VDKT-R-A		ZVZD-R-A
Hotelijerstvo i turizam (5)	ARNT-A	Transport (6)	ATPL-R-A
	LRH-R-A		LKPC-R-A
	HUPZ-R-A		JDPL-R-A
	MAIS-R-A		LKRI-R-A
	TUHO-R-A		ULPL-R-A
Industrija (4)	KOEI-R-A		LPLH-R-A
	ADPL-R-A		

Izvor: Prikaz autora

Podatke o cijenama dionica podijelili smo u tri perioda. Prvi period odnosi se na vremensko razdoblje od 2006. do 2007.g. koje je obilježeno gospodarskim rastom u Hrvatskoj. Slijedeći period odnosi se na razdoblje financijske krize: 2008.g. koja je obilježena velikim padom poslovanja na Zagrebačkoj burzi te 2009.g. obilježenu značajnim padom gospodarske aktivnosti u Hrvatskoj. Zadnji period se odnosi na razdoblje od 2013. do 2014.g. koje je obilježeno dugotrajnom stagnacijom gospodarstva u Hrvatskoj.

Ovisno o broju radnih dana, razdoblje promatranja u pojedinom vremenskom periodu iznosi: 499 dana za razdoblje od 2006.-2007., 502 dana za razdoblje od 2008.-2009. i 499 dana za razdoblje od 2013.-2014. godine.

5.4. Metodologija istraživanja

Prilikom izračuna vrijednosti VaR i CVaR primijenjena je povijesna metoda budući da je pogodnija za primjenu od parametarske metode na tržištima kapitala zemalja u tranziciji. Razlozi za ovaj navod leže u volatilnosti dionica, promjenjivosti korelacije između dionica, te činjenici da tržišni indeksi zemalja u tranziciji pokazuju veću asimetričnost i zaobljenost u odnosu na normalnu raspodjelu.

Prilikom izračun CVaR povijesnom metodom prvo je potrebno prikupiti podatke o kretanjima cijena vrijednosnica razvrstanih po pojedinom sektoru za svaki dan u svakom periodu. U sljedećoj tablici nalaze se podaci o kretanjima dionica razvrstanih u sektor Industrija za period od 2006-2007.g. Isti podaci prikupljeni su i za ostale dionice u preostalih 7 sektora za svako vremensko razdoblje.

Tablica 4: Povijesne promjene vrijednosti dionica sektora industrije za razdoblje 2006.-2007.g.

	ADPL-R-A	KOEI-R-A	DDJH-R-A	PTKM-R-A
31.12.2007	223,86	1.229,89	223,68	289,68
28.12.2007	220,81	1.240,88	219,69	284,31
27.12.2007	217,19	1.240,08	220,61	283,61
24.12.2007	219,11	1.200,78	219,65	280,15
21.12.2007	219,11	1.200,78	219,65	280,15
20.12.2007	218,93	1.183,36	218,47	275,68
19.12.2007	216,74	1.169,16	218,31	280,85
18.12.2007	212,69	1.134,01	214,49	272,71
…	…	…	…	…
12.1.2006	100,04	285,01	95,27	114,35
11.1.2006	100,17	283,31	95,27	110,12
10.1.2006	108,73	288,41	95,27	109,99
9.1.2006	108,73	285,94	95,27	110,25
5.1.2006	101,66	283,25	95,27	109,95
4.1.2006	106,22	282,5	95,27	110,00
3.1.2006	109,07	280,81	95,27	109,52
2.1.2006	109,96	288,89	95,27	110,17

Izvor: Izračun autora

Budući da se u radu računa jednodnevni CVaR, koristimo podatke o promjenama cijena svakog radnog dana, te samim time, računamo dnevne prinose dionica.

Kontinuirani dnevni prinosi računaju se sljedećom formulom:

$$\mathrm{R_x(t)} = \ln\left(\frac{P_x(t)}{P_x(t-1)}\right) \tag{5.4}$$

Gdje je:

$R_x(t)$ - prinos dionice X na dan t

$P_x(t)$ - cijena dionice X na dan t

$P_x(t-1)$ - cijena dionice X na dan t-1

Budući da se nije svim dionicama svaki radni dan trgovalo, za dane kada se pojedinom dionicom nije trgovalo, a ostalima jest, pretpostavili smo da je cijena dionice jednaka njenoj cijeni iz prethodnog dana.

Tablica 5: Prinosi dionica sektora industrije za razdoblje 2006.-2007.g.

	ADPL-R-A	KOEI-R-A	DDJH-R-A	PTKM-R-A
31.12.2007	0,01372	-0,00890	0,01800	0,01871
28.12.2007	0,01653	0,00064	-0,00418	0,00247
27.12.2007	-0,00880	0,03220	0,00436	0,01227
24.12.2007	0,00000	0,00000	0,00000	0,00000
21.12.2007	0,00082	0,01461	0,00539	0,01608
20.12.2007	0,01005	0,01207	0,00073	-0,01858
19.12.2007	0,01886	0,03053	0,01765	0,02941
18.12.2007	0,00566	0,02135	-0,00845	0,00018
…	…	…	…	…
12.1.2006	-0,00130	0,00598	0,00000	0,03769
11.1.2006	-0,08200	-0,01784	0,00000	0,00118
10.1.2006	0,00000	0,00860	0,00000	-0,00236
9.1.2006	0,06723	0,00945	0,00000	0,00272
5.1.2006	-0,04388	0,00265	0,00000	-0,00045
4.1.2006	-0,02648	0,00600	0,00000	0,00437
3.1.2006	-0,00813	-0,02837	0,00000	-0,00592

Izvor: Izračun autora

Slijedeći korak je izračunati prinos sektora industrije koji se računa kao prinos portfelja sastavljenog od 4 vrijednosnice s jednakim udjelima u portfelju, u ovom slučaju 25%.

Tablica 6. Prinos sektora Industrija za razdoblje od 2006.-2007.g.

Datum	Prinos sektora
31.12.2007	0,01038
28.12.2007	0,00387
27.12.2007	0,01001
24.12.2007	0,00000
21.12.2007	0,00923
20.12.2007	0,00107
19.12.2007	0,02411
18.12.2007	0,00468
…	…
12.1.2006	0,01059
11.1.2006	-0,02466
10.1.2006	0,00156
9.1.2006	0,01985
5.1.2006	-0,01042
4.1.2006	-0,00403
3.1.2006	-0,01060

Izvor: Izračun autora

Prinos sektora je izračunat pomoću korištenja funkcije u Excelu SUMPRODUCT (udijeli dionica;kontinuirani prinos dionica).

Kada bi pretpostavili da imamo ulog u portfelj dionica sektora industrije od 1.000.000,00 kuna, odnosno ulog u svaku pojedinu dionicu sektora od 250.000,00 kuna i pomnožili prinose pojedinih vrijednosnica, s planiranim ulogom u njih, te isto učinili za portfelj, dobili bi slijedeću distribuciju dobitaka i gubitaka prikazanu u tablici 7.

Tablica 7. Distribucija dobitaka i gubitaka dionica i sektora Industrije za razdoblje 2006.-2007.

	ADPL-R-A	KOEI-R-A	DDJH-R-A	PTKM-R-A	Sektor
31.12.2007	3.429,56	-2.224,02	4.499,75	4.677,92	10.383,21
28.12.2007	4.132,51	161,23	-1.044,74	616,28	3.865,28
27.12.2007	-2.200,34	8.051,14	1.090,27	3.068,72	10.009,79
24.12.2007	0,00	0,00	0,00	0,00	0,00
21.12.2007	205,46	3.653,37	1.346,67	4.021,10	9.226,60
20.12.2007	2.513,39	3.018,08	183,16	-4.644,99	1.069,64
19.12.2007	4.715,69	7.631,38	4.413,24	7.352,94	24.113,25
18.12.2007	1.414,50	5.336,49	-2.112,36	45,84	4.684,47
…	…	…	…	…	…
12.1.2006	-324,66	1.495,64	0,00	9.423,31	10.594,29
11.1.2006	-20.499,75	-4.460,34	0,00	295,31	-24.664,79
10.1.2006	0,00	2.150,27	0,00	-590,27	1.560,00
9.1.2006	16.808,46	2.363,02	0,00	681,20	19.852,68
5.1.2006	-10.969,63	662,84	0,00	-113,66	-10.420,45
4.1.2006	-6.619,37	1.500,07	0,00	1.093,30	-4.026,00
3.1.2006	-2.031,70	-7.091,93	0,00	-1.479,36	-10.602,99

Izvor: Izračun autora

Slijedeći korak je sortiranje distribucije gubitaka i dobitaka od najvećeg do najmanjeg iznosa. Budući za razdoblje od 2006.-2007. imamo izračunatih 499 gubitaka/dobitaka da bi izračunali CVaR 95% iz distribucije prinosa izdvajamo 5% najlošijih rezultata. 5% od 499 je 24,95 što znači da gledamo 25 najlošijih rezultata u distribuciji te iz njih izračunavamo aritmetičku sredinu pomoću funkcije u Excelu AVERAGE. Osim CVaR iz distribucije gubitaka i dobitaka možemo izračunati i VaR primjenom funkcije u Excelu PERCENTILE (distribucija dobitaka i gubitaka; α). Za portfelj vrijednosti 1.000.000,00 kn uložen u dionice sektora industrije dobivamo slijedeće vrijednosti CVaR i VaR uz razinu pouzdanosti od 95%:

Tablica 8. VaR i CvaR dionica i sektora industrije za razdoblje od 2006.-2007.g.

	ADPL-R-A	KOEI-R-A	DDJH-R-A	PTKM-R-A		Portfelj
VaR 95%	-8.392,31	-5.474,34	-9.127,10	-7.158,19		-21.158,12

	ADPL-R-A	KOEI-R-A	DDJH-R-A	PTKM-R-A		Portfelj
CVaR 95%	-10.981,03	-8.858,43	-17.595,86	-12.111,44		-30.866,96

Izvor: Izračun autora

VaR u razdoblju od 2006.-2007. iznosi 21.158,12 HRK, a objašnjava se na sljedeći način; ako uložimo 1.000.000,00 HRK u portfelj koji se sastoji od po 25% svake dionice sektora industrije, s 95%-tnom sigurnošću možemo reći da naš gubitak u sljedećem danu neće premašiti 21.158,12 HRK. CVaR u razdoblju od 2006.-2007. iznosi 30.866,96 HRK što znači ako dođe do ekstremnog događaja i ostvari se 5% najgorih slučajeva očekivani gubitak portfelja iznosi 30.866,96 kuna.

Navedeni postupak je ponovljen za svaku dionicu te za svaki sektor za sva tri vremenska razdoblja promatranja.

5.5. Rezultati i analiza kvantitativnog istraživanja

Pregled rezultata kvantitativnog istraživanja dan je u tablici 9.

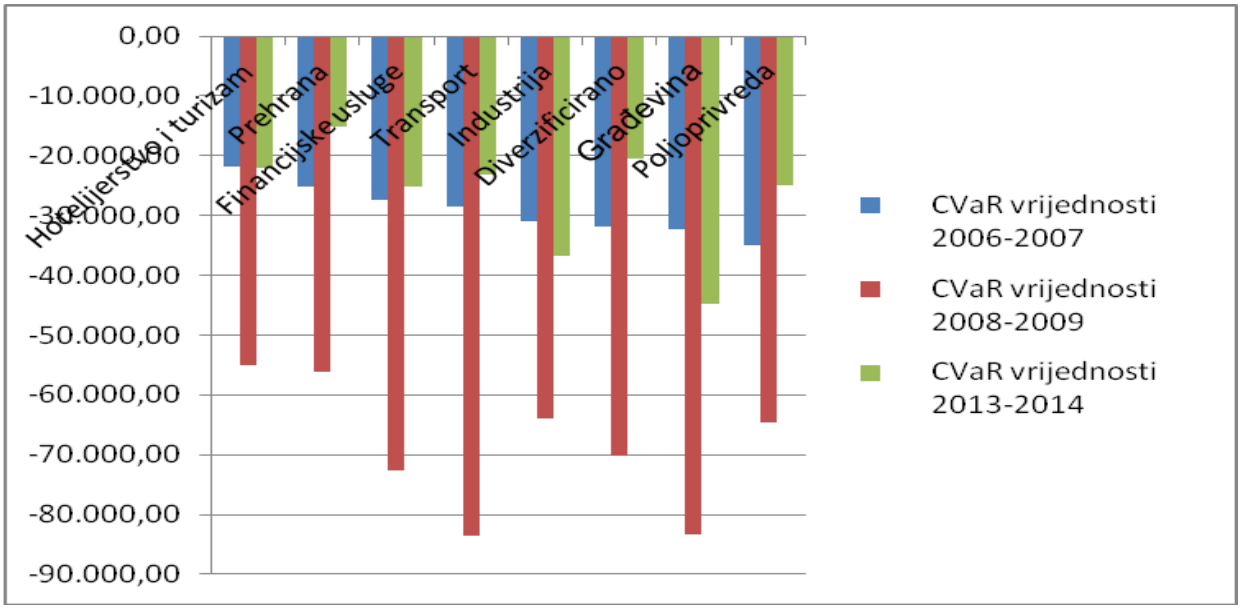
Tablica 9. Prikaz CVaR vrijednosti pojedinih sektora u 3 vremenska razdoblja promatranja

Sektor/ Razdoblje	CVaR vrijednosti		
	2006.-2007.	2008.-2009.	2013.-2014.
Hotelijerstvo i turizam	-22.080,46	-55.066,54	-19.280,08
Prehrana i maloprodaja	-25.058,82	-47.510,34	-15.122,48
Financijske usluge	-27.429,24	-72.650,05	-25.170,92
Industrija	-30.866,96	-64.010,66	-36.846,59
Transport	-31.719,01	-84.045,53	-23.200,82
Diversificirano	-31.756,28	-70.095,85	-20.475,90
Građevina	-32.271,37	-83.276,05	-44.780,10
Poljoprivreda	-35.064,61	-64.010,66	-24.991,52

Izvor: Izračun autora

Iz tablice 9. je primjetan značajan rast CVaR vrijednosti svih sektora u razdobljima kriznih godina u odnosu na razdoblje rasta te zatim ponovno smanjivanje vrijednosti CVaR u razdoblju stagnacije. Navedeno je prikazano i na slijedećem grafikonu.

Grafikon 4. CVaR vrijednosti pojedinih sektora u 3 vremenska razdoblja promatranja



Izvor: Prikaz autora

Slijedeći korak u razmatranju rizičnosti sektora je da su sektori rangirani od najvećeg do najmanjeg na način da je najmanje rizičnom sektoru u kontekstu CVaR dat rang 1, a najrizičnijem 8. Osim što svi sektori pokazuju nominalno povećanje CVaR primjetna je i promjena u rangu pojedinih sektora što je prikazano u slijedećoj tablici 10.

Tablica 10. Prikaz sektora s dodijeljenim CVaR rangom u tri razdoblja promatranja

	CVaR rang			Promjena u CVaR rangu		
Sektor	2006.-2007.	2008.-2009.	2013.-2014.	2008.-2009./ 2006.-2007.	2013.-2014./ 2008.-2009.	2013.-2014./ 2006.-2007.
Hotelijerstvo i turizam	1	2	2	-1	0	-1
Prehrana i maloprodaja	2	1	1	1	0	1
Financijske usluge	3	6	6	-3	0	-3
Industrija	4	3	7	1	-4	-3
Transport	5	8	4	-3	4	1
Diversificirano	6	5	3	1	2	3
Građevina	7	7	8	0	-1	-1
Poljoprivreda	8	4	5	4	-1	3

Izvor: izračun autora

Sektori koji su imali najveće negativne pomake u razdoblju krize su: Transport, Financijske usluge i Hotelijerstvo i turizam. Sektori koji su bili najmanje zahvaćeni krizom, odnosno pokazali su pozitivan pomak, u razdoblju od 2008.-2009. su: Poljoprivreda, Prehrana i maloprodaja, Industrija i Diversificirano. Sektor koji nije imao nikakav pomak u smislu ranga je Građevina.

Uspoređujući razdoblje stagnacije 2013.-2014. i razdoblje krize primjećuje se da je došlo do negativnih pomaka kod dva sektora koja su prethodnom razdoblju imala rast ranga: Industrija i Poljoprivreda dok je Građevina imala daljnji pad ranga te je u razdoblju 2013-2014.g. bila najrizičniji sektor u kontekstu CVaR. Pozitivne pomake u smislu ranga imao je sektor Transporta i Diversificirano dok pomaka u rangu nije bilo kod sektora: Hotelijerstva i turizma, Prehrane i maloprodaje i Financijskih usluga.

Može se primijetiti da su dva sektora najmanje rizična u svakom od 3 perioda, naime Hotelijerstvo i turizam i Prehrana i maloprodaja uvijek su na prva 2 mjesta po rangu najmanje rizičnih sektora. Sektori koji su se pokazali najviše pogođenima u vremenima krize su Transport te Financijske usluge.

U razdoblju stagnacije došlo je do pozitivnih pomaka kod sektora Transporta i Diversificirano, ali negativnih pomaka kod Industrije i Građevine koja je u svim periodima na začelju kao jedan od rizičnijih sektora u kontekst CVaR.

Uspoređujući početno razdoblje promatranja 2006.-2007.g. koje je bilo obilježeno pozitivnim rastom gospodarstva u odnosu na razdoblje 2013.-2014.g. primjećuje se da je na vrhu došlo do zamjene ranga između Hotelijerstva i turizma i Prehrane i maloprodaje.

Sektori koji su pokazali pozitivan pomak u smislu ranga u odnosu na razdoblje 2006.-2007.g. su Poljoprivreda, Diversificirano i Transport dok su negativan pomak imale Financijske usluge, Industrija i Građevina.

6. Usporedba i testiranje točnosti dobivenih rezultata

Unatoč bliskoj teoretskoj vezi s VaR, backtesting napravljen za VaR ne može se koristiti direktno za backtesting CVaR. U ovom primjeru backtesting CVaR napravljen je na način da je određena funkcija gubitka ρ koja izračunati CVaR uspoređen sa stvarnim prinosom r u slučajevima gdje r premašuje VaR:

$$\rho = \begin{cases} r \; ako \; je \; r < VaR \\ 0 \; ako \; je \; r \geq VaR \end{cases} \qquad (6.1)$$

Funkcija daje svakoj opservaciji gubitka u repu ponder (težinu) 1, a pripadajuća referentna vrijednost je jednostavno CVaR.

Primjer backtestinga CVaR pokazati ćemo na primjeru sektora Industrije u razdoblju od 2006.-2007.g.

Backtesting je rađen na osnovi 80 zadnjih godišnjih prinosa portfelja, odnosno za prinose portfelja od 13.10.2007.-31.12.2007. Svaki prinos uspoređen je s VaR sektora industrije izračunatim uz nivo pouzdanosti od 95% za razdoblje od 2006.-2007.g. koji je iznosio -21.158,12. U slučaju da je prinos veći ili jednak VaR opservaciji je dana vrijednost 0, a u slučaju da je manji od VaR zabilježena je njegova vrijednost. Od ukupno 80 prinosa njih 5 je premašivalo VaR te je od 5 prinosa koji su premašivali VaR izračunata aritmetička sredina.

Skraćeni rezultati prikazani su u Tablici 11.

Tablica 11. Backtesting CVaR za sektor Industrije u razdoblju od 2006.-2007.

R.b.	Prinos portfelja - r	VaR	ρ
1	10.383,21	-21.158,12	0,00
2	3.865,28	-21.158,12	0,00
3	10.009,79	-21.158,12	0,00
4	0,00	-21.158,12	0,00
5	9.226,60	-21.158,12	0,00
…	…	…	…
29	-45.689,67	-21.158,12	-45.689,67
30	-26.623,33	-21.158,12	-26.623,33
31	-29.638,22	-21.158,12	-29.638,22
32	4.583,05	-21.158,12	0,00
…	…	…	…
39	-23.661,95	-21.158,12	-23.661,95
40	-2.028,99	-21.158,12	0,00
…	…	…	…
74	-21.967,56	-21.158,12	-21.967,56
75	-7.350,46	-21.158,12	0,00
76	-19.308,60	-21.158,12	0,00
77	34.522,89	-21.158,12	0,00
78	2.539,83	-21.158,12	0,00
79	2.874,24	-21.158,12	0,00
80	-21.097,99	-21.158,12	0,00
Prosječna vrijednost:			-29.516,15

Izvor: izračun autora

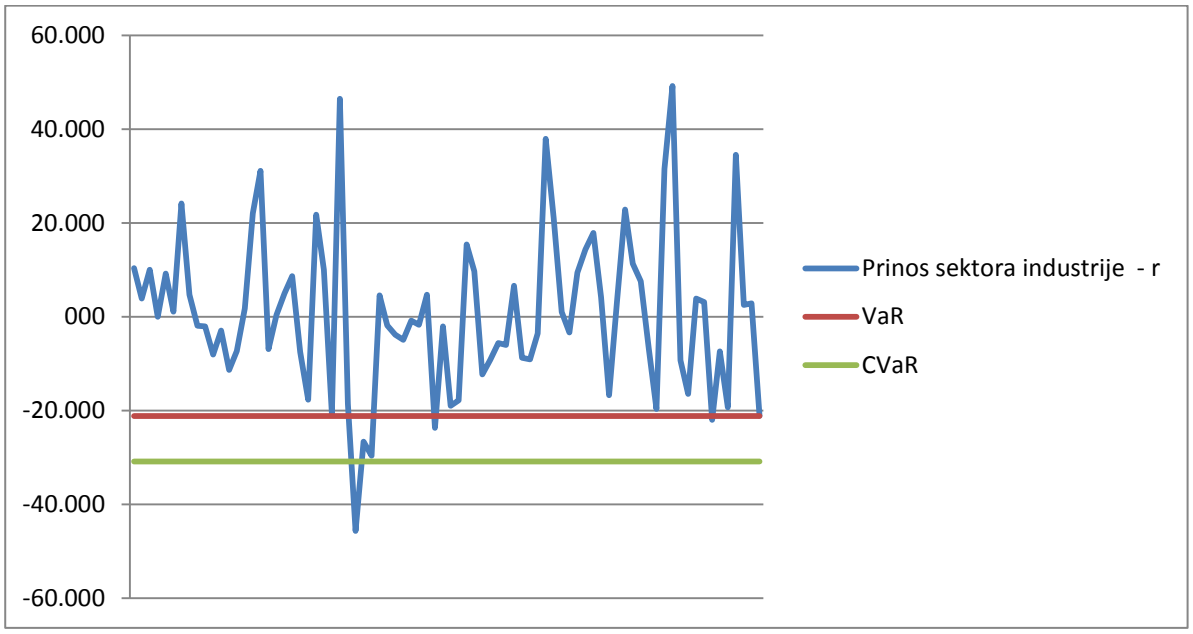
Izračunata prosječna vrijednost gubitaka koji premašuju VaR, odnosno gubitaka iz repa distribucije, vrijednosti -29.516,15 uspoređena je s referentnom vrijednosti koja je u ovom slučaju CVaR, koji za sektor industrije u periodu od 2006. do 2007.g. uz razinu pouzdanosti od 95% iznosi -30.866,96.

Budući da je prosječna vrijednost gubitaka koji premašuju VaR viša od CVaR, odnosno manje negativna

$$-29.516,15 < -30.866,96$$

može se zaključiti da je model za razdoblje od 2006.-2007. godine reprezentativan i primjenjiv na sektor Industrije na hrvatskom tržištu kapitala, te da dobro predviđa rizik.

Grafikon 5: Backtesting CVaR – prikaz kretanja prinosa sektora Industrije za period od 2006.-2007.g.

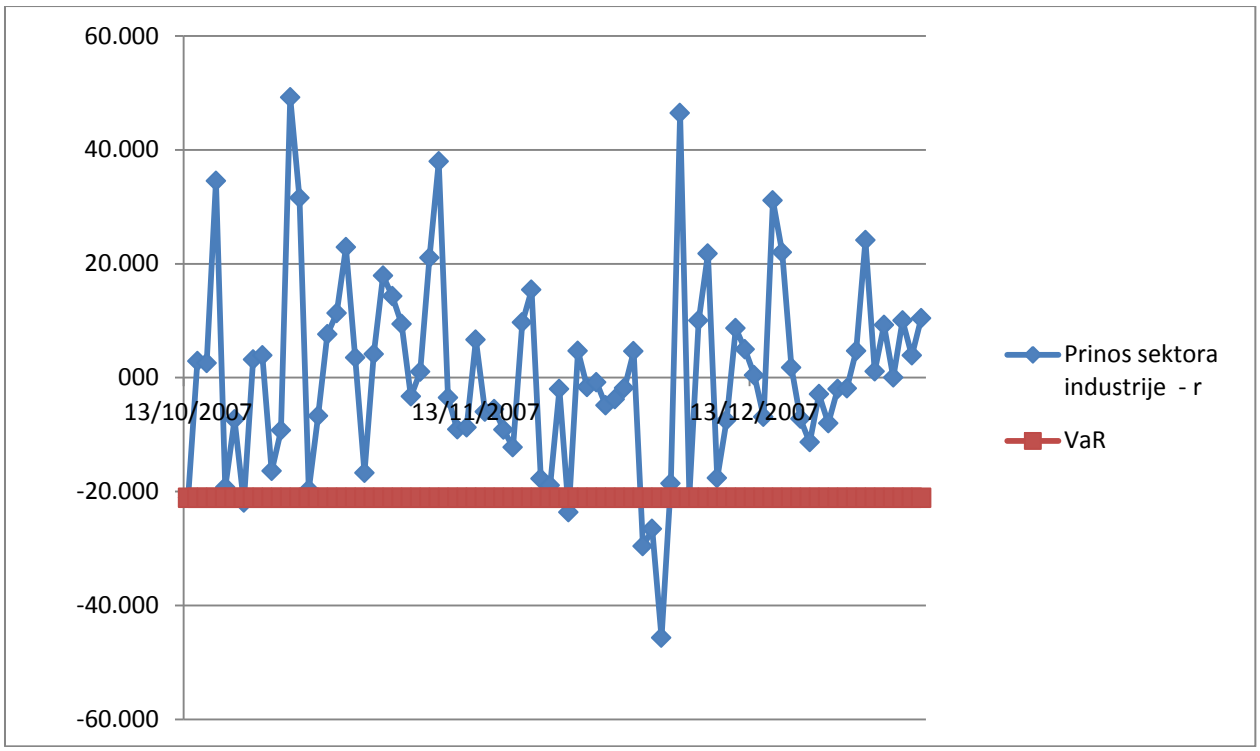


Izvor: prikaz autora

Na istom uzorku od zadnjih 80 prinosa razdoblja od 2006.-2007.g. napravljen je i backtesting VaR. Budući da je backtesting rađen na osnovi 80 zadnjih godišnjih prinosa sektora Industrije, da bismo prihvatili model, treba biti maksimalno 4 premašivanja VaR-a pri izabranoj razini pouzdanosti od 95%.

Rezultati backtestinga VaR za sektor Industrije za razdoblje od 2006.-2007.g. su prikazani na Grafikonu 6.

Grafikon 6: backtesting povijesne metode izračuna VaR za sektor Industrije za razdoblje od 2006.-2007.g.



Izvor: Prikaz autora

Prilikom backtestinga VaR, uz razinu pouzdanosti od 95% za sektor Industrije u razdoblju od 2006.-2007. godine, broj premašivanja VaR iznosio je 5. Prinosi su VaR premašili na datume 03.12.2007., 02.12.2007., 01.12.2007., 23.11.2007. i 19.10.2007.g. Budući da je broj premašaja VaR veći od predviđenog za odabranu razinu pouzdanosti od 95%, za povijesnu metodu izračuna VaR ne možemo reći da dobro procjenjuje rizik sektora Industrije na hrvatskom tržištu kapitala u razdoblju od 2006.- 2007. godine.

Backtesting CVaR i VaR napravljen je za svih osam sektora u svakom vremenskom periodu te su u slijedećoj Tablici 12. dati sumarni rezultati za backtesting CVaR i VaR.

Tablica 12: Rezultati backtesting-a CVaR prikazani po sektorima i vremenskim razdobljima

Sektor / Razdoblje	2006.-2007.		2008.-2009.		2013.-2014.	
	Prosječna vrijednost ρ	CVaR 95%	Prosječna vrijednost ρ	CVaR 95%	Prosječna vrijednost ρ	CVaR 95%
Hotelijerstvo i turizam	-23.248,84	-22.080,46	0,00	-47.510,34	-19.786,28	-19.280,08
Prehrana i maloprodaja	-22.716,94	-25.058,82	-41.904,94	-55.066,54	-12.530,63	-15.122,48
Financijske usluge	-26.347,46	-27.429,24	0,00	-72.650,05	-21.707,20	-25.170,92
Građevina	-42.258,14	-32.271,37	0,00	-83.276,05	0,00	-44.780,10
Transport	-36.927,04	-31.719,01	0,00	-84.045,53	-22.834,10	-24.599,64
Industrija	-29.516,15	-30.866,96	0,00	-64.010,66	-38.293,14	-36.846,59
Diversificirano	-23.719,19	-31.756,28	-53.285,33	-70.095,85	-21.224,85	-20.475,90
Poljoprivreda	-26.623,11	-35.064,61	-51.826,11	-64.532,59	-35.397,25	-24.991,52

Izvor: Izračun autora

Iz tablice se može primijetiti da je povijesna metoda izračuna CVaR za razdoblje od 2008. do 2009.g. reprezentativna i primjenjiva na hrvatskom tržištu kapitala. U navedenom periodu povijesna metoda izračuna CVaR dobro previđa rizik svih sektora na hrvatskom tržištu kapitala. U druga dva razdoblja od 2006.-2007. i od 2013.-2014.g. rezultati nisu jednaki za sve sektore. U razdoblju od 2006.-2007. povijesna metoda izračuna CVaR pokazala se reprezentativnom za pet sektora dok za tri sektora za povijesnu metodu CVaR ne možemo reći da dobro procjenjuje rizik. U razdoblju od 2013.-2014. povijesna metoda izračuna CVaR pokazala se reprezentativnom za četiri sektora dok za četiri sektora za povijesnu metodu CVaR ne možemo reći da dobro procjenjuje rizik. U razdoblju od 2006. do 2007.g. metoda dobro ne procjenjuje rizik za sektore: Hotelijerstva i turizma, Građevine i Transporta dok u razdoblju od 2013.-2014.g. metoda dobro ne procjenjuje rizike za sektore: Hotelijerstvo i turizam, Industrija, Diversificirano i Poljoprivreda.

Tablica 13: Rezultati backtesting-a VaR po sektorima i vremenskim razdobljima

Sektor / Razdoblje	2006.-2007.		2008.-2009.		2013.-2014.	
	Maksimalno dozvoljeni broj premašivanja za VaR 95%	Stvarni broj premašivanja VaR	Maksimalno dozvoljeni broj premašivanja za VaR 95%	Stvarni broj premašivanja VaR	Maksimalno dozvoljeni broj premašivanja za VaR 95%	Stvarni broj premašivanja VaR
Hotelijerstvo i turizam	4	8	4	0	4	8
Prehrana i maloprodaja	4	9	4	1	4	1
Financijske usluge	4	9	4	0	4	4
Građevina	4	8	4	0	4	0
Transport	4	10	4	0	4	5
Industrija	4	5	4	0	4	6
Diversificirano	4	5	4	2	4	10
Poljoprivreda	4	4	4	3	4	4

Izvor: Izračun autora

Iz tablice se može primijetiti da povijesna metoda izračuna VaR ne daje dobre rezultate u periodu od 2006. do 2007.g. Naime u navedenom periodu za samo jedan sektor možemo reći da povijesna metoda izračuna VaR dobro procjenjuje rizike na hrvatskom tržištu kapitala. Za razliku od prethodnog perioda, u periodu od 2008.-2009.g. model se pokazao kao reprezentativan i primjenjiv na hrvatskom tržištu kapitala te da dobro predviđa rizik.

U razdoblju od 2013.-2014.g. model dobro predviđa rizik za 4 sektora: Prehranu i maloprodaju, Financijske usluge, Građevinu i Poljoprivredu dok se nije pokazao reprezentativnim za sektore: Hotelijerstva i turizma, Transporta, Industrije i Diversificirano.

7. ZAKLJUČAK

Posljednjih dvadesetak godina sve su učestaliji poremećaji na financijskim tržištima što ukazuje da je kontroliranje rizika u investicijskim strategijama važno pitanje za cijelu globalnu ekonomiju. Možda ne postoji zlatno pravilo kako upravljati portfeljem, ali povijest je pokazala da je rizično fokusirati se isključivo na prinos. Krajem prošlog desetljeća mjera rizika zvana CVaR – uvjetna rizičnost vrijednosti je predstavljena na tržištu kao „nasljednik“ VaR – rizičnosti vrijednosti koja je došla u fokus financijskog tržišta, ali ima neke određene nepovoljne karakteristike poput toga što ne zadovoljava uvjet subaditivnosti što je važna karakteristika u svijetu financija. CVaR ima superiorne matematičke karakteristike u odnosu na VaR te je tzv. koherentna mjera rizika. Stoga je privukao posljednjih godina pažnju na financijskom tržištu. Koriste ga osiguravajuće kuće, investicijski fondovi i drugi sudionici na financijskom tržištu koji imaju potrebu za procjenom i mjerenjem rizika. Menadžment rizika s CVaR funkcijama može biti poprilično učinkovit. CVaR se može optimizirati i ograničiti s metodama konveksnog i linearnog programiranja, dok je VaR poprilično težak za optimizaciju. Problem kod VaR mjere rizika je što ne kontrolira scenarije koji premašuju VaR (npr. možete značajno povećati gubitak koji premašuje VaR, ali VaR mjera rizika se neće promijeniti). Ova karakteristika može biti i dobra i loša ovisno o ciljevima. Neosjetljivost VaR mjere rizika na ekstremne repove distribucije može biti dobra karakteristika ako se koriste loši modeli za formiranje distribucije. VaR zanemaruje određene dijelove distribucije za koji su samo loši izračuni dostupni. VaR izračuni su statistički stabilniji od CVaR izračuna. Ovo može dovesti do superiornih rezultata iz uzorka za VaR u odnosu na CVaR za određene aplikacije. Npr. za portfelj koji uključuje instrumente s jakim karakteristikama okretanja srednjoj vrijednosti, VaR neće penalizirati instrumente s ekstremno velikim gubicima. U statistici je jasno razumljivo da su izračuni temeljeni na VaR robusni i mogu automatski zanemariti ekstreme - vrijednosti koje jako odstupaju ili velike gubitke, koji mogu „zbuniti“ proceduru statističkog izračuna. Neosjetljivost VaR na ekstremne repove može biti i poprilično neželjena karakteristika koja dopušta da se poduzmu visoki nekontrolirani rizici. CVaR računa na gubitke koji premašuju VaR. Ova karakteristika može biti dobra ili loša ovisno o ciljevima. CVaR daje primjeren prikaz rizika koji se odražavaju u ekstremnim repovima distribucije. Ovo je jako važna karakteristika ako su ekstremni gubici u repovima distribucije

primjereno izračunati. CVaR može imati relativno loše performanse iz uzorka u usporedbi s VaR ako repovi nisu dobro modelirani.

Svrha ovog rada je dati uvid u rizičnost pojedinih sektora djelatnosti u različitim ekonomskim okolnostima, odnosno u periodu krize te u periodima rasta i stagnacije gospodarstva uz primjenu CVaR kao mjere rizika. Razumijevanje rizičnosti pojedinog sektora bitno je bankama i investitorima na financijskim tržištima da bi osigurali da ne postoji prevelika koncentracija rizika u određenim sektorima.

Primjenom metode CVaR na odabranih 29 dionica s hrvatskog tržišta kapitala razvrstanih u 8 sektora: Diversificirano, Financijske usluge, Građevina, Hotelijerstvo i turizam, Industrija, Poljoprivreda, Prehrana i maloprodaja, Telekomunikacije i Transport te promatranih u tri vremenska perioda 2006.-2007.g. (razdoblje rasta gospodarstva), 2008.-2009.g. (razdoblje gospodarske krize) i 2013.-2014.g. (razdoblje stagnacije) može se primijetiti da sektori koji su rizični u periodu rasta gospodarstva nisu isti sektori koji su rizični u periodu gospodarske krize ili stagnacije. U periodu financijske krize od 2008.-2009.g. svi sektori su imali rast CVaR, ali je došlo do promjene u rangovima pojedinih industrija. U periodu krize najveći negativni pomak ranga imali su sektori: Transport, Financijske usluge i Hotelijerstvo i turizam dok su pozitivan pomak ranga u razdoblju od 2008.-2009.g. imali sektori: Poljoprivreda, Prehrana i maloprodaja, Industrija i Diversificirano. Sektor koji nije imao nikakav pomak u smislu ranga je Građevina. Najveće promjene u rangu događale su se u sredini „rang liste“ dok su tijekom sva tri perioda najmanje rizični bili sektori: Hotelijerstva i turizma i Prehrane i maloprodaje, a sektor Građevine je u svim periodima bio na začelju.

Time je potvrđena temeljna radna hipoteza ovog rada „Sektori djelatnosti koji su rizični u periodu financijske krize nisu isti sektori koji su rizični u periodu koji prethodi krizi ili slijedi nakon krize“.

Backtestingom rezultata dobivenih istraživanjem dokazana je i prva pomoćna hipoteza „CVaR daje dobru procjenu rizičnosti pojedinog sektora“, naime od ukupno 24 sektora (portfelja) promatranih u 3 razdoblja, za njih 17 povijesna metoda izračuna CVaR se pokazala kao reprezentativna i primjenjiva na hrvatskom tržištu kapitala.

Usporedbom backtesting rezultata dobivenih za metodu CVaR i VaR može se primijetiti da CVaR daje bolje rezultate u periodu od 2006.-2007.g. dok su u periodu od 2008.-2009.g. i u periodu od 2013.-2014.g. obje metode jednako uspješne. Navedenim je potvrđena i druga

pomoćna hipoteza ovog rada „CVaR daje preciznije i pouzdanije procjene rizičnosti pojedinog sektora od VaR.“

LITERATURA

1. Acerbi, C., Tasche, D. (2002): On the coherence of Expected Shortfall, Journal of Banking & Finance, 26 (7), 1487-1503.
2. Aljinović, Z., Marasović, B., Šego, B. (2011): Financijsko modeliranje, II. Izmijenjeno i dopunjeno izdanje, Ekonomski fakultet u Splitu.
3. Allen, D.E., Powell, R. (2007): Transitional credit modelling and its relationship to market Value at Risk: An Australian Sectoral Percpective, Accounting and Finance, 49(3), 425-444.
4. Allen, D.E., Powell, R. (2009): CVaR and Credit Risk Measurment, Working Paper, Edith Cowan University. (https://www.ecu.edu.au/__data/assets/pdf_file/0016/40426/wp0905rp.pdf)
5. Ammann, M., Reich, C. (2001): Value-at-Risk for Nonlinear Financial Instruments–Linear Approximation or Full Monte-Carlo?, University of Basel, Department of Finance, Working Paper No. 8/01.
6. Andersson, F., Uryasev, S., Mausser, H., & Rosen, D. (2000): Credit risk optimization with Conditional Value-at Risk criterion, Mathematical Programming, 89(2), 273-291.
7. Andersen, J.V., Sornette, D. (2001) "Have Your Cake and Eat It, Too: Increasing Returns While Lowering Large Risks!", The Journal of Risk Finance, Vol. 2 Iss: 3, 70 – 82.
8. Artzner, P., Delbaen, F., Eber, J.M., Heath, D.: „Coherent measures of risk, Math finance, 9 (3), 1999, 203-228.
9. Basak, S., Shapiro, A. (2001): Value-at-Risk Based Risk Management: Optimal Policies and Asset Prices, Review of Financial Studies, Vol. 14, 371-405.
10. Basel Committee on Banking Supervision (2006): International Convergence of Capital Measurement and Capital Standards, Bank for International Settlements, Press & Communications.
11. Bazelski odbor za superviziju banaka, (2003): Dobre prakse za upravljanje i nadzor nad operativnim rizikom.
12. Bazelski odbor za superviziju banaka, (2000): Načela za upravljanje kreditnim rizikom. (http://www.hnb.hr/supervizija/papiri-bazelske-komisije/h-nacela-za-upravljanje-kreditnim-rizikom.pdf)
13. Beder, S. T. (1995): VaR: Seductive but dangerous, Financial Analysts Journal, Semptember-October 1995, Vol. 51 (5).
14. Benazić, M. (2010): Izloženost hrvatskih banaka valutnom riziku, Ekonomski fakultet u Zagrebu, Zagreb.
15. Benolić M. (2012): Svjetska ekonomska kriza: razvoj, utjecaj na Republiku Hrvatsku i subjektivni stavovi studenata, Pravnik: časopis za pravna i društvena pitanja, (46) 2012, 1 (92), 119-137.
16. Bertsimasa; D., Lauprete, G.J., Samarov A. (2004): Shortfall as a risk measure: properties,optimization and applications, Journal of Economic Dynamics & Control l28, 1353–1381.
17. Bešker, M. (2006): Izvori ugrožavanja i procjena stanja sigurnosti-rizika-ugroženosti, Oskar, Zagreb.

18. Blanco, C., Nihle, G. (1998): How good is Your VaR? Using backtesting to assess system performance, Financial Engineering News, August 1998.
19. Christoffersen, P., Hahn, J., Inoue, A. (2001): Testing and comparing Value-at-Risk measures, Journal of Empirical Finance 8, 325—342.
20. Crouhy M., Galai D., Mark R. (2001): Risk Managment, McGraw-Hill Education, New York.
21. Culp Christopher L., Miller Merton H., Neves Andrea M.P. (1998): Value at Risk: uses and abuses, Journal of Applied Corporate Finance, Vol.10, No.4., 26-38.
22. Cvetinović, M. (2008): Upravljanje rizicima u finansijskom poslovanju, Univerzitete Singidunum, Beograd.
23. Dowd, K. (2002): Measuring market risk, John Wiley and Sons, Chichester and New York.
24. Drljača, M., Bešker M. (2010): Održivi uspjeh i upravljanje rizicima poslovanja, Poslovna politika, Beograd.
25. Duffie, D., Pan, J. (1997): An overview of Value at Risk, Journal of Derivatives, Vol. 4, No. 3 (Spring 1997), str. 7-49.
26. Fabozzi, F., Konishi, A. (1995): „The Handbook of Asset/Liability Management: State-of-the Art Investment Strategies, Risk Controls and Regulatory Requirements“, McGraw-Hill.
27. Fallon, V. (1996): Calculating Value-at-Risk, Working Paper 96-49, Wharton Financial Institutions Center, The Warton School, University of Pennsylvania.
28. Fraser Donald R., Gup Benton E., Kolari James W. (2001): Commercial banking (The managment of risk), South-Western College Publishing, Cincinnati.
29. Goorbergh, R., Vlaar, P. (1999): Value-at-Risk Analysis of Stock Returns Historical Simulation, Variance Techniques or Tail Indeks Estimation?, De Nederlandsche Bank Staff Reports, No. 40.
30. Gregurek, M., Vidaković, N. (2011): Bankarsko poslovanje, RRIF, Zagreb.
31. Greuning H., Bratanović, S.B. (2006): Analiza i upravljanje bankovnim rizicima, 2. Izdanje, Mate, Zagreb.
32. Hendricks, D. (1996): Evaluation of Value-at-Risk models using historical data, Federal Reserve Bank of New York Economic Policy Review, 2, 39-69.
33. Holton, G. A. (2004): Defining risk, Financial Analysts Journal 60 (6), 19-25.
34. Hrvatska narodna banka (2013): Odluka o izmjenama i dopunama odluke o upravljanju rizicima. (http://www.hnb.hr/propisi/odluke-nadzor-kontrola/2014/h-odluka-izmjenama-dopunama-odluke-upravljanju-rizicima-2014.pdf)
35. Ivaniš, M. (2012): Rizici u bankarskom poslovanju, Pravno-Ekonomski pogledi, br.3, Beograd.
36. Jerončić, M., Aljinović, Z. (2011), Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Ekonomski pregled: mjesečnik Hrvatskog društva ekonomista Zagreb, 62 (2011), 9-10, 583-606.
37. Johanson, F., Seiler, M. J., Tjanberg, M. (1999): Measuring downside portfolio risk, Journal of Portfolio management, 26(1), 96-106.
38. Jones, J. (2006): An introduction to Factor analysis of information risk, Risk managemet insight LLC.
39. Jorion, P. (2001): Value at Risk, The New Benchmark for Managing Financial Risk, McGraw-Hill, New York.

40. Jovanović, M. (2011): Pojam rizika i upravljanje rizikom u ekonomiji, Pravno-ekonomski pogledi br. 3, Beograd.
41. Jović, S. (1990): Bankarstvo, Naučna knjiga, Beograd.
42. Jurman, A. (2001): Valutni rizik u poslovnim bankama, Zbornik radova Ekonomskog fakulteta u Rijeci, Časopis za ekonomsku teoriju i praksu, volumen 19, svezak 2, 153-168.
43. Knight, F. (2002): Risk, Uncertainty and Profits, Beard Books, Washington D.C.
44. Koch Timothy W., MacDonald S. (2000): Bank managment, The Dryden Press, Orlando.
45. Kritzman M., Rich D. (2002): The Mismeasurement of Risk, Financial Analysts Journal, 58, 91–100.
46. Krokhmal, P., Palmquist, J., Uryasev, S. (2001): Portfolio optimization with Conditional Value-at-Risk objective and constraints, The Journal of Risk, Vol. 4, No. 2, 2002, 11-27.
47. Kupiec, P.H.(1995); Techniques for Verifying the Accuracy of Risk Mesaurement Models, Journal of Derivatives, Vol 3, 73-84.
48. Letmark, M. (2010): Robustnes of Conditional Value-at-Risk (CVaR) when measuring market risk across different asset clasess, Master's thesis, Royal Institute of technology, Stockholm.
49. 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.
50. Ljubić, M. (2013): Upravljanje kamatnim i deviznim rizikom u bankarskom sektoru Republike Srbije, Megatrend univerzitet, Beograd.
51. Mahmutović H., Ćesić A., Mahmutović A., „Efikasno upravljanje rizicima financijskih institucija uz primjenu II Baselskog sporazuma“, Tranzicija, 12 (2011), 25-26 ; 75-83.
52. Makarov V. (1999): Value at Risk: Historical simulation, The Journal of Lending & Credit Risk management, 3, 25-29.
53. Manganelli, S., Engle, R. F. (2001): Value at Risk models in finance, European Central bank Working Paper Series No. 75.
54. Marina, E. (2014): Evaluacija VaR mere rizika, Master rad, Univerzitet u Novom Sadu.
55. Marrison C. (2002): The Fundamentals of Risk measurement, McGraw-Hill Education, New York.
56. Masinović, I. (2013): Rizična vrijednost (VaR) kao mjera tržišnog rizika, Diplomski rad, Ekonomski fakultet u Splitu.
57. Matas, A. (2012): Aktualna svjetska financijska kriza i njezine posljedice na Hrvatsku, diplomski rad, Ekonomski fakultet Split, Sveučilište u Splitu.
58. Mikulčić, D. (2001): Value at Risk (Rizičnost vrijednosti) Teorija i primjena na međunarodni portfelj instrumenata s fiksnim prihodom, Hrvatska Narodna Banka.
59. Miloš Sprčić, D. (2013): Upravljanje rizicima, Sveučilište u Zagrebu, Zagreb.
60. Nassim, T. (1997): Dynamic hedging: Managing vanilla anda exotic options, Wiley, New York.
61. Nieppola, O. (2009): Backtesting Value at Risk models, Master's Thesis in Economics, Helsinki School of Economics.
62. Novak, B., Sajter, D. (2007): VaR dioničkih i mješovitih investicijskih fondova u Republici Hrvatskoj, Financiranje razvoja i restruktuiranja gospodarstva, Osijek.

63. Plenković Pastuović, J. (2012): Primjena internih modela za izračun kapitalnih zahtjeva za pozicijski rizik, valutni rizik i/ili robni rizik investicijskih društava, Kvartalni bilten I/2012, 16, 19-34.
64. Regester, M., Larkin, J. (1997): Risk issues and crisis managment, Kogan P. Limited, London.
65. Riskmetrics-Tehnical document, (1996); J.P. Morgan/Reuters, New York.
66. Rockafellar R.T., Uryasev S. (1999): Optimization of Conditional Value at Risk, J.Risk 2, 21-41.
67. Rootzen H., Kluppelberg C., (1999): A single number can't hedge against economic catastrophes, Ambio 28 (6), 550-555. (http://www.math.chalmers.se/~hrootzen/papers/kluppelberg-rootzen-ambio1999.PDF)
68. Rose S.P., Hudgins S.C. (2005): Bankarski menadžment i finansijske usluge, Data status, Beograd.
69. Saunders, A., Millon Cornett, M. (2010): Financijska tržišta i institucije, Drugo izdanje, Masmedia, Zagreb.
70. Sinkey, J. F. (1998): Commercial bank financial managment, McMillan Publishing Company, New York.
71. Šantak, Z. (2000): Value at Risk, Hrvatsko mirovinsko investicijsko društvo, Pregled tržišta godina 2, broj 2, prosinac 2000.
72. Šarlija, N. (2008): Kreditna analiza, Ekonomski fakultet u Osijeku, Osijek.
73. Šverko, I. (2001): Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj, Financijska teorija i praksa, 25 - 4, str. 605-618.
74. Šverko I. (2002): Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, Vol. 53 No. 7-8.
75. Technical standard risk Taxonomy (2009), The Open Group, UK
76. Uryasev, S. (2000): Conditional Value-at-Risk (CVaR): Optimization algorithms and applications, Financial Engineering News, No. 14, 1-5.
77. Uryasev, S., Serriano, G., Sarykalin, S. (2008): Value-at-Risk vs. Conditional Value-at-Risk in risk managment and optimization, Tutorials in Operation research, Informs, Hanover, MD, 270-294. (http://www.ise.ufl.edu/uryasev/files/2011/11/VaR_vs_CVaR_INFORMS.pdf)
78. Wiener, Z. (1999), Introduction to VaR (Value-at-Risk), Risk Management and Regulation in Banking, Kluwer Academic Publishers, Boston.
79. Yamai, Y., Yoshiba, T. (2002): Comparative Analysis of Expected Shortfall and Value-at-Risk: Their Validity Under Market Stress, Monetary and Economic Studies 20 (3), 181–237.
80. Zelenika, R. (2000): Metodologija i tehnike izrade znanstvenog i stručnog djela, četvrto izdanje, Ekonomski fakultet u Rijeci.
81. Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Ekonomski fakultet u Ljubljani, Ljubljana.
82. Živko, I. (2006): Kamatni rizik u bankarstvu – izvori i učinci, Ekonomski fakultet, Sveučilište u Mostaru.
83. Živković, A., Ristić, Ž. (2000): Upravljanje financijskim i deviznim poslovanjem, Ekonomski fakultet, Beograd.

OSTALI IZVORI

84. **http://zse.hr/**
85. **http://www.hnb.hr/dub-konf/14-konferencija/young-zivkovic-2.pdf**
86. **https://www.kevinsheppard.com/images/4/47/Chapter8.pdf**
87. **http://people.stern.nyu.edu/adamodar/pdfiles/papers/VAR.pdf**
88. **http://www.math.ethz.ch/finance/misc/PortfolioSelection/VaRCVaRShortfallPortfolio.pdf**
89. **http://www.hgk.hr/sektor-centar/centar-makroekonomija/gospodarska-kretanja-122014**
90. **https://www.msci.com/gics**

POPIS SLIKA

Slika 1. Podjela financijskih rizika

Slika 2. Metoda izračuna rizične vrijednosti

Slika 3. Povijesna metoda

POPIS TABLICA

Tablica 1. Izabrani makroekonomski pokazatelji za razdoblje od 2006.-2014.g.

Tablica 2. Dionice izabrane u uzorak

Tablica 3. Dionice iz uzorka razvrstane prema sektorskoj pripadnosti

Tablica 4: Povijesne promjene vrijednosti dionica sektora industrije za razdoblje 2006-2007.g.

Tablica 5: Prinosi dionica sektora industrije za razdoblje 2006-2007.g.

Tablica 6. Prinos sektora industrija za razdoblje od 2006 – 2007.g.

Tablica 7. Distribucija dobitaka i gubitaka dionica i sektora industrije za razdoblje 2006.-2007.

Tablica 8. VaR i CvaR dionica i sektora industrije za razdoblje od 2006.-2007.g.

Tablica 9. Prikaz CVaR vrijednosti pojedinih sektora u 3 vremenska razdoblja promatranja

Tablica 10. Prikaz sektora s dodijeljenim CVaR rangom u tri razdoblja promatranja
Tablica 11. Backtesting CVaR za sektor industrije u razdoblju od 2006.-2007.
Tablica 12: Rezultati backtesting-a CVaR prikazani po sektorima i vremenskim razdobljima
Tablica 13: Rezultati backtesting-a VaR po sektorima i vremenskim razdobljima

POPIS GRAFIKONA

Grafikon 1. Krivulja normalne distribucije i površina VaR
Grafikon 2. CVaR i VaR
Grafikon 3. BDP u Hrvatskoj od 2006-2014, realne stope rasta
Grafikon 4. CVaR vrijednosti pojedinih sektora u 3 vremenska razdoblja promatranja
Grafikon 5: Backtesting CVaR – prikaz kretanja prinosa sektora industrije za period od 2006.-2007.g.
Grafikon 6: backtesting povijesne metode izračuna VaR za sektor industrije za razdoblje od 2006.-2007.g.