MEĐUODNOS BANKARSKIH RIZIKA I MAKROEKONOMSKIH KRETANJA U HRVATSKOJ

Prtenjača Mažer, Karmen

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:145:619174

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

EFOS REPOSITORY - Repository of the Faculty of Economics in Osijek

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski sveučilišni studij Management

Mr. sc. Karmen Prtenjača Mažer

MEĐUODNOS BANKARSKIH RIZIKA I MAKROEKONOMSKIH KRETANJA U HRVATSKOJ

DOKTORSKA DISERTACIJA

Osijek, 2022.

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski sveučilišni studij Management

Mr. sc. Karmen Prtenjača Mažer

MEĐUODNOS BANKARSKIH RIZIKA I MAKROEKONOMSKIH KRETANJA U HRVATSKOJ

DOKTORSKA DISERTACIJA

Mentor: izv. prof. dr. sc. Martina Briš Alić

Osijek, 2022.

University Josip Juraj Strossmayer in Osijek
Faculty of Economics in Osijek
Postgraduate doctoral study Management

Mr. sc. Karmen Prtenjača Mažer

INTERRELATION BETWEEN BANKING RISKS AND MACROECONOMIC TRENDS IN CROATIA

DOCTORAL THESIS

Mentor: izv. prof. dr. sc. Martina Briš Alić

Osijek, 2022

IZJAVA

O AKADEMSKOJ ČESTITOSTI, PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA, SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA

1. Kojom izjavljujem i svojim potpisom potvrđujem da je doktorski rad isključivo rezultat osobnoga rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu. Potvrđujem poštivanje nepovredivosti autorstva te točno citiranje radova drugih autora i referiranje na njih.

2. Kojom izjavljujem da je Ekonomski fakultet u Osijeku, bez naknade u vremenski i teritorijalno neograničenom opsegu, nositelj svih prava intelektualnoga vlasništva u odnosu na navedeni rad pod licencom *Creative Commons Imenovanje – Nekomercijalno – Dijeli pod istim uvjetima 3.0 Hrvatska.*

3. Kojom izjavljujem da sam suglasna da se trajno pohrani i objavi moj rad u institucijskom digitalnom repozitoriju Ekonomskoga fakulteta u Osijeku, repozitoriju Sveučilišta Josipa Jurja Strossmayera u Osijeku te javno dostupnom repozitoriju Nacionalne i sveučilišne knjižnice u Zagrebu (u skladu s odredbama Zakona o znanstvenoj djelatnosti i visokom obrazovanju, NN br. 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).

4. Izjavljujem da sam autorica predanog rada i da je sadržaj predane elektroničke datoteke u potpunosti istovjetan s dovršenom tiskanom verzijom rada predanom u svrhu obrane istog.

Ime i prezime studentice: mr. sc. Karmen Prtenjača Mažer

Matični broj studenta: 346

OIB: 57950424157

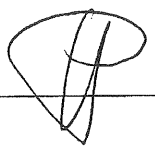
e-mail za kontakt: karmen.mazer@gmail.com

Naziv studija: Poslijediplomski sveučilišni studij Management

Naslov rada: Međuodnos bankarskih rizika i makroekonomskih kretanja u Hrvatskoj

Mentorica rada: izv. prof. dr. sc. Martina Briš Alić

U Osijeku, 2022. godine

Potpis 

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Doktorska disertacija**
Ekonomski fakultet u Osijeku

Znanstveno područje: Društvene znanosti
Znanstveno polje: Ekonomija

MEĐUODNOS BANKARSKIH RIZIKA I MAKROEKONOMSKIH KRETANJA U HRVATSKOJ

Mr. sc. Karmen Prtenjača Mažer

Disertacija je izrađena u: Osijek
Mentor: izv. prof. dr. sc. Martina Briš Alić
Komentor: izv. prof. dr. sc. Berislav Bolfek

Sažetak doktorske disertacije:

Financijski sektor predstavlja značaj stabilnosti svake zemlje. Dobar i profitabilan bankarski sustav može bolje podnijeti negativne šokove kao i pridonijeti stabilnosti financijskog sustava. Promjene u financijskom sektor mogu biti uzrok velikih gospodarskih kriza stoga se njihovo kretanje treba pratiti i nadzirati. Pri tome treba definirati parametre koji utječu na financijsku stabilnost, konkretno bankarsku stabilnost. Odraz stabilnosti bankarskog sustava ogleda se u kombinaciji vanjskih i unutarnjih čimbenika Analize uspješnog poslovanja banaka, upravljanje bankama i financijskim tržištima kao i nadzori nad bankama čine zanimljivo akademsko područje istraživanja.

Broj stranica: 196
Broj slika: 12
Broj tablica: 13
Broj literaturnih navoda: 278
Jezik izvornika: Hrvatski jezik
Ključne riječi: bankarski rizici, kreditni rizik, makroekonomske varijable, management rizika

Datum obrane: 27. lipnja 2022.

Stručno povjerenstvo za obranu:
1. prof. dr. sc. Jerko Glavaš
2. izv. prof. dr. sc. Berislav Bolfek
3. dr. sc. Martina Harc
4. prof. dr. sc. Đula Borozan (zamjenica)
5. prof. dr. sc. Nataša Šarlija (zamjenica)

Disertacija je pohranjena u: Nacionalnoj i sveučilišnoj knjižnici Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; Gradskoj i sveučilišnoj knjižnici Osijek, Europska avenija 24, Osijek; Sveučilištu Josipa Jurja Strossmayera u Osijeku, Trg sv. Trojstva 3, Osijek; Ekonomskom fakultetu u Osijeku, Trg Lj. Gaja 7, Osijek

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek **PhD thesis**
Faculty of Economics in Osijek

Scientific Area: Social science
Scientific Field: Economics

INTERRELATION BETWEEN BANKING RISKS AND MACROECONOMIC TRENDS IN CROATIA

Mr. sc. Karmen Prtenjača Mažer

Thesis performed at: Osijek
Supervisor: Martina Briš Alić, associate professor
Consultative supervisor: Berislav Bolfek, associate professor

Short abstract:
The financial sector is important for the stability of any country. A good and profitable banking system can bear negative shocks as well as contribute to the stability of the financial system. Changes in the financial sector can be the cause of major economic crises, so their movement should be controlled and monitored. It is necessary to define the parameters that affect financial stability, specifically banking stability. The stability of the banking system is combination of external and internal factors. Analyzes of successful banking operations, bank and financial market management as well as banking supervision make it an interesting academic area of research.

Number of pages: 196
Number of figures: 12
Number of tables: 13
Number of references: 278
Original in: Croatian
Key words: banking risks, credit risks, macroeconomic variables, risk management

Date of the thesis defense: June 27, 2022

Reviewers:
1. Jerko Glavaš, full professor
2. Berislav Bolfek, associate professor
3. Martina Harc
4. Đula Borozan, full professor (substitute)
5. Nataša Šarlija, full professor (substitute)

Thesis deposited in: National and University Library in Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; City and University Library of Osijek, Europska avenija 24, Osijek; Josip Juraj Strossmayer University of Osijek, Trg sv. Trojstva 3, Osijek; Faculty of Economics in Osijek, Trg Lj. Gaja 7, Osijek

Međuodnos bankarskih rizika i makroekonomskih kretanja u Hrvatskoj

SAŽETAK

Međuodnos bankarskih rizika i makroekonomskih kretanja jedna je od temeljnih pretpostavki stabilnosti financijskog sustava države. U ovom radu analizira se odnos makroekonomskih kretanja i financijske stabilnosti banaka u razdoblju prije, tijekom i nakon financijske krize 2008. godine u Hrvatskoj. Kretanje bruto domaćeg proizvoda, inflacije, kamatnih stopa, stope nezaposlenosti, udio neprihodujućih kredita u ukupnim kreditima u bankarskom sustavu, kretanje plasmana banke, odnosno povezanost poslovnih banaka i gospodarskih kretanja zemlje promatrano je u razdoblju od 2000. do 2019. godine. Naglašen je značaj bankarskog sustava te način na koji bankarski sustav funkcionira s posebnim naglaskom na bankarske rizike.

Statistički podaci korišteni u istraživanju preuzeti su iz baza podataka Hrvatske narodne banke, Državnog zavoda za statistiku, European Central bank, European Commission, SAS® OpRisk Global Data base, baze podataka KPMG-a za 2018. godinu, baze podataka Svjetske banke te baze podataka Global Finance Practice (2017). Provedena korelacijska analiza na temelju prikupljenih podataka potvrđuje međuovisnost makroekonomskih varijabli (bruto domaći proizvod, inflacija, stopa nezaposlenosti) i bankarskih varijabli (kamatne stope s valutnom klauzulom i bez valutne klauzule, plasmani banke te udio neprihodujućih kredita).

Na temelju provedenih analiza daju se preporuke za postupanje radi jačanja stabilnosti bankarskog sustava u vidu smanjenja izloženosti banaka strukturnim rizicima uzrokovanih internim ili eksternim čimbenicima.

Rezultati ovoga istraživanja mogu predstavljati smjernice financijskim institucijama i kreatorima politika prilikom razvijanja instrumenata koji dovode do poboljšanja uspješnosti funkcioniranja financijskih institucija i stabilnosti financijskog sustava.

Ključne riječi: bankarski rizici, kreditni rizici, makroekonomske varijable, upravljanje rizicima

ABSTRACT

Interrelation between banking risks and macroeconomic trends are one of the fundamental preconditions for the stability of a country's financial system. This paper analyses the relationship between the macroeconomic trends and the financial stability of banks in the period before, during and after the 2008 financial crisis in Croatia. Movement of gross domestic product, inflation, interest rates, unemployment rate, share of non-performing loans in total loans in the banking system, movement of bank loans, i.e. the connection between commercial banks and economic trends of the country was observed in the period from 2000 to 2019. The importance of the banking system and the way in which the banking system functions are emphasized, with special emphasis on banking risks.

The statistical data used in the survey were taken from the databases of the Croatian National Bank, the Central Bureau of Statistics, the European Central Bank, the European Commission, the SAS® OpRisk Global Database, the KPMG database for 2018, the World Bank database and the database Global Finance Practice (2017). The conducted correlation analysis based on the collected data confirms the interdependence of macroeconomic variables (gross domestic product, inflation, unemployment rate) and banking variables (interest rates with and without currency clause, bank loans and the share of non-performing loans).

Based on the conducted analyses, recommendations are given for actions to strengthen the stability of the banking system in the form of reducing banks' exposure to structural risks caused by internal or external factors.

The results of this research can provide guidance to financial institutions and policy makers in developing instruments that improve the performance of financial institutions and the stability of the financial system.

Key words: banking risks, credit risks, macroeconomic variables, risk management

1. Sadržaj

IZJAVA ... 3
O AKADEMSKOJ ČESTITOSTI, PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA, SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA 3

1. Uvod ... 1
1.1. Problem istraživanja ... 1
1.2. Ciljevi istraživanja i svrha rada ... 4
1.3. Hipoteze istraživanja ... 5
1.3.1. Djelovanje kreditnih rizika na gospodarska kretanja ... 6
1.3.2. Uloga makroekonomskih kretanja na promjene u bankarskom sustavu u Hrvatskoj ... 9
1.3.3. Upravljanje rizicima u bankama ... 10
1.3.4. Primjena alata i modela za upravljanje rizicima u bankama ... 12
1.4. Znanstvene metode ... 13
1.5. Očekivani znanstveni doprinos ... 15
1.6. Struktura rada ... 16

2. Bankarski sustav ... 18
2.1. Pojam i definicija bankarskog sustava ... 18
2.1.1. Profitna funkcija banke ... 20
2.1.2. Kamatne stope ... 22
2.2. Način organizacije i ustrojstva banaka ... 24
2.2.1. Internacionalno bankarstvo ... 27
2.2.2. Ustrojstvo i razvoj banaka u najvećim zemljama svijeta ... 29

3. Financijska kriza ... 33
3.1. Pojam i obilježja financijske krize ... 33
3.2. Uzroci financijskih kriza ... 37
3.3. Financijska kriza u Hrvatskoj ... 43

4. Upravljanje rizicima u bankama ... 47
4.1. Rizici u bankama ... 49
4.1.1. Kategorije bankarskih rizika ... 50
4.2. Alati, tehnike i modeli za upravljanje i analizu rizika u bankama ... 56
4.2.1. Alati i tehnike za upravljanje rizicima u bankama ... 56
4.2.2. Metode i modeli za analizu rizičnosti u bankama ... 62
4.3. Upravljanje kreditnim i operativnim rizikom ... 67
4.3.1. Kontrola kreditnog portfelja ... 72
4.3.2. Metode i modeli za izračun kreditnog rizika ... 73
4.4. Regulatorna tijela, smjernice i nadzor nad bankama ... 81
4.4.1. Primjena Bazelskih sporazuma u svrhu kontrole rizika banke ... 86

5. Empirijsko istraživanje međuodnosa bankarskih rizika i makroekonomskih kretanja ... 104
5.1. Empirijsko istraživanje odnosa kreditnih rizika i makroekonomskih kretanja (H1) 109

5.1.1. Pregled empirijskih istraživanja odnosa financijskog sustava i gospodarskog rasta 110
5.1.2. Podaci i metodologija 116
5.1.3. Empirijsko testiranje odnosa kreditnog rizika i gospodarskog rasta (H1) 121
5.1.4. Analiza dobivenih rezultata empirijskog istraživanja odnosa kreditnih rizika i makroekonomskih kretanja (H1) 136
5.2. Empirijsko istraživanje odnosa makroekonomskog okruženja i stabilnosti bankarskog sustava (H2) 140
5.2.1. Pregled empirijskih istraživanja odnosa makroekonomskog okruženja i stabilnosti financijskog sustava 141
5.2.2. Podaci i metodologija 151
5.2.3. Empirijsko testiranje odnosa makroekonomskog okruženja i stabilnosti bankarskog sustava (H2) 155
5.2.4. Analiza dobivenih rezultata empirijskog istraživanja makroekonomskih kretanja na kreditne rizike u poslovnim bankama (H2) 168
5.3. Empirijsko istraživanje o kvaliteti upravljanja rizicima u poslovnim bankama primjenom razvijenih alata i modela sukladno smjernicama Europske banke (h1 i h2) 172
5.3.1. Empirijsko testiranje pomoćnih hipoteza kroz analizu kretanja neprihodujućih kredita (NPL-a) 172
5.3.2. Empirijsko testiranje pomoćnih hipoteza kroz upravljanja operativnim rizikom 178
5.3.3. Analiza dobivenih rezultata istraživanja pomoćnih hipoteza rada 187
6. Implikacije istraživanja, ograničenja istraživanja i preporuke za buduća istraživanja 192
7. Zaključak 194
Literatura 197
Popis tablica 211
Popis slika 212
Popis grafikona 213
Popis dijagrama 214
Popis kratica i simbola 214
Prilozi 215

1. Uvod

Tijekom zadnjih desetljeća bankarski sustav diljem svijeta doživio je velike promjene u svojem radnom okruženju. Epizode duboke nevolje u bankarskom sustavu dogodile su se ne samo u zemljama u razvoju i tranziciji, već i u naprednim, industrijski razvijenim gospodarstvima, poput Sjedinjenih Američkih Država, nordijskih zemalja i Japana. Nedovoljna reguliranost bankarskog sustava kao i negativni vanjski čimbenici koji imaju značajan učinak na poslovanje banaka mogu utjecati na neravnotežu financijskog sustava, a time i na nestabilnost cijeloga gospodarstva.

Kako navodi Tooze (2018), financijska kriza može nastati jedino u neuravnoteženom, nereguliranom financijskom tržištu. Stoga je potrebno poduzeti sve mjere za postizanje ravnoteže i stabilnosti financijskog sustava. Potrebno je analizirati sve čimbenike koji svojim djelovanjem imaju utjecaj na bankarski sustav, bilo da se radi o internim čimbenicima, kao što je nedostatak unutarnjih kontrola ili nedovoljna primjena razvijenih alata i tehnika za sprječavanje potencijalnih štetnih događaja ili vanjski makroekonomski čimbenici koji svojim neposrednim djelovanjem mogu utjecati na nestabilnost bankarskog sustava.

U svim slučajevima, katastrofe u bankarskom sustavu dovode do velikih gubitaka i poremećaja u gospodarstvu, a rješavanje kriza često je veliki teret javnim sredstvima (Arpa et al., 2001).

1.1. Problem istraživanja

U ovoj doktorskoj disertaciji analizira se međuodnos bankarskih rizika i makroekonomskih kretanja u Hrvatskoj prije, tijekom i nakon financijske krize 2008. godine. Banke i drugi financijski posrednici imaju ključnu ulogu u razvoju gospodarstva, ne samo zato što su i sami dio mreže, djelujući kao posrednici, već i zato što kroz kreditnu aktivnost utječu na stvaranje i razvoj novih gospodarskih subjekata (Ashraf et al., 2017). Ako su banke i drugi financijski posrednici posebni po tome što imaju teško zamjenjivu (ako ne i doslovno jedinstvenu ulogu) u kreiranju kredita, tada poremećaji bankarske aktivnosti mogu imati makroekonomske posljedice (Bernanke, 1993). S druge strane, makroekonomski čimbenici izravno i posredno utječu na povećanje ili smanjenje performansi banaka (Samsul, 2006). U skladu s tim izjavama,

Athanasoglou et al. (2006) navode da je profitabilnost banaka u funkciji unutarnjih i vanjskih čimbenika. Unutarnji čimbenici su čimbenici specifični za banke te interno djeluju na profitabilnost banaka, dok su vanjski čimbenici varijable koje nemaju izravan odnos s bankom, no ti čimbenici posredno utječu na gospodarstvo i zakone te mogu utjecati na uspješnost financijskih institucija (Sahetapy, 2019).

Makroekonomska nestabilnost koja se očituje kroz nagle uspone i padove ekonomske aktivnosti, najočitiji je i najizravniji izvor koji ima nepovoljnu ulogu u poslovanju banaka. Osnova stabilnosti bankarskog sustava je gospodarski rast.

Prema Grizelju (2016), makroekonomska politika mora biti kvantitativno određena (ekonometrijski, matematički, statistički). U tom kvantitativnom pristupu naglašeno mjesto imaju ekonomski modeli koji dinamičkom analizom opisuju promjenu pojedinih makroekonomskih varijabli u vremenu pri čemu su modeli rasta instrument makroekonomske analize. Stoga Grizelj (2016) gospodarski rast definira kao dugoročno povećanje proizvodnje, odnosno uvećanje realnog bruto domaćeg proizvoda. Postojanje gospodarskoga rasta pretpostavka je zadovoljavanja stalno rastućih potreba ljudi pa je gospodarski rast osnovni ekonomski i politički cilj svake zemlje. Gospodarski se rast kvantitativno izražava na različite načine, a najčešće uz pomoć pokazatelja stope rasta BDP-a po glavi stanovnika u određenom razdoblju.

Škare (2007) pak definira gospodarski rast kao povećanje potencijalne proizvodnje (dobara i usluga), realnog dohotka, osobne potrošnje pojedinca ili profita poduzeća.

Među ekonomistima postoje neslaganja o tome koliko poticati pojedine čimbenike ekonomskoga rasta u ukupnom ekonomskom rastu. Kroz povijest je razvijeno više modela ekonomskoga rasta. Među najcitiranijim radovima o gospodarskom rastu su neoklasični modeli rasta i endogeni modeli rasta (Grizelj, 2016).

Prema neoklasičnom modelu rasta, pojam ili kategoriju gospodarskog rasta čini proizvodna funkcija poduzeća, društva. Otuda je matematički oblik modela rasta jednak jednostavnom obliku proizvodne funkcije (Škare, 2007):

$$Y = f (K, R, Z)$$

gdje (Y) predstavlja output, (K) = kapital, (R) = rad, (Z) = zemlja.

Gospodarstva s niskom akumulacijom kapitala i bez tehnološkog napretka susreću se s niskom proizvodnošću rada, ali i ukupnom proizvodnošću inputa, što rezultira nižim stopama ekonomskog rasta. Više stope ekonomskog rasta u odnosu na ulaganja, investicije, mogu se ostvariti jedino ako su investicije praćene rastom proizvodnosti inputa, koja se ostvaruje tehnološkim napretkom, ulaganjem u obrazovanje, deregulacijom i kompetitivnim tržištem. Noviji teorijski doprinosi, za razliku od neoklasičnog modela, naglašavaju da je gospodarski rast endogeni rezultat ekonomskog sustava, a ne snage koje djeluju izvan njega.

Mnogi se autori slažu s tvrdnjom (npr. Danisman et al., 2020; Berger et al., 2020; Ashraf i Shen, 2019; Tra et al., 2021. i dr.) da profitabilnost bankarskog sustava ovisi o gospodarskom rastu zemlje. Stoga značaj istraživanja bankarskih rizika i makroekonomskih kretanja proizlazi iz važnosti bankarskog sustava za rast i razvoj gospodarstva zemlje. Provedena su brojna istraživanja o važnosti financijskog sustava za dobro funkcioniranje gospodarstva. Konkretno, mnoga su istraživanja pokazala da krize u bankarskom sustavu mogu imati značajne negativne učinke na realno gospodarstvo (Aspachs et al., 2005).

Koristan način za analizu makroekonomskih odrednica zdravlja banaka je sagledavanje glavnih rizika banaka: tržišni rizik (rizik smanjenja vrijednosti temeljne imovine), rizik kamatnih stopa, rizik neplaćanja ili kreditni rizik (rizik da dužnici neće moći otplatiti svoje dugove) i rizik likvidnosti (Arpa et al., 2001). Na sve ove rizike, barem djelomično, utječu makroekonomska kretanja i politike. Neočekivane promjene unutar monetarne politike mogu djelovati na kretanje kamatnih stopa banaka, a time i na kretanje bankarskih kredita. U isto vrijeme te promjene mogu utjecati na potrošnju i proizvodnju te stvoriti negativan efekt na realno gospodarstvo (Bassett et al., 2014).

Unatoč povećanom trendu prema dezintegraciji banaka koji se primjećuje u mnogim zemljama, uloga banaka ostaje središnja u financiranju gospodarske aktivnosti općenito i različitih segmenata tržišta posebno. Dobar i profitabilan bankarski sustav može bolje podnijeti negativne šokove kao i pridonijeti stabilnosti financijskog sustava. Stoga analize uspješnog poslovanja banaka, upravljanje bankama i financijskim tržištima kao i nadzori nad bankama čine zanimljivo akademsko područje istraživanja.

1.2. Ciljevi istraživanja i svrha rada

Glavna problematika ovoga rada je utvrditi međuovisnost makroekonomskog okruženja i financijskog sustava, odnosno naglasiti značaj profitabilnosti, kapitaliziranosti i likvidnosti bankarskog sustava koji neposredno djeluje na stabilnost gospodarstva u cjelini.

Unatoč činjenici kako su razni autori (npr. Goldsmith, 1955; McKinnon, 1973; Greenwood i Jovanovic, 1990; Bencivenga i Smith, 1991; Levine, 1991; King i Levine, 1993; Becker i Knudsen, 2002; Becker, 2003. i dr.) dokazali uzajamnu važnost bankarskog sustava i kretanja u realnoj ekonomiji, odnos bankarskih rizika i makroekonomskih kretanja nije dovoljno istražen, a pogotovo ne u kontekstu bankarske stabilnosti.

Stoga se u radu, teorijski i empirijski, objašnjavaju i istražuju međuovisnosti bankarskih rizika i makroekonomskih kretanja zemlje kao i značaj adekvatnog upravljanja rizicima u poslovnim bankama te važnost primjene razvijenih alata u upravljanju rizicima u skladu s modelima i smjernicama Europske banke.

Nakon teorijskih istraživanja te analize empirijskih istraživanja, ispituju se postavljene hipoteze na temelju kojih će se zaključiti kakav je uzajamni odnos bankarskih rizika i makroekonomskih kretanja. Propast svake pojedine bankarske institucije, bez obzira na njezinu veličinu i značaj unutar financijskog sustava, ima negativne posljedice na financijski sustav zemlje stoga je odnos bankarskih rizika i makroekonomskih kretanja važan za stabilnost svake zemlje (Čihák et al., 2013).

Cilj ovoga rada je prikazati međuovisnost bankarskih rizika i makroekonomskih kretanja odnosno prikazati kako su i koliko pojedini makroekonomski pokazatelji povezani s likvidnošću banaka kao i ulogu banaka na gospodarska kretanja neke zemlje. U radu se analizira kretanje bruto domaćeg proizvoda, inflacije, kamatnih stopa, stope nezaposlenosti, udio neprihodujućih kredita u ukupnim kreditima u bankarskom sustavu te kretanje plasmana banaka. U radu se također prikazuje i analizira povezanost poslovnih banaka i gospodarskih kretanja zemlje. Na strani poslovnih performansi banaka korišten je pokazatelj kretanja kamatnih stopa te udio neprihodujućih kredita (engl. *non performing loans* – NPL) u bilanci banke.

Cilj ovoga istraživanja je analizirati kretanja makroekonomskih čimbenika i njihovo djelovanje na bankarski sustav te pronaći odrednice koje značajno djeluju na odnos bankarskog sustava i gospodarskog rasta. Provedenim analizama ispituje se u kojoj mjeri i kako makroekonomske varijable djeluju na bankarske aktivnosti, na poslovne odluke banaka, odnosno u kojoj se mjeri poslovanja banaka mijenjaju u skladu s promjenama makroekonomskih odrednica. Dodatan cilj istraživanja je ispitati značajnosti kvalitetnog upravljanja rizicima u poslovnim bankama kao i važnost primjene razvijenih alata i modela u upravljanju rizicima.
Iz navedenoga se može izdvojiti svrha ovoga rada. Prva je upoznati bankarski sustav: osnovne uloge banaka, zadatke banaka te vrste bankarskih organizacija, zatim predstaviti i upoznati se s osnovnim rizicima bankarskog sustava, prezentirati njihove utjecaje na kretanja u gospodarstvu te prikazati način organizacije poslovanja banaka radi zaštite banaka od rizika koji dovode do nestabilnosti banaka. Svrha rada je predočiti i upoznati se sa značajnim radovima drugih autora koji obrađuju utjecaj financijske razvijenosti na gospodarski rast.

1.3. Hipoteze istraživanja

U ovom potpoglavlju rada iznose se glavne i pomoćne hipoteze rada.

Rad se sastoji od dvije glavne i dvije pomoćne hipoteze rada. Glavne i pomoćne hipoteze rada su tematski srodne, povezane, pa se stoga i međusobno nadopunjuju. U kontekstu ovoga doktorskog rada analiza svake hipoteze (glavne i pomoćne) obrađena je zasebno, ali se dobiveni rezultati sistematiziraju i nadopunjuju kao zaokružena cjelina rada. Obradom hipoteza i analizom dobivenih rezultata donosi se i konačni zaključak ovoga rada.

Glavnim hipotezama rada analizira se i objašnjava međuodnos bankarskih rizika i makroekonomskih varijabli. Prva glavna hipoteza rada preko kreditnih rizika ispituje utjecaj i značaj bankarskog sustava na makroekonomska kretanja, točnije na kretanje bruto domaćeg proizvoda, dok se u drugoj glavnoj hipotezi ispituje uloga makroekonomskih kretanja u bankarskom sustavu. Za varijablu bankarskih rizika odabrani su kreditni rizici kao jedan od najznačajnijih rizika kojem su izložene financijske institucije, a u svrhu analize makroekonomskih čimbenika odabrano je nekoliko makroekonomskih pokazatelja.

Pomoćne hipoteze rada služe kao dopuna glavnim hipotezama rada te se njihovom obradom, analizom i rezultatima dodatno utvrđuju dobiveni rezultati postavljenih hipoteza s posebnim naglaskom na važnost primjene kvalitetnih alata i modela za upravljanje bankarskim rizicima.

1.3.1. Djelovanje kreditnih rizika na gospodarska kretanja

Poteškoće u utvrđivanju smjera uzročnosti između financijskog razvoja i gospodarskog rasta prvi je identificirao Patrick (1966), dalje ga je razvio Goldsmith (1969) i McKinnon (1988) koji je tvrdio da je veća stopa financijskog rasta pozitivno povezana sa stvarnim rastom, no problem promatran u navedenom radu (Patrick, 1966) ostaje neriješen: što je uzrok, a što posljedica? Jesu li financije vodeći sustav gospodarskog razvoja ili jednostavno slijede rast realne ekonomije koji se generira negdje drugdje.

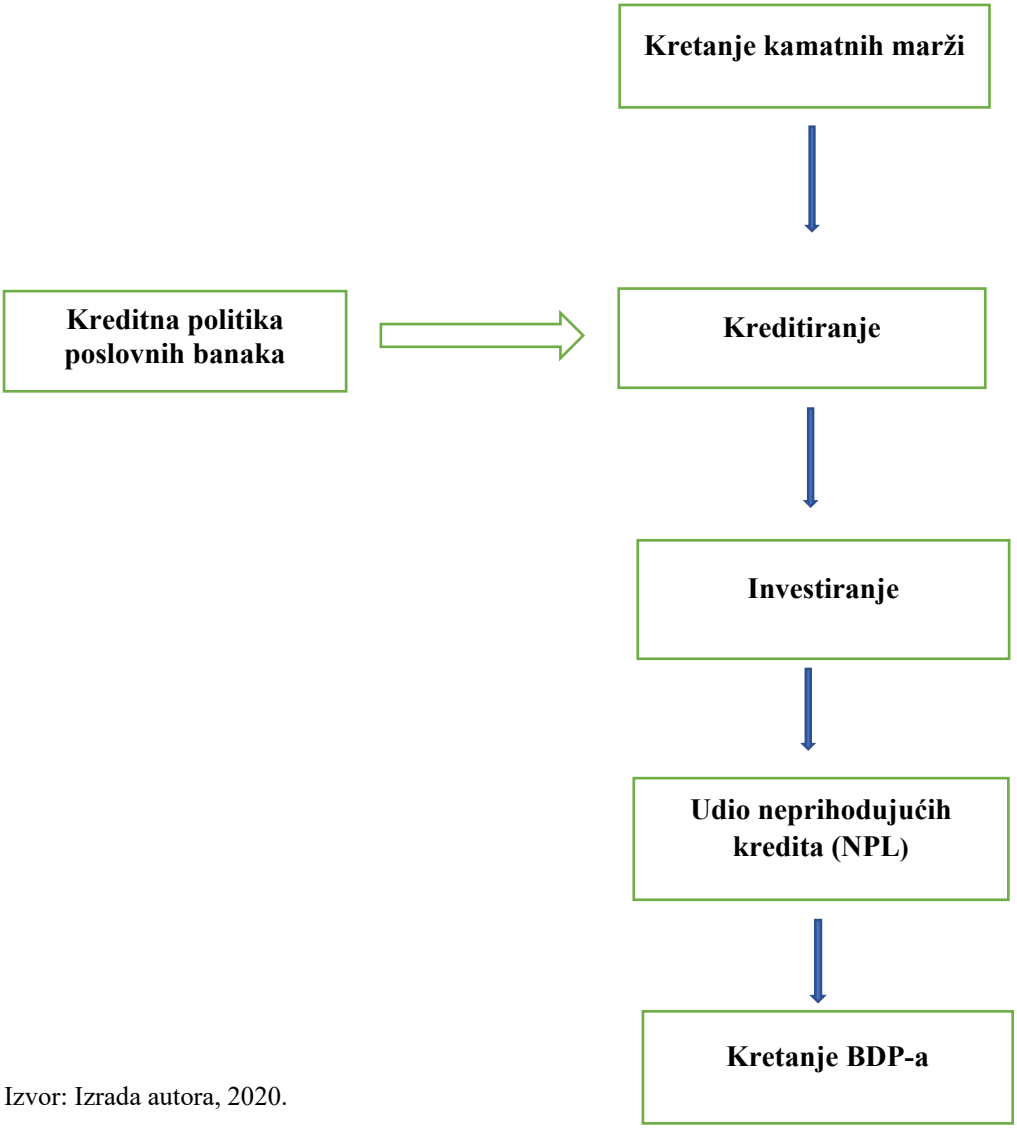
Posljedice loših poslovnih politika banaka dovode do negativnih makroekonomskih kretanja, a time i do gospodarske krize. Iako neki makroekonomisti zanemaruju važnost financijskih institucija te smatraju da zdravlje financijskoga sustava ne djeluje na realne ekonomske odluke već da financijski sustav slijedi promjene unutar realnog sustava (Robinson, 1965; Chick, 1983), uloga financijskih institucija izrazito je značajna te je itekako povezana s makroekonomskim kretanjima. Banka je financijska institucija preko koje prolaze svi novčani tokovi gospodarskih subjekata i zbog toga je njezin značaj za gospodarstvo golem. Dugoročna politika lošeg upravljanja unutar banke dovodi do pada aktive banke te može prouzročiti propast banke unatoč tome što banka posluje u razvijenom gospodarstvu kontinuiranog i stabilnog rasta. Želja za što većim rastom čest je bankarski sindrom. U želji za što većim rastom i zaradom banke često dovode do pretjeranoga kreditiranja uz visoke kamate. U vrijeme gospodarske ekspanzije pretjerano kreditiranje uz visoke kamate povećava sklonost slabljenju kriterija za procjenu rizika što djeluje na kvalitetu kreditnog portfelja. Tako je uočen velik udio nenaplativih kredita u kreditnim portfeljima banaka koje su doživjele propast (Lanine i Vennet, 2006). Koliko će financijski sustav biti profitabilan i stabilan ovisi o svakoj pojedinoj financijskoj instituciji, njezinu unutarnjem uređenju, ali i makroekonomskim kretanjima. Pod internim uređenjem misli se na kvalitetu menadžmenta, izvor kapitala, kvalitetu modela za izračun rizika i sl. Greenwood i Jovanovic (1990) smatraju da ako je gospodarstvo u kojem financijski sustav djeluje uspješno i stabilno, banke ne mogu biti pokretači gospodarske krize odnosno da je glavni kanal prijenosa financijskog razvoja na gospodarski rast zapravo učinkovitost ulaganja uvjetovana unutarnjim uređenjem financijskog sustava, a ne opseg

investicija (DeGregorio i Guidott, 1992). Da bi financijski sustav poticao gospodarski rast, nužno je postojanje financijske stabilnosti koja se očituje kao situacija u kojoj zdravlje financijskoga sustava ne utječe na realne ekonomske odluke (Bogdan i Stipković, 2017).

Banke se promjenama na tržištu, među ostalim, prilagođavaju visinom kamata na depozite i kredite. Razlika između aktivne i pasivne kamatne stope predstavlja graničnu kamatnu maržu. Do smanjenja kamatne marže ili čak do poslovanja uz negativnu kamatnu maržu, dolazi ako banka, slijedom odredbi zaključenih ugovora o plasmanu sredstava odnosno depozitima, ne može istodobno prilagoditi aktivne i pasivne kamatne stope novim stopama na tržištu. U uvjetima kada banka ne može povisiti aktivne kamatne stope vrlo brzo i/ili u istoj mjeri kao što su na tržištu porasle pasivne kamatne stope njezini kamatni troškovi rast će brže negoli prihodi po osnovi aktivnih kamata. Istu posljedicu ima i pad kamatnih stopa ako banka pasivnim kamatnim stopama ne može istom brzinom i/ili u istoj mjeri slijediti sniženje, koje je uslijed promjena na tržištu prisiljena napraviti u primjeni aktivnih kamatnih stopa (Miletić, 2008).

Ako banka dugoročno primjenjuje politiku kreditiranja uz primjenu slabije bonitetne kontrole, s vremenom će rasti udio nenaplativih ili neprihodujućih kredita (engl. *non performing loans*) (u nastavku teksta NPL) u bilancama banke što izravno utječe na kvalitetu aktive banke. Kako navodi Mileris (2012), neprihodujući krediti izravno su povezani s financijskim poslovanjem banke i jedan su od čimbenika kreditnog rizika bankarskog sustava. Povećanje NPL-a unutar banke sugerira da postoji visoka vjerojatnost velikog broja neprihodujućih kredita. Ovo utječe na neto vrijednost banke te nagriza vrijednost imovine banke. Nedostatak likvidnih sredstava banka će pokušati kompenzirati privlačenjem depozita uz veće kamatne stope što će povećati troškove. S druge strane, nedostatak likvidnih sredstava dovodi do ograničenja u kreditnoj aktivnosti banaka čime se smanjuje obujam kreditiranja, što je negativno povezano s rastom investicija i gospodarstvom u cjelini. Loše poslovanje samo jedne banke stvara negativan efekt na tržište u cjelini.

Slika 1. Djelovanje kreditnih rizika na makroekonomska kretanja.



Izvor: Izrada autora, 2020.

S obzirom na izneseno, glavna hipoteza rada glasi (H1):

Kreditni rizici poslovnih banaka djeluju na makroekonomska kretanja u zemlji.

1.3.2. Uloga makroekonomskih kretanja na promjene u bankarskom sustavu u Hrvatskoj

Još davne 1911. godine Joseph Schumpeter analizirao je i potvrdio poveznicu gospodarskog rasta i financijskog sustava koristeći se podacima osamdeset zemalja. Njegovi radovi s vremenom su potaknuli interes drugih ekonomista analitičara pa danas postoji paleta radova o poveznici gospodarskog rasta i financijskog sustava (Becker et al., 2013). O povezanosti makroekonomskih varijabli kao što je stopa inflacije, BDP, stopa nezaposlenosti te javni dug u kombinaciji sa slabom profitabilnošću gospodarstva i poslovne politike banke pisali su autori King i Levine, 1993; Delić i Rogić-Dumančić, 2016; Mankiw et al., 2005. i dr.

Temeljne makroekonomske uzroke bankarskih kriza u tržišnim gospodarstvima pokušavaju razjasniti brojne teorije. Zbog kompleksnosti istraživanja unutar doktorskog rada izdvojene su sljedeće teorije i istraživanja koja prate odnose makroekonomskih kretanja i bankarskog sustava: istraživanja koja prate i ispituju utjecaj ekonomskih politika na bankarski sustav; istraživanja koja prate poveznicu između monetarne i financijske stabilnosti; istraživanja autora koji se bave odnosom poslovnog ciklusa i kreditnog rizik; istraživanja koja ispituju učinak makroekonomskih čimbenika na likvidnost banaka te istraživanja koja ispituju djelovanje inflacije na bankarski sustav i međuovisnosti stope nezaposlenosti s kretanjima u financijskom sustavu.

Uspješnost bankarskog sustava ovisi o djelovanju i smjeru kretanja makroekonomskih agregata. Problemi stabilnosti u bankarstvu mogu biti potaknuti različitim čimbenicima, ali najčešće je to kombinacija makroekonomske nestabilnosti u okruženju i slabe profitabilnosti u poduzetništvu (Miletić, 2008). U svakom stabilnom makroekonomskom okruženju banke posluju s pozitivnim financijskim rezultatima, dok se u situaciji nepovoljnih ili nestabilnih makroekonomskih kretanja, kada se privreda suočava s recesijom i visokim realnim kamatnim stopama, banke suočavaju s gubicima koji nastaju zbog problema s otplatom kredita.

Rast bruto domaćeg proizvoda, kao jedna od komponenti gospodarskog rasta, trebao bi imati pozitivan učinak na profitabilnost banke. Inflacija može pozitivno i negativno djelovati na profitabilnost ovisno o sposobnosti uprave banke da efikasno upravlja sredstvima banke u uvjetima inflacije. U slučaju precijenjenosti domaće valute, domaća poduzeća bit će nekonkurentna na svjetskom tržištu, što će umanjiti njihove izvozne aktivnosti, obujam

proizvodnje, pa u konačnici i bruto domaći proizvod, što naposljetku može negativno djelovati i na profitabilnost banaka (Bach et al., 2009).

Slika 2. Djelovanje makroekonomskih kretanja na kreditnu politiku banaka



Izvor: Izrada autora, 2020.

S obzirom na izneseno, druga glavna hipoteza rada glasi (H2):

Makroekonomska kretanja djeluju na kreditne rizike u poslovnim bankama.

1.3.3. Upravljanje rizicima u bankama

Upravljanje rizicima je proces kojim se identificiraju, procjenjuju i obrađuju rizici pomoću konzistentnih i ponovljivih postupaka na osnovi čega se sastavlja izvještaj te provodi nadgledanje rizičnih aktivnosti. Upravljanje rizicima ne nastoji eliminirati rizike, već stvoriti okruženje u kojem se mogu donijeti optimalne poslovne odluke uzimajući u obzir identificirane rizike i posljedice koje oni mogu izazvati (Pongrac i Majić, 2015).

Svaka uspješna financijska institucija treba uspostaviti okvir za upravljanje rizicima. Okvir utvrđuje pravila za upravljanje rizicima unutar institucije, bankarske metodološke zahtjeve za provjeru rizika, pravila za poštivanje zakonitosti, pravila upravljanja kapitalom, likvidnost i poslovne modele. Vrlo je važno da banka ima uspostavljen jasan i transparentan popis svih vrsta rizika, da su određene odgovarajuće uloge i odgovornosti za praćenje rizika te da su propisana načela i aspekti kategorizacije modela rizika (HNB, 2020).

Banka stoga treba uspostaviti okvir za upravljanje rizikom koji joj omogućuje da definira stupanj prihvatljivog rizika, gdje osim značajnih rizika treba voditi računa i o sljedećim

kategorijama: riziku koncentracije, sekuritizacije, izloženosti izvanbilančnim stavkama i sl. (Mahmutović et al., 2010).

U skladu sa Zakonom o bankama, kako bi imali uvid u potencijalne rizike, banke su dužne provoditi: kontrolu i evaluacija svih rizika unutar banke koristeći pri tome različite alate ovisno o vrsti rizika; provoditi analizu i ocjenu svakoga potencijalnog rizika; provoditi praćenje rizika; omogućiti poduzimanje svih mjera za pravovremeno utvrđivanje rizičnih poslova radi smanjenja nastanka rizika; konstantno kreirati i ažurirati kreditne politike; provoditi superviziju procesa odobravanja i kvalitete donesenih odluka na poslovnoj strani (uključujući i korištenje pripadajućih alata).

Najstariji i najznačajniji rizik u bankarstvu je kreditni rizik. No banka je izložena i nizu vanjskih i unutarnjih rizika koji nisu manje značajni. Uz kreditne rizike banke sve više posvećuju pažnju upravljanju i zaštiti od operativnih rizika koji predstavljaju vrlo značajnu komponentu bankarskih rizika.

Neadekvatno upravljanje rizicima, utjecaji raznih makro- i mikroekonomskih čimbenika uzrok su nastanka gubitaka čije gomilanje neminovno dovodi do bankarske krize (Miletić, 2008).

Kvalitetnim upravljanjem kreditnim i operativnim rizicima, smanjuje se potencijalna izloženost banke izvanrednim negativnim događajima posljedica kojih može biti pad likvidnosti i nesolventnosti. Nesolventnost dovodi do stečaja banke, a time i do nepovjerenja i panike među klijentima banaka. Panika stvara masovno povlačenje depozita bez obzira na zdravlje banke te dovodi do nestabilnosti na financijskom tržištu.

Regulatorne institucije u svijetu uvidjele su nužnost provođenja mjera upravljanja svim rizicima s posebnim osvrtom na kreditne i operativne rizike. Tako je banka za međunarodna poravnanja (BIS) 1996. godine donijela propis kojim obvezuje banke na primjenu internih metoda procjene rizičnosti poslovanja pri izračunu adekvatnoga kapitala za pokrića gubitaka (Latković, 2002).

S obzirom na izneseno, pomoćna hipoteza rada glasi (h_1):

Kvalitetnim upravljanjem rizicima u poslovnim bankama smanjuje se negativni efekt krize.

1.3.4. Primjena alata i modela za upravljanje rizicima u bankama

Može li se financijska kriza spriječiti i kako? Ekonomskim stručnjacima često se postavlja pitanje kada i kako intervenirati. Prvo je potrebno definirati kada i do koje mjere je kretanje kreditnog „booma“ na granici fundamentalnoga kretanja, a kada nastaje devijacija. Izrazito veliku ulogu u determiniranju devijacija imaju banke.

Prvo i osnovno je primjena adekvatnih alata za analizu rizičnosti, odnosno izloženosti banke rizicima. Primjena modela u razvijenim bankama omogućuje bankama kontrolu nad svim rizicima, s naglaskom na kreditne i operativne rizike tako da se banka unaprijed zaštiti u vidu dodatnoga kapitala koji služi kao zaštita banke u slučaju nastupa izvanrednih negativnih okolnosti. Ako banka nema razrađene metode i tehnike za praćenje rizika, vjerojatnost da će preživjeti udar krize je vrlo mala. Činjenica da postoje makroekonomski rizici koji mogu izazvati šokove u financijskom sustavu ne znači nužno da bi šokovi bili veliki udarac za banke. Neravnoteža na tržištu može imati ograničen učinak na poslovanje banaka ako banke redovno provode politike kontrole svih rizika, s naglaskom na operativne i kreditne rizike. Svrha testova otpornosti na stres je utvrditi kako se rizici kombiniraju s izloženošću. Dizajn testova otpornosti na stres često je ponavljajući postupak, jer neki izvorno identificirani rizici mogu dovesti do relativno malih utjecaja, dok neki rizici prvotno procijenjeni kao mali mogu dovesti do velikih utjecaja ako postoje značajna izlaganja (Čihák, 2005).

Europska središnja banka (2017) propisala je jedinstvene smjernice za sve banke koje djeluju na području Europske unije o tome kako i koje rizike trebaju pratiti te kako se osigurati. Smjernice se konstantno nadograđuju i nadopunjuju jer je bankarsko tržište vrlo dinamično i teško predvidivo, a izrazito je važno za stabilnost cijeloga gospodarstva. Povećanje ili smanjenje kapitala posredno i izravno utječe na povećanje ili smanjenje drugih značajnih aktivnosti u banci. Tako da ako kapital raste, moguć je rast depozita i plasmana, a to onda znači i rast prihoda i profita. U suprotnom slučaju, tj. ako dolazi do pada kapitala banke, neminovno padaju i ostale navedene kategorije (Kovačević, 2016). Ako banka nema razvijene alate za praćenje i kontrolu rizika, uključujući kreditne i operativne rizike, samo jedan štetni događaj može nanijeti veliku financijsku štetu banci te izravno ugroziti solventnost i likvidnost banke, a time posredno djelovati na stabilnost financijskog sustava neke zemlje.

Stoga se redovito uvode nova pravila za kontrolu rada banaka kako bi se održala njihova stabilnost. Nakon krize 2007. godine uvedene su nove smjernice za kontrolu rada banaka (Basel

III). Krize su ukazale i na važnost fiskalne politike kao i važnu ulogu makrobonitetne politike koja u kombinaciji s drugim politikama, posebno monetarnom politikom, svojim mjerama može ublažiti krize u nastanku. Mnoge zemlje odlučile su se na povećanje svojih internacionalnih rezervi. Povećanje u rezervama pomoglo je brojnim zemljama da prevladaju financijsku krizu iz 2007. godine u puno blažem obliku.

S obzirom na izneseno, druga pomoćna hipoteza rada glasi (h_2):

Primjenom razvijenih alata u upravljanju rizicima kao i primjenom modela i smjernica Europske banke može se ublažiti ekonomska kriza zemlje.

1.4. Znanstvene metode

U znanstvenom istraživanju za potrebe ove doktorske disertacije primijenjeno je, u odgovarajućoj mjeri, više znanstveno-istraživačkih metoda kako bi se osigurale pouzdane, vjerodostojne i konkretne spoznaje te zaključci o predloženoj temi.

U svrhu analize postavljenih hipoteza u radu su primijenjene sljedeće znanstvene metode:

Za ispitivanje glavne hipoteze (H1) koja glasi „Kreditni rizici poslovnih banaka djeluju na makroekonomska kretanja u zemlji“ prikupljeni su kvantitativni podaci iz različitih izvora koji su zatim analizirani i sistematizirani. Podaci su prikazani kroz vremensku seriju kretanja koja je predočena grafičkim prikazom. Za utvrđivanje postojanja korelativne veze korišteni su parametrijski testovi. S obzirom na to da su prikupljeni brojčani podaci u linearnom odnosu, korišten je Pearsonov koeficijent korelacije. Linearni odnos varijabli prikazan je i tablično i putem dijagrama rasipanja (engl. *scatter diagram*). Uz parametrijske testove za ispitivanje glavne hipoteze primijenjena je i metoda kompilacije dobivenih rezultata s radovima drugih autora koji su provodili slična ili ista istraživanja.

U svrhu ispitivanja druge glavne hipoteze (H2) koja glasi „Makroekonomska kretanja djeluju na kreditne rizike u poslovnim bankama“ prikupljeni su kvantitativni podaci iz različitih izvora koji su zatim analizirani i sistematizirani. Podaci su prikazani kroz vremensku seriju kretanja koja je predočena grafičkim prikazom. Za utvrđivanje postojanja korelativne veze korišteni su parametrijski testovi odnosno Pearsonov koeficijent korelacije. Linearni odnos varijabli

prikazan je i tablično i putem dijagrama rasipanja (engl. *scatter diagram*). Za obradu hipoteze primijenjena je metoda kompilacije dobivenih rezultata s radovima drugih autora koji su provodili slična ili ista istraživanja.

Za ispitivanje pomoćne hipoteze koja glasi „Kvalitetnim upravljanjem rizicima u poslovnim bankama smanjuje se negativni efekt krize“ primijenjene su sljedeće znanstvene metode: metodom analize zaključak je sveden na jednostavnije dijelove, a prikupljeni kvantitativni podaci analizirani su i obrađeni Spearmanovim koeficijentom korelacije. Spearmanov koeficijent korelacije upotrijebljen je za utvrđivanje postojanja korelativne veze između varijabli o kretanju bruto domaćeg proizvoda (BDP-a), NPL-a, stope nezaposlenosti i indeksa pravnih radnji. S obzirom na to da su podaci o kretanju BDP-a po brojčanoj vrijednosti značajno veći i odstupaju od ranga kretanja brojčanih vrijednosti podataka o kretanju NPL-a i stope nezaposlenosti, primjena parametrijskih metoda mogla bi dovesti do krivih rezultata i zaključaka. Dobiveni rezultati obrađeni Spearmanovim koeficijentom korelacije prikazani su tablično. Grafički su prikazane distribucije i korelacije ispitivanih varijabli (matrice dijagrama rasipanja za sve ispitivane varijable). Za obradu hipoteze primijenjena je metoda kompilacije dobivenih rezultata s radovima drugih autora koji su vršili slična ili ista istraživanja.

Za dokazivanje pomoćne hipoteze „Primjenom razvijenih alata u upravljanju rizicima kao i primjenom modela i smjernica Europske banke može se ublažiti ekonomska kriza zemlje“ primijenjene su različite metode poput metode analize i sinteze kojom su kvantitativni podaci iz različitih izvora razvrstani u kategorizirane skupine na temelju kojih se zatim vršila obrada podataka. Metodom klasificiranja prikupljeni podaci svrstani su u kategorije prema zajedničkim svojstvima na temelju podataka kojima je već utvrđeno pripadanje pojedinoj kategoriji, podaci su obrađeni metodom kvantificiranja, a rezultati su predočeni u tabličnom prikazu.

Statistički podaci korišteni u istraživanju preuzeti su iz baza podataka Hrvatske narodne banke (u nastavku teksta HNB), Državnog zavoda za statistiku (u nastavku teksta DZS), European Central bank (u nastavku teksta ECB), European Commission, SAS® OpRisk Global Data base, baze podataka KPMG-a za 2018. godinu, baze podataka Svjetske banke te baze podataka Global Finance Practice (2017). Analiza rezultata primarnog istraživanja provedena je pomoću programskog paketa Statistica 13.5

1.5. Očekivani znanstveni doprinos

Temeljni cilj doktorske disertacije je oblikovanje modela međuodnosa kreditnih rizika i makroekonomskih kretanja, odnosno promatranje indikatora bankarskog sustava i njihova uloga u kretanju makroekonomskih varijabli u Hrvatskoj. Nakon identificiranja ključnih parametara za ispitivanje makroekonomskih kretanja kao i identificiranja ključnih indikatora bankarskog sustava, modeliranjem će se uspostaviti funkcijski odnos između parametara kretanja bankarskih i makroekonomskih varijabli.

Stoga se znanstveni doprinos doktorske disertacije ogleda u: iznošenju pregleda i analizi dosadašnjih konceptualnih i empirijskih istraživanja domaćih i stranih autora o predmetu istraživanja; razvoju znanstvenih spoznaja o rizicima u bankama; razvoju znanstvenih spoznaja o makroekonomskim varijablama te razvoju znanstvenih spoznaja o makroekonomskim kretanjima i njihovu značaju u formiranju poslovnih politika banaka čime će se unaprijediti postojeća znanja i pridonijeti daljnjem razvoju navedenih objekata istraživanja.

Očekivanja su da će provedena istraživanja, sekundarno i primarno, u znanstvenom smislu pridonijeti razumijevanju teorijskog okvira vezanog uz međuodnos makroekonomskih kretanja i bankarskih rizika. Rezultati istraživanja u užem kontekstu trebali bi pridonijeti teoriji o povezanosti makroekonomskih kretanja i bankarskih rizika s naglaskom na kreditne rizike kao generatoru makroekonomske stabilnosti zemlje, a u širem kontekstu u aplikativnom smislu na formuliranje svijesti o povezanosti rizika u poslovnim bankama i njihovu značajnu utjecaju na formiranje gospodarskih kretanja zemlje u čemu presudnu ulogu imaju kreditni i operativni rizici banaka.

Primjena statističkih metoda ekonomske analize treba omogućiti otkrivanje izravnih i posrednih djelovanja makroekonomskih varijabli na bankarske čimbenike kroz inkorporiranje većeg broja različitih varijabli čiji je utjecaj parcijalno testiran ranijim istraživanjima, ali nikada nisu testirane u okviru cjelovitog modela.

Aplikativni doprinos rada odnosi se na bankarski sustav, ali i na državne institucije. Očekuje se poboljšanje postojećeg modela upravljanja rizicima na način da će menadžeri u financijskim institucijama kao i Vlada više pažnje posvetiti bankarskim rizicima. Financijski menadžeri, uz osnovnu djelatnost odobravanja kredita i primanja depozita, moraju razviti svijest o potrebama

ulaganja za zaštitu od rizika. Pri tome se misli na osnivanje posebnih odjela unutar financijskih institucija za praćenje rizika kao i uvođenje novih te poboljšanje postojećih modela i alata za zaštitu od rizika. Razumijevanje rizika te kontrola nad rizicima pomoći će u eliminiranju nastanka potencijalnih šteta uzrokovanih rizičnim događajima, a time i na profitabilnost banke. Osim financijskim menadžerima, rezultati istraživanja mogu biti od koristi i Vladi jer upravljanje rizicima u bankama direktno ili indirektno utječu i na makroekonomska kretanja.
Na temelju provedenih analiza daju se preporuke za postupanje u svrhu jačanja stabilnosti bankarskog sustava smanjenjem izloženosti banaka strukturnim rizicima uzrokovanih internim ili eksternim čimbenicima.

1.6. Struktura rada

Rad je strukturiran u sedam poglavlja. U uvodnom dijelu rada definiran je problem istraživanja, ciljevi i svrha rada, hipoteze istraživanja, primijenjene znanstvene metode, očekivani znanstveni doprinos te opis strukture rada.
Nakon uvodnog dijela, drugo poglavlje rada odnosi se na bankarski sustav općenito. Obrađuje se profitna funkcija banke kao i način kreiranja kamatnih stopa. U nastavku drugog poglavlja rada predstavljen je način organizacije bankarskog sustava, područja djelovanja, način funkcioniranja te različiti tipovi i organizacije bankarskog sustava u svijetu.
Unutar trećeg poglavlja obrađuju se oblici financijskih kriza te njihov učinak na bankarski sustav, ne samo u Hrvatskoj, već u cijelom svijetu. U poglavlju je obrađena i uloga financijskih kriza na svjetsko gospodarstvo s osvrtom na gospodarstvo Hrvatske.
Nakon uvoda u bankarski sustav i financijske krize u četvrtom poglavlju rada obrađuju se bankarski rizici koji su podloga za razumijevanje nastavka doktorskog rada. Bankarski rizici su vrlo kompleksan segment banke i samo su dio područja banke, ali je njihov značaj za banku i gospodarstvo golem. U poglavlju o rizicima posebno su obrađeni kreditni rizici i operativni rizici kao najznačajniji bankarski rizici. Važnost rizika u bankarstvu opisana je u nastavku istoga poglavlja. Poglavlje završava regulatornim tijelima, smjernicama i nadzorom banaka.
Unutar petog poglavlja rada analizirane su i obrađene glavne i sporedne hipoteze rada. Poglavlje započinje obradom prve glavne hipoteze rada te prikazuje povezanost kreditnih rizika, kao najvažnijih rizika banke i gospodarskih kretanja. Poglavlje započinje ulogom financijskoga sustava na gospodarski rast koja je odavno predmet istraživanja ekonomista. Većina istraživanja odnosi se na skupine razvijenih država, a samo mali broj istraživanja odnosi se na

Hrvatsku i to uglavnom u sklopu istraživanja tranzicijskih zemalja. Dosadašnja empirijska istraživanja ostalih autora vezana uz odnos financijskog sustava i gospodarskog rasta opisana su tekstualno te radi lakšeg praćenja prikazana i tablično. Tablica 2. sadrži ključne podatke o autorima rada, nazivu rada, analizi koja je provedena u radu te zaključak za svaki rad zasebno. U nastavku poglavlja rada nalazi se empirijsko testiranje prve glavne hipoteza rada. Predočeni su učinci financijskoga sustava na gospodarski rast u Hrvatskoj. Kako bi se predočila poveznica, predstavljeni su indikatori za analizu profitabilnosti i rizičnosti bankarskog sustava u Hrvatskoj te modeli apsorpcije šokova u bankama jer samo stabilan financijski sustav može pridonijeti gospodarskom rastu. Prezentirani su podaci i metodologija za analizu hipoteze kao i empirijsko testiranje prikupljenih podataka i analiza dobivenih rezultata. U drugom dijelu petog poglavlja obrađuje se i druga glavna hipoteza rada; uloga makroekonomskih kretanja na promjene financijskog sustava u Hrvatskoj. Unutar poglavlja su sadržana dosadašnja empirijska istraživanja ostalih autora vezana uz odnos makroekonomskog okruženja i stabilnosti financijskog sustava. Istraživanja su opisana tekstualno te ujedno prikazana tablično radi lakšeg praćenja. Tablica 6. sadrži ključne podatke o autorima rada, nazivu rada, analizi koja je provedena u radu te zaključak za svaki rad zasebno. U nastavku poglavlja, u sklopu analize rada, objašnjene su varijable i korišteni parametri kojim će se potvrditi ili opovrgnuti druga hipoteza rada. Detalji o provedenoj analizi kao i dobiveni rezultati analize druge glavne hipoteze, objašnjeni su u nastavku poglavlja. Unutar zadnjeg potpoglavlja petog poglavlja obrađuju se i pomoćne hipoteze. Odnosno, provodi se empirijsko istraživanje o bitnosti kvalitetnog upravljanja rizicima u poslovnim bankama primjenom razvijenih alata u upravljanju rizicima sukladno uputama Europske banke. Istraživanje hipoteza obrađeno je preko dva najznačajnija bankarska rizika: operativni rizik i kreditni rizik. Empirijsko istraživanje kreditnog rizika provodi se putem udjela neprihodujućih kredita – NPL-a – u bilancama banaka, dok se istraživanje operativnih rizika obrađuje analizom štetnih događaja uzrokovanih operativnim rizicima. Analiza kao i rezultati provedenog istraživanja nalaze se u nastavku istog poglavlja rada. Indikatori unutar doktorskog rada sadržani unutar petog poglavlja rada obrađeni su različitim statističkim metodama ovisno o hipotezi, dobiveni rezultati su analizirani te obrađeni za svaku hipotezu zasebno. Dobiveni rezultati prikazani su grafički i tablično.

Šesto poglavlje prikazuje implikacije istraživanja, objašnjava ograničenja istraživanja te sadrži preporuke za menadžment banaka i Vladu kao i preporuke za buduća istraživanja.

Zadnji, ujedno i zaključni dio rada je u sedmom poglavlju ovog doktorskog rada.

2. Bankarski sustav

2.1. Pojam i definicija bankarskog sustava

Prema Heffernanu (2005), pojam „banka“ može se upotrijebiti za niz financijskih institucija, od malih depozitarnih agencija do velikih multinacionalnih financijskih korporacija. Gregurek i Vidaković (2015) definiraju banku kao instituciju koja se bavi prikupljanjem sredstava, plasiranjem sredstava i pružanjem financijskih usluga. Prema ovoj definiciji, banka je određena kao institucija, a ne kao financijska institucija jer banka više nije ograničena na financijsko poslovanje nego je proširila svoje usluge i izvan klasičnih okvira. Banke tako obavljaju i neke poslove na financijskom tržištu koje rade i druge institucije pa su se pretvorile u specifične financijske konglomerate, odnosno financijske institucije potpune usluge (Leko, Stojanović, 2018). U europskim zemljama uglavnom su razvijene velike regionalne, multinacionalne banke koje nude paletu financijskih usluga i zovu se univerzalne banke.

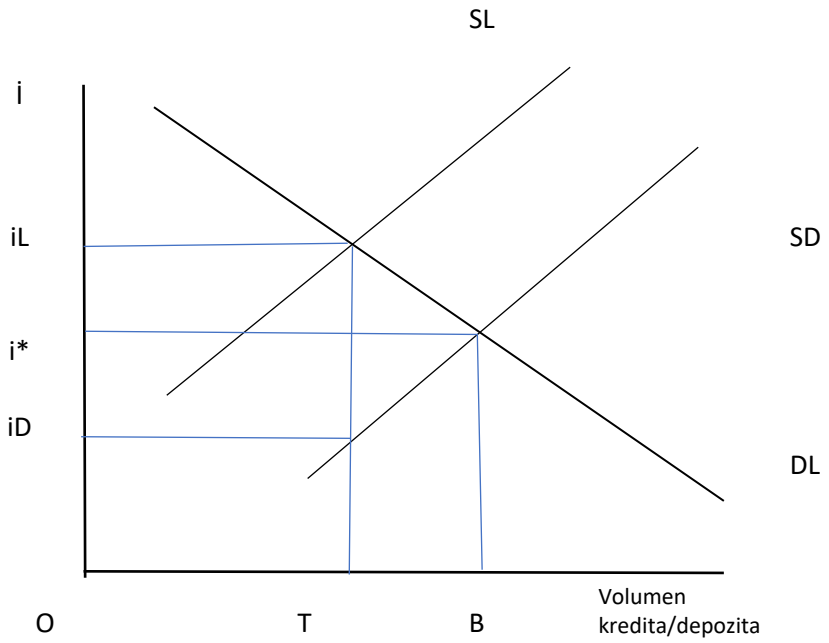
Financijske institucije su dio financijskog sustava. Financijski sustav može se definirati kao skup institucija, tržišta i propisa koji omogućuju alokaciju resursa u vremenu i prostoru. Ovaj temeljni cilj financijski sustav ispunjava obavljajući pet osnovnih funkcija: mobiliziranjem štednje, alokacijom resursa, korporativnom kontrolom, upravljanjem rizikom i olakšavanjem razmjene dobara i usluga (Levine, 1997). Prema Levinu (1997), financijski sustav objedinjuje tri područja: financijske institucije, ponudu i potražnju te novčano potraživanje, a osnovna zadaća je mobilizacija viškova novčanih sredstava na tržištu te transfer viška sredstava za potrošnju i investicije onima kojima je potrebno. Stabilan financijski sustav je pokretač cijeloga gospodarstva.

Stoga je kreditiranje putem banaka posebno važno iz dva razloga. Prvo, zajmovi banaka najčešći su izvor vanjskog financiranja za poduzeća. Relevantnost kreditiranja banaka kao izvora vanjskog financiranja posebno je značajna za mala i srednja poduzeća te u tržištima u nastajanju. Drugo, u suvremenim društvima banke su vrlo posebni subjekti, koji mogu imati značajan utjecaj na funkcioniranje gospodarskog sustava (Campiglio, 2016). Osiguravanje depozita i plasiranje kredita razlikuje banke od ostalih financijskih institucija. Depoziti su obveza banke prema klijentima s kojim uspješno upravlja u svrhu maksimalizacije profita, dok s druge strane postoje krediti koji čine osnovnu imovinu banke. Usluge banaka su primanje novčanih depozita i odobravanje kredita i drugih plasmana iz tih sredstava u svoje ime i za svoj račun, kao i izdavanje sredstava plaćanja u obliku elektronskog novca (Zakon o bankama, članak 3.). Stoga je osnovna uloga banke uspješno posredništvo u prikupljanju viška sredstava

(depozita) s jedne strane te uspješno plasiranje tih sredstava onome kome ta sredstva trebaju (zajmoprimci).

Taj se odnos najjednostavnije može predočiti sljedećim grafičkim prikazom.

Slika 3. Ponuda i potražnja za kreditnim proizvodima



Izvor: Heffernan, S., 1996. *Modern Banking in Theory and Practice*, str. 2

Pokazatelji označavaju sljedeće:

iL – iD – kamatna stopa nastala kao razlika između kamatne stope na kredit (iL) i kamatne stope na depozit (iD), kamatna marža

SD – krivulja ponude depozita

SL – krivulja ponude kredita

DL – krivulja potražnje kredita

OT – iznos plasiranih kredita

i* – tržišna kamatna stopa bez operativnih troškova banke.

Na vertikalnoj osi je kamatna stopa (i), a na horizontalnoj osi nalazi se iznos depozita/kredita. Na sjecištu krivulje ponude depozita (SD) i krivulje potražnje kredita (DL) je tržišna kamatna stopa (i*). To je čista kamatna stopa koja se formira u savršeno konkurentnoj ekonomiji bez dodatnih troškova provizije banke. Dakle, kamatna stopa banke formira se u odnosu na ponudu i potražnju za kreditima. Što je kamatna stopa banke veća, potražnja za kreditima pada i obratno.

Kako bi održale svoju profitabilnost, banke za svoje usluge naplaćuju proviziju koja je uračunata u cijenu kamatne stope i ona se nalazi pod točkom (iL). Čisti iznos kamatne marže je razlika između kamatne stope na kredit (iL) i kamatne stope na depozit (iD). U proviziji su uračunati troškovi banke za pružanje posredničkih usluga kao i zaštita banke od potencijalnih rizika neplaćanja. U troškove posredničkih usluga uključeni su: administrativni troškovi, transakcijski troškovi, troškovi softvera i sl.

2.1.1. Profitna funkcija banke

Reprezentativna banka (HUB, 2017) prema pretpostavci posluje u uvjetima savršene konkurencije tako da se profitna funkcija može zapisati kao:

$$\pi = r_L L - r_D D - C(D, L)$$

r_L kamatna stopa na dane kredite L, r_D kamatna stopa na primljene depozite D, a C su operativni troškovi upravljanja bankom.

Uvjet maksimalizacije profita može se dobiti derivacijom funkcije profita po kreditima i depozitima što daje:

$$\frac{\partial \pi}{\partial L} = r_L - \frac{\partial C}{\partial L} - (D, L) = 0$$

$$\frac{\partial \pi}{\partial D} = r_D - \frac{\partial C}{\partial D} - (D, L) = 0$$

Prebacivanjem parcijalne derivacije troškova na desnu stranu dobije se:

$$r_L = \frac{\partial C}{\partial L}\,(D, L)$$

$$r_{D=}\,\frac{\partial \mathrm{C}}{\partial \mathrm{D}}\,(\mathrm{D,L})$$

Dakle, u ovome će modelu banke prilagođavati količinu kredita i depozita ili kamatne stope na kredite i depozite tako da ostvarenom maržom pokriju granični (operativni) trošak upravljanja bankom (jednostavnije pisan kao MOC):

$$(r_{L-}\, r_D) = \text{MOC}$$

Ako se model prilagodi tako da se pretpostavi da banka posluje na tržištu oligopola, jednadžba se može zapisati kao:

$$(r_{L-}\, r_D) = \text{MOC} + \frac{1}{N}\left(\frac{1}{\mu L} + \frac{1}{\mu D}\right)$$

gdje je N broj banaka, a μ_L i μ_D elastičnosti ponude kredita i potražnje za depozitima. Što je manji broj banaka na tržištu i što su manje elastičnosti, to su veće kamatne marže (banke mogu naplaćivati više aktivne kamatne stope i plaćati niže pasivne kamatne stope). Prema analizi HUB-a (2017), budući da se tržišna koncentracija najčešće mjeri Herfindahl-Hirschmanovim indeksom, u nastavku teksta će izraz $\frac{1}{N}\left(\frac{1}{\mu L} + \frac{1}{\mu D}\right)$ biti zamijenjen kraticom HHI.

Osim operativnih troškova i tržišne koncentracije, na ponašanje banaka utječu i rizici, pri čemu se kao posebno važni ističu rizik likvidnosti LR i kreditni rizik CR. Uzimajući u obzir rizike, jednadžba se može zapisati na sljedeći način:

$$(r_L - r_{D)} = \text{MOC} + \text{HHI} + \text{LR} + \text{CL}$$

Rizik likvidnosti djeluje na kamatnu maržu tako da potreba za održavanjem viška likvidnosti za banke predstavlja oportunitetni trošak koji one pokušavaju kompenzirati povećanjem kamatne marže.

Kreditni rizik na maržu djeluje na dva načina:

(1) viši kreditni rizik podrazumijeva težu naplatu kredita te zahtijeva povećane resurse banke (troškove) pri naplati

(2) kreditni rizik povećava premiju rizika koja ulazi u izračun aktivne kamatne stope.

2.1.2. Kamatne stope

Veselica (2002) navodi da je akt štednje akt posuđivanja kao i uzajmljivanja i investiranja povezan preko financijskog sustava. Faktor koji signifikantno utječe na navedene procese i povezuje ih u cjelinu je **kamatna stopa**. Kamatna stopa kao povezujuća sila raznolikih interesa daje cjenovne signale uzajmljivačima, posuđivačima, štedišama i investitorima. Tako, npr., visoka kamatna stopa, općenito, generira veći volumen štednje i stimulira posuđivanje. Niske kamatne stope s druge strane slabe tijekove štednje i reduciraju posuđivačke aktivnosti. Istovremeno, visoke kamatne stope reduciraju volumen posuđivanja i kapitalnog investiranja, a niske kamatne stope stimuliraju uzajmljivanje i investicijsku potrošnju. Prema definiciji HNB-a (2020), kamata je cijena koju kreditna institucija naplaćuje za korištenje sredstava odobrenoga kredita odnosno cijena koju kreditna institucija plaća za sredstva koja potrošač ulaže kao depozit/štednju.

Visina kamate stope ovisi o vrsti i iznosu kredita ili depozita, roku na koji se kredit odobrava odnosno o roku na koji se sredstva ulažu, visini ugovorene kamatne stope i metodi obračuna kamata koju primjenjuje kreditna institucija. Nadalje, visina kamatne stope ovisi o konkurenciji, stopi inflacije, kreditnom rejtingu zemlje itd.

Kamatne stope mogu biti **fiksne i promjenjive**. Osim toga, potrebno je obratiti pozornost na razliku između nominalne i efektivne kamatne stope, a pri razmatranju odluke o ugovaranju kredita važna je informacija o visini interkalarne kao i zatezne kamatne stope (HNB, 2020).

Fiksne kamatne stope su stope koje su fiksne za cijelo vrijeme trajanja ugovornog odnosa te su zbog toga često nešto više od kamatnih stopa koje su navedene kao promjenjive. Za razliku od fiksnih kamatnih stopa, **promjenjive kamatne stope** se mogu za cijelo vrijeme trajanja ugovornog odnosa mijenjati ovisno o kretanju parametra promjenjivosti. Rast kamatne stope djeluje na povećanje obveze po kreditu, a ako je riječ o rastu ili padu kamatne stope na depozit, naknadnim smanjenjem ili povećanjem ugovorene promjenjive kamatne stope ostvaruje se rast ili pad prihoda od kamate na depozit.

U skladu sa sistematizacijom HNB-a u Hrvatskoj se primjenjuju sljedeće vrste kamatnih stopa:

Nominalna kamatna stopa – osnovna je kamatna stopa za obračun kamata i najčešće se iskazuje kao godišnja kamatna stopa, pa ju je za kraća razdoblja potrebno preračunavati, a

ugovara se kao fiksna ili promjenjiva. Maksimalna visina nominalne kamatne stope na kredite potrošačima propisana je odredbama članaka Zakona o potrošačkom kreditiranju.

Efektivna kamatna stopa (EKS) – jedinstven je način prikazivanja kamatne stope radi transparentnosti i lakše usporedbe uvjeta za odobravanje kredita/depozita kod svih kreditnih institucija i kreditnih unija. Osim nominalne kamatne stope u izračun se uključuju i naknade koje se plaćaju pri odobravanju kredita ili ulaganja depozita te predstavlja realniji prikaz ukupne cijene kredita/depozita. EKS omogućuje potpuniju informaciju na temelju koje se mogu usporediti aktualne ponude kako bi se donijela odluka o onoj koja najviše odgovara klijentovim mogućnostima i očekivanjima.

U izračun EKS-a za kredite ne uključuju se:

- javnobilježničke pristojbe
- zatezne kamate ili bilo koji drugi troškovi proizašli iz nepridržavanja uvjeta ugovora o kreditu
- poštarine, troškovi telegrama i telefaksa.

Maksimalna visina EKS-a za potrošače propisana je odredbama članka 20.a Zakona o potrošačkom kreditiranju, odnosno člankom 17. Zakona o stambenom potrošačkom kreditiranju.

Interkalarna kamatna stopa – primjenom te stope izračunava se i naplaćuje kamata od trenutka kada se odobri kredit do trenutka plaćanja prvog anuiteta/rate kredita. Ako kreditna institucija obračunava interkalarnu kamatu, prije zaključivanja ugovora poželjno je provjeriti trenutak isplate sredstava kredita kako bi interkalarna kamata bila što manja.

Zatezna kamatna stopa – primjenjuje se na iznos dospjele neplaćene obveze iz ugovora o kreditu. Visina najviše dopuštene zatezne kamatne stope za potrošače regulirana je Zakonom o obveznim odnosima.

Direktni dogovori o kreditiranju između zajmodavca i zajmoprimca često generiraju puno veće troškove nego što je iznos troška banke za posredničke usluge. Troškovi koji se mogu pojaviti pri direktnoj pogodbi su: pronalazak pravog zajmoprimca na tržištu, troškovi pregovaranja o uvjetima kreditiranja između zajmoprimca i zajmodavca, troškovi provjere solventnosti odnosno kreditne sposobnosti zajmoprimca (hoće li zajmoprimac moći izvršiti povrat

primljenih sredstava u skladu s planiranom dinamikom) kao i troškovi praćenja sigurnosti povrata sredstava. S obzirom na to da banke posluju na načelu ekonomije razmjera koja se još naziva ekonomija obujma, njezini troškovi su znatno niži pa je time i privlačnija za investitore. Upotrebom razgranate i široke baze podataka kojom raspolaže, banka smanjuje prosječne troškove „proizvodnje“ uslijed povećanog razmjera (volumena) „proizvodnje“. Banke se u svojem poslovanju služe paletom dostupnih, povjerljivih podataka o zajmoprimcima, posjeduju razvijene alate za mjerenje rizičnosti povrata svake investicije, zapošljavaju profesionalne i educirane timove za provjeru kvalitete investicije, pružaju pravnu podršku, pružaju uslugu pregovaranja između zainteresiranih strana za značajno manje troškove od troškova direktne pogodbe koje bi imao investitor ako samostalno želi pronaći ulagača. Što je veći broj investitora i zajmoprimaca, banka generira manji trošak. Pri obavljanju navedenih posredničkih poslova, banke su pod strogim nadzorom regulatornih tijela što dodatno stvara sigurnost depozitarima za investiranje sredstava kao i sigurnost pozajmljivačima za izbor pravog investitora za što niže troškove.

Jedan od kompleksnijih poslova svake banke je održavanje svakodnevne likvidnosti banke. Štediše, zajmoprimci i zajmodavci imaju različite sklonosti likvidnosti. Klijenti očekuju da u svakom trenutku mogu povući vlastita sredstva na svojim računima u banci, dok s druge strane banka ta ista sredstva plasira zajmodavcima koji vrše povrate zaprimljenih sredstava unaprijed dogovorenom dinamikom. Kada je riječ o golemom broju štediša i zajmodavaca koji na vlastiti zahtjev u bilo koje vrijeme moraju biti zadovoljeni, može doći do disbalansa u likvidnosti banke, stoga je upravljanje likvidnošću jedan od bitnih segmenata poslovanja banke.

2.2. Način organizacije i ustrojstva banaka

Prema Heffernan (2005), prva trgovačka banka osnovana je 1762. godine u Velikoj Britaniji. Originalna trgovačka banka bavila se uslugama financiranja uvoza i izvoza roba koje su proizvela mala i srednja poduzeća. Na početku su trgovačka društva izdavala bankama mjenice kao osiguranje financiranja, a nakon što su stekle kreditnu sposobnost financiranje se provodilo akreditivima (garancijska pisma) kojim banka garantira kupcu isporuku robe u iznosu i kvaliteti kako je dogovoreno ugovorom. Nakon financijske reforme iz 1986. godine izmijenjen je izvorni oblik trgovačkih banaka. Reforme su omogućile financijskim kompanijama sudjelovanje na

Londonskoj burzi, ukinuta je fiksna provizija te su ukinute razlike između brokera i špekulanata. Ove promjene utjecale su na povećanje aktivnosti banaka na burzama. Velike trgovačke banke u Velikoj Britaniji počele su pružati usluge slične uslugama američkih investicijskih banaka kao što su akvizicije i spajanje, upravljanje fondovima, konzultantske usluge, trgovina vlasničkim i obvezničkim vrijednosnim papirima itd. S vremenom je pojam „trgovačka banka“ u potpunosti nestao.

Prema Cindori i Petrović (2016), kolijevkom bankarstva smatra se Italija jer su prve banke nastale u Firenci, Genovi, Milanu i Veneciji. Bankarstvo se sve više širilo i razvijalo prema Atlantiku 1350. – 1600., a posebno je došlo do izražaja u 15. stoljeću s otkrićem novog puta prema Indiji. Ne samo kao djelatnost već i kao vještinu bankarstvo su 1260. Engleskoj predstavili Talijani tijekom obavljanja trgovinskih poslova u Londonu. Do uspona engleskog bankarstva i financija dolazi 1814. porazom Napoleona, nakon čega u 19. stoljeću Engleska postaje centar međunarodnih financija. Nizozemski utjecaj na međunarodno bankarstvo, a posebno na razvoj bankarstva u Engleskoj, izrazit je u 17. stoljeću. U istom je razdoblju, točnije 1609., u Amsterdamu osnovana i burza kapitala.

Začetnik komercijalnog i investicijskog bankarstva su Sjedinjene Američke Države. Osnovna uloga investicijskih banaka je prikupljanje sredstava za velike korporacije i države djelujući kao osiguravatelj korporativnih i državnih vrijednosnica te pružanje usluga akvizicije i spajanja. Moderne investicijske banke obavljaju niz usluga kao što su: globalno skrbništvo, upravljanje fondovima, konzultantske usluge, trgovina vlasničkim i obvezničkim vrijednosnim papirima, spajanje i preuzimanje, osiguranje i sl.

Danas se postavlja pitanje jesu li investicijske banke uopće banke. S obzirom na poslove koje obavljaju, postavlja se pitanje koja je razlika između investicijske banke i nebankarske financijske kompanije. Kao što je spomenuto, osnovna zadaća banaka je posrednička uloga između štediša i zajmoprimaca, kontrola likvidnosti te pružanje usluge platnog prometa. Osnovna uloga investicijske banke je pružanje usluga osiguranja, savjetničke usluge prilikom spajanja ili preuzimanja, trgovina, skrbništvo i upravljanje imovinom. Investicijske banke ne odobravaju kredite kao standardne komercijalne banke stoga se postavlja pitanje koliko su one uopće banke (prilagođeno prema Heffernan, 2005). Danas su uglavnom rasprostranjene univerzalne banke. Uloga univerzalnih banaka je pružanje različitih financijskih usluga. Univerzalno bankarstvo širi poslovne mogućnosti banaka. Međutim, upravo taj širi spektar

poslovnih mogućnosti dovodi do širenja spektra rizika kojima su ove banke izložene. U literaturi se univerzalne banke često označavaju kao osnovni problem globalnog financijskog sustava, koji je omogućio da se rizik investicijskog bankarstva ugradi u komercijalne banke (Pajović, 2018).

Banke su danas organizirane na različite načine. Postoje specijalizirane banke za obavljanje određene vrste poslova i banke koje su organizirane tako da pružaju široku paletu usluga klijentima te obavljaju različite vrste poslova u ime i za račun klijenta. Postojanje i opstanak banaka danas je ugrožen značajnim porastom nebankarskih financijskih institucija koje preuzimaju neke od značajnih poslova banaka kao npr. investiranje i posredništvo (Pirtea et al., 2008). Prema navodima autora, oba sustava treba razvijati jer nude važne sinergije, namijenjene poticanju gospodarskog rasta. Iako banke dominiraju financijskim sustavima u većini zemalja, poduzeća, kućanstava i javni sustav, oslanjaju se na dostupnost širokog raspona financijskih proizvoda kako bi zadovoljili svoje financijske potrebe. Takve proizvode ne pružaju samo banke, već i osiguranje, leasing, faktoring i društva rizičnoga kapitala kao i uzajamni fondovi ili mirovinski fondovi. Za razliku od banaka, ove institucije ne podliježu nadzoru raznih regulatornih tijela te omogućuju relativno brz i jeftin pristup kapitalu. Iako nebankarske financijske institucije pomažu u poticanju gospodarstva, oni također donose opasnosti. Najbolji način za kontrolu tih opasnosti su zakonski propisi. Rizici će se razlikovati ovisno o ekonomskim funkcijama koje obavljaju. Izazov pri uspostavi regulacije je postizanje harmonije između visine rizika i prednosti financiranja jer premala ili nikakva regulativa može dovesti do krize i ozbiljno utjecati na gospodarstvo (Kalra, 2016).

Zarada ili dobit je primarni cilj poslovanja svake poslovne banke, no tek uz uvjet da su u svakom trenutku sposobne izvršiti sve dospjele obveze te barem očuvati vrijednost uloženoga kapitala dioničara. Međutim, profitabilnost i uspješnost poslovanja banaka nije važna samo njihovim dioničarima, upravama, zaposlenima i komitentima već i cjelokupnoj javnosti (Bach et al., 2009).

Način organizacije i ustrojstva banaka pod utjecajem je regulatornih propisa. Različite organizacijske strukture i ustrojstva ipak ne utječu na osnovnu ulogu banaka, a to je pružanje financijskih usluga te obavljanje platnog prometa.

2.2.1. Internacionalno bankarstvo

U zemljama OECD-a uglavnom djeluju međunarodne financijske institucije. Pojam međunarodno bankarstvo prisutan je još od 13. stoljeća (Finel-Honigman i Sotelino, 2015).

Internacionalna banka je svaka poslovna organizacija koja ima svoje podružnice izvan svojih granica (Heffernan, 2005). Prema Fohlin (2014), metode investicijskog bankarstva i stope razvoja investicijskih banaka s vremenom su varirali od zemlje do zemlje. Većina banaka s ulaganjem započele su još kao privatna poduzeća, često pojedinačni trgovci koji su se zatim proširili u privatna partnerstva. Izbor pravnih struktura proširio se političkom i pravnom liberalizacijom u 19. stoljeću. U industrijaliziranim zemljama kontinentalne Europe najveće banke kombinirale su ulaganje i komercijalno bankarstvo te su do 1870-ih postale jedne od najvećih dioničkа društva. Nasuprot tome, velike britanske i američke investicijske banke ostale su u privatnom partnerstvu tijekom cijelog razdoblja.

Razlog postojanja i nastajanja internacionalnih banaka je povećanje profitabilnosti. Internacionalno bankarstvo omogućava izbjegavanje zakonskih barijera, omogućuje slobodu trgovanja i tržišne nepravilnosti. Houston et al. (2012) u svojem radu proučavaju djeluju li razlike u propisima među zemljama na međunarodne bankarske tokove. Njihovo istraživanje upućuje na to da su banke prenosile sredstva na slabije regulirana tržišta u namjeri da ostvare veće profite. Ovaj oblik regulatorne arbitraže sugerira da bi u globalnim propisima mogla postojati destruktivna „utrka do dna“ koja ograničava mogućnost domaćih regulatora da ograniče preuzimanje rizika od banaka. Međutim, također otkrivaju da su veze između regulatornih razlika i bankarskih tokova znatno jače ako je država primateljica sredstava razvijena zemlja s jakim imovinskim pravima i pravima vjerovnika. To sugerira da iako razlike u propisima imaju značajan učinak, bez jakoga institucionalnog okruženja propisi sami po sebi nisu dovoljni za poticanje masovnih tokova kapitala.

Bankarske obitelji Barings[1] i Rothschild[2] su prvi pomaknuli granice financijskog poslovanja s domaćeg na globalno tržište. Obje su obitelji započele kao trgovačke kuće u Londonu i

[1] Francis Baring osnovao je Barings banku 1762. godine. Tijekom napoleonskih ratova od 1801. do 1815., Alexander Baring transformirao je banku u veliku međunarodnu financijsku instituciju. Krajem 1980-ih banka se od tradicionalnog bankarstva prebacila na devizno (FOREX) trgovanje preko svojih inozemnih podružnica te postala žrtva i nesvjesni sudionik masovne prevare. Barings je izgubio više od 1,8 milijardi američkih dolara 1995. godine. Banka je bankrotirala te ju je preuzela nizozemska banka ING po cijeni od 1 američkog dolara.

[2] Obitelj Rothschild poznata je frankfurtska obitelj koja se bavila trgovinom tekstila i robom. Tijekom napoleonskih ratova Nathan Rothschild stigao je u London i stekao bogatstvo kupujući zlatne poluge i prodavajući ih britanskoj vladi. Do 1815. godine, osnovane su prve Rothschild banke u Parizu, Frankfurtu i Londonu. 1981.

Frankfurtu 1760-ih, a do sredine 19. stoljeća proširile su svoje poslovanje na izdavanje obveznica, savjetodavne usluge te posredničke usluge na međunarodnim financijskim tržištima izvan Europe (Finel-Honigman i Sotelino, 2015).

U prirodi bankarskog poslovanja je poslovanje s nematerijalnom imovinom koja nije utrživa na slobodnom robnom tržištu stoga banke otvaraju podružnice u drugim zemljama kako bi pristupile novim tržištima. Na primjer, posao sekuritizacije je bio izrazito popularan na američkom financijskom tržištu, a s obzirom na to da takvog modela poslovanja nije bilo na europskom tržištu, američke banke su preko svojih filijala u Londonu otvorile prostor za pružanje novih financijskih usluga te na taj način stvarale dodatan profit. U posljednjim desetljećima 20. stoljeća banke poput Deutsche Bank (Njemačka), UBS (Švicarska), HSBC (Ujedinjeno Kraljevstvo), UniCredit (Italija) i Citibank (Sjedinjene Države) evoluirale su od moćnih domaćih banaka do multinacionalnih banaka čija profitabilnost više ovisi o ulaganju u inozemstvu nego ulaganju na domaćem tržištu (Finel-Honigman i Sotelino, 2015). Najčešći razlog proširenja poslovanja u druge zemlje je potreba banke za pružanjem potpunih usluga svojim klijentima (najčešće multinacionalnim korporacijama). Kako bi zadovoljili sve potrebe svojih klijenata u drugim zemljama, nužno je poznavati kulturu i tržište zemlje stoga u podružnicama zapošljavaju lokalne profesionalce koji svojim znanjem mogu pratiti zahtjeve klijenata i prilagoditi ih uvjetima zemlje u kojoj se nalaze. Reputacija je izrazito važna imovina banke stoga prilagodba novim tržištima zahtijeva znanje o specifičnostima tržišta što mogu jedino menadžeri iz domicilne zemlje.

U skladu s navedenim, multinacionalne banke mogu se definirati kao trgovci internacionalnih bankarskih usluga.

Prednosti i nedostaci internacionalnih banaka očituju se kroz profitabilnost banke. Kako globalizacija bankarstva raste, tako naknade klijentima trebaju padati zbog lakšeg i jednostavnijeg pristupa kapitalu. Otvaranjem podružnica multinacionalne banke onemogućuju monopol domaćih banaka. Domaće banke pod utjecajem konkurencije stranih banaka prisiljene su sniziti naknade svojih usluga, što pozitivno utječe na klijente koji nemaju mogućnosti zaduživati se u inozemstvu (uglavnom domaće pravne osobe), ali se smanjuje profit bankama. Ovo natjecanje uzrokuje znatno nižu dobit i za strane i za domaće banke (Williams, 2002). To

godine banka je nakratko nacionalizirana. Početkom 2000-ih dolazi do spajanja francuske i britanske Rothschild banke.

potvrđuju Milbourne i Cumberworth (1991) koji navode da je ulazak stranih banaka i trgovaca doveo do povećane konkurencije na veleprodajnom bankarskom tržištu.

Prevelika koncentracija stranih banaka djeluje na kretanje visine naknade. Visina naknade, koje banke naplaćuju za svoje usluge, djeluje na prihodovnu komponentu zemlje, odnosno na državne prihode. Visoka koncentracija stranih banaka dovodi do snižavanja naknade koje banke naplaćuju svojim klijentima za pružene usluge. Što su naknade niže, manje sredstava ide u državni proračun, a sva zarada stranih banaka ide u izvandržavni proračun.

Rast i razvoj internacionalnoga platnog sustava, razvoj globalnoga međubankarskog tržišta te pojava sofisticiranog eurotržišta pokazuje koliko banke danas ovise o profitu ostvarenom trgovanjem na internacionalnom bankarskom tržištu. Danas u svim zemljama OECD-a posluju multinacionalne banke koje pružaju paletu bankarskih usluga.

2.2.2. Ustrojstvo i razvoj banaka u najvećim zemljama svijeta

Kako navodi Heffernan (1996), osamdesetih godina prošloga stoljeća bankarsko tržište je rapidno raslo, između 1973. i 1988. imovina top tristo banaka se udvostručila. Dolazi do značajnog razvoja bankarstva u Japanu koji je danas financijska velesila. Godine 1969. pri rangiranju top deset banaka u svijetu nije bilo nijedne japanske banke, a već 1988. godine u top deset svjetskih banaka devet je bilo japanskih. Godine 1974. više od 41 % ukupne imovine top deset banaka u svijetu pripadale su američkim bankama, slijedile su francuske banke (25 %), britanske banke (17 %), zapadnonjemačke banke (9 %) i japanske banke (8 %). Do 1988. godine udio imovine japanskih banaka značajno je porastao te je iznosio 92,25 % ukupne imovine top deset svjetskih banaka, dok su francuske banke sudjelovale s udjelom od samo 7,75 %.

Prema Heffernanu, sve do sedamdesetih godina prošlog stoljeća zabilježen je rast internacionalnih banaka u Americi. Od 1970. godine globalni razvoj internacionalnih banaka je stao. Godinama je Bank of Amerika zauzimala prvo ili drugo mjesto u rangu top deset svjetskih banaka da bi 1988. godine pala na 41. mjesto. Velika američka banka Chase Manhattan također je doživjela pad te se 1987. godine našla na tek 33. mjestu. Citicorp je bila jedina američka banka koja je uspjela zadržati svoju poziciju u top deset banaka sve do 1987. kada je prvi put došla na 11. mjesto zbog rasta japanskih banaka koje su ušle u top deset. U to vrijeme glavni razlog održivosti Citicorpa bilo je ulaganje u naprednu tehnologiju, razvoj novih proizvoda kao

i kompjuterizacija procesa. Najizraženiji pad poslovne aktivnosti doživjele su komercijalne i trgovačke banke koje se nisu na vrijeme prilagodile trendovima i tržištima Europe i Azije. U to vrijeme američke banke zabilježile su značajan pad u svojim poslovnim aktivnostima. Silazni trend profitabilnosti bilježen je sve do 1988. godine kada je dosegnuo najnižu stopu profitabilnosti u posljednjih petnaest godina. Pad profitabilnosti na američkom financijskom tržištu dogodio se kao posljedica financijskih problema zemalja u razvoju te opadanja cijena roba i nekretnina. Komercijalne banke doživjele su potpuni slom jer su poduzeća s viškovima novčanih sredstava omogućavala zajmove po puno nižim kamatnim stopama nego banka.

Prema Bedeniković (2019), potkraj 1984. na američkom bankarskom tržištu poslovale su 15 084 banke. Do 2005. taj se broj gotovo prepolovio te je pao na 7 482, što je pad od čak 48 %. U navedenom razdoblju nestale su 8 122 banke, a njihov nestanak u najvećoj je mjeri uzrokovan spajanjima i pripajanjima te ostalim oblicima udruživanja poslovanja između 1993. i 2003. godine.

Jedan od razloga pojave holdinga je državna regulacija, kao što je na primjer u SAD-u učinjeno Glass-Steagallovim zakonom kojim je provedena separacija investicijskog i komercijalnog bankarstva. S obzirom na to da je paralelno s Glass-Steagallovim zakonom donesen i zakon o zabrani spajanja banaka iz različitih saveznih država, donošenjem Reagle-Nealova zakona 1994. godine konglomerizacija u SAD-u počela je drastično rasti jer je navedenim zakonom ukinuta zabrana konglomerizacije izvan matične savezne države (Bedeniković, 2019).

Ustrojstvo i organizacija banaka ima svoje specifičnosti. Struktura i način organizacije banaka razlikuje se od zemlje do zemlje. Razlike u razinama, trendovima i strukturi stvaranja kapitala utječu i na brzinu i karakter gospodarskog rasta (Goldsmith, 1955).

Financijske institucije Velike Britanije karakterizira jasno razgraničen sustav u skladu s navedenim kategorijama (Heffernan, 1996):

- komercijalno bankarstvo
- investicijske i trgovačke banke
- osiguranja
- upravljanje fondovima
- stambeno financiranje
- trgovanje vrijednosnim papirima.

Prema Finel-Honigman i Sotelino (2015), osamdesetih godina prošloga stoljeća britanski financijski sustav doživio je neviđenu kombinacija strukturnih promjena i financijskih inovacija poznatije kao Big Ban.[3] Strukturne promjene obuhvatile su integraciju teritorijalno razgraničenih institucija, a financijske inovacije obuhvatile su kreiranje novih financijskih instrumenata (novih proizvoda), tehnika (inovacije procesa) i tržišta. To je utjecalo na opseg, broj i raznolikost individualnih instrumenata te je omogućeno da se karakteristike i rizici pojedinih instrumenata mogu razdvojiti te ponovno sastaviti u različitim kombinacijama.

Kako navode Finel-Honigman i Sotelino, financijske inovacije dovele su do smanjenja razlike između bankarskih i nebankarskih financijskih proizvoda. Promjene su dovele do značajnih strukturnih pomaka unutar poduzeća u britanskom financijskom sustavu. Prvi značajni pomak je specijalizacija bankarskih usluga. Od financijskih institucija koje su pružale paletu proizvoda i usluga, bez obzira na to je li riječ o uslugama za pravne osobe ili za građanstvo, do specijaliziranih institucija za pružanje usluga isključivo na području kreditiranja građanstva.

Značaj japanskoga bankarskog sustava je visoka stopa reguliranosti i nadzora koji provodi Japanska nacionalna banka i ministarstvo financija. Nakon propasti 13 financijskih institucija 1995. godine kada su nenaplativi krediti dosegnuli stopu od 13 % ukupnog bruto zaduženja u ožujku 1998., prema Zakonu o stabilizaciji, vlada je bila primorana ubrizgati 1,8 bilijuna ¥ u 21 banku. Od 1999. do 2003. godine čitav je sustav prošao konsolidaciju i reformu kroz niz velikih domaćih spajanja: IBJ se spojio s Dai-Ichijem, Kangyom i Fujijem u Mizuho, financijska grupa Mitsubishi UFJ spojila se i postala druga najveća svjetska banka. Provedena reforma cijelog sustava prije financijske krize 2008. godine utjecala je na to da je Japan relativno neozlijeđen izašao iz globalne financijske i dužničke krize (Finel-Honigman i Sotelino, 2015).

[3] Do 1984. trgovačke banke su počele sudjelovati u brokerskim poslovima, a stranim bankama predvođenim SG Warburgom i Morganom Stanleyu je bilo dopušteno sudjelovati u privatizaciji British Telecoma. Te su reforme kulminirale deregulacijom bankarske strukture poznate kao Big Bang 27. listopada 1986. godine.

Obilježje japanskog financijskog sustava je visoka razina segmentacije. Prema segmentaciji Liu i Wilson (2009), na tržištu djeluju:

1. komercijalne banke
2. kreditne banke
3. skrbničke banke
4. štedne i depozitarne banke
5. poduzeća za trgovanje vrijednosnim papirima
6. ostale financijske institucije kao što je japanska razvojna banka i uvozno-izvozna banka.

Godine 1980. provedena je reforma japanskoga financijskog sustava kojom je omogućeno sudjelovanje japanskim bankama na globalnom financijskom tržištu, dok je domaćim poduzećima omogućeno zaduživanje na offshore tržištima. Nakon reforme prevedene 1992. godine dopušten je pristup stranim financijskim kompanijama na japansko tržište (Liu i Wilson, 2009).

Osim što djeluju kao posrednici između zajmodavaca i zajmoprimaca, banke upravljaju likvidnošću te igraju vrlo značajnu ulogu u makroekonomiji. Različita organizacijska struktura omogućuje bankama prilagodbu tržištu i zahtjevima tržišta. Banke se stoljećima prilagođavaju izmjenama tržišta i potrebama klijenata kako bi ostvarile maksimalan profit, a zbog značaja i utjecaja na ekonomiju zemlje, pod kontrolom su središnjih banaka zemlje u kojoj posluju. Regulatorna tijela, smjernice i nadzor nad bankama obrađuje se u poglavlju 4.4.

3. Financijska kriza

3.1. Pojam i obilježja financijske krize

U ovome poglavlju rada obrađuje se pojam, obilježja i nastanak financijskih kriza. Ekonomisti monetarnog uvjerenja (Mishkin, 1992; Kirkpatrick, 2009; Jickling, 2009; Crotty, 2020., Swagel, 2009; Kahle i Stulz 2013. i dr.) smatraju da je financijska kriza usko povezana s krizom banaka i kada je stabilnost bankarskog sustava ugrožena, financijska struktura će bez prisutnosti središnje banke kolabirati.

Financijska kriza je tipični multidimenzionalni događaj koji se teško može objasniti samo jednim čimbenikom. Osnovna uloga banaka je kreditiranje zajednice ili nacije na temelju povjerenja svojih klijenata. Propast banke manifestira se kroz gubitak povjerenja njezinih klijenata. Gubitak povjerenja može se preliti na nepovjerenje prema cijelom financijskom sustavu te na nepovjerenje prema državi i regulatorima.

Dinamika kretanja makroekonomskih i financijskih varijabli prije i za vrijeme krize predmet su istraživanja brojnih autora (Swagel, 2009; Griffith-Jones et al., 2009. i dr.). Empirijska istraživanja dokumentirala su i analizirala različite faze nastanka krize. Kriza ne mora nastupiti naglo i nepredviđeno. Može biti uzrokovana dugotrajnom nestabilnošću na financijskom tržištu, dugoročno lošim kreditnim politikama financijskih institucija popraćenih s nerealnim stanjima na tržištu; nerealnim cijenama nekretnina, precijenjenim vrijednostima poduzeća, špekulativnim ulaganjima u visokorizične plasmane itd.

Gotovo nema zemlje na svijetu koja nije prošla barem jednu bankarsku krizu. Prva bankarska kriza dogodila se u 14. stoljeću padom kralja Eduarda III. kada je bankrotirala poznata firentinska bankarska obitelj Bardi. Prve veće ozbiljne financijske krize dogodile su se u Ujedinjenom Kraljevstvu 1866. godine i u SAD-u 1933. godine (Finel-Honigman i Sotelino, 2015). Tijekom 19. stoljeća u Engleskoj su pale dvije velike bankarske institucije: Overend, Gurney i Company Ltd. 1866. godine te Baring Brothers 1890. godine. Posljedica pada dviju velikih financijskih institucija dovela je do lančane reakcije propasti i svih povezanih manjih financijskih institucija (Tooze, 2018). Prva velika kriza u SAD-u bila je 1933. godine kada je propalo 608 banaka. Sve je počelo slomom burze 1929. godine. Nesigurnost na tržištu dionica prenijela se na cijelo financijsko tržište. Dogodio se slom najveće komercijalne banke u SAD-

u – u to vrijeme Banka USA. Banka je bila član američkoga sustava saveznih rezervi i nije se uspjela oporaviti unatoč državnoj pomoći. Nakon siječnja 1933. propast banaka proširila se na cijeli američki kontinent. Da bi se banke zaštitile, predsjednik Roosevelt je od 13. do 15. ožujka 1933. godine bio primoran uvesti državni praznik kako bi se banke zaštitile od paničnih naleta štediša. Godine 1931. u Austriji je bankrotirala najveća austrijska banka Kreditanstalt, dok su se u Njemačkoj banke zatvarale (Heffernan, 2005).

Prema Claessens i Kose (2013), financijska kriza može se pojaviti u različitim oblicima, no mogu se podijeliti na četiri osnovna tipa: kriza nastala utjecajem promjena makroekonomskih varijabli i tečaja, kriza nastala utjecajem promjena u financijskom sustavu tzv. „dužničke krize“, bankarske krize te krize nastale naglim i nepredviđenim šokovima. Kako navode autori, kriza promjene tečaja uključuje špekulativne udare na tečaj što dovodi do deprecijacije valute. Krizom promjene tečaja regulatori poduzimaju mjere za obranu tečaja plasiranjem većih količina internacionalnih rezervi na tržište, politikom naglog podizanja kamatnih stopa te uvođenjem dodatnih kapitalnih kontrola. U literaturi se navode tri modela tečajnih kriza. Prva tečajna kriza nastala je naglim padom cijene zlata 1970. godine opisana kroz tzv. „KFG“ model, zatim model višestruke ravnoteže i model treće generacijske krize oslonjen na neravnotežu platne bilance. Prema autorima, kriza kapitala uzrokuje naglo smanjenje priljeva internacionalnoga kapitala na domaće tržište. U slučaju kada država ne može podmiriti svoje dospjele dugove prema inozemstvu govori se o krizi stranog duga, a kriza domaćeg duga nastaje u situacijama kada država ne može podmiriti domaće dospjele dugove. Nadalje autori navode da priljev stranoga kapitala može imati pozitivan i negativan efekt ako zemlja nije organizirana, odnosno financijski sustav nije dovoljno razvijen za upravljanje većim količinama inozemnoga kapitala, ne postoje kontrole i regulacije na tržištu, ili ne postoji kvalitetna makroekonomska politika.

Financijska kriza poremećaj je na financijskim tržištima na kojem se problemi moralnog hazarda pogoršavaju, tako da financijska tržišta ne mogu učinkovito usmjeravati sredstva onima koji imaju najproduktivnije mogućnosti ulaganja. Kao posljedica toga, financijska kriza može odvesti gospodarstvo do neravnoteže (Mishkin, 1992).

Početkom 20. stoljeća bankarske krize bile su česte, sve dok nije uvedeno osiguranje štednog depozita 1933. godine (Calomiris i Gorton, 1991). Unatoč zaštiti depozita uvođenjem osiguranja depozita, financijska kriza od 2007. do 2009. (u nekim zemljama i do 2013.)

uzrokovala je propast nekoliko velikih financijskih institucija u kojima je došlo do masovnog povlačenja depozita i investicijskih uloga investitora. Mora se uzeti u obzir da u 21. stoljeću osim klasičnih depozita investitori ulažu u banke paletom drugih proizvoda koji nisu osigurani od države. Investiranje u različite vrijednosne papire investitorima donose velike profite (puno veći od kamate na štedne depozite), ali s druge strane u slučaju nastanka krize nisu pokrivena osiguranjem. Za razliku od dužničkih kriza, bankarske krize pojavljuju se često i mnogo su kompleksnije. Problematika se krije u tome što svaka bankarska institucija pojedinačno može biti pokretač krize. Razlog krize ne mora biti isključivo loša poslovna politika banke već i okruženje u kojem ona djeluje. Bankarski sustav podložan je i osjetljiv na promjene na tržištima kao što su izmjene zakona, regulatorne izmjene, odnosno makroekonomske promjene. Zbog kompleksnosti svojega poslovanja, štediše/depozitari ne raspolažu informacijama što se događa unutar banaka koje su uglavnom u privatnom vlasništvu. Poslovne politike i poslovanje banaka izrazito je kompleksno i nerazumljivo štedišama stoga i najmanja naznaka problema unutar jedne financijske institucije može dovesti do panike među štedišama koji masovno počinju povlačiti svoje depozite i dovode do dodatne nestabilnosti ne samo jedne banke već lančano do niza financijskih institucija. Makroekonomske i financijske implikacije kriza obično su ozbiljne i dijele mnoge zajedničke karakteristike različitih vrsta. Veliki gubici proizvodnje zajednički su mnogim krizama, a druge makroekonomske varijable obično bilježe značajan pad (Claessens i Kose, 2013).

Da bi zaštitile financijsko tržište i osigurale povjerenje štediša, središnje banke uvele su niz kontrola i regulativa svim financijskim institucijama. Uloga središnjih banaka je osigurati stabilnost i kontrolu nad financijskim institucijama.

Za održavanje bankarske stabilnosti vrlo je važno kretanje cijena na tržištu nekretnina. (Calomiris i Gorton, 1991). Tržište nekretnina usko je povezano s bankarskim poslovanjem jer osim što nekretnine bankama služe kao vid osiguranja za potencijalne gubitke uslijed neplaćanja obveza klijenata, iznimno su popularni investicijski građevinski krediti. Predviđanja o povratu uloženih sredstava provode se na temelju kretanja cijena nekretnina. Stoga ako dođe do pada cijena nekretnina na tržištu, vrlo vjerojatno će se to značajno odraziti na bankarski sustav. Iako je prave uzroke financijske krize teško identificirati, financijske krize rijetko nastaju kao iznenadni događaj. Posljednjih stoljeća obrasci značajnog povećanja cijena imovine, često praćeni padovima, istaknuti su u mnogim izvještajima o financijskoj

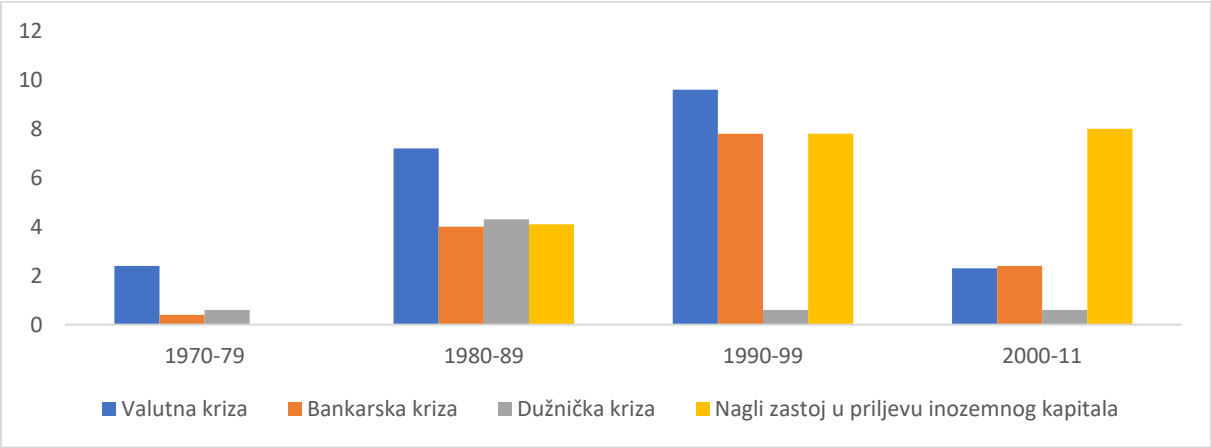
nestabilnosti, kako za napredne, tako i za zemlje u razvoju. Mjehuriće kretanja cijena imovina može se vidjeti u radovima Evanoff et al. (2012) i Scherbina (2013).

Prema Sajter (2017), strukturni problemi kao što je moralni hazard i slaba ili nikakva kontrola, loše korporativno upravljanje također mogu dovesti do bankarske krize. Jedan od najčešćih strukturnih problema upravo su loše ili nikakve kontrole unatoč visokoj reguliranosti. Smatra kako je jedan od temelja globalne financijske krize 2008. upravo moralni hazard te je kao takav izrazito u fokusu interesa kod institucija koje se smatraju „prevelikima da bi propale“, odnosno kod globalno sistemski važnih financijskih institucija.

Praćenjem učestalosti pojavljivanja krize kroz stoljeća, ustanovljeno je da kriza može nastati bez obzira na to je li riječ o razvijenom tržištu ili tržištu zemlje u razvoju. Veća je vjerojatnost da će kriza nastati na tržištu u razvoju i to upravo zbog nedovoljnog stupnja razvijenosti tržišta, nedostatka razvijenih mehanizmima za zaštitu od krize kao i nedostatka regulatornih smjernica. Prema Tooze (2018), od većih i značajnijih kriza zemalja u razvoju valja istaknuti krizu u Latinskoj Americi iz 1970-ih, meksičku krizu iz 1995. godine te istočnoazijsku krizu nastalu sredinom 1990-ih. Većina danas razvijenih zemalja, poput Australije, Španjolske, Velike Britanije i SAD-a, je za vrijeme svojega ubrzanog razvoja prošla razdoblje financijskih kriza. Na primjer, Francuska je čak osam puta od 1550. do 1800. doživjela krizu vanjskog duga. Japan je proživljavao financijsku krizu 1990-ih, a SAD je pak proživio najveću financijsku krizu u povijesti 2007. godine unatoč činjenici da mu je tržište tada bilo na vrhuncu razvoja.

No svakako valja napomenuti da krize novijeg doba nastale u 20. i 21. stoljeću ipak traju puno kraće.

Grafikon 1. Prosječan broj kriza kroz desetljeće



Izvor: Introduction and Description of Financial Crises, Claessens and Kose, 2013.

3.2. Uzroci financijskih kriza

Analizom financijske krize kroz vrijeme dolazi se do zaključka da krize mogu biti uzrokovane domaćom i inozemnom nestabilnošću, privatnim ili državnim sustavom. Javljaju se u različitim oblicima i veličinama te mogu uzrokovati financijsku nestabilnost zemlje, regije, ali i cijelog svijeta.

Financijska kriza od 1997. do 1998. godine u sjevernoj Aziji, Rusiji i Brazilu nastala je zbog nereguliranosti tržišta u situaciji velikog pritoka internacionalnoga kapitala bez postojanja državne regulacije u područjima upravljanja kapitalom. Mishkin (1999) definira financijsku nestabilnost na temelju problema asimetrije informacija ističući kako ona nastupa kada „šokovi financijskog sustava ometaju tokove informacija na način da financijski sustav ne djeluje više u smjeru produktivnih financijskih mogućnosti“. Ako je financijska nestabilnost zastupljena toliko da se urušava i onemogućuje djelovanje financijskog sustava, nastaje financijska kriza.

Prema Laiu (2002), financijska kriza je pojava unutar financijskog sustava koja rezultira gubitkom ekonomske vrijednosti ili gubitka povjerenja u financijski sustav što dovodi do negativnog efekta na realnu ekonomiju. Značajke financijskih kriza Lai dijeli na sljedeći način: „krize uključuju značajne realne troškove u ekonomskom proizvodu, one su epizodni događaji, nastanak krize nije lako predvidljiv, kreditna ekspanzija najčešće prethodi krizi, predstavlja

smanjenu likvidnost, nestabilnost u cijenama aktiva, širenje zaraze među tržištima te gubitak povjerenja od investitora“. U definiranju uzroka financijskih kriza, bankarski sustavi se u izvorima (Heffernan, 2005; Tooze, 2018; Claessens i Kose, 2013) spominje kao osnovni pokretač, odnosno izvor problema. Banke na sebe preuzimaju golem rizik pozajmljivanjem sredstava poduzećima i kućanstvima koji zatim ta sredstva investiraju u imovinu i kapital. Kako udio kratkoročnog financiranja u ukupnom financiranju raste, rizik je sve veći. Kada klijenti više ne mogu podmiriti svoje dugovanje, banke se pokušavaju naplatiti iz imovine dužnika. Kako imovini pada cijena, dolazi do sve većeg rasta NPL-a u bilancama banke. Zbog pada profita, padaju cijene dionica i sve se više iscrpljuje kapital banaka. Među depozitarima raste zabrinutost te u slučaju nedovoljnog osiguranja depozita od banke i/ili države, depozitari povlače svoja sredstva. Kada zabrinutost prijeđe u paniku, dolazi do kolapsa financijskih institucija.

Kolaps većih financijskih institucija prenosi se na manje banke: nastaje panika među građanima koji ne prepoznaju razliku između zdrave, stabilne financijske institucije i financijske institucije u problemu što dovodi do panike i masovnog povlačenja depozita. Bez intervencije središnje banke, manje financijske institucije ostaju bez likvidnih sredstava što dovodi do bankrota, dok veće financijske institucije umanjuju vrijednost svoje imovine u nastojanju da osiguraju dovoljno likvidnih sredstava. Lamfalussy i Lamfalussy (2000) krizu razvijenih zemalja i zemalja u razvoju objašnjavaju kroz problematiku nacionalnih banaka. Kada se nacionalne središnje banke nađu u nedostatku rezervi za podmirenje dospjelih inozemnih obveza denominiranih u drugim valutama te kada takve informacije dospiju u javnost, dolazi do rapidnog povlačenja inozemnoga kapitala iz zemlje što dovodi do kolapsa domaćeg tržišta kapitala i pada vrijednosti domaće valute. U zemljama u razvoju velik priljev stranoga kapitala može biti pokretač krize. Pozitivan kreditni rejting zemlje u razvoju zajedno s optimističnim prognozama mogu ohrabriti strane investitore na velika ulaganja. Tržište kapitala raste te dolazi do ekonomske ekspanzije izvan okvira ekonomske opravdanosti. Samo jedan negativan događaj u zemlji može dovesti do panike stranih investitora koji će početi povlačiti svoje uloge i prestati s investicijama čime će se ugroziti devizna pozicija zemlje.

Kako navodi Heffernan (2005), među prvim značajnim financijskim krizama uzrokovanim lošim upravljanjem središnje banke je bankrot Overend Gurney Ltd. 1866. godine te kriza u SAD-u između 1930. i 1933. godine. Upravo je loša politika središnjih banaka u to vrijeme uzrokovala, odnosno nije spriječila nastanak financijske krize 1866. godine pa zatim 1930. –

1933. Središnja banka nije na vrijeme osigurala likvidnost solventnim, ali nelikvidnim bankama što je dodatno uzrokovalo pad nekih najvećih financijskih institucija. No u vrijeme ubrzanog razvoja financijskih institucija vrlo je otežano prepoznati problem likvidnosti pogotovo ako su banke solventne.

Ekonomska i financijska kriza zemalja u razvoju 2008. godine bila je potaknuta kombinacijom triju čimbenika: visokom razinom financijske dostupnosti, visokom cijenom roba i usluga, te velikim protokom kapitala među razvijenim zemljama. Kriza naglašava žurnu potrebu za ubrzavanjem financijskog razvoja zemalja u razvoju, kako kroz domaće financijsko produbljivanje i mobilizaciju domaćih resursa, tako i kroz reformu međunarodnoga financijskog sustava (Naudé, 2009). Za vrijeme ekonomskog uzleta dolazi do povećane potražnje za kreditima.

Prema Schularick i Taylor (2012), kreditni *boom* povećava ponudu novca na tržištu što dovodi do rasta investicija. Bankarski sustav postaje sve krhkiji:

- banke ne vrše rezervaciju za potencijalne gubitke u iznosima koje bi trebale jer ne očekuju pad vrijednosti osiguranja za vrijeme ekonomskog uzleta što investitorima omogućuje ulaganja u sve rizičnije plasmane
- potražnja nadmašuje ponudu u novim profitabilnim sustavima, dolazi do porasta cijena, stvaraju se dodatni profiti, veća ulaganja i veća zarada koja dovodi do novih rizičnih ulaganja
- ponašanje krda u kombinaciji sa špekulativnim investicijama i neiskusnim financijskim savjetnicima dovodi do neizbježnoga kraha.

Manija za špekulativnim ulaganjima za ostvarenje što većeg profita bez obzira na rizik koji nosi takvo ulaganje, dovodi do rasta cijena izvan granica ekonomske opravdanosti. Stvara se tzv. „bubble“. Do stvaranja mjehurića mogu dovesti mikro- i makročimbenici. Mjehurići se mogu odnositi na agencijska pitanja (Allen i Gale, 2007). Mjehurić raste sve dok ne pukne, a njegovim pucanjem nastaju financijske krize. U takvom okruženju samo je jedan događaj dovoljan da dođe do potpunoga kaosa. U trenutku kada kućanstva i poduzeća više ne mogu podmirivati svoje dospjele obveze, pada vrijednost nekretnine, vrijednost osiguranja bankama ne pokriva ni trećinu izloženosti, a rezervacije za potencijalne gubitke ili se nisu provodile ili nisu bile dostatne. Tzv. *bubble kriza* prvi put se pojavila u 17. stoljeću, poznatija kao Dutch Tulip Mania, (Van der Veen, 2012) zatim French Mississippi Bubble 1716. – 1720. godine (Knight, 2002) i

South Sea Bubble u Britaniji 1720. godine. Tijekom ovoga razdoblja cijene određenih proizvoda rapidno su rasle u vrlo kratkom vremenu.

Na temelju rezultata na velikom uzorku razvijenih zemalja i zemalja u razvoju Kaminsky i Reinhart (1999) upućuju na to da se bankarske krize javljaju kada gospodarstvo ulazi u recesiju, često nakon dugotrajnog procvata gospodarske aktivnosti potaknutog povećanim bankarskim kreditiranjem. Dužnici ostaju bez posla i pokušavaju prodati svoju imovinu, ali zbog enormne količine ponude cijene drastično padaju. Ljudi i poduzeća proglašavaju osobni bankrot, propada sve veći broj velikih financijskih kompanija i time je val krize započet. Ovakva situacija stresa i panike prisutna je na tržištima sve dok financijski posrednici ne shvate da su cijene preniske odnosno da su podcijenjene, sve dok se ne zaustavi trgovanje na burzama i dok se ponuda likvidnih sredstava ne uskladi sa stvarnom realnom potražnjom.

Rapidni rast kredita može biti uzrokovan raznim čimbenicima i strukturnim promjenama na tržištu. Šokovi koji dovode do kreditnog *booma* uključuju promjene u produktivnosti, ekonomskoj politici i priljevu kapitala. Ovi šokovi obično se javljaju za vrijeme ili nakon razdoblja ekonomskog uzleta. Empirijska istraživanja (Hristov et al., 2012; Laeven i Majnoni, 2003; Peek et al., 2003. i dr.) dokazala su pozitivnu povezanost između rasta BDP-a i kreditnog *booma*. Kao što je spomenuto, priljev stranoga kapitala također ima utjecaj na kreditni *boom*. Većina internacionalnih tržišta je pod utjecajem globalnih kretanja stoga se učinak krize vrlo često prelijeva na globalno gospodarstvo. Priljev stranoga kapitala stvara dodatna likvidna sredstva bankama koje zatim višak likvidnih sredstava plasiraju na tržište. Što su priljevi kapitala veći, likvidnost banaka je veća, kamatne stope su niže i dolazi do kreditnog *booma*. Relativno niske kamatne stope u SAD-u tijekom 2000. – 2004. često se spominju kao glavni čimbenik rapidnog porasta cijena nekretnina.

Najveća prijetnja svjetskoj ekonomiji svakako je bila kriza 2008. godine. Uzrokovana je neravnotežom na američkom tržištu nekretnina koja se zatim prelila na sve zemlje svijeta bez obzira na stupanj razvijenosti zemlje. Cijena nekretnina u Americi dosegnula je svoj vrhunac ljeti 2006. godine, a nakon toga je počela lagano padati. Ljeti 2007. godine počele su se zatvarati građevinska poduzeća u Španjolskoj, a u listopadu 2007. dolazi do naglog pada cijena nekretnina u Velikoj Britaniji. Deseci milijuna vlasnika nekretnina bili su prisiljeni sniziti cijene nekretnina te je počela padati vrijednost imovine. Ljudi više nisu imali sredstava za podmirivanje svojih obveza. Sekuritizacija je trebala utjecati na disperziju rizika i umanjiti

krizu, ali to je bila samo teorija. U kasno ljeto 2007. godine bilo je evidentno da je to samo teorija, a stvarnost je bila sasvim nešto drugo (Tooze, 2018). Ova je kriza potkopala mnoge najveće financijske institucije u SAD-u i drugdje, kao i ozbiljno naštetila velikom dijelu svjetskoga financijskog sustava.

Nakon izbijanja mjehura *Dotcoma* 2000. i terorističkih napada na SAD, većina naprednih ekonomija započela je razdoblje ekspanzivne ekonomske politike za odbijanje recesije. Federalne rezerve snižavale su diskontnu stopu 27 puta između 2001. i 2003. (Lin, 2008). Niske kamatne stope, olakšane velikim trgovinskim suficitima koje su imale Kina i druge zemlje koje su nekad kupovale američke državne obveznice, potaknule su brzi rast kredita. Rast cijena nekretnina dodatno je potaknuo rast kredita, posebno kroz hipotekarno kreditiranje. U SAD-u se hipotekarno kreditiranje zasnivalo isključivo na vrijednosti nekretnina bez osnovnog sredstva za vraćanje zajmova kao što je kreditna sposobnost dužnika. Takav način kreditiranja poprimio je goleme razmjere jer su cijene nekretnina samo rasle i banke su se osjećale sigurno. Većina američkih hipotekarnih zajmodavaca sekuritizirale su drugorazredne zajmove koji su se zatim prodavali kroz financijski sustav kao imovina. Zbog neadekvatne regulacije tržišta i financijskih inovacija sekuritizacija loših zajmova je bila veliki trend. Druge institucije otežano su procjenjivale rizike sekuritiziranih hipoteka što je dovelo do subprime hipoteka, kredita bez čvrstih jamstava.

Alati i modeli za upravljanje rizikom u rastućoj ekonomiji nisu bili adekvatni ni dovoljno precizni. Rejting agencije su bez većih provjera dodjeljivale visoke ocjene jer je prevladavala ekonomija rasta, a i cijene nekretnina su konstantno rasle.

Barth (2008) u svojem radu upućuje na to da je rejting agencija Standard Poor's 2007. godine 45 % svih novoizdanih vrijednosnih papira ocijenila s AAA. Ljeti 2007. godine dolazi do prve pojave krize. Dolazi do pada u podmirivanju kreditnih obveza i sve većeg broja neplaćenih hipotekarnih kredita. Broj pokrenutih ovrha signalizirao je da je drugorazredno tržište u krizi. Cijene nekretnina, a time i cijene financijskih dionica počele su naglo padati. To je smanjilo vrijednost bogatstva kućanstava diljem SAD-a, a riječ je o milijardama dolara. Solventnost Fanny Mae i Freddie Maca, kao i brojnih poznatih međunarodnih financijskih institucija bila je ugrožena (Tooze, 2018).

Prema Prohaska et al. (2013), u želji da spriječi kolaps na tržištu, 7. rujna 2008. vlada SAD-a nacionalizirala je Fanny Mae i Freddie Mac. Financijsku krizu nastalu 2008. godine na

američkom tržištu produbilo je bankrotiranje američke investicijske banke Lehman Brothers te problemi u poslovanju iznimno velike banke Merryl Lynch i najveće američke osiguravajuće kuće AIG. Taj šok uzrokovao je financijsku paniku i doveo do masovne prodaje dionica. Industrija investicijskog bankarstva u SAD-u bila je izbrisana. Vrijednosni papiri koji su nosili visoku rejting ocjenu temeljenu na precijenjenim vrijednostima hipoteka bili su „skriveni" odnosno raspodijeljeni po financijskome sustavu te se nisu mogli jednostavno locirati, odnosno prepoznati. Naglo je došlo do pada kreditne aktivnosti, posebno na međubankarskom tržištu, koje je ubrzalo propadanje brojnih poduzeća u Europi.

Kriza se velikom brzinom prelila na tržišta Europe i ostatka svijeta: došlo je do propasti velikih banaka u kombinaciji s padom kreditne aktivnosti, smanjio se izvoz dobara i usluga što je dovelo do dodatne nelikvidnosti, dok su zemlje u razvoju izgubile pritok eksternoga kapitala o kojem su ovisile. Pad cijena dionica i nekretnina doveo je do smanjenja kapitala banaka (i drugih velikih poduzeća). Pad kapitala banke dovodi do smanjenja kreditne aktivnosti, a pad kreditne aktivnosti dovodi do problema sa solventnosti. U konačnici dolazi do smanjenja bankarskih zajmova, smanjenja investicija i pada BDP-a te rasta stope nezaposlenosti.

Zemlje u razvoju utjecaj krize najviše su osjetile kroz pad izvoza i pritoka inozemnoga kapitala. Prema Siddiqui (2009), s obzirom na to da je većina zemalja, kao što je Kina, Indija, Japan, svoju ekonomiju temeljila na rastu izvoza, kriza je dovela do značajnog pada zarade od izvoza. Priljev sredstava od privatnih ulaganja u zemlje u razvoju i zemlje u usponu u krizi je smanjen, a investitori skloniji riziku premještaju svoja sredstva u zamišljena „sigurnija" utočišta. Smanjeni tokovi novca utječu na zaduživanje države te dovode do porasta državnih troškova kao što su troškovi državnih obveznica i komercijalni dug – oba važna izvora financiranja.

Gilbo (2017) navodi da zaduživanje institucionalnih sustava (monetarne vlasti, države, banaka, ostalih sustava) u inozemstvu može dovesti do nejednakosti u domaćoj proizvodnji i potrošnji te dovesti do neravnoteže štednje i investicija. U situacijama kada su uvjeti zaduživanja u inozemstvu povoljniji nego u domaćoj ekonomiji može doći do nedostatka domaćih sredstava potrebnih za poslovanje sustava.

3.3. Financijska kriza u Hrvatskoj

Svjetska kriza iz 2008. godine nije zaobišla ni Hrvatsku. Kako bi spriječila udar na banke, Vlada je 2008. godine reagirala vrlo brzo i podignula iznos osiguranja depozita štediša s tadašnjih 100. 000 kuna na 400.000 kuna. Taj se potez pokazao vrlo uspješnim i značajnim za bankarski sustav. Potkraj 2008. godine Vlada je objavila paket od deset antirecesijskih mjera za drastično sprječavanje pada BDP-a.

Popis antirecesijskih mjera izglasanih 2008. godine u Hrvatskoj (Vlada RH, 2008):

- dodatno jačanje makroekonomske stabilnosti Hrvatske kroz rebalans proračuna
- rasterećenje gospodarstva, odnosno neporeznih davanja
- osiguranje likvidnosti javnih poduzeća i privatnog sustava skraćivanjem rokova plaćanja obveza javnih poduzeća na 60 dana
- iznos potpore EU-a koju jedan poslovni subjekt može dobiti u tri godine, a da za to ne treba mišljenje Agencije za zaštitu tržišnog natjecanja, povećao se s 200.000 eura na 500.000 eura
- dodatnih 400 milijuna eura za HBOR radi jačanja financijske pozicije HBOR-a, a time i veće potpore izvoznicima, turizmu, poljoprivredi, malim i srednjim poduzetnicima
- mjera potpore tržištu nekretnina putem subvencioniranih kamatnih stopa pri kupnji prvog stana ili povećanja kvadrature
- poziv bankama za smanjenje kamatnih stopa za stambene kredite, a građevinska poduzeća da smanje cijene stanova
- antirecesijske mjere vezane su i za jačanje turizma, privlačenje izravnih stranih investicija, pojačan nadzor nad uvozom, posebno roba lošije kvalitete te održavanje životnog standarda najugroženijih skupina u društvu.

Propast velike bankarske institucije Lehman Brothersa posebice je teško pogodilo regiju Sjeverne i Istočne Europe (SIE) jer su tranzicijske zemlje svoju dugogodišnju ekspanziju uvelike financirale inozemnim zaduživanjem. Kako navodi Broz (2009), u Hrvatskoj prihodi proračuna konsolidirane središnje države od siječnja do travnja 2009. ostvareni su u iznosu od samo 37,5 milijardi kuna, što je za 6,1 % manje nego u isto vrijeme prethodne godine. Zbog pada potrošnje najviše su pali prihodi koji su uz nju direktno vezani, primjerice PDV i trošarine.

Navodi da je naplata PDV-a u prva četiri mjeseca 2009. godine podbacila za 16,2 % u odnosu na isto razdoblje prethodne godine, dok su se trošarine smanjile za čak 27,1 % na međugodišnjoj razini. Nadalje, zbog problema s likvidnošću, potkraj 2008. i početkom 2009. godine Ministarstvo financija je počelo s obilnim izdavanjem trezorskih zapisa. Trezorski zapisi u kunama su na kraju lipnja 2009. godine iznosili 12,2 milijarde kuna, odnosno 3 milijarde kuna manje nego potkraj 2008. godine. Međutim, država je u prosincu 2008. ponovno počela izdavati trezorske zapise u eurima zbog nepovjerenja investitora u domaću valutu, pa se ukupno stanje trezorskih zapisa povećalo potkraj drugog tromjesečja za 830 milijuna kuna u odnosu na kraj 2008. godine.

Stanje realnog sustava ubrzano se pogoršavalo, puno više nego što je bilo predviđeno. Zbog neplanirano visokog pada gospodarske aktivnosti, ne samo u Hrvatskoj već i u cijeloj regiji, početkom 2009. godine dolazi do vrhunca panike u financijskom sustavu. Postaje upitno hoće li dužnici, uključujući i državu, moći podmiriti svoje obveze.

Kako navodi Mihaljek (2009), potkraj svibnja 2009. Vlada je na međunarodnom tržištu izdala euroobveznice u vrijednosti od 750 milijuna eura, s kuponom od 6,5 % i dospijećem u siječnju 2015. godine. U usporedbi s ostalim zemljama iz SIE-a koje su se zadužile u prvoj polovici 2009. godine te u usporedbi s prijašnjim hrvatskim izdanjima euroobveznica, trošak novog duga bio je relativno visok. No ni euroobveznice nisu značajno pomogle hrvatskom gospodarstvu te dolazi do drugog i trećeg rebalansa proračuna. Prihodi su i dalje neplanirano padali, a rashodi rasli.

Zbog previsoke cijene zaduživanja na vanjskom tržištu, država se u 2009. godini obratila za pomoć domaćim bankama te se u prvih pet mjeseci 2009. godine ukupan iznos bankarskih zajmova državi povećao za gotovo 10 milijardi kuna, u usporedbi s 8 milijardi kuna u cijeloj 2008. godini. Istodobno je ukupni iznos kredita banaka stanovništvu smanjen za 1,8 milijardi kuna, dok su krediti poduzećima povećani za manje od milijarde kuna (nasuprot povećanju većem od 10 milijardi kuna u 2008. godini). Budući da su banke zbog pojačanog financiranja države prestale kreditirati privatni sustav, poduzeća i stanovništvo bili su prisiljeni na povlačenje depozita iz banaka kako bi mogli plaćati dospjele obveze. Do svibnja 2009. godine depozitni se novac konsolidiranoga bankarskog sustava postupno smanjio za gotovo 20 % u odnosu prema kraju 2008. godine (Mihaljek, 2009).

Udio loših kredita rastao je konstantno u 2010. godini zbog velike stope nezaposlenosti i rasta švicarskog franka. No unatoč problemima s kojim su se susrele hrvatske banke za vrijeme i nakon financijske krize, može se zaključiti da je hrvatski bankarski sustav stabilan. Jedina zamjerka je što su se viškovi sredstava uglavnom koristili za financiranje države, a ne i za održavanje privrede. To je logičan potez banaka s obzirom na to da je udio loših kredita u bilancama banaka rastao te zbog straha od stečaja, banke su se orijentirale na plasiranje sredstava „sigurnim“ klijentima kao što je država i državne institucije.

HNB se koristio određenim regulatornim zahtjevima kako bi osigurao stabilnost financijskog sustava i preko banaka utjecao na razvoj gospodarstva. Prije pojave financijske krize, HNB je vodio restriktivnu monetarnu politiku, ali pojavom krize, njegova politika postaje ekspanzivna jer je težila povećanju likvidnosti bankarskog sustava da bi banke mogle svoja sredstva usmjeriti u razvoj privrede (Draženović et al., 2012). Pad bankarske aktivnosti za vrijeme krize utječe na razvoj međunarodne trgovine koja ovisi o bankama, odnosno bankarskim garancijama. Banke ograničavaju svoju izloženost riziku čime izravno utječu na međunarodnu trgovinu.

Može se zaključiti da ne postoji „općeprihvaćena teorija financijske krize“ koja propisuje zemljama i financijskim institucijama kako se ponašati u budućnosti kako do krize ne bi došlo te pravila i politike koje bi svaka pojedina država trebala usvojiti nakon krize (Jonung, 2008). No praćenjem kriza kroz povijest, usporedbom uzroka nastanka i posljedica, mogu se povući paralele te poduzeti mjere za ublažavanje financijske krize, ako je nije moguće spriječiti. Prije svega potrebno je uključiti intervenciju države tamo gdje i kada je to moguće, a posebno u zemljama u razvoju koje ovise o dotoku inozemnoga kapitala. Subvencija države potrebna je za spašavanje ugroženih ključnih industrija.

S druge strane, treba biti jako oprezan pri intervenciji države vezano uz financijski sustav. Sve zemlje koje imaju zdrav i razvijen financijski sustav trebale bi izbjegavati intervenciju države u nacionalizaciji banaka ako se njihov kolaps može spriječiti. Potrebno je zadržati neovisnost financijskog sustava zasnovanog na privatnom sustavu ako je to moguće. Ako financijski sustav leži na zdravoj konkurenciji, pod nadzorom je središnje banke te je dovoljno kapitaliziran, intervencija države tada nije ni poželjna ni potrebna. Nacionalizacija banaka može biti kratkoročna hitna mjera za sprječavanje propadanja banaka, ali stvara niz dugoročnih poteškoća kao što je moralni hazard.

O potrebi uvođenja koordinacije rada središnjih banaka u svijetu te većoj kontroli banaka, a time i cijeloga financijskog sustava već je pisano u prethodnim poglavljima ovoga rada. Dugoročno gledano, zemlje se moraju usredotočiti na jačanje svojih financijskih sustava prateći globalnu financijsku strukturu jer domaći financijski sustav ovisi o globalnoj financijskoj strukturi i obratno. Kao i svaki drugi sustav, i financijski sustav treba nadograđivati, razvijati, ali i kontrolirati. Financijski razvoj odnosi se ponajprije na stvaranje novih proizvoda i usluga s većim pristupom kreditima. Većom učinkovitosti financijskog sustava omogućuje se učinkovitija raspodjela kapitala u cijeloj ekonomiji. Stabilan financijski sustav važan je za ekonomsku diversifikaciju, rast poduzetništva i za učinkovitu primjenu fiskalne i monetarne politike.

4. Upravljanje rizicima u bankama

Upravljanje rizikom je aktivnost koja uključuje uočavanje rizika, procjenu, razvoj strategija za upravljanje rizikom kao i upravljačke resurse (Hopkin, 2018). Neki tradicionalni pogledi usmjereni su na rizike od fizičkih do zakonskih, prirodnih katastrofa, smrti, događaja do nesreća. Iako je upravljanje rizikom oduvijek bilo dio ljudske aktivnosti i njihovih organizacija, moralo je proći nekoliko desetljeća prije nego što su menadžeri i donositelji odluka prihvatili integrirani pristup.

Rizik se definira kao volatilnost ili standardno odstupanje neto novčanih tokova poduzeća ili ako je poduzeće vrlo velika jedinica unutar nje (Heffernan, 1996). Prema Cade (2013), odgovarajuća definicija rizika u bankarstvu je: izloženost neizvjesnosti događaja.

Upravljanje rizikom na razini pojedinih financijskih institucija znatno je unaprijeđeno posljednjih godina. Ova poboljšanja u velikoj su mjeri potaknuta pritiskom nestabilnosti dinamičnog financijskog okruženja nakon nekoliko financijskih kriza. Od osamdesetih godina prošlog stoljeća regulatori su poduzeli značajne napore za upravljanje rizicima unutar financijskih institucija uvođenjem standardnih mjera za upravljanje bankama. Mjere su ponajprije potrebne kako bi se smanjile opasnosti od sistemskog rizika te radi jačanja stabilnosti. Banke su financijske institucije koje u svojem poslovanju preuzimaju velike rizike. Kada stvari krenu suprotno očekivanjima, rezultati mogu biti spektakularni. Banka Merrill Lynch je 1987. godine izgubila 377 milijuna dolara zbog trgovanja, tada još novim i neprovjerenim, hipotekarnim vrijednosnim papirima. Godine 1989. došlo je do kolapsa tržišta bezvrijednih obveznica, a s njim i bogatstva Drexela Burnhama Lamberta. Godine 1991. Bank of New England izvršila je velika rezerviranja na štetu depozita stoga je vlada morala pomoći ulogom oko 2 milijarde dolara. Barclays banka izvršila je 1992. godine rezervaciju od 2,5 £ milijardi za loša i sumnjiva potraživanja. Credit Lyonnais podlegnuo je sličnim problemima i zabilježio je neto gubitak od 6,9 milijardi franaka. Kako bi spriječila kolaps vlada je investirala 44,9 milijardi franaka u banku. Ovo je samo nekoliko primjera neuspješnog upravljanja rizicima unutar banaka (Cade, 2013).

Moderne bankarske sustave karakterizira prilično složena mreža međusobnih kreditnih izloženosti. Ove kreditne izloženosti proizlaze iz upravljanja likvidnošću s jedne strane te međubankarskog trgovanja derivatima s druge strane. U takvom sustavu međusobne izloženosti

stvarni rizik snosi bankarski sustav u cjelini stoga pojedinačni potencijalni rizici mogu ostati „skriveni“ odnosno lako se mogu sakriti na razini pojedine banke. Stoga je uvođenje regulatornih mjera na svjetskoj razini nužno. Banke su dužne uspostaviti sveobuhvatan i pouzdan sustav upravljanja rizikom, integrirati ga u sve poslovne aktivnosti i osigurati da profil rizika banke uvijek bude u skladu s utvrđenom sklonošću riziku (Odluka o upravljanju rizicima, HNB, 2016).

Svaka financijska institucija mora raspolagati informacijama o izloženosti pojedinim rizicima, o profilu rizičnosti i njegovim promjenama, mora sadržavati podatke o značajnim internim gubicima, informacije o mjerama i aktivnostima koje se namjeravaju poduzeti ili su poduzete radi ovladavanja rizikom, informacije o prekoračenju limita te informacije o pozitivnim i negativnim promjenama u pokazateljima poslovanja koje upućuju ili mogu upućivati na promjenu izloženosti riziku (HNB, Odluka o sustavu upravljanja, Narodne novine, br. 96/18 i 67/19).

Kako navodi Sajter (2017), bit upravljanja rizicima u menadžmentu financijskih, ali i nefinancijskih institucija u paralelnom je vođenju dvaju procesa:

a) proširenje područja u kojem postoji bar nekakva kontrola nad ishodom odlučivanja
b) smanjenje područja u kojem ne postoji nikakva kontrola nad ishodom odlučivanja i/ili gdje je nepoznata veza između uzroka i posljedica.

Sustav upravljanja rizikom uključuje (Odluka o upravljanju rizicima, članak 7.):

- strategije i politike upravljanja rizikom, kao i postupke za identifikaciju i mjerenje rizika, tj. za procjenu i upravljanje rizikom
- odgovarajuću unutarnju organizaciju, tj. organizacijsku strukturu banke
- učinkovit proces upravljanja rizikom koji pokriva sve rizike kojima je banka izložena ili kojima može biti izložena u poslovanju
- odgovarajući sustav interne kontrole
- odgovarajući informacijski sustav
- odgovarajući postupak procjene adekvatnosti internoga kapitala.

Sustav upravljanja rizicima može se definirati kao cjelovit proces obuhvaćanja, mjerenja i nadziranja relevantnih i potencijalnih rizika te analize s tim u vezi potencijalnih gubitaka (Bedenik, 2003).

Strategija upravljanja rizicima uključuje ciljeve i osnovna načela preuzimanja i upravljanja rizicima, te sklonost banke za preuzimanje rizika (HNB).

4.1. Rizici u bankama

Svaka profitna organizacija, uključujući i banke, suočena je s makroekonomskim rizicima kao što je inflacija, recesija, razvoj novih tehnologija, političke promjene i sl. Uz vanjske rizike, banke su dodatno izložene i unutarnjim rizicima netipičnim za klasične profitne organizacije.

Zdravlje kreditnog portfelja banke ovisi o ekonomskim kretanjima. Potencijalni poremećaji u bankarskom sustavu mogu se predvidjeti ekonomskim prognozama i pokušati spriječiti odnosno ublažiti njihov utjecaj ako se prognoza i ostvari. No ponajprije treba detektirati i definirati sve potencijalne rizike koje mogu dovesti bankarski sustav u krizu, a time i cijelo gospodarstvo.

Prema Van Greuning i Bratanović (2020), od 1970. godine uloga banaka se značajno promijenila. Dotadašnje bankarsko okruženje bilo je relativno stabilno i pod značajnim utjecajem regulatora koji su ograničavali opseg rada i razvoj novih proizvoda kako bi sveli financijske rizike poslovanja na minimum. Ovakav način poslovanja bankama nije stvarao dodatnu zaradu te su osamdesetih godina počele reforme bankarskog sustava. Inovacije, nova tržišta, razvoj tehnologije i potreba za novim proizvodima omogućilo je bankama više slobode u pružanju usluga, ali su banke bile suočene i s novim, do tada nikad ispitanim, rizicima. Banke su se uz tržišne rizike počele suočavati i s kreditnim rizicima, rizicima upravljanja likvidnošću, valutnim i operativnim rizicima. U osamdesetim godinama počele su ozbiljne promjene u organizaciji banaka te su osnovani posebni odjeli za praćenje rizika, mjerenje nastalih šteta uzrokovanih rizicima te praćenje potencijalnih budućih rizika.

Kako navodi Baele et al. (2004), bez obzira na to kako je banka organizirana, je li riječ o komercijalnoj, trgovačkoj ili investicijskoj banci, šokovi generirani stvarnim ekonomskim kretanjima mogu pogoditi banke preko brojnih kanala rizičnosti. Ekonomska kriza u

kombinaciji s negativnim rastom prihoda u lošim ekonomskim uvjetima s vremenom može utjecati na kapitalne rezerve banke do te mjere da se cijeli bankarski sustav suočava s krizom. Štoviše, iako su bankarske krize često uzrokovane ekonomskim padom, one također mogu pojačati recesiju. U većini slučajeva bankarske krize povezane su sa značajnim padom stvarne aktivnosti, ponekad uzrokovane kreditnom krizom.

Prema HNB-u, osnovna uloga menadžmenta rizika je identifikacija rizika, upravljanje rizicima te prilagodba alata i metoda za identifikaciju potencijalnih budućih rizika.
Bez obzira na to je li riječ o banci tradicionalnog ustrojstva ili razgranatom financijskom konglomeratu koji pruža paletu financijskih usluga, osnovni cilj svake financijske institucije je **maksimalizacija profita i stvaranje dodane vrijednosti uz minimalne rizike**. Dodana vrijednost dioničara definira se kao zarada veća od minimalnog očekivanog povrata na uloženi kapital. Ako dioničar uloži sredstva u kapital banke te očekuje minimalni povrat od 15 %, a dionice su prodane za 20 %, dodatnih 5 % predstavlja pozitivnu dodanu vrijednost na uloženi kapital. Ako su pak dionice prodane za manje od očekivanih 15 %, posljedica za dioničara je negativna dodana vrijednost. Postoji poveznica između očekivane dodane vrijednosti na dioničarski kapital i drugih alata za mjerenje uspješnosti kao što su povrat na imovinu (ROA) i povrat na kapital (ROE). ROA, ROE i mjera profitabilnosti su osnovni pokazatelji uspješnosti poslovanja korporacija, uključujući i banke koje kotiraju na burzama (Klaassen i van Eeghen, 2015). Ako banka u nekoliko kvartala zaredom ima opadajući trend ROA i ROE, vlasnici dioničari mogu umanjiti vrijednost dionica, što će dovesti do pada cijene dionica. **Ako se i dalje zadrži negativan trend, dodana vrijednost na uloženi kapital bit će sve manja, ako ne i negativna, što dovodi do propasti financijske institucije.**

Zbog kompleksnosti i velike rizičnosti u razvijenim bankarskim sustavima, rizici se mjere i na razini banke, na razini svakoga pojedinog odjela banke te na razini proizvoda.

4.1.1. Kategorije bankarskih rizika

Za uspješno poslovanje banke potrebno je prepoznati i detektirati velik broj rizika koji ugrožavaju njezino poslovanje. Banke su uspješne kada su rizici koje su preuzele racionalni, kontrolirani i u okviru njihove nadležnosti i kontrole.

U određivanju prirode ekonomske kategorije rizika istraživači primjećuju da je ona povezana sa sukobom, neizvjesnošću i učinkovitošću. Konflikt proizlazi iz subjektivno-objektivne prirode rizika, prisutnosti proturječja između objektivno postojećih rizičnih situacija i njihove subjektivne procjene, a neizvjesnost je povezana s nemogućnošću procjene vjerojatnosti nastanka određenih događaja i opsega njihove manifestacije (prilagođeno prema Britchenko i Stojka, 2017).

John Keynes (1984) jedan je od prvih koji je predložio klasifikaciju rizika. Identificirao je tri glavne vrste rizika: poduzetnički rizik, rizik "vjerovnika" i rizik promjene vrijednosti valute. Poduzetnički rizik, prema Keynesu, je neizvjesnost primitka očekivanog prihoda od ulaganja; rizik „vjerovnika" je rizik povrata kredita, čiji su sastavni dijelovi pravni rizik (izbjegavanje otplate zajma) i kreditni rizik (nedostatak sredstava); rizik promjene vrijednosti valute je vjerojatnost gubitka sredstava zbog promjene tečaja nacionalne valute.

Burdenko i Pozhar (2006) pak kategoriziraju rizike u bankama prema mjestu formiranja: eksterni (politički, ekonomski i zakonodavni rizik) i interni (kreditni rizik, kamatni rizik, rizik fonda, valutni rizik, tržišni rizik, rizik prijevremenog povlačenja depozita, rizik vezan za nove aktivnosti, rizik likvidnosti). Prema veličini: prihvatljivi, kritični i katastrofalni rizik. Prema raspodjeli u vremenu: prošli, sadašnji i budući rizik.

Epifanov i Vasilyeva (2012) dijele rizike na vanjske: rizici prirodnih katastrofa, rizik zemlje, politički, zakonodavni, gospodarski i konkurentski rizici i interne: rizici upravljanja – prijevara, neučinkovit organizacijski rizik, nesposobnost menadžmenta da donosi racionalne odluke, neučinkovit sustav stimulacije zaposlenika. Rizik organizacije transakcija unutar banaka: tehnološki, strateški, rizik uvođenja novih proizvoda i tehnologija. Financijski rizici: kreditni, kamatni, rizik likvidnosti, investicijski i valutni rizik, rizik nesolventnosti.

Prema Van Greuning i Bratanović (2009), tri osnovne kategorije bankarskih rizika su:

Financijski rizik koji obuhvaća dva tipa rizika: tradicionalni rizik i rizik riznice. Tradicionalni bankarski rizici mogu uzrokovati gubitke ako se s njima pravilno ne upravlja. Rizik riznice temelji se na financijskoj arbitraži, može ostvariti profit ili gubitak. Glavne kategorije arbitražnog rizika su: rizik likvidnosti, rizik kamatne stope, tečajni rizik i tržišni rizik.

Operativni rizici i poslovni rizici su rizici povezani s unutarnjim procesima banke, politikama i procedurama banke, tehnologijom, informacijskim sustavom, internim i vanjskim prevarama kao i unutarnjim uređenjem.

Rizik okoline povezan je s okolinom u kojoj banka djeluje. Uključuje makroekonomske čimbenike, političko uređenje zemlje te zakonske i regulatorne čimbenike, sveobuhvatnu financijsku strukturu. Rizik okoline stoga uključuje sve tipove vanjskih čimbenika koji mogu utjecati na poslovanje banke.

U tablici 1. prikazane su tri osnovne kategorije bankarskih rizika (financijski rizik, operativni i poslovni rizik te rizik okoline) kao i potkategorije svake od kategorija rizika.

Tablica 1. Kategorije rizika u bankama

Financijski rizik	Operativni i poslovni rizici	Rizik okoline
Struktura bilance	Interna prijevara	Politički rizik i rizik zemlje
Račun dobiti i gubitka	Eksterna prijevara	Makroekonomska politika
Adekvatnost kapitala	Poslovna praksa i zaštita na radu	Financijska infrastruktura
Kredit	Klijenti, proizvodi i usluga	Pravna i zakonodavna infrastruktura
Likvidnost	Šteta na fizičkoj imovini	Bankarska kriza
Tržište	Tehnološki rizik	Reputacijski rizik
Kamatna stopa	Izvršenje i upravljanje poslovnim procesima	Strategijski rizik
Valuta	Izdvajanje glavnih funkcija izvan banke	Pranje novca
	Poslovno i tržišno okruženje	Kibernetički kriminal
	Kvaliteta upravljanja podacima	

Izvor: Van Greuning, Bratanović, 2020.

U bankama u Hrvatskoj kategorizacija rizika provedena je u skladu sa smjernicama Hrvatske narodne banke (HNB). Prema HNB-u, potkategorije rizika koje se pojavljuju u financijskim institucijama mogu se svrstati u sljedeće kategorije (Odluka o upravljanju rizicima, 2016):

Likvidnosni rizik je rizik gubitka koji proizlazi iz postojeće ili očekivane nemogućnosti kreditne institucije da podmiri svoje novčane obveze na vrijeme.

Rizik financiranja likvidnosti je rizik da kreditna institucija neće biti u stanju uspješno ispuniti očekivane i neočekivane sadašnje i buduće potrebe za novčanim sredstvima te potrebe za instrumentima osiguranja, a da ne utječe na svoje redovito dnevno poslovanje ili na vlastiti financijski rezultat.

Tržišni rizici su pozicijski, valutni i robni rizik. **Pozicijski rizik** je rizik gubitka koji proizlazi iz promjene cijene financijskog instrumenta ili, kod izvedenoga financijskog instrumenta, promjene cijene odnosne varijable. Pozicijski rizik dijeli se na opći i specifični rizik. **Valutni rizik** je rizik gubitka koji proizlazi iz promjene tečaja valute i/ili promjene cijene zlata, rizik gubitka koji proizlazi iz promjene cijene robe.

Rizik ročne neusklađenosti je 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.

Rizik krivulje prinosa je rizik kojem je kreditna institucija izložena zbog promjene oblika i nagiba krivulje prinosa.

Rizik osnovice je rizik kojem je kreditna institucija izložena zbog razlike referentnih kamatnih stopa za instrumente sa sličnim karakteristikama u odnosu na ročnost ili vrijeme do sljedeće promjene kamatne stope.

Rizik opcije je rizik kojem je kreditna institucija izložena zbog opcija ugrađenih u kamatno osjetljive pozicije (npr. kredite s mogućnošću prijevremene otplate, depozite s mogućnošću prijevremenog povlačenja i sl.).

Valutni rizik je rizik gubitka koji proizlazi iz promjene tečaja valute i/ili promjene cijene zlata.

Valutno inducirani kreditni rizik je rizik gubitka kojem je banka dodatno izložena pri odobravanju plasmana u stranoj valuti ili uz valutnu klauzulu i koji proizlazi iz dužnikove izloženosti valutnom riziku.

Rizik strane države je rizik da odgovarajuća tijela ili središnja banka neće moći ili neće htjeti podmiriti obveze prema drugim državama i vjerovnicima u tim državama i da ostali dužnici u toj državi neće moći podmiriti obveze prema vjerovnicima izvan te države.

Rizik druge ugovorne strane proizlazi iz neispunjavanja obveza druge ugovorne strane. Rizik može nastati u slučaju da osoba s kojom banka sklapa poslove na financijskim tržištima ne može ili neće u cijelosti ili djelomično podmiriti svoje obveze prema banci.

Kreditni rizik druge ugovorne strane ili „CCR" znači rizik da bi druga ugovorna strana u transakciji mogla doći u status neispunjavanja obveza prije konačne namire novčanih tokova transakcije.

Koncentracijski rizik je rizik koji proizlazi iz svake pojedinačne, izravne ili posredne, izloženosti prema jednoj osobi, skupini povezanih osoba odnosno središnjoj drugoj ugovornoj strani ili skupa izloženosti koje povezuju zajednički činitelji rizika kao što su isti gospodarski sustav, odnosno geografsko područje, istovrsni poslovi ili roba, odnosno primjena tehnika smanjenja kreditnog rizika, uključujući posebno rizike povezane s velikim neizravnim kreditnim izloženostima prema pojedinom davatelju kolaterala koji može dovesti do gubitaka koji bi mogli ugroziti nastavak poslovanja kreditne institucije ili materijalno značajnu promjenu njezina profila rizičnosti. Koncentracija unutar rizika odnosi se na koncentracije rizika koje se mogu javiti zbog međudjelovanja različitih izloženosti rizicima jedne kategorije rizika. Koncentracija među rizicima odnosi se na koncentracije rizika koje se mogu javiti zbog međudjelovanja različitih izloženosti rizicima na razini različitih kategorija rizika. Djelovanja među različitim izloženostima rizicima mogu proizlaziti iz zajedničkoga odnosnog pokretača rizika ili iz međudjelovanja pokretača rizika.
U skladu s HNB-ovoj Odluci o upravljanju rizicima (članak 35. i članak 36.) uspostavljena pravila za upravljanje koncentracijskim rizikom uključuju:

- identificiranje i mjerenje koncentracije koja se odnosi na pojedine osobe i skupine povezanih osoba
- identificiranje i mjerenje koncentracije koja se odnosi na skup izloženosti koje povezuju zajednički činitelji rizika kao što su isti gospodarski sustav, odnosno geografsko područje, istovrsni poslovi, odnosno primjena tehnika smanjenja kreditnog rizika
- identificiranje i mjerenje koncentracije koja se odnosi na cijeli kreditni portfelj.

Metodologije za praćenje i umanjenje koncentracijskog rizika uključuju:

- aktivno upravljanje kreditnim portfeljem radi diversifikacije
- utvrđivanje limita koncentracije
- prijenos, odnosno smanjenje kreditnog rizika, što uključuje izravnu prodaju plasmana, prijenos plasmana ili kreditnog rizika sekuritizacijom te upotrebu kreditnih izvedenica i instrumenata osiguranja potraživanja.

Rizik eksternalizacije skupni je naziv za sve rizike koji nastaju kada kreditna institucija ugovorno povjerava drugoj strani (pružateljima usluga) obavljanje aktivnosti koje bi inače sama obavljala.

Strateški rizik je rizik gubitka do kojeg dolazi zbog donošenja pogrešnih poslovnih odluka, neprilagodljivosti promjenama u ekonomskom okruženju i sl.

Reputacijski rizik je rizik gubitka povjerenja u integritet kreditne institucije do kojeg dolazi zbog nepovoljnog javnog mnijenja o poslovnoj praksi kreditne institucije, neovisno o tome postoji li osnova za takvo javno mnijenje ili ne.

Pravni rizik je rizik koji nastaje zbog mogućnosti da neispunjene ugovorne obveze, pokrenuti sudski postupci protiv kreditne institucije kao i donesene poslovne odluke za koje se ustanovi da su neprovedive, negativno utječu na poslovanje ili financijski položaj kreditne institucije.

Ekonomski rizik je rizik ekonomske i financijske politike određene države te njegova financijska pozicija prema inozemstvu.

Politički rizik je rizik promjena odluka i aktivnosti javnog sustava.

Rizik modela je rizik gubitka koji bi kreditna institucija mogla pretrpjeti zbog odluka koje bi se mogle ponajprije temeljiti na rezultatima internih modela, i to zbog pogrešaka u oblikovanju, primjeni ili upotrebi tih modela.

Rizik namire je rizik gubitka kreditne institucije koji nastaje zbog razlike u ugovorenoj cijeni namire za određeni dužnički, vlasnički, devizni ili robni instrument i njezine sadašnje tržišne vrijednosti.

Rizik usklađenosti je rizik od izricanja mogućih mjera i kazni te rizik od nastanka značajnoga financijskoga gubitka ili gubitka ugleda, što ga kreditna institucija može pretrpjeti zbog neusklađenosti s propisima, standardima i kodeksima te internim aktima.

Poslovni rizik je negativna, neočekivana promjena obujma poslovanja i/ili profitnih marži koja može dovesti do značajnih gubitaka i na taj način umanjiti tržišnu vrijednost kreditne institucije. Do poslovnog rizika ponajprije može doći zbog značajnog pogoršanja tržišnog okružja i promjena u tržišnom natjecanju ili ponašanju potrošača.

Rezidualni rizik je rizik gubitka koji nastaje ako su priznate tehnike smanjenja kreditnog rizika kojima se koristi kreditna institucija manje djelotvorne nego što se očekivalo.

Rizik prekomjerne financijske poluge znači rizik koji proizlazi iz ranjivosti institucije zbog financijske poluge ili potencijalne financijske poluge i koji može dovesti do neželjenih izmjena njezina poslovnog plana, uključujući prisilnu prodaju imovine što može rezultirati gubicima ili prilagodbom vrednovanja njezine preostale imovine.

Upravljački rizik je rizik gubitka do kojeg dolazi zato što kreditna institucija zbog svoje veličine ima ograničen kapacitet za uspostavljanje sofisticiranih upravljačkih mehanizama, sustava i kontrola.

Rizik prilagodbe kreditnom vrednovanju ili »*CVA*« znači prilagodbu vrijednosti portfelja transakcija s drugom ugovornom stranom vrednovanog po srednjoj tržišnoj vrijednosti. Spomenuta prilagodba odražava trenutačnu tržišnu vrijednost kreditnog rizika druge ugovorne strane za instituciju, ali ne odražava trenutačnu tržišnu vrijednost kreditnog rizika institucije za drugu ugovornu stranu.

Razrjeđivački rizik znači rizik smanjenja iznosa otkupljenih potraživanja na osnovi gotovinskih ili negotovinskih potraživanja dužnika.

Rizik profitabilnosti (rizik zarade) je rizik koji nastaje zbog neodgovarajućeg sastava i raspodjele zarade ili nemogućnost kreditne institucije da osigura odgovarajuću i konstantnu razinu profitabilnosti.

Rizik ulaganja u nekretnine je rizik gubitka koji proizlazi iz promjena tržišnih vrijednosti portfelja nekretnina u kreditnoj instituciji.

Operativni rizik znači rizik gubitka koji proizlazi iz neadekvatnih ili neuspjelih unutarnjih procesa, ljudi i sustava ili iz vanjskih događaja, uključujući pravni rizik.

4.2. Alati, tehnike i modeli za upravljanje i analizu rizika u bankama

4.2.1. Alati i tehnike za upravljanje rizicima u bankama

Financijski izvještaji pripremljeni u skladu s IFRS-om omogućuju prikaz osnovnih financijskih informacija o poslovanju financijskih institucija, ali te informacije često nisu dovoljne za ocjene rizičnosti. Osim financijskih informacija sadržanih u financijskim izvještajima, vrlo su bitne i nefinancijske informacije koje u kombinaciji s financijskim informacijama pružaju puno širu sliku.

Tradicionalne banke uglavnom se služe kvantitativnim alatima za kontrolu omjera u kretanju izloženosti banke rizicima. Omjeri su uglavnom povezani s likvidnošću, adekvatnošću kapitala, kvalitetom investicijskog portfelja, profitabilnošću, veličinom izloženosti, otvorenim deviznim pozicijama i sl. Iako su omjeri nužni, sami po sebi nisu dovoljno dobar pokazatelj, dovoljno kvalitetan indikator rizičnosti banke odnosno njezine financijske stabilnosti (Van Greuning i Bratanović, 2006).

Iako su osnovne tehnike za prikaz financijske stabilnosti financijskih institucija sadržane u izvještaju o poslovanju, pokazatelji rizičnosti uključuju i kvalitativne faktore koji se pridružuju okvirima za ocjenu rizičnosti. Kvalitativni faktori uključuju kvalitetu i stil rukovođenja

menadžmenta, potpunost, točnost i transparentnost bankarskih politika i procedura, djelotvornost i potpunost internih kontrola, točnost i pouzdanost informacijskih sustava i njihovu pouzdanost.

Da bi se dobila potpuna slika o poslovanju banke, ona mora sadržavati podatke o poslovanju kao pojedinačni poslovni subjekt i na konsolidiranoj osnovi pogotovo ako je riječ o internacionalnoj banci koja posluje u više zemalja.

Analiza temeljena na riziku indicira je li poslovanje banke u skladu s trendovima i politikama matične banke, posebno kada je riječ o pokazateljima kao što je profitabilnost, struktura bilance i adekvatnost kapitala. Kvaliteta financijskih pokazatelja također ovisi o točnosti i transparentnosti podataka kao i o kvaliteti baze podataka. Kvalitetna baza podataka je ključan alat u modernoj ekonomiji za izračun rizičnosti i primjenu modernih alata.

U razvijenoj ekonomiji izvještaji o financijskoj rizičnosti trebali bi uz klasične financijske pokazatelje prikupljene iz financijskih izvještaja sadržavati sljedeće (Van Greuning i Bratanović, 2020):

- Financijske ciljeve: uz podatke o postignutim ciljevima podaci bi trebali sadržavati informacije o planiranim ciljevima.
- Pokazatelje poslovanja ostalih financijskih institucija na tržištu: banke bi u svojim izvještajima trebale prikazati i podatke poslovanja ostalih banaka na tržištu. Katkad se teško u potpunosti osloniti na tržišne rezultate jer svaka financijska institucija ima svoje strategije, planove i ciljeve prema kojima teži. Različite strategije utječu na podatke prikazane u financijskim izvještajima stoga se usporedba podataka često ne može uzeti kao jedino mjerilo već isključivo kao smjernica kretanja.
- Ekonomsko okruženje u kojem banka djeluje: makroekonomsko stanje je ključno za analizu trenutačnih pokazatelja kao i budućih planova.

Financijske analize podrazumijevaju primjenu i uporabu analitičkih aplikacija za točne i pouzdane izračune financijskih stanja, trendova, odnosa i kretanja. Primjena i obrada podataka treba biti automatizirana kako bi se izbjeglo bilo kakvo manipuliranje dobivenim podacima. Izazov financijskim analitičarima je razviti trendove o kretanju financijskih pokazatelja uključujući makroekonomske podatke, sektorske podatke u kombinaciji s kvalitativnim podacima o stanju i poslovanju menadžmenta kao i procesima unutar banke.

Pouzdani izvještaji o kretanju financijskih pokazatelja trebali bi sadržavati podatke o financijskim izvještajima u razdoblju od pet do deset godina u svrhu formiranja trenda na temelju kojeg se stvara adekvatna podloga za buduća planiranja.

Većina analiza sadrži isključivo kvantitativne informacije o trenutačnom stanju bez dodatnih objašnjenja „što je uzrok dobivenih rezultata“ odnosno „zašto“. Stoga svaka kvalitetna analiza treba sadržavati odgovore na sljedeća pitanja (Van Greuning i Bratanović 2020):

- Što se dogodilo?
- Zašto se to dogodilo i postoji li potencijalna opasnost da će se to ponoviti?
- Utjecaj pojedinih događaja na financijske pokazatelje.
- Koje akcije trebaju poduzeti za sprječavanje negativnih događaja?
- Preporuke financijskog analitičara.

Postoje brojni alati koje banke danas primjenjuju za evidenciju i analizu podataka rizičnosti, no svaki alat nije dovoljno adekvatan i pouzdan. Da bi alat bio adekvatan za analizu, treba sadržavati niz podataka o poslovanju. Podaci trebaju biti sustavni, točni i transparentni te sadržavati prikaz stvarnog stanja o poslovanju banke. Automatizacija obrade i prikaza rezultata nužna je za sprječavanje zlouporabe podataka kao i smanjenje potencijalnih pogrešaka.

Podaci sadržani u alatima za mjerenje rizičnosti trebaju biti adekvatni, odnosno uporabljivi za analizu. Da bi analiza bila izvediva i adekvatna, set podataka trebao bi pokriti sljedeća područja (prilagođeno prema Van Greuning i Bratanović, 2020):

1. potrebe institucije
2. prikaz stanja financijskog sustava i procedure
3. perspektivu banke (povijest i organizacijsku strukturu grupe)
4. računovodstvena pravila i politike
5. informacijske tehnologije
6. modele upravljanja financijskom institucijom
7. financijski menadžment upravljanja rizikom, uključujući podatke o imovini i obvezama banke, profitabilnosti, kreditnom riziku, i ostalim važnim financijskim pokazateljima.

Adekvatan analitički alat objedinjuje prikupljene podatke te prikazuje rezultate u obliku financijskih omjera (analitički) i grafički. Rezultati podataka služe menadžmentu za donošenje poslovnih odluka i za planiranje strategija.

Financijski omjeri su matematički prikazi omjera jednog pokazatelja u odnosu na kretanje drugog pokazatelja.

Mjerenje performansi banaka tradicionalno se temelji na analizi financijskih pokazatelja (financijskih omjera). Međutim, bez obzira na to koliko se i kojih pokazatelja koristi, još nije definiran jedinstveni univerzalni model koji bi u potpunosti zadovoljavao potrebe za analizom i vrednovanjem efikasnosti poslovanja banaka. Zbog toga se analiza financijskih omjera nadopunjuje različitim kvalitativnim vrednovanjima kojima se nastoje u konačnu ocjenu uključiti i obilježja poput kvalitete menadžmenta, strukture vlasništva, konkurentske pozicije i druga (Hunjak i Jakovčević, 2003).

Financijska analiza koristi analitičarima za procjenu budućih kretanja i pruža uvid u mikroekonomske aspekte poslovanja banke kao što je dobit, procjena novčanog toka te pruža informacije o financijskoj fleksibilnosti banke u vidu brzine podmire svojih dugovanja u slučaju izvanrednih okolnosti. Iako se financijski omjeri koriste kao osnovni pokazatelji poslovanja, oni katkad ne prikazuju u potpunosti realnu sliku poslovanja. Omjeri su podložni manipulacijama, pogotovo za kraće razdoblje, stoga je potrebno provoditi dvostruku kontrolu izračuna omjera.

Podaci sadržani u bazama podataka u analitičkim softverima mogu se interpretirati na različite načine. Analitičke tehnike obuhvaćaju: omjere, analizu presjeka, analizu trendova i regresijsku analizu (Van Greuning i Bratanović, 2020). Kao što je spomenuto u prošlom ulomku, omjeri su uglavnom osnovni alat za prikaz kretanja financijskih podataka i osnovni pokazatelj za analizu rizika. Omjer kao podatak sam za sebe ne pruža potpunu sliku poslovanja. Omjeri se uvijek moraju promatrati u kontekstu kretanja ostalih varijabli. U praksi se omjeri često koriste za usporedbu s ostalim bankama na tržištu. Ako neki od omjera banke odstupaju od rezultata ostalih banaka koje posluju na tržištu, analitičarima je to signal za oprez.

Dvadesete godine prošlog stoljeća bile su razdoblje velikog entuzijazma što se tiče mogućnosti uporabe omjera kao analitičkog alata, i prvi realni kritičari pojavili su se u tom razdoblju. Gilman (1925) je došao do sljedećih zaključaka:

1. promjene omjera kroz vrijeme ne mogu se ispravno interpretirati jer i brojnik i nazivnik mogu varirati
2. omjeri su „umjetne“ mjere
3. odvlače pažnju analitičara od sveobuhvatnog pogleda na poduzeće
4. pouzdanost omjera kao indikatora bitno varira među pojedinim omjerima.

Ovi zaključci vrlo su važni i za suvremenu analizu i svakako ih treba uzimati u obzir i imati ih na umu pri uporabi omjera (Novak i Sajter, 2005).

Prema Van Greuning i Bratanović (2020), bilanca banke vrlo je važan izvještaj o poslovanju banke, a nastaje spajanjem velike količine podataka prikupljenih iz raznih izvora koji se sklapaju u jedinstveni izvještaj. Najčešće sadrži podatke o poslovanju tekuće i prethodne godine. Praćenje poslovanja ne temelju usporedbe poslovnih podataka u dvije posljednje godine analitičarima služi tek za praćenje osnovnih kretanja i odstupanja bez ikakvih dodatnih podataka. Banka, kao i svaka druga poslovna jedinica, ima potrebu za rastom i razvojem. Analizom bilance može se iščitati rast banke te strukturne promjene ako ih je bilo. Iako rast ne mora biti značajan, individualne komponente bilance reagiraju na promjene tržišta uključujući ekonomsko okruženje i zakonske promjene. Kako se mijenja struktura bilance, tako raste inherentni rizik. Bilanca uključuje i pokazatelje kretanja potencijalnih rizika. U normalnim situacijama, povećanje imovine banke utječe na stvaranje osnovice za zaradu kao što je stabilan pritok kapitala uz niže troškove. Poslovne banke koje imaju ubrzan rast sklone su preuzimanju neopravdanih rizika, dok njihovi administrativni i informacijski sustavi nisu dovoljno razvijeni za adekvatno praćenje kretanja poslovnih procesa.

Prema Pejić Bach et al. (2009), *analiza presjeka* odnosno „pooling“ vremenskih presjeka financijskih izvještaja služi za usporedbu jedne poslovne jedinice s drugom koje djeluju u istom sustavu iako poslovne jedinice mogu biti različite veličine i mogu poslovati u različitim zemljama. Pri korištenju usporednih podataka o poslovanju dviju banaka, analitičari moraju biti oprezni jer veličina utječe i na financijske rezultate. U usporednoj analizi dviju zasebnih poslovnih jedinica analiziraju se podaci kao što je pokazatelj profitabilnosti između banaka te pokazatelj makroekonomskog okruženja. Problem kod analize presjeka je primjena drugačijih računovodstvenih pravila i metoda pri knjiženju pojedinih stavki financijskih izvještaja koji se upotrebljavaju za analizu.

Prema Thalheimer i Ali (1979), analiza vremenskog niza prikazuje kretanje pojedinih pokazatelja kroz vrijeme, odnosno daje uvid menadžmentu o tome je li pokazatelj u trendu ili odstupa. Pruža uvid u povijesne podatke i kretanje budućih pokazatelja na temelju trendova iz prošlosti te predviđanja. No pri planiranju budućih trendova osim povijesnih podataka u obzir se trebaju uzeti i ostali pokazatelji kao što je ekonomsko okruženje banke, politička situacija, strateški planovi banke i sl. Dakle, analiza trenda sama po sebi nije pokazatelj koji može samostalno služiti kao adekvatna podloga za postavljanje budućih trendova već se u obzir mora uzeti mikro- i makrookruženje.

No svaka od navedenih analitičkih tehnika koje se primjenjuju u bankama za praćenje poslovne aktivnosti neće biti adekvatna ako ne sadrži transparentne i točne podatke analitičkih alata. Stoga je Bazelski komitet 2013. godine izdao Smjernice za učinkovito prikupljanje podataka o rizicima i izvještavanja o riziku radi osvještavanja banaka o važnosti prikupljanja i vođenja podataka kako bi se mogli obraditi te prikazati u izvještajima.

Smjernicama su propisana sljedeća područja primjene (Bazelski odbor za superviziju banaka, 2006):

- sveobuhvatno upravljanje i infrastruktura
- prikupljanje podataka o rizicima
- uspostava prakse izvještavanja
- provođenje kontrole nad izvještajima.

Svrha smjernica je potaknuti banke na prikupljanje velikog broja raznih podataka na temelju kojih se mogu provesti transparentne analize i prikazati stvarno stanje banke. Primjena smjernica nije jednostavna pogotovo za velike internacionalne banke koje imaju razgranatu strukturu s mnogo odjela, direkcija i sustava koji raspolažu različitim podacima koje zatim treba koordinirati, sumirati te razviti alate za njihovo praćenje.

4.2.2. Metode i modeli za analizu rizičnosti u bankama

Svaka banka dužna je uspostaviti proces upravljanja rizicima koji uključuje redovito i pravodobno utvrđivanje, mjerenje, odnosno ovladavanje rizicima i praćenje rizika, uključujući izvješćivanje o rizicima kojima je banka izložena ili bi mogla biti izložena u svojem poslovanju. Proces upravljanja rizicima uključuje definiranje vrste rizika kojem je banka izložena, dokumentiranje rizičnosti te analiza rizičnosti sa sklonošću preuzimanju rizika. Obveza banke je utvrditi rizike kojima je izložena ili bi mogla biti izložena u svojem poslovanju te analizirati uzroke izloženosti rizicima (Odluka o upravljanju rizicima, HNB, 2016).

Pojam upravljanja rizicima iz članka 95. Zakon o kreditnim institucijama (2008) uključuje postupke i metode za:

1. utvrđivanje
2. mjerenje, odnosno procjenjivanje
3. ovladavanje
4. praćenje rizika, uključujući i izvješćivanje o rizicima.

Postupci mjerenja i procjenjivanja rizika obuhvaćaju prikladne kvantitativne i/ili kvalitativne metode procjene rizika koje omogućuju uočavanje promjena u profilu rizičnosti i pojavljivanje novih vrsta rizika (Odluka o upravljanju rizicima, HNB, 2016).

Kvalitativno upravljanje naročito je važno za one čimbenike rizika koji se ne mogu izraziti brojčano, uglavnom zasnovane na iskustvu stručnjaka banke. Kod rizika koji se pak mogu izmjeriti tendencija je u široj primjeni modernih, razvijenih kvantitativnih metoda za njihovo mjerenje.

Kod **kvantitativnog sagledavanja** bankarskih rizika osnovni pristup sastoji se u računanju prosječnog iznosa gubitaka oko trenda vrijednosti (Ćurčić, 2002). Kvantitativni pristup procjeni rizika temelji se na korištenju egzaktnih numeričkih vrijednosti. U tom slučaju, parametrima za izračun rizika nastoje se odrediti točne vrijednosti (Šegudović, 2006).

Kvantitativne i kvalitativne metode procjene rizika kao i kriteriji za odlučivanje i postupci za ovladavanje rizicima definirani su za svaki pojedini rizik u okviru rizika kojim je banka izložena (Odluka o upravljanju rizicima, HNB, 2016).

Pojam **modela za analizu rizičnosti odnosi se na kvantitativnu metodu**, sustav ili pristup koji primjenjuje statističke, ekonomske, financijske ili matematičke teorije, tehnike i pretpostavke za obradu ulaznih podataka u kvantitativne procjene (HNB, 2020).

Prema Šegudoviću (2006), kod kvalitativnog pristupa veliku važnost ima iskustvo, stručnost i nadasve sposobnost osoba koje provode procjenu rizika. Procjena se provodi kvalitativno, no zbog lakše interpretacije rezultata, kod kvalitativne procjene rizika parametri se, isto kao i procijenjeni rizik, kvantificiraju. Za razliku od kvantitativnog pristupa, u ovom slučaju, tako dobivene numeričke vrijednosti nisu apsolutne, već relativne.

Kvantitativne metode za poslovne analize čine pomak u menadžerskom odlučivanju. Metode obuhvaćaju procese prikupljanja podataka i informacija na temelju kojih se provode analize i stvaraju podloge za donošenje odluka. Kvantitativne metode primjenjuju se za analizu poslovnih procesa i tokova u kojima su uključeni ljudski potencijali te materijalni i financijski resursi. Njihova uloga je optimiziranje poslovnih procesa.

Efikasna identifikacija rizika uzima u obzir interne faktore (kao što su struktura banaka, priroda bankarskih aktivnosti, kvaliteta ljudskih resursa banke, organizacijske promjene i promet po zaposlenom) i eksterne faktore (kao što su promjene u bankarskom sustavu i tehnološki napredak) koji mogu nepovoljno utjecati na ostvarivanje ciljeva financijskih institucija. Tehnike identificiranja rizika koje predlaže suvremeni menadžment su upitnik interne kontrole i radionice (workshops) (Živković, 2019).

Svaki model može nositi i određeni stupanj rizika. Rizikom modela smatra se potencijalni gubitak koji bi financijska institucija mogla pretrpjeti kao posljedicu odluka koje se temelje na izlaznim podacima modela, pogrešaka u razvoju modela, pogrešaka u provedbi modela ili korištenju modela. Stoga je vrlo važno uvesti sustav praćenja modela (HNB, 2020).

Kako navodi HNB u Odluci o upravljanju rizicima (2016), ovisno o značaju utjecaja na proces donošenja osjetljivih odluka, modeli mogu biti razvrstani u jednu od triju kategorija:

- **Niski utjecaj**: informacije na temelju ulaznih podataka dobivenih iz modela nisu kritične za proces donošenja odluka; eventualne pogreške mogu imati utjecaj na manji broj poslovnih jedinica banke.

- **Srednji utjecaj**: informacije na temelju ulaznih podataka dobivenih iz modela su važne za proces donošenja odluka; eventualne pogreške mogu imati utjecaj na značajan broj poslovnih jedinica banke.
- **Visoki utjecaj**: informacije na temelju ulaznih podataka dobivenih iz modela su kritične za proces donošenja odluka; eventualne pogreške mogu imati utjecaj na izvještaje prema trećim stranama (npr. regulatoru, dioničarima, rejting agencijama).

Redovito praćenje ključnih pokazatelja rizika omogućuju banci procjenu izloženosti rizicima. Praćenje se provodi samoprocjenom rizika uključujući redovnu kontrolu procesa. Na temelju dobivenih podataka provodi se analiza unutarnjih gubitaka ako ih je bilo. Praćenje rizika podrazumijeva prilagodbu novonastalim situacijama kao i redovito obavještavanje menadžmenta banke pružajući menadžmentu banke redovitu procjenu poboljšanja ili pogoršanja te procjenu kontrolnog okruženja ako ono zahtijeva posebnu pažnju, korektivnu mjeru ili akcijski plan. Banke bi trebale sve pokazatelje rizičnosti učestalo revidirati kako bi alarmirali menadžment na promjene koje mogu upućivati na pojavu rizika. Takvi pokazatelji mogu uključivati broj propalih trgovanja, stope kretanja djelatnika i učestalost i/ili ozbiljnost pogrešaka i propusta. Vrlo je važno da su ključni pokazatelji rizika razumljivi, primjenjivi i provjerljivi jer na temelju dobivenih rezultata menadžment banke donosi poslovne odluke.
Sustav unutarnjih kontrola propisan je Glavom XV. (člancima 180. – 189.) Zakona o kreditnim institucijama (2008). Iz odredbi koje definiraju funkciju kontrole rizika može se zaključiti da je većinu poslova upravljanja rizicima moguće vezati za funkciju kontrole rizika s obzirom na to da ona u skladu sa Zakonom obavlja sljedeće poslove:

1. analizu rizika
2. praćenje rizika
3. izvještavanje uprave i ostalih osoba o rizicima
4. sudjelovanje u izradi, primjeni i nadzoru nad funkcioniranjem metoda i modela za upravljanje rizicima.

Praćenje ključnih pokazatelja rizika omogućuje proaktivno i napredno upravljanje rizicima u bankama. Pokazatelji rizika daju rano upozorenje na buduće operativne gubitke redovitim prikazivanjem trendova i razvoja.

Pokazatelji rizika moraju omogućiti iscrpnu procjenu izloženosti riziku te biti predmetom analize i redovitog praćenja na osnovi jasnih pravila procjene utvrđenih za svaki pokazatelj rizika kao što su:[4]

- svrha: razlog mjerenja
- rizici na koje se pokazatelj rizika odnosi
- definicija djelokruga na koji se procjena rizika odnosi
- jedinica mjerenja: broj, učestalost, stopa, iznos itd.
- definirati intervale u kojima se pokazatelj rizika prati i analizira (dnevno, tjedno, mjesečno, kvartalno itd.), moraju biti razmjerni osjetljivosti pozadinskih rizika i promjenama u unutarnjim i vanjskim okolišnim čimbenicima (ažuriranje podataka, smanjenje vremena za povrat informacije...)
- pravila za izračun; pokazatelji rizika moraju biti definirani tako da odgovaraju razini aktivnosti banke (opći troškovi, djelatnici, obujam posla, broj transakcija itd.)
- odgovornost menadžera
- dinamika izvještavanja ili prag minimalnog praćenja (redovito ili izvanredno izvješćivanje itd.)
- tijek izvještavanja
- standard ili mjerilo koje mora biti posebno utvrđeno za svaki rizik
- prag upozorenja iznad kojeg ključni pokazatelj rizika zahtijeva posebno praćenje.

Kako unutar svake veće institucije, tako i banke, potrebno je jasno definirati uloge i odgovornosti svakog djelatnika i menadžera kako bi se potencijalni rizici sveli na minimum.

U većim bankama postoje zasebni odjeli kojima je osnovna uloga praćenje i kontrola rizika. Kontrola se provodi izradom akcijskih planova te korektivnim mjerama kada i ako je potrebno, analizira se važnost utvrđivanja novih ključnih pokazatelja rizika te promjena u aktivnosti radi proaktivnog upravljanja operativnim rizikom.

[4] Prilagođeno prema European central bank; ECB guide to internal models Risk-type-specific chapters: https://www.bankingsupervision.europa.eu/legalframework/publiccons/pdf/internal_models_risk_type_chapters/ssm.guiderisktypespecific201907.en.pdf

Banke su u sklopu upravljanja rizicima dužne provoditi testiranja otpornosti na stres s ciljem što kvalitetnije procjene svoje izloženosti riziku, i to za sve ključne rizike (Odluka o upravljanju rizicima, HNB, 2016):

- testiranje otpornosti na stres za kreditni rizik
- testiranje otpornosti na stres za rizik likvidnosti
- testiranje otpornosti na stres za operativni rizik
- testiranje otpornosti na stres za kamatni rizik u Knjizi banke
- testiranje otpornosti na stres za portfelj državnih obveznica
- testiranje otpornosti na stres za utjecaj vanjskih činitelja
- testiranje otpornosti na stres za rizik promjene cijena nekretnina
- testiranje otpornosti na stres za makroekonomski rizik.

Banka rezultate testiranja otpornosti na stres uključuje u procjenu adekvatnosti internoga kapitala i likvidnosti, aktivnosti povezane s planovima postupanja u kriznim situacijama, u okviru preispitivanja sklonosti preuzimanja rizika.
Da bi se rizici uspješno pratili, svaka veća institucija treba imati uspostavljen okvir za upravljanje rizicima te razvijen sustav unutarnjih kontrola. Unutarnja kontrola predstavlja skup postupaka koji se provode kako bi se mogle steći realne spoznaje o učinkovitosti poslovanja, pouzdanosti financijskih izvješća te ustanoviti usklađenost s važećim zakonima i propisima (Labudović, 2016). Okvir utvrđuje općenito upravljanje i bankarske metodološke zahtjeve za inventuru rizika, poštovanje zakonitosti, dodjeljivanje kapitala, likvidnost i poslovne modele (Zakon o kreditnim institucijama, 2020. članak 104.).
Uspostava odgovarajućega kontrolnog okruženja ima vrlo važnu ulogu u djelotvornom upravljanju rizicima modela.

Rizik modela sastoji se od dvije komponente: inherentni rizik i rezidualni rizik (EBA, 2014).[5]
Inherentni rizik vezan je uz upotrebu modela bez postojećih kontrola za ublažavanje.
Rezidualni rizik ostaje nakon što se u obzir uzmu kontrole. Vezan je uz rad modela i mjeri se periodično (ovisno o razredu modela) pregledom modela i procjenom učinkovitosti kontrolnih okruženja.

[5] European bank authority (EBA): Guidelines on common procedures and methodologies for the supervisory review and evaluation process (SREP), 2014.

Rizik modela može se identificirati te na temelju prikupljenih dokaza o radu modela periodično mjeriti učinkovitost modela dok model prolazi svoj životni ciklus.

Modeli se dijele u kategorije na skali:

- Razred 1 = visok
- Razred 2 = srednji
- Razred 3 = nizak

Procjena složenosti modela na skali od tri razine:

- niska: jasan, jednostavan model; malen broj povezanih izvora podataka i informatičkih sustava (jedan do dva izvora)
- srednja: složen model koji se može shvatiti i kojim se može upravljati bez specijaliziranoga tehnološkog znanja i vještina; na temelju samo nekih pretpostavki, broj izvora/informatičkih sustava za unos podataka je između tri i pet
- visoka: vrlo složen model koji zahtijeva specijalizirano tehnološko znanje i vještine; na temelju velikog broja pretpostavki, koje podržava velik broj izvora podataka i/ili informatičkih sustava (više od pet izvora).

Ako zadovoljava većinu kriterija, modelu se dodjeljuje specifična kategorija.

4.3. Upravljanje kreditnim i operativnim rizikom

S obzirom na to da se u ovome doktorskom radu posebna pažnja posvećuje upravo kreditnim rizicima kao i njihovoj korelaciji s makroekonomskim varijablama, kreditni rizici izdvojeni su u zasebno poglavlje. Kreditni rizik je najznačajniji rizik u bankarstvu. On nastupa kada pozajmljivač zbog financijskih poteškoća ne može ispuniti svoje obveze u skladu s ugovorom o kreditu te na vrijeme izvršiti povrat pozajmljenih sredstava.

Kreditni rizik je rizik financijskoga gubitka kapitala i/ili prihoda banke, koji je posljedica dužnikove nemogućnosti da zbog bilo kojeg razloga ispuni svoje financijske ili ugovorne obveze u cjelini i/ili na vrijeme prema ugovoru o plasmanu sklopljenom s bankom (Todorović, 2009). Autor također navodi da je kreditni rizik najveći rizik kojem je banka izložena u svojem poslovanju. Ovaj je rizik star koliko i samo bankarstvo, jer je pozajmljivanje novca drugoj ugovornoj strani uvijek sa sobom nosilo opasnost da pozajmljena sredstva neće biti vraćena.

Na bankarski kreditni rizik mogu utjecati (Castro, 2012):

- čimbenici koji utječu na sustavni kreditni rizik
- čimbenici koji utječu na nesustavni kreditni rizik.

Čimbenici koji utječu na sustavni kreditni rizik su:

- makroekonomski čimbenici poput stope zaposlenosti, rasta bruto domaćeg proizvoda, indeksa dionica, stope inflacije i kretanja tečaja
- promjene ekonomskih politika, poput promjena monetarne i porezne politike, promjene ekonomskog zakonodavstva, kao i ograničenja uvoza i poticanja izvoza
- političke promjene ili promjene ciljeva vodećih političkih stranaka.

Navedene varijable mogu imati značajan utjecaj na vjerojatnost da će zajmoprimci otplatiti svoje dugove, ali kako je promjene u ekonomskoj politici i političke promjene teško ispitati, literatura se uglavnom usredotočila na makroekonomske čimbenike.

Čimbenici koji utječu na nesustavni kreditni rizik su:

- za pojedince: poput njihove individualne osobnosti, financijske solventnosti i kapitala, kreditnog osiguranja
- za poduzeća: poput kvalitete uprave, financijskog položaja, izvora sredstava i kvalitete financijskog izvještavanja, njihove sposobnosti plaćanja zajma te specifičnosti sustava industrije kojem pripadaju. Faktori specifični za industriju mogu uključivati strukturu i ekonomsku uspješnost industrije, zrelost industrije i njezinu stabilnost.

Navedeni čimbenici mogu utjecati na kretanje NPL-a u bankama. Ako je udio NPL-a u odnosu na imovinu banke visok, postoji potencijalni rizik nelikvidnosti. Klasične mikroekonomske teorije podupiru stajalište da su rizik likvidnosti i kreditni rizik usko povezani. Oba rizika unutar bankarske industrije u postavkama Bryant (1980) ili Diamond i Dybiga (1983) sugeriraju da su struktura imovine i obveza banke usko povezane, posebno s obzirom na potencijalni gubitak neplaćanja u kombinaciji s potrebama za novčanim sredstvima.
Gubitak nastao zbog nenaplativosti kredita utječe na kvalitetu imovine banke. Ako su gubici visoki, odnosno omjer nenaplativih kredita u odnosu na imovinu banke visok, to može utjecati na trošak kapitala, a u ekstremnim slučajevima može dovesti i do insolventnosti banke. Prema

Imbierowiczi i Rauch (2013), rizik likvidnosti i kreditni rizik dva su najvažnija čimbenika opstanka banaka.

Unatoč novim proizvodima, prema podacima HNB-a, čak 89 % bilance banke povezano je s kreditnim rizikom. Zbog toga su kreditni rizici najčešći uzrok propadanja banaka. Iako su kreditni rizici uglavnom povezani sa životnim ciklusom kredita, vrlo značajnu ulogu imaju i uspostavljena pravila i modeli za ocjenu kreditne rizičnosti kao i upravljanje banke ovim rizikom.

Neprimjenjivanje adekvatnih metoda za izračun i procjenu kreditnih rizika banaka može dovesti do značajnih gubitaka koji bi institucija mogla pretrpjeti zbog odluka koje su donesene na temelju rezultata dobivenih primjenom neadekvatnih internih modela za izračun rizika.

Prema definiciji HNB-a, kreditni rizik je rizik smanjenja kreditne sposobnosti klijenta koja može dovesti do djelomičnog ili potpunog neispunjavanja ugovornih obveza dinamikom kakva je predviđena ugovorom o kreditu što pak dovodi do štetnog događaja za banku. U bankama dolazi do smanjenja kapitala banke što utječe i na njezin lošiji rezultat.

Kreditni rizik predstavlja najveći izazov za menadžere i tržišne regulatore (Duffie i Singleton, 2012). Kreditni rizik je najstariji i najveći rizik kojem je banka izložena stoga je u svakoj financijskoj instituciji potrebno definirati proces popisa svih rizika, propisati načela i aspekte kategorizacije modela rizika te provoditi reviziju adekvatnosti modela svih rizika, a posebno kreditnih. Okvir za upravljanje rizicima modela uključuje procese, ljudske resurse i tehnologije kojima se osigurava jaka, kvalitetna i jasna uporaba modela za donošenje odluka (EBA smjernice, 2017). Ako financijska institucija ne primjenjuje adekvatne modele za procjene kreditnih rizika, menadžment može dovesti do lošeg odlučivanja što pak može utjecati na profitabilnost institucija pa čak i stečaj banke. Proglašenjem stečaja financijske institucije stvara se negativni reputacijski rizik prema financijskim institucijama što dovodi do nepovjerenja stanovništva u bankarske institucije, a time i do gospodarske krize. Povlačenjem depozita iz banaka te nelikvidnost bankarskog sustava može dovesti do nelikvidnosti realnog sustava koji je pokretač gospodarstva zemlje. Imbierowiczi i Rauch (2013) tvrde da bi se zajedničkim upravljanjem rizikom likvidnosti i kreditnim rizikom u banci moglo smanjiti neizvjesnost i znatno povećati stabilnost banke. Rezultati njihove analize podržavaju i podupiru regulatorne napore poput Basel III i Dodd-Frankova zakona[6] koji stavljaju naglasak na važnost upravljanja rizikom likvidnosti u sprezi s kvalitetom imovine i kreditnim rizikom banke.

[6] Dodd-Frank (2010). Wall Street reforma i Zakon o zaštiti potrošača ili Dodd-Frank zakon, je skup zakona donesenih kako bi se osigurala financijska stabilnost nakon velike recesije u 2008. Zakon štiti porezne obveznike

Banka može utjecati na visinu kreditnih rizika tako da odobrava samo plasmane sa sigurnim povratima, no ti plasmani najčešće nose i niske prinose što pak može dovesti do snižavanja profitabilnosti. Prema Mihalić (2017), banka mora osigurati optimalnu kombinaciju visoko rizičnih plasmana koji nose viske prinose te plasmana niskog rizika s manjim prinosima. Pri tome svakako treba voditi računa o moralnom hazardu. Mihalić navodi da je moralni hazard rizik koji podrazumijeva da osoba koja je sudionik ugovora nije potpisala ugovor u dobroj namjeri, tj. da osoba nije dala točne informacije o imovini, pasivi ili kreditnoj sposobnosti, ili ima namjeru poduzimati veći rizik kako bi ostvarila veći profit prije nego što istekne ugovor. Jednostavnije, moralni hazard se pojavljuje kada je osoba spremna više riskirati jer netko drugi snosi posljedice toga rizika.
Zbog posljedica moralnog hazarda, banka može snositi velike gubitke, stoga moderne i razvijene banke danas provode niz provjera vjerodostojnosti podataka zaprimljene od klijenata. Dobro organiziran menadžment kreditnih rizika ključ je uspjeha svake financijske kompanije.
Svaka komercijalna banka ima kreditni portfelj kojim upravlja. Povećanje kreditnog rizika utječe na povećanje cijene kapitala za banku, kapitalne rezerve, stoga je kontrola kreditnih rizika iznimno važna. Sve veće, ozbiljnije banke danas primjenjuju suvremene metode za izračun kreditnih rizika, posebno za portfelje pravnih osoba, a posebno za građanstvo. Zbog nepouzdanosti informacija o financijskoj sposobnosti fizičkih osoba, često su rizici puno veći kod fizičkih osoba nego kod pravnih osoba iako su plasmani prema fizičkim osobama prema izloženosti znatno manji.

Dobra politika upravljanja kreditnim rizicima ne znači provođenje restriktivne politike kreditiranje već dobru i kvalitetnu procjenu plasmana od analitičara u kombinaciji s uspostavljenim modelima i aplikacijama za izračun rizičnosti.

Prema Heffernanu (2005), postoje tri seta kontrola upravljanja kreditnim rizicima:

1. *Limitiranje kreditnih rizika*

Uključuje politike i koncentraciju izloženosti velikim rizicima, diversifikaciju izloženosti, pozajmljivanje povezanim osobama i analizu prezaduženosti. Danas se posebna pažnja posvećuje limitiranju izloženosti i koncentraciji izloženosti prema jednoj osobi ili sustavu (npr.

od tereta druge banke spašavanja, kao i nepravedno postupanje financijskih organizacija, kao što su zajmodavci, dužnici i agencije za izvještavanje o kreditima.

maloprodaji, građevini, trgovini i sl.) posebno u manjim bankama. U većini zemalja uspostavljena su ograničenja financiranja prema jednoj osobi tako da izloženost ne smije prijeći limit od 10 do 25 % kapitala banke. Ako izloženost prijeđe limit, banka je dužna uspostaviti dodatna osiguranja za tako velike izloženosti. Upravljanje velikim izloženostima zahtijeva i poseban pristup. U slučaju velikih klijenata i velikih izloženosti banke moraju osigurati pristup svim informacijama, izrazito paziti na novčani tok te biti uključeni u sve značajne poslovne odluke. Financiranje povezanih osoba veliki je rizik za banku. Povezane osobe uključuju matičnu banku, glavne dioničare, podružnice poduzeća, međusobno povezana poduzeća, direktore i izvršne direktore. Ključno pitanje pri financiranju povezanih osoba jest je li odluka o financiranju objektivna te sadrži li sve bitne elemente rizičnosti u skladu s procedurama i politikama banke. Većina regulatora je problematiku financiranja povezanih osoba riješila tako da je uspostavljen limit financiranja, odnosno ograničen je iznos tako da izloženost ne smije prijeći određeni postotak temeljnoga kapitala banke.

2. *Izloženost kreditnom riziku kroz klasifikaciju imovine*

Ovaj set kontrola podrazumijeva periodičnu analizu i evaluaciju kvalitete kreditnog portfelja. Svaka banka trebala bi imati uspostavljenu kreditnu politiku. Kreditna politika trebala bi sadržavati politiku upravljanja kreditnim portfeljima banke sistematiziranom prema valuti kredita, ocjeni kreditne sposobnosti, prema kvaliteti portfelja, tipu kredita/proizvoda (Odluka o upravljanju rizicima, članak 8., HNB, 2016).

U skladu s EBA-om i Smjernicama o internom upravljanju (2018) kreditna politika sadrži i politiku pozajmljivanja. Politika pozajmljivanja razlikuje se ovisno o veličini banke. Manje banke su više centralizirane, dok velike banke, zbog brzine i manjeg rizika, imaju decentraliziranu politiku kreditiranja. Ako je riječ o velikim bankama koje posluju u više različitih zemalja, poželjno je da je politika kreditiranja decentralizirana jer svaka zemlja ima svoje specifičnosti i često jednaka pravila nisu primjenjiva u svim zemljama na isti način. Unutar politike mora biti propisano postupanje za svaki tip proizvoda, vrstu proizvoda, odnosno opis svih proizvoda koje banka nudi svojim klijentima, kao i propisane instrumente osiguranja kredita. Instrumenti osiguranja plasmana propisuju se ovisno o visini izloženosti i tipu proizvoda i o povijesnim podacima o uspješnosti naplate iz njih. Vrijednost procijenjene imovine u odnosu na izloženost i metode primijenjene u procjeni, trebaju biti propisane i transparentne. Kamate obračunate na kredit trebaju biti dovoljno visoke kako bi pokrile

troškove banke kao što su trošak nabave sredstava, trošak plaća, administrativne troškove i rizik potencijalnoga gubitaka, a ne bi smjele biti previsoke, odnosno nekonkurentne. Odnosno, trebaju osigurati profitnu maržu. Kamate je potrebno periodično usklađivati i prilagođavati stanju na tržištu i potrebama klijenta. Politika pozajmljivanja treba imati propisano maksimalno dospijeće za svaki tip kredita s adekvatnim i transparentnim otplatnim planom i pokrićem za cijelo vrijeme trajanje kredita. Dimenzija kreditnog rizika koju ne treba zanemariti je i kreditna izloženost banke prema jednom sustavu ili regiji. Banka je puno „ranjivija“ ako je kreditno koncentrirana na jedan gospodarski sustav stoga je potrebno voditi kontrolu izloženosti i u svakom trenutku voditi računa o disperziji rizika ulaganja.

3. *Rezervacije za potencijalne gubitke*

Rezervacija za potencijalne gubitke je provedba adekvatne rezervacije rizičnih plasmana. Razvijene banke u sklopu svojih modela analize rizičnosti uključuju analizu rizičnosti gospodarskih sustava što uzimaju u obzir pri odobravanju plasmana. Internacionalne banke uz navedene rizike suočene su i s dodatnim rizikom zemlje. Rizičnost zemlje podrazumijeva makroekonomsku situaciju i socijalnu situaciju u zemlji. Amihud et al. (2002) navode da se ukupni i sustavni rizik internacionalnih banaka ne mijenjaju značajno u odnosu na banke na njihovim matičnim tržištima. Štoviše, i banke koje imaju značajne aktivnosti u inozemstvu ovisne su o ekonomskim uvjetima matične zemlje. U sklopu kreditne politike za kontrolu kreditnih rizika ne smije se zanemariti rezervacija potencijalnih gubitaka za rizične plasmane koja se treba provoditi bez obzira na to je li plasman naplativ, nenaplativ ili djelomično naplativ.

4.3.1. Kontrola kreditnog portfelja

Kreditni portfelj banke predstavlja tržišnu poziciju banke stoga je važno provoditi *reviziju/ kontrolu kreditnog portfelja banke*.

Pregled kreditnog portfelja trebao bi uključivati (prilagođeno prema Heffernanu, 2005):

1. sve kreditne izloženosti veće od 5 % kapitala banke
2. sve kreditne izloženosti prema dioničarima i povezanim osobama
3. sve kreditne izloženosti u kojima je došlo do promjene uvjeta kredita za vrijeme trajanja otplate kao što je: izmjena kamatne stope, refinancirani i restrukturirani krediti, moratoriji i sl.

4. sve kreditne izloženosti u kojima je nastupilo kašnjenje u otplati obveza dulje od 30 dana
5. sve kreditne izloženosti klasificirane kao sumnjiva i sporna potraživanja. Analiza i revizija kreditnog portfelja banke treba obuhvatiti potpuni pregled kreditnog spisa s popratnom dokumentacijom koja uključuje dokumentaciju o zajmoprimcu, dokumentaciju na temelju koje se analizirao i ocjenjivao kreditni rizik prije odobravanja plasmana, odluke o odobravanju plasmana, važne informacije koje su utjecale ili su mogle utjecati na donošenje odluke kao i postotak rezervacije. Revizija kreditnog portfelja treba se provoditi periodično, sustavno i prema objektivnim kriterijima. Pri određivanju rezervacije, da bi uljepšali sliku banke, menadžment banaka je zadržavao diskrecijsko pravo subjektivne procjene postotka rezervacije. S vremenom su se metode procjene rezervacije unaprijedile tako da je središnja banka u svakoj zemlji propisala jedinstvena pravila za provedbu rezervacije plasmana kojih se trebaju pridržavati sve financijske institucije.

4.3.2. Metode i modeli za izračun kreditnog rizika

Za izračun kreditne rizičnosti, kreditne institucije izradile su kvantitativne i kvalitativne modele. Banke mogu minimalizirati kreditne rizike koristeći se sljedećim modelima zaštite od rizika (prilagođeno prema Van Greunung i Bratanović, 2020):

1. određivanjem cijene kredita
2. određivanjem i postavljanjem kreditnog limita
3. kvalitetnim osiguranjem plasmana
4. diversifikacijom rizika
5. upotrebom kreditnih derivata.

1. *Određivanjem cijene kredita kroz kamatnu stopu* svaka kreditna institucija trebala bi osigurati da je u cijeni kredita sadržana cijena rizika i trošak banke.

$$R_L = i + ip + naknade$$

Gdje je:

R_L: kamatna stopa na kredit

i: tržišna kamatna stopa (Libor, Euribor, Zibor)

ip: premija rizika koja negativno korelira s povratom kredita (ako je siguran povrat kredita, ip = 0)

Premija rizika i tržišna kamatna stopa koreliraju pozitivno. Što je veća tržišna kamatna stopa, to je veći rizik povrata odnosno vjerojatnost neplaćanja. Osim tržišne kamatne stope i drugi čimbenici utječu na visinu kamatne stope kao što je kvaliteta osiguranja kredita. Ako je kredit dobro kolateraliziran, kamatna stopa je niža i obratno. Neke banke u startu naplaćuju veću naknadu ili uzimaju depozit kao osiguranje povrata te naplaćuju nižu kamatnu stopu.

2. *Kreditni limiti* je mjera kontrole kreditnih rizika.

U svim razvijenim kreditnim institucijama uspostavljeni su kreditni limiti koji ograničavaju prekomjernu zaduženost klijenta koja bi potencijalno ugrozila povrate postojećih obaveza. Mjera kreditnog limita sadrži kvalitativne i kvantitativne podatke o kreditnoj sposobnosti klijenta.

Kvalitativni podaci su: povijest zaduženja, omjer zaduženja i primanja, imovina klijenta, povijest zaposlenja, visina primanja, stupanj obrazovanja, struka, dob klijenta, bračno stanje i slično.

Sinkey i Joseph (2002) kvalitativne kriterije odredili su kao „5 K“:

- Karakter klijenta – Je li spreman otplatiti dugovanje?
- Kapacitet – Koliko je klijent kreditno sposoban za povrat kredita?
- Kapital – Kolika je količina i vrijednost imovine kojom klijent raspolaže?
- Kolateral ili osiguranje – Raspolaže li dovoljno vrijednim osiguranjem?
- Kreditni uvjet – Kakvo je stanje ekonomije te hoće li klijent podnijeti pad ekonomske aktivnosti?

Karakter klijenta odnosi se na integritet i poštenje zajmoprimca te volju za podmirenje dugova na vrijeme jer često klijent ima mogućnost, ali ne i volju da podmiri svoje obveze na vrijeme. Stoga je važno procijeniti karakter klijenta, odnosno njegovu kreditnu povijest.

Vrlo je bitno provjeriti koliko je klijent kreditno sposoban za povrat pozajmljenih sredstava. Pri provjeri *kapaciteta klijenta* misli se na provjeru iznosa i urednosti primanja kod fizičkih osoba te provjeru financijskih izvještaja ako se radi o pravnoj osobi. Pri izračunu kapaciteta potrebno je uzeti u obzir da se samo dio primanja može umanjiti obvezama za kredit, a ne primanja u cijelosti jer u tom slučaju, ako obveze nadilaze primanja, klijent će vrlo brzo postati neuredan.

Kapital je količina i vrijednost imovine kojom klijent raspolaže. Ako vrijednost imovine značajno nadilazi obveze, veća je vjerojatnost da će klijent biti uredan, odnosno rizik povrata svest će se na minimum. Kod pravnih osoba kapital predstavlja vrijednost poduzeća. Što je veći kapital vlasnika poduzeća, to je poduzeće manje rizično te time poželjnije za kreditiranje.

Kolateral predstavlja imovinu dužnika koja zajmodavcu služi kao osiguranje u slučaju da se kredit ne može naplatiti iz redovitog poslovanja. Banka pri plasiranju određenih kredita mora zahtijevati osiguranje plasmana u obliku kolaterala. Na primjer, to može biti kuća ili hipoteka nad nekom drugom nekretninom, oprema, pogoni ili postrojenje. Banka se kolateralom koristi jedino u slučaju da dužnik ne može otplatiti svoj dug, ali kolateral nikako ne smije zamijeniti primarni izvor otplate kredita, osim u slučaju lombardnih kredita kada se kreditna sposobnost klijenta temelji na vrijednosti likvidne imovine koja služi kao osiguranje (Hosjak, 2017).

Ako banka ne naplati svoje potraživanje iz primarnog novčanog toka klijenta, pravnim putem naplaćuje se iz imovine klijenta. Banke kvalitetnim osiguranjem smanjuju kreditne rizike. Naravno, vrijednost osiguranja nije konstantna što znači da može padati i rasti. Ako vrijednost osiguranja padne (recimo pad cijene nekretnina na tržištu) a da bi spriječile porast kamatne stope na kredit, banke će zatražiti od klijenta „nadopunu“ kolaterala putem depozita ili putem dodatne kolaterale. Kroz povijest poslovanja pokazalo se da kolateralno osiguranje samo za sebe nije dovoljna sigurnost banke u slučaju pada sposobnosti klijenta za povratom pozajmljenih sredstava. Tržište nekretnina i pokretnina je jako promjenjivo stoga se vrijednost nekretnine pri odobravanju kreditnog plasmana i na kraju razdoblja otplate može znatno promijeniti.

Kreditni uvjeti su uvjeti ugovora o kreditu. Izrazito je važno da su uvjeti ugovora o kreditu usklađeni s potrebama klijenta. Važno je prilagoditi uvjete potrebama klijenta te što više iz primjene izbaciti „tipizirane“ ugovore o kreditu. Na primjer, klijent koji diže turistički kredit za pripremu turističke sezone imat će poček u otplati, isto kao i kredit za investiranje u novi pogon

ili opremu. Dok se investicija ne realizira te dok se ne ostvari novčani tok iz investicije, banka klijentu može ugovoriti poček u otplati kredita. U protivnom, klijent iz tekućeg poslovanja vrlo vjerojatno neće moći odmah vršiti povrat pozajmljenih sredstava.

Kvantitativni model kreditnih rizika podrazumijeva upotrebu financijskih podataka za mjerenje i procjenu vjerojatnosti neizvršenja novčanih obveza.

Kreditni skoring sustav dodjeljuje jednu kvantitativnu mjeru, takozvani skor, potencijalnom klijentu predstavljajući njegovo ponašanje u otplati dodijeljenoga kredita. Ukupan broj bodova (skor) dobiven zbrojem bodova prema određenim karakteristikama uspoređuje se s najniže prihvatljivim brojem bodova definiranim kreditnom politikom banke na temelju čega se kredit odobrava ili ne odobrava (Kvesić, 2013). Kreditni skoring je proces kojim se određuje koliko je vjerojatno da klijent kasni u otplatama rata kredita (Hand i Henley, 1997).
Primjena kreditnoga skoring modela omogućila je precizniju ocjenu kreditne sposobnosti potencijalnih klijenata.
Prema Bohaček et al. (2003), neke od prednosti zajmodavatelja pri upotrebi skoring modela su: (1) preciznije procjenjivanje rizika; (2) kvalitetnije donošenje odluka; (3) povećanje brzine odlučivanja, a time i broja kredita koje zajmodavatelji mogu pregledati; (4) mogućnost kreiranja kreditnih programa za ciljanu populaciju. Neke od prednosti za mala poduzeća: (1) povećava se dostupnost kredita malim poduzetnicima; (2) cijena kredita određuje se prema očekivanom riziku; (3) skraćeno vrijeme postupka odobravanja i realizacije kredita.

Financijske institucije u razvijenim zemljama primjenjuju različite modele kreditnoga skoringa kreirane na temelju vlastitih podataka ili podataka drugih financijskih institucija. Poseban problem nastaje kada kreditni odjel banke ne raspolaže podacima te kada u bankarskom sustavu ne postoje spoznaje i iskustva vezana uz razvoj i primjenu modela kreditnoga skoringa (Kvesić, 2013).

Osim zaštite od rizika skoring modeli omogućuju bankama da privuku kvalitetne klijente tako da boljim klijentima, s boljim skoringom, mogu ponuditi povoljnije kreditne uvjete i za niže troškove za banku.

Prednosti skoring modela (Rackov, 2013):

- Kreditni skoring modeli su objektivni, konzistentni i efikasni.
- Smanjuje se operativni rizik – proces je automatiziran stoga je mogućnost pogreške minimalizirana.
- Primjena kreditnoga skoring modela snižava troškove.
- Kreditni skoring modeli relativno su jednostavni i lako se interpretiraju.
- Metodologija primijenjena u izgradnji takvih modela je jednostavna i transparentna.
- Banke ostvaruju bolje usluge potencijalnim klijentima.
- Kako kreditni skoring određuje vjerojatnost kašnjenja, cijena kredita može se prilagoditi riziku.
- Ovisno o situaciji na tržištu, banka može ocijeniti količinu kredita koju će ponuditi u skladu s kreditnom politikom banke.
- Osigurava se bolja kontrola kreditnog portfelja i njegovih karakteristika nadgledanjem i revidiranjem kreditnoga skoring modela.

Nadalje Rackov (2013) navodi nedostatke kreditnoga skoring modela kako slijedi:

- Modeli tijekom vremena degradiraju – potrebno je konstantno usklađivati model sa stanjem na tržištu.
- Razvijeni kreditni skoring modeli primjenjuju se samo na tipove klijenata koji su bili uključeni u razvoj modela. Na primjer, ako se banka odluči za izdavanje kreditnih kartica studentima, ali primjenjuje kreditni skoring model koji je razvijen na temelju uzorka koji nije uključivao studente, model neće dobro razlikovati dobre i loše klijente.
- Vjerojatnost neizvršenja obveza izračunate na osnovi interno razvijenoga kreditnog skoring modela ne može se promatrati na tržištu.
- Ako ne postoji dovoljan obujam uzorka ili u sustavu banke ne postoje povijesni podaci, model se ne može razvijati.

Svi ti pokazatelji određuju limit zaduženja preko kojeg se ne bi smjelo prijeći pri odobravanju kredita.

3. U sklopu praćenja *kvalitete kreditnog portfelja***,** banke su dužne provoditi procjene očekivanih gubitaka.

Pri izračunu procjene očekivanih gubitaka banke se koriste sljedećim parametrima (prilagođeno prema Van Greuning i Bratanović, 2020):

- Vjerojatnost neispunjenja obveza (engl. *probability of default* – PD)

Postotak rizika da klijent neće uspjeti na vrijeme ispuniti svoje obaveze u skladu s uvjetima i dinamikom ugovora o kreditu. PD se računa ili za svakoga klijenta koji ima kreditnu obvezu ili za skupinu klijenata sa sličnim atributima.

Pri računanju PD-a u obzir se uzimaju:

- povijesni podaci o potencijalnom neispunjenju obveza
- procjene nastale na temelju kretanja cijena opcija, dionica i ostalih vrijednosnica na zajedničkom tržištu
- podaci vanjskih rejting agencija za procjenu PD-a
- kreditni „scorecard".

- Gubitak zbog nastanka statusa neispunjavanja obveza (engl. *loss given default* – LGD)

Ekonomski gubitak koji uzima u obzir vremensku vrijednost novca, svođenja na sadašnju vrijednost (diskonta) te značajne izravne i neizravne troškove povezane s naplatom za pojedine izloženosti (npr. troškovi naplate po pojedinim instrumentima osiguranja) (EBA/GL/2017/16).

- Izloženost u trenutku stupanja u status neispunjavanja obveza (engl. *exposure at default* – EAD)
- Očekivani gubitak (engl. *expected loss* – EL)

Iznos u nacionalnoj valuti kojoj je banka izložena prema trećoj osobi za koju se očekuje potpuni gubitak nakon nastanka neispunjenja obveza. EL kalkulacija je osnova za izračun rezervacija.

- Neočekivani gubitak (engl. *unexpected loss* – UL)

Gubitak koji će se pojaviti zbog izvanrednih događaja na tržištu.

Slika 4. Izračun očekivanih gubitaka

Očekivani gubitak (EL)	=	Vjerojatnost neispunjenja obveza (PD) %	×	Gubitak zbog nastanka statusa neispunjavanja obveza (LGD) %	×	Izloženost u trenutku stupanja u status neispunjavanja obveza (EAD)

Izvor: Van Greuning, Bratanović, 2020. *Analyzing banking risk*, fourth edition, str. 190

Slika 5. Primjena formule za izračun očekivanih gubitaka: EL = PD × EAD × LGD

Portfelj	Rejting	Iznos kredita (€)	PD %	EAD €	LGD %	EL (€)
A	AAA	1.000,00	0.05	20,00	30	3,000
B	B+	1.000,00	5,25	60,00	45	1.417,50
C	D	1.000,00	100,00	1.000,00	100,00	1.000.000

Izvor: Izrada autor prema van Greuning, Bratanović, 2020. *Analyzing banking risk*, fourth edition, str.191

Na slici 5. prikazan je način izračuna očekivanoga gubitaka na primjeru tri kreditna portfelja; A, B i C. Portfelj A ima najbolji kreditni rejting (AAA), portfelj B je rejting B+, dok portfelj C ima najlošiji kreditni rejting označen s rejtingom D. Radi lakše usporedbe izračuna očekivanoga gubitka, iznos kredita je u sva tri portfelja isti i iznosi tisuću eura. Nakon što smo definirali rejting kreditnog portfelja, iznos odobrenog zajma uvrštava se u sustav za izračun očekivanoga gubitka. Vjerojatnost neispunjenja obveza različita je za svaki portfelj i ovisi o kreditnom rejtingu portfelja. Očekivani gubitak za portfelj C je najveći jer portfelj C nosi najrizičniji kreditni rejting te je očekivani gubitak u potpunosti izjednačen s iznosom plasiranih sredstava (tisuću eura). To znači da banka za plasman iz najrizičnijega kreditnog portfelja C ne očekuje nikakav povrat pozajmljenog iznosa (banka je plasman rezervirala 100 % i on je u bankama knjige prikazan kao čisti gubitak). Portfelj iz skupine B+ je djelomično rizičan i očekivani gubitak iznosi 3 eura, dok je očekivani gubitak za portfelj B 1.417 eura.

Prema Gornjak (2017), internacionalni financijski izvještajni standardi, poznatiji kao IFRS 9, danas propisuju suvremen pristup procjene kreditnoga gubitka kao i način procjene adekvatnog

stupanja rezervacije. Obvezu provođenja IFRS-a ima svaka banka koja posluje u Europskoj uniji. Načela za prepoznavanje, mjerenje i otkrivanje informacija o financijskim instrumentima u financijskim izvještajima izvorno su propisani 2003. godine u Internacionalnim računovodstvenim standardima IAS 39. U 2018. godini IAS 39 „Prepoznavanje i mjerenje" zamijenjen je IFRS-om 9. IFRS 9 uveo je značajne promjene u primjeni i računanju rezervacija. IAS 39 se pri računanju rezervacija oslanjao na već nastale gubitke, dok je IFRS 9 model mjerenja budućih potencijalnih gubitaka, koji zahtijeva primjenu mjera za procjenu budućih gubitaka u kreditnom portfelju.

4. *Diversifikacija rizika banke* provodi se diversifikacijom kreditnog portfelja banke.

Diversifikaciju kreditnog portfelja banke treba shvatiti kao nastojanje uprave banke da smanji rizik poslovanja povećanjem broja bankarskih proizvoda, povećanjem broja klijenata, kreditiranjem novih djelatnosti i povećanjem teritorijalnog područja djelovanja. Rezultat koji se želi postići diversifikacijom je smanjenje izloženosti kreditnom riziku. Kreditna diversifikacija i izloženost riziku dva su suprotna pojma. Svaka nova diversifikacija djeluje na koncentraciju rizika promjenom strukture kreditnog portfelja (Perić, 2012).

5. *Upotreba kreditnih derivata*

Tradicionalni instrumenti i tehnike prijenosa kreditnog rizika su osiguranje obveznica, garancije, kolateral, otkaz ugovora o kreditu, prijenos prava i obaveza, neting, put opcije, sindicirani krediti, diversifikacija, kreditni limiti i posredovanje. Kreditni derivati „izoliraju i odvajaju kreditni rizik od drugih vrsta rizika, kao što su tržišni i operativni rizik. S obzirom na to da su omogućili efikasan, fleksibilan i jednostavan način transfera kreditnog rizika, smatra se da su kreditni derivati veoma moćni instrumenti" (Spasojević, 2013). Kreditni derivati uvedeni su kako bi se uklonili nedostaci tradicionalnih instrumenata za transfer kreditnog rizika. Drugim riječima, javila se potreba da se investitori poput velikih investicijskih banaka, investicijskih i mirovinskih fondova te osiguravajućih društava zaštite od gubitaka koji nastaju kao posljedica neizvršenja dijela ili obveza pojedinih klijenata (Perić, 2012).

Uz kredite, međubankarski depoziti su najvažnija kategorija imovine koja predstavlja visok kreditni rizik. Menadžment upravljanja kreditnim rizikom trebao bi pratiti međubankarske depozite jednako kao i kreditnu izloženost. Korespondentne banke trebale bi propisati instrumente osiguranja te pratiti izloženost. To vrijedi i za izvanbilančne obveze. Izloženost banke za izdane garancije i akreditive kao i bilančne kreditne obveze trebaju se pratiti.

4.4. Regulatorna tijela, smjernice i nadzor nad bankama

Zašto je potrebno regulirati banke? Tko su regulatori banaka, tko postavlja „pravila igre“ i tko je zadužen za njihovu regulaciju?
Svako tržište, svaka organizacija ima svoja pravila. Pravila su potrebna kako bi svi sudionici na tržištu ostvarili svoja prava, odnosno kako bi tržište bilo konkurentno, transparentno i kako ne bi došlo do neravnoteže tržišta, a time i do gospodarske krize.

Banke i financijsko tržište kontrolira se zbog više razloga (Heffernan, 2006):

1. Zaštite klijenta: bankarsko poslovanje je izrazito kompleksno. Zbog svoje kompleksnosti klijenti nisu svjesni svih potencijalnih rizika niti na njih mogu djelovati. Stoga je potrebno prije svega zaštititi klijente, odnosno depozitare. Financijske institucije trebaju upoznati klijente sa svim potencijalnim rizicima i posljedicama prilikom korištenja proizvoda banke.
2. Sprječavanja potencijalnog monopola odnosno stvaranja konkurentnog i transparentnog tržišta. Uloga regulatora je sprječavanje nastajanja monopola. Kada jedna institucija ima monopol nad pružanjem određene usluge, na tržištu nije formirana tržišna cijena te je uloga regulatora spriječiti nastajanje monopola ili duopola radi zaštite potrošača. Radi konkurentnosti u financijskom sustavu, potrebno je omogućiti razvoj što većeg broja financijskih institucija specijaliziranih za različite vrste usluga.
3. Zaštite od kriminalnih aktivnosti: u financijskim institucijama dolazi do obrtaja velikih količina novca. Stoga bez uspostave regulacije i strogog nadzora može doći do kriminalnih radnji koje dovode do nerazmjernih šteta. Potrebno je spriječiti prijevare, pranje novca i slične kriminalne aktivnosti.

4. Sprječavanje nastanka izvanrednih ekstremnih situacija od pojedinih subjekata na tržištu. Težnja za što većom zaradom, plasiranjem novih, neprovjerenih, visokorizičnih proizvoda na tržište može uzrokovati negativne efekte sa značajnim posljedicama za financijska tržišta.

Mnogo je pozitivnih primjera[7] u kojim su središnje banke na vrijeme ustanovile i spriječile nastanak potencijalnih šteta koje su uzrokovali pojedini sudionici na financijskome tržištu te zaštitile financijsko tržište u cjelini, a time i sve ostale sudionike. Zbog toga je uloga središnjih banaka važna za kontrolu tržišta u cjelini i zadržavanje stabilnosti tržišta.

Reputacija banaka izrazito je važna za stabilnost financijskog tržišta. Zbog nedovoljne transparentnosti i nedostatka znanja vezano uz poslovanje banaka, reputacija je katkad jedini kriterij klijenta pri donošenju odluke o investiranju sredstava u banku. Ako se reputacija samo jedne banke ugrozi, gubi se generalno povjerenje u bankarski sustav te se stvara panika među klijentima što dovodi do povlačenja sredstava iz svih banaka i nastaje sistemski rizik. Rastuća averzija prema riziku ili kriza povjerenja mogu imati izražene negativne učinke na realno gospodarstvo, posebno kada je kapitalna baza financijskih institucija oslabljena. Mehanizam širenja dovodi do pada zajmova u bankama i generira trajni pad ukupnih ulaganja i proizvodnje (Chen, 2001).

Dovoljno je da samo jedna banka u financijskom sustavu svojom lošom poslovnom politikom dovede do nestabilnosti cijelog sustava. Zbog toga je iznimno važno uspostaviti mehanizme kontrole i pravila koja će natjerati banke da se ponašaju u skladu sa zahtjevima regulatora bez obzira na veličinu ili strukturu banke. U razvoju analitičkog okvira i pokazatelja za makrobonitetnu analizu bankarskog sustava, glavni je cilj obuhvatiti sve glavne izvore rizika. To zahtijeva pozornost na strukturne promjene u gospodarstvu, financijskim tržištima i poslovnim aktivnostima banaka jer te promjene utječu na profile rizika banaka (Mörttinen et al., 2005).

U ograničavanju nastanka sistemskog rizika veliku ulogu čine međubankovna tržišta i eurotržišta. Uloga međubankovnih tržišta je apsorbirati rizike i spriječiti njihovo širenje, ali s druge strane čine globalno financijsko tržište ranjivim prema određenim egzogenim šokovima.

[7] 1998. Njujorška federalna banka je spriječila financijsku krizu zbog propsati hedge fonda Long Term Capital Markets.

Dodatan problem je uloga bankarskog sustava na kreiranju monetarne politike. Država preko banaka djeluje na kretanje makroekonomske politike, na kretanje ponude novca i formiranje cijena na tržištu. Ako dođe do kolapsa bankarskog sustava, dolazi do pada ponude novca što dovodi do makroekonomskih problema. Potrebno je razviti kontrolni sustav koji može otkriti izloženost agregatnom riziku koji je nevidljiv za bankarski nadzor oslanjajući se samo na procjenu pojedinačnih institucija (Elsinger et al., 2003).

Zbog straha od narušavanja tržišne ravnoteže, države su često spremne poduzeti mjere za spašavanje posrnulih banaka te financijskim injekcijama ublažiti gubitke proizašle iz poslovanja. Kao primjer državne intervencije u svrhu zaštite klijenata u slučaju nastanka štetnog događaja je osiguranje depozita. Država bez naknade osigurava depozite štediša te ako dođe do nelikvidnosti banaka, novac štediša nije ugrožen jer država garantira za njihove povrate. U tako „sigurnom“ poslovnom okruženju, bankarski menadžment ima veću slobodu pa se često i nesvjesno izlaže rizičnijim investicijama. Kako ne bi došlo do potpune slobode u rizičnom ponašanju banaka, koje su uglavnom u privatnom vlasništvu, država je dužna kontrolirati njihovo poslovanje te spriječiti pojavu moralnog hazarda. Moralni hazard u svojem radu predočuje Acharya (2009). Jamstvo države kada vlasnici banaka prilikom zajedničkog neuspjeha očekuju veću pomoć države nego u slučaju pojedinačnog neuspjeha, naglašava sistemski rizik tjerajući banke na korelirana ulaganja kako bi se izvukle veće regulatorne podružnice.

Prema Bergseth (2017), moralni hazard je situacija u kojoj osoba namjerno preuzima rizik, znajući da će netko drugi snositi posljedice ako dođe do negativnog događaja. Hellmann, Murdock i Stiglitz (2000) moralni hazard opisuju kao rizik kojem su podložne sve banke na svijetu bez obzira na veličinu i strukturu. Moralni hazard nastaje kao posljedica dvaju bitnih elemenata sigurnosti. Prvi je osiguranje depozita građana od države u slučaju propasti banke i drugi kada se značaj bankarskog poslovanja preuveličava primjenom pravila „prevelike i značajne da bi propale“, dakle kada se bankarstvo predstavlja kao značajan čimbenik gospodarstva čije je propadanje nedopustivo te su vlade spremne poduzeti razne mjere za sprječavanje propadanja jedne ili više banaka radi sprječavanja gospodarske krize bez obzira na to što je riječ o institucijama koje su uglavnom u privatnom vlasništvu (Bergseth, 2017).

Kada je ekonomska politika relativno neizvjesna, menadžerima banaka je lakše iskriviti financijske informacije, jer nepredvidive promjene ekonomske politike otežavaju procjenu

stvarnog stanja i učinke skrivenih „negativnih vijesti“ za investitore i vjerovnike. Neizvjesnost ekonomske politike također povećava fluktuaciju zarada i novčanih tokova banaka, pružajući tako dodatne poticaje i mogućnosti menadžerima banaka da upravljaju zaradom (Jin et al., 2019). Akerlof i Romer (1993) vrlo su slikovito opisali situaciju moralnog hazarda menadžmenta banke. Analizirali su situaciju u banci u kojoj je došlo do značajnih financijskih problema, ne ulazeći u detalje uzroka problema. U trenutku spoznaje o nastanku štete i iznosu gubitka kojem je banka izložena, menadžment banke odlučio je negativan događaj „prekriti“ unutar banke na što dulje razdoblje kako bi za to vrijeme pokušali pronaći rješenje i spriječiti propast banke. U želji da ostvare što veći profit kojim bi se prekrio nastali gubitak, menadžment je preuzimao visokorizične poslove. Odobravanjem sredstava klijentima s lošim bonitetom za kratko vrijeme povećali su bilancu banke i prividno djelovali na rast vrijednosti banke. Dionice banke kratkoročno su imale veću vrijednost, a menadžment je, svjestan stvarnog stanja, prodavao vlastite udjele na tržištu dok su oni još uvijek imali vrijednost i time osigurali osobnu korist. Onoga trenutka kada je štetni događaj postao javan, odnosno u trenutku kada je banka doživjela financijski slom, zbog straha od nastanka panike među štedišama drugih banaka, država preuzima trošak zaštite nad imovinom štediša i sanira nastalu štetu. Postavlja se pitanje gdje je tu odgovornost menadžmenta.

Danas se u modernim teorijama sve više govori o „slobodnom bankarstvu“. Pojam slobodno bankarstvo u 21. stoljeću podrazumijeva poslovanje privatnih banaka bez potrebe za regulacijom središnjih banaka u razvijenom i konkurentom tržištu, pod pretpostavkom da je zdravo okruženje i razvijeno tržište samo po sebi dovoljan regulator. U odsutnosti državne sigurnosti, pretpostavka je da će privatne banke samostalno poduzeti mjere za minimiziranje rizika poslovanja uvođenjem i primjenom vlastitih kontrola i pravila. Pod utjecajem modernih teorija vezanih uz poslovanje banaka, Novi Zeland je 1990. godine uveo i predstavio sustav slobodnog bankarstva. Ukinuto je osiguranje depozita od države, a bankama je nametnuta obveza javnog i redovnog objavljivanja financijskih izvještaja (Turner, 2000). S obzirom na to da su banke koje posluju u Novom Zelandu uglavnom podružnice velikih bankarskih konzorcija iz inozemstva te da je njihovo poslovanje regulirano i pod kontrolom matičnih banaka koje su pak pod kontrolom središnje banke u zemlji u kojoj imaju sjedište, kritičari Hickson i Turner (2003) smatraju da ovaj model ne predstavlja pravo značenje pojma slobodno bankarstvo. Rezervna banka Novog Zelanda je ipak 2003. godine objavila akt kojim se uvodi kontrola poslovanja nad bankama, među ostalim i provjera kvalitete i educiranosti menadžmenta banke. U skladu s navedenim aktom, svaki potencijalni investitor, ako iskaže

interes za suvlasništvom banke u iznosu većem od 10 % kapitala banke, mora dobiti suglasnost od rezervne banke Novog Zelanda. Ekonomski teoretičari Friedman i Schwartz (1986) razmatraju ideju slobodnog bankarstva. Smatrali su da će se slobodnim bankarstvom eliminirati zakonske obvezne pričuve, a time i probleme „institucionalne nestabilnosti“ i „gumenog“ multiplikatora novca stvorenog za inovacije. Schuler (1992) u istraživanje slobodnog bankarstva uključuje studije slučaja iz Škotske, SAD-a, Kanade, Švedske, Švicarske i Čilea. Budući da nijedan od šest sustava koje je ispitao nije uživao potpunu slobodu od zakonskih ograničenja, smatra da je „lagano regulirano bankarstvo“ učinkovitija mjera od „potpuno slobodnog bankarstva“.

Prema Van Greuning i Bratanović (2020), da bi kontrola banaka koje djeluju internacionalno (u više zemalja) bila učinkovita, potrebno je uskladiti kontrole na globalnoj razini. Prije svega potrebno je upoznati i educirati bankarske menadžere i regulatore sa svim potencijalnim rizicima koje nosi poslovanje banaka na globalnom internacionalnom tržištu. Drugi problem je uvođenje jedinstvenih kontrola podružnica. Osnovni problem je kako provesti kontrolu podružnice internacionalne banke te podliježe li podružnica strane banke kontroli zemlje u kojoj je matična banka ili zemlje u kojoj podružnica posluje. Zbog straha od propasti i potencijalnih posljedica koje mogu nastati bankrotom internacionalne podružnice u matičnoj zemlji, domaći regulatori zahtijevaju od podružnica primjenu pravila zemlje u kojoj posluju kako bi imali kontrolu nad podružnicama te time izbjegli potencijalne rizike. S druge strane, matična banka podružnice ima problem s praćenjem regulatornih smjernica za svaku podružnicu zasebno uključujući i zahtjeve različitih zemalja u kojima podružnice djeluju. Stoga se adekvatna kontrola može provoditi jedino ako su uspostavljena usklađena internacionalna pravila na globalnoj razini. Zbog toga su 1988. godine izdane prve smjernice, poznatije kao Bazelski sporazum, koje bankama u savezu propisuju obvezu uspostave i primjene kontrole rada i procesa. Primjenu smjernica preuzele su i druge zemlje bez obzira na to što nisu bile obveznice primjene.

4.4.1. Primjena Bazelskih sporazuma u svrhu kontrole rizika banke

Kada su dvije internacionalne banke 1974. godine objavile stečaj (Bankhause Herstatt i Franklin National Bank) središnje banke zemalja G-10 (Belgija, Kanada, Francuska, Njemačka, Italija, Japan, Nizozemska, Švedska, Ujedinjeno Kraljevstvo i SAD), uključujući Luksemburg i Švicarsku, prepoznale su potrebu za uspostavom kontrole nad bankarskim poslovanjem. Osnovan je središnji ured u Banci za međunarodna poravnanja sa sjedištem u Baselu te je uspostavljen odbor koji je imao obvezu sastajanja svaka tri mjeseca kako bi analizirao provedbu i primjenu smjernica u zemljama obveznicama. Osnovna uloga Bazelskog odbora je rasprava o regulatornim problemima vezanim uz poslovanje internacionalnih banaka zemalja članica. Osnovni cilj je uspostava adekvatnih mjera za praćenje poslovnih procesa u bankama radi sprječavanja provođenja poslovnih transakcija koje mogu dovesti do propadanja banaka i stvaranja neravnoteže na tržištu što dovodi do globalne krize (Chiuri et al., 2002). Budući da aktivnosti banaka nisu ograničene na područje pojedinačnih država, potrebna je međunarodna koordinacija pojedinačnih regulativa. Usporedo s lokalnim (nacionalnim) pravilima te kontinentalnim (europskim), banke u svijetu najčešće poštuju i Baselske sporazume. To su preporuke regulative banaka koje priprema i izdaje Baselsko povjerenstvo za superviziju banaka (Basel Committee on Banking Supervision – BCBS) pri Banci za međunarodna poravnanja (Bank International Settlements – BIS) u Baselu (Švicarska) (Sajte, 2017).

Prema Sbârcea (2014), tri najvažnija dokumenta koje je izdao Bazelski odbor i koji su u osnovi koordiniranih međunarodnih aktivnosti su Basel I (1988), Basel II (2004) i Basel III (2010). Ovi ugovori definiraju glavne ciljeve kapitala banke, mjeru stupnja rizika povezanog s imovinom banaka, pravila koja se odnose na minimalni kapital koji mora posjedovati kreditna institucija u svrhu pokrivanja rizika kao i mjere za analizu i nadzor tržišne discipline.

Prvi Bazelski sporazum propisuje mjere zaštite kapitala banaka no kako su bankarski poslovi postajali kompleksniji, javila se potreba za dodatnim mjerama za kontrolu rizika koje su propisane sporazumom Basel II, a kasnije i Baselom III te Baselom IV. Basel IV standardi su promjene globalnih zahtjeva bankarskoga kapitala koje su dogovorene 2017. godine, a trebaju se provesti u siječnju 2023. Regulatori smatraju da je Basel IV samo dopuna reforme Basela

III. Bazelski odbor (BCBS) sam ih naziva jednostavno „finaliziranim reformama“ postojećeg Basela III pa ga se u literaturi može pronaći i pod nazivom Basel III.I.

Prvi Bazelski sporazum (Basel I) sklopljen je 1988. godine. Sporazumom su definirane odgovornosti za provođenje nadzora nad podružnicama matičnih banaka u stranim zemljama pa je tako definirano (Heffernan, 2006):

- Nadzor nad likvidnošću podružnice strane banke provodi središnja banka u zemlji u kojoj podružnica djeluje.
- Nadzor nad solventnošću podružnice strane banke provodi središnja banka u zemlji u kojoj podružnica djeluje.
- Nadzor nad likvidnošću strane podružnice provodi središnja banka u zemlji u kojoj djeluje matična banka.

Uvedena je obveza za izradom konsolidiranih izvještaja kako bi Odbor raspolagao s transparentnim podacima i aktivnostima svih internacionalnih banaka bez obzira na to u kojoj zemlji ona djeluje.

Bazelski sporazum iz 1988. godine (Basel I) usredotočio se na uspostavu i provedbu adekvatnih kontrola nad internacionalnim bankarskim transakcijama. Ključno je bilo uspostaviti i unaprijediti internacionalnu financijsku stabilnost, odnosno urediti mehanizme praćenja i kontrole kako bi se umanjili potencijalni financijski rizici. Bazelskim sporazumom o kapitalu definiran je način izračuna jamstvenoga kapitala i ponderirane aktive koji je imao pozitivan učinak na visinu kapitala banaka (Van Roy, 2005). Prema Sajter (2017), Basel I bio je fokusiran na kreditni rizik i razvio je sustav klasifikacije imovine banke na pet kategorija, u skladu s visinom kreditnog rizika. Svaka kategorija imala je pripadajući ponder kojim se trebao opteretiti iznos kapitala. Nakon što se rizici kvantificiraju, potrebno je izračunati kapital koji je potrebno izdvojiti kako bi banka pokrila eventualne gubitke po tim rizicima.

Basel I zahtijevao je od svih internacionalnih banaka primjenu jedinstvene definicije jamstvenoga kapitala te uspostavu okvira u kojem jamstveni kapital treba pokrivati 8 % rizika (Balin, 2006).

$$\text{Omjer imovine i rizika} = \frac{Kapital\ (osnovni\ kapital\ i\ dopunski\ kapital)}{Imovina\ (po\ tipu\ kredita) + Kreditno\ rizični\ ekvivalenti}$$

- Osnovni kapital (engl. *Tier 1*) smatra se kapitalom za trajnost poslovanja.
  Kapital za trajnost poslovanja omogućuje banci da nastavi sa svojim aktivnostima i osigurava joj solventnost. Najviša razina kvalitete osnovnoga kapitala naziva se **redovni osnovni kapital**.
- Dopunski kapital (engl. *Tier 2*) smatra se kapitalom koji se koristi u slučaju propasti kreditne institucije. Kapital koji se koristi u slučaju propasti kreditne institucije, odnosno ako banka postane insolventna, iz dopunskoga kapitala isplaćuju se deponenti i vjerovnici višega isplatnog reda (Basel III definition of capital, July 2011).

Bazelskim sporazumom definiran je i propisan iznos jamstvenoga kapitala. Jamstveni kapital mora iznositi najmanje 8 % ukupnog iznosa aktive i aktivnih izvanbilančnih stavki banke. Najmanje polovica jamstvenoga kapitala mora biti *osnovni kapital* koji služi kao osiguranje u slučaju nepredviđenih situacija u banci. S vremenom je Basel I pokazao nedostatke, odnosno propisane mjere nisu bile dovoljne za sprječavanje rizika, stoga je 2004. godine uspostavljen novi sporazum.

Godine 2004. sporazumom u Bruxellesu uspostavljen je novi sporazum pod nazivom Basel II.[8] Osnovna uloga smjernica Basela II je sveobuhvatniji pristup mjerama za kontrolu rizika novih i kompleksnijih financijskih proizvoda uz zadržavanje osnovnog cilja: promocija sigurnosti i stabilnosti bankarskog sustava uz poboljšanje i poticanje konkurentnosti između banaka. Baselom II rejting je postao temelj za određivanje kapitalnih zahtjeva, čime su na značaju dobile procjene rejting agencije (Sajter, 2017). Najznačajniji aspekt Basela II je izrada i upotreba internih aplikacija za praćenje rizika u svrhu prezentiranja podataka za izračun adekvatnosti kapitala. Sporazum je zahtijevao unaprjeđenje alata za mjerenje rizika sofisticiranijim pristupom rizicima.

[8] Basel II ili Revised Framework on International Convergence of Capital Measurement and Capital Standards.

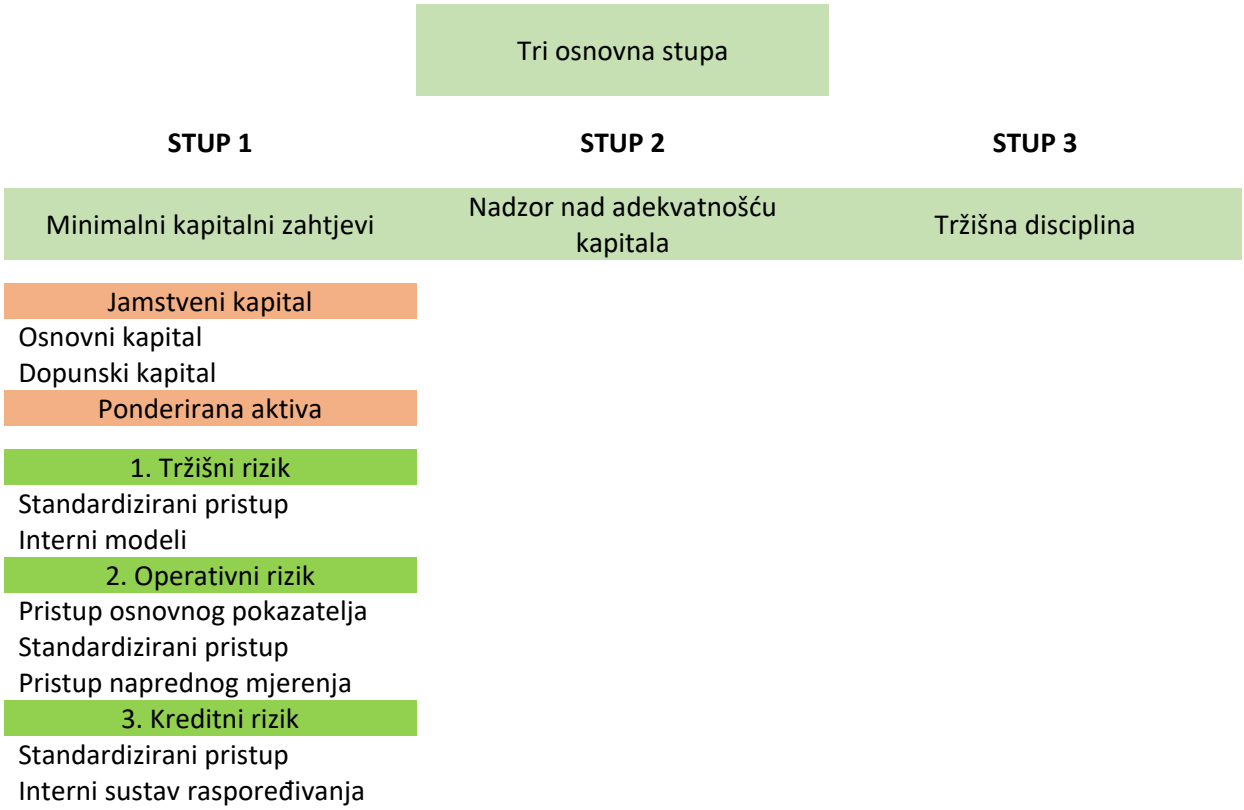
Karakteristika Basela II je njegova struktura koja se temelji na tri osnovna stupa (prilagođeno prema Balin, 2006):

1. *Ključni minimalni kapitalni zahtjevi (Stup 1)*: definira pravila za izračunavanje kreditnog i operativnog rizika; ustanovljeno je da se načini prezentiranja rezultata poslovanja kao i podaci o izloženosti rizicima između banaka dosta razlikuju, stoga dotadašnje mjerenja rizika nije davalo odgovarajuće rezultate za sve banke. Prvi „stup" pokazuje najveću ekspanziju od Basela I. Kao odgovor na kritike Basela I, Basel II predstavlja osjetljivije mjerenje rizične aktive banke i pokušava ukloniti nedostatke Basela I koji bankama dopuštaju da preuzmu dodatni rizik dok kozmetički umanjuju minimalne zahtjeve za adekvatnošću kapitala. Njegov prvi zadatak je proširiti opseg propisa tako da uključuje i imovinu holding društva međunarodno aktivne banke. To je učinjeno kako bi se izbjegao rizik da će banka „sakriti" preuzimanje rizika prenošenjem svoje imovine na druge podružnice te radi uvrštavanja financijskog zdravlja cijelog poduzeća u izračun kapitalnih zahtjeva za podružnicu.

2. *Nadzor nad adekvatnošću kapitala (Stup 2)*: banka treba voditi računa o izloženostima svim rizicima i u skladu s tim osigurati adekvatne kapitalne zahtjeve. Uloga supervizora je ovdje posebno naglašena. Stup 2 ponajprije se bavi interakcijom regulator – banka, proširujući prava regulatora u nadzoru i raspuštanju banaka. Regulatori imaju ovlast nadgledati interne režime procjene rizika predložene u Stupu 1 i mijenjati ih na jednostavnije, konzervativnije pristupe temeljene na sustavima kada smatraju da banka nije u stanju samostalno upravljati svojim kreditnim, tržišnim i operativnim rizicima.

3. *Tržišna disciplina (Stup 3):* služi kao podrška Stupu 1. Primjena najnaprednijih pristupa u mjerenju kreditnog i operativnog rizika nosi obvezu objavljivanja dodatnih informacija prema Stupu 3. Veća transparentnost poslovanja banaka trebala bi pridonijeti većoj otpornosti financijskog sustava na šokove te time pozitivno djelovati na njegovu stabilnost, što je svakako bio jedan od ciljeva Basela II. Stup 3 nastoji povećati tržišnu disciplinu u bankarskom sustavu zemlje. Preporučuje se objavljivanje podataka o kapitalu banke i pozicija preuzimanja rizika koje su nekad bile dostupne samo regulatorima za objavljivanje široj javnosti Sporazumom Basel II.

Slika 6. Tri osnovna stupa u skladu s Baselom II

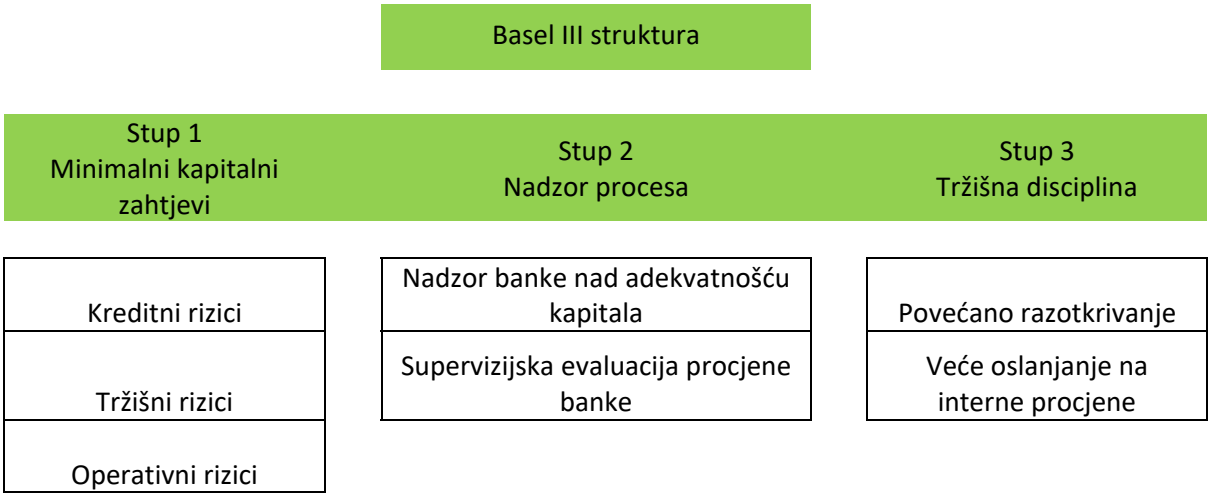


Izvor: Izrada autora prema Van Greuning i Bratanović, 2020.

Globalna financijska kriza 2007. godine koja je zahvatila gotovo cijeli svijet postavila je temelje za uspostavu novog sporazuma. Basel III objavljen je 2011. godine s primjenom od siječnja 2013. Minimalna stopa adekvatnosti kapitala (8 %) te način i visina izračuna kapitalnih zahtjeva ostala je ista kao za vrijeme Basela II. Basel III implementiran je i u propise i praksu Europske unije.

Uz postojeće kapitalne zahtjeve propisane u sklopu Basela I i Basela II, Basel III sadrži dva dodatna stupa: poboljšani postupak nadzorne revizije (Stup 2) i učinkovito korištenje tržišne discipline (Stup 3).

Slika 7. Konceptualni okvir primjene Basela III



Izvor: Van Greuning i Bratanović, 2020. *Analyzing banking risk*, fourth edition, str. 131

Prema Birovu (2011), Basel III definira minimalne standarde upravljanja likvidnošću kroz sljedeća dva indikatora:

1. *koeficijent pokrića likvidnosti* (engl. *liquidity coverage ratio – LCR*) koji uspostavlja standard upravljanja kratkoročnom likvidnošću:

$$LCR = \frac{visoko\ likvidna\ imovina}{potrebni\ stabilni\ izvori} \geq 1$$

2. *pokriće neto stabilnih izvora financiranja* (engl. *net stable funding ratio – NSFR*) koji uspostavlja novi standard upravljanja strukturnom, odnosno dugoročnom likvidnošću:

$$NFRS = \frac{visoko\ likvidna\ imovina}{neto\ odljevi\ novca\ u\ 30\ dana} \geq 1$$

Stabilni izvori (kapital, dugoročni krediti, depoziti) moraju biti veći od potrebnih stabilnih izvora koji se procjenjuju na temelju ročnosti i kvalitete danih kredita.

Nije održiva ni dopuštena situacija u kojoj bi banke kratkoročne izvore sredstava koristile za financiranje dugoročnih investicija (poput stambenih kredita) (Birov, 2011).

Prema Slovik i Cournède (2011), svrha Basela III ogleda se u:

- povećanju kvalitete regulacijskoga kapitala u kojemu se dionički kapital povećava s 2 na 4,5 %
- uvodi se zaštitni sloj kapitala čija kvaliteta mora biti jednaka osnovnom kapitalu 2,5 %; zaštitni sloj kapitala služit će kao sigurnost osnovnoga kapitala u vrijeme financijskih kriza
- zaštitni sloj kapitala od 2,5 % povećava ukupni dionički kapital na 7 %
- ukupni kapital uvećan za zaštitni sloj kapitala povećava se s 8 % na 10,5 %
- ako dođe do narušavanja zaštitnog sloja kapitala, banke nemaju pravo isplaćivati dividende i bonuse (Galijašević i Vujnović-Gligorić, 2012); banke čiji kapital je u „tampon zoni“ između 4,5 i 7 % suočit će se s ograničenjima u vezi s isplatom dividendi i bonusa zaposlenicima.

Nakon razdoblja ekspanzije kreditne aktivnosti, gubici u bankarskom sustavu mogu biti iznimno visoki i imati značajne negativne učinke. Pretjerani gubici mogu destabilizirati bankarski sustav te dovesti do značajnog pada poslovanja financijskog sustava. Takvi negativni događaji ukazali su na potrebu uvođenja sloja zaštitnoga kapitala kao dodatnu zaštitu od negativnih događaja.

Basel III značajna je prekretnica u razvoju ujednačenih kapitalnih zahtjeva. Konkretno, naglasak Basela III je na kvaliteti i količini temeljnoga kapitala – s glavnim ciljem jačanja bankarskoga kapitala na globalnoj osnovi. Nadalje, pokušavajući ispraviti nedostatke Basela I i II, osmišljen je režim koji uključuje zahtjeve za likvidnošću kao i niz makrobonitetnih alata usmjeren na smanjenje sistemskog rizika (King i Tarbert, 2011).

Prema Varotto (2011), usklađena s Basel standardima *adekvatnost kapitala* mora biti u skladu s izloženosti banke rizicima. Adekvatnost kapitala je osnova Basela I, a sadržana je i kao dio osnovnoga kapitala u smjernicama Basela II. Izračun adekvatnosti kapitala determiniran je s četiri rizične komponente: kreditnim rizikom, kreditnim rizikom druge ugovorne strane, tržišnim rizikom i operativnim rizikom.

U fokusu izračuna adekvatnosti kapitala je *izloženost banke kreditnom riziku* koji s rizikom zemlje i rizikom druge ugovorne strane čini najveću izloženost banke.
Prema Penikas (2015), u smjernicama Basela I sadržane su jednostavne smjernice za izračun kreditnih rizika temeljene na vjerojatnostima za nastanak negativnog događaja za različite kategorije imovine banke. U izračun su uključene i izvanbilančne izloženosti banke. Razvojem kompleksnijih kreditnih proizvoda te razvojem financijskog tržišta, Basel II, a kasnije i Basel III propisuju puno kompleksnije izračune kreditne rizičnosti uključujući i primjenu modela internog rejtinga (IRB).

Prema Baselu III, omjer likvidnosti banke trebao bi održavati dovoljnu likvidnost da izdrži sve vrste događaja s kojima se banka može suočiti. Prema Prgi et al. (2019), kontinuirana procjena rizika likvidnosti i pozicija likvidnosti važan je pokazatelj koji će osigurati pravilno funkcioniranje banke. Stoga bi banke trebale održavati optimalnu razinu likvidnosti koja može maksimizirati njihovu dobit i omogućiti im da se zadovolje njihove obveze. Likvidnost banke je proces nesmetanog pretvaranja novčanih sredstava u kreditne i nekreditne plasmane, odnosno pretvaranje potraživanja banke po svim osnovama (glavnica, kamata, naknada) i u svim oblicima (kredit, vrijednosni papir) u novčana sredstva planiranom dinamikom (Šverko, 2007). Likvidna imovina je ona imovina u koju se može brzo pretvoriti gotovina ako postoji zahtjev za podmirivanjem financijskih obveza. U slučaju kada banka ne može na vrijeme i na zahtjev deponenta podmiriti svoje tekuće obveze, kaže se da banka ima problem s likvidnosti. Potencijalni gubici u financijskom sustavu ograničavaju bankama ponude kredita što dovodi do povećanja kamatnih stopa. Porast kamatnih stopa može negativno utjecati na likvidnost zajmoprimatelja što dovodi do pogoršanja u otplati kredita, odnosno javlja se kreditni i kamatni rizik. Ako štediše odluče povući svoje depozite, pojavit će se problem s likvidnosti (rizik likvidnosti).

Panika nastala zbog nedostatka likvidnosti u bankama se može vrlo brzo proširiti i na cijeli sustav što dovodi do pojave sistemskog rizika. Bankovni sustav je vrlo kompleksan financijski sustav koji može utjecati na gospodarstvo neke zemlje. Stoga je važno zadržati povjerenje u financijski sustav, sustav banaka te razviti modele za održavanje njegove stabilnosti. Rizik likvidnosti je, s kreditnim rizikom i rizikom promjene kamatne stope, osnovni oblik rizika u bankama – tj. onaj koji postoji i kod najjednostavnijih banaka (Prga et al., 2009).

Prema HUB-u na smanjenje dobiti banaka mogu utjecati: smanjenje troškovne efikasnosti, pad neto kamatnih prihoda, pad neto nekamatnih prihoda i povećanje rezerviranja (pad kvalitete plasmana). Prema Van Greuning i Bratanović (2020), većina banaka za izračun kreditnog rizika primjenjuje model standardnog pristupa izračunu kreditnog rizika. Standardni pristup izračunu kreditnog rizika podrazumijeva korištenje vanjskih agencija (rejting agencija) ili revizorskih kuća za izračun kreditnog rizika. Vanjske agencije i revizorske kuće se objektivne, nezavisne, transparentne, kredibilne institucije kojima je omogućen direktan pristup svim podacima banke potrebnim za objektivan izračun izloženosti banke kreditnom riziku. Središnja banka zadužena je za provjeru kredibilnosti vanjskih agencija u zemlji u kojoj ona djeluje. S vremenom se ni vanjske agencije nisu pokazale kao siguran alat za izračun kreditnih rizika banke. Često se metode i pristupi vanjskih agencija za izračun kreditnih rizika razlikuju od metoda i modela koje primjenjuju banke te može doći do različitih rezultata. Ako rezultati nisu u korist banke, menadžment banke može vršiti pritisak na vanjske agencije, tim više jer upravo banke plaćaju usluge vanjskih agencija.

U nekim zemljama ne postoje nezavisne kreditne agencije. Stoga se metode standardnog pristupa za izračun kreditne izloženosti u tim zemljama ne mogu primijeniti.

S druge strane, metoda standardnog pristupa omogućuje bankama primjenu tehnika za ublažavanje prikaza izloženosti banke kreditnim rizicima uključujući vrijednosti osiguranja u vidu kolaterala i jamstava kao osnovu za smanjenje izloženosti banke kreditnom riziku.

Kako bi se ispravili nedostaci Basela II, Basel III propisuje dodatne mjere za izračun izloženosti banke riziku (King i Tarbert, 2011):

1. Poticanje banaka na razvoj i primjenu metoda za izračun izloženosti kreditnom riziku koje se neće zasnivati isključivo na rejtingu vanjskih agencija.
2. Veća sistematizacija portfelja banke po tipu izloženosti (vrsta kreditne linije, vrijeme otplate, na osigurane/neosigurane proizvode i sl.).
3. Razvoj i primjena sofisticiranih modela za izračun kreditne izloženosti malog i srednjeg poduzetništva i pravnih osoba.
4. Uključivanje izvanbilančnih izloženosti u izračun kreditne izloženosti: za izračun kreditnog rizika izvanbilančnih izloženosti u obvezi je primjena konverzijskog faktora kojim se izvanbilančna izloženost tretira kao kreditna bilančna izloženost banke.

Slika 8. Basel III: Metode primjene u svrhu izračuna kapitala kreditnog rizika

Basel III: Metode primjene u svrhu izračuna kapitala kreditnog rizika		
Standardni pristup u izračun su uključene vanjske agencije	**Osnovni pristup** zasnovan na primjeni internih metoda	**Napredni pristup** primjena internih naprednih metoda

Izvor: Van Greuning i Bratanović, 2020. *Analyzing banking risk*, fourth edition

Metoda internog rejtinga u odnosu na pristup (Van Greuning i Bratanović, 2020):

Metoda internog rejtinga (IRB) – bazični pristup temelji se na izračunu izloženosti kreditnom riziku svrstanim unutar različitih klasa imovine ovisno o tipu proizvoda. Svaka klasa nosi svoj koeficijent rizičnosti. U izračun su uključeni sljedeći parametri: vjerojatnosti neispunjenja obveza (*PD*), gubitak u slučaju neplaćanja (*LGD*) izražen kao postotak izloženosti banke i izloženost u slučaju neplaćanja (*EAD*).

Za svaku klasu imovine uz osnovni *IRB* može se primijeniti i napredni izračun *IRB*-a.

Metoda internog rejtinga (IRB) – napredni pristup temelji se na izračunima *PD*-a, *LGD*-a i *EAD*-a. To su sofisticirani parametri koji se primjenjuju u razvijenim alatima za modeliranje kreditnih rizika.

Prije primjene metoda internog rejtinga, banka mora dobiti dopuštenje središnje banke koja provodi testiranje, provjeru i analizu objektivnosti te adekvatnosti primjene metode *IRB*-a.

U izračun adekvatnosti kapitala potrebno je uključiti i **izloženost banke tržišnom riziku**.
Banka je dužna u sklopu zaštite od tržišnog rizika provoditi upravljanje, mjerenje i ograničavanje rizika koji proizlaze iz kretanja na tržištu, kao i nadzor nad izloženostima druge ugovorne strane te kontrolu likvidnosti (Odluka o upravljanju rizicima, HNB, 2016).

U tržišne rizike spadaju (Šverko i Prga, 2005):

- Izloženost *valutnom riziku* ili *otvorena valutna pozicija* predstavlja razliku između bilančnih i izvanbilančnih stavki imovine i obveza izraženih u stranoj valuti ili vezanih za stranu valutu. Otvorena pozicija može biti duga ili kratka ovisno o tome je li veća izloženost valutnom riziku na strani imovine (duga pozicija) ili obveza (kratka pozicija). Može nastati fluktuacijom tržišnih deviznih tečajeva i njihovih međusobnih omjera.
- *Rizik likvidnosti* „derivirani" je oblik rizičnosti i posljedica je izloženosti drugim rizicima zbog čega ga banke često marginaliziraju.
- *Kamatni rizik* je rizik učinka promjene tržišne kamatne stope na financijski rezultat iz pozicija izloženih kamatnom riziku.
- *Rizik promjene cijena vrijednosnica* je potencijalni utjecaj promjene cijena vrijednosnica u trgovačkim portfeljima banaka na profitabilnost poslovanja banke. Ovaj rizik najčešće se mjeri metodom svođenja na tržišnu vrijednost. Osnovna ideja je izračunati ili aproksimirati tržišnu vrijednost svake vrijednosnice u portfelju te ih zatim agregirati u tržišnu vrijednost ukupnog portfelja. Nakon toga se prate dnevne promjene tržišne vrijednosti portfelja iz čega se mogu izračunati pripadajuće rizične vrijednosti (*VaR*).
- *Vrijednost izložena riziku (VaR)* predstavlja maksimalni iznos koji portfelj, prema odabranom modelu izračuna i uz određenu razinu vjerojatnosti, može izgubiti od svoje vrijednosti tijekom određenog razdoblja, uz pretpostavku normalnih tržišnih uvjeta.

Prema Van Greuning i Bratanović (2020), za izračun izloženosti tržišnom riziku bankama je prepuštena odluka o modelu za izračun. Stoga mogu primjenjivati metodu standardnog pristupa izračunu putem vanjskih agencija kao i model internog izračuna. Obje metode podrazumijevaju izračun stvarnog troška kapitala koji mora biti usklađen sa zahtjevima o adekvatnosti kapitala na nacionalnoj razini. Od banaka se očekuje da upravljaju tržišnim rizikom na dnevnoj razini uključujući i sve izloženosti koje se očekuju sa sljedećim danom.

Središnje komponente za praćenje tržišnih rizika su RAROC mjera vrijednosti raspodjele kapitala (engl. *Risk-Adjusted Return On Capital*) i VaR. RAROC riziku prilagođen povrat na kapital kriterij je utvrđivanja cijene kredita prema kojem banka postavlja rok kredita tako da se postigne određena stopa povrata na regulatorni kapital koji zahtijeva Baselska uredba. Neke banke izračunavaju iznos regulatornoga kapitala za svaki kredit zasebno prema

standardiziranom pristupu, a druge na temelju internog rejtinga (IRB banke) (Zhang et al., 2021). Nakon krize 2008. godine Bazelski komitet prepoznao je potrebu za unaprjeđenjem metoda i modela za praćenje tržišnih rizika te potrebu za unaprjeđenjem modela rizične vrijednosti (engl. *Value at risk* – VaR model), koji se primjenjivao kao osnovni model za izračun tržišnog rizika.

Prema Sajter (2017), temeljni je cilj VaR modela procjene kreditnih rizika odgovoriti na pitanje koliki je očekivani gubitak vrijednosti kredita ako razvoj događaja bude nepovoljan. Odgovor se temelji na kreditnom rejtingu dužnika; vjerojatnosti pada kreditnog rejtinga; procjeni iznosa gubitaka te vjerojatnost promjene razlike između kamatnih stopa na rizičnije i manje rizične kredite.

RAROC se koristi kao mjera za praćenje rizika između različitih odjela banke, ali isto tako služi kao mjera uspješnosti, dok se VaR koristi kao brojčani pokazatelj izloženosti banke tržišnom riziku. Danas su gotovo sve velike banke i financijski posrednici razvili modele RAROC (Risk Adjusted Return On Capital) za procjenu profitabilnosti različitih djelatnosti, uključujući i njihovo kreditiranje (Chłopek, 2013). Prva primjena RAROC-a bila je sedamdesetih godina prošlog stoljeća. RAROC je bankarima služio kao osnovni pokazatelj mjerenja rizika kreditnog portfelja koji je imao ulogu usmjeravanja i informiranja menadžmenta banke o rizičnoj poziciji banke i profitabilnosti banke (Zhang, Yang i Huang, 2021).

Dobit svih poslovnih linija može se uskladiti za rizik (RAROC) tako da se očekivani gubici odbiju od dobiti zajedno s drugim troškovima. Kapital se može uskladiti za rizik (RORAC) tako da mu se maksimalni gubici temelje na budućim prinosima ili na iznosu nužnom za pokriće dobiti (Pavković, 2004).

Prema Chłopek (2013), RAROC se definira kao:

$$\text{RAROC} = \frac{riziku\ prilagođena\ dobit}{kapital}$$

Prilagođeni prihod = prihodi – rashodi – očekivani gubici + povrat ekonomskoga kapitala +/– prijenosne vrijednosti/cijene.

Rizični kapital = kapital rezerviran za pokriće gubitka u najgorem slučaju (minus očekivani gubitak) do potrebnog praga povjerenja (npr. 95 %) za kreditne, tržišne i druge rizike.

RORAC se definira kao (Perez, 2020):

$$\text{RORAC} = \frac{neto\ dobit}{riziku\ prilagođen\ kapital}$$

Kretanje pokazatelja RAROC i RORAC važne su za donošenje poslovnih odluka i praćenje u kretanju trendova. Value at risk (VaR) je model koji služi za izračun tržišnog rizika banke i ima drugačiju ulogu od RAROC-a. Prvi VaR model razvili su JP Morgan Riskmetrics.
Osnovni potencijalni gubitak može se izračunati prema sljedećim odnosima (prilagođeno prema Heffernanu, 2005):

Rizična vrijednost (VaR) = (tržišna vrijednost pozicije) × (cjenovna osjetljivost)×(potencijalna promjena kamatnih stopa)
ili
Rizična vrijednost (VaR) = (tržišna vrijednost pozicije) × (cjenovna promjenjivost)

Nedostaci primjene VaR modela su (Heffernan, 2006):

- Banke ignoriraju sve potencijalne rizike ako vjerojatnost za njihovo pojavljivanje iznosi manje od 1 % očekivanja, a da pri tome nemaju informaciju koliko iznosi 1 % u apsolutnom iznosu, je li riječ o 2 mil. eura ili o 32 mil. eura, odnosno nije uspostavljena granica potencijalnoga gubitka.
- VaR model ne prikazuje vjerojatnost bankrota banke, već iznos gubitaka koji mogu nastati izloženošću banke tržišnom riziku.
- Nesposobnost za adekvatno praćenje rizika tržišne likvidnosti: osnovna pretpostavka modela je da banke imaju mogućnost praćenja te prodaje izloženosti iz knjige trgovanja deset dana bez utjecaja na tržišne cijene. No u razdobljima izvanrednih stresnih događaja, bankarski sustav rapidno gubi na likvidnosti (jer su sve banke izložene istom riziku) te se događa da u tako kratkom razdoblju banke ne mogu priskrbiti dovoljno likvidnih sredstava i zadržati svoju poziciju.

- Nemogućnost adekvatnog praćenja kreditnog rizika kroz knjigu trgovanja: praćenje izloženosti riziku kroz deset dana koje koristi VaR i stresni VaR je prekratko razdoblje za izračun potencijalnih gubitaka u trenutku pada kreditnog rejtinga vrijednosnice.

Sve donedavno interni modeli za izračun tržišnih rizika temeljili su se na dvjema komponentama ovisno o tome koja je komponenta bila viša:

- vrijednost VaR-a od prijašnjeg dana
- prosječna vrijednost VaR-a u posljednjih 60 dana.

Za analizu se uzima prosjek najvećih očekivanih gubitaka u razdoblju od deset dana. Za banke koje djeluju internacionalno, supervizijske kontrole u svim zemljama u kojima banka djeluje moraju surađivati u procesu odobravanja internih mjera za izračun rizičnosti u svrhu izračuna regulatornoga kapitala.

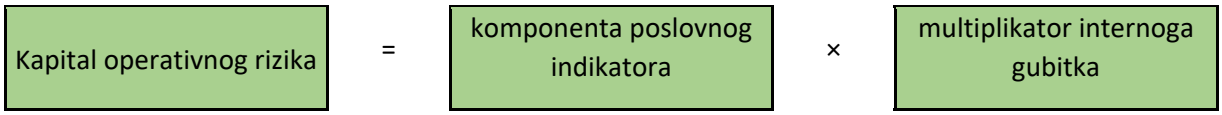
Banke imaju slobodu u kreiranju vlastitih internih modela, ali uz obvezu redovne, periodične provjere svakoga od modela, posebno u vrijeme strukturnih promjena uzrokovanih vanjskim ili unutarnjim čimbenicima.

Baselom III propisana je obveza praćenja i mjerenja *operativnih rizika*. Statistike o poslovanju banaka ukazuju na sve veći porast izloženosti banke operativnim rizicima zbog sve veće automatizacije procesa, primjene internetskog bankarstva, raznovrsnih sofisticiranih softvera za obradu podataka i sl. Zbog sve veće izloženosti banke operativnom riziku, Basel III prilikom izračuna visine internoga kapitala banke uključuje obvezu praćenja izloženosti banke operativnom riziku.

Basel III sporazum predlaže nametanje viših standarda za poboljšanje sposobnosti bankarskog sustava da apsorbira šokove iz ekonomskog i financijskog sustava (Sbârcea, 2014).

Reforme iz 2017. godine pojednostavljuju uspostavljene okvire za mjerenje rizika unutar Basela II te ga zamjenjuju Standardiziranim pristupom. Novi postavljeni okvir za mjerenje izloženosti riziku puno je osjetljiviji i zamjenjuje interne modele za mjerenje rizičnosti. Novi pristup pretpostavlja da operativni rizici rastu u skladu s rastom bruto dohotka banke te da banke koje su u prošlosti bile izložene visokom operativnom riziku imaju veće šanse za potencijalnu štetu.

Slika 9. Mjere izloženosti riziku



Izvor: Van Greuning i Bratanović, 2020. Analyzing banking risk, fourth edition.

Prema Van Greuning i Bratanović (2020), supervizijska kontrola provjere adekvatnosti kapitala dio je Stupa 2 u Bazelskom sporazumu. Glavna uloga supervizijske kontrole je:

1. Provjerava raspolaže li banka dovoljnom razinom adekvatnoga kapitala u skladu s njezinim poslovnim aktivnostima, a i okolinom u kojoj djeluje.
2. Da potakne banke na uspostavljanje politika, internih procesa i metoda za praćenje izloženosti banke rizicima u svrhu adekvatne procjene adekvatnosti kapitala.

Supervizijska kontrola (engl. *supervisory review evaluation process* – SREP) nalaže bankama uspostavu i provedbu postupka procjene adekvatnosti kapitala (ICAAP) tako da (EBA, 2016):[9]

a) menadžment banke osigura sve potrebne mjere za prikladno identificiranje, mjerenje i provedbu kontrole nad svim potencijalnim rizicima kojima je banka izložena
b) osigura dovoljnu pokrivenost kapitala za zaštitu banke od osnovnih i dodatnih rizika
c) uspostavi i razvije adekvatan odjel za upravljanje rizicima koji je neovisan o ostalim dijelovima banke.

Supervizijska uloga nije isključivo kontrolna već i savjetodavna. U situacijama kada se ustanovi da banka ne raspolaže dovoljnom pokrivenošću kapitala rizikom, a postoji visok rizik nastupa štetnog događaja, supervizija nalaže poduzimanje mjere za zaštitu i ispravak nedostataka.
U ICAAP-u su sadržani svi podaci o rizicima banke koji čine osnovu za donošenje menadžerskih odluka. Unutar ICAAP-a sadržane su: strategije i izloženosti riziku, procjene rizika, upravljanje rizikom, planiranje kapitala, provođenje stres testova i analize scenarija, definiranje potrebnog iznosa kapitala te uspostava plana oporavka u slučaju nastupa izvanrednih štetnih događaja (European Central bank, 2018).[10]

[9] EBA (2016). Guidelines on ICAAP and ILAAP information collected for SREP purposes.
[10] European Central bank, ECB Guide to the internal capital adequacy assessment process (ICAAP), str. 9.

Prema Europskoj središnjoj banci (engl. *European Central bank*) (2018), najobuhvatniji i najznačajniji test za procjenu stabilnosti banke je stres test. Pri planiranju i provođenju stres testova vrlo je važna objektivnost, primjena stvarnih i točnih podataka, primjena podataka koji su usporedivi i mjerljivi te podaci koji su lako i brzo dostupni. Rezultat provedbe stres testa trebao bi prikazati realnu i objektivnu osjetljivost banke prema riziku u različitim scenarijima te razina utjecaja svakog od scenarija na profitabilnost banke i kapital. Pri odabiru scenarija uzimaju se u obzir i makroekonomske promjene u zemlji u kojoj banka djeluje. Najčešće makroekonomske promjene su promjene pada BDP-a, rast stope nezaposlenosti, promjena cijena nekretnina na tržištu ili šokovi uzrokovani vanjskim ekonomskim promjenama.

Baselom III propisana je obveza praćenja i mjerenja *tržišne discipline.* Od banaka se zahtijeva mjerenje i praćenje tržišne discipline tako da pri procjeni adekvatnosti kapitala uključe podatke o tržišnoj disciplini (EBA, 2013).[11] Vrlo je važno da banka raspolaže provjerenim podacima te je pri izračunu izloženosti riziku potrebno ukalkulirati iznos potencijalne štete koja bi mogla nastati zbog netočne ili lažne informacije ili štete koja može nastati pri iznošenju povjerljivih podataka prema trećim osobama. Svaka financijska institucija treba imati uspostavljenu i razvijenu politiku zaštite podataka te uspostaviti mjere osiguranja za sprječavanje zlouporabe podataka.

Područja koja obuhvaća tržišna disciplina je struktura kapitala, adekvatnost kapitala te mjere i procjene izloženosti riziku. U mjerenje se uključuju kvantitativni i kvalitativni pokazatelji. Kvalitativnim mjerama obuhvaćene su strategije, politike, procesi struktura i organizacija, a kvantitativne su stvarne brojčane veličine (EBA, 2013).

Navedene mjere i analize provode se za procjenu adekvatnosti kapitala. Berger (1995) u svojem radu dokumentira pozitivnu vezu kapitala i zarade kod američkih banaka.

Menadžment banke zadužen je za procjenu i kontrolu adekvatnosti kapitala banke te mora imati: uspostavljene planske ciljeve/veličine adekvatnosti kapitala, adekvatne politike i procese za mjerenje, kontrolu i provođenje politika u svrhu procjene adekvatnosti kapitala, izrađene metode za procjenu i razvijene te uspostavljene interne kontrole adekvatnosti kapitala. Dužna je osigurati mjere za zadržavanje trenutačne visine adekvatnoga kapitala te provoditi kontrole

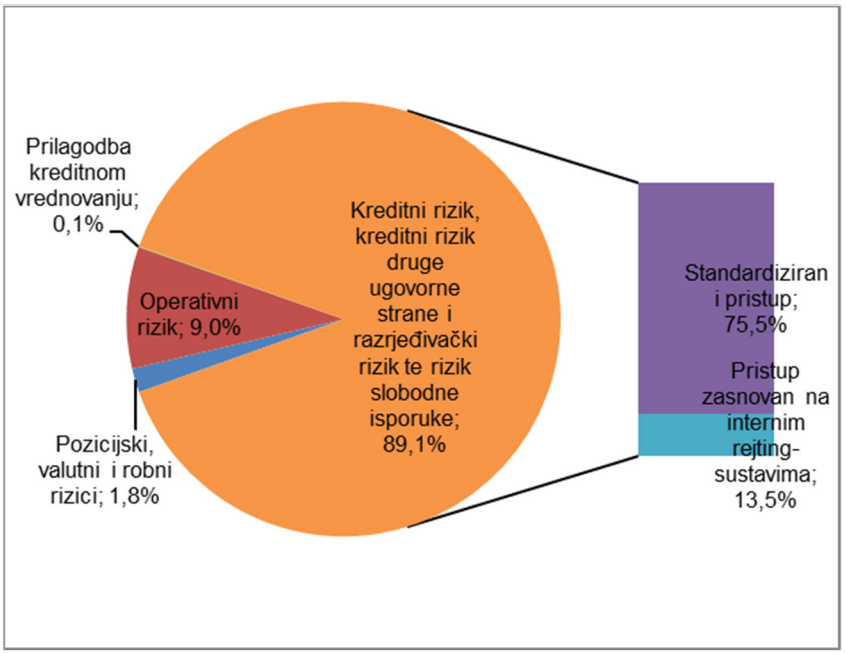
[11] EBA (2013). Capital Requirements Regulation (CRR).

radi procjene je li trenutačna visina adekvatnoga kapitala realna i objektivna, posebno ako se očekuju neke veće interne ili eksterne strukturne promjene.

Prema Europskoj središnjoj banci (2018), analiza adekvatnosti kapitala uključuje:

- analizu strukture kvalificiranoga kapitala
- analizu profila rizičnosti banke i izloženosti riziku
- procjenu trenutačne i buduće potrebe za kapitalom.

Slika 10. Struktura ukupne izloženosti banaka riziku na dan 30. lipnja 2019.



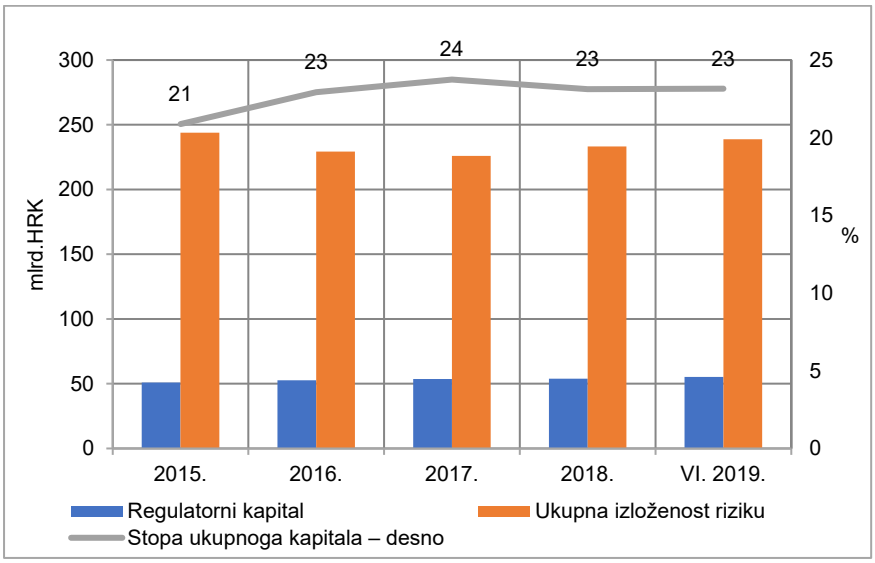
Izvor: HNB, 2020.

Prema HNB-u, ukupnu izloženost banaka riziku čine izloženosti: kreditnom riziku (uključujući kreditni rizik druge ugovorne strane, razrjeđivački rizik i rizik slobodne isporuke), riziku namire/isporuke, pozicijskom, valutnom i robnom riziku, operativnom riziku, riziku za prilagodbu kreditnom vrednovanju i riziku povezanom s velikim izloženostima koje proizlaze iz stavki u knjizi trgovanja.

Na slici 10. prikazana je struktura izloženosti rizicima hrvatskih banaka kao i mjere koje se primjenjuju u bankama za praćenje izloženosti rizicima. Najveći udio u ukupnoj izloženosti rizicima su rizici unutar kategorije kreditnih rizika s čak 89,1 %, slijede operativni rizici s 9 %, dok su valutni i robni rizici zastupljeni s 1,8 % unutar ukupne izloženosti rizicima. Zbog značajnosti udjela kreditnih i operativnih rizika u rizicima banaka, navedeni rizici su posebno

obrađeni u ovom doktorskom radu. Kao mjera za praćenje izloženosti riziku, u 75,5 % primjenjuje se standardizirani pristup mjerenju rizika, dok 13,5 % banaka primjenjuje metodu internog rejtinga odnosno pristup zasnovan na internim rejting sustavima.

Slika 11. Stopa ukupnoga kapitala banaka



Izvor: HNB, 2020.

Iz slike 11. može se pratiti vremensku dinamiku kretanja ukupnoga kapitala banaka u odnosu na ukupnu izloženost riziku. Podaci se odnose na banke koje posluju u Hrvatskoj u razdoblju od 2015. do kraja drugoga kvartala 2019. godine. U 2015. godini regulatorni kapital je iznosio 50 mlrd. HRK (najniža razina), dok je ukupni kapital te iste godine činio samo 20,09 % ukupne izloženosti riziku. S godinama ukupna izloženost riziku unutar banaka pada, dok stopa regulatornoga kapitala raste (2016. godine). Stopa ukupnoga kapitala je najveća u 2017. godini i iznosi 23,8 %. Nakon 2017. godine blago opada ovisno o ukupnoj izloženosti banaka rizicima, dok visina regulatornoga kapitala ostaje nepromijenjena od 2016. godine (51 %).

5. Empirijsko istraživanje međuodnosa bankarskih rizika i makroekonomskih kretanja

U analizi glavnih i pomoćnih hipoteza rada primijenjene su dvije temeljne skupine metoda istraživanja:

1. Za *izradu teorijske analize* u prvoj fazi istraživanja provedena je analiza dosadašnjih istraživanja drugih autora objavljenih u znanstvenim knjigama i znanstvenim člancima. Na temelju prikupljenih podataka iz sekundarnih izvora, prikupljeni su i izneseni teorijski podaci važnih autora te su prikazani u radu. Prikazan je pregled dosadašnjih istraživanja važnih za razumijevanje ključnih pojmova i dosadašnjih teorijskih spoznaja o predmetu istraživanja, dok su primarni podaci osigurali ostvarenje glavnog cilja disertacije. Dosadašnja istraživanja drugih autora prikazana u ovome radu bave se ispitivanjem poveznica financijskog sustava i ekonomske politike zemlje kao i poveznice makroekonomskog okruženja i stabilnosti banaka. S obzirom na to da su ekonomske politike, makroekonomske varijable i financijski sustav vrlo kompleksne domene istraživanja, u ovome su radu izdvojena istraživanja ekonomskih analitičara koja su podijeljena i svrstana u zasebne dijelove rada ovisno o temi koja se u radu obrađuje. Izdvojena su sljedeća empirijska istraživanja autora vezano uz:

- odnos financijskog sustava i gospodarskog rasta

Iz dosadašnjih analiza odnosa financijskog sustava i gospodarskog rasta u ovome su radu izdvojeni radovi autora Mankiw, Ball i Reis (2005), radovi autora Pejić Bach et al. (2009) te autora Albertazzi i Gambacorta (2009), Agnello i Sousa (2013), Messai et al. (2015), Bogdan i Stipković (2017) (ostali značajni radovi izdvojeni su i prikazani u tablici 2.). U nekim analiziranim radovima, primjerice McKinnon (2010) te Delić i Rogić-Dumančić (2016) smatra se da su gospodarski rast i financijski sustav u međusobnoj ovisnosti, dok Robinson (1965) i Lucas (1988) u radovima ne potvrđuju vezu između financijskog sustava i gospodarskog rasta, odnosno smatraju da su kretanja unutar financijskog sustava samo „nusproizvod“ gospodarskih kretanja. Nadalje, Law i Singh (2014) te Gambacorta et al. (2014) smatraju da povezanost financijskog sustava i gospodarskog rasta postoji jedino ako su zadovoljeni odgovarajući uvjeti.

Detalji empirijskih analiza i radova autora obuhvaćeni su i razrađeni u petom poglavlju ovoga rada (unutar poglavlja 5.1.1.).

- odnos makroekonomskog okruženja i stabilnost financijskog sustava

U nastavku petog poglavlja (5.2.1.) koji obrađuje odnos makroekonomskih čimbenika na financijski sustav, s naglaskom na bankarski sustav, izdvojena su dosadašnja istraživanja autora Levine (1997), zatim Granville i Mallick (2009), Castro (2012), Agnello i Sousa (2013), Ashraf i Shen (2019), Karadima i Louri (2020), Tran et al. (2021) te drugih koji su se bavili odnosom makroekonomskih varijabli kao što je BDP, inflacija, stopa nezaposlenosti i stabilnosti financijskog sustava.

2. Prilikom analiza i prikupljanja podataka *za izradu empirijskog dijela disertacije* pregledani su sljedeći dostupni izvori: Hrvatske narodne banke – HNB, Državni zavod za statistiku – DZS, European Central bank – ECB, European Commission, SAS® OpRisk Global Data base, baza podataka KPMG-a za 2018. godinu, baza podataka Svjetske banke te baze podataka Global Finance Practice (2017).

Primijenjene su sljedeće statističke metode obrade prikupljenih podataka: deskriptivna statistička metoda, korelacijska analiza, analiza vremenske serije kao i različite metode njihova prezentiranja.

I. Korelacijska analiza

Kako bi se utvrdila i opisala povezanost dviju varijabli provedena je korelacijska analiza. Korelacijska analiza ispituje stupanj povezanosti dviju varijabli, a koeficijent korelacije najčešće je upotrebljavana mjera za opisivanje povezanosti varijabli.

U radu je izračunat Pearsonov koeficijent korelacije kojim se mjeri intenzitet i smjer povezanosti dviju varijabli, a označava se s r.

Vrijednost Pearsonova koeficijenta korelacije (r) kreće se od +1 do –1. Predznak koeficijenta korelacije upućuje na smjer korelacijske povezanosti varijabli gdje pozitivan predznak (+) sugerira pozitivnu povezanost između varijabli, a negativan predznak (–) negativnu korelaciju. Koeficijent korelacije ne upućuje na snagu korelacije (prilagođeno prema Mijoč i Horvat, 2019). Koeficijent od +1 pokazuje da su dvije varijable savršeno pozitivno povezane te da se s

povećanjem jedne varijable, druga varijabla proporcionalno povećava. Suprotno tome, koeficijent od –1 ukazuje na savršen negativan odnos: ako se jedna varijabla povećava, druga se proporcionalno smanjuje. Koeficijent nula ukazuje na to da uopće nema linearnog odnosa te ako se jedna varijabla promijeni, druga će ostati ista. Nadalje, vrijednost Pearsonova koeficijenta korelacije od ±0,1 predstavlja slabu korelaciju, vrijednost od ±0,3 predstavlja umjerenu korelaciju te ±0,5 predstavlja jaku korelaciju. Navedene vrijednosti su samo smjernice za tumačenje koeficijenta korelacije, no veličinu korelacije svakako treba tumačiti u kontekstu istraživačke literature (prilagođeno prema Field, 2018).

Pearsonov koeficijent korelacije izračunava se prema izrazu (Mijoč i Horvat, 2019):

$$r = \frac{n\sum xy - \sum x \sum y}{\sqrt{(n\sum x^2 - (\sum x)^2) \times (n\sum y^2 - (\sum y)^2)}}$$

gdje je:

x – nezavisna varijabla

y – zavisna varijabla

n – broj promatranja

Uz izračun koeficijenta korelacije tumači se i statistička značajnost korelacije (p).

Spearmanov koeficijent korelacije ranga neparametrijski je test kojim se testira pretpostavka o povezanosti dviju populacija. Uporaba Pearsonova koeficijenta korelacije primjena je za ispitivanje povezanosti kvantitativnih varijabli, dok se Spearmanov koeficijent korelacije ranga preporučuje ako su varijable mjerene ordinalnom razinom mjerenja, ali i ako je narušena pretpostavka o normalnosti distribucije (Horvat i Mijoč, 2019).

Podaci obiju varijabli uređuju se redoslijedno kako bi im se dodijelio rang. Nakon određivanja rangova izračunava se razlika rangova i potom se primjenjuje izraz za izračunavanje pokazatelja Spearmanova koeficijenta korelacije ranga (Horvat i Mijoč, 2019):

$$r_s = 1 - \frac{6\sum d^2}{n(n^2 - 1)}$$

d – razlika rangova varijabli

II. Regresijska analiza

Tehnike regresije dugo su bile glavne tehnike analize na području ekonomske statistike („ekonometrije“).

Regresijska analiza je statistički alat za istraživanje odnosa između varijabli. Regresijska analiza slijedi nakon upoznavanja vrijednosti zavisne i nezavisne varijable, a primjenjuje se ako su korelacijskom analizom utvrđene povezanosti dviju varijabli. Dodjeljivanje uloga varijablama je korak i preduvjet analiza koje ispituju povezanost među varijablama (korelacijska i regresijska analiza). Nezavisnom varijablom (x) imenuje se ona varijabla kojom će se predviđati vrijednost zavisne varijable (y) (Horvat i Mijoč, 2019).

Kad postoji samo jedna prediktorska varijabla, tehnika se naziva jednostavnom regresijom, ali kada postoji nekoliko prediktora u modelu, naziva se višestrukom regresijom. Regresijskom analizom nastoji se utvrditi učinak jedne varijable na drugu; učinak povećanja/smanjenja varijable x na varijablu y ili učinak promjena varijable x na stopu varijable y (prilagođeno prema Field, 2018).

Prema Fieldu (2018), regresijska analiza može biti:

Jednostavna regresijska analiza ispituje odnos jedne nezavisne i jedne zavisne varijable.

Odnos između dviju varijabli analitički se zapisuje regresijskim modelom kojim se (prilagođeno prema Horvat i Mijoč, 2019):

- opisuje povezanost između varijabla zapisana izrazom:

$$y = \beta_0 + \beta_1 x + \in$$

y – zavisna varijabla

x – nezavisna varijabla

β0 +β1 – parametri populacije

∈ – slučajna pogreška (pogreška modela)

- minimaliziraju udaljenosti podataka od linije regresije
- tumače predviđanja o varijacijama zavisne varijable.

Višestruka regresijska analiza pripada skupini multivarijatnih metoda kojima se analizira odnos triju ili više varijabli. Omogućuje da se svaki čimbenik promatra zasebno kako bi se mogao procijeniti učinak svakog od njih. Korisna je za kvantificiranje učinaka različitih pojedinačnih varijabli na jednu ovisnu varijablu. Dakle, podrazumijeva i promatra učinak više nezavisnih varijabli na zavisnu varijablu.

Višestruki regresijski model zapisan matematičkom jednadžbom glasi:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k + \varepsilon$$

y – zavisna varijabla

$x_1, x_2, \ldots, x_k$ – nezavisne varijable

$ß_0, ß_1, \ldots, ß_k$ – parametri populacije

Ɛ – slučajna pogreška (pogreška modela)

5.1. Empirijsko istraživanje odnosa kreditnih rizika i makroekonomskih kretanja (H1)

U prethodnim poglavljima rada objašnjen je i analiziran kreditni rizik. Porast kreditnog rizika znači porast nenaplativih kredita u bilanci banke. Ako iznos nenaplativih kredita poraste u značajnoj mjeri, to će djelovati i na kapital banke kao i na likvidnost i profitabilnost (Bryant, 1980; Diamonda i Dybiga, 1983).

Profitabilnost banke djeluje na sposobnost stvaranja dodatnoga kapitala koje se zatim prenosi na gospodarstvo (Ghosh, 2019). Kao i svaka nefinancijska institucija, tako i banka u svojoj bilanci sadrži imovinu i obveze. Što je imovina veća od obveza, prihod i profitabilnost banke su veći. Upravo zbog održavanja stabilnosti i profitabilnosti, banke su razvile strategije i politike upravljanja rizicima koje obuhvaćaju upravljanje svim rizicima s naglaskom na kreditne rizike i kamatne rizike unutar kojih se prati kontrola kretanja kamatnih stopa. S obzirom na to da promjene kamatnih stopa djeluju na zaradu banke mijenjajući neto kamatni prihod kao i operativne troškove banke, prihvaćanje ovoga rizika normalan je dio bankarstva i važan je izvor profitabilnosti i vrijednosti dioničara. Iznenadno mijenjanje kamatne stope imat će za posljedicu i mijenjanje kamatnih prihoda banke (Živko, 2006).

Porastom kamatnih stopa, raste teret otplate kredita dužnika. Ako se povećava obveza klijenta prema banci zbog rasta kamatne stope, dolazi do smanjenja potrošnje kao i do smanjenja investicija u privatnom sustavu. Smanjenje investicija i smanjenje potrošnje dovodi do pada gospodarske aktivnosti zemlje. Stoga kamatne stope imaju veliki značaj i procesom manipulacije kamatnim stopama utječe se na globalna ekonomska kretanja (makrookruženja), na izbor investicijskih projekata, na financijski položaj gospodarstvenih jedinica (Veselica, 2002).

Da bi kompenzirale gubitke ostvarene zbog niskih kamatnih stopa, banke mogu vršiti niža rezerviranja, što zauzvrat može ugroziti financijsku stabilnost ili mogu niže prihode od kamata kompenzirati s nižim kamatnim troškovima. Nižim kamatama banka ostvaruje manje prihode, ali zauzvrat niže kamate potiču povećanje potražnje za kreditima. Manji iznos kamate kompenziran je većim obujmom plasiranih kredita stoga profitabilnost banke nije ugrožena. Zajmovi s niskim kamatnim stopama stimulirat će gospodarski rast. Cijena kredita je niska i klijenti nemaju problema u otplati svojih obveza, a banke u bilancama imaju nizak udio loših kredita, manji su troškovi i profitabilnost banke je veća. Da se bilance banke usklađuju i

prilagođavaju u razdoblju negativnih kamatnih stopa potvrđuju Demiralp et al. (2017). Koristeći se povjerljivim podacima na razini banaka za europodručje, pronalaze dokaze da banke doista drugačije posluju pod negativnim stopama. Reakcije banaka na negativne stope anuliraju se akvizicijama domaćih obveznica, odobravanjem više zajmova nefinancijskom privatnom sustavu i smanjenjem udjela u trgovinskom financiranju. Djelovanje kamatnih stopa na gospodarstvo može biti toliko značajno da kreira stopu rasta ili pada BDP-a.

Kada prevladavaju visoke kamatne stope, smanjit će se financiranje, a time dolazi i do pada u gospodarskom rastu. Profitabilnost banaka generira stvaranje kapitala stoga banke imaju značajnu ulogu u pribavljanju sredstava za financiranje gospodarstva, a time neposredno djeluju na rast i razvoj gospodarstva.

Zbog svojeg značaja za gospodarstvo politika kamatnih stopa je pod utjecajem i kontrolom središnjih banaka. Najveće središnje banke u svijetu usmjerene su na kretanje kamatnih stopa na tržištu novca. U vrijeme financijske krize središnje banke primjenjuju mjere monetarne politike za stabilizaciju gospodarskog razvoja. Tijekom krize učinkovitost standardne kamatne politike je smanjena. Pet godina prije početka financijske krize 2008. godine potražnja za kreditima imala je uzlaznu putanju. Velika potražnja za kreditima, popraćena slabijom kreditnom politikom rizika, potaknula je ekspanziju kredita. Velika ekspanzija kredita, bez većih kontrola, bila je okidač financijske krize u SAD-u koja se zatim prelila i na ostatak svijeta (Tooze, 2018). Za vrijeme financijskih kriza pooštrava se kreditna politika banaka što djeluje na smanjenje kreditne ponude.

Pregled dosadašnjih istraživanja odnosa kreditnih rizika i makroekonomskih kretanja kao i provedeno empirijsko istraživanje izneseno je u nastavku rada.

5.1.1. Pregled empirijskih istraživanja odnosa financijskog sustava i gospodarskog rasta

Utjecaj financijskoga sustava na gospodarski rast odavno je predmet istraživanja brojnih ekonomista. Među prvim autorima koji je analizirao poveznicu financijskog sustava i gospodarskog rasta je Joseph Schumpeter (1911) koji je tvrdio da su usluge financijskih posrednika u prikupljanju štednje, ocjenjivanju projekata, upravljanju rizikom važan faktor ekonomske stabilnosti.

Goldsmith (1955) analizira stvaranje kapitala te kanale i načine kojima investitori dolaze do kapitala. Osnovno pitanje koje postavlja je veza fizičke imovine, dugova i potraživanja na koje se akumulira fizički kapital. Autor u svojem radu uvodi pojam „indeks financijske zrelosti“ i predstavlja ga kao omjer financijskih odnosa i njegove statističke komponente. Ovi indeksi iskazuju nacionalnu neto akumulaciju dugova kao omjer vrijednosti fizičke imovine. Rad se bavi izvorima i kanalima financiranja i prirodom ekonomskog rasta u „naprednim“ kapitalističkim zemljama koje su definirane kao zemlje s velikom vrijednošću stvarnoga nacionalnog proizvoda po glavi stanovnika u kojima je potpuno razvijen financijski sustav. Rad Goldsmitha (1969) i McKinnona (1973) ilustrira usku poveznicu između financijskog i ekonomskog razvoja za nekoliko zemalja. McKinnon naglašava važnost osnivanja tržišta kapitala te razvoj internacionalne trgovine kao strategije ekonomskog razvoja zemlje.

Brojne hipoteze pretpostavljaju da financijski čimbenici uzrokuju ekonomske promjene (Goldsmith, 1969; McKinnon, 1973; Huang i Lin 2009) te su predmet mnogobrojnih analiza. Među radovima koji su se bavili pitanjem uloge financijskog razvoja u gospodarskom rastu istaknuti su radovi autora Levine (1998) i Levine (1999) koji su prvi dokazali da institucionalno nasljeđe utječe na rast dohotka upravo kroz odraz na financijski sustav. Levine et al. (2000), Beck et al. (2001), La Porta et al. (2002) i Beck i Levine (2005) također su istaknuli ulogu razlika u institucionalnom okružju, koje mogu objasniti razlike u stupnju financijskog razvoja. Neimke (2003) u svojem radu prikazuje pozitivan utjecaj financijske razvijenosti na rast gospodarstava u tranziciji. Zatim autori Cojocaru et al. (2012) dokazuju da u tranzicijskim zemljama porast kredita privatnom sustavu ima pozitivan efekt na gospodarski rast, ali da ga znatno mogu ublažiti stopa inflacije, visoke razlike među kamatnim stopama na kredite i depozite te smanjenje konkurentnosti među bankama. Često se smatra da su bankarski zajmovi, posebno oni koji ovise o bankama bez mogućnosti na tržištu kapitala, osnovni pokretači gospodarskog rasta (npr. Smith, 2002; Jayaratne i Strahan, 1996).

Prema Heffernanu (2005), analiza kreditnog rizika također je važna jer su bankroti mnogih banaka povezani s golemim omjerom nenaplativih zajmova u ukupnim zajmovima. Upravo su stoga autori Marcucci i Quagliariello (2009) analizirali odnos kreditnih rizika i poslovnog ciklusa koji izričito dopušta asimetrije, koje su do tada bile gotovo uvijek zanemarene. Zapravo su istražili empirijske dokaze o asimetričnom ponašanju kreditnog rizika ne samo kroz poslovni ciklus, već i kroz različite režime kreditnog rizika. Zaključuju da su portfelji rizičnijih banaka više ciklički (tj. osjetljiviji na poslovni ciklus) te da je cikličnost izraženija u lošim ekonomskim

vremenima. Smatraju da se mogu identificirati one banke za koje je vjerojatnije da će biti pogođene recesijskim uvjetima – i to bi trebalo uzeti u obzir prilikom procjene adekvatnosti kapitala. Koristeći se makroekonomskim prognozama i budućim scenarijima, menadžeri banaka putem stres testova mogu procijeniti razvoj rizičnosti portfelja banaka u slučaju da se ostvari scenarij.

S osam odrednica kreditnog rizika autori Ahmadi i Ariff (2007) uspoređuju bankarski sustav gospodarstva u usponu s razvijenim gospodarstvima. Otkrivaju da su od dva do četiri čimbenika sami po sebi značajno povezani s kreditnim rizikom bilo kojega bankarskog sustava. Regulatorni kapital važan je za bankarske sustave koji nude više proizvoda; kvaliteta upravljanja ključna je u slučajevima banaka u kojima dominiraju zajmovi u gospodarstvima u razvoju. Suprotno teoriji ili studijama, nailaze da poluga nije u korelaciji s kreditnim rizikom.

Odedokun (1996) se osvrće na učinke financijskog posredovanja na rast realnog BDP-a u najrazvijenijim zemljama analizirajući podatke za 71 zemlju tijekom različitih razdoblja od 1960. do 1980. godine. U radu identificira da: (a) financijske institucije potiču ekonomski rast u oko 85 % zemalja; (b) u usporedbi s čimbenicima koji su u literaturi često naglašavani kao važni pokretači rasta (npr. ekspanzija, omjer formiranja kapitala i rast radne snage), financijsko posredovanje je partner u promicanju ekonomskog rasta; (c) učinci financijskih institucija koji potiču rast prevladavaju u zemljama s niskim prihodima više nego u najrazvijenijim zemljama; i (d) efekti financijskog posredovanja koji potiču rast praktički su invazivni u različitim regijama svijeta. Bencivenga i Smith (1991) opisuju potrebu za uvođenjem financijskog posredovanja u okruženje koje se suočava s budućim potrebama za likvidnošću stoga akumuliraju kapital i likvidnu, ali neproduktivnu imovinu. U takvom okruženju potrebno je osigurati uvjete uz koje uvođenje posrednika premješta štednju prema kapitalu te na taj način potiče rast. Osim toga, posrednici općenito smanjuju socijalno nepotrebnu likvidaciju kapitala, opet promičući rast.

Levine (1991) smatra da je razvoj financijskih tržišta i institucija kritičan za ekonomski rast, a ne sporedni ili pasivni odgovor na rast. Levine tvrdi da teorijski i empirijskih dokazi upućuju na pozitivan, prvorazredni odnos između financijskog razvoja i ekonomskog rasta. Postoje čak i dokazi da je razina financijskog razvoja dobar prognozer stopa gospodarskog rasta, akumulacije kapitala i tehnoloških promjena. Nadalje, analize tržišta, analiza slučaja, industrije i razine poduzeća dokumentiraju velika razdoblja kada financijski razvoj (ili njegov nedostatak)

djeluje na brzinu i obrazac ekonomskog razvoja. Levine objašnjava što financijski sustav radi i kako djeluje na gospodarski rast. Teorija sugerira da financijski instrumenti, tržišta i institucije smanjuju transakcijske troškove. Bez minimiziranja uloge institucija, Levine zagovara funkcionalan pristup razumijevanju uloge financijskih sustava u gospodarskom rastu. Ovaj se pristup usredotočuje na veze između rasta i kvalitete funkcija koje pruža financijski sustav. Levine obeshrabruje uski fokus na jedan financijski instrument, poput novca ili određene institucije, poput banaka. Umjesto toga, on se bavi opširnijim i teškim pitanjima: Kakav je odnos financijske strukture i funkcioniranja financijskog sustava? Zašto se, primjerice, financijska struktura mijenja kako zemlje rastu? Zašto zemlje u sličnim fazama gospodarskog razvoja imaju različite financijske sustave? Postoje li dugoročne prednosti gospodarskog rasta od usvajanja zakonskih i političkih promjena koje stvaraju jednu vrstu financijske strukture, a ne drugu?

Saint-Paul (1992) tvrdi da tržište kapitala omogućuje financijsku diversifikaciju, ali i veći rizik. Bez takvih tržišta, agenti mogu ograničiti rizik samo odabirom manje specijaliziranih i manje produktivnih tehnologija (tehnološka diversifikacija). Na takvim tržištima financijske su usluge nerazvijene, a tehnologija nespecijalizirana. U strogo stručnome pogledu financijska se stabilnost može definirati kao „stanje očitovano u neometanom i učinkovitom funkcioniranju svih segmenata financijskog sustava (financijskih institucija, financijskih tržišta i financijske infrastrukture) u procesu alokacije resursa, procjene i upravljanja rizicima te izvršavanja plaćanja, kao i u otpornosti sustava na iznenadne šokove“ (Dumičić, 2015).

Roubini i Sala-i-Martin (1992) analiziraju odnos trgovinskog režima, stupnja financijskog razvoja i učinka rasta na velikom broju zemalja. Sustavno otkriće je da postoji negativna veza nerazvijene trgovine i rasta. Otkrivaju kako financijska represija ima negativne posljedice na rast. Nalaze da je inflacija negativno povezana s rastom i taj odnos tumače kao simptomatski, a ne kao uzročni.

U nastavku rada u tablici 2. prikazan je sustavan pregled empirijskih istraživanja s popisom autora, naziva rada, provedene analize u radu i zaključak svakoga od radova.

Tablica 2. Pregled empirijskih istraživanja veze između financijskog sustava i gospodarskoga rasta

Pregled empirijskih istraživanja veze između financijskog sustava i gospodarskoga rasta				
Godina	**Autor**	**Naziv**	**Metodologija**	**Zaključak**
1955.	W. Goldsmith	Financial Structure and Economic Growth in Advanced Countries: An Experiment in Comparative Financial Morphology	Bavi se izvorima i kanalima financiranja i prirodom ekonomskog rasta u „naprednim“ kapitalističkim zemljama, definiranim kao zemlje s velikom vrijednošću stvarnoga nacionalnog proizvoda po glavi stanovnika u kojima je potpuno razvijen financijski sustav.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.
1973.	McKinnon	Money and Capital in Economic Development	Teorijskom analizom naglašava važnost osnivanja tržišta kapitala te razvoj internacionalne trgovine kao strategija ekonomskog razvoja zemlje.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.
1990.	Greenwood i Jovanovic	Financial Development, Growth, and the Distribution of Income	Prikazana je paradigma u kojoj se endogeno određuje i opseg financijskog posredovanja i brzina gospodarskog rasta. Financijsko posredovanje potiče rast jer omogućuje ostvarenje veće stope prinosa na kapitalu, a rast zauzvrat pruža sredstva za primjenu skupih financijskih struktura.	Financijsko posredovanje i gospodarski rast neraskidivo su povezani u skladu s gledištem Goldsmith-McKinnon-Shawa na ekonomski razvoj.
1991.	Bencivenga i Smith	Financial Intermediation and Endogenous Growth	Potrebno je osigurati uvjete uz koje uvođenje posrednika premješta štednju prema kapitalu te tako potaknuti rast gospodarstva.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.
1991.	Ross Levine	Financial Development and Economic Growth: Views and Agenda. Journal of Economic Literature	Usredotočuje se na veze između rasta i kvalitete funkcija koje pruža financijski sustav.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.
1991.	Gertler i Rose	Finance, growth, and public policy	Autori ispituju odnos rasta financija i ulogu vladine politike. Mnogi ekonomisti naglašavaju kako problemi asimetričnih informacija i provođenje ugovora ometaju funkcioniranje financijskih tržišta zemalja u razvoju.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.
1992.	Roubini i Sala-i-Martin	Financial repression and economic growth	Analiza literature koja proučava odnos trgovinskog režima, rasta i financijskog razvoja, financijske represije i rasta na velikom broju zemalja.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.

1992.	DeGregorio i Guidott	Financial development and economic growth	Ovaj rad ispituje empirijski odnos između dugoročnog rasta i stupnja financijskog razvoja, potaknut omjerom bankarskih kredita prema privatnom sustavu, kao dio BDP-a.	Njihova otkrića sugeriraju da je glavni kanal prijenosa s financijskog razvoja na rast učinkovitost ulaganja, a ne njegov volumen. Također ukazuju na negativnu povezanost financijskog posredovanja i rasta koji proizlazi iz financijske liberalizacije u lošem regulatornom okruženju.
1992.	Jaramillo, Schiantarelli i Weiss	The effect of financial liberalization on allocation of credit: panel data evidence for Ecuador	Autori analiziraju učinak financijske liberalizacije, koristeći se podacima ekvadorskih poduzeća.	Postoji pozitivna veza između reforme tržišta (liberalizacije), kreditne aktivnosti i gospodarskog rasta.
1993.	King i Levine	Finance and Growth: Schumpeter Might Be Right	Predstavljaju međudržavne dokaze da financijski sustav može poticati ekonomski rast koristeći se podacima o 80 zemalja tijekom 1960. – 1989.	Različite mjere razine financijskog razvoja snažno su povezane s realnim rastom BDP-a po stanovniku, stopom akumulacije fizičkoga kapitala i poboljšanjem učinkovitosti kojom gospodarstva koriste fizički kapital.
1996.	Odedokun	Alternative econometric approaches for analysing the role of the financial sector in economic growth: Time-series evidence from LDCs	Rad utvrđuje i analizira učinke financijskog posredovanja na rast realnog BDP-a u najrazvijenijim zemljama korištenjem godišnjih podataka za 71 zemlju tijekom različitih razdoblja koja uglavnom obuhvaćaju 1960. i 1980. godinu.	Otkrića su sljedeća: (a) financijsko posredovanje potiče ekonomski rast u oko 85 % zemalja; (b) u usporedbi s čimbenicima koji su u literaturi često naglašavani (npr. ekspanzija, omjer formiranja kapitala i rast radne snage) kao važni pokretači rasta, financijsko posredovanje je važan partner u promicanju ekonomskog rasta; (c) učinci financijskog posredovanja koji potiču rast prevladavaju u zemljama s niskim prihodima više nego u najrazvijenijim zemljama najrazvijenijih zemalja; i (d) efekti financijskog posredovanja potaknuti na rast praktički su neprimjereni u različitim regijama svijeta.
2002.	Mankiw, Ball i Reis	Monetary Policy for Inattentive Economies	Ovaj rad pridonosi analizi optimalne monetarne politike. Započinje s kritičkom ocjenom postojeće literature tvrdeći da se najveći dio radova temelji na nevjerojatnim modelima dinamike inflacije i proizvodnje.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.
2003.	Markus C. Becker,Thorbjørn Knudsen	Schumpeter 1911: Farsighted Visions on Economic Development	Analizira poveznicu financijskog sustava i gospodarskog rasta koristeći se podacima 80 zemlja.	Postoji pozitivna veza između financijskog sustava i gospodarskog rasta.
2006.	Loayza i Rancière	Financial Development, Financial Fragility and Growth	Ovaj rad istražuje kontradikcije o učincima financijskog posredovanja na gospodarsku aktivnost.	Da bi financijski sustav poticao gospodarski rast, nužno je postojanje financijske stabilnosti.
2009.	Albertazzi i Gambacorta	Bank profitability and the business cycle	U ovome se radu procjenjuje skup jednadžbi za neto kamatni prihod, nekamatni prihod, operativne troškove, rezerve i dobit prije poreza za banke u glavnim industrijaliziranim zemljama i procjenjuje učinke profitabilnosti na makroekonomske i financijske čimbenike.	Razlikujući uglavnom europodručje od anglosaksonskih zemalja, analiza utvrđuje razlike u otpornosti pojedinih bankarskih sustava i povezuje ih s karakteristikama njihove financijske strukture.

2012.	Gunsel	Micro and Macro Determinants of Bank Fragilityin North Cyprus Economy	Glavna svrha ovoga rada je empirijsko istražiti odrednice krhkosti banaka u ekonomiji Sjevernog Cipra od 1984. do 2008., koristeći multivarijatni logit model. Panel podataka koji sadrži podatke o razini banke za 24 komercijalne banke s varijablama koje se odnose na makroekonomsko okruženje.	Empirijski nalazi sugeriraju da su neadekvatnost kapitala, manji prihodi, niža veličina banke, visoka stopa inflacije, niža stopa rasta, nepovoljni uvjeti trgovinskih šokova i tržišni pritisak u Turskoj važne odrednice zabrinutosti bankarskog sustava na Sjevernom Cipru.
2013.	Pečarić i Visković	The effects of prudential policy measures on financial stability in post-transition countries	Cilj ovoga rada je analizirati učinke bonitetne politike na financijsku stabilnost post-tranzicijskih zemalja orijentiranih na banke pristupom panel analize podataka.	Dva glavna zaključka: (1) bonitetne mjere pozitivno djeluju na stabilnost bankarskog sustava izražene pokazateljima financijske stabilnosti; (2) bonitetne mjere predstavljaju važan instrument središnje banke.
2015.	Messai, Gallalia i Jouini	Determinants of Bank Profitability in Western European Countries Evidence from System GMM Estimates	U radu se identificiraju odrednice profitabilnosti za zemlje Zapadne Europe u vrijeme nakon krize 2007. – 2011. Uzorak uključuje 322 banke podijeljene na dva poduzorka GIPSI zemlje pogođene krizom (Grčka, Italija, Portugal, Španjolska i Irska) i ostale zemlje zapadne Europe.	Stopa rasta BDP-a pozitivno djeluje na profitabilnost banaka, jer izravno djeluje na dohodak poduzeća i kućanstava, što poboljšava ekonomsku stabilnost i profitabilnost banaka, a time i stabilnost bankarskog sustava.
2016.	Delić i Rogić-Dumančić	Utjecaj razvijenosti financijskog sustava na gospodarski rast zemalja Srednje i Istočne Europe	Dinamička panel analiza utjecaja razvoja financijskog sustava na gospodarski rast odabranih jedanaest zemalja Istočne i Srednje Europe u razdoblju od 1995. do 2014. godine.	Rezultati analize potvrđuju da financijski razvoj ima signifikantan utjecaj na gospodarski rast.
2017.	Bogdan i Stipković	Pokazatelji hrvatskog bankarskog sustava i gospodarski rast	Rad prikazuje nekoliko indikatora profitabilnosti, rizičnosti i kapitaliziranosti hrvatskoga bankarskog sustava. Izrazito dobra kapitaliziranost jamči stabilnost i mogućnost pozitivnog utjecaja na gospodarski rast u Hrvatskoj.	Financijski razvoj prije krize utjecao je na gospodarski rast kroz akumulaciju kapitala, ali i kroz stimulaciju osobne i državne potrošnje.

Izvor: Izrada autora, 2020.

5.1.2. Podaci i metodologija

U sklopu ovoga poglavlja doktorskog rada prezentiraju se podaci i metodologija za obranu glavne hipoteze rada koja glasi:

H1: Kreditni rizici poslovnih banaka djeluju na makroekonomska kretanja u zemlji

Cilj ovoga istraživanja je pronaći odrednice koje značajno djeluju na odnos financijskog sustava i gospodarskog rasta te potvrditi ili odbaciti postavljenu hipotezu rada.

Varijable kojima su se drugi autori koristili u istraživanju međuovisnosti bankarskih kretanja i makroekonomskih varijabli (kao što je kretanje BDP-a, inflacije, kretanje kamatnih stopa, NPL te kretanje plasmana) preuzete su uz nužne prilagodbe. Navedene varijable u svojim su radovima primjenjivali: Rogić i Bogdan, 2012; Bogdan i Stipković, 2017; Castro, 2012; Cota et al., 2012; Lucian-Liviu, 2006; Dotsey, 1998; Ashraf i Shen, 2019; Beck et al., 2013; Delić i Rogić-Dumančić, 2016; Hristov et al., 2012.

U svrhu analize glavne hipoteze rada koja ispituje povezanost kreditnih rizika i makroekonomskih kretanja, u ovom doktorskom radu analizirani su povijesni podaci o kretanju kamatnih stopa. Prikupljeni su kvantitativni podaci iz različitih izvora koji su zatim analizirani i sistematizirani. Podaci su prikazani kroz vremensku seriju kretanja koja je predočena grafičkim prikazom. Za utvrđivanje postojanja korelativne veze koristili su se parametrijski testovi. S obzirom na to da su prikupljeni brojčani podaci u linearnom odnosu, korišten je Pearsonov koeficijent korelacije. Linearni odnos varijabli prikazan je i tablično i dijagramima rasipanja (engl. *scatter diagram*). Uz parametrijske testove za ispitivanje glavne hipoteze primijenjena je i metoda kompilacije dobivenih rezultata s radovima drugih autora koji su provodili slična ili ista istraživanja.

U prijašnjim poglavljima rada objašnjen je kreditni rizik, a sada se ispituje učinak kreditnih rizika kroz promjene u kretanjima kamatnih stopa te djelovanje kretanja kamatnih stopa na promjene u gospodarstvu. Kretanje kreditnih rizika može se pratiti na dva načina: udjelom neprihodujućih kredita u bilancama banaka i putem promjena u kretanju kamatnih stopa (aktivnih i pasivnih kamatnih stopa). U svrhu analize uloge kreditnih rizika na makroekonomska kretanja ispitivanja provest će se analizom mjesečnih promjena u kretanju kamatnih stopa na novoodobrene kredite i depozite kao i mjesečne promjene u kretanju bruto domaćeg proizvoda kako bi se dobili što točniji rezultati promatranja.

Ispitivanjem uloge kreditnih rizika na makroekonomska kretanja putem varijable neprihodujućih kredita za ovu vrstu analize ne bi dobili točne vrijednosti jer se promjene u kretanju neprihodujućih kredita ne mogu pratiti u realnom vremenu s obzirom na to da se kredit proglašava neprihodujućim tek nakon 90 dana kašnjenja u ispunjenju svojih obveza. Stoga varijabla neprihodujućih kredita neće biti korištena za analizu ispitivanja prve glavne hipoteze koja ispituje ulogu kreditnih rizika na makroekonomska kretanja.

Navedenim metodama prikazano je kretanje kamatnih stopa na kredite s valutnom klauzulom i bez valutne klauzule te kamatnih stopa na depozite s valutnom klauzulom i bez valutne klauzule u 19 godina kao i kretanje pojedinačnih monetarnih agregata. Istraživanje obuhvaća analizu međuovisnosti kamatnih stopa i gospodarskih kretanja od 2000. do 2019. godine u Hrvatskoj. Podaci su prikupljeni iz baze podataka Hrvatske narodne banke i Državnog zavoda za statistiku. Za analizu kamatnih stopa podaci su uzeti sa službene stranice HNB-a. Statistika kamatnih stopa, od srpnja 1995., zasniva se na podacima prikupljenima na temelju HNB-ove Odluke o obvezi dostavljanja izvješća o kamatnim stopama banaka na kredite i depozite. Povijesni podaci statistike kamatnih stopa banaka na kredite i depozite za razdoblje od prosinca 1992. do ožujka 2014. sastavljeni su prema staroj nacionalnoj metodologiji. Dobiveni rezultati prikazani su tablično i grafički radi lakšeg praćenja kretanja varijabli koje se uspoređuju.

Za analizu pokazatelja bankarskog sustava mogu se koristiti pokazatelji likvidnosti, profitabilnosti i kapitaliziranosti, dok kreditni rizici čine osnovnu varijablu u svakom od navedenih pokazatelja. Dakle, ako dođe do porasta kreditnih rizika u financijskoj instituciji, doći će i do pada svih pokazatelja uspješnosti u bankarskom sustavu.

Prikupljeni i analizirani podaci o kretanju kamatnih stopa predstavljaju varijablu korištenu u svrhu analize poveznice kreditnih rizika i makroekonomskih kretanja.

U analizi kamatnih stopa prema definiciji HNB-a koriste se vagani mjesečni prosjeci kamatnih stopa kreditnih institucija za odabrane agregirane kategorije *novih depozitnih poslova* (samo za oročene depozite) i *novih kreditnih poslova* (za kredite koji nisu prekoračenja po transakcijskom računu te potraživanja i krediti po kreditnim karticama) te zbroja iznosa novih poslova za te kategorije depozita i kredita, po izvještajnim mjesecima od 2000. do 2019. godine. U tablicama za analizu iskazani su mjesečni prosjeci kamatnih stopa posebno za kunske depozite bez valutne klauzule, a posebno za kunske depozite s valutnom klauzulom. Prekoračenja po transakcijskom računu te potraživanja i krediti po kreditnim karticama prikazani su kao knjigovodstvena stanja. Depoziti i krediti kućanstvima i nefinancijskim društvima dijele se na depozite i kredite bez valutne klauzule, na depozite i kredite s valutnom klauzulom i na devizne depozite i kredite (HNB).

Podaci o kretanju kamatnih stopa preuzeti su sa stranica HNB-a, a za analizu su uzete sljedeće varijable:

a) kamatne stope na kunske kredite bez valutne klauzule (novi poslovi)
b) kamatne stope na kunske kredite s valutnom klauzulom (novi poslovi)
c) kamatne stope na kunske depozite bez valutne klauzule (novi poslovi)
d) kamatne stope na kunske depozite s valutnom klauzulom (novi poslovi).

Prilikom analize kamatnih stopa na depozite uzeti su svi depoziti bez obzira na ročnost. Kratkoročni depoziti su depoziti s izvornim dospijećem do i uključujući jednu godinu, a dugoročni depoziti su depoziti s izvornim dospijećem duljim od jedne godine. Oročeni depoziti su depoziti čije se upotrebe deponent odriče na određeno dogovoreno vrijeme. Sredstva oročenih depozita ne mogu se koristiti za plaćanja. Ovi depoziti uključuju i oročene depozite s ugovorenim otkaznim rokom ako zahtjev za raspolaganje sredstvima nije podnesen (HNB).

U radu se prate kretanja kamatnih stopa **na novoodobrene kredite i novoodobrene depozite**. Da bi analiza mogla prikazati trenutačne promjene u kretanju kamatnih stopa te ih usporediti s trenutačnim kretanjima BDP-a, potrebno je pratiti kretanja novoodobrenih kamatnih stopa na mjesečnoj/kvartalnoj razini. Ako bi se u analizu uključile kamatne stopa na sve kredite i/ili depozite (ne samo na novoodobrene kredite i depozite), tada bi vagani mjesečni prosjeci kamatnih stopa kreditnih institucija sadržavali podatke ne samo za novoodobrene kamate već i kamate na aktivne dugoročne kredite i depozite odobrene i dogovorene prije nekoliko godina. Takav podatak ne bi dao realnu sliku o iznosu trenutačno aktivnih i pasivnih kamatnih stopa te ne bi bio adekvatan za usporedbu s trenutačnim kretanjima BDP-a.

Dinamiku kretanja kamatnih stopa ne regulira uvijek i isključivo tržište. Kamatne stope su jedan od instrumenata monetarne politike kojim središnje banke kontroliraju ponudu novca te time utječu na rast gospodarske aktivnosti. Kretanje kamatnih stopa u Hrvatskoj znatno se mijenjalo posljednjih 19 godina. Za analizu je uzeto dulje razdoblje kretanja kako bi se obuhvatilo razdoblje prije financijske krize 2008. godine, razdoblje za vrijeme trajanja krize te poslijekrizno razdoblje, odnosno kretanje kamatnih stopa u vrijeme krize, za vrijeme oporavka gospodarstva te za vrijeme stagnacije.

Za praćenje kretanja kamatnih stopa računat će se tzv. granična kamatna marža. Granična kamatna marža definira se kao razlika između aktivne i pasivne kamatne stope na novoodobrene

depozite i kredite (Analiza, HUB, 2017). Granična kamatna marža na novoodobrene kredite i depozite pokazuje razliku između prosječnih aktivnih i pasivnih kamatnih stopa ponderiranih vrijednošću ugovora sklopljenih u posljednjem izvještajnom mjesecu.

Druga promatrana varijabla unutar H1 je BDP. Premda je njegov izračun prilično složen, BDP je, prema osnovnoj definiciji, vrijednost finalnih dobara i usluga proizvedenih u zemlji tijekom godine te pojednostavljeno predstavlja snagu odnosno veličinu pojedinoga gospodarstva. Veći BDP znači da je zemlja ekonomski jača, a njegova veličina u relaciji s brojem stanovnika govori o razini razvijenosti pojedine zemlje.[12]

Komponente BDP-a čine: osobna potrošnja (C), ulaganja ili investicijska potrošnja (I), državna potrošnja (G) i neto izvoz (NX) odnosno (Mankiw, 2014):

$$BDP= C + I + G + NX$$

Osobna potrošnja „C“: predstavlja osobnu potrošnju građanstva odnosno kućanstava na robe i usluge.

Ulaganja ili investicijska potrošnja (I): ulaganje u opremu, zalihe i ulaganje u stambene površine – općenito u imovinu koja će donijeti prihod vlasniku kroz neko vrijeme.

Državna potrošnja (G): podrazumijeva potrošnju države koja se financira preko državnog proračuna, izvanproračunskih fondova te proračuna lokalnih jedinica.

Neto izvoz (NX): predstavlja razliku između izvoza i uvoza roba i usluga.

Nakon što se obrade kretanja varijabli kamatnih stopa s valutnom klauzulom i bez valutne klauzule, u nastavku poglavlja objašnjava se kretanje varijable bruto domaći proizvod (BDP) i kretanje varijable BDP-a Hrvatske usporedno s kretanjem BDP-a u zemljama europske unije kroz razdoblje od 2000. do 2019. godine. Podaci o postotnoj promjeni kretanja BDP-a u odnosu na prethodnu godinu preuzeti su iz podataka Državnog zavoda za statistiku. Za razdoblje od 2007. do 2019. godine prikazano je usporedno kretanje graničnih marži s valutnom klauzulom i bez valutne klauzule i kretanje varijable BDP-a. Podaci o kretanju BDP-a, odnos prema

[12] Hrvatska gospodarska komora, Kretanje BDP-a u Hrvatskoj – izvori rasta i posljedice, 2017.

prethodnom tromjesečju, preuzeti su iz baze podataka Državnog zavoda za statistiku. Radi analize prikazane su kvartalne promjene u kretanju BDP-a u odnosu na prethodno tromjesečje.

Radi određivanja intenziteta i smjera povezanosti kamatne razlike s valutnom klauzulom i kamatne razlike bez valutne klauzule s BDP-om provedena je korelacijska analiza i izračunat je Pearsonov koeficijent korelacije. Za varijable kod kojih je dobivena statistički značajna povezanost izračunata je i jednadžba pravca regresije te su podaci prikazani unutar dijagrama rasipanja.

5.1.3. Empirijsko testiranje odnosa kreditnog rizika i gospodarskog rasta (H1)

Ovom analizom pokušavaju se detektirati promjene u „ponašanju“ banaka te ustanoviti ulogu promjena kamatnih stopa (rast i pad kamatnih stopa) u promjenama na gospodarskom tržištu. Želi se ispitati djeluju li banke svojim politikama na promjene makroekonomskih varijabli. Istraživanje će obuhvatiti analizu međuovisnosti kamatnih stopa i gospodarskih kretanja od 2000. do 2019. godine u Hrvatskoj. Podaci za analizu prikupljeni su iz dostupnih izvora o kretanju varijabli iz baze podataka HNB-a i Državnog zavoda za statistiku.

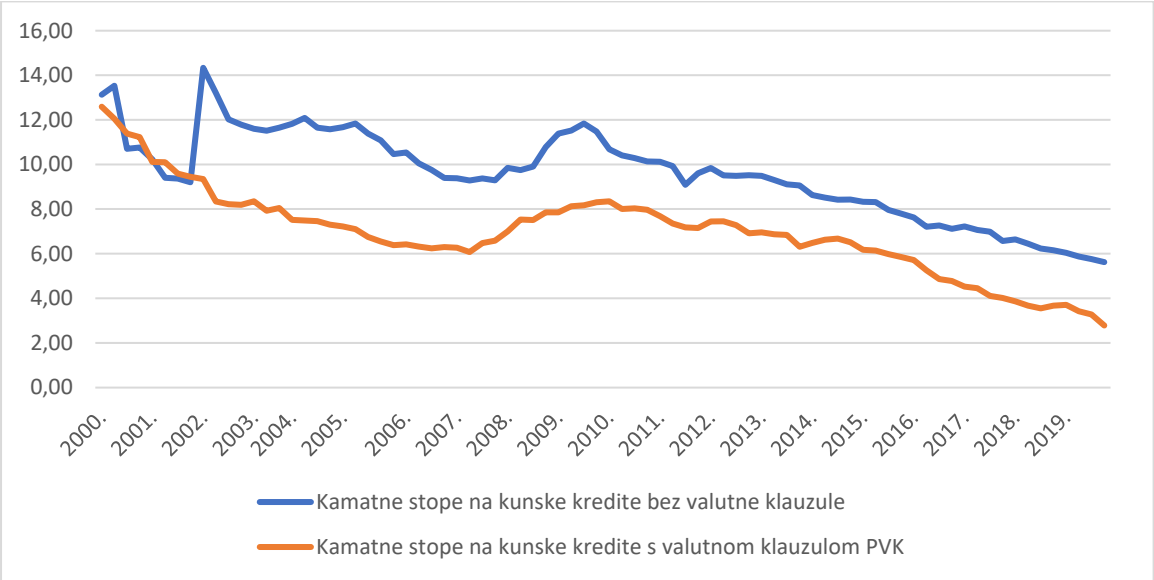
U bazama podataka preuzetih iz HNB-ove statističke baze iskazuju se vagani mjesečni prosjeci kamatnih stopa te zbroj iznosa novih depozitnih poslova kreditnih institucija u izvještajnom mjesecu, posebno za kunske depozite bez valutne klauzule, za kunske depozite s valutnom klauzulom i za devizne depozite razvrstane na: depozite kućanstava i nefinancijskih društava, prema instrumentima, podjela prema ročnosti i podjela prema valuti indeksacije odnosno prema valutama, ovisno o prezentacijskom formatu u pojedinoj tablici.

Za potrebe analize prikupljeni su podaci o kretanju mjesečnih kamatnih stopa. Podaci su prikupljeni iz različitih baza podataka. Podaci su sistematizirani, kamatne stope uprosječene i svedene na kvartale kako bi se mogla izvršiti usporedba kretanja kamata iz prethodnih razdoblja (baza podataka nalazi se u poglavlju Prilozi na kraju doktorskog rada).

Na temelju prikupljenih podataka o kretanju aktivnih kamatnih stopa na novoodobrene plasmane, izrađen je grafikon kretanja radi boljeg praćenja dobivenih rezultata. Aktivnim kamatnim stopama nazivaju se kamatne stope na kredite i nalaze se u aktivi banke.

Kretanje kamatnih stopa na kunske kredite s valutnom klauzulom i bez valutne klauzule na novoodobrene plasmane prikazano je na grafikonu 2.

Grafikon 2. Kretanje kamatnih stopa na novoodobrene kunske kredite



Izvor: Izrada autora prema podacima službenih stranica HNB-a, 2019.

Na grafikonu 2. prikazan je trend kretanja kamatnih stopa na novoodobrene kunske kredite stanovništva i nefinancijskog sustava s valutnom klauzulom i bez valutne klauzule. Za sve vrijeme promatranog razdoblja kamatne stope na kunske kredite bez valutne klauzule značajno su više od kamatnih stopa na kunske kredite s valutnom klauzulom. Na početku promatranog razdoblja 2000. i 2001. godine kamatne stope kretale su se na istim razinama da bi se 2003. godine dogodio veliki skok, odnosno rast kamata na kunske kredite bez valutne klauzule.

Kamatne stope na kunske kredite s valutnom klauzulom niže su od kamatnih stopa na kunske kredite bez valutne klauzule zato što je štednja građana denominirana u stranim valutama (eurske i dolarske štednje) kao što je i zaduživanje banaka na međunarodnim tržištima u stranim valutama. Banke raspolažu sa značajno većim izvorom sredstava u valuti nego u kunama stoga je zaduživanje u kunama skuplje. S druge strane, banke raspolažu s puno većim izvorom sredstava denominiranim u valutama stoga je i veća ponuda kredita s valutnom klauzulom.

Glavni razlog relativno velikog udjela depozita građana u stranoj valuti je makroekonomska nestabilnost i strah od inflacije iz prošlosti. Unatoč činjenici da je kuna stabilna dulje od četvrt stoljeća, štediše i dalje više preferiraju čuvati svoj novac u devizama (uglavnom euru). Prema

podacima iz siječnja 2020., ukupna devizna štednja u hrvatskim bankama iznosila je 193,7 milijardi kuna, dok je štednja u kunama iznosila samo 35,6 milijardi kuna (HNB).

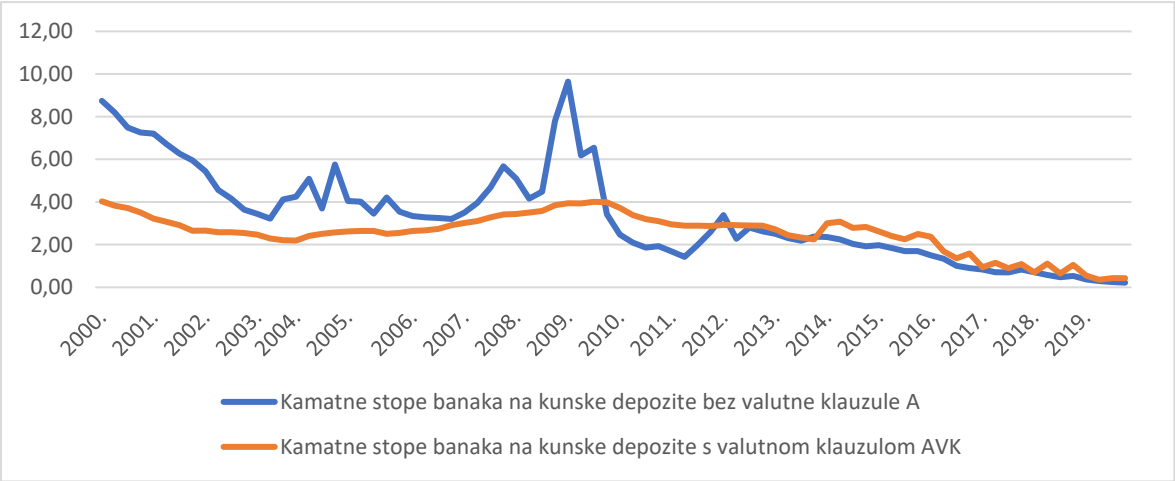
Radi zaštite svoje imovine, građani će se prije odlučiti na štednju u nekoj od „stabilnijih“ valuta kao što je prije bila njemačka marka, a danas je to euro ili dolar. Skorim uvođenjem eura trebao bi se ukloniti trenutačno visoki valutni rizik kao i ušteda u mjenjačkim troškovima.

Zbog značajno veće štednje građana i nefinancijskog sustava u stranim valutama, zanimljivo je promotriti kretanje kamatnih stopa na depozite s valutnom klauzulom i bez valutne klauzule. Kako bi podaci bili usporedivi, za analizu je potrebno uzeti isto razdoblje, odnosno razdoblje od 2000. do 2019. godine.

Na temelju prikupljenih podataka o kretanju pasivnih kamatnih stopa na novoodobrene depozite, izrađen je grafikon kretanja radi boljeg praćenja dobivenih rezultata. Kamatna stopa na depozite naziva se pasivnom kamatnom stopom. Ona predstavlja odljev sredstava iz banke, odnosno sva plaćanja koja banka vrši prema trećim osobama. Pasivna kamata je ona kamata koju banka plaća na „pasivne poslove“, kao što su ulozi na štednju, depoziti po računima, kamatni kuponi po vlastitim obveznicama i blagajničkim zapisima i slično (HNB).

Kretanje pasivnih kamatnih stopa na novoodobrene depozite s valutnom klauzulom i bez valutne klauzule prikazano je na grafikonu 3.

Grafikon 3. Prikaz kretanja kamatnih stopa na novoodobrene kunske depozite s valutnom klauzulom i bez valutne klauzule

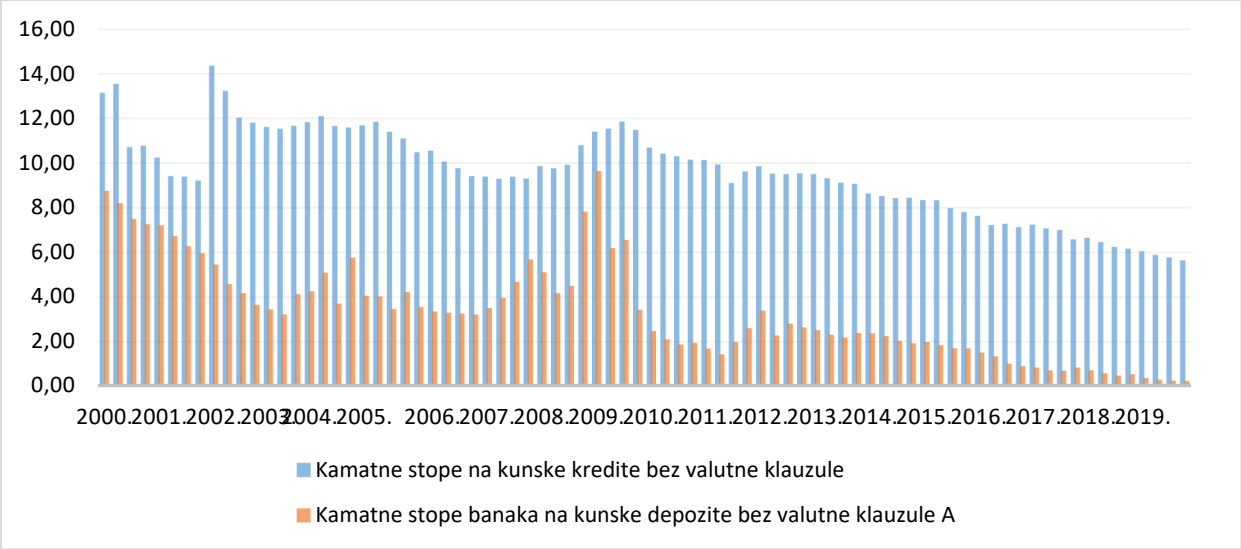


Izvor: Izrada autora prema podacima službenih stranica HNB-a, 2019.

Grafikon 3. prikazuje kretanje kamatnih stopa na novoodobrene kunske depozite bez valutne klauzule i na kunske depozite s valutnom klauzulom. Iz grafikona je vidljiva oscilacija u kretanju kamatnih stopa na kunske depozite bez valutne klauzule, dok je kamatna stopa na depozite s valutnom klauzulom relativno stabilna; oscilira, ali bez značajnijih odstupanja. Razlog osciliranja pasivnih kamatnih stopa bez valutne klauzule je u preferenciji građana u valuti za štednju. Na početku i za vrijeme trajanja gospodarske krize vidljive su oscilacije kamatnih stopa kao posljedica kretanja kamatne stope na kunske kredite bez valutne klauzule. Na početku promatranog razdoblja, odnosno do 2003. godine bilježi se pad kretanja kamatnih stopa da bi 2004. bio značajniji rast i pad u istoj godini. Zanimljiv je skok u kamatnoj stopi na kunske depozite 2009. godine kada je prosječna kamata iznosila 9 %. Posljedica takvog naglog rasta je reakcija na započetu krizu. Pogoršanje međunarodnoga i domaćega makroekonomskog okruženja zbog utjecaja svjetske financijske krize znatno je djelovalo na financijsku stabilnost u 2009. godini. Kako bi spriječile povlačenje depozita, banke su bile prisiljene povećati kamatne stope.

Na grafikonu 4. prikazano je kretanje kamatne stope na novoodobrene kunske kredite i novoodobrene depozite bez valutne klauzule, dok je u grafikonu 5. prikazano kretanje kamatne stope na novoodobrene kunske kredite i novoodobrene depozite s valutnom klauzulom. Razlika između kamatnih stopa na novoodobrene kredite i depozite predstavlja kamatnu graničnu maržu.

Grafikon 4. Prikaz kretanja kamatnih stopa na novoodobrene kunske kredite i depozite bez valutne klauzule



Izvor: Izrada autora, 2020.

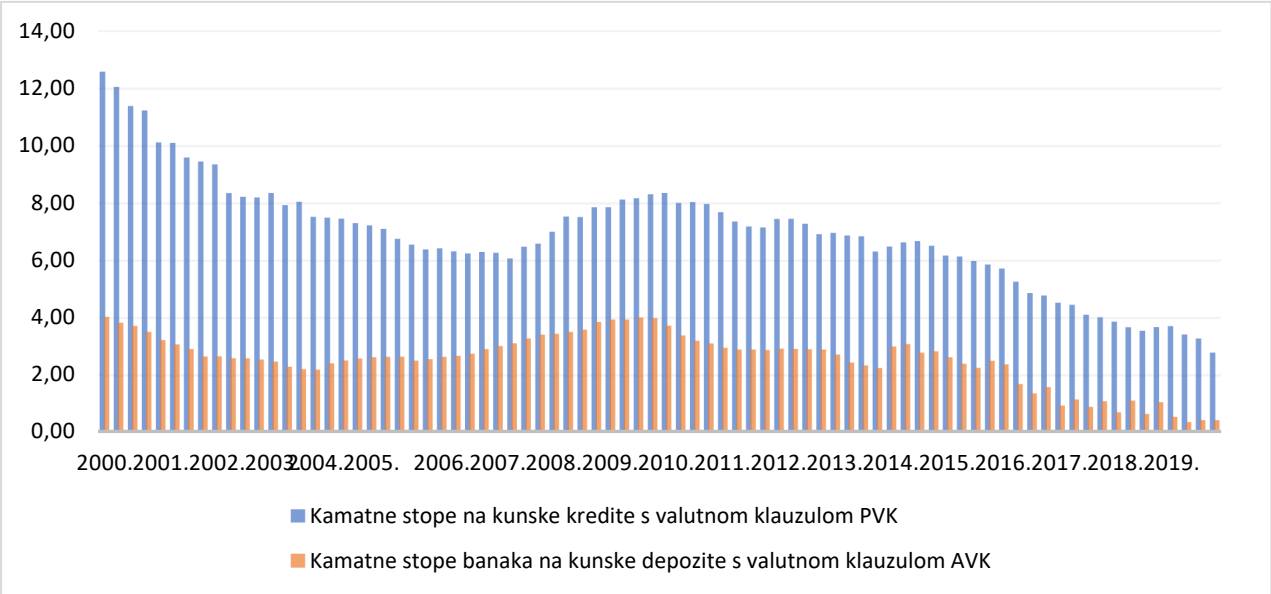
Grafikon 4. daje uvid u kretanje kamatnih stopa na novoodobrene kunske kredite i depozite bez valutne klauzule u razdoblju od 2000. do 2019. godine. Godine 2000. kamatna stopa na kunske depozite iznosila je više od 8 %, dok je te iste godine kamatna stopa na kunske depozite s valutnom klauzulom iznosila samo 4 % (grafikon 5). Tu upućuje na to da je u tom razdoblju bankama nedostajalo depozita bez valutne klauzule i višom kamatnom stopom su privlačili građane na štednju u domaćoj valuti. Ako se usporedi kretanje kamatnih stopa na kunske kredite bez valutne klauzule u razdoblju od 2000. do 2002. godine, može se uočiti nagli pad kamate na kunske kredite bez valutne klauzule krajem 2000. i taj značajni pad potrajao je sve do kraja 2002. godine kad opet počinje rasti i prelazi stopu od 14 %. Nakon 2002. godine ona blago opada da bi opet počela rasti krajem 2008. godine, početkom krize. Kamatne stope na depozite bez valutne klauzule su padale unatoč činjenici da su na kredite rasle te je kamatna marža u promatranom razdoblju od kraja 2002. godine do kraja 2008. godine bila iznimno visoka. U kriznom razdoblju od 2008. do kraja 2009. godine kamatna razlika se smanjila te je upravo 2009. godine bila minimalna i iznosila je samo tri postotna poena.

To govori da u vrijeme krize banke nemaju puno izbora. Odnosno da bi prikupile sredstva i održale likvidnost, prisiljene su povisiti kamatne stope na depozite, a taj porast kompenziraju povisivanjem kamatne stopa na plasirane kredite. Kamatna razlika uvijek mora ići u korist banke, u protivnom će doći do nelikvidnosti banke, a katkad i do stečaja banke. S druge strane, poskupljenje bankarskih kredita dovodi do smanjenja potražnje za kreditima što također negativno djeluje na bilancu banke. Veliku ulogu u formiranju kamatnih stopa na kredite ima

središnja banka, koja svojim politikama djeluje na formiranje kamatnih stopa. Tako je središnja banka brzom intervencijom početkom 2010. godine smanjila regulatorni trošak kako bi spriječila banke da cjelokupni teret rasta kamatnih stopa prebace na dužnike. Veliku ulogu u „preživljavanju“ ove krize je razdoblje blagostanja kada su banke stvorile zalihu koja im je omogućila da podnesu dio troškova financiranja.

Nakon 2009. godine kamatna razlika opet je iznimno visoka unatoč tome što se bilježi pad i kamata na kredite kao i kamata na depozite. Pad kamata na depozite značajno je veći od pada kamata na kredite što je i glavni razlog visoke kamatne razlike.

Grafikon 5. Prikaz kretanja kamatnih stopa na novoodobrene kunske kredite i depozite s valutnom klauzulom



Izvor: Izrada autora, 2020.

Grafikon 5. prikazuje kretanje kamatnih stopa na kredite i depozite s valutnom klauzulom. Kretanje kamatne razlike za promatrano razdoblje znatno manje oscilira u usporedbi s kretanjem kamatne razlike bez valutne klauzule u istom promatranom razdoblju (grafikon 4.). Godine 2000. zabilježena je najviša kamatna stopa na kunske kredite s valutnom klauzulom i iznosi više od 12 %, dok je u istoj godini kamatna stopa na depozite s valutnom klauzulom iznosila oko 4 %. U tom razdoblju (od početka 2000. do sredine 2001. godine) kamatna razlika iznosila je više od osam postotnih poena i najviša je u promatranom razdoblju. Nakon 2001. godine kamatne stope na kredite lagano opadaju, dok su kamatne stope na depozite uglavnom na istoj razini i kreću se od 3 do 4 %. Veće odstupanje zabilježeno je krajem 2007. godine pa sve do kraja 2010. godine kada je zabilježen rast i kamatnih stopa na kredite kao i rast kamatnih

stopa na depozite vezane uz valutnu klauzulu. Razlog je financijska kriza u svijetu koja se prelila i na hrvatske banke. Od kraja 2010. pa do kraja 2019. godine (uz manje oscilacije 2014. i 2015. godine) zabilježen je negativan trend u kretanju kamatnih stopa i na kredite i na depozite s valutnom klauzulom.

Godine 2008. HNB je ukinuo instrument granične obvezne pričuve (GOP), koji je bio veliko porezno opterećenje na inozemno zaduživanje banaka posljednjih nekoliko godina te je potaknuo poslovne banke na zaduživanje u inozemstvu radi pribavljanja potrebne devizne likvidnosti. Zbog toga kamatne stope na kunske kredite kao i kamatne stope na depozite s valutnom klauzulom prikazuju relativno stabilan trend bez značajnih odstupanja (Galac, 2011). Od 2010. godine kamatne stope na kunske depozite s valutnom klauzulom su veće nego kamatne stope na depozite bez valutne klauzule, odnosno na kunsku štednju što znači da građani sve više prihvaćaju kunu kao stabilnu valutu za štednju, odnosno banke raspolažu dovoljnim izvorima sredstava u domaćoj valuti.
Nakon propasti jedne od najvećih svjetskih banaka Lehman Brothersa u rujnu 2008. godine, domaće stanovništvo izgubilo je povjerenje u bankarski sustav te je došlo do masovnog povlačenja depozita iz hrvatskih banaka. Središnja banka reagirala je uvođenjem restriktivne politike kamatnih stopa tako da se visokim kamatnim stopama ograničila ponuda kunske likvidnosti te je s mjerama za smanjenje regulatornog troška osigurala dostatnu likvidnost bankarskom sustavu. Time je kompenzirala odljev depozita i stvorila dodatna sredstva za kreditiranje domaćeg poduzetništva. Stabilizacija tečaja također je odigrala ključnu ulogu jer je stabilnom politikom tečaja spriječena veća problematika otplate kredita stanovništva i poduzeća s valutnom klauzulom s obzirom na to da je u to vrijeme većina kredita bila s valutnom klauzulom.

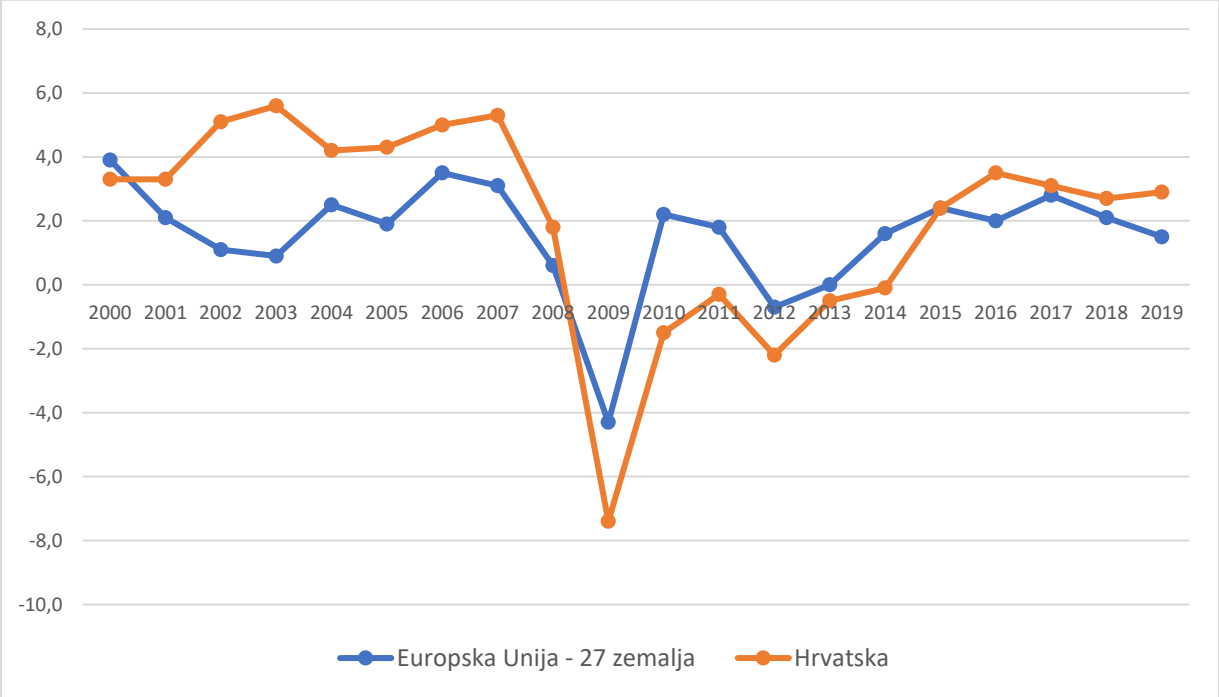
Nakon što je obrađeno kretanje varijabli kamatnih stopa s valutnom klauzulom i bez valutne klauzule u nastavku rada objašnjava se varijabla bruto domaći proizvod (BDP), kretanje varijable BDP-a kroz godine te se prikazuje usporedno kretanje varijable BDP-a i kamatnih razlika s valutnom klauzulom i bez valutne klauzule.

Premda je njegov izračun prilično složen, BDP je, prema osnovnoj definiciji, vrijednost finalnih dobara i usluga proizvedenih u zemlji tijekom godine te pojednostavljeno predstavlja snagu

odnosno veličinu pojedinoga gospodarstva. Veći BDP znači da je zemlja ekonomski jača, a njegova veličina u relaciji s brojem stanovnika govori o razini razvijenosti pojedine zemlje.[13]

Radi boljeg razumijevanja varijable BDP-a u grafikonu 6. prikazana je dinamika kretanja BDP-a Hrvatske usporedo s kretanjem BDP-a u zemljama europske unije. Grafikon prikazuje postotnu promjenu kretanja BDP-a u odnosu na prethodnu godinu. Prikazuje se vremenska serija podataka o bruto domaćem proizvodu i temeljnim agregatima nacionalnih računa prema Nacionalnoj klasifikaciji djelatnosti 2007. (NKD, 2007).

Grafikon 6. Kretanje BDP-a u odnosu na prethodnu godinu (izraženo u postocima)



Izvor: Eurostat, 2020.

U promatranom razdoblju vidljiv je značajan rast BDP-a u Hrvatskoj od 2001. do 2003. godine koji je od 2003. godine veći od prosjeka zemalja EU-27. Ako bi se u promatranom razdoblju od 2001. do 2003. uzela u obzir usporedba rasta BDP-a u Hrvatskoj sa stopom rasta zemalja EU-15, rast bi bio znatno manji. No kako bi se provela realna usporedba, nije poželjno u tom razdoblju uspoređivati rast BDP-a Hrvatske s top 15 zemalja Europe. Radi što realnije slike u

[13] Hrvatska gospodarska komora, Kretanje BDP-a u Hrvatskoj – izvori rasta i posljedice, 2017.

analizi je obuhvaćeno svih EU-27 zemalja iako u promatranom razdoblju nisu sve zemlje bile članice EU-a.

Prosječna stopa rasta BDP-a u Hrvatskoj u razdoblju od 2000. do 2008. iznosi 4,2 %. Rast je povezan s ulaganjima u infrastrukturu i fiksni kapital. Globalna kriza utjecala je na gospodarski rast od 2007. pa sve do 2015. godine. Kriza je prouzročila pad realnog BDP-a za 12,6 %, mjeren realnim BDP-om. Oporavak se dogodio 2015. godine i nastavio se kroz 2016. i 2017. godinu s dobrim izgledima za nastavak pozitivnih pomaka.

Prilikom testiranja poveznice kreditnih rizika i makroekonomskih čimbenika provedena je analiza vremenskih serija koja predstavlja skup metoda za proučavanje vrijednosti podataka prikupljenih tijekom procesa. U svrhu dokazivanja ove hipoteze korištena je vremenska serija u razdoblju od 2007. do 2019. godine. Provedbom analize vremenskih serija pokušalo se identificirati i razumjeti vremenske zavisnosti unutar dva procesa; kretanje varijabli banke s makroekonomskom varijablom BDP. Analiza vremenskih serija zasniva se na pretpostavci da se društveni procesi i sustavi sastoje od međusobno povezanih kratkoročnih, srednjoročnih i dugoročnih kretanja.

Za analizu uloge kreditnih rizika na makroekonomska kretanja korištene su sljedeće varijable te njihovo vremensko kretanje u razdoblju od dvanaest godina:

1. kamatna razlika s valutnom klauzulom na novoodobrene kredite: odnos prema prethodnom kvartalu
2. kamatna razlika bez valutne klauzule na novoodobrene kredite: odnos prema prethodnom kvartalu
3. bruto domaći proizvod (BDP): odnos prema prethodnom tromjesečju.

Podaci su prikupljeni i sumirani te predočeni tablično i grafički radi boljeg praćenja vremenske dinamike kretanja varijabli koje se ispituju te njihova međuodnosa.

Tablica 3. Pregled kretanja BDP-a i kamatnih razlika s valutnom klauzulom i bez valutne klauzule: odnos prema prethodnom razdoblju

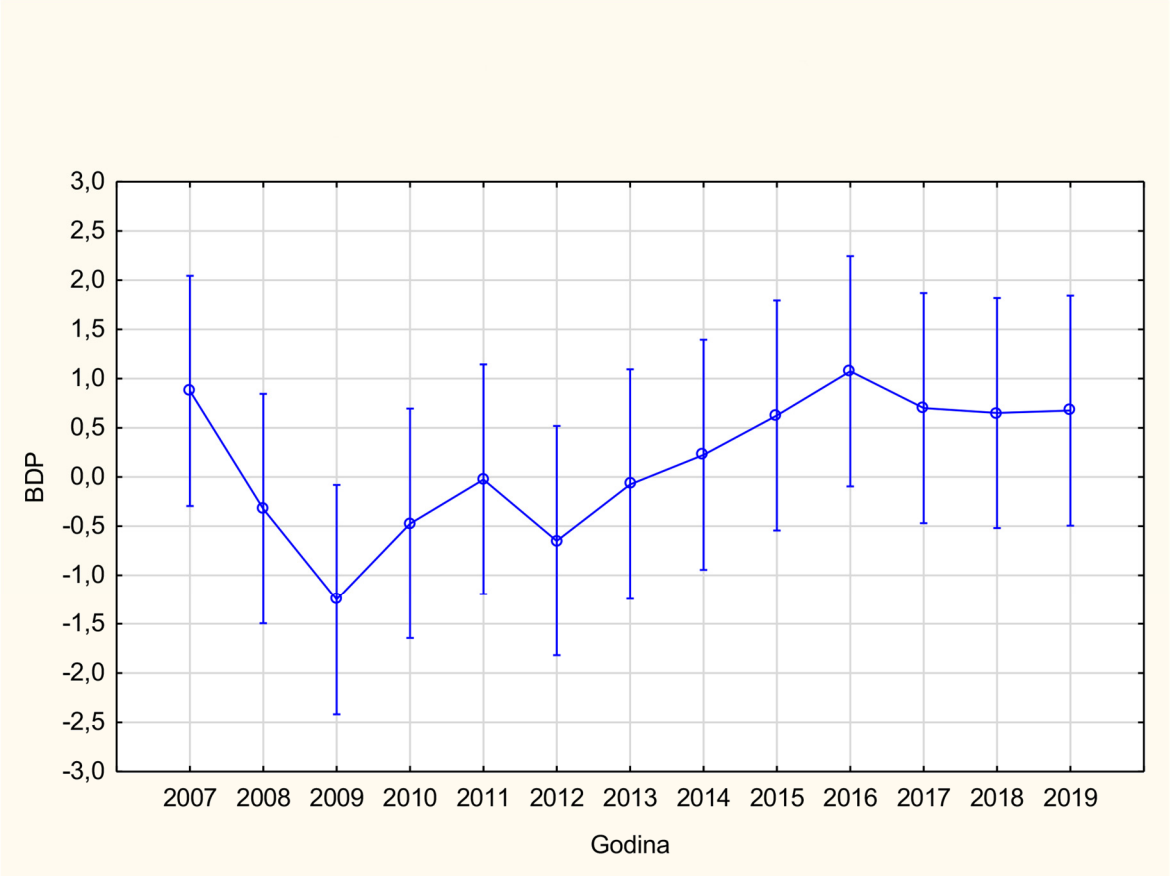
Godina	BDP realne stope rasta: odnos prema prethodnom tromjesečju	Kamatna razlika s valutnom klauzulom: odnos prema prethodnom kvartalu	Kamatna razlika bez valutne klauzule: odnos prema prethodnom kvartalu
2007.	2,5	-0,14	-0,31
	0,6	-1,84	-0,56
	0,2	-0,44	-0,62
	0,2	-0,05	-1,08
2008.	2,4	2,19	1,14
	0,6	-1,74	0,84
	-1,6	-2,21	-0,17
	-2,7	-1,08	-2,45
2009.	-4,5	-1,77	-1,23
	0,1	4,59	3,60
	-1,3	-1,43	-0,04
	0,7	2,02	2,76
2010.	-1,1	-1,77	0,15
	-1,0	0,01	0,11
	1,5	2,56	0,11
	-1,3	-2,80	-0,22
2011.	-0,6	0,66	0,24
	1,6	2,21	0,05
	-0,4	-1,95	-1,39
	-0,7	-0,29	-0,10
2012.	-1,2	-0,55	-0,55
	-0,8	0,40	0,78
	0,3	1,10	-0,55
	-0,9	-1,23	0,21
2013.	0,6	1,54	0,09
	0,0	-0,63	0,02
	-0,7	-0,65	-0,08
	-0,2	0,51	-0,24
2014.	0,0	0,12	-0,41
	0,5	0,55	0,00
	-0,4	-0,95	0,12
	0,8	1,27	0,12
2015.	0,7	-0,17	-0,16
	0,9	0,21	0,13
	1,1	0,27	-0,21
	-0,2	-1,36	-0,17
2016.	1,6	1,80	0,02
	0,7	-0,91	-0,25
	1,1	0,38	0,38
	0,9	-0,16	-0,04
2017.	0,4	-0,46	0,17
	1,1	0,63	-0,04
	0,7	-0,32	-0,06
	0,6	-0,14	-0,55
2018.	-0,2	-0,83	0,19
	2,1	2,30	-0,07
	0,3	-1,82	-0,11
	0,4	0,19	-0,14
2019.	1,1	0,67	0,05

	0,6	-0,55	-0,09
	0,6	0,02	-0,07
	0,4	-0,19	-0,11

Izvor: Izrada autora, 2020.

Na temelju podataka iz priložene tablice 3. napravljen je grafikon 7. na kojem je prikazano kretanje varijable BDP-a.

Grafikon 7. Kretanje BDP-a u Hrvatskoj kroz godine – analiza vremenske serije



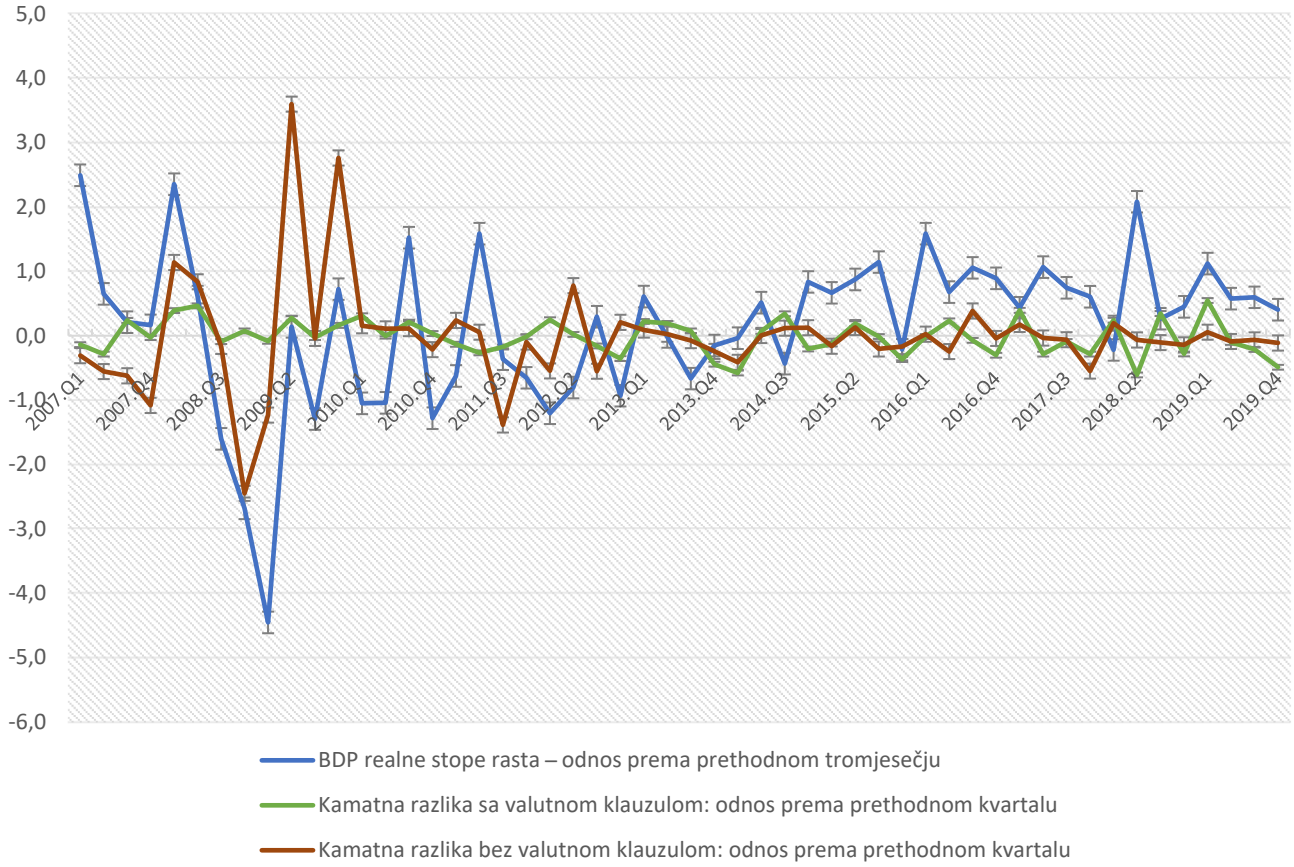
Izvor: Izrada autora, 2020.

Naime, vremenskom serijom prikazan je slijed brojčanih podataka promatrane varijable BDP-a koji su odijeljeni jednakim vremenskim intervalima te poredani u vremenskom redoslijedu od 2007. godine do 2019. godine. S obzirom na to da je kretanje BDP-a varijabla ekonomske aktivnosti koja se događa kontinuirano, slijedom tromjesečnih vrijednosti BDP-a moguće je samo diskretno izmjeriti ekonomsku aktivnost. Grafikonom je prikazan trend kao i ciklične fluktuacije u vremenskom nizu te vrijednosti svake sljedeće razine serije ovisno o prethodnoj.

Varijabla BDP-a izmjerena u diskretnom vremenu prikazana je kao stepenasta funkcija, u kojem je za svako prikazano razdoblje os iste dužine kao i svako drugo razdoblje, a izmjerena varijabla prikazana je kao visina koja je konstantna u cijelom području razdoblja. Vidljiva je korelacijska ovisnost između uzastopnih razina vremenskih serija kretanja BDP-a.

Na grafikonu 8. prikazano je kretanje triju varijabli: varijable kamatne razlike s valutnom klauzulom i varijable kamatne razlike bez valutne klauzule te varijable BDP-a, u istom promatranom razdoblju od 2007. do 2019. godine. Radi što točnije usporedbe dinamike kretanja, u prikazanom razdoblju korištene su promjene u odnosu na prethodno razdoblje (rast ili pad) za sve tri varijable.

Grafikon 8. Kretanje kamatnih razlika i BDP-a u Hrvatskoj po kvartalima od 2007. do 2019. godine



Izvor: Izrada autora, 2020.

Iz grafikona 8. vidljivo je usporedno kretanje varijable kamatne razlike na novoodobrene plasmane bez valutne klauzule i varijable BDP-a. Budući da je kretanje kamatnih razlika na

novoodabrane plasmane bez valutne klauzule detaljno objašnjeno na prethodnim stranicama rada, ovdje će se objasniti kretanje varijable BDP-a po kvartalima. U prvom kvartalu 2007. godine zabilježen je nagli pad BDP-a koji se nastavlja sve do zadnjeg kvartala 2007. godine. Krajem 2007. godine zabilježen je ponovni rast BDP-a da bi već u Q1 2008. godine bio zabilježen strmoviti pad BDP-a i to na najnižu razinu u cijelom promatranom razdoblju. Vidljiva je potpuno ista dinamika kretanja varijable kamatne razlike na novoodabrane plasmane bez valutne klauzule i varijable BDP-a. Budući da nije uočena sličnost u dinamici kretanja varijable kamatne razlike na novoodabrane plasmane s valutnom klauzulom i varijable BDP-a, u nastavku analize grafikona kretanje navedene varijable neće se posebno analizirati.

Vrlo zanimljivo kretanje zabilježeno je u zadnjem kvartalu 2008. godine kao i u prva dva kvartala 2009. godine. Zabilježen je rast kamatne razlike bez valutne klauzule i BDP-a, s time da rast BDP-a slijedi rast varijable kamatne razlike bez valutne klauzule. Iz toga proizlazi da su banke svojim djelovanjem putem promjene kamatnih stopa reagirale na promjene prije nego što su zabilježene promjene u gospodarstvu. Nakon Q2 2019. godine zabilježene su značajne oscilacije u kretanju varijable kamatnih razlika bez valutne klauzule kao i varijable BDP-a. Kretanje tih dviju varijabli i dalje je usklađeno, ali sa značajnim oscilacijama.

Može se zaključiti da je do kraja promatranog razdoblja dinamika kretanja kamatnih razlika na novoodobrene plasmane bez valutne klauzule usklađena s kretanjem BDP-a, s malim, beznačajnim odstupanjima u pojedinim kvartalima te da se u pojedinim razdobljima promatranja promjene u kretanju kamatnih razlika bez valutne klauzule događaju prije nego što su zabilježene promjene u gospodarstvu.

Radi određivanja intenziteta i smjera povezanosti kamatne razlike s valutnom klauzulom i kamatne razlike bez valutne klauzule s BDP-om provedena je korelacijska analiza i izračunat je Pearsonov koeficijent korelacije što je vidljivo u tablici 4. i dijagramu 1.

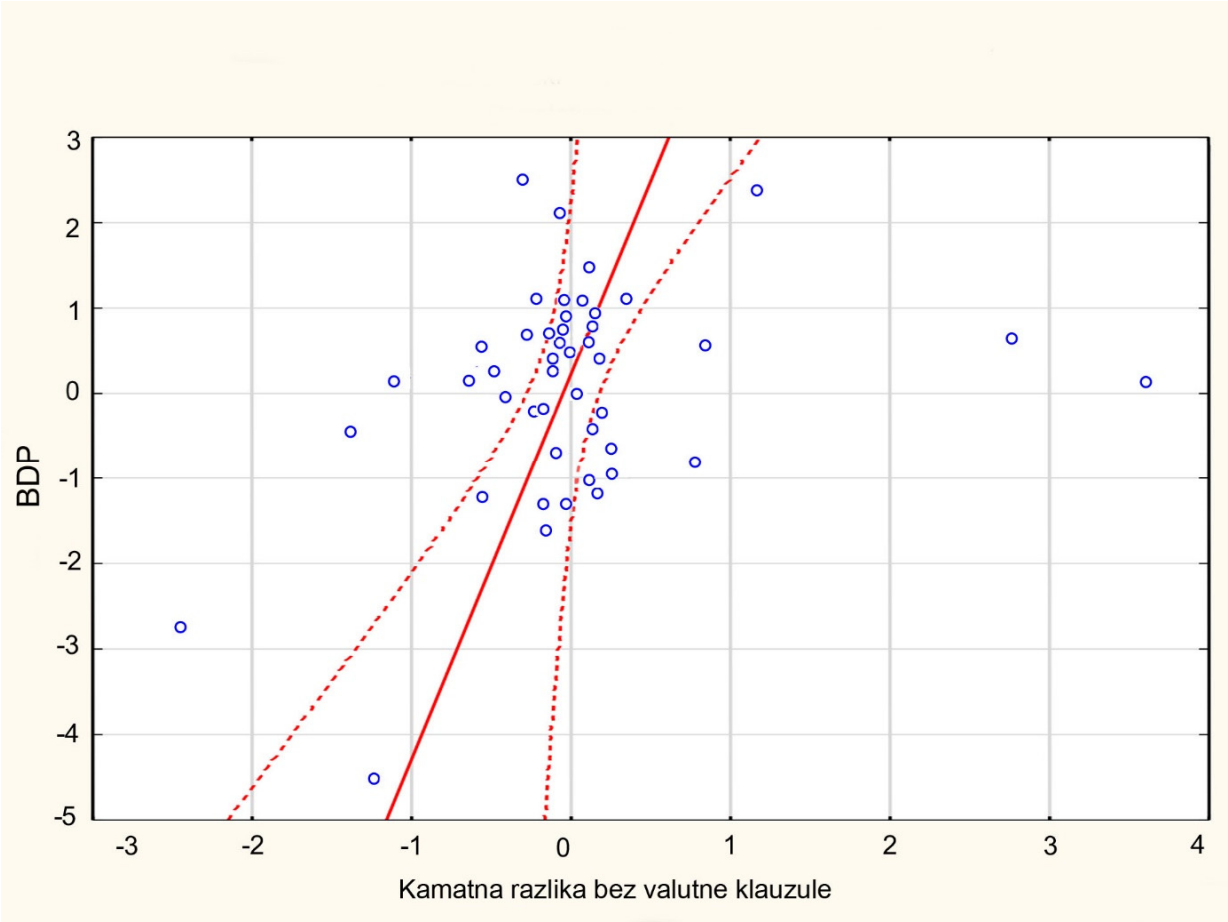
Tablica 4. Pearsonov koeficijent korelacije kamatnih razlika s valutnom klauzulom i bez valutne klauzule i BDP-a

Varijable	Značajne korelacije p < ,05000 N = 52	
BDP	Kamatna razlika s valutnom klauzulom	Kamatna razlika bez valutne klauzule
	-0,036	0,3180*
	p = 0,800	p =0,022

Izvor: Izrada autora, 2020. *p < ,05; **p < ,01

Rezultat upućuje na negativnu korelaciju kamatne razlike s valutnom klauzulom i BDP-a (r = –0,036, p = 0,800). No, s obzirom na vrijednost p, može se primijetiti da ta vrijednost nije statistički značajna. Kada se promatraju vrijednosti kamatne razlike bez valutne klauzule i BDP-a, može se primijetiti da se radi o pozitivnoj korelaciji koja je statistički značajna (r = 0,318, p =0 ,022). Dobiveni rezultat pokazuje da je kretanje kamatnih stopa bez valutne klauzule usklađeno s kretanjem BDP-a.

Dijagram 1. Odnos kretanja kamatnih razlika bez valutne klauzule i BDP-a



Izvor: Izrada autora, 2020.

Regresijski model zapisan matematičkom jednadžbom, tzv. jednadžba pravca regresije glasi:

Kamatna razlika bez valutne klauzule = –0.497+ 0,22160 *BDP

Zavisna varijabla (y): bruto domaći proizvoda

Nezavisna varijabla (x): kamatna razlika bez valutne klauzule

Smjer linearne regresije upućuje na to za koliko se u prosjeku mijenja vrijednost zavisne varijable BDP-a za jediničnu promjenu vrijednosti nezavisne varijable kamatne razlike bez valutne klauzule. Prema dobivenoj jednadžbi, ako kamatna razlika bez valutne klauzule poraste za 0,4 postotna poena u odnosu na prethodni kvartal, može se očekivati rast BDP-a za 0,22 postotna poena.

Iz korelacijske matrice vidljivo je da postoji statistički značajna pozitivna veza između kamatne stope bez valutne klauzule kao nezavisne varijable i BDP-a kao zavisne varijable (r = 0,3180; p = 0,022). Unutar dijagrama rasipanja tzv. scatter dijagrama grafički je prikazan odnos navedenih dviju varijabli. Vrijednosti varijable BDP-a prikazane su na y osi, a vrijednosti varijable kamatne razlike bez valutne klauzule prikazane su na x osi dijagrama. Točke presjeka kreću se oko određenog pravca koji se naziva linija regresije.

Na temelju dijagrama rasipanja uočava se da postoji pozitivna linearna povezanost analiziranih varijabli. Nezavisna varijabla kamatna razlika bez valutne klauzule pozitivno djeluje na kretanje zavisne varijable BDP-a. Što su točke bliže pravcu, korelacija je veća. Koeficijent korelacije r = ,31805 ukazuje na srednje jaku korelaciju ovih dviju varijabla.

5.1.4. Analiza dobivenih rezultata empirijskog istraživanja odnosa kreditnih rizika i makroekonomskih kretanja (H1)

Za analizu poveznice kreditnih rizika i makroekonomskih čimbenika prikupljeni su kvantitativni podaci iz različitih izvora koji su zatim analizirani i sistematizirani. Provođenjem parametrijskih testova utvrdilo se postojanje korelativne veze u kretanju pojedinih varijabli. Uz parametrijske testove za ispitivanje glavne hipoteze u nastavku poglavlja primjenjuje se i metoda kompilacije dobivenih rezultata s radovima drugih autora koji su provodili slična ili ista istraživanja. Istraživanje je obuhvatilo analizu međuovisnosti kamatnih stopa i gospodarskih kretanja od 2007. do 2019. godine u Hrvatskoj. Podaci za analizu prikupljeni su iz dostupnih izvora o kretanju varijabli iz baze podataka HNB-a i Državnog zavoda za statistiku.

Cilj analize bio je utvrditi promjene u „ponašanju“ banaka te ustanoviti ulogu promjena kamatnih stopa (rast i pad kamatnih stopa) u promjenama na gospodarskom tržištu. Željelo se ispitati djeluju li banke svojim politikama na promjene makroekonomskih varijabli.

Učinci promjena u kretanju kamata dovoljno su snažni da proizvedu značajne promjene u kretanju BDP-a. Različiti rizici, potražnja i ponuda za depozitima i kreditima ovisno o kretanju kamatnih stopa, profitabilnost banaka i njihova kvaliteta upravljanja, konkurencija na tržištu, kretanje monetarne politike, likvidnost tržišta te brojni drugi čimbenici imaju učinak na kretanje prikazanih kamatnih stopa na depozite i kredite.

Dobiveni rezultati prikazani su grafički, tablično te pomoću dvodimenzionalnoga grafikona, tzv. scatter dijagrama (dijagrama rasipanja), a za analizu usporedbe kretanja korišten je Pearsonov koeficijent korelacije.

Rezultati analize upućuju na sljedeće:

U skladu s navedenim rezultatima za promatrano razdoblje može se potvrditi da banke prate makroekonomska kretanja, odnosno da je u nekim periodima promatranog razdoblja kretanje kamatnih stopa na novoodobrene plasmane usklađeno s dinamikom kretanja BDP-a, ali s vremenskim odmakom od jednoga kvartala. To znači da su u pojedinim periodima banke reagirale na promjene tržišta prije nego što su se one uistinu i dogodile pa se može zaključiti da poslovne banke reagiraju na promjene tržišta prije nego što se promjene dogode čime one neposredno djeluju na makroekonomska kretanja. Kao posljedica kontinuirane povećane kamatne razlike, dolazi do smanjenja potražnje za novcem što izravno djeluje na sastavne komponente BDP-a; investicije (I) i osobnu potrošnju (C) što automatski povlači za sobom smanjenje prihoda države od poreza pa time i smanjenje komponente potrošnje države (G), a time i do pada BDP-a. Smanjenje razlike kamatnih stopa rezultira povećanjem atraktivnosti pokretanjem investicija u gospodarstvu (I), osobne potrošnje (C) što s vremenskim odmakom dovodi do ponovnog rasta BDP-a.

Pearsonov koeficijent korelacije ukazuje na negativnu korelaciju kamatne razlike s valutnom klauzulom i BDP-a ($r = –0,036$, $p = 0,800$) te statistički značajnu pozitivnu korelaciju kamatne razlike bez valutne klauzule i BDP-a ($r = 0,318$, $p = 0,022$). Dobiveni rezultat ukazuje na to da je kretanje kamatnih stopa bez valutne klauzule usklađeno s kretanjem BDP-a.

Uočena je umjerena korelacija ovih dviju varijabli čime se dokazuje hipoteza da bankarski sustav ima ulogu na kretanje BDP-a. Dakle, bankarski sustav pridonosi rastu dohotka kroz investicije, ali je porast i ostalih komponenti domaće potražnje također potpomognut kreditnom aktivnošću banaka.

U usporedbi dobivenih rezultata empirijskog istraživanja s rezultatima drugih autora koji su u svojim radovima ispitivali poveznicu financijskog sustava i gospodarskog sektora izdvojeni su sljedeći autori i njihovi radovi:

Bogdan i Stipković (2017) u svojem su radu preko nekoliko indikatora profitabilnosti, rizičnosti i kapitaliziranosti hrvatskoga bankovnog sustava zaključili da je financijski razvoj prije krize utjecao na gospodarski rast kroz akumulaciju kapitala, ali i kroz stimulaciju osobne i državne potrošnje. U analizi su koristili varijablu kreditnog rizika koju su ispitali preko kretanja kamatnih rizika i valutno induciranih kreditnih rizika te pokazatelje profitabilnosti banke kao što je povrat na prosječnu imovinu (ROAA), povrat na prosječni kapital (ROAE).

Delić i Rogić-Dumančić (2016) potvrđuju da financijski razvoj u tranzicijskim zemljama pozitivno utječe na rast gospodarstva. Dinamičkim modelom panel analize utjecaja razvoja financijskog sustava na gospodarski rast izvršili su na odabranom uzorku od 11 zemalja Istočne i Srednje Europe u razdoblju od 1995. do 2014. godine. Rezultati analize potvrđuju da financijski razvoj ima signifikantan utjecaj na gospodarski rast. Grizelj (2016) je u svojem radu teorijski i empirijski potvrdio pozitivnu vezu financijskog sustava i gospodarskog rasta. Statističkom analizom dokazan je utjecaj razvijenijih i aktivnijih financijskih sustava na gospodarski rast. Reforme financijskih sustava većine promatranih zemalja utjecale su na razvoj financijskoga sustava i na gospodarski. Prema Grizelju, razvoj financijskog sustava pridonijet će boljoj alokaciji resursa i većem gospodarskom rastu.

Odnos kreditnog rizika i financijskog sustava obrađuju Agnello i Sousa (2013). U radu istražuju djelovanje bankarske krize na raspodjelu dohotka. Dolaze do zaključka da se nejednakost dohotka povećava prije epizoda bankarske krize, a nakon toga naglo opada. Također tvrde da porast kreditne dostupnosti, tj. bolji pristup kreditima koje pruža bankarski sustav, pridonosi ravnomjernijoj raspodjeli dohotka. U analizi su koristili godišnje podatke za 62 zemlje OECD-a i one koje nisu članice OECD-a, u razdoblju od 1980. do 2006. Podatke o veličini vlade, dohotku po stanovniku, financijskom dugu i stopi nezaposlenosti preuzeli su iz baze podataka Svjetske banke. Zaključuju da pad nezaposlenosti i lakši pristup kreditima iz bankarskog sustava omogućuje kućanstvima s nižim dohotkom mogućnost zaduživanja kako bi postigli viši životni standard.

No neka istraživanja potvrđuju nelinearnost između financijske razvijenosti i dohotka odnosno ona postoji ako su zadovoljeni odgovarajući uvjeti. Huang i Lin (2009) potvrđuju pozitivnu vezu od financijskoga razvoja prema gospodarskome rastu koja je ipak izraženija u zemljama s nižim dohotkom. Deidda i Fattouh (2002) utvrđuju pozitivnu vezu između financijskoga razvoja i gospodarskoga rasta koja je izražena u zemljama s visokim dohotkom, dok u

siromašnima nema poveznice. Navedeni radovi, uključujući Zhang i Kim (2016), dokaz su kako primjena drukčijih metoda može dovesti do potpuno različitih zaključaka. Rioja i Valev (2004.a) pokazuju da je najsnažniji pozitivan efekt financijskoga razvoja na rast u zemljama sa srednjim, a nešto slabiji kod onih s visokim stupnjem financijskoga razvoja i nejasan u zemljama niskog stupnja financijskoga razvoja.

U novije vrijeme istraživanja pokazuju da veza između financijskoga razvoja i gospodarskoga rasta postaje slabija ili da čak poprima negativan predznak odnosno da preko određene razine omjera kredita i BDP-a daljnji financijski razvoj djeluje nepovoljno na gospodarski rast (obrnuti U oblik veze) (Bogdan i Stipković, 2017).

Neki su radovi (npr. Demirgüç-Kunt et al., 2013) uputili na promjenu financijske strukture zemalja u korist financijskih tržišta kako zemlja postaje bogatija pa se objašnjenje može tražiti u tom smjeru. Rousseau i Wachtel (2011) primjećuju da je slabljenje važnosti financijskoga razvoja na gospodarski rast povezano s krizama banaka i financijskim krizama.

Arcand et al. (2015) tvrde da snažan financijski sustav može dovesti do odljeva radne snage iz visokoproduktivnih sustava ili poticati ulaganja u manje produktivnim sustavima što može narušiti dugoročan rast. Prema njihovu mišljenju, financijski razvoj nepovoljno djeluje na rast BDP-a nakon što udio kredita privatnome sustavu prekorači 100 % BDP-a.

Iako je učinak financijskog sustava na gospodarski rast obrađen i potvrđen u dosadašnjim istraživanjima, prema novijim rezultatima istraživanja Rousseau i Wachtel (2011) smatraju da taj učinak ipak nije toliko značajan. Pri tome daju nekoliko objašnjenja. Prvo, učestalost financijskih kriza povezana je s prigušivanjem učinka produbljivanja financija na rast. Prekomjerno financijsko produbljivanje ili prebrzi rast kredita možda su doveli do inflacije i do slabljenja bankarskog sustava što je zauzvrat dovelo do financijske krize koja sprječava rast. Prekomjerno financijsko produbljivanje može također biti rezultat široke financijske liberalizacije krajem 1980-ih i početkom 1990-ih u zemljama kojima nedostaje pravna ili regulatorna infrastruktura za uspješno iskorištavanje financijskog razvoja. Također smatraju da liberalizacija nije imala važnu izravnu ulogu u smanjenju učinka financija.

Shen i Lee (2006) u svojem djelu preispituju odnos financijskog razvoja i realnog BDP-a po stanovniku u 48 zemalja. Dolaze do zaključka da jedino razvoj tržišta dionica ima pozitivne učinke na rast, dok pak bankarski razvoj ima nepovoljan, ako ne i negativan učinak na rast.

Rezultati jasno pokazuju da uvjetne varijable financijske liberalizacije, visoka razina prihoda i dobra zaštita dioničara ublažavaju negativne učinke razvoja bankarstva na rast. Suprotno tome, varijable razine dohotka, bankarske i valutne krize, dobra zaštita kreditora i veća korupcija jačaju negativne učinke na rast. Dolaze do zaključka da je odnos rasta i razvoja banke bolje opisan kao slab obrnuti U-oblik. Ovaj obrnuti U-oblik postaje jači kada se dodaju dodatne varijable na tržištu. Dakle, financijski razvoj i rast mogu, zapravo, biti u nelinearnom obliku. S obzirom na navedeno, može se potvrditi hipoteza rada:

H1: Kreditni rizici poslovnih banaka djeluju na makroekonomska kretanja u zemlji.

5.2. Empirijsko istraživanje odnosa makroekonomskog okruženja i stabilnosti bankarskog sustava (H2)

Unutar ovoga poglavlja rada prikazana su makroekonomska kretanja i učinak tih kretanja na bilance banaka, profitabilnosti, sposobnosti banaka na podnošenje rizika te analizu njihove važnosti za monetarnu politiku. Prikazano je pojedinačno kretanje odabranih makroekonomskih varijabli te njihov značaj za bankarski sustav.

Pad financijskih pokazatelja potaknut nestabilnošću makroekonomskog okruženja manifestira se rastom udjela NPL-a u bilancama banke koji zatim djeluju na profitabilnost i razinu adekvatnosti kapitala banke. Prema Miletiću (2008), makroekonomska nestabilnost: visoke i promjenjive kamatne stope, nagli usponi i padovi ekonomske aktivnosti u gospodarstvu i neodržive fiskalne i inozemne pozicije najočitiji su i najizravniji makroekonomski izvori koji nepovoljno utječu na poslovanje banaka zbog negativnog utjecaja na kolebanje cijena i alokaciju financijskih sredstava. Negativna kretanja vrijednosti makroekonomskih agregata izravno ili posredno djeluje na kvalitetu bankarskog sustava. Stoga je nužno da privreda definira adekvatne strategije kako bi se što bezbolnije prilagodila novonastalim nestabilnostima na tržištu, poput svjetske financijske krize, porasta neproduktivnih poduzeća itd. (Mitrović et al., 2016). Stvaranje likvidnosti jedna je od najvažnijih uloga banaka. Stvaranje likvidnosti banaka povezano je s gospodarstvom.

Pregled dosadašnjih istraživanja međuodnosa makroekonomskih varijabli i stabilnosti financijskog sustava kao i provedeno empirijsko istraživanje izneseno je u nastavku rada.

5.2.1. Pregled empirijskih istraživanja odnosa makroekonomskog okruženja i stabilnosti financijskog sustava

S obzirom na to da su u prijašnjim poglavljima ovoga doktorskog rada obrađene empirijske studije vezano uz odnos financijskog sustava i gospodarskog rasta, u ovome poglavlju rada prikazuju se dosadašnja istraživanja vezana uz djelovanje makroekonomskog okruženja na stabilnost financijskog sustava.

Kako bi se omogućio bolji pregled empirijskih istraživanja koja se bave odnosom makroekonomskog okruženja i stabilnosti financijskog sustava, organizirana su na sljedeći način:

a) radovi koji istražuju poveznicu ekonomskih politika i bankarskog sustava
b) radovi koji istražuju poveznicu između monetarne i financijske stabilnosti
c) radovi koji istražuju odnos između poslovnog ciklusa i kreditnog rizika
d) djelovanje inflacije na financijski sustav i međuovisnosti stope nezaposlenosti s kretanjima u financijskom sustavu

a) Utjecaj ekonomskih politika na bankarski sustav

Istraživanjem poveznice neizvjesne ekonomske politike i poslovanja banaka Tran et al. (2021) na velikom uzorku američkih banaka od 2000. do 2017. otkrivaju da će banke vjerojatnije diversificirati svoj tok prihoda u nove aktivnosti koje stvaraju nekamatni prihod usred visoke neizvjesnosti ekonomske politike. Naglašavaju važnost državne potrošnje koja zbog neizvjesnosti ekonomske politike ima značajnu ulogu na poslovne aktivnosti banaka.

Kroz uzorak američkih banaka i indeksa nesigurnosti ekonomske politike koji su razvili Baker et al. (2016), Jin et al. (2019) istražuju je li nesigurnost ekonomske politike sustavno povezana s nepredvidivošću bankarske zarade. Kada je ekonomska politika relativno neizvjesna, upraviteljima banaka je lakše iskriviti financijske informacije, jer nepredvidive promjene ekonomske politike otežavaju procjenu postojanja skrivenih „negativnih vijesti“ za investitore i vjerovnike. Neizvjesnost ekonomske politike također povećava fluktuaciju zarada i novčanih tokova banaka, pružajući tako dodatne poticaje i mogućnosti menadžerima banaka da se bave zaradom. Rezultati pokazuju da je nesigurnost u ekonomskoj politici pozitivno povezana s nepredvidivošću zarade, koja je posljedica veličine diskrecijskih odredbi o gubitku zajma i

vjerojatnosti da će se samo ostvariti ili pobijediti zaradu iz prethodne godine, a negativno povezana s razinom računovodstvene konzervativnosti (tj. pravodobnost prepoznavanja loših vijesti u odnosu na dobre vijesti). Zaključno, njihovi radovi sugeriraju da neizvjesnost ekonomske politike dovodi do veće nepredvidivosti zarade. Također tvrde da je učinak neizvjesne ekonomske politike na krivo financijsko izvještavanje manje izražen za jače banke (tj. banke s visokom kapitaliziranošću).

Ispitivanje poveznice ekonomskih politika i bankarskog sustava na rast kredita analizirali su Danisman, Demir i Ersan (2020). U analizi su se koristili uzorkom od 2977 privatnih i kotiranih banaka u zemljama EU-5 (Ujedinjeno Kraljevstvo, Njemačka, Španjolska, Italija, Francuska) u razdoblju od 2009. do 2018. godine. Rad istražuje neizvjesnosti ekonomske politike i njezin učinak na rast kredita. Njihova otkrića ukazuju na to da nesigurnost u ekonomskim politikama koči kreditni rast europskih banaka. Negativni učinak neizvjesnosti ekonomske politike na rast kredita raste s dospijećem duga i slabi u bankama s većim brojem zaposlenih. Nadalje, nepovoljni učinci jači su u dobro kapitaliziranim bankama, bankama koje posluju u inozemstvu.

Učinak nestabilne ekonomske politike na rast NPL-a u bankama ispitale su autorice Karadima i Louri (2020). Nakon financijske i dužničke krize u eurozoni i kašnjenja u formuliranju kohezivnog odgovora na politike, banke su se suočile s ozbiljnim problemima s najvećim rastom nenaplativih zajmova. Nesigurnost ekonomske politike često je kriva za pokretanje i širenje problematičnih kredita. U ovome istraživanju autorice su analizirale podatke prikupljene iz 507 banaka, četiri glavne države eurozone (Francuska, Njemačka, Italija i Španjolska) od 2005. do 2017. Utvrdile su da nesigurna ekonomska politika ima pozitivan učinak na NPL-ove, ali taj učinak značajno opada u zemljama gdje prevladava veća koncentracija banaka. Autor Sporta (2018) u svojem radu potvrđuje poveznicu između financijske uspješnosti i adekvatnosti kapitala. Korelacijska i panel regresijska analiza utvrdile su da NPL-i imaju značajan učinak na kvalitetu imovine komercijalnih banaka. Rezultati studije ukazuju na pozitivnu vezu između nekvalitetne imovine banke i loše financijske rezultate te predlažu uspostavu dodatnih smjernica bankama za sprječavanje udjela nenaplativih kredita.

Koristeći se podacima na razini banaka u 19 glavnih gospodarstava Hu i Gong (2019) ispitivali su teorije o bankarskom kreditiranju, nesigurnosti ekonomske politike i nacionalnim bonitetnim propisima. Otkrili su da nesigurnost ekonomske politike značajno koči rast bankarskih kredita, ali učinak se razlikuje u bankama. Konkretno, negativni učinak nesigurnosti ekonomske

politike na rast kredita veći je kod velikih i rizičnijih banaka, dok je slabiji kod likvidnih i diversificiranih banaka. Uz to, učinak nestabilne ekonomske politike na zajmove banaka kritično ovisi o nacionalnim bonitetnim propisima, tako da se čini da negativni učinak ublažuje i makrobonitetne i mikroprudencijalne politike.

Djelovanje ekonomske nestabilnosti na rizik banaka ispitala je skupina autora Wu et al. (2020). Koristili su se panel podacima na razini 1500 banaka u 34 gospodarstva u razvoju u razdoblju od 2000. do 2016. Naišli su na dosljedne i snažne dokaze da se bankarski rizik povećava s povećanjem razine ekonomske nesigurnosti. Također su istražili mehanizme kojim se ekonomska nesigurnost prelijeva u bankarski rizik te izložili dokaze da je povezanost nesigurnosti i rizika u bankama više pripisana opcijskoj vrijednosti čekanja, strategijama prinosa i ponašanju banaka nego različitim popratnim efektima.

Berger et al. (2020) ispitali su povezanost ekonomske politike i likvidnosti banaka. Analizom su obuhvatili imovinu, obveze i izvanbilančne aktivnosti. Obradili su uzorak od više od milijun varijabli iz tromjesečnih izvještaja banaka iz cijelog svijeta. Došli su do zaključka da banke kao odgovor na nesigurnosti ekonomske politike zadržavaju likvidnost u cjelini. Ovakvo ponašanje izraženije je u manjim bankama s manje likvidnosti.

Ashraf i Shen (2019) indeksom neizvjesnosti ekonomske politike analiziraju podatke na razini banaka iz 17 zemalja u razdoblju od 1998. do 2012. Otkrili su da neizvjesnost vladine ekonomske politike ima značajnu pozitivnu povezanost s kamatnim stopama na bruto zajmove banaka. Točnije, povećanje standardne devijacije indeksa neizvjesnosti ekonomske politike dovodi do porasta prosječnih kamatnih stopa na bruto zajmove banaka za 21,84 bazna boda. Može se pretpostaviti da nesigurnost ekonomske politike povećava cijene zajmova banaka povećavajući rizik neplaćanja zajmoprimaca. Njihovi rezultati sugeriraju da je neizvjesnost vladine ekonomske politike ekonomski važan čimbenik rizika za određivanje cijena kredita banaka.

U tablici 6. dan je pregled odabranih empirijskih istraživanja uloge ekonomskih politika na bankarski sustav ili na njegove određene dijelove.

Tablica 6. Pregled empirijskih istraživanja uloge ekonomskih politika na bankarski sustav ili na njegove određene dijelove

Godina	Autor	Naziv	Metodologija	Zaključak
2020.	Danisman, Demir i Ersan	Economic policy uncertainty and bank credit growth: Evidence from European banks	Analiziran je učinak neizvjesnosti ekonomske politike na rast kredita.	Nesigurnost u ekonomskim politikama koči kreditni rast europskih banaka.
2020.	Berger, Guedhami, Kim, Li	Economic Policy Uncertainty and Bank Liquidity Hoarding	Analiziran je učinak nesigurne ekonomske politike na likvidnost banaka.	Banke kao odgovor na nesigurnosti ekonomske politike zadržavaju likvidnost u cjelini.
2019.	Ashraf, Shen	Economic policy uncertainty and banks' loan pricing	Analiziran je učinak nesigurne ekonomske politike s kamatnim stopama na bruto zajmove banaka.	Povećanje standardne devijacije indeksa neizvjesnosti ekonomske politike dovodi do porasta prosječnih kamatnih stopa na bruto zajmove banaka.
2020.	Viet Tran,Hoang, Nguyen	How does economic policy uncertainty affect bank business models?	Analiziran je učinak neizvjesne ekonomske politike na poslovanje banaka.	Banke će usred visoke neizvjesnosti ekonomske politike diversificirati svoj tijek prihoda u nove aktivnosti koje stvaraju nekamatni prihod.
2019.	Jin, Kanagaretnam, Liu, Lobo	Economic policy uncertainty and bank earnings opacity	Istražuje se učinak nesigurne ekonomske politike na neizvjesnost zarade u bankama.	Nesigurnost u ekonomskoj politici pozitivno povezana s nepredvidivošću zarade.
2020.	Karadima, Louri	Economic policy uncertainty and non-performing loans: The moderating role of bank concentration	Analiziran je učinak nesigurne i ekonomske politike na rast neprihodonosnih kredita.	Nesigurnost ekonomske politike često je kriva za pokretanje i širenje problematičnih kredita.
2019.	Hu i Gong	Economic policy uncertainty, prudential regulation and bank lending	Analizirane su teorije o bankarskom kreditiranju, nesigurnosti ekonomske politike i nacionalnim bonitetnim propisima.	Negativni učinak nesigurnosti ekonomske politike na rast kredita veći je kod velikih i rizičnijih banaka, dok je slabiji kod likvidnijih banaka i diversificiranijih banaka; učinak nesigurne ekonomske politike na zajmove banaka kritično ovisi o nacionalnim bonitetnim propisima.
2020.	Wu,Yao Yao, Minghua Chen, Bang i Nam Jeon	Economic uncertainty and bank risk: Evidence from emerging economies	Analiziran je učinak ekonomske nesigurnosti na rizik banaka	Bankarski rizik povećava se s povećanjem razine ekonomske nesigurnosti.

Izvor: Izrada autora, 2020.

b) Poveznica između monetarne i financijske stabilnosti

Poveznicu između monetarne i financijske stabilnosti u svojem radu obrađuju autori Granville i Mallick (2009). U analizi upotrebljavaju vremensku dimenziju kamatnih stopa, cijene dionica, kretanje deviznih tečajeva, rast cijena nekretnina, omjera depozita i zajma bankarskog sustava te promjene na razini potrošačkih cijena i stope politike ECB-a. VaR pristupom otkrivaju da postoji prociklična veza između monetarne i financijske stabilnosti na duge staze. Smatraju da politika kamatnih stopa koja se koristi za ciljanje inflacije djeluje na financijsku stabilnost zemlje.
S pomoću Taylorova pravila, Castro (2012) uspostavlja jednostavnu linearnu vezu između kamatne stope, inflacije i proizvodnog jaza. Reakcijama monetarne politike, ovaj rad analizira može li se monetarna politika središnjih banaka doista opisati linearnim Taylorovim pravilom ili, umjesto toga, nelinearnim pravilom. Rezultati upućuju na to da se monetarno ponašanje Europske središnje banke i Engleske banke najbolje opisuje nelinearnim pravilom, ali ponašanje Federalnih rezervi SAD-a može se dobro opisati linearnim Taylorovim pravilom.

Autor Saeed (2014) regresijskom i korelacijskom analizom provedenom na temelju prikupljenih podataka banaka u UK, dolazi do zaključka da veličina banke, omjer kapitala, zajam, depoziti, likvidnost i kamatna stopa pozitivno djeluje na ROA i ROE, dok BDP i stopa inflacije imaju negativan učinak.

c) Odnos između poslovnog ciklusa i kreditnog rizika

U novijoj bankarskoj literaturi (Sovilj, 2020; Lazić, 2020; Antoun et al., 2021; Gregoriou et al., 2021) odnos između poslovnog ciklusa i kreditnog rizika (tzv. cikličnost kreditnog rizika) analiziran je i za potrebe makrofinancijske stabilnosti i za mikroupravljanja rizikom. Zapravo, potencijalni učinci gospodarskog razvoja na portfelje banaka relevantni su za predviđanje i sprječavanje nestabilnosti banaka u nepovoljnim ekonomskim uvjetima kao i za planiranje potencijalnih rizika unutar banaka. Bazelski sporazumi o kapitalu banaka jasno propisuje da se mora podudarati mikro- i makrodimenzija rizika.

Virolainen (2004) analizira makroekonomski model kreditnog rizika za finski korporativni sustav. Razdoblje analize uključuje ozbiljnu recesiju sa znatno višim stopama neplaćanja u

ranim 1990-ima. Rezultati sugeriraju značajnu povezanost stopa neplaćanja u korporacijskom sustavu i ključnih makroekonomskih čimbenika, uključujući BDP, kamatne stope i zaduživanje poduzeća. Procijenjeni model koristi se za analizu kreditnih rizika poduzeća koji ovise o trenutačnim makroekonomskim uvjetima. Nadalje, rad predstavlja primjene modela na makrotestiranje otpornosti na stres, tj. analizu učinaka različitih nepovoljnih makroekonomskih događaja na kreditne rizike banaka koji proizlaze iz korporacijskog sustava. Rezultati stres testova sugeriraju da su kreditni rizici finskoga korporativnog sustava prilično ovisni o trenutačnom makroekonomskom okruženju.

Studija financijske stabilnosti postala je temelj moderne makroekonomske politike, posebno za razvijene zemlje. Globalna financijska kriza naglasila je važnost razumijevanja financijske nestabilnosti, posebno u kontekstu upravljanja kreditnim rizikom, s posebnim naglaskom na bankarski sustav. Stoga je ključna motivacija rada autorima Ali i Daly (2010) poboljšanje razumijevanja modeliranja kreditnog rizika na razini zemlje, posebno u okviru standarda adekvatnosti kapitala Basel II. Cilj studije je istražiti interakciju između cikličnih implikacija agregatnih zadanih vrijednosti u gospodarstvu i temeljnoga kapitala banke. Primijenjen pristup zahtijevao je autorima izgradnju makroekonomskoga kreditnog modela koji pruža okvir za provođenje analize scenarija. U radu je provedena usporedna analize dviju zemalja, relativno imune ekonomije Australije i najgore pogođene ekonomije SAD-a. Ključna pitanja postavljena u studiji su važnost makroekonomskih varijabli za obje zemlje te djelovanje nepovoljnih makroekonomskih šokova na stope neplaćanja u obje zemlje. Rezultati pokazuju da isti skup makroekonomskih varijabli prikazuje različite stope zadanih vrijednosti za dvije zemlje. Uz to, studija otkriva da je u usporedbi s Australijom američko gospodarstvo mnogo osjetljivije.

Pejić Bach et al. (2009) u svojem su radu primijenili regresijsku metodu kojom su utvrdili i istražili determinante profitabilnosti hrvatskih banaka, pri tome su posebno analizirali čimbenike okruženja (bruto domaći proizvod, inflacija, tečaj), kao i čimbenike specifične za svaku banku (veličina bilance, struktura prihoda i troškova). Rezultate istraživanja usporedili su s istraživanjem koje su proveli Demirguc-Kunt i Levine (2001) te su posredno dokazali da se može potvrditi pretpostavka o ujednačenosti hrvatske bankarske prakse i njihove poslovne politike s praksom i poslovnom politikom banaka u razvijenim zemljama. Podaci o pokazateljima poslovanja banaka i makroekonomskim pokazateljima združeni su u jednu seriju te je u analizi korištena serija sa svim opažanjima. Drugim riječima, proveden je „pooling“ vremenskih presjeka. Empirijski rezultati regresijskog modela pokazuju da je profitabilnost

hrvatskih banaka u promatranom razdoblju od 1999. do 2005. ovisila ponajprije o karakteristikama specifičnim za svaku banku, premda stopa rasta bruto domaćeg proizvoda ima pozitivan učinak na stopu profitabilnosti imovine banke (ROA). U skladu s rezultatima provedenog istraživanja može se zaključiti da su u kratkom roku i stabilnim makroekonomskim uvjetima profitabilnije slabije kapitalizirane banke s većim tržišnim udjelom koje učinkovito upravljaju operativnim troškovima te imaju nizak udjel „neprihodujuće" imovine čije troškove uspješno prevaljuju na svoje komitente njihovim uključivanjem u cijenu kredita banaka i drugih usluga. Zaključno, ovo istraživanje potvrdilo je uobičajene pretpostavke o učinku pojedinih standardiziranih varijabli na računovodstvene pokazatelje profitabilnosti banaka ROA i ROE u hrvatskome bankarskom sustavu. Time se posredno dokazuje i pretpostavka o ujednačenosti hrvatske bankarske prakse, kao i njihove poslovne politike s bankama u drugim zemljama na čijim su bankarskom sustavima provedena prethodna istraživanja.

d) Uloga makroekonomskih čimbenika na likvidnost banaka

O odnosu BDP-a i likvidnosti banaka autori imaju različite stavove. Neki autori dokazali su postojanje poveznice u kretanju BDP-a i likvidnosti banaka, dok drugi u svojim analizama dokazuju da ne postoji poveznica tih dviju varijabli.

Mahmood et al. (2019) u svojoj studiji ispituju učinak vanjskih čimbenika na likvidnost banaka u razdoblju od 2000. do 2017. U analizi se koriste makro specifičnim čimbenicima: BDP, inflacija, monetarna politika i nezaposlenost, a za bankarske čimbenike uzeli su bankarske krize, veličinu banke, ukupni depozit i profitabilnost banaka. Rezultati analize otkrivaju da makroekonomski čimbenici značajno djeluju na likvidnost banaka. Empirijski rezultati pokazali su da ukupni depoziti, BDP, veličina banke i nezaposlenost negativno djeluju na likvidnost banke, a monetarna politika, bankarska kriza i profitabilnost pozitivno djeluje na likvidnost. Inflacija ima beznačajnu vezu s likvidnošću. Da se razina problematičnih kredita može pripisati i makroekonomskim uvjetima i specifičnim čimbenicima banaka u svojem radu objašnjava autor Klein (2013). Iako je utvrđeno da problematični krediti odgovaraju na makroekonomske uvjete, poput rasta BDP-a, nezaposlenosti i inflacije, analiza također pokazuje da postoji snažna povratna veza između bankarskog sustava i realne ekonomije, što sugerira da visok udio NPL-a u mnogim zemljama CESEE-a negativno djeluje na rast gospodarskog oporavka. Kako u svojem radu navodi Ozili (2019), učinkovitost banke, omjer pokrića gubitka, konkurencija i stabilnost bankarskog sustava obrnuto su povezani s NPL-om.

Nenaplativi krediti pozitivno su povezani s bankarskom krizom i koncentracijom banaka dok su negativno povezani s regulatornim kapitalom i likvidnošću banaka, što implicira da bankarski sustav s većim regulatornim kapitalom i višim stupnjem likvidnost ima manje problematičnih kredita u svojoj bilanci.

Prateći makrovarijable kao što je godišnja stopa rasta bruto domaćeg proizvoda, javni dug kao postotak bruto domaćeg proizvoda i nezaposlenost te mikrovarijable kao što je omjer zajmova i depozita, prinos na imovinu, povrat na kapital, Makri et al. (2014) u sklopu svojega rada istražuju koji od navedenih čimbenika određuju NPL na ukupnoj razini. Njihovi nalazi otkrivaju snažne korelacije između NPL-a i različitih makroekonomskih varijabli (javni dug, nezaposlenost, postotak bruto domaćeg proizvoda) i poveznicu varijabli specifičnih za banke (omjer adekvatnosti kapitala, stopa nenaplativih zajmova iz prethodne godine i povrat na kapital).

Analizirajući uzorak podataka prikupljenih u 75 zemalja, Beck et al. (2013) potvrđuju da na omjere NPL-a učinak imaju sljedeće varijable: realni rast BDP-a, cijene dionica, tečaj i kamatna stopa na pozajmice. U slučaju deviznih tečajeva, smjer učinka ovisi o opsegu deviznoga kreditiranja neosiguranih zajmoprimaca.

Dimitrios et al. (2016) analizom tromjesečnih podataka banaka iz europodručja u razdoblju od 1990. do 2015. utvrdili su da su makrovarijable poput stope nezaposlenosti i gospodarskog rasta međusobno povezane. Nadalje, varijable specifične za banke, a povezane s upravljanjem unutar banaka djeluju na buduće kretanje NPL-a.

Stvaranje likvidnosti jedna je od najvažnijih uloga banaka u gospodarstvu. Banka stvara likvidnost preko zajmova, depozita, izvanbilančnih garancija, derivata te putem ostalih bilančnih i izvanbilančnih aktivnosti. Stvaranje likvidnosti u bankama teorijski je povezano s gospodarstvom. Bankarski zajmovi posebno su značajni onim klijentima i industrijama koje nemaju mogućnost financiranja na tržištu kapitala. U sklopu svojeg rada autori Berger i Sedunov (2016) analiziraju je li stvaranje likvidnosti banaka, statistički i ekonomski, pozitivno povezano s ekonomskom proizvodnjom (BDP). Prilikom analize obuhvatili su razdoblje prije i za vrijeme financijske krize. Došli su do zaključka da su učinci stvaranja likvidnosti u odnosu na BDP po stanovniku veći za vrijeme gospodarske kriza nego u normalnim vremenima. Proučavajući dinamiku odnosa na razini države otkrivaju da su učinci stvaranja likvidnosti najveći u industrijama koje ovise o bankama.

Aspachs et al. (2005) u svojem radu otkrivaju da su rezerve likvidnosti banaka protuciklične. Drugim riječima, banke stvaraju rezerve likvidnosti u razdobljima slaboga gospodarskog rasta, a zatim te rezerve povlače u razdobljima snažnoga gospodarskog rasta.

Chen et al. (2014) također potvrđuju negativnu poveznicu likvidnosti banaka i kretanja BDP-a. Istražuju čimbenike koji djeluju na veličinu rezerve likvidnosti u bankama te prate dinamiku kreditiranja u bankama, obilježja banaka, makroekonomske osnove i regulatornu politiku na likvidnost banaka. Rezultati rada sugeriraju da svi čimbenici značajno djeluju na razinu likvidnosti banaka. Monetarna politika negativno djeluje na razinu likvidnosti. Potražnja za likvidnošću je protuciklična, stvaranje likvidnosti banaka u suprotnosti je s poslovnim ciklusom, a razina rezerve likvidnosti banaka raste u razdoblju krize.

e) Djelovanje inflacije na bankarski sustav i međuovisnosti stope nezaposlenosti s kretanjima u financijskom sustavu

Radovi Vodove (2011) i Belete (2013) pokazuju da je stopa inflacije pozitivno povezana s likvidnošću banke. S druge strane, studije Horwath et al. (2012) pokazale su da je stopa inflacije negativno povezana s likvidnošću banke. U svojim radovima autori prikazuju da kapital negativno uzrokuje Grangerovo stvaranje likvidnosti, ali i uočavaju da Grangerovo stvaranje uzrokuje smanjenje kapitala. Ova otkrića podupiru stajalište u kojem reforme Basela III zahtijevaju veći kapital, mogu smanjiti stvaranje likvidnosti, ali i da veće stvaranje likvidnosti može imati štetan učinak na smanjenje solventnosti banaka.

Koriste li se „zamke likvidnosti“ za ciljanje inflacije kao jedne od strategija monetarne politike, u svojem radu analizira McCallum (2001). On tvrdi da ciljana inflacija nije zamka likvidnosti, odnosno nije značajna za likvidnost. Također, naglašava da ako je uobičajeni instrument kamatne stope imobiliziran zamkom likvidnosti, još uvijek postoji tečajni kanal pomoću kojeg monetarna politika može imati stabilizacijske učinke, a relevantna ciljana varijabla i dalje može biti stopa inflacije.

Barro (1995) je istraživao djelovanje inflacije na ekonomski razvoj. U analizi za procjenu učinaka inflacije na gospodarske performanse uzeo je u obzir bazu podataka za stotinjak zemalja u razdoblju od 1960. do 1990. Ako se određen broj varijabli u zemljama obuhvaćenih analizom ne promijeni, tada rezultati regresije upućuju na to da učinci povećanja prosječne inflacije za 10 postotnih bodova godišnje smanjuju stope rasta realnog BDP-a po stanovniku za

0,2 – 0,3 postotna boda godišnje, dok se omjer ulaganja u BDP-u smanjuje za 0,4 – 0,6 postotnih bodova. Iako se nepovoljno djelovanje inflacije na ekonomski rast čini malim, dugoročni učinci inflacije imaju značajan učinak na životni standard. Primjerice, procjena pomaka u monetarnoj politici koja povisuje dugoročnu prosječnu stopu inflacije za 10 postotnih bodova godišnje smanjuje razinu stvarnog BDP-a nakon 30 godina za 4 – 7 %.

O odnosu stope nezaposlenosti i kretanja likvidnosti, a time i djelovanje na stabilnost financijskog sustava dosta je objavljenih radova. Povećanje javne likvidnosti kroz veću ponudu stvarnih državnih obveznica povećava stvarnu kamatnu stopu, istiskujući privatnu likvidnost i povećavajući nezaposlenost (Rocheteau i Rodriguez-Lopez, 2014). Ako je nezaposlenost visoka, održavanje likvidnosti može biti socijalno prihvatljiva. U gospodarstvu u kojem kućanstva štede zbog straha od rizika nezaposlenosti, stvara se pad ukupne potražnje i potrošnje, a time i rast nezaposlenosti.

Ekonometrijske procjene podupiru predviđanje da su uvjetna varijanca nezaposlenosti i stopa inflacije pozitivno povezani (Ruge-Murcia, 2003). Gospodarska nesigurnost čini važnu poveznicu između stope nezaposlenosti i inflacije (Wieland, 2003). Nesigurnost djeluje na kreiranje i smjer monetarne politike.

Postoji pozitivna veza između likvidnosti banaka i adekvatnosti kapitala te udjela NPL-a i kretanja kamatnih stopa (Vodová, 2011), a utvrđen je negativan efekt stope inflacije, poslovnih ciklusa i financijske krize na likvidnost.

5.2.2. Podaci i metodologija

U sklopu ovoga poglavlja doktorskog rada prezentiraju se podaci i metodologija za obranu glavne hipoteze rada koja glasi:

H2: Makroekonomska kretanja djeluju na kreditne rizike u poslovnim bankama.

Cilj ovoga istraživanja je analizirati kretanja makroekonomskih čimbenika i njihovo djelovanje na bankarski sustav. Provedena analiza ispituje jesu li ove nestandardne mjere bile uspješne u poticanju kreditiranja odnosno na koje su bankarske poslovne modele imale efekt. Da li i na koji način makroekonomske varijable djeluju na bankarske aktivnosti, na odluke investitora za ulaganje, na odluke banaka za plasiranje sredstava te na kretanje likvidnosti banaka. Kreditna ekspanzija veća je u vrijeme ekonomske ekspanzije. Veća potražnja potiče banke na širenje portfelja u vidu novih proizvoda i usluga. Slično tome, tijekom gospodarskog pada javlja se pad kreditne aktivnosti. Stoga je za očekivati da će banke tijekom gospodarskog procvata povećavati svoje aktivnosti usmjerene na jačanje likvidnosti i profitabilnosti.

Po uzoru na druge autore koji su ispitivali poveznicu makroekonomskih varijabli i financijskog sustava, Messai i Jouini, 2013; Ahmad et al., 2016; Mazreku, et al., 2018, Levine 1997; Granville i Mallick, 2009; Castro, 2012. te Agnello i Sousa, 2013. i drugi, uz određene prilagodbe, provodi se empirijska analiza izabranih makroekonomskih i bankarskih varijabli: NPL, BDP-a, inflacija, kretanje kamatnih stopa.

Među najznačajnijim makroekonomskim agregatima koji definiraju financijske rezultate bankarskog sustava izdvajaju se: bruto domaći proizvod (BDP), tečaj, visina inflacije i visina referentne kamatne stope.

Da bi se postigao željeni cilj, za analizu su korištene varijable prikupljene iz javno dostupnih baza podataka o poslovanju banaka u Hrvatskoj od 2007. do 2019. godine kao i kretanje makroekonomskih varijabli u razdoblju od 2007. godine do 2019. godine. Radi se o bazama podataka Hrvatske narodne banke – HNB-a i Državnog zavoda za statistiku. Podaci su prikupljeni za razdoblje od 2007. do 2019. godine kako bi obuhvatili razdoblje prije, tijekom i nakon financijske krize. Ove se kvantitativne informacije temelje na neovisnim i ovisnim čimbenicima koji upućuju na bankarske, industrijske i makroekonomske odrednice profitabilnosti bankarskog sustava Hrvatske.

Za potrebe analize u kategoriji **bankarskih varijabli** korišteni su sljedeći pokazatelji:

- udio NPL-a u ukupnim kreditima banaka
- kretanje kamatnih razlika s valutnom klauzulom
- kretanje kamatnih razlika bez valutne klauzule
- kretanje plasmana banaka.

Za makroekonomske varijable korištene su sljedeće varijable:

- bruto domaći proizvod: BDP
- stopa inflacije
- stopa nezaposlenosti.

Dosadašnji radovi drugih autora (Ghosh, 2019; Žiković et al., 2015; Škarica, 2013; Louzis et al., 2012, Beck et al., 2013) pokazali su da *nenaplativi zajmovi* ili NPL-i imaju negativan efekt na banke i razvoj gospodarstva. Rast portfelja ovih kredita značajna je financijska briga bankarskog sustava. Rast udjela nekvalitetnih zajmova negativno djeluje na likvidnost banaka.

Podaci o kretanju NPL-a kroz godine preuzeti su sa službene stranice HNB-a iz statističke baze podataka o kretanju djelomično nadoknadivih i potpuno nenadoknadivih kredita u ukupnim kreditima (raspoloživi podaci od 2008. do 2016. godine) te podaci o udjelu NPL-a u ukupnim kreditima za razdoblje od 2016. do 2019. godine također su preuzeti sa službene stranice HNB-a (promijenjena metodologija). Za analizu podataka korištene su kvartalne veličine kretanja NPL-a po godinama.

Plasmani su financijska imovina u pojavnom obliku odobrenih kredita, dužničkih instrumenata i drugih potraživanja koje kreditna institucija u skladu sa svojim poslovnim politikama klasificira u kategorije financijskih instrumenata koje su prema Međunarodnom računovodstvenom standardu 39 Financijski instrumenti: priznavanje i mjerenje (u nastavku teksta: MRS 39) nazvane: „zajmovi i potraživanja“ i „ulaganja koja se drže do dospijeća“.

Osim glavnice plasmanom se smatraju kamate po nominalnoj kamatnoj stopi i sve provizije i naknade odnosno kamatni prihod u cjelini koji se odnosi na pojedini financijski instrument. (HNB, NN 001/2009.)

Podaci o kretanju plasmana banaka preuzeti su sa službene stranice HNB-a iz statističke baze podataka o kretanju monetarnih i kreditnih agregata. Kretanje plasmana iskazano je na mjesečnoj osnovi, a za ovu analizu kretanje je svedeno na kvartalne veličine.

BDP je bruto domaći proizvod koji predstavlja ekonomski rast. Kretanje nacionalnog BDP-a prema gore ili dolje ima pozitivan ili negativan učinak na profitabilnost banaka. Podaci o kretanju BDP-a, odnos prema prethodnom tromjesečju, preuzeti su iz baze podataka Državnog zavoda za statistiku. Radi analize prikazane su kvartalne promjene u kretanju BDP-a u odnosu na prethodno tromjesečje.

Kamata je cijena kredita odnosno depozita (prinos na depozit), koja ovisi o nominalnom iznosu kredita (glavnici), odnosno iznosu depozita, načinu i roku njegova povrata te visini ugovorene ili propisane kamatne stope, a predstavlja naknadu koju dužnik plaća za pozajmljenu glavnicu na određeno vrijeme (HNB, NN, 1/09 i 41/09).

Kamatna stopa je relativni broj p koji pokazuje koliki prinos donosi svota od 100 novčanih jedinica u određenom razdoblju (obračunsko razdoblje ili termin), odnosno kamatna stopa je iznos kamata za 100 novčanih jedinica, za određenu vremensku jedinicu. (HNB, NN broj 1/2009. i 41/2009).

Kamatne razlike s valutnom klauzulom i bez valutne klauzule također djeluju na likvidnost banaka. Kao što je objašnjeno u prethodnim poglavljima rada, granična kamatna stopa predstavlja razliku između bruto troškova koje plaća dužnik u banci i neto povrat koji je primio deponent. Što je granična kamatna stopa veća, banke će plasirati više sredstava. Ovo je još jedan izvor prihoda banaka i stoga ima pozitivan odnos s profitabilnošću banaka. Za analizu unutar ovoga rada korištene su razlike kamatnih stopa na novoodobrene kredite i novoodobrene depozite posebno za kredite i depozite s valutnom klauzulom, a posebno za kredite i depozite bez valutne klauzule (granične marže). Nakon izračunatih veličina o kvartalnom kretanju graničnih marži s valutnom klauzulom i bez valutne klauzule, za potrebe analize izračunate su promjene u kretanju granične marže u odnosu na prethodni kvartal posebno za graničnu maržu bez valutne klauzule, a posebno s valutnom klauzulom. Podaci o kretanju kamatnih stopa na kredite i depozite preuzeti su iz baze podataka sa stranice HNB-a.

Prema Europskoj središnjoj banci, *stopa inflacije* znači brzinu promjene cijene bilo koje robe. Inflacija je u obrnutom odnosu s profitabilnošću, jer porast inflacije znači smanjenje

profitabilnosti banaka zbog viših cijena. Za ovu analizu podaci o kretanju inflacije na kvartalnoj bazi preuzeti su sa stranice Državnog zavoda za statistiku.

Kretanje inflacije također djeluje na dinamiku kretanja kreditne aktivnosti financijskih institucija, a time i na likvidnost. Inflacija smanjuje stopu povrata ne samo u novčanom smislu već i na imovini općenito. Smanjenje povrata djeluje negativno na kreditno tržište, odnosno banke u inflaciji nisu sklone pozajmljivati sredstva što dovodi do pada investicija i negativne raspodjele resursa na tržištu. Banke ne plasiraju svoja sredstva jer značajno gube na cijeni što dovodi do rasta likvidnosti jer zadržavaju sredstva neraspoređena.

U skladu s Državnim zavodom za statistiku *stopa nezaposlenosti* u ekonomskim terminima podrazumijeva nezaposlene osobe starije od 16 godina koje su sposobne i voljne raditi i aktivno traže posao, ali su bez posla. Stopa nezaposlenosti je broj nezaposlenih radnika podijeljen s ukupnim brojem radno sposobnog stanovništva (radno sposobnim stanovništvom smatraju se osobe između 16 i 65 godina).[14] Podaci o kretanju stope nezaposlenosti preuzeti su sa stranice Hrvatskoga zavoda za statistiku također na kvartalnoj osnovi.

Rast stope nezaposlenosti negativno djeluje na kreditnu aktivnost banke, a time i na likvidnost. Rastom stope nezaposlenosti, veći je kreditni rizik, odnosno porast NPL-a, a time dolazi do pada likvidnosti.

Grafički su prikazana kretanja promatranih varijabli kako bi se omogućio detaljan uvid u moguće poveznice pojedinih varijabli i njihovih kretanja.

Radi određivanja intenziteta i smjera povezanosti makroekonomskih varijabli (BDP-a, stope inflacije, stope nezaposlenosti) i bankarskih varijabli (NPL-a, kamatne razlike s valutnom klauzulom, kamatne razlike bez valutne klauzule, plasmana) provedena je korelacijska analiza i izračunat je Pearsonov koeficijent korelacije. Za varijable kod kojih je dobivena statistički značajna povezanost izračunata je i jednadžba pravca regresije te su podaci prikazani dijagramima rasipanja.

[14] https://www.dzs.hr/

5.2.3. Empirijsko testiranje odnosa makroekonomskog okruženja i stabilnosti bankarskog sustava (H2)

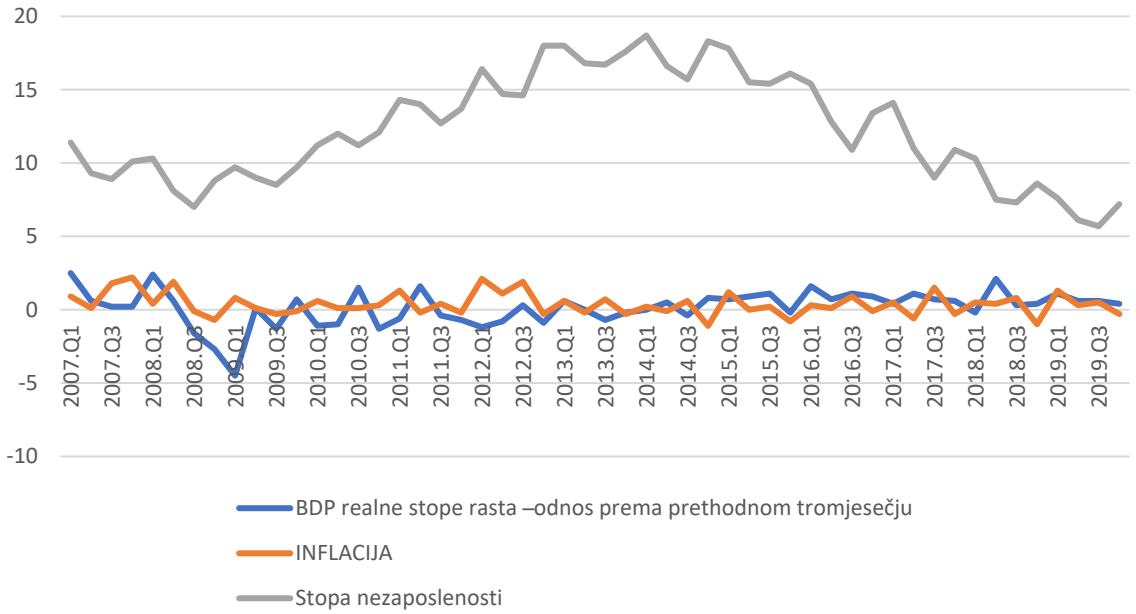
U prijašnjim poglavljima rada ispitivana je uloga kreditnih rizika na makroekonomske promjene u Hrvatskoj, odnosno analizom podataka o kretanju kamatnih razlika s valutnom klauzulom i bez valutne klauzule i BDP-a potvrđena je hipoteza da kreditni rizici financijskih institucija djeluju na kretanja u gospodarstvu Hrvatske.

U ovome poglavlju rada analiziraju se kretanja makroekonomskih čimbenika i njihovo djelovanje na bankarski sustav.

Praćenje kretanja navedenih varijabli u razdoblju od 2007. do 2019. godine te usporedba pojedinih kretanja omogućuje detaljni uvid u moguće poveznice pojedinih varijabli i njihovih kretanja. Podaci za analizu prikupljeni su iz dostupnih izvora o kretanju varijabli iz baze podataka HNB-a i Državnog zavoda za statistiku. Brojčani podaci o kretanju varijabli prikazani su u Prilogu 4., grafički prikaz kretanja makroekonomskih varijabli predočen je na grafikonu 9., a prikaz bankarskih varijabli na grafikonu 10.

Grafikon 9. prikazuje kretanje izabranih makroekonomskih varijabli BDP-a, inflacije i stope nezaposlenosti po kvartalima u razdoblju od 2007. do 2019. godine u Hrvatskoj.

Grafikon 9. Kretanje makroekonomskih varijabli u Hrvatskoj po kvartalima od 2007. do 2019. godine

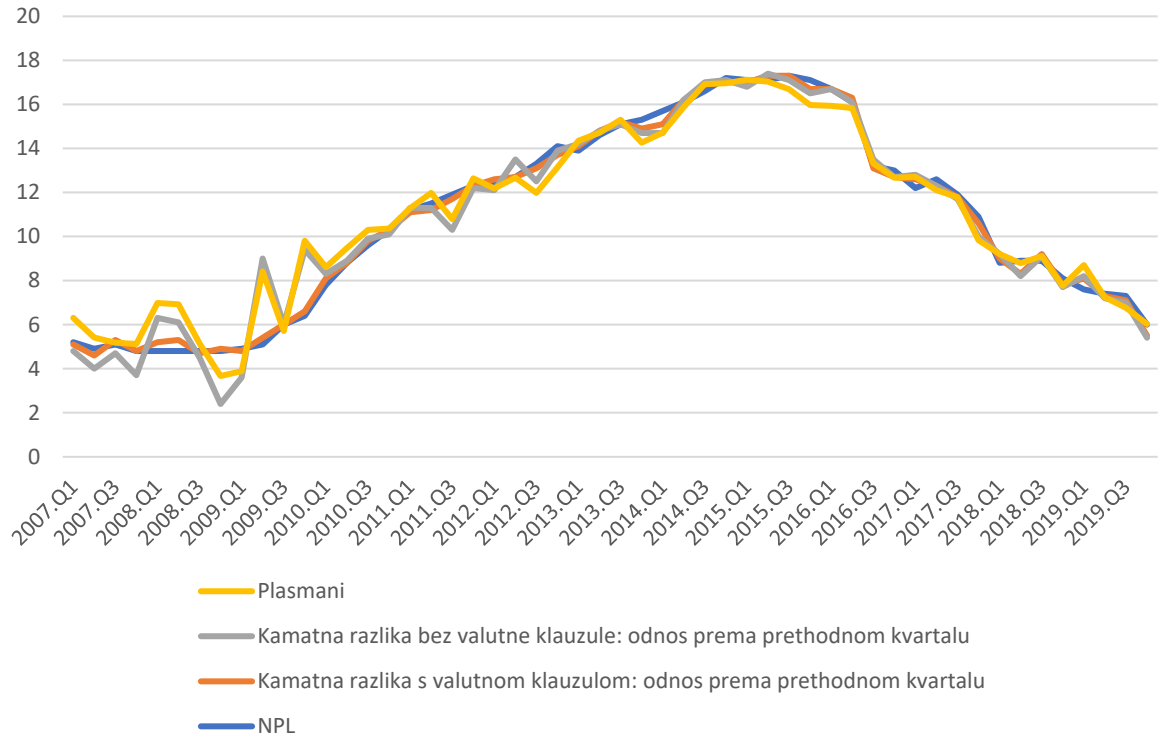


Izvor: Izrada autora, 2020.

Prvo značajnije odstupanje u trendu kretanja svih triju varijabli zabilježeno je 2009. godine zbog nastupa globalne financijske krize. Godine 2009. zabilježen je značajan pad BDP-a, rast inflacije (za čak 1,1 postotni poen) kao i rast stope nezaposlenosti za 2,7 postotna poena. Najniža stopa BDP-a zabilježena je u Q1 2009. godine kad je zabilježen pad od 6,4 postotna poena da bi se već u Q3 zabilježio rast stope BDP-a. Negativna stopa rasta BDP-a zabilježena je još u zadnjem kvartalu 2010. godine (-1,3 %). Nakon 2009. godine stopa nezaposlenosti bilježi uzlazan trend kretanja (uz manja odstupanja) i postiže maksimalnu vrijednost u Q1 2014. godine (18,7 %). Nakon 2014. godine zabilježen je silazni trend te je u Q3 2019. godine zabilježen pad stope nezaposlenosti za 5 postotnih poena. U trendu kretanja inflacije najveća stopa zabilježena je u prvom kvartalu 2012. godine kada je iznosila (2,1 %), dok je najniža stopa inflacije zabilježena u Q4 2014. godine nakon oporavka gospodarstva od globalne krize.

Na grafikonu 10. prikazano je kretanje bankarskih varijabli u razdoblju od 2007. do 2019. godine u Hrvatskoj. Izabrane bankarske varijable predočene u grafikonu su: udio plasmana u bankama, kamatna razlika s valutnom klauzulom i bez valutne klauzule i NPL.

Grafikon 10. Kretanje bankarskih varijabli u Hrvatskoj po kvartalima od 2007. do 2019. godine



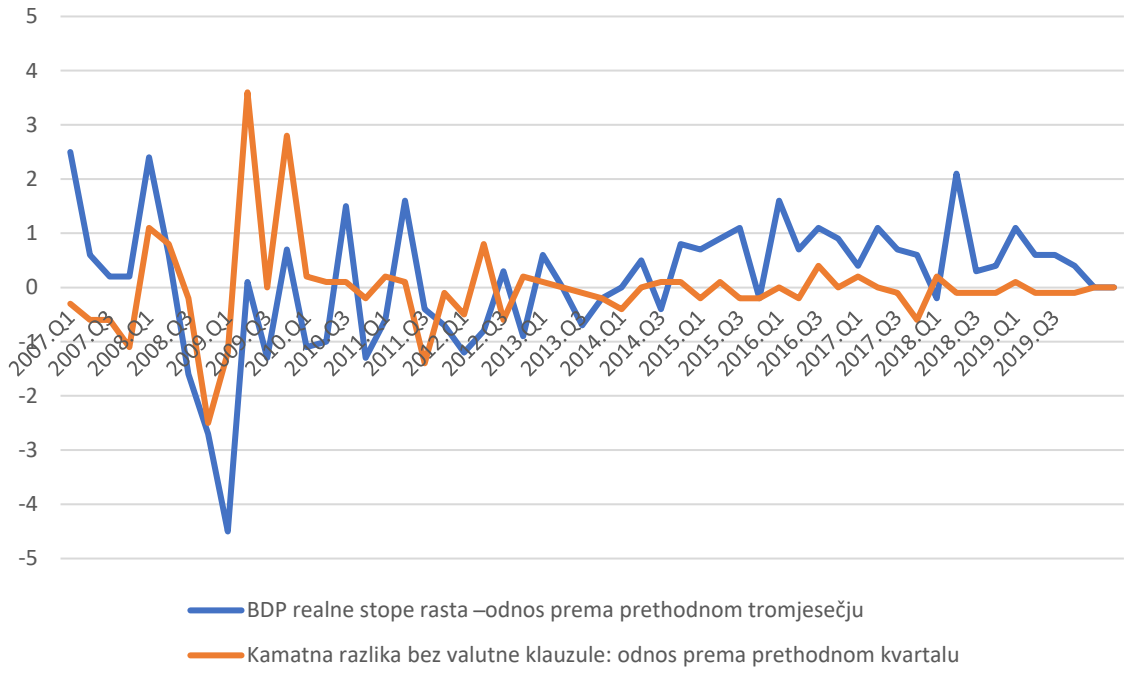
Izvor: Izrada autora, 2020.

Značajnije odstupanje u trendu kretanja svih triju varijabli zabilježen je u zadnjem kvartalu 2008. godine i to je odstupanje posebno naglašeno kod kamatnih razlika bez valutne klauzule. Pad je zabilježen sve do drugoga kvartala 2009. godine, a nakon toga zabilježen je nagli rast svih varijabli, a posebno porast udjela plasmana. Pozitivan trend u kretanju nastavlja se sve do kraja Q3 2015. godine da bi nakon 2015. godine uslijedio negativan trend u kretanju koji je zabilježen i u posljednjem kvartalu 2019. godine.

Na temelju prikupljenih podataka, a radi boljeg praćenja dobivenih rezultata obrađenih putem Pearsonova koeficijenta korelacije (vidljivog u tablici 7.), izrađeni su grafikoni kretanja sljedećih varijabli:

1. Kretanje varijable BDP-a i kamatne razlike bez valutne klauzule (grafikon 11.)
2. Inflacije i kamatne razlike s valutnom klauzulom (grafikon 12.)
3. Kretanje stopa nezaposlenosti s NPL-om i varijablom kretanja plasmana u bankama (grafikon 13).

Grafikon 11. Kretanje varijable BDP-a i kamatne razlike bez valutne klauzule u Hrvatskoj po kvartalima od 2007. do 2019. godine



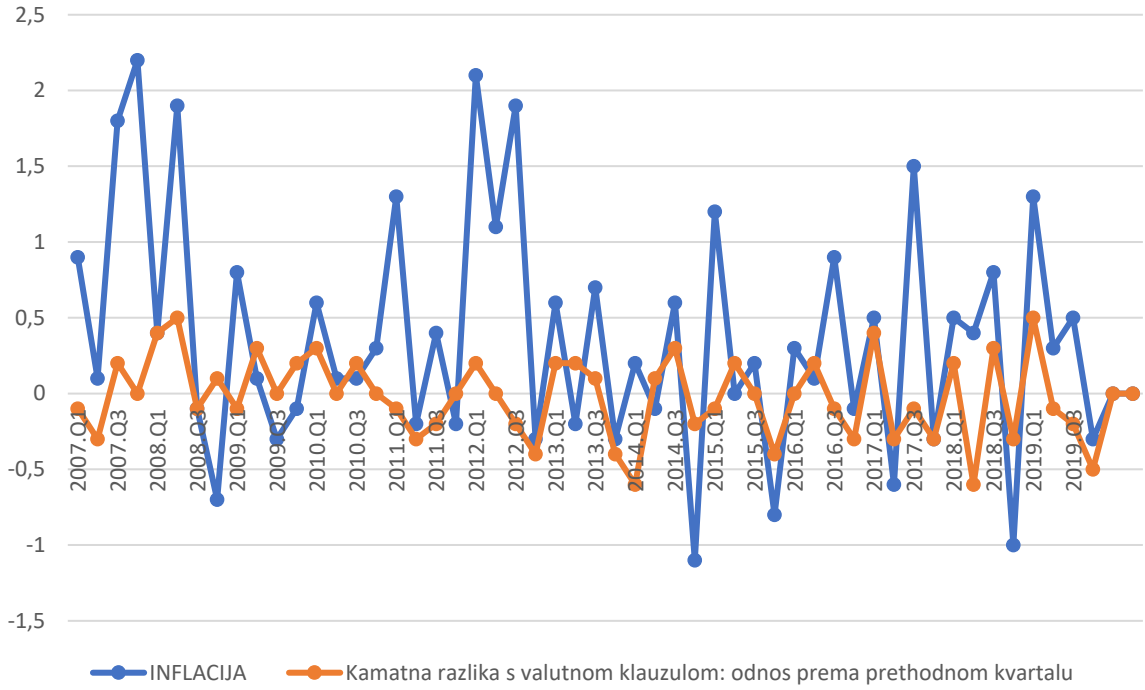
Izradila: Izrada autora, 2020.

Za analizu kretanja mjesečnih kamatnih stopa na kredite i depozite preuzeti su podaci iz dvije različite baze podataka HNB-a i Državnog zavoda za statistiku. Podaci su sistematizirani, kamatne stope uprosječene i svedene na kvartale kako bi se mogla provesti usporedba kretanja kamata iz prethodnih razdoblja (baza podataka nalazi se u sklopu poglavlja Prilozi na kraju doktorskog rada). Za praćenje kretanja kamatnih stopa koristi se podatak o kretanju granične kamatne marže koja se definira kao visina razlika između kamatne stope na kredite i kamatne stope na depozite.

Iz grafikona 11. može se pratiti kretanje kamatnih razlika bez valutne klauzule s kretanjem BDP-a kroz razdoblje od 2007. do 2019. godine. Pearsonovim koeficijentom korelacije uočena je statistički značajna pozitivna povezanost u kretanju BDP-a i kamatne razlike na novoodobrene kredite i depozite bez valutne klauzule (detalji analize prikazani su u nastavku rada). Tijekom promatranog razdoblja kamatne razlike bez valutne klauzule prate kretanje BDP-a (s tek manjim oscilacijama zabilježenim u posljednjem kvartalu 2010. godine kao i u posljednjem kvartalu 2011. godine). Isto upućuje na to da banke usklađuju politike kamatnih stopa s kretanjima BDP-a. Odnosno u razdobljima rasta BDP-a, raste i kamatna razlika bez

valutne klauzule i obratno. Uslijed pada BDP-a, pada i kamatna razlika bez valutne klauzule. U vrijeme blagostanja i rasta BDP-a, povećavaju se investicije, a time dolazi do potražnje za kreditima. Zbog povećane potražnje za kreditima banke reagiraju tako da povisuju kamatne stope na kredite i smanjuju kamatne stope na depozite čime dolazi do rasta u kamatnoj razlici kako je i prikazano na grafikonu 11.

Grafikon 12. Kretanje inflacije i kamatne razlike s valutnom klauzulom u Hrvatskoj po kvartalima od 2007. do 2019. godine

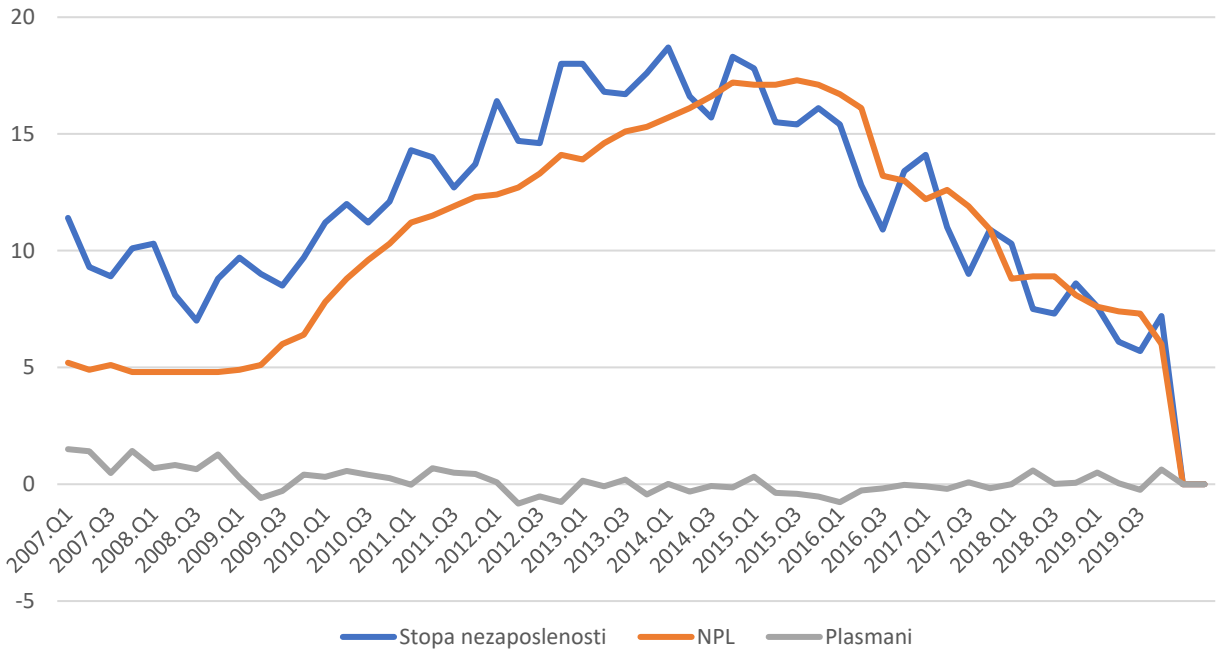


Izradila: Izrada autora, 2020.

Iz grafikona 12. može se pratiti kretanje inflacije i kamatne razlike s valutnom klauzulom kroz razdoblje od 2007. do 2019. godine. Pearsonovim koeficijentom korelacije uočena je statistički pozitivna korelacija u kretanju inflacije i kamatne razlike na novoodobrene kredite i depozite s valutnom klauzulom (detalji analize prikazani su u nastavku rada). Manja odstupanja zabilježena su krajem 2008. i 2014. godine. Inflacija se definira kao opće povećanje cijena dobara i usluga (Europska središnja banka). Inflacija smanjuje vrijednost novca tijekom vremena što znači da za istu količinu novca danas moguće je kupiti manje nego što se za isti novac moglo kupiti ranije. Stoga rastom inflacije rastu troškovi, a time raste i potražnja za novcem u stranoj valuti. Isto vrijedi i obratno. Padom cijena smanjuje se potražnja za novcem u stranoj valuti odnosno dolazi do pada kamatnih razlika s valutnom klauzulom. Kamate na

kredite padaju jer je potražnja za novcem manja, a time dolazi i do pada kamata na depozite jer banke raspolažu s viškovima novca.

Grafikon 13. Kretanje stope nezaposlenosti, NPL-a i udjela plasmana banaka u Hrvatskoj po kvartalima od 2007. do 2019. godine



Izvor: Izrada autora, 2020.

Iz grafikona 13. prati se kretanje stope nezaposlenosti, NPL-a i kretanje plasmana banaka u Hrvatskoj po kvartalima od 2007. do 2019. godine. Pearsonovim koeficijentom korelacije uočena je statistički značajna pozitivna veza između stope nezaposlenosti i NPL-a, kao i statistički značajna negativna veza između stope nezaposlenosti i plasmana banke (detalji analize prikazani su u nastavku rada). Grafikon jasno prikazuje vezu između stope nezaposlenosti i NPL-a. Linijska kretanja su u potpunosti usklađena. Rast stope nezaposlenosti djeluje na smanjenje likvidnosti, a time i na porast nenaplativih kredita u bilancama banaka. S druge strane, porast stope nezaposlenosti djeluje i na udio plasmana u bankama, ali s negativnim predznakom što upućuje na to da veća stopa nezaposlenosti smanjuje udio plasmana u bankama. Kada je nezaposlenost visoka, stanovništvo nije likvidno što ograničava banke u kreditiranju.

Radi određivanja intenziteta i smjera povezanosti nezavisnih makroekonomskih varijabli (BDP-a, stope inflacije, stope nezaposlenosti) i zavisnih bankarskih varijabli (NPL-a, kamatne

razlike s valutnom klauzulom, kamatne razlike bez valutne klauzule, plasmana) provedena je korelacijska analiza i izračunat je Pearsonov koeficijent korelacije što je vidljivo u tablici 7.

Tablica 7. Pearsonovi koeficijenti korelacije između makroekonomskih indeksa i bankarskih varijabli

Korelacije: značajne korelacije za p < ,05000 N = 52							
Varijable	BDP	INFLACIJA	Stopa nezaposlenosti	NPL	Kamatna razlika s valutnom klauzulom	Kamatna razlika bez valutne klauzule	Plasmani
INFLACIJA	0,0084						
	p = 0,953						
Stopa nezaposlenosti	-0,0122	-0,0977					
	p = 0,931	p = 0,491					
NPL	0,1528	-0,1799	0,8374**				
	p = 0,279	p = 0,202	p = 0,000				
Kamatna razlika s valutnom klauzulom	-0,036	0,3825**	-0,1097	-0,1592			
	p = 0,800	p = 0,005	p = 0,439	p = 0,260			
Kamatna razlika bez valutne klauzule	0,3180*	-0,0516	-0,0484	-0,064	0,2800*		
	p=0,022	p = 0,716	p = 0,733	p = 0,652	p = 0,044		
Plasmani	0,0362	0,1911	-0,4193**	-0,6324**	0,0509	-0,3003*	-
	p = 0,799	p = 0,175	p = 0,002	p = 0,000	p = 0,720	p = 0,031	-

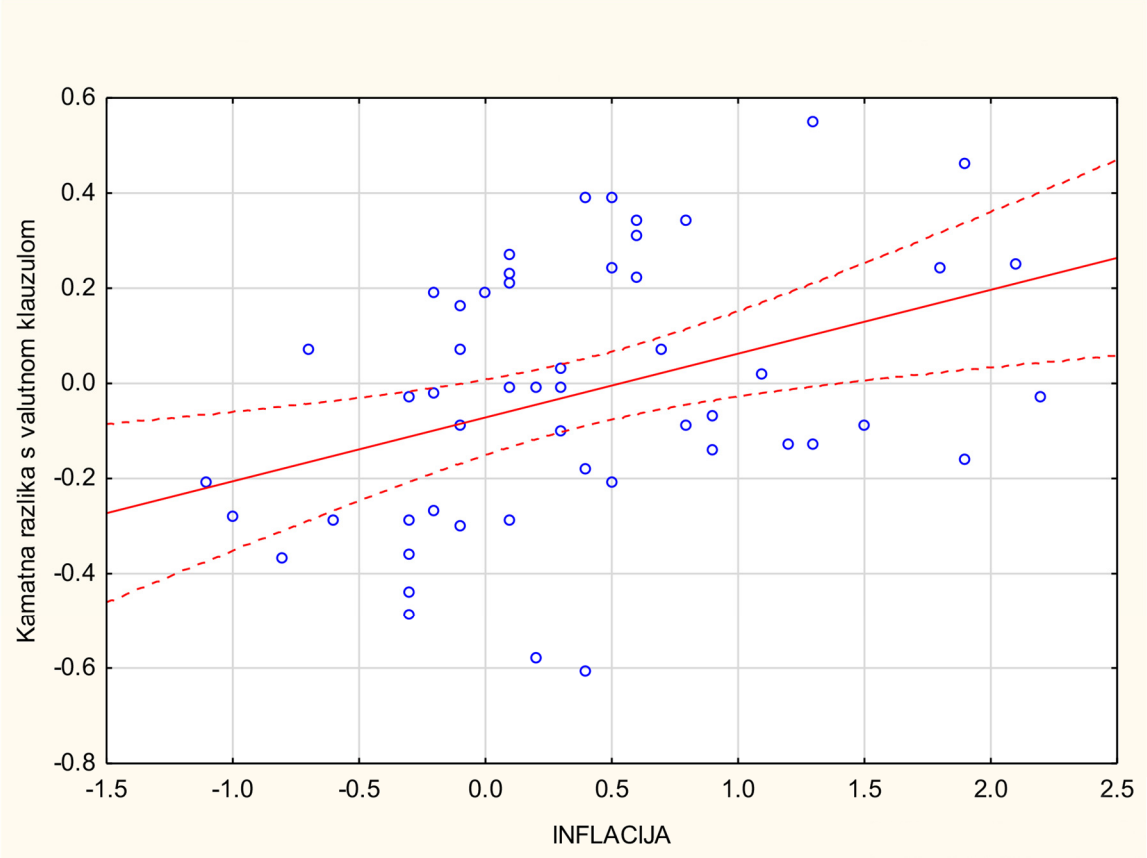
Izvor: Izrada autora, 2020. *$p < .05$; **$p < .01$

Pearsonovim koeficijentom korelacije prikazana je pozitivna povezanost u kretanju BDP-a i kamatne razlike na novoodobrene kredite i depozite bez valutne klauzule (0,318; p = 0,022). Pozitivna korelacija prikazana je i dijagramom rasipanja (Dijagram 1. Odnos kretanja kamatnih razlika bez valutne klauzule i BDP-a) u poglavlju Empirijsko testiranje odnosa kreditnog rizika i gospodarskog rasta. To pokazuje da ako raste BDP, raste i kamatna razlika na novoodobrene kredite i depozite bez valutne klauzule. U vrijeme blagostanja i rasta BDP-a povećavaju se investicije, a time raste potražnja za plasmanima banke. Kako bi zadovoljila povećanu potražnju za kreditima, banke povisuju kamatne stope na kredite i smanjuju kamatne stope na depozite u domaćoj valuti. Bolji ekonomski uvjeti povećavaju broj profitabilnih projekata, a time raste i potražnja za kreditima, potičući banke da povećaju kamatne stope jer zajmoprimci nemaju izbora.

Značajna povezanost ostalih varijabli prikazana je pomoću dvodimenzionalnoga grafikona – dijagrama rasipanja (dijagram 2., dijagram 3. i dijagram 4.).

Pozitivna korelacija inflacije i kamatne stope s valutnom klauzulom predočena je dijagramom rasipanja 2.

Dijagram 2. Odnos kretanja kamatnih razlika s valutnom klauzulom i inflacije



Izvor: Izrada autora, 2020.

Regresijski model zapisan matematičkom jednadžbom, tzv. jednadžba pravca regresije glasi:

Kamatna razlika s valutnom klauzulom = –0,0716 + 0,13417* Inflacija

Zavisna varijabla (y): kamatna razlika s valutnom klauzulom

Nezavisna varijabla (x): inflacija

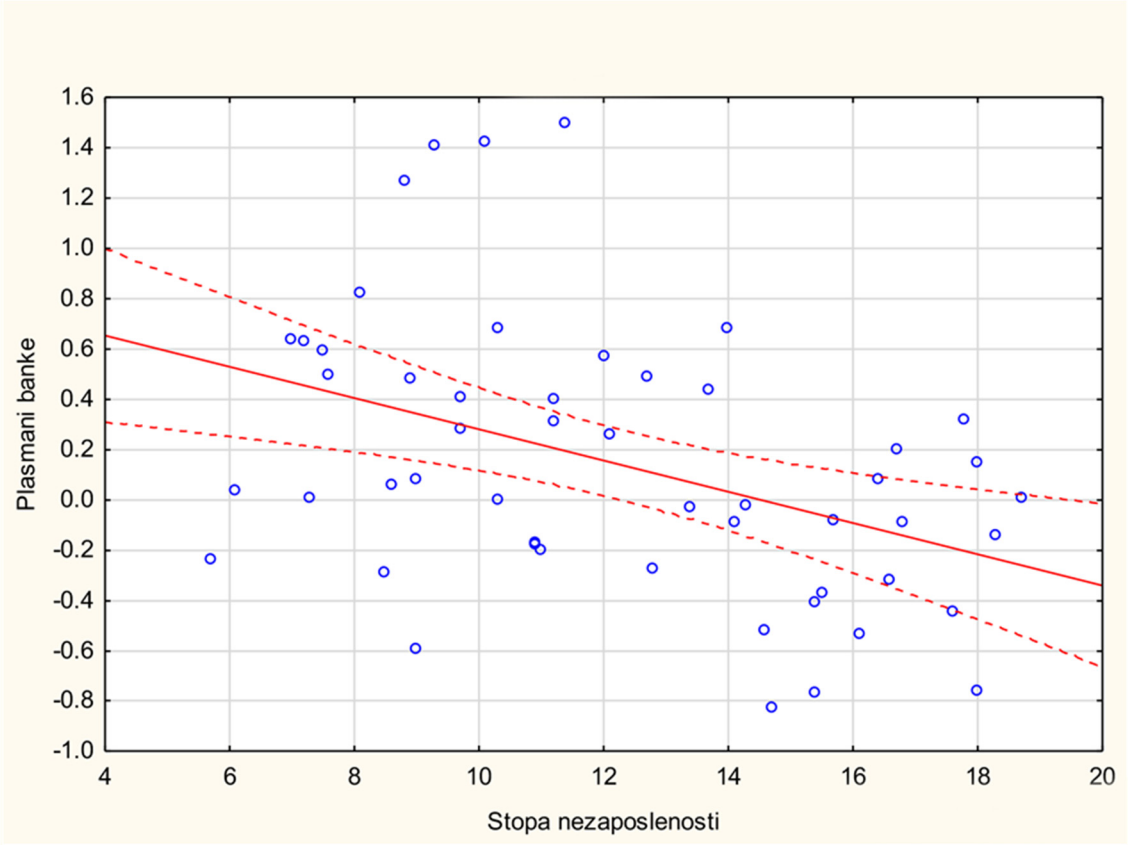
Smjer linearne regresije upućuje na to za koliko se u prosjeku mijenja vrijednost zavisne varijable kamatne razlike s valutnom klauzulom za jediničnu promjenu vrijednosti nezavisne varijable u ovom slučaju inflacije. Prema dobivenoj jednadžbi, ako inflacija poraste za 0,0716 postotna poena u odnosu na prethodni kvartal, može se očekivati rast kamatnih razlika s valutnom klauzulom za 0,134 postotna poena.

Iz korelacijske matrice prikazane u tablici 7. vidljivo je da postoji statistički značajna pozitivna veza između inflacije kao nezavisne varijable i kamatne razlike s valutnom klauzulom kao zavisne varijable ($r = 0,3825$; $p = 0,005$). Navedeno upućuje na to da kretanje nezavisne varijable, u ovom slučaju inflacije, prati kretanje kamatnih razlika s valutnom klauzulom. Povećana količina novca djeluje na kretanje inflacije, a time i na kretanje kamatnih stopa. Rastom ekonomske aktivnosti dolazi do porasta dohotka. Porast dohotka djeluje na povećanje potrošnje i porast investicija koje se uglavnom financiraju zajmovima banaka. Porast investicija djeluje na potražnju za kreditima, a time i na kretanje kamatnih stopa s valutnom klauzulom.

Ovaj dijagram rasipanja rezultat je kretanja inflacije kroz promatrano razdoblje. Prosječna godišnja stopa inflacije u Hrvatskoj u razdoblju od 2000. do 2015. godine iznosila je 2,5 %, što za HNB u konačnici znači održavanje niske inflacije. Najveću inflaciju Hrvatska je imala 2012. godine kada je iznosila 4,7 %. Kretanje inflacije povezano je s kretanjem kamatnih stopa s valutnom klauzulom što je očekivano. U razdobljima rasta inflacije dolazi do nepovjerenja stanovništva u stabilnost domaće valute te raste potražnja za kreditima uz valutnu klauzulu kao što raste i udio štednje denominirane u stranoj valuti.

Negativnu korelaciju između stope nezaposlenosti i plasmana banke kao i gotovo savršenu pozitivnu koreliranost u kretanju stope nezaposlenosti i NPL-a najbolje predočuju dijagrami rasipanja koje su vidljive na dijagramu 3. i dijagramu 4.

Dijagram 3. Prikaz odnosa u kretanju plasmana banke i stope nezaposlenosti



Izvor: Izrada autora, 2020.

Matematička jednadžba pravca regresije glasi:

$$\text{Plasmani banke} = 0{,}902 - 0{,}062 * \text{Stopa nezaposlenosti}$$

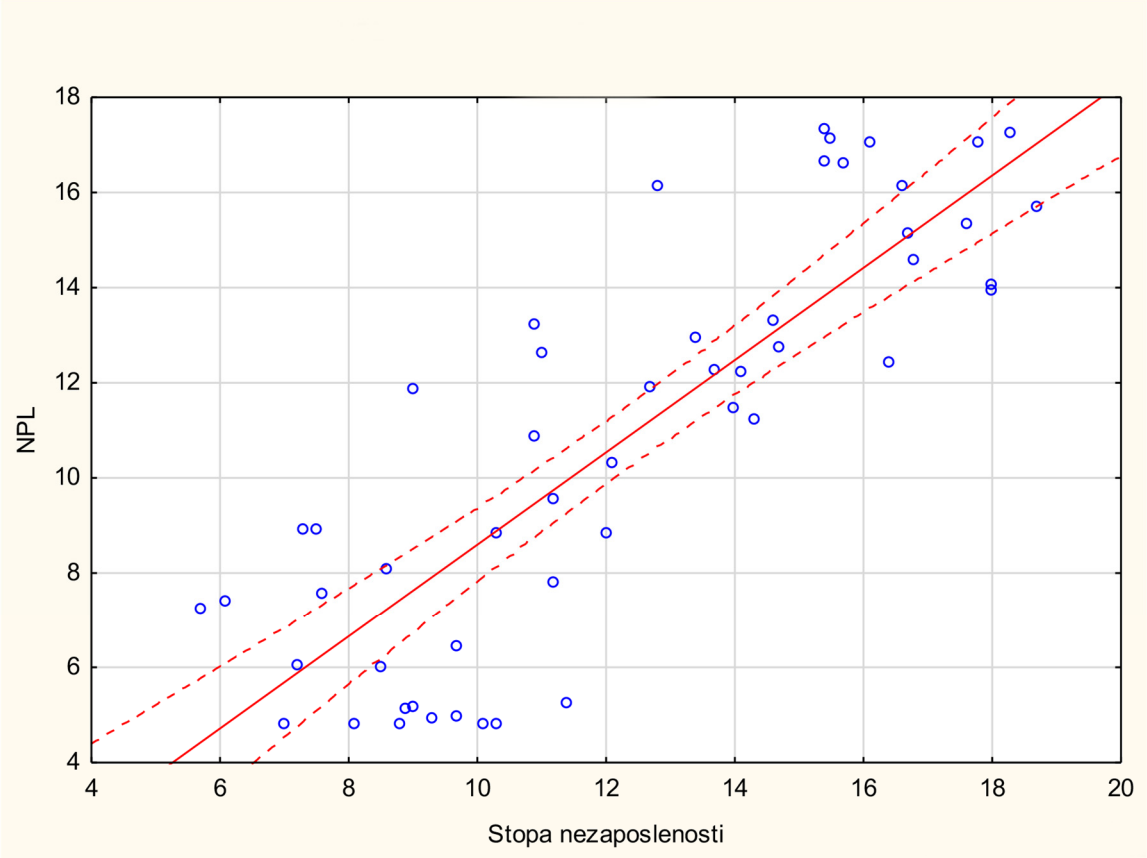
Zavisna varijabla (y): plasmani banka

Nezavisna varijabla (x): stopa nezaposlenosti

Smjer linearne regresije upućuje na to za koliko se u prosjeku mijenja vrijednost zavisne varijable plasmani banke za jediničnu promjenu vrijednosti nezavisne varijable, u ovom slučaju stope nezaposlenosti. Prema dobivenoj jednadžbi, ako stopa nezaposlenosti poraste za 0,902 postotna poena u odnosu na prethodni kvartal, može se očekivati pad plasmana za 0,062 postotna poena.

Iz korelacijske matrice vidljivo je da postoji statistički značajna negativna veza između stope nezaposlenosti kao nezavisne varijable i plasmana banke kao zavisne varijable (r = –0,4193, p = 0,002) što znači da kada raste nezaposlenost, udio plasmana u bankama opada. Banke nemaju dovoljno kreditno sposobnih klijenata jer je nezaposlenost visoka. Nezaposlene osobe su nelikvidne jer nemaju redovna primanja, a samim time ne zadovoljavaju osnovne kriterije za dobivanje kredita – radi se o kreditnoj sposobnosti koja čini osnovu za povrat pozajmljenih financijskih sredstava. Dakle, kada je nezaposlenost visoka, banke su ograničene u plasiranju kredita stoga su plasmani banke u opadanju.

Dijagram 4. Prikaz odnosa u kretanju NPL-a i stope nezaposlenosti



Izvor: Izrada autora, 2020.

Dijagramom 4. prikazan je odnos nezavisne varijable stope nezaposlenosti i zavisne varijable neprihodujućih kredita (NPL-a). Matematička jednadžba pravca regresije glasi:

$$NPL = –1,104 + 0,97^{*} \text{ stopa nezaposlenosti}$$

Zavisna varijabla (y): udio neprihodujućih kredita (NPL-a)

Nezavisna varijabla (x): stopa nezaposlenosti

Smjer linearne regresije pokazuje za koliko se u prosjeku mijenja vrijednost zavisne varijable udio neprihodujućih kredita za jediničnu promjenu vrijednosti nezavisne varijable u ovom slučaju stope nezaposlenosti. Prema dobivenoj jednadžbi, ako NPL poraste za 1,104 postotna poena u odnosu na prethodni kvartal, možemo očekivati rast stope nezaposlenosti za 0.97 postotna poena.

Nadalje vidljivo je da postoji statistički značajna pozitivna veza između stope nezaposlenosti i NPL-a ($r = 0,8374$; $p = 0,000$). U vremenima kada je nezaposlenost visoka, raste udio neprihodujućih kredita u bilanci banke. Naime, ako je klijent banke postao nezaposlen, on ne raspolaže sredstvima za urednu otplatu kredita i time njegov kredit ulazi u kašnjenje. Nakon 90 dana kašnjenja takav kredit se proglašava neprihodujućim kreditom. Zato u situacijama visoke nezaposlenosti raste i udio NPL kredita u bankama. Kao posljedica rasta NPL-a i rasta stope nezaposlenosti, pada udio plasmana, odnosno novoodobrenih kredita. Međutim, kada se prati samo kreditni rizik, nije dovoljno zaustaviti se na udjelu nenaplativih kredita. Ponajprije, veća količina odobrenih kredita znači i veću raširenost financijskih usluga pa će više kredita stimulirati investicije i gospodarski rast. Međutim, kao što se vidi i u slučaju Hrvatske, uz rast ukupnih plasmana postoji i rast nenadoknadivih kredita pa preveliko „razbacivanje“ s kreditima krije u sebi i veliki kreditni rizik (Bogdan i Stipković, 2017).

Nezaposlenost, osim što negativno djeluje na rast kredita u bankama, negativno utječe i na redovnu otplatu kreditnih obveza. Jedan od osnovnih uvjeta za dobivanje kredita/zajma u bankama je kreditna sposobnost klijenta. Ako klijent nije zaposlen i nema redovna primanja, on je kreditno nesposoban i ne ispunjava jedan od osnovnih uvjeta za dobivanje zajma. U situacijama visoke nezaposlenosti banke nemaju dovoljno kreditno sposobnih klijenata koji zadovoljavaju uvjete za dobivanje kredita stoga udio plasmana u bankama opada. Zbog toga se kaže da postoji značajna negativna veza između stope nezaposlenosti i udjela plasmana u bankama. Savršeno pozitivna korelacija upućuje na to da u situacijama kada raste nezaposlenost klijenti koji su nekad bili kreditno sposobni više nisu u mogućnosti uredno vraćati pozajmljena sredstva banci i ulaze u kašnjenje. Kašnjenje u podmirivanju obveza, dulje od 90 dana, naziva se neprihodujući kredit. Što je veća stopa nezaposlenosti, veći je udio nenaplativih kredita pa se kaže da oni pozitivno koreliraju.

Dijagramom 4. prikazan je odnos nezavisne varijable stope nezaposlenosti i zavisne varijable neprihodujućih kredita (NPL-a). Matematička jednadžba pravca regresije glasi:

$$NPL = -1{,}104 + 0{,}97^{*} \text{ stopa nezaposlenosti}$$

Zavisna varijabla (y): udio neprihodujućih kredita (NPL-a)

Nezavisna varijabla (x): stopa nezaposlenosti

Smjer linearne regresije upućuje na to za koliko se u prosjeku mijenja vrijednost zavisne varijable udio neprihodujućih kredita za jediničnu promjenu vrijednosti nezavisne varijable u ovom slučaju stope nezaposlenosti. Prema dobivenoj jednadžbi, ako NPL poraste za 1,104 postotna poena u odnosu na prethodni kvartal, može se očekivati rast stope nezaposlenosti za 0,97 postotna poena.

Nadalje, vidljivo je da postoji statistički značajna pozitivna veza između stope nezaposlenosti i NPL-a ($r = 0{,}8374$; $p = 0{,}000$). U vremenima kada je nezaposlenost visoka, raste udio neprihodujućih kredita u bilanci banke. Naime, ako je klijent banke postao nezaposlen, on ne raspolaže sredstvima za urednu otplatu kredita i time njegov kredit ulazi u kašnjenje. Nakon 90 dana kašnjenja takav kredit se proglašava neprihodujućim kreditom. Zato u situacijama visoke nezaposlenosti raste i udio NPL kredita u bankama. Kao posljedica rasta NPL-a i rasta stope nezaposlenosti, pada udio plasmana, odnosno novoodobrenih kredita. Međutim, kada se prati samo kreditni rizik, nije dovoljno zaustaviti se na udjelu nenaplativih kredita. Ponajprije, veća količina odobrenih kredita znači i veću raširenost financijskih usluga pa će više kredita stimulirati investicije i gospodarski rast. Međutim, kao što se vidi i u slučaju Hrvatske, uz rast ukupnih plasmana postoji i rast nenadoknadivih kredita pa preveliko „razbacivanje“ s kreditima krije u sebi i veliki kreditni rizik(Bogdan i Stipković, 2017).

5.2.4. Analiza dobivenih rezultata empirijskog istraživanja makroekonomskih kretanja na kreditne rizike u poslovnim bankama (H2)

Za analizu poveznice makroekonomskih kretanja na kreditne rizike u radu su primijenjene statističke metode obrade prikupljenih podataka: deskriptivna statistička metoda, korelacijska analiza i različite metode njihova prezentiranja.

Podaci su prikazani kroz vremensku seriju kretanja koja je predočena grafičkim prikazom. Za utvrđivanje postojanja korelativne veze korišteni su parametrijski testovi odnosno Pearsonov koeficijent korelacije. Linearni odnos varijabli prikazan je tablično i dijagramima rasipanja. Za obradu hipoteze primijenjena je u nastavku poglavlja i metoda kompilacije dobivenih rezultata s radovima drugih autora koji su provodili slična ili ista istraživanja.

Za analizu su korištene varijable preuzete iz javno dostupnih baza podataka o kretanju makroekonomskih varijabli kao i podaci o poslovanju banaka u Hrvatskoj od 2007. godine do 2019. godine. Podaci za analizu prikupljeni su sa službene stranice HNB-a iz statističke baze podataka o kretanju monetarnih i kreditnih agregata te iz baze podataka Državnog zavoda za statistiku.

Cilj analize bio je prikazati makroekonomska kretanja i učinak tih kretanja na poslovanje banke. Željelo se ispitati koje makroekonomske varijable imaju značajnu ulogu na poslovanje banaka kao i odrediti smjer djelovanja – imaju li pozitivan ili negativan učinak na profitabilnost banaka. Na temelju priloženih analiza može se zaključiti da kretanja u gospodarstvu igraju značajnu ulogu u poslovnim politikama banaka. Navedeni makroekonomski indikatori djeluju na poslovnu politiku banaka kao i na stabilnost financijskog sustava. Pozitivna stabilna makroekonomska kretanja stvaraju financijsku sigurnost. U stabilnom gospodarstvu poslovne banke potaknute željom za većim profitom poticat će ekspanzivnu kreditnu politiku kako bi povećale aktivu banke. Zbog povećane potražnje za kreditima, ekspanzivna kreditna politika dovodi do smanjenja kamatnih stopa na kredite što ima pozitivan učinak na rast investicija i porast gospodarskih aktivnosti, točnije investicija.

Rezultati djelomično potvrđuju međuovisnost gospodarskih kretanja i financijskog sustava u Hrvatskoj. Od ukupno sedam korištenih indikatora, empirijskim modelom tri su varijable pokazale značajnu vezu financijskog sustava s gospodarskim kretanjima.

Nadalje, prema rezultatima analize, utvrđeno je da gospodarska kretanja djeluju na poslovnu politiku banaka. Sva četiri makroekonomska indikatora pokazala su poveznicu s kretanjima bankarskih indikatora.

Dok stopa rasta BDP-a pozitivno djeluje na profitabilnost banaka, negativna korelacija stope nezaposlenosti i plasmana banke (-0,4193; p = 0,002) ukazuje na to da rast stope nezaposlenosti ima negativan učinak na profitabilnost banaka. Smatra se da stopa nezaposlenosti koja izravno djeluje na prosječni dohodak djeluje i na sposobnost potrošača da vraćaju preuzete zajmove kao i na njihovu sposobnost štednje. Štoviše, ukupna potražnja za financijskim uslugama, uključujući nove kredite, negativno je pogođena nezaposlenošću. Stoga se banke suočavaju s povećanim gubicima zbog povećanih izdataka po kreditima.

Nezaposlenost negativno djeluje na profitabilnost bankarskih institucija zbog negativnog učinka na kvalitetu kreditnih portfelja. Pri analizi podataka, testovi sugeriraju da su varijable likvidnosti banaka i nezaposlenosti determinante NPL s obzirom na to da zajedno čine značajan dio varijacija u kreditnom riziku mjerenom nenaplativim kreditima. Konačno, makroekonomska varijabla poput inflacije jasno djeluju na uspješnost bankarskog sustava.

U usporedbi dobivenih rezultata empirijskog testiranja s rezultatima drugih autora koji su u svojim radovima ispitali uloge makroekonomskih varijabli i bankarskog sektora izdvojeni su sljedeći autori i njihova djela:

Mahmood et al. (2019) u svojoj su studiji ispitivali učinak vanjskih čimbenika na likvidnost banaka u razdoblju od 2000. do 2017. U analizi su se koristili makro specifičnim čimbenicima: BDP, inflacija, monetarna politika i nezaposlenost, a za bankarske čimbenike uzeli su bankarske krize, veličinu banke, ukupni depozit i profitabilnost banaka. Rezultati analize otkrivaju da makroekonomski čimbenici značajno djeluju na likvidnost banaka. Empirijski rezultati pokazali su da ukupni depoziti, BDP, veličina banke i nezaposlenost negativno djeluju na likvidnost banke, a monetarna politika, bankarska kriza i profitabilnost pozitivno djeluje na likvidnost. Inflacija ima beznačajnu vezu s likvidnošću. Da se razina problematičnih kredita može pripisati i makroekonomskim uvjetima i specifičnim čimbenicima banaka u svojem radu objašnjava autor Klein (2013). Iako je utvrđeno da problematični krediti odgovaraju na makroekonomske uvjete, poput rasta BDP-a, nezaposlenosti i inflacije, analiza također pokazuje da postoji snažna povratna veza između bankarskog sustava i realne ekonomije, što

sugerira da visok udio NPL-a u mnogim zemljama CESEE-a negativno djeluje na rast gospodarskog oporavka.

Prateći makrovarijable kao što je godišnja stopa rasta bruto domaćeg proizvoda, javni dug kao postotak bruto domaćeg proizvoda i nezaposlenost te mikrovarijable kao što je omjer zajmova i depozita, prinos na imovinu, povrat na kapital, Makri et al. (2014) u svojem radu istražuju koji od navedenih čimbenika određuju NPL na ukupnoj razini. Njihovi nalazi otkrivaju snažne korelacije između NPL-a i različitih makroekonomskih varijabli (javni dug, nezaposlenost, postotak bruto domaćeg proizvoda) i poveznicu varijabli specifičnih za banke (omjer adekvatnosti kapitala, stopa nenaplativih zajmova iz prethodne godine i povrat na kapital).

Analizirajući uzorak podataka prikupljenih u 75 zemalja Beck et al. (2013) potvrđuju da sljedeće varijable imaju učinak na omjere NPL-a: realni rast BDP-a, cijene dionica, tečaj i kamatna stopa na pozajmice. U slučaju deviznih tečajeva, smjer učinka ovisi o opsegu deviznoga kreditiranja neosiguranih zajmoprimaca.

Dimitrios et al. (2016) analizom tromjesečnih podataka banaka iz europodručja u razdoblju od 1990. do 2015. utvrdili su da su makrovarijable poput stope nezaposlenosti i gospodarskog rasta međusobno povezane. Nadalje, varijable specifične za banke, a povezane s upravljanjem unutar banaka djeluju na buduće kretanje NPL-a.

Stvaranje likvidnosti jedna je od najvažnijih uloga banaka u gospodarstvu. Banka stvara likvidnosti preko zajmova, depozita, izvanbilančnih garancija, derivata te putem ostalih bilančnih i izvanbilančnih aktivnosti. Stvaranje likvidnosti u bankama teorijski je povezano s gospodarstvom. Bankarski zajmovi posebno su značajni onim klijentima i industrijama koje nemaju mogućnost financiranja na tržištu kapitala. U sklopu svojeg rada Berger i Sedunov (2016) analizirali su je li stvaranje likvidnosti banaka, statistički i ekonomski, pozitivno povezano s ekonomskom proizvodnjom (BDP). Analizom su obuhvatili razdoblje prije i za vrijeme financijske krize. Došli su do zaključka da su učinci stvaranja likvidnosti u odnosu na BDP po stanovniku veći za vrijeme gospodarske kriza nego u normalnim vremenima. Proučavajući dinamiku odnosa na razini države otkrivaju da su učinci stvaranja likvidnosti najveći u industrijama koje ovise o bankama.

Aspachs et al. (2005) u svojem radu otkrivaju da su rezerve likvidnosti banaka protuciklične. Drugim riječima, banke stvaraju rezerve likvidnosti u razdobljima slaboga gospodarskog rasta, a zatim te rezerve povlače u razdobljima snažnoga gospodarskog rasta.

Chen et al. (2014) također potvrđuju negativnu poveznicu likvidnosti banaka i kretanja BDP-a. Istražuju čimbenike koji djeluju na veličinu rezerve likvidnosti u bankama te prate dinamiku kreditiranja u bankama, obilježja banaka, makroekonomske osnove i regulatornu politiku na likvidnost banaka. Rezultati rada sugeriraju da svi čimbenici značajno djeluju na razinu likvidnosti banaka. Monetarna politika negativno djeluje na razinu likvidnosti. Potražnja za likvidnošću je protuciklična, stvaranje likvidnosti banaka u suprotnosti je s poslovnim ciklusom, a razina rezerve likvidnosti banaka raste u razdoblju krize.

S obzirom na navedeno, može se potvrditi hipoteza rada:

H2: Makroekonomska kretanja djeluju na kreditne rizike u poslovnim bankama.

5.3. Empirijsko istraživanje o kvaliteti upravljanja rizicima u poslovnim bankama primjenom razvijenih alata i modela u skladu sa smjernicama Europske banke (h1 i h2)

U svrhu analize pomoćnih hipoteza izvršena je statistička obrada podataka o kretanju neprihodujućih izloženosti (engl. *non preforming loans* – NPL) kao i obrada podataka o kretanju operativnih rizika. Svi podaci prikupljeni su iz javno dostupnih izvora podataka o poslovanju banaka. Metodom klasificiranja prikupljeni podaci svrstani su u kategorije prema zajedničkim svojstvima na temelju podataka kojima je već utvrđeno pripadanje pojedinoj kategoriji, podaci su obrađeni metodom kvantificiranja, a rezultati su predočeni u tablično.

U svrhu analize značajnosti kvalitetnog upravljanja rizicima u poslovnim bankama kao i o važnosti primjene razvijenih alata i modela u upravljanju rizicima, u ovom doktorskom radu analizirano je kretanje neprihodujućih kredita te se preko provedene analize o kretanju NPL-a objasnilo i predočilo koliko je bitno kontrolirati i kvalitetno upravljati svim rizicima kojim se banka suočava s naglaskom na kreditne i operativne rizike.

5.3.1. Empirijsko testiranje pomoćnih hipoteza kroz analizu kretanja neprihodujućih kredita (NPL-a)

Visinu izloženosti banke kreditnom riziku najjednostavnije je prikazati kroz razinu neprihodujućih kredita (NPL-a). Visoka razina NPL-a utječe na stabilnost i održivost kapitalne pozicije banke. Ako banka ima velik udio NPL-a u bilanci, to je pokazatelj ili loše kreditne politike banke ili lošega gospodarskog stanja zemlje. Visok udio NPL-a u bilanci banke generira troškove te utječe na pad likvidnosti, a zatim i na profitabilnost banke (Prtenjača Mažer et al., 2020).

Rast pokazatelja adekvatnosti kapitala upućuje na veću stabilnost kreditne institucije te može utjecati na rast regulatornoga kapitala u odnosu na izloženost riziku kao i na smanjenje izloženosti riziku u odnosu na kapital. Povećanje pokrivenosti NPL-a ispravcima vrijednosti korigirat će visinu regulatornoga kapitala umanjujući njegov iznos. Pozitivan efekt smanjenja udjela NPL-a utječe na visinu regulatornoga kapitala realizacijom prihoda kroz račun dobiti i gubitka, odnosno otpuštanjem ispravaka vrijednosti predmetnih kredita u većem iznosu nego

što je trošak otpisa stoga banka ima obvezu redovite kontrole i provođenje „čišćenja“ nenaplativih potraživanja iz svojih bilanci.

Stoga je za dugoročno planiranje i postizanje ciljeva banke ključno osigurati kvalitetno upravljanje aktivom banke, uspostaviti mehanizme za uspješno ograničavanje pogoršanja kao i redovito čišćenje nenaplativih potraživanja iz knjiga banke.

U skladu sa smjernicama Europske banke iz 2018. godine, udio NPL-a u portfeljima banaka na razini svake zemlje ne bi trebao biti veći od 5 %. **Ako postotak prelazi 5 %, bankarski sustav te zemlje je nestabilniji i nesigurniji za investiranje.** Na temelju podataka Hrvatske središnje banke (HNB), omjer nekvalitetnih zajmova (NPL) u hrvatskom bankarskom sustavu u rujnu 2018. godine iznosio je 12,51 %. Prema najnovijim podacima preuzetim iz HNB-a, za 2021. godinu smanjen je udio neprihodujućih kredita (NPL) za 0,9 % u odnosu na 2020. što je rezultiralo daljnjim smanjenjem udjela NPL-a u ukupnim kreditima, s 5,4 % na kraju 2020. na 5,3 % na kraju prvog tromjesečja 2021.

Uzrok porasta NPL-a u bilanci banke može biti posljedica utjecaja:

1. negativnih gospodarskih kretanja (makroekonomski čimbenici)
2. loše poslovne politike banke (mikročimbenici).

Rast NPL-a može biti posljedica i makroekonomskih promjena stoga je radi zaštite od rizika menadžment banke dužan u analize uvrstiti te pratiti kretanje makroekonomskih indikatora i predviđanja o kretanju makroekonomskih varijabli.

Glavne makroekonomske varijable koje imaju značajan i jak utjecaj na kretanje NPL-a su (Europska centralna banka, 2017):

- bruto domaći proizvod
- stopa nezaposlenosti
- inflacija
- kamatne stope i udio blokiranih građana
- u okviru makroekonomskog stres testa (ICAAP) uzimaju se u obzir i dodatne varijable kao što su prosječna neto plaća i tečaj.

5.3.1.1. Podaci i metodologija

U svrhu analize pomoćnih hipoteza putem utjecaja egzogenih čimbenika na kretanje NPL-a, analizirani su podaci iz 39 europskih zemalja, uključujući Hrvatsku.

Varijable uzete za analizu su:

1. Udio neprihodujućih kredita (NPL-a) za svaku zemlju zasebno
2. BDP po glavi stanovnika na razini svake države
3. Indeks trajanja pravnih postupaka u svrhu učinkovitosti naplate spornih potraživanja pravnim putem.

Varijable za analizu preuzete su po uzoru na radove drugih autora koji su ispitivali kretanje NPL-a. Prema tvrdnjama Žiković, Žiković i Blecich (2015), omjer NPL-a kreće se u istom smjeru kao i ekonomsko usporavanje mjereno realnim BDP-om ili indeksom industrijske proizvodnje. Škarica (2013) je također utvrdio da je negativni rast BDP-a glavni pokretač NPL-a u sedam zemalja Srednje i Istočne Europe (CEE). Najopsežniju analizu nenaplativih kredita daju Beck et al. (2013) na uzorku 75 zemalja. Prema njihovu istraživanju, rast BDP-a, cijene dionica (burzovni indeksi), devizni tečaj i kamatne stope na kredite značajno utječu na razinu problematičnih kredita, odnosno njihov udio u ukupno odobrenim kreditima bankarskih sustava analiziranih zemalja. Kao banko specifične determinante rasta NPL-a prepoznati su indikatori solventnosti, stope rasta kreditnog portfelja i moralni hazard višeg menadžmenta (Novellyni i Ulpah, 2017).

Podaci za analizu prikupljeni su iz sljedećih izvora:

- baze podataka Europske komisije
- podaci za analizu prodaje NPL-a i ostalih tijekova NPL-a za Hrvatsku prikupljeni su iz baze podataka HNB-a i KPMG-a za 2018. godinu
- podaci o BDP-u po glavi stanovnika i stopi nezaposlenosti preuzeti su iz baze podataka Svjetske banke
- podaci o kretanju indeksa vezano za trajanje pravnih postupaka preuzeti su iz baze podataka Global Finance Practice (2017).

Dugotrajni pravni postupci na sudovima otegotna su okolnost za naplatu dospjelih potraživanja. Dugotrajnost i neefikasnost sudskih procesa onemogućuje bankama brzu naplatu dospjelih

dugovanja. Takva potraživanja prikazana su u knjigama banke sve do okončanja sudskog procesa što može trajati nekoliko godina ako ne i desetljeće.

Indeks trajanja pravnih postupaka temelji se na više od 120 000 anketiranih kućanstava i 3800 stručnih istraživanja. Indeks trajanja pravnih postupaka mjeri iskustva javnosti iz 126 zemalja svijeta kao i podatke o trajanju pravnih postupaka širom svijeta. Indeks trajanja pravnih postupaka mjeri kvalitetu sudskih postupaka zemlje na temelju osam čimbenika: ograničenja vladinih ovlasti, odsutnost korupcije, transparentnost i otvorenost vlade, temeljna prava, red i sigurnost, provođenje propisa, građansko i kazneno pravo (Global Finance Practice, 2017).

Podaci su analizirani i obrađeni putem Spearmanova koeficijenta korelacije.

Količina i opseg NPL-a sastoje se od dvije varijable:

- podataka o NPL-ovima u privatnom sustavu
- podataka o NPL-ovima u maloprodajnom sustavu.

Tablica 8. Korelacija među varijablama: NPL, BDP po glavi stanovnika, stopa nezaposlenosti i indeks trajanja pravnih postupaka (N = 39)

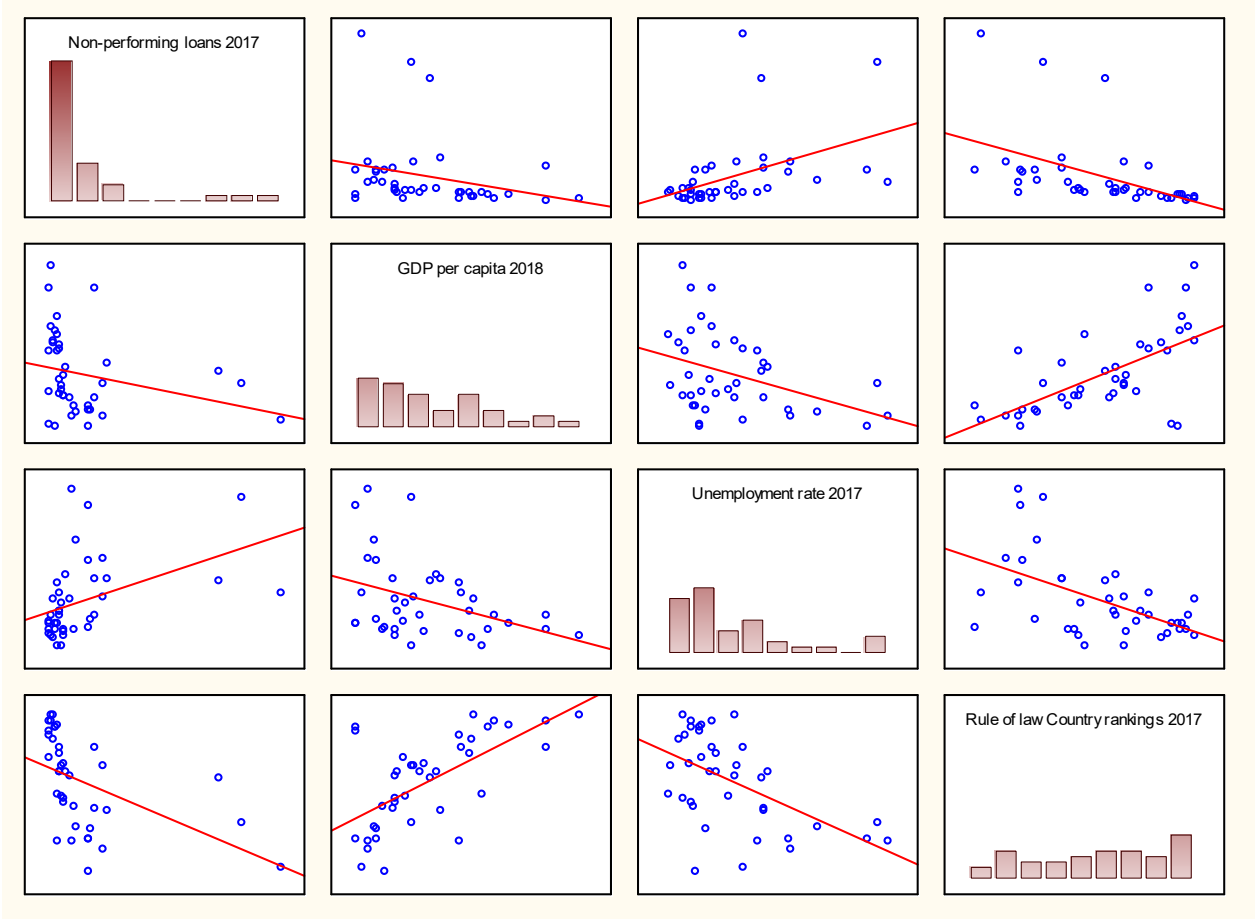
Varijable	Spearman Rank Order Correlations			
	NPL, 2017	BDP	Stopa nezaposlenosti	Indeks pravnih radnji
NPL	1,00	-0,45***	0,58***	-0,73***
BDP po glavi stanovnika		1,00	-0,37*	0,65***
Stopa nezaposlenosti			1,00	-0,51***
Indeks pravnih radnji				1,00

Izvor: Prtenjača Mažer et al., 2020; *p<.05, **p<.01, ***p<.001

Spearmanov koeficijent korelacije upotrijebljen je za utvrđivanje postojanja korelativne veze između postavljenih varijabli. S obzirom na to da su podaci o kretanju BDP-a po brojčanoj vrijednosti značajno veći i odstupaju od ranga kretanja brojčanih vrijednosti podataka o kretanju NPL-a i stope nezaposlenosti, primjena parametrijskih metoda mogla bi dovesti do krivih rezultata i zaključaka. Stoga je radi dobivanja ispravnih korelacija primijenjena neparametrijska metoda koja je dovela do sljedećih zaključaka. Spearmanovim koeficijentom korelacije ranga uočena je statistički značajna korelacija između NPL-a i BDP-a, što upućuje na to da ako se BDP poveća, stopa NPL-a se smanjuje. Negativni rast BDP-a mogao bi se smatrati glavnim

pokretačem NPL-a. Vrlo je vjerojatno da je usporavanje gospodarske aktivnosti negativno utjecalo na financijsku stabilnost regije. Rezultati također prikazuju stopu nezaposlenosti kao značajnu odrednicu NPL-a. Empirijska procjena potvrdila je pozitivnu vezu nezaposlenosti i NPL-a s obzirom na to da veća stopa nezaposlenosti utječe na lošiju sposobnost otplate zajma i uvjete refinanciranja zajmoprimca. Pozitivna korelacija uočena je između trajanja pravnih postupaka i NPL-a. Neučinkovitost i neizvjesnost sudskih postupaka značajne su prepreke oporavku dužnika i/ili naplati dospjelih obveza u mnogim europskim zemljama, uključujući i Hrvatsku.

Slika 12. Grafički prikazi distribucije i korelacije ispitivanih varijabli (matrica dijagrama rasipanja za sve ispitivane varijable)



Izvor: Prtenjača Mažer et al., 2020.

Grafički prikazi distribucije i korelacije ispitivanih varijabli upućuju na jaku negativnu korelaciju BDP-a i NPL-a. Više znanstvenih istraživanja (Žiković et al., 2015; Škarica, 2013; Louzis, Vouldis i Metaxas, 2012) dokazalo je da BDP i NPL imaju negativnu povezanost: kada BDP raste, NPL pada i obratno. Stopa (ne)zaposlenosti, inflacija i kamatne stope imaju zajednički utjecaj na NPL u vidu smanjenja platežne moći dužnika i poskupljenja zaduženja, što znači da rast tih makroekonomskih varijabli u kratkom roku determinira porast NPL-a. Stoga je pri definiranju operativnog plana banke potrebno u obzir uzeti trenutačne makroekonomske indikatore, njihove utjecaje na rezultat banke kao i buduće projekcije.

U skladu s EBA-inim smjernicama osim godišnjeg izračuna rejtinga na temelju financijskih pokazatelja i business modela (transparentnost poslovanja, koncentracija kupaca/dobavljača, elastičnost tržišta, konkurencija, vlasnička struktura), banke su dužne sustavno pratiti razvoj financijskih, poslovnih i drugih okolnosti vezanih uz poslovanje pravnih osoba. Pri tome dužne su se služiti sofisticiranim modelima ranog upozorenja, tzv. engl. *early warning signals*, koji uključuje praćenja pojave odnosno negativnih tendencija u danima kašnjenja, blokade poslovnih i osobnih računa građana, pad prometa preko poslovnog računa, praćenje liste poreznih neplatiša i sl. Za što kvalitetnije upravljanje rizikom banke često provode i tzv. post mortem analizu, analizu dužnika nad kojima je proglašen status neispunjavanja obveza pregledom svih prethodnih kreditnih aplikacija, kretanja financijskih pokazatelja radi detektiranja razloga za ulazak klijenta na listu problematičnih plasmana. Osim gospodarskog rasta, rješenje problema nenaplativih zajmova trebao bi biti i proaktivan i kooperativan pristup dužnika, kreditora i regulatornih institucija (Škarica, 2013). Banke koje usvoje napredne tehnike upravljanja kreditnim rizikom doživljavaju porast kreditiranja od oko 50 %. Implikacije novih tehnika upravljanja rizikom djeluje na povećanje učinkovitosti financijskog sustava (Goderis et al., 2007).

5.3.2. Empirijsko testiranje pomoćnih hipoteza kroz upravljanja operativnim rizikom

U ovome poglavlju rada ispituje se važnost uspostave i upravljanja rizicima u financijskim institucijama s **naglaskom na operativne rizike**. U prijašnjim poglavljima ovoga rada objašnjen je utjecaj kreditnih rizika na poslovanje banke, a u nastavku rada analiziraju se podaci o iznosu gubitaka uslijed nastupa štetnog događaja koji spada u kategoriju operativnog rizika. Štete generirane pod utjecajem drugih rizika, a koji ne spadaju u kategoriju operativnog rizika, neće se uzeti u obzir u ovoj analizi.

Operativni rizici primaju sve značajniju pozornost regulatora i menadžmenta, jer se financijski skandali uzrokovani operativnim rizicima nastavljaju pojavljivati (na primjer, Enron i Parmalt) i zato što su događaji nastali zbog operativnih gubitaka postali glavni uzrok značajnih poslovnih neuspjeha (Moosa, 2007).

Brojni su autori ispitivali utjecaj operativnih rizika na poslovanje poduzeća. Abdullah et al. (2011) u svojem radu ispituju utjecaj operativnih rizika u islamskim bankama. U radu se utvrđuju implikacije na ponašanje povezane s operativnim rizikom islamskih banaka, kao i implikacije na mjerenje rizika, upravljanje rizikom, adekvatnost kapitala i nadzor nad rizikom. Embrechts et al. (2003) smatraju da se prema predloženom, tada još novom sporazumu (Basel II), operativni rizik mora izričito tretirati. Ustanovili su da činjenice povijesnih gubitaka operativnog rizika općenito nisu u skladu s pretpostavkama modeliranja. Imajući na umu da se najozbiljniji gubici operativnog rizika ne mogu ocijeniti slučajnim nadzorom, **postaje očito da je jedini način da se stekne nadzor nad operativnim rizikom poboljšanje kvalitete kontrole mogućih izvora velikih operativnih gubitaka.**

5.3.2.1. Podaci i metodologija

U svrhu analize operativnih rizika te njihove uloge i značaja za stabilnost bankarskog sustava, za potrebe ovoga doktorskog rada korišteni su podaci preuzeti iz SAS® OpRisk Global Data base, svjetske platforme podataka koja prikuplja, analizira i proučava veliku količinu podataka – strukturiranih i nestrukturiranih – različitih industrija. Podaci se mogu ekstraktirati i analizirati radi uvida koji vode do boljih odluka i strateških poslovnih poteza.

Od baze podataka koja sadrži ukupno 16 182 financijske institucije, uključujući osiguravajuća društva, financijske agencije, financijske institucije specijalizirane za pravne osobe, financijske institucije specijalizirane za poslovanje s građanstvom, financijske institucije za trgovinu i

prodaju te financijske posrednike iz cijeloga svijeta, za potrebe ove analize preuzeti su podaci za 3 783 financijske institucije sa sjedištem u Europi za razdoblje od 1. siječnja 2000. do 30. lipnja 2018. godine.

Analizom su obuhvaćene isključivo financijske institucije koje su zabilježile financijski gubitak kao posljedicu **operativnog rizika.**

Varijable prema kojima su promatrane financijske institucije:

- Financijske institucije sa sjedištem u Europi
- Imovina financijske institucije u godini izvještavanja iskazana u mil. $
- Broj zaposlenika financijske institucije u godini izvještavanja
- Iznos gubitka od nastalog događaja iskazan u mil. $
- Veličina financijske institucije.

Pri klasifikaciji utvrđivanja veličine financijske institucije praćena je definicija klasifikacije Europske komisije koja prepoznaje četiri veličine gospodarskih subjekata. Još uvijek ne postoji jedinstvena definicija malog poduzeća, stoga je Europska komisija dala preporuku svojim članicama, Europskoj investicijskoj banci i Europskom investicijskom fondu za uzimanje jedinstvenih kriterija za definiranje ovoga pojma.

Navedena je definicija nastala kombinacijom sljedećih kriterija (Nanić, 2013):

- broj zaposlenih
- godišnji obujam prodaje
- prosječni obujam aktive poduzeća
- samostalnost u odlučivanju (kontrola drugih ne smije biti veća od 25 %).

U skladu s preporukama i zakonodavstvom Europske komisije glavni čimbenici kojima se određuje radi li se o malom poduzeću ili ne su broj zaposlenih i ukupan promet ili ukupan iznos bilance. Prema tome, razlikuje se:[15]

1. kategorija mikro, malih i srednjih poduzeća koja zapošljavaju manje od 250 osoba i čiji godišnji promet ne prelazi 50 milijuna eura te čija ukupna godišnja bilanca ne prelazi 43 milijuna eura

[15] European Community Commission (2003). Recommendation concerning the definition of micro, small and medium-sized enterprises. Official Journal of the European Union (L 124/36).

2. kategorija malih poduzeća koja zapošljavaju manje od 50 osoba i čiji godišnji promet i ukupna godišnja bilanca ne prelazi 10 milijuna eura
3. kategorija mikropoduzeća koja zapošljavaju manje od 10 osoba i čiji godišnji promet i ukupna godišnja bilanca ne prelazi 2 milijuna eura.

Usporedbom navedenih kriterija može se utvrditi pripada li gospodarski subjekt u mikro, malo, srednje ili veliko poduzeće. Navedeni kriteriji moguće vidljivi su i u tablici 10.

Tablica 9. Definicija malih i srednjih i velikih poduzeća prema standardima Europske komisije

Veličina gospodarskog subjekta	Broj zaposlenih	Godišnji prihod u mil. eura	Imovina poduzeća u mil. eura
Mikropoduzeće	≤ 10	≤ 2 milijuna	≤ 2 milijuna
Malo poduzeće	≤ 50	≤ 10 milijuna	≤ 10 milijuna
Srednje poduzeće	≤ 250	≤ 50 milijuna	≤ 43 milijuna
Veliko poduzeće	> 250	> 50 milijuna	> 43 milijuna

Izvor: Europska komisija, 2005.

U skladu s navedenim kriterijima postavljenim u tablici 9. treba izdvojiti broj zaposlenih kojemu se daje najveća prednost u odnosu na druge zato što je otporan na inflaciju odnosno nije pod utjecajem promjena kupovne moći dolara, transparentan je, što znači da se lako zapaža i razumije, usporediv te raspoloživ (Siropolis, 1995).

Nakon što je uzorak financijskih institucija definiran na temelju kriterija veličine, analiziran je odnos prijavljenih šteta s imovinom gospodarskog subjekta za svaku kategoriju veličine poslovnog subjekta te je prikazan odnos veličine i iznosa štete nastalih od operativnih rizika (tablica 10.).

Tablica 10. Rezultati analize šteta nastalih operativnim rizikom

Veličina gospodarskog subjekta	Broj zaposlenih	Iznos nastale štete u mil. $	Imovina u mil. $	Udio gubitka u imovini u postocima	Broj financijskih institucija
Mikro poduzeće	≤ 10	179.617,16	3.516.219,83	5,11	19,00
Malo poduzeće	≤ 50	2.558.530,84	9.190.929,43	27,84	70,00
Srednje poduzeće	≤ 250	623.400,63	210.261.259,82	0,30	107,00
Veliko poduzeće	> 250	82.697.627,29	693.213.278.865,89	0,01	3.455,00

Izvor: Izrada autora, 2020.

Dobiveni rezultati upućuju na to da udio gubitka od operativnih rizika u ukupnoj imovini mikropoduzeća iznosi 5 %, a kod malih poduzeća omjer štete u odnosu na imovinu je više od 27 %. Kod velikih poduzeća postotak je puno niži i pada ispod 1 %. Dakle, ukupan iznos šteta je puno veći kod mikro i malih gospodarskih subjekata jer ili nemaju dovoljno sredstava za ulaganje u zaštitu od operativnog rizika ili nemaju dovoljno obrazovnoga kadra koji bi se bavio isključivo zaštitom. Omjer šteta u odnosu na imovinu financijske institucije puno je manji kod velikih i srednjih financijskih institucija nego što je kod mikro i malih financijskih institucija. Može se **zaključiti da veće i razvijenije financijske institucije puno više ulažu u zaštitu od rizika nego što to rade manje institucije, odnosno prikazana je važnost ulaganja u mjerenja i praćenje operativnih rizika te važnost razvoja sustava zaštite od pojave operativnih rizika** (Prtenjača Mažer et al., 2021).

Do istih su zaključaka došli Baele et al. (2004). Istraživali su rizično ponašanje europskih banaka za vrijeme ekonomskog pada od 2000. do 2003. Za potrebe analize uzete su banke s različitim strategijama i različitim karakteristikama prije usporavanja gospodarstva te njihov profil rizika prije i tijekom pada. Rezultati istraživanja otkrivaju da se prinosi i rizici banaka razlikuju među zemljama i institucionalnim vrstama. Visoko kapitalizirane banke su za vrijeme pada gospodarske aktivnosti imale veće povrate i pokazale su veću stabilnost. To naglašava važnost pravila adekvatnosti kapitala za sistemsku stabilnost bankarskog sustava.

Za potrebe dodatne analize iz baze podataka izdvojeni su podaci kojim je **provedena analiza iznosa nastale štete za svaku vrstu štetnog događaja, po poslovnoj liniji u odnosu na veličinu gospodarskog subjekta.**

Vrste štetnih događaja prema kategoriji rizičnosti razvrstane su po sljedećim kategorijama:

1. Pogreške u poslovanju uključujući i sistemske pogreške
2. Štete uvjetovane klijentom, proizvodom i poslovnom praksom
3. Šteta nastala na imovini društva
4. Radnička prava i zaštita na radu
5. Štete u poslovnima procesima
6. Eksterne štete
7. Interne štete.

Iznose nastale štete po vrstama štetnog događaja u milijunima dolara može se vidjeti u tablici 11.

Tablica 11. Iznos nastale štete po vrstama štetnog događaja u mil. $

Iznos nastale štete po vrsta štetnog događaja u mil. $									
Veličina gospodarskog subjekta	**Broj zaposlenih**	**Ukupan iznos nastale štete u mil. $**	**Pogreške u poslovanju uključujući i sistemske pogreške**	**Štete uvjetovane klijentom, proizvodom i poslovnom praksom**	**Šteta nastala na imovini društva**	**Radnička prava i zaštita na radu**	**Štete u poslovnima procesima**	**Eksterne štete**	**Interne štete**
Mikropoduzeće	**≤ 10**	**179.617,16**	**65,30**	**159.300,28**	**/**	**/**	**313,72**	**499,22**	**19.438,65**
Malo poduzeće	**11 ≤ 50**	**2.558.530,84**	**358.391,38**	**386,34**	**/**	**/**	**1.048,02**	**2.054.702,58**	**144.115,81**
Srednje poduzeće	**51 ≤ 250**	**623.400,63**	**588,91**	**320.756,87**	**/**	**21,46**	**88.771,87**	**139.119,88**	**74.028,35**
Veliko poduzeće	**> 250**	**82.697.627,29**	**254.468,54**	**69.141.756,18**	**100.566,66**	**871.309,39**	**1.634.983,94**	**5.921.712,41**	**4.772.830,17**
Ukupno štete		**86.059.175,92**	**613.514,13**	**69.622.199,67**	**100.566,66**	**871.330,85**	**1.725.117,55**	**8.116.034,08**	**5.010.412,98**
Omjer u ukupnim štetama			**0,71%**	**80,90%**	**0,12%**	**1,01%**	**2,00%**	**9,43%**	**5,82%**

Izvor: Izrada autora, 2020.

Dobiveni rezultati upućuju na to da je od ukupnog iznosa štetnog događaja najprisutniji štetni događaj uvjetovan klijentom, proizvodom i poslovnom praksom, više od 80 %. S druge strane, najmanji omjer u ukupnim štetama su pogreške u poslovanju uključujući i sistemske pogreške (0,71 %) te štete nastale fizičkim oštećenjem imovine (0,12 %) koje zajedno iznose manje od 1 % svih štetnih događaja.

U tablici 12. prikazane su nastale štete raspoređene po zemljama Europe, tj. prikazani su podaci u kojim zemljama se najučestalije javljaju štete te iznos nastale štete po svakoj pojedinoj zemlji.

Podaci o prijavljenim štetama odnose se na razdoblje od 1. siječnja 2000. do 30. rujna 2018. godine. Iz raspoložive baze podataka na dan 30. rujna 2018. godine za ovu analizu primijenjeni su sljedeći kriteriji:

1. Financijske institucije sa sjedištem u Europi
2. Financijske institucije s imovinom ≥ 1 mil. eur ≤ 10 mil. eura
3. Financijske institucije s brojem zaposlenih ≥ 1000 ≤ 3000.

Prema navedenim kriterijima, izdvojeno je 76 financijskih institucija sa sjedištem u Europi.

Tablica 12. Prikaz štetnih događaja raspoređenih prema zemljama u kojima je prijavljen štetni događaj

Imovina u milijunima EUR	Zemlja podrijetla	Zemlja u kojoj je nastao štetni događaj	Basel poslovna linija – Level 1	Basel poslovna linija – Level 2	Kategorija rizičnog događaja	Gubitak u milijunima EUR-a EUR
3.426	Europa	Austrija	Commercial Banking	Commercial Banking	Internal Fraud	1,38
1.181	Europa	Austrija	Retail Banking	Retail Banking	Internal Fraud	0,94
3.125	Europa	Austrija	Retail Banking	Retail Banking	Internal Fraud	1,15
2.811	Europa	Hrvatska	Retail Banking	Retail Banking	Internal Fraud	1,10
1.055	Europa	Cipar	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	0,48
3.090	Europa	Cipar	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	1,20
6.870	Europa	Cipar	Retail Banking	Card Services	Clients, Products & Business Practices	1,64
3.880	Europa	Francuska	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	0,48
2.225	Europa	Francuska	Insurance	Health Insurance	Internal Fraud	0,91
1.108	Europa	Francuska	Retail Brokerage	Retail Brokerage	Employment Practices and Workplace Safety	8,81
1.748	Europa	Francuska	Retail Brokerage	Retail Brokerage	Clients, Products & Business Practices	0,18
1.477	Europa	Francuska	Trading & Sales	Market Making	Employment Practices and Workplace Safety	0,10

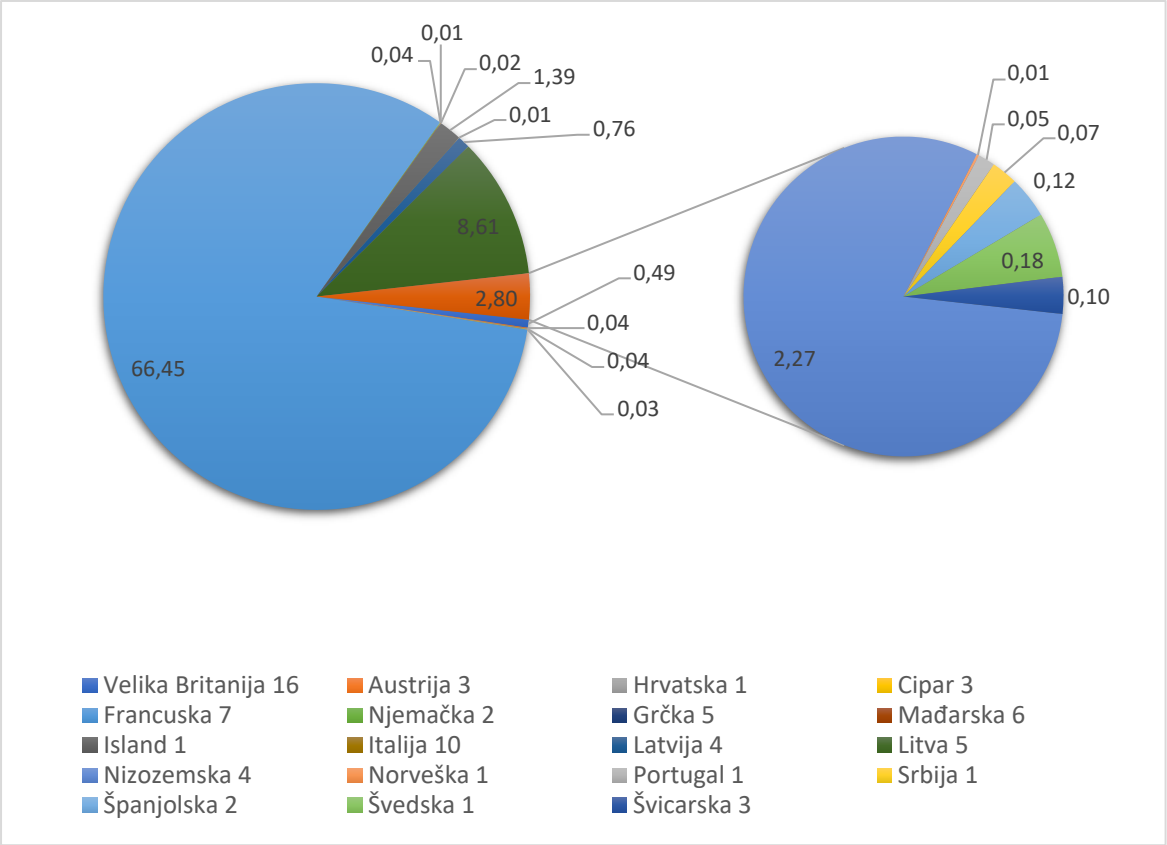
1.798	Europa	Francuska	Trading & Sales	Market Making	Clients, Products & Business Practices	0,11
6.635	Europa	Francuska	Trading & Sales	Sales	Clients, Products & Business Practices	0,18
7.213	Europa	Njemačka	Insurance	Health Insurance	Clients, Products & Business Practices	5,56
5.830	Europa	Njemačka	Retail Banking	Retail Banking	Damage to Physical Assets	0,29
2.635	Europa	Grčka	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	0,48
3.505	Europa	Grčka	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	0,48
4.317	Europa	Grčka	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	0,11
4.810	Europa	Grčka	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	0,48
5.924	Europa	Grčka	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	0,14
2.908	Europa	Mađarska	Retail Banking	Retail Banking	Clients, Products & Business Practices	0,89
3.105	Europa	Mađarska	Retail Banking	Retail Banking	Clients, Products & Business Practices	0,30
6.600	Europa	Mađarska	Retail Banking	Retail Banking	Clients, Products & Business Practices	1,83
7.047	Europa	Mađarska	Retail Banking	Retail Banking	Clients, Products & Business Practices	0,32
8.759	Europa	Mađarska	Retail Banking	Retail Banking	Clients, Products & Business Practices	5,41
9.285	Europa	Mađarska	Retail Banking	Retail Banking	Clients, Products & Business Practices	0,32
4.287	Europa	Island	Commercial Banking	Commercial Banking	Internal Fraud	59,45
7.859	Europa	Italija	Corporate Finance	Corporate Finance	Clients, Products & Business Practices	3,66
5.092	Europa	Italija	Retail Banking	Retail Banking	External Fraud	0,09
5.777	Europa	Italija	Retail Banking	Retail Banking	Clients, Products & Business Practices	2,71
6.202	Europa	Italija	Retail Banking	Retail Banking	External Fraud	0,08
6.394	Europa	Italija	Retail Banking	Card Services	Clients, Products & Business Practices	0,44
8.696	Europa	Italija	Retail Banking	Retail Banking	External Fraud	0,10
9.344	Europa	Italija	Retail Banking	Retail Banking	External Fraud	0,14
9.614	Europa	Italija	Retail Banking	Retail Banking	External Fraud	0,19
9.874	Europa	Italija	Retail Banking	Retail Banking	External Fraud	0,64
6.052	Europa	Italija	Trading & Sales	Market Making	Clients, Products & Business Practices	0,22
3.216	Europa	Latvija	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	1,59
1.840	Europa	Latvija	Retail Banking	Card Services	Clients, Products & Business Practices	0,75
2.682	Europa	Latvija	Retail Banking	Retail Banking	External Fraud	0,98
3.216	Europa	Latvija	Retail Banking	Private Banking	Clients, Products & Business Practices	80,11
2.595	Europa	Litva	Commercial Banking	Commercial Banking	Clients, Products & Business Practices	2,41
1.079	Europa	Litva	Retail Banking	Retail Banking	External Fraud	0,08
2.741	Europa	Litva	Retail Banking	Card Services	Clients, Products & Business Practices	0,33

3.129	Europa	Litva	Retail Banking	Retail Banking	Internal Fraud	932,58
3.134	Europa	Litva	Retail Banking	Retail Banking	Internal Fraud	156,61
1.908	Europa	Nizozemska	Payment and Settlement	External Clients	Business Disruption and System Failures	9,38
6.640	Europe	Nizozemska	Retail Banking	Retail Banking	External Fraud	531,58
7.125	Europa	Nizozemska	Retail Banking	Retail Banking	Clients, Products & Business Practices	0,11
9.529	Europa	Nizozemska	Trading & Sales	Sales	Damage to Physical Assets	30,31
3.480	Europa	Norveška	Retail Banking	Retail Banking	External Fraud	0,24
6.684	Europa	Portugal	Trading & Sales	Sales	Internal Fraud	3,22
1.657	Europa	Srbija	Retail Banking	Retail Banking	Internal Fraud	1,24
4.720	Europa	Španjolska	Insurance	Property and Casualty Insurance	Clients, Products & Business Practices	0,25
6.265	Europa	Španjolska	Insurance	Brokerage and Advisory	Clients, Products & Business Practices	12,78
4.252	Europa	Švedska	Commercial Banking	Commercial Banking	External Fraud	7,85
9.056	Europa	Švicarska	Asset Management	Discretionary Fund Management	External Fraud	14,49
4.113	Europa	Švicarska	Insurance	Property and Casualty Insurance	Internal Fraud	0,90
6.273	Europa	Švicarska	Retail Banking	Private Banking	Clients, Products & Business Practices	4,84
1.250	Europe	Ujedinjeno Kraljevstvo	Asset Management	Non-Discretionary Fund Management	Execution, Delivery & Process Management	11,24
2.599	Europa	Ujedinjeno Kraljevstvo	Asset Management	Discretionary Fund Management	Clients, Products & Business Practices	60,10
3.453	Europa	Ujedinjeno Kraljevstvo	Asset Management	Discretionary Fund Management	Clients, Products & Business Practices	0,10
4.856	Europae	Ujedinjeno Kraljevstvo	Asset Management	Non-Discretionary Fund Management	Execution, Delivery & Process Management	8,22
7.314	Europa	Ujedinjeno Kraljevstvo	Asset Management	Non-Discretionary Fund Management	Execution, Delivery & Process Management	0,10
5.941	Europa	Ujedinjeno Kraljevstvo	Insurance	Property and Casualty Insurance	Clients, Products & Business Practices	1,18
1.138	Europa	Ujedinjeno Kraljevstvo	Retail Banking	Retail Banking	Clients, Products & Business Practices	0,67
1.605	Europa	Ujedinjeno Kraljevstvo	Retail Banking	Card Services	Clients, Products & Business Practices	193,17
9.047	Europa	Ujedinjeno Kraljevstvo	Retail Banking	Retail Banking	Clients, Products & Business Practices	0,94
7.800	Europa	Ujedinjeno Kraljevstvo	Retail Brokerage	Retail Brokerage	Clients, Products & Business Practices	0,70
1.252	Europa	Ujedinjeno Kraljevstvo	Trading & Sales	Sales	Clients, Products & Business Practices	23,54
2.085	Europa	Ujedinjeno Kraljevstvo	Trading & Sales	Sales	Clients, Products & Business Practices	10,14
3.359	Europa	Ujedinjeno Kraljevstvo	Trading & Sales	Sales	Clients, Products & Business Practices	6,39
4.066	Europa	Ujedinjeno Kraljevstvo	Trading & Sales	Sales	Internal Fraud	21,91
7.865	Europa	Ujedinjeno Kraljevstvo	Trading & Sales	Sales	Clients, Products & Business Practices	4,61
8.177	Europa	Ujedinjeno Kraljevstvo	Trading & Sales	Market Making	Clients, Products & Business Practices	6,59

Izvor: Izrada autora na temelju SAS baze podataka, 2020.

Na osnovi tablice dobiveni su sljedeći rezultati:

Grafikon 14. Udio prijavljenih šteta od operativnog rizika u ukupnoj imovini banaka u zemljama Europe (u postocima)



Izvor: Izrada autora, 2020.

Najveći broj šteta prijavljen u financijskim institucijama je u Velikoj Britaniji (16), slijedi je Italija s 10, Francuska sa sedam i Mađarska sa šest. U Francuskoj udio prijavljenih šteta u ukupnoj imovini financijskih institucija iznosi više od 66 %, dok udio prijavljenih šteta u ukupnoj imovini financijskih institucija u Velikoj Britaniji iznosi samo 0,49 %. Značajan udio štete u ukupnoj imovini prijavljen je i u Litvi, 8,61 %.

5.3.3. Analiza dobivenih rezultata istraživanja pomoćnih hipoteza rada

Potreba za regulacijom bankarskog sustava javila se još u 18. stoljeću s prvim značajnim krizama banaka koje su negativno djelovale na cjelokupno gospodarstvo. Europska unija suočila se s nizom izazova u ovom stoljeću. Ekspanzivan rast i razvoj internacionalnih banaka zahtijevao je razvoj i primjenu mehanizama kontrole bankarskog sustava. Uvođenje mehanizama kontrole nije važno jedino regulatorima već i bankarskim menadžerima za sprječavanje potencijalnih rizika stabilnosti internacionalnoga financijskog sustava u cjelini. Ako dođe do sloma banke u zemlji bez obzira na to je li riječ o internacionalnoj banci, štediše matične zemlje osjećat će se ugroženo i stvorit će nepovjerenje prema financijskim institucijama što posljedično može dovesti do financijske, a zatim i gospodarske krize. Pad dviju velikih banaka 1974. godine (Bankhaus Herstatt i Franklin National Bank) rezultirao je osnivanjem i uvođenjem komiteta za nadzor bankarskog poslovanja koje su činile članice zemalja G-10 plus Luksemburg i Švicarska. Taj događaj jasno je dokazao da financijske krize nisu ograničene samo na jednu zemlju te da je potrebna međunarodna koordinacija nad poslovanjem banaka kako bi se spriječilo nastajanje, a time i širenje financijskih kriza. U svrhu kontrole banaka 1988. godine osnovan je prvi Bazelski sporazum poznat kao Basel I, zatim je 2004. godine uslijedio „nadopunjeni“ Basel II, 2009. godine Basel III te 2017. godine Basel IV s rokom primjene do 2023. godine. Svaki novi Bazelski sporazum uvodio je nove smjernice i pravila za kontrole rizika u bankama. Bazelske regulative učinile su značajan pomak u regulaciji financijskih institucija. Velika financijska kriza 2009. godine svakako je donekle ublažena zbog primjene regulacijskih alata za zaštitu od rizika. **Problem koji je još uvijek prisutan i nije do kraja reguliran su alati za procjenu kreditnog rizika kao i primjena analitičkih metoda procjena rizika unutar banaka.**

Prilikom provjere važnosti i uloge razvijenih alata u upravljanju rizicima unutar ovoga rada, analize i obrade podataka te rezultati istraživanja prikazani su opisnom statistikom.

Primjenom velikog uzorka podataka ispitan je učinak neprihodujućih kredita na bilancu banke kao i učinak štetnih događaja uvjetovanih operativnim rizicima na poslovanje financijskih institucija.

U radu je prikazana:

a) važnost primjene razvijenih i sofisticiranih alata za procjenu kreditnog rizika u svrhu smanjenja NPL-a u bankama

U posljednje se vrijeme izrazito razvija svijest o potrebi za upravljanjem kreditnim rizikom. Kontinuirano pogoršanje kvalitete kreditnoga portfelja utječe na jačanje funkcije upravljanja kreditnim rizicima u bankama. Rezultati provedene analize u poglavlju pet ukazuju na to koliko su važne kreditne politike banke. Kreditne politike banke moraju imati ključnu ulogu u određivanju razina NPL-a. Provedena analiza pokazala je da visoka razina NPL-a nije rezultat samo loših internih poslovnih politika i modela već su bitni i eksterni čimbenici koji se također moraju pratiti i ugraditi u sve modele, politike i alate za praćenje i kontrolu kreditnih rizika.

U skladu sa smjernicama Europske središnje banke, financijske institucije dužne su provoditi niz aktivnih mjera za naplatu kao što je osnivanje specijaliziranih odjela za naplatu dospjelih potraživanja, osiguranje naplate iz kvalitetnih kolaterala, uključujući i odgovarajuće procjene kolaterala, primjena pravnih mogućnosti naplate, uključujući izvanparnične opcije (izvansudski dogovor s dužnicima), prodaju portfelja, otpise. Zbog napretka u informacijskoj tehnologiji, olakšan je i način praćenja kreditnog rizika. Zbog financijskih inovacija, podjela rizika postala je lakša. Osnovne razine upravljanja rizicima nametnute su bankama od regulatora, dok je primjena naprednih tehnika i alata još uvijek prepuštena bankama na izbor. Konkurencija gura banke na primjenu naprednih modela upravljanja rizicima. Banke napredne modele za praćenje kretanja kreditnog portfelja upotrebljavaju i u svrhu prilagodbe strukture kapitala banke. Nadalje, napredni alati omogućuju bankama prijenos kreditnog rizika zamjenom polovice njihova kreditnog portfelja za kreditni portfelj druge banke. Prijenosom rizika banke mogu diversificirati svoje portfelje i biti profitabilnije. Mnoge financijske institucije u razvijenim zemljama primjenjuju različite metode za upravljanje rizicima svojih investicijskih ili trgovačkih portfelja.

U usporedbi dobivenih rezultata s rezultatima autora koji su u svojim radovima obrađivali uloge NPL-a na bankarski sektor izdvojeni su sljedeći autori i njihovi radovi: Ozili (2019) navodi da

su učinkovitost banke, omjer pokrića gubitka, konkurencija i stabilnost bankarskog sustava obrnuto povezani s NPL-om. Nenaplativi krediti pozitivno su povezani s bankarskom krizom i koncentracijom banaka dok su negativno povezani s regulatornim kapitalom i likvidnošću banaka, što implicira da bankarski sustav s većim regulatornim kapitalom i većim stupnjem likvidnost ima manje problematičnih kredita u svojoj bilanci. Goderis et al. (2007) ustanovili su da banke koje usvajaju napredne tehnike upravljanja kreditnim rizikom ostvaruju porast kreditnih plasmana. Njihovo istraživanje potvrđuje da banke koje primjenjuju učinkovite tehnike za upravljanje rizikom doživljavaju trajno povećanje njihove ciljane razine kredita za oko 50 %.

b) važnost ulaganja u mjerenje i praćenje operativnih rizika te važnost razvoja sustava zaštite od pojave operativnih rizika

Detalji provedenih analiza obrađeni su u petom poglavlju rada, a rezultati analize upućuju na to da je kod operativnih rizika omjer štete u odnosu na imovinu financijske institucije puno manji kod velikih i srednjih financijskih institucija koje imaju razvijene alate za praćenje rizika nego što je kod mikro i malih financijskih institucija. Veće i razvijenije financijske institucije koje su zbog svojeg značaja i pod većom kontrolom regulatornih tijela, puno više ulažu u zaštitu od rizika nego što to rade manje institucije. U radu je prikazana važnost ulaganja u mjerenje i praćenje operativnih rizika te važnost razvoja sustava zaštite od pojave operativnih rizika.

Nadalje, ako banka nema razvijene alate za praćenje i kontrolu svih rizika u sustavu, dovoljan je samo jedan štetan događaj koji može biti poguban za banku. Ako je iznos štete uzrokovan izvanrednim događajem toliko velik da ga banka ne može podmiriti, može doći do propasti banke, a time i do nestabilnosti na financijskom tržištu.

Hrvatski bankarski sustav još uvijek zaostaje za bankama u razvijenim zemljama u mjerenju i upravljanju tržišnim rizicima. Zakonom o bankama uspostavljena je obveza za uspostavu praćenja i mjerenja svih rizika kojima je banka u svojem poslovanju izložena. U skladu sa Zakonom, mjerenje i kontrola rizika mora biti funkcionalno i organizacijski odvojeno od drugih dijelova banke, stoga su veće banke osnovale zasebne, nezavisne organizacijske odjele za upravljanje rizicima kojima je zadatak praćenje, mjerenje i upravljanje svim rizicima kojim je banka izložena. U većini banaka osnovani su zasebni organizacijski odjeli za upravljanje aktivom i pasivom, kojima je zadatak obavještavati menadžment banke o kretanju financijskih pokazatelja aktive i pasive banke.

U usporedbi dobivenih rezultata empirijskog testiranja s rezultatima drugih autora koji su u svojim radovima ispitivali utjecaj operativnih rizika na poslovanje banaka izdvojeni su radovi sljedećih autora:

Helbok i Wagner (2005) u svojem su radu istražili prakse banaka vezano uz izvještavanja o operativnom riziku za razdoblje od 1998. do 2001. godine, odnosno uzeli su u razmatranje razdoblje i uzorke u kojem je zabrinutost zbog operativnog rizika počela rasti, ali s tim u vezi objavljivanje nije bilo obvezno. Analizirajući godišnja izvješća financijskih institucija, dolaze do dokaza da su se opseg i sadržaj otkrivanja banaka o operativnom riziku znatno povećali, što odražava pojačane napore banaka, nadzornika i drugih agenata u upravljanju rizicima. Došli su do zaključka da su opseg i sadržaj otkrivanja operativnog rizika negativno povezani s omjerom kapitala i profitabilnošću banke.

Važnost kvalitete i sadržaja izvještaja o operativnim rizicima ispitivali su Lamanda i Tamasne Voneki (2020). U svojem radu analiziraju način praćenja i otkrivanja operativnog rizika za 26 velikih banaka iz Češke, Mađarske, Poljske i Slovačke u razdoblju od 2008. do 2016. U analizi su ispitali sadržaj i kvalitetu izvještaja vezanih uz operativne rizike, oslanjajući se na godišnja izvješća i izvješća o objavljivanju Stupa 3. Primjenom regresijske analize prikazuju da velik broj ukupne imovine i primjena Baselovog naprednog pristupa mjerenju rezultiraju boljim i transparentnijim izvještajima vezanim uz rizik.

Aldasoro et al. (2020) u svojem se radu koriste jedinstvenim skupom podataka o štetnim događajima za različite zemlje kako bi analizirali karakteristike operativnog rizika banaka. Nakon naglog porasta štetnih događaja uslijed velike financijske krize, operativni gubici su se posljednjih godina smanjili. U velikim bankama porast štetnih događaja je najvećim dijelom posljedica nepravilne poslovne prakse koje su se dogodile uoči krize, ali su prepoznate tek kasnije. Smatraju da operativni gubici nisu neovisni o makroekonomskim uvjetima i regulatornim karakteristikama. Konkretno, oni pokazuju da kreditni procvat i razdoblja pretjerano akomodativne monetarne politike prate veći operativni gubici. Oni smatraju da je bolji nadzor, s druge strane, povezan s manjim operativnim gubicima.

Velez (2021) kroz svoj rad analizira važnost upravljanja operativnim rizikom. Studija se odnosi na aktivnosti višeg menadžmenta koje mogu biti učinkovite u ispunjavanju dobrih praksi upravljanja rizicima koje propisuje Basel III, što može smanjiti širenje značajnih gubitaka u bankama. Značajni gubici banaka mogu se usporediti s nepredvidivim virusnim gubicima.

Kombinacija ljudskih pogrešaka, prijevara i pravnih troškova usklađena je sa sustavnim operativnim rizikom. Nepredvidivi gubici stalna su globalna prijetnja održivosti globalnih financijskih tržišta.

Tamásné (2020) je u svojem istraživanju došao do zaključka da poduzeće treba pružiti tri vrste odgovora na krizu: operativni, upravljački i komunikacijski odgovori. Trenutačna pandemija COVID-19 promijenila je portfelje operativnih rizika banaka, povećavajući vjerojatnost vrsta rizika kao što su kibernetički rizik, rizik vanjskih poslova i prijevare. Autor smatra da financijske institucije i druge organizacije moraju poboljšati svoje sustave ranog upozoravanja kako bi na vrijeme prepoznale te prijetnje. U svojem se radu bavi pristupima, zadaćama i fazama korporativnog upravljanja krizom, naglašavajući posebne zadaće sudionika u bankarskom sustavu.

Power (2006) ispituje pojavu operativnog rizika od niskog epistemskog statusa do njegove institucionalizacije kao ključne sastavnice globalne bankarske regulative. Međunarodne banke žestoko su osporavale značenje i implikacije bazelskih prijedloga, a tri su ključna područja bila dio rasprave: pitanje definicije operativnih rizika, prikupljanje podataka o operativnim rizicima i ograničenja kvantifikacije. U radu se raspravlja o napetostima unutar ova tri područja koja otkrivaju značaj operativnog rizika kao mjesta okupljanja različitih interesa te kao potencijalnog ponovnog otkrića menadžerskog znanja između revizije i financija. Rad skreće pozornost za potrebom širenja „prisilne samoregulacije“ duboko u poslovanje banaka, kombinirajući napredne ideje tehničkog modeliranja s jedne strane i mekše metode korporativnog upravljanja s druge strane. S obzirom na navedeno, mogu se potvrditi pomoćne hipoteze rada:

h1: Kvalitetnim upravljanjem rizicima u poslovnim bankama smanjuje se negativni efekt krize.

h2: Primjenom razvijenih alata u upravljanju rizicima kao i primjenom modela i smjernica Europske banke, može se ublažiti ekonomska kriza zemlje.

6. Implikacije istraživanja, ograničenja istraživanja i preporuke za buduća istraživanja

Empirijske studije drugih autora predočene u ovome radu pokazale su da snaga monetarne politike ovisi o karakteristikama bilance financijskih institucija. Manje i slabije kapitalizirane financijske institucije reducirat će svoju kreditnu aktivnost, dok su veće i bolje kapitalizirane i likvidnije banke otpornije na monetarne kontrakcije, jer mogu lako zamijeniti depozite drugim izvorima financiranja, apsorbirati očekivane gubitke i preusmjeriti likvidnost kako bi zadovoljile povećanje potražnje za kreditima.

Naime, dobiveni rezultati u ovome radu impliciraju da su se banke u Hrvatskoj istaknule kao najvažniji dio financijskog sustava koji generira gospodarski rast zemlje, te ako postoje visoke stope nenaplativih kredita, generira pad. Pretpostavka je da će njihovo djelovanje s razvojem zemlje početi slabiti te da će se u tom trenutku fokus okrenuti na relativno zanemareno tržište financijskih vrijednosnica. Bankarski sustav kao krucijalan dio financijskog sustava u Hrvatskoj, u ovom se istraživanju pokazao kao bitan pogon u održavanju smjera ekonomskog rasta ili pada.

Nadalje, korišteni makroekonomski indikatori u radu potvrdili su svoju značajnost te ukazali na to kako razvijenost financijskog sustava ovisi o kretanju gospodarstva. Financijsko tržište Hrvatske karakterizira ovisnost o bankarskom sustavu koji je povezan s kretanjem u gospodarstvu. Na temelju dobivenih rezultata može se zaključiti da bankarski sustav reagira na promjene kretanja u gospodarstvu. Rezultati impliciraju da su stope rasta nezaposlenosti i NPL-a negativno povezane s kretanjima novoodobrenih plasmana u bankama, dok stopa rasta BDP-a djeluje na rast potražnje za kreditima te banke povećavaju svoju profitnu maržu. Nekoliko različitih testova također je potvrdilo ove rezultate. S obzirom da je rad bio usmjeren na ispitivanje međuodnosa bankarskog sektora i makroekonomskih kretanja, implikacije u ovom istraživačkom području mogu biti od koristi prvenstveno menadžmentu banaka, kao i Vladi. Rezultati ovog istraživanja menadžmentu banaka, ali i Vladi pružaju značajne informacije o ulozi bankarskog sektora na gospodarstvo Hrvatske, odnosno prikazuju bitne čimbenike bankarskog sektora koji djeluju na gospodarski rast i razvoj Hrvatske. Preporuka menadžmentu banaka je prilikom izrade i razvijanja instrumenata koji dovode do poboljšanja uspješnosti funkcioniranja financijskih institucija i stabilnosti financijskog sustava implementirati modele

za praćenje promjena u kretanju makroekonomskih varijabli za koje je dokazano da neposredno djeluju na bankarski sustav. Konačno, analiza je provedena uz određena ograničenja koja bi mogla biti osnova za daljnja buduća istraživanja. Ograničenje rada odnosi se na mali uzorak zbog posebnosti hrvatskoga bankarskog sustava. Buduća istraživanja mogu ovo ograničenje prevladati koristeći se većim uzorkom koji će uključivati više banaka iz raznih zemalja eurozone ili Srednje i Istočne Europe.

Analiza ovoga rada daje zanimljive smjernice za buduća istraživanja. Poželjno je proširiti analizu i na druge zemlje EU-a. Potencijalni problem takve analize je široka paleta usporedivih podataka koje je potrebno prikupiti iz više različitih izvora za više različitih zemalja za koje podaci često nisu javno dostupni. Unutar istraživanja bilo bi zanimljivo provjeriti jesu li nove smjernice Bazelskog sporazuma imale pozitivan efekt na kretanje pokazatelja rizika u bankama uzrokovanih izvanrednim stresnim događajem zbog pandemije koronavirusa. Odnosno, trebalo bi analizirati poslovanje banaka za vrijeme trajanja i nakon krize uzrokovane pandemijom COVID-19, jesu li banke bile spremne na izvanrednu situaciju uzrokovanu pandemijom korona virusa. Nadalje, trebalo bi analizirati jesu li primjenjivani alati i tehnike za smanjenje negativnih učinaka sukladno stres testovima koje su banke provele 2020. godine, koliko su primjene novih tehnika za zaštitu od rizika bile uspješne i jesu li stres testovi koje su banke u Hrvatskoj provele 2020. godine pokazale stvarnu otpornost bankarskog sustava na ovakve izvanredne događaje.

Preporuka je, nakon određenog vremenskog odmaka, analizirati uspješnost primjene novih razvijenih metoda i alata za praćenje kreditnih rizika u skladu sa smjernicama Basela III u korelaciji s kretanjem NPL-a u bankama i kretanju BDP-a. Pri tome treba uzeti u obzir da smanjenje NPL-a u bilancama banaka nije rezultat prodaje potraživanja na sekundarnom tržištu ni pozitivnih kretanja u gospodarstvu, već isključivo primjena razvijenih alata u financijskim institucijama u skladu s Basel III smjernicama. Da bi se dobili što točniji rezultati za analizu kretanja varijabli, trebalo bi uzeti u razmatranje dulje razdoblje kretanja NPL-a prije gospodarske krize, za vrijeme gospodarske krize i nakon gospodarske krize te analizirati jesu li nove smjernice imale učinak na smanjenje razine loših kredita u bilancama banaka bez obzira na kretanja u gospodarstvu.

7. Zaključak

Banke kao financijski posrednici, imaju značajnu ulogu u financiranju ulaganja i potrošnje poduzeća i kućanstava u cijelom svijetu, a posebno u zemljama Europe gdje su banke još uvijek glavni izvor financiranja. Više od 50 % svih zajmova poduzećima u Europi čine bankarski zajmovi stoga su uvjeti za bankarsko kreditiranje presudni za gospodarsku aktivnost i razvoj realne ekonomije. Iako u razvijenim zemljama razvojem nebankarskih financijskih institucija financiranja putem banaka opadaju (djelomično zbog financijske krize), bankarski sustav i dalje ima važne implikacije na monetarnu politiku i financijsku stabilnost. Osnovna funkcija bankarskog sustava je preusmjeriti višak financijskih sredstava od štediša do produktivnih poduzeća koji će ta ista sredstva uložiti u nove razvoje te time povećati gospodarski rast i razvoj. Pri toj kompleksnoj aktivnosti banke su suočene s paletom potencijalnih rizika. Zbog toga je ključno kontrolirati rad banaka i njihovu sposobnost da preuzmu rizik kako bi se osigurao zdrav tijek kreditiranja realne ekonomije.

Financijska kriza iz 2008. godine potaknula je zanimanje analitičara za ispitivanje čimbenika odgovornih za nastanak financijske krize kao i utjecaj bankarskih kriza na gospodarstvo. Za razliku od prijašnjih istraživanja koja su uglavnom bila usmjerena na proučavanje vanjskih čimbenika koji svojim djelovanjem negativno utječu na poslovanje banaka, novija istraživanja su više usmjerena na ispitivanje unutarnjih čimbenika koji negativno djeluju na unutarnje poslovanje banaka. Unutarnji čimbenici mogu biti jednokratni (jedan negativni poslovni događaj) ili višekratni (više uzastopnih loših poslovnih događaja). Uzastopni negativni poslovni događaji najčešće se vezuju uz lošu poslovnu politiku banke. Negativni događaji dovode banku do problema nelikvidnosti i/ili nesolventnosti. Jedan od negativnih poslovnih događaja je i porast loših ili nenaplativih kredita u bilanci. Porast loših ili nenaplativih kredita u bilanci banke može biti potaknut ili lošom poslovnom politikom banke ili moralnim hazardom.

Stoga je za razumijevanje nastanka bankarskih kriza ponajprije potrebno analizirati unutarnje uređenje banaka. Zbog svih potencijalnih rizika kojima su izložene financijske institucije u svijetu, a koji mogu dovesti do ugroženosti cijelog tržišta, nužno je provođenje nadzora nad bankarskim poslovanjem. Osnovni cilj uvođenja regulacije rada banaka je svođenje rizika na minimum. Loše poslovne odluke banaka mogu izazvati šokove na financijskom tržištu i dovesti do smanjenja kreditne ponude. Stoga se javlja potreba za kontrolom monetarne politike. Nakon financijske krize 2008. godine djelovanjem smjernica Europske banke dodatno su povećani

omjeri regulatornoga kapitala što danas banke čini otpornijima na stres. Stoga je u radu, između ostalog, provedeno empirijsko istraživanje o kvaliteti upravljanja rizicima u poslovnim bankama. Provedena analiza ukazuje na potrebu uvođenja i implementacije kontrolnih mehanizama i alata za sprječavanje nastupa štetnih događaja. Analizom je predočena važnost provođenja kontrole i kvalitete u upravljanju svim rizicima s posebnim naglaskom na kreditne i operativne rizike.

Ostvareni znanstveni doprinos disertacije proizlazi iz potvrđivanja glavnih hipoteza rada, tj. tvrdnje da kreditni rizici poslovnih banaka imaju značajnu ulogu na makroekonomska kretanja u zemlji kao i da makroekonomske varijable svojim promjenama djeluju na kreiranje poslovne politike u bankama.

Za ispitivanje ekonomske povezanosti kretanja bankarskih i makroekonomskih varijabli provedeni su različiti testovi procjene. Ispitana je kratkoročna i dugoročna dinamika kretanja aktivnih i pasivnih kamatnih stopa, kretanje NPL-a i plasmana banke te učinci kretanja stope inflacije, BDP-a i stope nezaposlenosti na poslovne politike banaka u Hrvatskoj. Provedena analiza u radu pokazuje da se kreditni rizici u bilancama banaka smanjuju kako se makroekonomski uvjeti poboljšavaju. To djeluje na smanjenje zaliha loših zajmova (NPL) u bilancama banaka, što omogućuje bolje kreditne uvjete za produktivna poduzeća i kućanstva. Profitabilnost banaka djeluje na stvaranje dodatnoga kapitala koji pozitivno djeluje na sposobnost osiguranja dodatnih sredstva za financiranje gospodarstva jer uspješnost monetarne politike te njezin učinak na kretanja u realnoj ekonomiji ovisi o kvaliteti „kreditnoga kanala“. Promjene monetarne politike mogu djelovati na cijene i dostupnost kredita prema realnom sustavu te tako neposredno djelovati na gospodarski rast i razvoj.

Empirijski rezultati ukazuju da poslovnu politiku hrvatskih banaka oblikuju bankarski specifični čimbenici (koji djeluju na upravljanje na razini banke) i makroekonomske, kontrolne varijable koje nisu izravni rezultat banke, ali imaju značajnu ulogu na kreiranje poslovne politike. Analizom statističkih podataka te analizom teorijskih spoznaja iz područja upravljanja rizicima u bankama, potvrđena je tvrdnja da negativna stopa kretanja BDP-a, porast stope nezaposlenosti kao i inflacija djeluju na poslovanje banaka u Hrvatskoj. U usporedbi s drugim tranzicijskim gospodarstvima te analizom statističkih podataka o neprihodujućim kreditima potvrđeno je da na razinu neprihodujućih kredita u zemljama Srednje i Istočne Europe te u Hrvatskoj značajnu ulogu imaju sljedeći strukturni čimbenici: BDP, nezaposlenost, loša

kvaliteta podataka, nerazvijen način bodovanja u financijskim institucijama, spori zakonski i sudski sustav, nerazvijena sekundarna tržišta za nenaplative kredite, nejasni, nedosljedni i pretjerano strogi porezni sustavi.

Rezultati analize mogli bi se pokazati korisnima u procesu odlučivanja hrvatskih banaka u vezi s formiranjem i provedbom strategije za zaštitu od rizika. U poslovnoj praksi implementacija novih alata i modela često implicira velike izdatke za poslovnu banku stoga se njihova primjena ili izbjegava ili ograničava s ciljem smanjenja troškova. Stoga provedena analiza u kojoj je obuhvaćen respektabilan broj financijskih institucija te rezultati analize mogu pozitivno djelovati na odluku menadžmenta banke prilikom donošenja odluka o uvođenju strategije za zaštitu od rizika. Osim toga, nalazi ovoga rada također su značajni kreatorima hrvatske gospodarske politike. Nema dvojbe da promjene u gospodarstvu djeluju na financijski sektor s naglaskom na bankarski sustav, što uostalom pokazuju i provedeni rezultati. Vlada može svojim neposrednim djelovanjem putem izmjene Zakona utjecati pozitivno na gospodarska kretanja, a time pozitivno djelovati i na financijski sektor koji nije neovisan. Da bi se financijski sustav razvijao potreban je stabilan i razvijen gospodarski sustav. S druge strane, financijski sustav može djelovati na gospodarski rast. Kako navodi Vujčić (1998), inflacija nije jedini način kojim središnja banka može pridonijeti višim stopama gospodarskog rasta. Središnja banka može, osim brigom o stabilnosti cijena, doprinijeti gospodarskom rastu i svojim aktivnim sudjelovanjem u razvoju financijskog tržišta (Privredna kretanja i ekonomska politika, 1998).

Djelovanje čimbenika vanjskog okruženja na banke ispitivani su tijekom duljeg razdoblja, uključujući i posljednju financijsku krizu, dok empirijski nalazi potvrđuju rezultate prethodnih studija o profitabilnosti banaka.

Razumijevanje načina oblikovanja profitabilnosti banaka u kombinaciji s makroekonomskim kretanjima omogućuju menadžmentu banaka, regulatornim tijelima i monetarnim vlastima dizajnirati, razviti i nametnuti instrumente koji dovode do stabilnosti financijskog sustava.

Literatura

1. Abdullah, M., Ismail, A. G., Shahimi, S. (2011). Operational risk in Islamic banks: examination of issues. *Qualitative Research in Financial Markets*, 3(2), pp. 131-151
2. Acharya, V. (2009). *A Theory of Systemic Risk and Design of Prudential Bank Regulation*. London Business School, NYU-Stern and CEPR.
3. Agnello, L., Sousa, R. M. (2013). Fiscal policy and asset prices. *Bulletin of Economic Research*, 65(2), 154-177.
4. Ahmad, M. I., Guohui, W., Hasan, M., Ali, R., Rafiq, M. Y., Rehman, R. (2016). Non-performing loans and economic growth. *Journal of Economics, Business and Management*, 3, 584-586.
5. Ahmad, N. H., Ariff, M. (2007). Multi-country study of bank credit risk determinants. *International Journal of Banking and Finance* (*IJBF*), 5(1), 35-52.
6. Akerlof, G. A., Romer, P. M., Hall, R. E., & Mankiw, N. G. (1993). Looting: The economic underworld of bankruptcy for profit. Brookings papers on economic activity, 1993(2), 1-73.
7. Albertazzi, U., Gambacorta, L. (2009). Bank profitability and the business cycle. *Journal of Financial Stability*. 5(4), pp. 393-409.
8. Aldasoro, I., Gambacorta, L., Giudici, P., Leach, T. (2020). Operational and cyber risks in the financial sector. *BIS Working Paper*, No. 840
9. Ali, A., Daly, K. (2010). Macroeconomic determinants of credit risk: Recent evidence from a cross country study. *International Review of Financial Analysis*, 19(3), 165-171.
10. Allen, F., Gale, D. (2007). *Understanding Financial Crises (Clarendon Lect. Finance).* Oxford: Oxford University Press.
11. Amihud, Y., DeLong, G, Saunders, A. (2002). The effects of cross-border bank mergers on bank risk and value. *Journal of International Money and Finance*, 21, pp. 857-877.
12. Antoun, R., Coskun, A., Youssef, D. (2021). Bank-Specific, Macroeconomic, and Institutional Factors Explaining the Capital Buffer and Risk Adjustments in Banks: A Simultaneous Approach. *Eastern European Economics*, 59(2), 103-124.
13. Arcand, J. L., Berkes, E., Panizza, U. (2015). Too much finance?. *Journal of Economic Growth*, 20, pp.105-148.
14. Arpa, M., Giulini, I., Ittner, A., Pauer, F. (2001). The influence of macroeconomic developments on Austrian banks: implications for banking supervision. *Bis Papers*, 1, 91-116.
15. Ashraf, B., Shen, Y. (2019). Economic policy uncertainty and banks' loan pricing. *Journal of Financial Stability*, 44.
16. Ashraf, Q., Gershman, B., Howitt, P. (2017). Banks, market organization, and macroeconomic performance: an agent-based computational analysis. *Journal of Economic Behavior & Organization*, 135, 143-180.
17. Aspachs, O., Nier, E. W., Tiesset, M. (2005). *Liquidity, banking regulation and the macroeconomy*. Available at SSRN 673883.

18. Athanasoglou, P., Delis, M., Staikouras, C. (2006). Determinants of bank profitability in the South Eastern European region.
19. Baele, L, De Jonghe, O., Vennet, R. (2004). *Bank risks and the business cycle*. Working paper.
20. Baker, S. R., Bloom, N., Davis, S. J. (2016). Measuring economic policy uncertainty. *The quarterly journal of economics*, 131(4), 1593-1636.
21. Balin, B. (2008). *Basel I, Basel II, and Emerging Markets: A Nontechnical Analysis.* Washington DC 20036: The Johns Hopkins University School of Advanced International Studies (SAIS).
22. Ball, L., Mankiw, G., Reisc, R. (2005). Monetary policy for inattentive economies. *Journal of Monetary Economics*, 52(4), pp. 703-725.
23. Bank for International Settlements. www.bis.org
24. Barro, R. J. (1995). Inflation and economic growth. National bureau of economic research.
25. Barth, M. E. (2008). Global financial reporting: Implications for US academics. *The Accounting Review*, 83(5), 1159-1179.
26. Bassett, W. F., Chosak, M. B., Driscoll, J. C., Zakrajšek, E. (2014). Changes in bank lending standards and the macroeconomy. *Journal of Monetary Economics*, 62, 23-40.
27. Bazelski odbor za superviziju banaka (2006). *Osnovna načela djelotvorne supervizije banaka*.
28. Beck, R., Jakubik, P. i Piloiu, A., 2013. Non-performing loans: what matters in addition to the economic cycle?. *ECB Working Paper Series*, No. 1515.
29. Becker, M., Knudsen, T. (2002). Schumpeter 1911: Farsighted Visions on Economic Development. *The American Journal of Economics and Sociology*, 61(2), pp. 387-403.
30. Bedeniković, N. (2019). *Konglomerizacija u hrvatskom bankovnom sustavu*. Doktorski rad. Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet.
31. Belete, T. (2013). Asset Liability Management and Commercial Banks Profitability in Ethiopia. *Research Journal of Finance & Accounting*, 4(10), 77-91.
32. Bencivenga, V., Smith, B. (1991). Financial Intermediation and Endogenous Growth. *The Review of Economic Studies*, 58(2), pp. 195-209.
33. Berger, A. N. (1995). The Relationship between Capital and Earnings in Banking. *Journal of Money, Credit and Banking*, 27(2), pp. 432-456.
34. Berger, A., Guedhami, O., Kim, H., Li, X. (2020). Economic Policy Uncertainty and Bank Liquidity Hoarding. *Journal of Financial Intermediation*
35. Berger, A., Sedunov, J. (2016). *Bank Liquidity Creation and Real Economic Output*. https://www.sc.edu/study/colleges_schools/moore/documents/finance/berger/bank-liquidity-creation-and-real-economic-output.pdf (pristupljeno, prosinac 2020)
36. Berger, N. A., DeYoung, R. (1997). Problem loans and cost efficiency in commercial banks. *Finance and Economics Discussion Series 1997*-8, *Board of Governors of the Federal Reserve System (US)*.
37. Bergseth, K. E. (2017). Financial crisis: Scoping moral hazard (Master's thesis, Høgskolen i Molde-Vitenskapelig høgskole i logistikk).
38. Berislav, B., Prtenjača Mažer, K., Peša, A. (2019). *New guidelines for decreasing non-performing exposures in financial institutions in Croatia.*Opatija: IMR konferencija.
39. Bernanke, B. S. (1993). Credit in the Macroeconomy. *Quarterly Review-Federal Reserve Bank of New York*, 18, 50-50.

40. BIS, Annual Economic Report (2019). *II. Monetary policy frameworks in EMEs: inflation targeting, the exchange rate and financial stability.*
41. Bogdan, Ž., Cota, B., Erjavec, N. (2011). *Bank System Vulnerability to Macroeconomic Shocks in Croatia*. U L. Božina, M. Gonan-Božac i S. Krtalić (ur.), Toward Global Governance (str. 249-278). Pula: Sveučilište Jurja Dobrile u Puli.
42. Bogdan, Ž., Stipković, P. (2017). Pokazatelji hrvatskog bankovnog sustava i gospodarski rast. *Zbornik Ekonomskog fakulteta u Zagrebu*. 15(2).
43. Bohaček, Z., Benšić, M., Šarlija, N. (2003). *Upotreba kredit skoring modela za ocjenjivanje kreditne sposobnosti malih poduzetnika*. Izvorni znanstveni rad. *Ekonomski pregled*. 54(7-8), pp. 565-580.
44. Britchenko I. Stoika V.(2017). Bank risks: Economic essence, calssification and management features. Znanstvena misel journal №3/2017
45. Broz, T.(2009). *Recesija*. Aktualna ekonomska kretanja
46. Bryant, J. (1980). A Model of Reserves, Bank Runs and Deposit Insurance. *Journal of Banking & Finance*. 4(4), pp. 335-344.
47. Burdenko, I. and Pozhar, O. (2006). Disclosure of Information about Bank Risks in Financial Statements. – The Bulletin of the NBU, 7, p. 50-54 [in Ukrainian].
48. Cade, E. (2013). Managing banking risks: reducing uncertainty to improve bank performance. Routledge.
49. Calomiris, C. W., Gorton, G. (1991). The origins of banking panics: models, facts, and bank regulation. In Financial markets and financial crises (pp. 109-174). University of Chicago Press.
50. Campiglio, E. (2016). Beyond carbon pricing: The role of banking and monetary policy in financing the transition to a low-carbon economy. Ecological economics, 121, 220-230.
51. Castro, V. (2012). Macroeconomic determinants of the credit risk in the banking system: The case of the GIPSI. *Working paper. NIPE* WP 11*.
52. Chen, I. J., Phuong, N. L., Lin, W. (2014). The determinants of bank liquidity buffer. Available at SSRN.
53. Chen, N. K. (2001). Bank net worth, asset prices and economic activity. *Journal of Monetary. Economics*. 48, 415-436.
54. Chick, V. (1983). Macroeconomics after Keynes: a reconsideration of the general theory. mit Press.
55. Chiuri, M. C., Ferri, G., Majnoni, G. (2002). The macroeconomic impact of bank capital requirements in emerging economies: Past evidence to assess the future. Journal of banking & finance, 26(5), 881-904.
56. Chłopek, P. S. (2013). RAROC as a credit risk approach. Nauki o Finansach, (3 (16)), 64-76.
57. Cindori, S., Petrović, T. (2016). Indikatori rizičnosti bankarskog sektora u okvirima prevencije pranja novca. Zbornik Pravnog fakulteta u Zagrebu, 66(6), 761-784.
58. Claessens, S., Kose, M. (2013). Financial Crises: Explanations, Types, and Implications. *SSRN Electronic Journal*.
59. Cojocaru, L., Hoffman, S., Miller, J. (2012), Financial Development and Economic Growth in Transition Economies: Empirical Evidence from the CEE and CIS
60. Cota, B. (2003). Ponašanje depozitnih institucija na tržištu depozita i kredita. *Ekonomski pregled*. 53(1-2), pp.106-121.

61. Cota, B., Erjavec, N., Jakšić, S. (2012). Sign restriction approach to macro stress-testing of the Croatian banking system. *Article 2 JEL: C32, C51, E52* UDC: 336.71(497.5) doi: 10.3326/fi ntp/36.4.4
62. Countries. IEE Working Papers, 173, Ruhr Universität Bochum
Countries. University of Delaware Working Papers, 11-22, str. 1-32.
63. Crotty, J. (2020). Structural causes of the global financial crisis: a critical assessment of the 'new financial architecture'. *Cambridge Journal of Economics 2009*. 33, pp. 563-580.
64. Čihák, M. (2005). A Stress Testing: A Review of Key Concepts. *Czech Journal of Economics and Finance*. 53(9-10), pp. 417-440.
65. Čihák, M., Demirgüč-Kunt, A., Feyen, E., Levine, R. (2013). Financial Development in 205 Economies, 1960 to 2010. Financial Development in 205 Economies, 1960 to 2010. *Journal of Financial Perspectives*, EY Global FS Institute. 1(2), pp. 17-36.
66. Ćurčić, U. N. (2002). Bankarski portfolio menadžment – strategijsko upravljanje bankom, bilansima, bonitetom, kvalitetom i portfolio rizicima banke. Novi Sad: Feljton
67. Danisman, G., Demir, E., Ersan, O. (2020). Economic policy uncertainty and bank credit growth: Evidence from European banks. *Journal of Multinational Financial Management*. Elsevier, vol. 57.
68. DeGregorio, J., Guidotti, P. (1995). *Financial development and economic growth*. *World Development*, 23(3), pp. 433-448.
69. Deidda, L. Fattouha, B. (2002). Non-linearity between finance and growth. *Economics Letters*, 74(3), pp. 339-345.
70. Delić, A., Rogić-Dumančić, L. (2016). Utjecaj razvijenosti financijskog sustava na gospodarski rast zemalja srednje i istočne Europe. *Ekonomski pregled*. 67(6), pp. 535-556.
71. Demiralp, S., Eisenschmidt, J.,Vlassopoulos, T. (2017). Negative interest rates, excess liquidity and bank business models: Banks' reaction to unconventional monetary policy in the euro area (No. 1708). Working Paper.
72. Demirgüç-Kunt, A., Feyen, E., Levine, R. (2013.). The evolving importance of banks and securities markets. *World Bank Economic Review*. 27(3), pp. 476-490
73. Diamond, D. W., Dybvig, F. (1983). Bank Runs, Deposit Insurance, and Liquidity. *The Journal of Political Economy*. 91(3), pp. 401-419.
74. Dimitrios, A., Helen, L., Mike, T. (2016). *Determinants of non-performing loans: Evidence from Euro-area countries.* Finance research letters, 18, 116-119.
75. Dotsey, M. (1998). *The predictive content of the interest rate term spread for future economic growth.* FRB Richmond Economic Quarterly, 84(3), 31-51.
76. Draženović, O. B., Prohaska, Z., Suljić, S. (2012). *Uloga banaka u recesiji hrvatskog gospodarstva*. Poglavlje u knjizi, Knjiga: Financijska tržišta i institucije Republike Hrvatske u procesu uključivanja u Europsku uniju. Rijeka: Sveučilište u Rijeci, Ekonomski fakultet, 2012. str. 200-215
77. Duffie, D., Singleton, K. J. (2012). *Credit risk: pricing, measurement, and management.* Princeton university press.
78. Elsinger, H., Lehar, A., Summer, M. (2003). *Risk Assessment for Banking Systems.* Vancouver: Main Mall.
79. Embrechts, P., Furrer, H., Kaufmann R. (2003). Quantifying regulatory capital for operational risk. Research supported by Credit Suisse Group, Swiss Re and UBS AG through RiskLab, Switzerland.

80. Epifanov, A. O. and Vasylyeva, T. A. (2012).The Risk Management of Banks: Monograph in 2 Volumes. Volume 1: Risk Management of Basic Bank Transactions. Sumy, DVNZ "UABS NBU" [Ukrainian].
81. Euroepan Banking Authority, „Smjernice o internom upravljanju", 2018
82. European Banking Authority (2018), *Final report: Guidelines on management of non-performing and forborne exposures*
83. European Banking Coordination "Vienna" Initiative (2012). *Working Group on NPLs in Central, Eastern and South-eastern Europe*
84. European Banking Coordination "Vienna" Initiative (2018). NPL Monitor for the CESEE region, H2 2018
85. European Commission (2018). *Country Report Croatia 2018 Including an In-Depth Review on the prevention and correction of macroeconomic imbalances*, Brussels, 7.3.2018 SWD (2018) 209 final
86. European Commission, (2018), The 2018 EU Scoreboard, Communication from the Commission to the European Parliament, the Council, the European Central Bank, the European Economic and Social Committee and the Committee of the Regions COM (2018) 364 final
87. European parliament (2016). *Economic governance support unit; Non-performing loans in the Banking Union: stocktaking and challenges*
88. Europska centralna banka (2017). *Guidance to banks on non-performing loans*.
89. Evanoff, D. D., Kaufman, G. G., Malliaris, A. G. (2012). *New Perspectives on Asset Price Bubbles*. Oxford: Oxford University Press.
90. Finel-Honigman, I., Sotelino, F. (2015). *International banking for a new century*. Routledge.
91. Fohlin, C. (2014). A brief history of investment banking from medieval times to the present. In The Oxford Handbook of Banking and Financial History.
92. Friedman. M, Schwartz, A. (1986). *Has Government Any Role in Money?. Journal of Monetary Economics 17* (January 1986), pp. 37-62.
93. Galac, T. (2011). *Središnja banka kao krizni menadžer u Hrvatskoj – analiza hipotetičnih scenarija.* Zagreb: HNB.
94. Gambacorta, L., Yang, J., Tsatsaronis, K. (2014). Financial structure and growth.
95. Gertler, M. Andrew, R. (1991). *Finance, growth, and public policy*. Working paper. Country Economics department. The World Bank. Decemeber 1991. WPS 814
96. Ghosh, S., (2019). Loan delinquency in banking systems: How effective are credit reporting systems? Qatar Central Bank PO Box 1234 Doha, Qatar
97. Gilbo, M. (2017). Utjecaj stupnja zaduženosti država na ekonomski i ukupni razvoj. *Pravnik*. 51(1), 102.
98. Gilman, S. (1925). Analyzing financial statements. Ronald Press Company.
99. Goderis, B. Marsh, I. Castello, J. Wagner, W. (2007). *Bank behaviour with access to credit risk transfer markets.* Bank of Finland. Research Discussion Papers
100. Goldsmith, R. (1955). *Financial Structure and Economic Growth in Advanced Countries: An Experiment in Comparative Financial Morphology*. Princeton: University Press. Chapter pages in book pp. 111-168.
101. Goldsmith, R. W. (1969). Financial structure and development (No. HG174 G57).
102. Gornjak, M. (2017). Comparison of IAS 39 and IFRS 9: The analysis of replacement. International Journal of Management, Knowledge and Learning, (1), 115-130.

103. Granville, B., Mallick, S. (2009). Monetary and financial stability in the euro area: Pro-cyclicality versus trade-off. Journal of International financial markets, institutions and money, 19(4), 662-674.
104. Greenwood, J., Jovanovic, B. (1990). Financial Development, Growth, and the Distribution of Income. The Journal of Political Economy. 98 (5), Part 1, pp. 1076-1107.
105. Gregoriou, G. N., Racicot, F. É., Théoret, R. (2021). The response of hedge fund tail risk to macroeconomic shocks: A nonlinear *VAR approach*. Economic Modelling, 94, 843-872.
106. Gregurek, M., Vidaković, N. (2015.), Bankarsko poslovanje. Zagre: RRiF plus
107. Griffith-Jones, S., Ocampo, O. J. (2009). *The financial crisis and its impact on developing countries*. *Working Paper*.No. 53.
108. Grizelj, S. (2016). *Utjecaj financijskog sustava na gospodarski rast*. Doktorski rad. Split: Sveučilište u Splitu, Poslijediplomski sveučilišni studij ekonomija i poslovna ekonomija.
109. Gunsel, N. (2012). Micro and macro determinants of bank fragility in North Cyprus economy. *Article*. 6(4), pp. 1323-1329.
110. Hand, D. J., Henley, W. E. (1997). Statistical classification methods in consumer credit scoring: a review. Journal of the Royal Statistical Society: Series A (Statistics in Society), 160(3), 523-541.
111. Heffernan, S. (1996). *Modern Banking in Theory and Practice*. Wiley.
112. Heffernan, S. (2005). *Modern Banking.* 1 izdanje.Wiley.
113. Helbok, G. Wagner, C. (2005). Determinants of operational risk reporting in the banking industry. Available at SSRN 425720, 2006 – papers.ssrn.com
114. Hellmann, T. F., Murdock, K. C., Stiglitz, J. E. (2000). *Liberalization, moral hazard in banking, and prudential regulation: Are capital requirements enough?.* American economic review, 90(1), 147-165.
115. Hickson, C., Turner, J. (2003). *Free banking gone awry: the Australian banking crisis of 1893.* Published online by Cambridge University Press: 19 February 2003
116. Hopkin, P. (2018). *Fundamentals of risk management: understanding, evaluating and implementing effective risk management.* Kogan Page Publishers.
117. Horvat, J., Mijoč, J. (2019). *Istraživački SPaSS*. Knjiga.
118. Horwath, R., Seidler, J., Weill, L. (2012). Bank Capital and Liquidity Creation. European Central Bank, Working Paper Series No 1497
119. Hosjak, F. (2017). *Upravljanje kreditnim rizikom u bankarstvu*. Diplomski rad. Osijek: Sveučilište u Osijeku, Ekonomski fakutltet.
120. Houston, J. F., Lin, C., Ma, Y. (2012). *Regulatory Arbitrage and International Bank Flows.* Journal of Finance. 67(5), pp. 1845-1895.
121. Hristov, N., Hülsewig, O., Wollmershäuser, T. (2012). *Loan supply shocks during the financial crisis: Evidence for the Euro area.* Journal of International Money and Finance, 31(3), 569-592.
122. Hrvatska narodna banka (2009). *Odluka o klasifikaciji plsmana i izvanbilančnih obveza kreditnih institucija*. Narodne novine 001/2009
123. Hrvatska narodna banka (2010). *Odluka o efektivnoj kamatnoj stopi kreditnih institucija i kreditnih unija te ugovaranju usluga s potrošačima* ("Narodne novine", broj 1/2009. i 41/2009.

124. Hrvatska narodna banka (2015). *Regulativa (online)*. Dostupno na: https://www.hnb.hr/temeljne-funkcije/financijska-stabilnost/regulativa (19. lipnja 2019.)
125. Hrvatska narodna banka (2016). *O financijskoj stabilnosti*. Dostupno na: https://www.hnb.hr/temeljne-funkcije/financijska-stabilnost/o-financijskoj-stabilnosti (pristupljeno 21. veljače 2019.)
126. Hrvatska narodna banka (2019). *Financijska stabilnost (online)*. Broj 20. Dostupno na: https://www.hnb.hr/documents/20182/2820345/h-fs-20.pdf/73114398-be25-b962-9e60-f6c19c61cb3f (pristupljeno16. lipnja 2019.)
127. Hrvatska narodna banka (2019). *Godišnje izvješće 2018. (online)*. Zagreb, lipanj 2019 Dostupno na: https://www.hnb.hr/documents/20182/2842124/h-gi-2018.pdf/bf2860e3-91d3-90d8-5ba8-f9630c156310 (pristupljeno16. lipnja 2020.)
128. Hrvatska narodna banka (2020). *Odluka o sustavu upravljanja*. Narodne novine br. 96/2018., 67/2019. i 145/2020
129. Hu, S., Gong, D. (2019). *Economic policy uncertainty, prudential regulation and bank lending.* Finance Research Letters. 29, pp. 373-378.
130. Huang, H., Lin, S. (1992). *Non–linear finance–growth nexus.* Economics of tranisition. 17(3), pp. 439-466.
131. HUB (2017). *Kamatna marža Hrvatskih banaka: mjerenje, usporedbe, trendovi i uzroci promjena.* HUB Analize. 62. Zagreb: Hrvatska udruga banaka.
132. Hunjak, T., Jakovčević, D. (2003). *Višekriterijski modeli za rangiranje i uspoređivanje banaka*. Zbornik Ekonomskog fakulteta u Zagrebu, 1(1), 43-60.
133. Hyytinen, A., Takalo, T. (2004). Preventing systemic crises through bank transparency. Economic Notes, 33(2), 257-273.
134. Imbierowiczi, B., Rauch, C. (2013). *The Relationship between Liquidity Risk and Credit Risk in Banks.* Journal of Banking & Finance. May 2013Journal of Banking & Finance 40(1)
135. Jaramillo, F., Schiantarelli, F., Weiss, A. (1992). *The effect of financial liberalization on allocation of credit: panel data evidence for Ecuador*. Working paper. Country Economics Department. The World Bank. 1993
136. Jickling, M. (2009). *Causes of the Financial Crisis.* DigitalCommons@ILR. ILR School
137. Jin, J., Kanagaretnam, K., Liu, Y., Lobo, G. (2019). Economic policy uncertainty and bank earnings opacity. *Journal of Accounting and Public Policy*. 38(3), pp. 199-218.
138. Jonung, L. (2008). Lessons from financial liberalisation in Scandinavia. Comparative Economic Studies, 50(4), 564-598.
139. Kahle, K. M., Stulz, R. M. (2013). *Access to capital, investment, and the financial crisis.* Journal of Financial economics. Journal of Financial Economics, 2013, vol. 110, issue 2, 280-299
140. Kalra, R. (2016). *Performance Analysis of Non-Banking Financial Institutions.* International Journal of Research in Economics and Social Sciences (IJRESS). 6(11).
141. Kaminsky, G. L., Reinhart, C. M. (1999). *The twin crises: The causes of banking and balance-ofpayments problems.* American Economic Review. 89(3), pp. 473-500.
142. Karadima, M., Louri, H. (2020). *Economic policy uncertainty and non-performing loans: The moderating role of bank concentration.* Finance Research Letters
143. Keynes, J. (1948). The General Theory of Employment, Interest and Money. Moscow [in Russian].

144. Kim, J., Zhang, L. (2016). *Accounting conser Accounting conservatism and st atism and stock price cr ock price crash risk: Firm-le ash risk: Firm-level evidence*. Published in Contemporary Accounting Research, 33(1), pp. 412-441.
145. King, P., Tarbert, H. (2011). Basel III: An Overview. *Banking and financial services*. 30(5).
146. King, R. Levine, R. (1993). *Finance and Growth: Schumpeter Might Be Right. The Quarterly Journal of Economics*. 108(3), pp. 717-737.
147. Kirkpatrick, G. (2009). The Corporate Governance Lessons from the Financial Crisis. *OECD Journal: Financial Market Trends*.
148. Klaassen, P., van Eeghen, I. (2015). *Analyzing Bank Performance—Linking RoE, RoA and RAROC: US Commercial Banks: 1992-2014*. Journal of Financial Perspectives, 3(2).
149. Klein, N. (2013). *Non-performing loans in CESEE: Determinants and impact on macroeconomic performance.* International Monetary Fund.
150. Knight, A. (2002). *A Bubble on the Mighty Mississippi: An Application of a General Model of Speculative Bubbles to the Mississippi Bubble of 1716-1720*. Major Themes in Economics, 4(1), 71-94.
151. Kovačević, V. (2016). *Modeli upravljanja rizikom u bankarskom sektoru*. Doktorska disertacija. Novi Sad: Fakultet za ekonomiju i inženjerski management u Novom Sadu.
152. KPMG (2018), Non-performing loans in Europe, What are the solutions? Document Classification: KPMG Public
153. Kvesić, Lj. (2013). Primjena stabla odlučivanja u kreditnom skoringu. *Ekonomski vjesnik*. 2, pp. 382-390
154. La Porta, R., Lopez-de-Silanes, F., Shleifer, A., Vishny, R. (2000). Investor protection and corporate governance. Journal of financial economics, 58(1-2), 3-27.
155. Labudović, I. (2016). Razvijenost unutarnjih kontrola u upravljanju rizicima poduzeća (Doctoral dissertation, Josip Juraj Strossmayer University of Osijek. Faculty of Economics in Osijek. Chair of Finance and Accounting).
156. Laeven, L., Majnoni, G. (2003). *Loan loss provisioning and economic slowdowns: too much, too late?*. Journal of financial intermediation, 12(2), 178-197.
157. Lai, A. (2002) Modelling Financial Instability: A Survey of the Literature, Bank of Canada, Working Paper, 12, str. 1-40.
158. Lamanda, G., Tamasne Voneki, Z. (2020). What Do Risk Disclosures Reveal About Banking Operational Risk Processes? Content Analysis of Banks' Risk Disclosures in the Visegrad Four Countries. Journal of Operational Risk, 2020
159. Lamfalussy, A., Lámfalussy, S. (2000). Financial crises in emerging markets: An essay on financial globalisation and fragility. Yale University Press.
160. Lanine, G., Vander Vennet, R. (2006). Failure prediction in the Russian bank sector with logit and trait recognition models. *Expert Systems with Applications*, *30*(3), 463-478.
161. Latković, M. (2002). *Upravljanje rizicima: identifikacija, mjerenje i kontrola*. *Financijska teorija i praksa*. Financijska teorija i praksa, 2002
162. Law, S. H., Singh, N. (2014*). Does too much finance harm economic growth?*. Journal of Banking & Finance, 41, 36-44.
163. Lazić, M. (2020). Utjecaj pokazatelja financijske stabilnosti na kreditni rejting i gospodarski rast Republike Hrvatske (Doctoral dissertation, University North. University centre Varaždin. Department of Business Economics.).

164. Leko, V., Stojanović, A. (2018). *Financijske institucije i tržišta*. Zagreb: Sveučilište u Zagrebu – Ekonomski fakultet
165. Levine, R. (1997). Financial Development and Economic Growth: Views and Agenda. *Journal of Economic Literature*. 35(2), pp. 688-726.
166. Lin, J. Y. (2008). The impact of the financial crisis on developing countries.
167. Liu. H, Wilson. O. S. J. (2009). *The Profitability of Banks in Japan: The Road To Recovery?* Working paper. London: Cass business school.
168. Loayza, N., Ranciere, R. (2013). *Financial Development, Financial Fragility, and Growth*. Policy Research Working Papers.
169. Louzis, D., Vouldis, A. Metaxas, V. (2012), Macroeconomic and Bank Specific Determinants of Non-Performing Loans in Greece: A Comparative Study of Mortgage, Business and Consumer Loan Portfolios, Journal of Banking and Finance, 36, 1012-1027. https://doi.org/10.1016/j.jbankfin.2011.10.012
170. Lucas Jr, Robert E. (1988). On the mechanics of economic development. *Journal of monetary economics*, 22(1), 3-42.
171. Lucian-Liviu, A. L. B. U. (2006). *Trends in the interest rate–investment–GDP growth relationship. Romanian Journal of Economic Forecasting*, 5.
172. Mahmood, H., Khalid, S., Waheed, A.,
173. Arif, M. (2019). Impact of macro specific factor and bank specific factor on bank liquidity using FMOLS approach. Emerging Science Journal, 3(3), 168-178.
174. Mahmutović, H., Ćesić, A., Mahmutović, A. (2010). *Efikasno upravljanje rizicima financijskih institucija uz primjenu II Bazelskog sporazuma*. Tranzicija, 12(25-26), 75-83.
175. Makri, V., Tsagkanos, A., Bellas, A. (2014). Determinants of non-performing loans: The case of Eurozone. Panoeconomicus, 61(2), 193-206.
176. Mankiw, N. G. (2014). Principles of economics. Cengage Learning.
177. Marcucci, J., Quagliariello, M. (2009). Asymmetric effects of the business cycle on bank credit risk. Journal of Banking & Finance, 33(9), 1624-1635.
178. Mazreku, F., Morina, V., Misiri, J. V., Spiteri, S., Grima S. (2019). Exploring the Liquidity Risk Factors in the Balkan Region Banking System. *European Research Studies Journal*. XXII(1).
179. Mažer P. K., Briš M. A., Harc M. (2021). *Operational risk management in banks*. Opatija: IMR konferencija.
180. McCallum, B. T. (2001). Monetary policy analysis in models without money.
181. McKinnon, R. (2010). *Money and Capital in Economic Development*. Brookings Institution Press, 1. pro 2010
182. McKinnon, R. I. (1988). Monetary and exchange rate policies for international financial stability: a proposal. Journal of Economic Perspectives, 2(1), 83-103.
183. McKinnon, RI. (1973), Money and Capital in Economic Development, Washington, DC:Brookings Institution.
184. Messai, A. Gallali, M., Jouini, F. (2015). Determinants of Bank Profitability in Western European Countries Evidence from System GMM Estimates. *International Business Research*. 8(7).
185. Mihalić, M. (2017). *Utjecaj osiguranja depozita na moralni hazard, sigurnosnu mrežu i kontrolu tržišta*. Diplomski rad. Zagreb: Sveučilište u Zagrebu, Pirodoslovno-matematički fakultet.

186. Mihaljek, D. (2009). Globalna financijska kriza i fiskalna politika u Središnjoj i Istočnoj Europi: hrvatska proračunska odiseja u 2009. godini. *Financijska teorija i praksa*. 33(3), pp. 241-276.
187. Milbourne, R., Cumberworth, M. (1991). *Australian banking performance in an era of deregulation*. *Australian Economic Papers.* 30, pp. 171-191.
188. Mileris, R. (2012). Macroeconomic determinants of loan portfolio credit risk in banks. Engineering Economics, 23(5), 496-504.
189. Miletić, I. (2008). *Makroekonomski i mikroekonomski uzroci nestabilnosti banaka*. Izvorni znanstveni rad. UDK 330.101.541/.542:336.71
190. Mishkin, F. (1992). Anatomy of a financial crisis. *Journal of Evolutionary Economics volume*. 2, pp.115-130.
191. Mishkin, F. S. (1999) Global Financial Instability: Framework, Events, Issues, The Journal of Economic Perspectives, Vol. 13, No. 4, str. 3-20.
192. Mitrović, R., Nestorović, M., Ljubić, M. (2016). Međusobna povezanost makroekonomskih agregata i poslovnih performansi banaka. *Megatrend revija*. 13(1), pp. 131-146.
193. Moosa, I. A. (2007). Operational risk: a survey. Financial Markets, Institutions & Instruments, 16(4), 167-200.
194. Mörttinen, L., Poloni, P., Sandars, P., Jukka, V. (2005). Analysing banking sector conditions – how to use macro-prudential indicators. *ECB Occasional Paper.* 26
195. Nanić, A. (2013). *Mala i srdnja poduzeća kao nosilac razvoja privrede Europske unije*, Tranzicija, Vol.15, No.31
196. *Narodne novine* (2019). Odluka o sustavu upravljanja. 96/18. i 67/19. https://www.hnb.hr/documents/20182/2628295/h-odluka-o-sustavu upravljanja_npt.pdf/2cfcb52e-67a7-45b7-6979-5eba8f045d95
197. Naudé, W. (2009). The Financial Crisis of 2008 and the Developing Countries. United Nations University (UNU). *World Institute for Development Economics Research (WIDER). Discussion Paper.* 2009/01.
198. Neimke, M. (2003). Financial Development and Economic Growth in Transition
199. Neveščanin, M. (2019). Značaj sistemskog rizika za financijsku stabilnost. Diplomski rad. Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet.
200. Novak, B., Sajter, D. (2005). Financijski omjeri. Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues, 18(1-2), 89-96.
201. Novellyni, D., Ulpah M. (2017). Non-Performing Loans, Moral Hazard and Lending Behaviour of Indonesian Banks. International Journal of Economics & Management, 11.
202. Odedokun, M. (1996). Alternative econometric approaches for analysing the role of the financial sector in economic growth: Time-series evidence from LDCs. *Journal of Development Economics*, 50(1), pp. 119-146
203. Osmanagić-Bedenik, N. (2003). *Kriza kao šansa*. Zagreb: Školska knjiga.
204. Ozili, P. K. (2019). Non-performing loans and financial development: new evidence. *The Journal of Risk Finance*.
205. Pajović, M. (2018). Uticaj diversifikacije izvora prihoda na volatilnost profitabilnosti banaka. Bankarstvo, 47(2), 52-69.
206. Patrick, H. T. (1966). Financial development and economic growth in underdeveloped countries. *Economic development and Cultural change*, 14(2), 174-189.

207. Pavković, A. (2004). Instrumenti vrednovanja uspješnosti poslovnih banaka. *Zbornik Ekonomskog fakulteta u Zagrebu*. 2(1).
208. Pečarić, M. Visković, J. (2013). The effects of prudential policy measures on financial stability in post-transition countries. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu*. 31(1).
209. Peek, J., Rosengren, E. S., Tootell, G. M. (2003). *Identifying the macroeconomic effect of loan supply shocks.* Journal of Money, Credit and Banking, 931-946.
210. Pejić Bach, M., Posedel, P., Stojanović, A. (2009). Determinante profitabilnosti banaka u Hrvatskoj. *Zbornik Ekonomskog fakulteta u Zagrebu*. 7(1).
211. Penikas, H. (2015). History of banking regulation as developed by the Basel Committee on Banking Supervision 1974-2014. Estabilidad financiera. Nº 28 (mayo 2015), p. 9-47.
212. Perez, P. (2010). Assessment of Profitability and Risk of Banks Listed on the Warsaw Stock Exchange in 2004-2009. e-Finanse, 6(numer specjalny), 66-75.
213. Perić, R. (2012). *Zaštita od kreditnog rizika optimizacijom kreditnog portfolija i politikom rezervisanja*. Civitas, 2(03), 153-167.
214. Pirtea, M., Iovu, L., Milos, M. (2008). Importance of Non-banking Financial Institutions and of the Capital Markets in the Economy. The Case of Romania. *Theoretical and Applied Economics*. BROJ
215. Pongrac B., Majić, T. (2015). *Upravljanje poslovnim rizicima*. Technical journal 9, 1(2015), 94-98
216. Power, M. (2006). The invention of operational risk. ESRC Centre for Analysis of Risk and Regulation, London School of Economics and Political Science. Pages 577-599 | Published online: 20 Aug 2006
217. Prga, I., Šverko, I. (2005). Izloženost banaka tržišnim rizicima. *Zbornik Ekonomskog fakulteta u Zagrebu*. 3.
218. Prga, I.,Vrdoljak, T., Šverko, I., (2009). *Upravljanje rizikom likvidnosti korištenjem valutnih swap ugovora*. UDK 336.7(497.5):339.7.012
219. Privredna kretanja i ekonomska politika (1999). Makroekonomska politika i gospodarski rast: teorijski modeli, empirijska istrazivanja i pouke za hrvatsku. Zbirka autora. Broj 73
220. Prohaska, Z., Olgić Draženović, B., Suljić, S. (2013). Uloga banaka u recesiji hrvatskog gospodarstva. Financijska tržišta i institucije Republike Hrvatske u procesu uključivanja u Europsku uniju, 200.
221. Rackov, S. (2013). *Primena Koksovog PH modela u analizi kreditnog rizika*. Magistarski rad. Novi Sad: Univerzitet u Novom Sadu, Prirodno-matematički fakultet.
222. Rioja, F. Valev, N. (2004). Does one size fit all?: a reexamination of the finance and growth relationship. *Journal of Development Economics*. 74(2), pp. 429-447.
223. Robinson, J. (1965). *Essays in the theory of economic growth.* Springer, 1965.
224. Rocheteau, G., Rodriguez-Lopez, A. (2014). Liquidity provision, interest rates, and unemployment. Journal of Monetary Economics, 65, 80-101.
225. Rogić, L., Bogdan, Ž. (2012). Utjecaj razvijenosti financijskog sustava na gospodarski rast u Republici Hrvatskoj. Zbornik radova znanstvenog skupa: Razvojna strategija malog nacionalnog gospodarstva u globaliziranom svijetu, Ekonomski fakultet u Zagrebu.
226. Roubini, N., Sala, M. X. (1992). Financial repression and economic growth. *Journal of Development Economics*. 39(1), pp. 5-3.

227. Rousseau, P., Wachtel, P. (2011). What is happening to the impact of financial deepening on economic growth?. *Economic inqury*, 49(1), pp. 276-288.
228. Ruge-Murcia, F. J. (2003). Does the Barro–Gordon model explain the behavior of US inflation? A reexamination of the empirical evidence. Journal of monetary economics, 50(6), 1375-1390.
229. Saeed, M. (2014). Bank-related, Industry-related and Macroeconomic Factors Affecting Bank Profitability: A Case of the United Kingdom. *Research Journal of Finance and Accounting*. 5(2). ISSN 2222-1697 (Paper).
230. Sahetapy, K. A. (2019, December). The Relationship Between Macroeconomy Factors and Indonesian Banks' Financial Sustainability. In Abstract Proceedings International Scholars Conference (Vol. 7, No. 1, pp. 1204-1216).
231. Saint-Paul, G. (1992). Technological choice, financial markets and economic development. *European Economic Review*. 36(4), pp. 763-781.
232. Sajter, D. (2017). *Osnove upravljanja rizicima u financijskim institucijama*. Ekonomski fakultet u Osijeku. Knjiga
233. Samsul, M. (2006). Pasar Modal dan Manajemen Portofolio. Jakarta: Penerbit Erlangga.
234. Sbârcea, I. R. (2014). International Concerns for Evaluating and Preventing the Bank Risks–Basel I Versus Basel II Versus Basel III. Procedia Economics and Finance, 16, 336-341.
235. Scherbina, M. A. (2013). *Asset price bubbles: A selective survey*. International Monetary Fund.
236. Schularick, M., Taylor, A. M. (2012). *Credit booms gone bust: Monetary policy, leverage cycles, and financial crises, 1870-2008*. American Economic Review, 102(2).
237. Schuler, K. (1992). *The World History of Free Banking*. in Kevin Dowd, ed., The Experience of Free Banking. London: Routledge.
238. Shen, C., Lee, C. (2006). Same Financial Development Yet Different Economic Growth: Why?. *Journal of Money, Credit and Banking*, 38(7), pp. 1907-1944.
239. Siddiqui, K. (2009). Financial crisis and its impact on the economies of China and India. Research in Applied Economics, 1(1).
240. Sinkey, Joseph F, Jr. (2002). Commercial Bank Financial Management In The Financial service Industry, Sixth Edition. New Jersey: Prentice hall
241. Siropolis, N. C. (1995). *Menadžment malog poduzeća*. 4. izdanje. Zagreb: MATE.
242. Slovik, P., Cournède, B. (2011). Macroeconomic impact of Basel III.
243. Smith, B. D. (2002). Monetary policy, banking crises, and the Friedman rule. American Economic Review, 92(2), 128-134.
244. Sovilj, R. P. (2020). *Izazovi upravljanja kreditnim rizikom u investicionim društvima u kriznim situacijama*. Strani pravni život, 64(3), 43-56.
245. Spasojević, J. (2013). *Kreditni rizik i kreditni derivati. Bankarstvo Magazine*, (1).
246. Sporta, F. O. (2018). Effect of Financial Distress Factors on Performance of Commercial Banks in Kenya (Doctoral dissertation, JKUAT).
247. Stulz, R. M. (1996). *Rethinking risk management*. Journal of applied corporate finance, 9(3), 8-25.
248. Swagel, P. (2009). *The financial crisis: an inside view.* Brookings Papers on Economic Activity.
249. Šegudović, H. (2006). *Prednosti i nedostaci metoda za kvalitativnu analizu rizika*. Infigo IS, Zagreb.

250. Škare, M. (2007). Priroda gospodarskog rasta u Hrvatskoj. Ekonomija Economics, 14(1), 107-126.
251. Škarica, B. (2013). *Determinants of non-performing loans in Central and Eastern European countries*. Article JEL: E32, E44, E52, G10 doi: 10.3326/fintp.38.1.2
252. Šverko, I. (2007). Upravljanje nekreditnim rizicima u hrvatskim financijskim institucijama, HIBO, Zagreb, str. 158.
253. Tamásné Vőneki, Z. (2020). Crisis management and operational risk management in the financial sector in the shadow of COVID-19. ECONOMY AND FINANCE: ENGLISH-LANGUAGE EDITION OF GAZDASÁG ÉS PÉNZÜGY, 7(3), 309-325
254. Thalheimer, R., Ali, M. M. (1979). Time series analysis and portfolio selection: An application to mutual savings banks. Southern Economic Journal, 821-837.
255. Todorović, T. (2009). Upravljanje kreditnim rizikom u banci. *Ekonomski horizonti*, 11(2), pp. 81-99.
256. Tooze, A. (2018). *Crashed: How a Decade of Financial Crises Changed the World*. Knjiga. kolovoz 7, 2018
257. Tran, D. V., Hoang, K., Nguyen, C. (2021). How does economic policy uncertainty affect bank business models?. *Finance Research Letters*, *39*, 101639.
258. Turner, J. D. (2000). The Hayekian approach to banking supervision in New Zealand. *Annals of Public and Cooperative Economics*, 71(1), 105-125.
259. Van der Veen, A. M. (2012). *The Dutch Tulip Mania: The Social Foundations of a Financial Bubble*. Department of Government College of William & Mary.
260. Van Greuning, H., Bratanović, S. B. (2006). Analiza i upravljanje bankovnim rizicima. Mate, Zagreb.
261. Van Greuning, H., Bratanović, S. B. (2020). Analyzing banking risk: a framework for assessing corporate governance and risk management. World Bank Publications.
262. Van Roy, P. (2005). The impact of the 1988 Basel Accord on banks' capital ratios and credit risk-taking: an international study. In EFMA 2004 Basel Meetings, Forthcoming.
263. Varotto, S. (2011). Liquidity risk, credit risk, market risk and bank capital. International Journal of Managerial Finance.
264. Velez, S. B. (2021). Idiosyncratic Viral Loss Theory: Systemic Operational Losses in Banks. Journal of Risk and Financial Management, 14(2), 82.
265. Veselica, V. (2002). Kamatna i profitna stopa. Ekonomski pregled, 53(7-8), 601-621.
266. Virolainen, K. (2004). Macro stress testing with a macroeconomic credit risk model for Finland. Bank of Finland Research Discussion Paper, (18).
267. Vlada Republike Hrvatske (2008). https://vlada.gov.hr/
268. Vodová, P. (2011). Determinants of commercial banks' liquidity in the Czech Republic. ratio, 50, 3.
269. Wieland, V. (2003). Monetary policy and uncertainty about the natural unemployment rate. Available at SSRN 400400.
270. Williams, B. (2002). Domestic and international determinants of bank profits: Foreign banks in Australia. *Journal of Banking & Finance.* 27, pp.1185-1210.
271. Wu, J., Yao, Y., Chen, M., Jeon, M. (2020). Economic uncertainty and bank risk: Evidence from emerging economies. *Journal of International Financial Markets. Institutions and Money*. Journal of International Financial Markets, Institutions and Money, Elsevier, vol. 68(C).
272. Zakon o bankama (2002). NN 84/2002

273. *Zakon o kreditnim institucijama* (2020). Pročišćeni tekst zakona. NN 159/13, 19/15, 102/15, 15/18, 70/19, 47/20 (vidi čl. 70.). na snazi od 25. travnja 2020. https://www.zakon.hr/z/195/Zakon-o-kreditnim-institucijama
274. *Zakon o potrošačkom kreditiranju (2020).* Pročišćeni tekst zakona. NN 75/09, 112/12, 143/13, 147/13, 09/15, 78/15, 102/15, 52/16. na snazi od 30.09.2015.
275. *Zakona o stambenom potrošačkom kreditiranju* (2020). NN 101/2017
276. Zhang, Y., Li, P., Yang, S. A., Huang, S. (2021). Inventory financing under Risk-Adjusted-Return-On-Capital criterion. Naval Research Logistics (NRL).
277. Žiković, I., Žiković, S., Blecich, A. (2015). *The Drivers Behind Household and Corporate Non-performing Loans Ratio: The Case of Croatia*. *Privredna kretanja i ekonomska politika (Economic Trends and Economic Policy*). 24(2).
278. Živko, I. (2006). *Kamatni rizik u bankarstvu – izvori i učinci*. UDK / UDC: 336.7(368.025.6)
279. Živković, A. (2019). Kvalitet upravljanja operativnim rizicima u finansijskim institucijama. Akcionarstvo, 25(1), 5-32.

Popis tablica

Tablica 1. Kategorije rizika u bankama

Tablica 2. Pregled empirijskih istraživanja veze između financijskog sustava i gospodarskoga rasta

Tablica 3. Pregled kretanja BDP-a i kamatnih razlika s valutnom klauzulom i bez valutne klauzule: odnos prema prethodnom razdoblju

Tablica 5. Pearsonov koeficijent korelacije kamatnih razlika s valutnom klauzulom te bez valutne klauzule i BDP-a

Tablica 6. Pregled empirijskih istraživanja uloge ekonomskih politika na bankarski sustav ili na njegove određene dijelove

Tablica 7. Pearsonovi koeficijenti korelacije između makroekonomskih indeksa i bankarskih varijabli

Tablica 8. Korelacija među varijablama: NPL, BDP po glavi stanovnika, stopa nezaposlenosti i indeks trajanja pravnih postupaka (N = 39)

Tablica 9. Definicija malih i srednjih i velikih poduzeća prema standardima Europske unije

Tablica 10. Rezultati analize šteta nastalih operativnim rizikom

Tablica 11. Iznos nastale štete po vrstama štetnog događaja u mil. $

Tablica 12. Prikaz štetnih događaja raspoređenih prema zemljama u kojima je prijavljen štetni događaj

Popis slika

Slika 1. Djelovanje kreditnih rizika na makroekonomska kretanja.

Slika 2. Djelovanje makroekonomskih kretanja na kreditnu politiku banaka

Slika 3. Ponuda i potražnja za kreditnim proizvodima

Slika 4. Izračun očekivanih gubitaka

Slika 5. Primjena formule za izračun očekivanih gubitaka: EL = PD × EAD × LGD

Slika 6. Tri osnovna stupa sukladno Baselu II

Slika 7. Konceptualni okvir primjene Basela III

Slika 8. Basel III: Metode primjene u svrhu izračuna kapitala kreditnog rizika

Slika 9. Mjere izloženosti riziku

Slika 10. Struktura ukupne izloženosti banaka riziku na dan 30. lipnja 2019.

Slika 11. Stopa ukupnoga kapitala banaka

Slika 12. Grafički prikazi distribucije i korelacije ispitivanih varijabli (matrica raspršenoga grafikona za sve ispitivane varijable).

Popis grafikona

Grafikon 1. Prosječan broj kriza kroz desetljeće

Grafikon 2. Kretanje kamatnih stopa na novoodobrene kunske kredite

Grafikon 3. Prikaz kretanja kamatnih stopa na novoodobrene kunske depozite s v Grafikon 4. Prikaz kretanja kamatnih stopa na novoodobrene kunske kredite i depozite bez valutne klauzule

Grafikon 5. Prikaz kretanja kamatnih stopa na novoodobrene kunske kredite i depozite s valutnom klauzulom

Grafikon 6. Kretanje BDP-a u odnosu na prethodnu godinu (izraženo u postocima)

Grafikon 7. Kretanje BDP-a u Hrvatskoj kroz godine; analiza vremenske serije

Grafikon 8. Kretanje kamatnih razlika i BDP-a u Hrvatskoj po kvartalima od 2007. do 2019. godine

Grafikon 9. Kretanje makroekonomskih varijabli u Hrvatskoj po kvartalima od 2007. do 2019. godine

Grafikon 10. Kretanje bankarskih varijabli u Hrvatskoj po kvartalima od 2007. do 2019. godine

Grafikon 11. Kretanje varijable BDP-a i kamatne razlike bez valutne klauzule u Hrvatskoj po kvartalima od 2007. do 2019. godine

Grafikon 12. Kretanje inflacije i kamatne razlike s valutnom klauzulom u Hrvatskoj po kvartalima od 2007. do 2019. godine

Grafikon 13. Kretanje stope nezaposlenosti, NPL-a i udjela plasmana banaka u Hrvatskoj po kvartalima od 2007. do 2019. godine

Popis dijagrama

Dijagram 1. Odnos kretanja kamatnih razlika bez valutne klauzule i BDP-a

Dijagram 2. Odnos kretanja kamatnih razlika s valutnom klauzulom i inflacije

Dijagram 3. Prikaz odnosa u kretanju plasmana banke i stope nezaposlenosti

Dijagram 4. Prikaz odnosa u kretanju NPL-a i stope nezaposlenosti

Popis kratica i simbola

HNB = Hrvatska narodna banka
BDP = bruto domaći proizvod
NPL = neprihodujući krediti
HUB = Hrvatska udruga banaka
EBA = Europska banka (engl. *European Banking Authority*)

Prilozi

PRILOG 1.

Kretanje kamatnih stopa u RH u razdoblju od 2000. do 2019. godine

Godina	Kvartali	Kamatne stope na kunske kredite bez valutne klauzule *(pasivna kamata)*	Kamatne stope na kunske kredite s valutnom klauzulom *(pasivna kamata)*	Kamatne stope banaka na kunske depozite bez valutne klauzule *(aktivna kamata)*	Kamatne stope banaka na kunske depozite s valutnom klauzulom *(aktivna kamata)*
2000.	Q1	13,13	12,59	8,74	4,03
	Q2	13,53	12,05	8,19	3,82
	Q3	10,70	11,38	7,48	3,71
	Q4	10,76	11,23	7,25	3,50
2001.	Q1	10,23	10,12	7,20	3,22
	Q2	9,40	10,10	6,71	3,07
	Q3	9,37	9,59	6,26	2,91
	Q4	9,20	9,45	5,95	2,65
2002.	Q1	14,34	9,35	5,44	2,65
	Q2	13,21	8,34	4,56	2,58
	Q3	12,02	8,22	4,16	2,58
	Q4	11,79	8,19	3,64	2,54
2003.	Q1	11,60	8,35	3,44	2,47
	Q2	11,51	7,93	3,22	2,29
	Q3	11,65	8,04	4,12	2,20
	Q4	11,82	7,52	4,25	2,19
2004.	Q1	12,09	7,49	5,08	2,41
	Q2	11,65	7,46	3,69	2,51
	Q3	11,58	7,30	5,76	2,57
	Q4	11,67	7,22	4,05	2,62
2005.	Q1	11,83	7,10	4,02	2,64
	Q2	11,39	6,75	3,45	2,64
	Q3	11,08	6,55	4,21	2,50
	Q4	10,47	6,38	3,54	2,55
2006.	Q1	10,54	6,42	3,34	2,64
	Q2	10,05	6,31	3,28	2,67
	Q3	9,75	6,24	3,25	2,74
	Q4	9,39	6,29	3,20	2,91
2007.	Q1	9,38	6,26	3,50	3,01
	Q2	9,28	6,07	3,96	3,11
	Q3	9,37	6,48	4,67	3,28
	Q4	9,29	6,58	5,67	3,41
2008.	Q1	9,85	7,00	5,09	3,44
	Q2	9,75	7,53	4,16	3,50
	Q3	9,90	7,51	4,48	3,58
	Q4	10,78	7,85	7,81	3,85
2009.	Q1	11,39	7,85	9,65	3,94

	Q2	11,52	8,12	6,18	3,93
	Q3	11,84	8,17	6,54	4,01
	Q4	11,47	8,31	3,42	3,99
2010.	Q1	10,68	8,35	2,47	3,72
	Q2	10,41	8,00	2,09	3,38
	Q3	10,29	8,03	1,86	3,20
	Q4	10,14	7,97	1,93	3,10
2011.	Q1	10,12	7,68	1,68	2,95
	Q2	9,92	7,35	1,43	2,89
	Q3	9,09	7,18	1,98	2,89
	Q4	9,60	7,15	2,59	2,87
2012.	Q1	9,84	7,44	3,38	2,92
	Q2	9,51	7,45	2,27	2,91
	Q3	9,49	7,28	2,80	2,90
	Q4	9,52	6,91	2,63	2,89
2013.	Q1	9,49	6,96	2,51	2,71
	Q2	9,30	6,87	2,30	2,44
	Q3	9,11	6,84	2,18	2,33
	Q4	9,06	6,31	2,38	2,24
2014.	Q1	8,63	6,48	2,36	3,00
	Q2	8,51	6,63	2,24	3,08
	Q3	8,42	6,67	2,03	2,78
	Q4	8,43	6,51	1,92	2,83
2015.	Q1	8,32	6,17	1,97	2,62
	Q2	8,31	6,14	1,84	2,40
	Q3	7,96	5,98	1,69	2,25
	Q4	7,79	5,85	1,69	2,50
2016.	Q1	7,62	5,72	1,50	2,37
	Q2	7,21	5,26	1,33	1,68
	Q3	7,27	4,86	1,01	1,36
	Q4	7,11	4,78	0,90	1,58
2017.	Q1	7,22	4,52	0,83	0,93
	Q2	7,06	4,45	0,71	1,15
	Q3	6,98	4,10	0,69	0,89
	Q4	6,57	4,01	0,83	1,09
2018.	Q1	6,64	3,86	0,71	0,70
	Q2	6,45	3,67	0,58	1,11
	Q3	6,23	3,54	0,47	0,64
	Q4	6,15	3,67	0,53	1,05
2019.	Q1	6,04	3,71	0,37	0,54
	Q2	5,87	3,42	0,29	0,36
	Q3	5,76	3,27	0,25	0,43
	Q4	5,62	2,78	0,22	0,42

Izvor: Izrada autora, 2020.

PRILOG 2.

Kamatna razlika krediti s valutnom klauzulom i bez valutne klauzule

Godina	Kvartali	Kamatni spread krediti bez valutne klauzule	Kamatni spread krediti s valutnom klauzulom
2000.	Q1	4,39	8,56
	Q2	5,34	8,23
	Q3	3,22	7,67
	Q4	3,51	7,72
2001.	Q1	3,03	6,90
	Q2	2,69	7,03
	Q3	3,11	6,68
	Q4	3,25	6,80
2002.	Q1	8,90	6,69
	Q2	8,65	5,76
	Q3	7,86	5,64
	Q4	8,15	5,65
2003.	Q1	8,16	5,88
	Q2	8,29	5,64
	Q3	7,53	5,84
2004.	Q4	7,57	5,33
	Q1	7,00	5,08
	Q2	7,96	4,95
	Q3	5,82	4,73
2005.	Q4	7,63	4,60
	Q1	7,82	4,46
	Q2	7,94	4,11
	Q3	6,87	4,04
	Q4	6,93	3,83
2006.	Q1	7,20	3,78
	Q2	6,77	3,64
	Q3	6,51	3,50
	Q4	6,19	3,39
2007.	Q1	5,88	3,25
	Q2	5,32	2,96
	Q3	4,70	3,20
	Q4	3,62	3,17
2008.	Q1	4,75	3,56
	Q2	5,59	4,02
	Q3	5,42	3,93
	Q4	2,97	4,00
2009.	Q1	1,74	3,92
	Q2	5,34	4,19
	Q3	5,29	4,16
	Q4	8,05	4,32
2010.	Q1	8,21	4,63

	Q2	8,31	4,62
	Q3	8,42	4,83
	Q4	8,21	4,87
2011.	Q1	8,44	4,73
	Q2	8,50	4,47
	Q3	7,11	4,29
	Q4	7,01	4,27
2012.	Q1	6,46	4,52
	Q2	7,24	4,54
	Q3	6,69	4,38
	Q4	6,89	4,02
2013.	Q1	6,98	4,24
	Q2	7,00	4,43
	Q3	6,93	4,51
	Q4	6,68	4,06
2014.	Q1	6,27	3,48
	Q2	6,27	3,55
	Q3	6,39	3,89
	Q4	6,51	3,68
2015.	Q1	6,35	3,55
	Q2	6,48	3,74
	Q3	6,27	3,73
	Q4	6,10	3,36
2016.	Q1	6,12	3,34
	Q2	5,88	3,57
	Q3	6,26	3,50
	Q4	6,22	3,20
2017.	Q1	6,39	3,59
	Q2	6,35	3,30
	Q3	6,29	3,21
	Q4	5,74	2,93
2018.	Q1	5,93	3,17
	Q2	5,87	2,56
	Q3	5,76	2,90
	Q4	5,62	2,62
2019.	Q1	5,67	3,16
	Q2	5,58	3,06
	Q3	5,51	2,85
	Q4	5,40	2,36

Izvor: Izrada autora, 2020.

PRILOG 3.

Kretanja kamatne razlike i bruto domaćeg proizvoda (BDP)

Godina	Kamatni spread krediti s valutnom klauzulom	Kamatni spread krediti bez valutne klauzule	BDP tržišne cijene / realne stope rasta odnosu na prethodno tromjesečje	Bruto domaći proizvod (tržišne cijene) u mil. kn
2000.	8,56	4,39	2,1	40.433
	8,23	5,34	-0,9	44.462
	7,67	3,22	2,1	48.551
	7,72	3,51	1,3	45.925
2001.	6,90	3,03	0,1	44.022
	7,03	2,69	1,1	48.784
	6,68	3,11	0,6	51.640
	6,80	3,25	1,4	48.908
2002.	6,69	8,90	1,9	48.614
	5,76	8,65	0,8	52.490
	5,64	7,86	1,7	57.547
	5,65	8,15	-0,2	52.434
2003.	5,88	8,16	3,4	53.370
	5,64	8,29	1,4	58.336
	5,84	7,53	0,5	63.467
	5,33	7,57	-0,1	57.400
2004.	5,08	7,00	2,9	57.722
	4,95	7,96	0,1	62.848
	4,73	5,82	0,7	67.988
	4,60	7,63	1,2	62.436
2005.	4,46	7,82	-0,6	60.479
	4,11	7,94	3,6	67.870
	4,04	6,87	1,3	73.883
	3,83	6,93	0,7	67.783
2006.	3,78	7,20	0,9	66.940
	3,64	6,77	1,2	73.802
	3,50	6,51	1,4	79.835
	3,39	6,19	1,4	73.868
2007.	3,25	5,88	2,5	73.563
	2,96	5,32	0,6	81.132
	3,20	4,70	0,2	87.256
	3,17	3,62	0,2	80.840
2008.	3,56	4,75	2,4	79.421
	4,02	5,59	0,6	88.267
	3,93	5,42	-1,6	94.562
	4,00	2,97	-2,7	84.485
2009.	3,92	1,74	-4,5	76.119
	4,19	5,34	0,1	84.127

	4,16	5,29	-1,3	88.353
	4,32	8,05	0,7	82.172
2010.	4,63	8,21	-1,1	75.070
	4,62	8,31	-1,0	82.202
	4,83	8,42	1,5	89.920
	4,87	8,21	-1,3	81.632
2011.	4,73	8,44	-0,6	74.842
	4,47	8,50	1,6	84.353
	4,29	7,11	-0,4	91.271
	4,27	7,01	-0,7	82.749
2012.	4,52	6,46	-1,2	74.603
	4,54	7,24	-0,8	83.231
	4,38	6,69	0,3	90.754
	4,02	6,89	-0,9	81.921
2013.	4,24	6,98	0,6	75.283
	4,43	7,00	0,0	84.213
	4,51	6,93	-0,7	90.384
	4,06	6,68	-0,2	81.330
2014.	3,48	6,27	0,0	73.959
	3,55	6,27	0,5	83.766
	3,89	6,39	-0,4	91.250
	3,68	6,51	0,8	82.368
2015.	3,55	6,35	0,7	75.430
	3,74	6,48	0,9	85.628
	3,73	6,27	1,1	94.069
	3,36	6,10	-0,2	84.569
2016.	3,34	6,12	1,6	77.020
	3,57	5,88	0,7	87.959
	3,50	6,26	1,1	98.645
	3,20	6,22	0,9	87.544
2017.	3,59	6,39	0,4	79.587
	3,30	6,35	1,1	92.338
	3,21	6,29	0,7	103.307
	2,93	5,74	0,6	91.194
2018.	3,17	5,93	-0,2	83.351
	2,56	5,87	2,1	96.779
	2,90	5,76	0,3	108.246
	2,62	5,62	0,4	94.590
2019.	3,16	5,67	1,1	88.104
	3,06	5,58	0,6	100.460
	2,85	5,51	0,6	112.905
	2,36	5,40	0,4	98.633

Izvor: Izrada autora, 2020.

PRILOG 4.

Kretanje makroekonomskih varijabli i varijabli bankarskog sustava u Hrvatskoj

Godina	BDP realne stope rasta – odnos prema prethodnom tromjesečju	INFLACIJA	Stopa nezaposlenosti u postocima	UDIO DJELOMIČNO NADOKNADIVIH I POTPUNO NENADOKNADIVIH KREDITA U UKUPNIM KREDITIMA NPL	Kamatna razlika s valutnom klauzulom: odnos prema prethodnom kvartalu	Kamatna razlika bez valutnom klauzulom: odnos prema prethodnom kvartalu	Plasmani
2007.Q1	2,5	0,9	11,4	5,2	-0,1	-0,3	1,50
2007.Q2	0,6	0,1	9,3	4,9	-0,3	-0,6	1,41
2007.Q3	0,2	1,8	8,9	5,1	0,2	-0,6	0,48
2007.Q4	0,2	2,2	10,1	4,8	0,0	-1,1	1,42
2008.Q1	2,4	0,4	10,3	4,8	0,4	1,1	0,68
2008.Q2	0,6	1,9	8,1	4,8	0,5	0,8	0,82
2008.Q3	-1,6	-0,1	7,0	4,8	-0,1	-0,2	0,64
2008.Q4	-2,7	-0,7	8,8	4,8	0,1	-2,5	1,27
2009.Q1	-4,5	0,8	9,7	4,9	-0,1	-1,2	0,28
2009.Q2	0,1	0,1	9,0	5,1	0,3	3,6	-0,59
2009.Q3	-1,3	-0,3	8,5	6,0	0,0	0,0	-0,29
2009.Q4	0,7	-0,1	9,7	6,4	0,2	2,8	0,41
2010.Q1	-1,1	0,6	11,2	7,8	0,3	0,2	0,31
2010.Q2	-1,0	0,1	12,0	8,8	0,0	0,1	0,57
2010.Q3	1,5	0,1	11,2	9,6	0,2	0,1	0,40
2010.Q4	-1,3	0,3	12,1	10,3	0,0	-0,2	0,26
2011.Q1	-0,6	1,3	14,3	11,2	-0,1	0,2	-0,02
2011.Q2	1,6	-0,2	14,0	11,5	-0,3	0,1	0,68
2011.Q3	-0,4	0,4	12,7	11,9	-0,2	-1,4	0,49
2011.Q4	-0,7	-0,2	13,7	12,3	0,0	-0,1	0,44
2012.Q1	-1,2	2,1	16,4	12,4	0,2	-0,5	0,08
2012.Q2	-0,8	1,1	14,7	12,7	0,0	0,8	-0,83
2012.Q3	0,3	1,9	14,6	13,3	-0,2	-0,6	-0,52
2012.Q4	-0,9	-0,3	18,0	14,1	-0,4	0,2	-0,76
2013.Q1	0,6	0,6	18,0	13,9	0,2	0,1	0,15
2013.Q2	0,0	-0,2	16,8	14,6	0,2	0,0	-0,09
2013.Q3	-0,7	0,7	16,7	15,1	0,1	-0,1	0,20
2013.Q4	-0,2	-0,3	17,6	15,3	-0,4	-0,2	-0,44
2014.Q1	0,0	0,2	18,7	15,7	-0,6	-0,4	0,01
2014.Q2	0,5	-0,1	16,6	16,1	0,1	0,0	-0,32
2014.Q3	-0,4	0,6	15,7	16,6	0,3	0,1	-0,08
2014.Q4	0,8	-1,1	18,3	17,2	-0,2	0,1	-0,14
2015.Q1	0,7	1,2	17,8	17,1	-0,1	-0,2	0,32
2015.Q2	0,9	0,0	15,5	17,1	0,2	0,1	-0,37
2015.Q3	1,1	0,2	15,4	17,3	0,0	-0,2	-0,41
2015.Q4	-0,2	-0,8	16,1	17,1	-0,4	-0,2	-0,53
2016.Q1	1,6	0,3	15,4	16,7	0,0	0,0	-0,77

2016.Q2	0,7	0,1	12,8	16,1	0,2	-0,2	-0,27
2016.Q3	1,1	0,9	10,9	13,2	-0,1	0,4	-0,18
2016.Q4	0,9	-0,1	13,4	13,0	-0,3	0,0	-0,03
2017.Q1	0,4	0,5	14,1	12,2	0,4	0,2	-0,09
2017.Q2	1,1	-0,6	11,0	12,6	-0,3	0,0	-0,20
2017.Q3	0,7	1,5	9,0	11,9	-0,1	-0,1	0,08
2017.Q4	0,6	-0,3	10,9	10,9	-0,3	-0,6	-0,17
2018.Q1	-0,2	0,5	10,3	8,8	0,2	0,2	0,00
2018.Q2	2,1	0,4	7,5	8,9	-0,6	-0,1	0,59
2018.Q3	0,3	0,8	7,3	8,9	0,3	-0,1	0,01
2018.Q4	0,4	-1,0	8,6	8,1	-0,3	-0,1	0,06
2019.Q1	1,1	1,3	7,6	7,6	0,5	0,1	0,50
2019.Q2	0,6	0,3	6,1	7,4	-0,1	-0,1	0,04
2019.Q3	0,6	0,5	5,7	7,3	-0,2	-0,1	-0,24
2019.Q4	0,4	-0,3	7,2	6,0	-0,5	-0,1	0,63

Izvor: Izrada autora, 2020.

PRILOG 5. b

Kategorije rizika u bankarskom sustavu po tipu prijevare – 1., 2. i 3. razina

1. razina	2. razina	3. razina
1.Interna prijevara	1.Nasilni događaj	Provala
		Pljačka (uspješna(neuspješna)
		Krađa
		Teroristički napad
		Napad na bankomat (uspješan/neuspješan)
	2. Financijski događaj	Zlouporaba
		Nepravilno rukovanje
		Prijevara vezana uz kredit (gotovinski, potrošački, stambeni...)
		Neovlaštene transakcije
		Neovlašteno unovčavanje
		Ostala financijska kaznena djela
		Izdavanje nepokrivenih čekova
	3. IT događaj	Krađa podataka
		DDOS napad
		Pokušaj provale u kompjuter
		Napad virusa
		Zlouporaba podataka o klijentima
		Velika količina spama
		Ostali događaji vezani uz sigurnost informatičkog sustava
	4. Zlouporaba bankovne kartice	Krađa kartice
		Prijevara počinjena lažnom karticom
		Zlouporaba interneta i zlouporaba vezana uz narudžbe preko pošte i preko telefona
		Zlouporaba podataka o klijentima
		Ostale prijevare
	5. Korupcija	Korupcija – podmićivanje
	6. Rizik usklađenosti	Financiranje terorizma
		Pranje novca
		Utjecaj trgovanja povlaštenom informacijom na tržište
		Kršenje etičkoga kodeksa
		Neusklađenost trgovanja bančinih relevantnih osoba s relevantnim internim aktima
		Ispreplетanje odnosa između investicijskih i financijskih aktivnosti
	7. Ostali događaji	Prijetnja bombom
		Ostali događaji vezani uz sigurnost
2.Eksterna prijevara	1. Nasilni događaj	Provala
		Pljačka (uspješna/neuspješna)
		Krađa
		Teroristički napad
		Napad na bankomat (uspješan/neuspješan)
		Palež

	2. Financijski događaj	Prijevara vezana uz kredit (gotovinski, potrošački, stambeni..)
		Neovlaštene transakcije
		Neovlašteno unovčavanje
		Prijevara bankovnom garancijom
		Ostala financijska kaznena djela
		Zlouporaba čekova
		Prijevara počinjena krivotvorenim dokumentima
	3. IT događaj	Krađa podataka
		DDOS napad
		Pokušaj provale u kompjuter
		Napad virusa
		Zlouporaba podataka o klijentima
		Velika količina spama
		Ostali događaji vezani uz sigurnost informatičkog sustava
		Internetska prijevara
	4. Zlouporaba bankovne kartice	Krađa kartice
		Prijevara počinjena lažnom karticom
		Zlouporaba interneta vezana uz narudžbe preko pošte i preko telefona
		Zlouporaba podataka o klijentima
		Ostale prijevare
		Instalacija skimming uređaja na bankomatu
	5. Događaji vezani uz poštivanje zakonitosti	Pranje novca
	6. Ostali događaji	Prijetnja bombom
		Ostali događaji vezani uz sigurnost
3.Prakse zapošljavanja, zaštita na radnom mjestu	1. Odnos sa zaposlenicima	Radnje koje nisu u skladu s ugovorom o radu
		Odlazak ključnih zaposlenika, menadžera
		Prekoračenje rokova vezanih uz radni odnos
		Nedostatak obuke i edukacije
		Povreda zastupanja i zaposlenja
		Štrajkovi, prosvjedi
		Sve vrste diskriminacije na radnom mjestu
		Plaće i kompenzacije, beneficije, pitanja u vezi s prestankom radnog odnosa
	2. Sigurno radno okruženje, zaštita radnika na poslu	Ozljeda na radnom mjestu
		Nesreća na radu
		Nesreća s pojedincem/klijentom koju je uzrokovala banka (ozljeda)
4.Šteta na materijalnoj imovini	1. Prirodna katastrofa	Poplava
		Potres
		Šteta nakon oluje, udar groma
	2. Ostali događaji	Šteta i vandalizam
		Društveni nemiri
		Štete koje su zaposlenici nenamjerno napravili

		Šteta koje su zaposlenici namjerno napravili
		Vatra
		Namjerne štete uzrokovane od treće strane
		Nenamjerne štete uzrokovane od treće strane
5. Prekid sistemske veze, greška u sustavu	1. Funkcioniranje IT sustava	Pogreška u hardveru
		pogreška u softveru
		Komunikacijska pogreška
		Nestanak struje
	2. IT razvoj, projekti	Manjkava, slaba specifikacije s poslovne strane
		pogreške u programiranju
		Pogreške u testiranju
	3. Sistemske veze	Problemi u sinkronizaciji
		Problemi sa sučeljem
6. Klijenti, proizvodi, poslovna praksa	1. Kršenje pravila	Kršenje pravila o sukobu interesa
		Kršenje pravila o zaštiti podataka
		Zlouporaba povjerljive informacije
		Trgovanje povlaštenom informacijom (za račun banke) i prekršaji drugih banaka
		Poslovanje bez dozvole
		Povreda bankarske tajne
		Povreda tajni vezanih uz vrijednosne papire
		Kršenje etičkih pravila
		Kršenje internih propisa
		Kršenje pravila utakmice
		Neusklađenost internih i eksternih propisa
		Ostali prekršaji
		Neplaćanje poreza
		Neprikladna trgovina i tržišna praksa
		Manipulacija tržištem
	2. Neprikladna praksa	Pogreška u proizvodu
		Pogreška u modelu
		Pogreška u dizajnu
		Poslovna komunikacija
		Problemi s pružanjem podataka izvan banke / s pružanjem informacija
		Neadekvatne klauzule ugovora
7. Izvršenje, isporuka i upravljanje procesima	1. Upravljanje klijentima i zadacima	Netočna komunikacija
		Pogreška u administraciji, čuvanju ili prenošenju podataka
		Propušteni rok
		Računovodstvena, knjigovodstvena ili ident. pogreška

		Nepravilno izvršavanje drugih zadataka
		Pogreška u administraciji
		Pogreška u upotrebi kolaterale
		Nedostaju autorizacije klijenata
		Nedostaje pravna dokumentacija
		Pristup računima bez autorizacije
		Netočne informacije o klijentima i računima
		Gubitak uzrokovan nemarom prema klijentima
		Autorizacija transakcija koja je nije u skladu s pravilima
		Agresivna prodaja
		Neadekvatan odabir klijenta (kršenjem pravila)
		Prekoračenje limita izloženosti prema klijentu
		Netočno podnošenje
		Netočna, neprecizna regulatorna izvješća
	2. Eksterni partneri	Kršenje pravila kartičnih kuća
		Ovisnost o partnerima u monopolističkoj poziciji
		Loša kvaliteta usluga
		Nedostatak usluga
		Kršenje ugovora (ili ugovorne obveze)
	3. Interna revizija	Praćenje interne revizije
	4. Eksterno nadležno tijelo	Novčana kazna
	5. Usluge	Ovisnost o partnerima u monopolističkoj poziciji
		Loša kvaliteta usluga
		Nedostatak usluga

Izvor: Izrada autora, 2020.