ANALIZA FAKTORA KOJI UTIČU NA RAST NEKVALITETNIH KREDITA U BANKARSKOM SEKTORU BOSNE I HERCEGOVINE

By Zorana Agić

WORD COUNT 82348 TIME SUBMITTED 10-NOV-2017 11:58AM
PAPER ID 32784112

65
UNIVERZITET SINGIDUNUM
BEOGRAD

DEPARTMAN ZA POSLEDIPLOMSKE STUDIJE
I MEĐUNARODNU SARADNJU

DOKTORSKA DISERTACIJA

ANALIZA FAKTORA KOJI UTIČU NA RAST NEKVALITETNIH KREDITA U BANKARSKOM SEKTORU BOSNE I HERCEGOVINE

MENTOR
Prof. dr Zoran Jeremić

KANDIDAT
Zorana Agić

Beograd, 2017. godina

SADRŽAJ

UVODNA RAZMATRANJA 5

1. Predmet istraživanja 7
2. Značaj i aktuelnost istraživanja 7
3. Cilj istraživanja 8
4. Hipoteze istraživanja 8
5. Metode istraživanja 9
6. Obim i ograničenja istraživanja 10
7. Struktura rada 11

I DIO: POJMOVNO ODREĐENJE I PREGLED EMPIRIJSKE LITERATURE O NEKVALITETNIM KREDITIMA 14

1. POJAM NEKVALITETNIH KREDITA 14

1.1. Definicija nekvalitetnih kredita na finansijskim tržištima razvijenih zemalja 14
1.2. Definicija nekvalitetnih kredita u Bosni i Hercegovini 21
1.3. Definicija nekvalitetnih kredita u akademskoj literaturi 22

2. PREGLED EMPIRIJSKE LITERATURE O NEKVALITETNIM KREDITIMA 23

2.1. Osnovne karakteristike studija o nekvalitetnim kreditima 23
2.2. Studije sprovedene u pojedinačnim zemljama 24
2.3. Studije sprovedene u više zemalja 32
2.4. Studije sprovedene u Bosni i Hercegovini 38

3. KONCEPTUALNI OKVIR 39

II DIO: IDENTIFIKACIJA FAKTORA KOJI UTIČU NA NEKVALITETNE KREDITE 43

1. MAKROEKONOMSKI FAKTORI 44

1.1. Stopa rasta realnog bruto domaćeg proizvoda 45
1.2. Stopa nezaposlenosti 46
1.3. Stopa inflacije 47

2. SPECIFIČNI BANKARSKI FAKTORI 48

2.1. Koeficijent adekvatnosti kapitala 52
2.2. Odnos kredita i depozita 52
2.3. Pokazatelji profitabilnosti banke 53
2.3.1. Prinos na aktivu 54
2.3.2. Prinos na akcijski kapital 55
2.4. Aktivna kamatna stopa 55
2.5. Kreditni rast 56

III DIO: KARAKTERISTIKE I PERFORMANSE BANKARSKOG SEKTORA BOSNE I HERCEGOVINE....58

1. FINANSIJSKI SEKTOR BOSNE I HERCEGOVINE....59

2. BANKARSKI SEKTOR BOSNE I HERCEGOVINE....64

2.1. Reforma bankarskog sistema Bosne i Hercegovine....64
2.2. Institucionalni okvir....65
2.3. Komercijalne banke u Bosni i Hercegovini....65
2.3.1. Broj komercijalnih banaka....66
2.3.2. Vlasnička struktura komercijalnih banaka....67
2.3.3. Ljudski resursi u komercijalnim bankama....70

3. FINANSIJSKI POKAZATELJI POSLOVANJA BANKARSKOG SEKTORA BOSNE I HERCEGOVINE....73

3.1. Struktura bilansa banaka....73
3.2. Kvalitet aktive komercijalnih banaka....76
3.3. Kapital komercijalnih banaka....78
3.4. Likvidnost komercijalnih banaka....80
3.5. Profitabilnost komercijalnih banaka....81

4. DEPOZITNI I KREDITNI POTENCIJAL BANKARSKOG SEKTORA BOSNE I HERCEGOVINE....84

4.1. Depoziti komercijalnih banaka....84
4.1.1. Sektorska struktura prenosivih depozita....86
4.1.2. Sektorska struktura ostalih depozita....88
4.2. Krediti komercijalnih banaka....91
4.2.1. Sektorska struktura kratkoročnih kredita....93
4.2.2. Sektorska struktura dugoročnih kredita....95

IV DIO: ANALIZA FAKTORA KOJI UTIČU NA NEKVALITETNE KREDITE U BANKARSKOM SEKTORU BOSNE I HERCEGOVINE....97

1. METODOLOGIJA ISTRAŽIVANJA....98

1.1. Način istraživanja i pristup....98
1.2. Podaci i instrumenti za prikupljanje podataka....98
1.3. Analiza i prezentacija podataka....99
1.4. Promjenljive u istraživanju....100
1.4.1. Zavisna promjenljiva....100
1.4.2. Nezavisne promjenljive....101
1.5. Specifikacija modela....104
1.5.1. Specifikacija modela korelacione analize....105
1.5.2. Specifikacija modela regresione analize....106

2. REZULTATI ISTRAŽIVANJA....110

2.1. Promjenljive u istraživanju....110
2.1.1. Ekonomska kretanja u Bosni i Hercegovini....110
2.1.2. Bankarski sektor....113
2.2. Deskriptivna statistika....117

2.3. Procjena normalnosti raspodjele i transformacija podataka 117
2.4. Korelaciona analiza 122
2.4.1. Analiza makroekonomskih faktora koji utiču na nekvalitetne kredite 124
2.4.2. Analiza specifičnih bankarskih faktora koji utiču na nekvalitetne kredite 128
2.5. Prosta regresiona analiza 136
2.5.1. Analiza makroekonomskih faktora koji utiču na nekvalitetne kredite 138
2.5.2. Analiza specifičnih bankarskih faktora koji utiču na nekvalitetne kredite 146
2.6. Višestruka regresiona analiza 162
2.7. Analiza kretanja nekvalitetnih kredita 169
2.8. Rezultati sprovedenog anketiranja 172

3. DISKUSIJA 184

3.1. Makroekonomski faktori koji utiču na nekvalitetne kredite 184
3.2. Specifični bankarski faktori koji utiču na nekvalitetne kredite 186

V DIO: KOMPARATIVNA ANALIZA TRENDOVA KRETANJA NEKVALITETNIH KREDITA NA FINANSIJSKOM TRŽIŠTU BOSNE I HERCEGOVINE, ZEMALJA REGIONA I RAZVIJENIH ZEMALJA 190

1. NEKVALITETNI KREDITI NA FINANSIJSKIM TRŽIŠTIMA ZEMALJA REGIONA 191

2. NEKVALITETNI KREDITI NA FINANSIJSKIM TRŽIŠTIMA RAZVIJENIH ZEMALJA 164

3. KOMPARATIVNA ANALIZA NEKVALITETNIH KREDITA 196

ZAKLJUČNA RAZMATRANJA 198

1. Zaključak 198
2. Predlog mjera za smanjenje nekvalitetnih kredita 204

LITERATURA ..... Error! Bookmark not defined.

PRILOZI 216

UVODNA RAZMATRANJA

Bankarski sektor ima veoma važnu ulogu u Bosni i Hercegovini, prvenstveno zbog nedovoljno razvijenog tržišta kapitala, ali i zbog postojanja nedovoljnog broja nebankarskih finansijskih institucija. Prema tome, stabilnost bankarskog sektora je veoma važna za cjelokupnu ekonomiju Bosne i Hercegovine. Na stabilnost bankarskog sektora utiče više faktora. Tokom globalne finansijske krize došlo je do visokog rasta nekvalitetnih kredita (engl. *nonperforming loans*), što je ugrozilo stabilnost bankarskog sektora Bosne i Hercegovine. Pored toga, povećanje nekvalitetnih kredita ugrozilo je i ekonomsku stabilnost cijele zemlje, tako da komercijalne banke, a i regulatori, moraju preduzeti više konkretnih mjera pomoću kojih bi se njihov nivo smanjio u narednom periodu.

U posljednjih nekoliko godina, kredit je postao skoro najznačajniji faktor finansijskog opstanka jedne zajednice, jer on podstiče i omogućava njene privredne aktivnosti. Samim tim, kredit podstiče i cjelokupan ekonomski razvoj te zajednice. Banke odobravaju kredite koji se razlikuju po pojavnim oblicima, namjeni, načinima i rokovima otplate, obezbjeđenju i drugim karakteristikama, ali svi oni se koriste za zadovoljenje ličnih potreba potrošača onda kada potrošač nema dovoljno sopstvenih sredstava. U svom poslovanju, banke prikupljaju finansijska sredstva od onih koji imaju višak sredstava i plasiraju ih onima kojima su ta sredstva neophodna, pa se za banke često kaže da su depozitno – kreditne institucije.

Slobodno se može reći da je kredit vid pozajmljivanja sredstava, najčešće novčanih, koja povjerilac daje dužniku ukoliko ispuni određene uslove, a dužnik preuzima obavezu da ta sredstva vrati u skladu sa postavljenim uslovima. Krediti se odobravaju pojedincima, preduzećima i državi, a čine osnovnu komponentu aktive u većini banaka. Upravo zbog toga, kvalitet aktive banaka u velikoj mjeri zavisi od kvaliteta kreditnog portfolia.

Krediti sa sobom uvijek nose i kreditni rizik, koji predstavlja jednu od ključnih prijetnji kvalitetu bankarskog portfolia. Banke su konstantno izložene kreditnom riziku koji predstavlja opasnost da dužnik neće moći u potpunosti izmiriti svoju obavezu prema banci u roku, ili da će je samo djelimično izmiriti. Ovaj rizik se uglavnom odnosi na nemogućnost naplate potraživanja od dužnika, ali može nastati i zbog kašnjenja naplate ili restrukturiranja kredita zbog pogoršanja kreditne sposobnosti dužnika. I dok se većina problema kašnjenja u naplati potraživanja obično rješava na adekvatan način, restrukturiranje kredita ukazuje na pad kreditnog rejtinga i predstavlja opasnost da banka neće povratiti uložena sredstva. Upravo zbog toga, procjena kreditnog rizika u banci je osnov za njeno uspješno poslovanje.

Postojanje rizika uvijek je vezano za donošenje odluka, a te odluke mogu rezultovati pozitivnim ishodima ili donijeti određenu opasnost i prijetnju. Jedna od takvih odluka je i kreditna odluka, koja, ukoliko se procijeni kao loša, može rezultovati pojavom nekvalitetnih kredita koji mogu ozbiljno oštetiti finansijsku poziciju banke i imati negativan uticaj na njen rad. Prema tome, osnovni cilj menadžmenta banke treba da se odnosi na efikasno upravljanje rizicima, koje podrazumijeva identifikaciju, mjerenje i nadzor neizvjesnosti sa kojima se svi susreću obavljajući određene poslovne aktivnosti. Ukoliko se rizicima ne upravlja na adekvatan način, oni mogu dovesti u pitanje pojedinačne poslove banke, a samim tim uticati i na njeno cjelokupno poslovanje. Iako su banke izložene čitavom spektru rizika, oni se svrstavaju u četiri kategorije (finansijski, operativni, poslovni i rizik događaja) i iskazuju se u novčanom obliku.

Tokom protekle decenije, kvalitet kreditnog portfolia banaka se pogoršao zbog finansijske krize koja je pogodila globalnu ekonomiju tokom 2008. godine. Slobodno se može reći da je povećanje nivoa nekvalitetnih kredita u aktivi bankarskog sektora direktna posljedica globalne finansijske krize koja se vrlo brzo proširila u veliki broj zemalja. Do sredine 2007. godine, kvalitet kreditnog portfolia banaka širom svijeta bio je prilično stabilan, ali se naglo pogoršao usljed problema koje je kriza donijela sa sobom.

Uticaj globalne finansijske krize različito se odrazio na ekonomije zemalja širom svijeta, tako da je i oporavak od njenih posljedica prilično neujednačen. Jedna od posljedica je povećanje nivoa nekvalitetnih kredita u kreditnom portfoliu banaka. Prema podacima Svjetske banke, razvijene zemlje tokom 2015. godine nisu dostigle nivo od 5% nekvalitetnih kredita, tako da su Austrija, Belgija, Danska, Norveška i Švedska godinu završile sa 3,5%, 4,0%, 4,4%, 1,3% i 1,1% nekvalitetnih kredita, respektivno (Svjetska banka, 2016). Istovremeno, Bosna i Hercegovina je imala 14,1% nekvalitetnih kredita, što je mnogo više nego u razvijenim ekonomijama, ali je manje nego u Srbiji i Hrvatskoj koje su na kraju 2015. godine imale 22,8%, odnosno 17,1% nekvalitetnih kredita, respektivno (Svjetska banka, 2016). Visok udio nekvalitetnih u ukupnim kreditima bankarskih sektora posljedica je sporog oporavka privrede u Bosni i Hercegovini, Srbiji i Hrvatskoj.

Upravljanje nekvalitetnim kreditima je problem sa kojim se susreću sve banke, a loše upravljanje je velika opasnost za njihov opstanak na tržištu. Upravo zbog toga, veoma je važno identifikovati faktore koji utiču na pojavu i rast nekvalitetnih kredita, a zatim predložiti kako da se ostvare poboljšanja u ovoj oblasti, što je i predmet ove disertacije.

U disertaciji, analiziraju se makroekonomski i specifični bankarski faktori koji utiču na rast nekvalitetnih kredita bankarskog sektora Bosne i Hercegovine. Nakon analize faktora, izvršena je komparativna analiza kretanja nivoa nekvalitetnih kredita u bankarskom sektoru Bosne i Hercegovine i bankarskim sektorima zemalja regiona, a zatim i bankarskim sektorima koji posluju na razvijenim finansijskim tržištima. Sprovedena analiza odnosi se na period od početka 2006. do kraja 2015. godine.

Sprovedeno je mnogo studija koje se bave faktorima koji određuju nekvalitetne kredite, tako da se u literaturi mogu naći studije koje se odnose na bankarski sektor jedne zemlje, ali i studije koje se odnose na bankarske sektore više zemalja. U nekim od sprovedenih istraživanja analizirani su samo makroekonomski faktori koji utiču na nekvalitetne kredite, u drugim samo specifični bankarski faktori, a u nekim istraživanjima analizirane su obe grupe faktora. Pored studija u kojima se analiziraju faktori koji utiču na nekvalitetne kredite, postoje i studije u kojima se analizira kretanje nivoa nekvalitetnih kredita prije, tokom i nakon globalne finansijske krize. Većina tih istraživanja sprovedena je u razvijenim zemljama, a u Bosni i Hercegovini, za sada, ne postoji mnogo studija koje se bave ovom problematikom.

Pregledom literature koja se bavi ovom problematikom, može se uočiti da postoji više makroekonomskih i specifičnih bankarskih faktora koji utiču na nekvalitetne kredite banaka. Međutim, rezultati sprovedenih istraživanja pokazuju da je uticaj tih faktora različit u zemljama, tako da se ne mogu izvući generalni zaključci koji su primjenljivi u svim zemljama.

1. Predmet istraživanja

Predmet istraživanja i kritičke analize u disertaciji su teorijske pretpostavke i identifikacija makroekonomskih i specifičnih bankarskih faktora koji imaju statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine. U cilju što temeljnije obrade teme, izvršena je komparativna analiza kretanja nivoa nekvalitetnih kredita u bankarskim sektorima na finansijskom tržištu Bosne i Hercegovine, finansijskim tržištima zemalja regiona i na razvijenim finansijskim tržištima. Razmatranje postojećih saznanja o nekvalitetnim kreditima podrazumijeva naučne postulate, sudove i zaključke na kojima će biti zasnovana analiza. Teorijska analiza predmeta istraživanja biće podržana saznanjima iz domaće i međunarodne naučne i stručne literature.

2. Značaj i aktuelnost istraživanja

Banke se, u svom poslovanju, baziraju na prikupljanje depozita i plasiranje kredita. Pri tom, one se susreću sa velikim brojem rizika, a jedan od najznačajnijih je kreditni rizik. Kreditni rizik banaka često se posmatra kao rizik druge strane, jer on predstavlja opasnost da će doći do negativnih efekata ako drugo lice ne izmiri svoje obaveze iz ugovora. U slučaju neuspjelog kreditnog aranžmana banka može ostati bez profita, ali i bez sopstvenih sredstava koja je plasirala u određeni kredit. Problem se dodatno komplikuje u slučaju da veći broj značajnih dužnika ne uspijeva da izmiruje svoje kreditne obaveze, a to, posmatrano sa mikro aspekta, banku može dovesti u stanje nelikvidnosti, insolventnosti ili čak bankrotstva. Posmatrano sa makro aspekta, ovaj problem se može negativno odraziti na finansijski sistem zemlje.

Značaj i aktuelnost ove teme posebno su došli do izražaja tokom globalne finansijske krize, odnosno u vrijeme u kome je bankarsko poslovanje postalo značajno rizičnije. Značaj disertacije ogleda se u identifikovanju faktora koji utiču na pojavu i rast nekvalitetnih kredita, mjerenju ovog uticaja, kao i u procjenama nenaplativosti kredita na osnovu istorijskih podataka. Na osnovu navedenog, vidi se koliki je značaj identifikacije faktora koji utiču na nekvalitetne kredite, kako za pojedinačne banke, tako i za bankarski i finansijski sektor u cjelini, ali i za cjelokupnu ekonomiju zemlje. Poznavanje faktora koji određuju nekvalitetne kredite može pomoći direktorima, menadžerima i službenicima banaka da bolje razumiju kreditne aktivnosti i poboljšaju svoj rad, odnosno da se usredsrede na kvalitet kredita, a ne na njihov kvantitet.

Rezultati istraživanja treba da ukažu na probleme bankarskog sektora, kao i na faktore koji utiču na rast nekvalitetnih kredita, te da se, u skladu sa tim, usmjeri pažnja subjekata političke i ekonomske vlasti u Bosni i Hercegovini na njih, kako bi bili efikasniji u procesu donošenja konkretnih odluka. Bankarski sektor Bosne i Hercegovine suočava se sa brojnim problemima i izazovima, tako da je potrebno sprovesti više istraživanja čiji rezultati mogu da doprinesu boljem sagledavanju trenutnog stanja i perspektiva ovog sektora. Rezultati istraživanja trebali bi uticati na menadžere banaka kako bi oni u narednom periodu pažljivije donosili kreditne odluke i efikasnije upravljali kreditnim portfoliom, a samim tim i kreditnim rizicima. Ispravna kreditna odluka, monitoring odobrenog kredita i efikasno upravljanje rizicima su bitni faktori za poboljšanje aktive banaka, za stabilnost bankarskog sektora i za ekonomski razvoj Bosne i Hercegovine.

Takođe, istraživanje, pored analize udjela nekvalitetnih u ukupnim kreditima bankarskog sektora Bosne i Hercegovine, treba da ukaže i na ovaj odnos u bankarskim sektorima zemalja regiona (Srbija, Crna Gora, Hrvatska, Slovenija i Makedonija) i razvijenih zemalja (SAD, Njemačka, Španija, Francuska, Italija i Austrija). Ova analiza pokazaće trenutni položaj bankarskog sektora Bosne i Hercegovine, odnosno pokazaće da li on, i u kojoj mjeri, zaostaje za bankarskim sektorima razvijenih zemalja i zemalja regiona.

3. Cilj istraživanja

Naučni cilj istraživanja je da se, na osnovu relevantne domaće i strane literature, sagleda uticaj makroekonomskih i specifičnih bankarskih faktora na nekvalitetne kredite komercijalnih banaka. Tek nakon što se identifikuju faktori i izmjeri uticaj koji oni imaju na nekvalitetne kredite, direktori i menadžeri banaka, regulatori i monetarne vlasti mogu preduzeti određene mjere za rješavanje ovog problema. Cilj disertacije je i sprovođenje komparativne analize kretanja nivoa nekvalitetnih kredita na razvijenim finansijskim tržištima i tržištima u razvoju, u prethodnoj deceniji.

Društveni cilj istraživanja je identifikacija faktora koji utiču na pojavu i rast nekvalitetnih kredita komercijalnih banaka, kako bi se preduzele adekvatne mjere da se smanji rizik u ovom sektoru. Metodologija i rezultati istraživanja mogu biti korisni širokom krugu čitalaca – prvenstveno menadžerima banaka, investitorima i regulatorima, ali i svima drugima koji su zainteresovani za poboljšanje upravljanja kreditnim rizikom, a samim tim i smanjenje nekvalitetnih kredita u komercijalnim bankama, odnosno, bankarskom sektoru u cjelini.

4. Hipoteze istraživanja

Cilj istraživanja je identifikacija faktora koji utiču na nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine. Slična istraživanja sprovedena su u zemljama širom svijeta, ali se dobijeni rezultati značajno razlikuju. Pregledom empirijske literature uočavaju se razlike u rezultatima – određeni faktor u jednoj zemlji nema uticaj na nekvalitetne kredite, dok u drugoj zemlji ima, a dešavalo se da određeni faktor u jednoj zemlji ima pozitivan, a u drugoj negativan uticaj na nekvalitetne kredite.

Na osnovu pregleda empirijske literature, razvijene su sljedeće hipoteze:

Generalna hipoteza:

Postoje makroekonomski i specifični bankarski faktori koji imaju statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine.

Posebne hipoteze:

- Udio nekvalitetnih u ukupnim kreditima bankarskog sektora povećao se za vrijeme globalne finansijske krize.
- Poslovne banke mogu da identifikuju faktore koji dovode do nastanka nekvalitetnih kredita.

Pojedinačne hipoteze:

- Stopa rasta realnog bruto domaćeg proizvoda (GDP) ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Stopa nezaposlenosti (UNEMP) ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Stopa rasta potrošačkih cijena (ICP) ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Koeficijent adekvatnosti kapitala (CAR) ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Odnos kredita i depozita (LTD) ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Prinos na aktivu (ROA) ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Prinos na akcijski kapital (ROE) ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Aktivna kamatna stopa (IR) ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka.
- Stopa kreditnog rasta (CG) ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka.

5. Metode istraživanja

Zbog specifičnosti i složenosti problema istraživanja, a sa ciljem zadovoljenja osnovnih metodoloških zahtijeva (objektivnost, pouzdanost, opštost i sistematičnost) i dolaska do kvalitetnih rezultata, korištene su opšte-naučne i naučno-istraživačke metode. Od opšte-naučnih metoda korištene su: hipotetičko-deduktivna, analitičko-deduktivna, komparativna, statistička i metoda modelovanja. Od naučno-istraživačkih metoda korištene su analitičke metode (metode analize, apstrakcije, specijalizacije i dedukcije) i sintetičke metode (metode sinteze, konkretizacije, generalizacije i indukcije). Iako su na prvi pogled metod indukcije i metod dedukcije međusobno isključivi, činjenica je da ova dva metoda imaju zajednički osnovni predmet saznanja, tako da se indukcijom ne može doći do rezultata kao čisto opšte iz posebnog, a dedukcijom se ne može doći do rezultata čisto posebnog, bez opšteg.

Adekvatna primjena ovih metoda omogućava da se dođe do saznanja o faktorima koji imaju statistički značajan uticaj na nekvalitetne kredite, odnosno do zaključaka koji su relevantni za ostvarenje naučnog i društvenog cilja istraživanja. Istraživanje se vrši i pomoću analize sadržaja dokumenata na koji potiču iz primarnih (izvornih dokumenata komercijalnih banaka i bankarskog sektora u cjelini i statističkih dokumenata) i sekundarnih izvora (adekvatne stručne literature i rezultata ranijih istraživanja).

Prva faza istraživanja odnosi se na sveobuhvatno istraživanje teorijsko – metodoloških aspekata faktora koji imaju uticaj na pojavu i rast nekvalitetnih kredita banaka. Poredetaljne analize postojećih teorijskih osnova, koja je zasnovana na relevantnoj stranoj i domaćoj literaturi, te izvještajima međunarodnih i nacionalnih finansijskih institucija, dat je pregled plasmana u bankarskom sektoru Bosne i Hercegovine. Detaljnom analizom volumena i strukture plasmana, a pomoću metoda deskriptivne i komparativne analize, prikazano je stanje u nacionalnom bankarskom sektoru, bankarskim sektorima zemalja regiona i razvijenim zemljama. U ovom dijelu istraživanja prvenstveno je korištena relevantna strana i domaća literatura, te naučni radovi i monografije stranih i domaćih autora. Prilikom opisivanja stanja u bankarskom sektoru Bosne i Hercegovine korištene su publikacije Centralne banke Bosne i Hercegovine. Također, autor se oslonio i na lično iskustvo i poznavanje prilika na domaćem bankarskom tržištu.

Druga faza istraživanja odnosi se na empirijsko testiranje postavljenih hipoteza, pri čemu su dominantno korišteni izvještaji Centralne banke Bosne i Hercegovine i Svjetske banke. U ovom dijelu istraživanja korištene su statističke metode koje, sa određenim procentom sigurnosti, dokazuju zavisnost između posmatranih pojava. Pomoću komparativnih metoda su analizirani trendovi kretanja nekvalitetnih kredita na finansijskom tržištu Bosne i Hercegovine, zemalja regiona i na finansijskim tržištima razvijenih zemalja. Pored navedenog, sprovedena je i anketa među bankarskim menadžerima, kao i veliki broj intervjua sa rukovodiocima poslovnih banaka u bankarskom sektoru Bosne i Hercegovine. Rezultati dobijeni empirijskom analizom pokazali su da postoje makroekonomski i specifični bankarski faktori koji utiču na nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine, te da ih bankarski menadžeri mogu identifikovati.

6. Obim i ograničenja istraživanja

Disertacija je koncipirana tako da zadovolji postavljene hipoteze i da pregled faktora koji utiču na nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine tokom određenog vremenskog perioda i u skladu sa mogućnostima. Analizirani su makroekonomski i specifični bankarski faktori, u periodu od početka 2006. do kraja 2015. godine. Pored analize faktora, urađena je i komparativna analiza kretanja nivoa nekvalitetnih kredita u bankarskom sektoru Bosne i Hercegovine, bankarskim sektorima zemalja regiona i razvijenih zemalja.

Uprkos naporima da se problem nekvalitetnih kredita sagleda što kvalitetnije, postoje određena ograničenja koja to onemogućavaju. Prvo ograničenje odnosi se na nedostatak istorijskih podataka koji su neophodni za kompleksniju analizu. Istraživanje bi bilo mnogo kvalitetnije kada bi se analizirao nivo nekvalitetnih kredita za svaku banku pojedinačno, ali ti podaci nisu dostupni. Dalje, nepotpuni su i podaci o faktorima koji određuju nekvalitetne kredite. Problem nedostatka podataka nije prisutan samo u Bosni i Hercegovini, nego i u zemljama regiona, pa čak i u razvijenim zemljama.

Drugo bitno ograničenje odnosi se na samu definiciju nekvalitetnih kredita, jer još uvijek ne postoji međunarodno usaglašena definicija. Iako ne postoji opšteprihvaćeni standard koji se koristi prilikom definisanja nekvalitetnih kredita, najčešće se, kao kriterijum klasifikacije, koristi broj dana kašnjenja otplate glavnice i/ili kamate, a u većini zemalja riječ je o kašnjenju od 90 i više dana. U nekim zemljama, nekvalitetni krediti su oni čija otplata kasni 31 ili 61 dan, a u nekim zemljama se koriste i potpuno drugačiji kriterijumi za klasifikaciju nekvalitetnih kredita.

Iako navedena ograničenja postoje i predstavljaju prepreku za kompleksniju analizu, u disertaciji će biti identifikovani makroekonomski i specifični bankarski faktori koji određuju nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine. Dalje, sagledaće se i kvalitet aktive banaka (mjeren nivoom nekvalitetnih kredita) u Bosni i Hercegovini u odnosu na kvalitet aktive banaka koje posluju u zemljama regiona i razvijenim zemljama. Na kraju, važno je naglasiti da se rezultati i zaključci disertacije odnose na vremenski period od početka 2006. do kraja 2015. godine.

7. Struktura rada

Teorijska i istraživačka razmatranja podijeljena su na četiri dijela, tako da se rad sastoji od uvodnog dijela, razrade, zaključnih razmatranja, i na samom kraju dat je pregled korištene literature.

U prvom, uvodnom dijelu, obrazložena je tema i značaj istraživanja, definisani su predmet, problem i ciljevi istraživanja i navedene su metode koje su korištene tokom istraživanja. U ovom dijelu, autor je ukazao na ograničenja sa kojima se susreo, a koja su uticala na kvalitet istraživanja i dobijenih rezultata.

Razrada obuhvata teorijska razmatranja o nekvalitetnim kreditima i faktorima koji utiču na njih, kao i analizu faktora koji utiču na nekvalitetne kredite bankarskog sektora Bosne i Hercegovine. Razrada je podijeljena na pet dijelova. U prvom dijelu definisan je pojam nekvalitetnih kredita i dat pregled empirijske literature koja je zasnovana na različitim studijama koje su sprovedene. U drugom dijelu, na osnovu prethodno sprovedenih istraživanja, identifikovani su makroekonomski i specifični bankarski faktori koji utiču na nekvalitetne kredite. Treći dio obuhvata analizu poslovanja komercijalnih banaka Bosne i Hercegovine u periodu od 2006. do 2015. godine. U ovom dijelu navedene su osnovne karakteristike sektora, dat je pregled bilansne strukture banaka u navedenom periodu i pokazatelji uspješnosti njihovog poslovanja. Četvrti dio, koji je možda i najvažniji dio disertacije, jeste analiza faktora koji utiču na nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine. Pored opisa metodologije istraživanja, ovaj dio sadrži i objašnjenje promjenljivih koje se koriste, te rezultate istraživanja. Dobijeni rezultati mogu pomoći direktorima i menadžerima banaka, regulatorima i organima vlasti kao smjernice za dalje poslovne aktivnosti, kako bi se unaprijedilo poslovanje komercijalnih banaka, a prvenstveno efikasnije upravljalo kreditnim rizikom. Peti, ujedno i posljednji dio razrade, odnosi se na komparativnu analizu kretanja nivoa nekvalitetnih kredita bankarskih sektora na finansijskom tržištu Bosne i Hercegovine, finansijskim tržištima zemalja regiona (Srbija, Crna Gora, Hrvatska, Slovenija i Makedonija) i razvijenim finansijskim tržištima (SAD, Njemačka, Španija, Francuska i Italija).

U zaključnim razmatranjima su objedinjene teorijske osnove i rezultati empirijskog istraživanja koji dokazuju da postoje makroekonomski i specifični bankarski faktori koji dovode do nastanka i utiču na rast nekvalitetnih u ukupnim kreditima komercijalnih banaka. Ova razmatranja su precizno izvedena iz razrade, a njima su potvrđene ili opovrgnute hipoteze koje su postavljene u uvodnom dijelu. Takođe, date su i određene preporuke za efikasnije upravljanje nekvalitetnim kreditima, koje su u skladu sa dobijenim rezultatima.

Završni dio disertacije sadrži pregled korištene literature – knjiga, stručnih radova i članaka, empirijskih studija, publikacija i izvještaja na kojima je zasnovana teorijska i naučna utemeljenost rada. Ovaj dio sadrži i pregled Internet izvora sa kojih su preuzeti podaci koji su korišteni u istraživanju.

I DIO

POJMOVNO ODREĐENJE I PREGLED EMPIRIJSKE LITERATURE O NEKVALITETNIM KREDITIMA

1. POJAM NEKVALITETNIH KREDITA

1.1. Definicija nekvalitetnih kredita na finansijskim tržištima razvijenih zemalja

Posljednjih nekoliko godina, tačnije od izbijanja svjetske ekonomske krize krajem 2007. godine, interes akademskih krugova za nekvalitetne kredite (*non – performing loans – NPL*) je povećan. Pregled literature pruža dragocjene informacije o faktorima koji utiču na nekvalitetne kredite, ali se njihova definicija razlikuje u različitim zemljama, pa je ove studije teško uporediti i treba im pristupiti vrlo oprezno.

Iako još uvijek ne postoji univerzalno prihvaćena definicija nekvalitetnih kredita, najčešće se koriste definicije Međunarodnog monetarnog fonda (*International Monetary Fund, IMF*), Bazelskog komiteta za superviziju banaka (*Basel Committee on Banking Supervision, BCBS*) i Instituta za međunarodne finansije (*Institute for International Finance, IIF*).

Prema definiciji Međunarodnog monetarnog fonda, nekvalitetni kredit je kredit kod koga:

- dužnik sa plaćanjem glavnice i/ili kamate kasni barem tri mjeseca (90 dana) u odnosu na rok definisan ugovorom o kreditnom odnosu,
- iznos kamata za tri mjeseca (90 dana) ili više je kapitalizovan (reinvestiran u iznos glavnice), refinansiran ili je dogovoreno njegovo odgođeno plaćanje (IMF, 2006).

Bazelski komitet za superviziju banaka preporučuje poštovanje pravila „90 dana“, odnosno, navodi se „neispunjenje obeveze se dogodilo ukoliko dužnik više od 90 dana kasni sa podmirivanjem svojih obaveza prema banci“ (BIS, 2006).

Veliki broj međunarodnih regulatora slijedi upustva za definisanje nekvalitetnih kredita koja je dao Institut za međunarodne finansije. Naime, Institut za međunarodne finansije sve kredite klasifikuje u pet kategorija: standardni, pod posmatranjem, substandardni, sumnjivi i nenadoknadivi krediti. Prema njima, nekvalitetni krediti su krediti iz posljednje tri grupe i to: substandardni krediti (plaćanje kamata i/ili glavnice kasni više od 90 dana), sumnjivi krediti (plaćanje kamata i/ili glavnice kasni više od 180 dana) i nenadoknadivi krediti – gubitak (smatra se da se kredit nikad neće vratiti kreditoru, tj. kreditor nikad neće naplatiti svoja potraživanja, odnosno, dužnik sa plaćanjem glavnice i/ili kamate kasni više od godinu dana) (IIF, 1999).

Iako se navedene definicije primjenjuju u velikom broju zemalja, u nekim zemljama se smatra da su nekvalitetni krediti oni kod kojih dužnik kasni sa otplatom 31 i više, odnosno 61 i više dana. Međutim, broj dana kašnjenja dužnika da izmiri svoje obaveze nije jedini kriterijum po kome se razlikuju definicije nekvalitetnih kredita u različitim zemljama. U ostale kriterijume klasifikacije ubrajaju se kriterijum finansijske sposobnosti dužnika, činjenica da li je pokrenut sudski postupak protiv dužnika, da li je nekvalitetni kredit prikazan u bruto ili neto iznosu, a često se koriste i kriterijumi garancije i kolaterala. Kao što su različiti kriterijumi za klasifikaciju nekvalitetnih kredita, različiti su i kriterijumi za klasifikaciju višestrukih kredita istog klijenta. U nekim zemljama, ako je jedan kredit klasifikovan kao nekvalitetni, tada se i svi ostali krediti tog klijenta klasifikuju kao nekvalitetni. Većina studija koje su sprovedene odnosi se na faktore koji utiču na rast nekvalitetnih kredita u ukupnoj aktivi bankarskog sektora, a mali broj studija bavi se samom definicijom.

Barisitz se bavio analizom nacionalnih definicija nekvalitetnih kredita u različitim zemljama. Prva studija koju je sproveo 2011. godine, pod nazivom „Nekvalitetni krediti u CESEE – Šta oni čine?“ (naslov originala: *Nonperforming Lonas in CESEE – What Do They Comprise*), obuhvatila je nacionalne definicije iz deset zemalja Centralne, Istočne i Jugoistočne Evrope (Bugarska, Hrvatska, Češka, Mađarska, Poljska, Rumunija, Rusija, Srbija, Slovačka i Ukrajina) (Barisitz, 2011, str. 46 - 68). Autor je, u ovoj studiji, istakao da poređenje nekvalitetnih kredita često može da bude teško jer se pri identifikaciji nekvalitetnih kredita koriste tri pristupa. Prvo, polazi se od međunarodno prihvaćene definicije koju je dao Međunarodni monetarni fond, a koja podrazumijeva poštovanje pravila kašnjenja „90 i više dana“. Drugi pristup se odnosi na klasifikaciju kredita, prema kojoj nekvalitetni krediti obuhvataju substandardne, sumnjive i nenadoknadive kredite, što je u skladu sa definicijom koju je dao Institut za međunarodne finansije. Treći pristup podrazumijeva postojanje „dobro definisanih slabosti“ kredita ili neke druge faktore. Zaključak ove studije je da definicije nekvalitetnih kredita u zemljama navedene regije imaju visok stepen sličnosti i da se temelje na kriterijumu kašnjenja od „90 i više dana“.

Druga studija koju je Barisitz sproveo 2013. godine, pod nazivom „Nekvalitetni krediti u Zapadnoj Evropi – Selektivna poređenja zemalja i nacionalnih definicija“ (naslov originala: *Nonperforming Lonas in Western Europe – A Selective Comparision of Countries and National Definitions*), obuhvatila je nacionalne definicije nekvalitetnih kredita u zemljama Zapadne Evrope (Austrija, Finska, Francuska, Njemačka, Irska, Italija, Portugal, Španija i Velika Britanija) (Barisitz, 2013, str. 28 - 47). U suštini, ona predstavlja nastavak prethodno sprovedene studije. Autor smatra da kredit, koji je klasifikovan kao nekvalitetni, mora da ima jedan od dva primarna elementa, i to da glavnica i/ili kamata kasni više od 90 dana (prema definiciji IMF-a) ili da postoje dobro definisane slabosti kredita. Dalje, on smatra da postoje i sekundarni elementi koji utiču na klasifikaciju nekvalitetnih kredita i koji su značajni za uporedivost definicija, a ti elementi su: da li je restrukturirani kredit klasifikovan kao nekvalitetni ili nije, da li garancije i kolaterali utiču na klasifikaciju kredita ili ne, da li se cjelokupan kredit smatra nekvalitetnim ili samo njegov dio i da li banke sve kredite istog dužnika klasifikuju kao nekvalitetne ili ne. Zaključak ove studije je sličan kao i zaključak prethodne, odnosno, u analiziranim zemljama Zapadne Evrope uglavnom se poštuje pravilo kašnjenja „90 i više dana“, a sekundarni elementi kredita se razlikuju.

Treća studija, koju je Barisitz takođe sproveo 2013. godine, pod nazivom „Nekvalitetni krediti u CESEE – Još dublje poređenje definicije“ (naslov originala: *Nonperforming Lonas in CESEE – An even Deeper Definitional Comparison*), nadovezuje se na prethodne dvije studije, a u njoj se analiziraju nacionalne definicije nekvalitetnih kredita u zemljama Centralne, Istočne i Jugoistočne Evrope (Bugarska, Hrvatska, Češka, Mađarska, Poljska, Rumunija, Rusija, Srbija, Slovačka i Ukrajina) (Barisitz, 2013, str. 67 - 84). Autor u ovoj studiji analizira primarne (kašnjenje glavnice i/ili kamate 90 i više dana ili postojanje dobro definisanih slabosti kredita) i sekundarne (tretman restrukturiranih kredita, uticaj garancija i kolaterala, evidentiranje ukupnog kredita ili samo njegovog dijela kao nekvalitetnog i tretman višestrukih kredita istog dužnika) elemente u definiciji nekvalitetnih kredita. I u ovom slučaju, analiza je pokazala da se u navedenim zemljama poštuje pravilo kašnjenja „90 i više dana“, ali se sekundarni elementi nekvalitetnih kredita razlikuju u zemljama Centralne, Istočne i Jugoistočne Evrope.

Problem nepostojanja jednoobrazne definicije nekvalitetnih kredita, koja bi omogućila pouzdanije poređenje kvaliteta bankarske aktive u različitim zemljama, istaknut je i u okviru Inicijative za koordinaciju evropskih banaka, tzv. „Bečke" inicijative.[1] U izvještaju radne grupe „Bečke" inicijative, pod nazivom "Radna grupa za nekvalitetne kredite u Centralnoj, Istočnoj i Jugoistočnoj Evropi" (naslov originala: *Working Group on NPLs in Central, Eastern and Southeastern Europe*) navedeno je da se prilikom određivanja nekvalitetnih kredita koristi pravilo kašnjenja od 90 i više dana, a u izvještavanju se obuhvata cjelokupan iznos kredita kod koga je zabilježeno takvo kašnjenje (European Banking Coordination "Vienna" Initiative, 2012). Međutim, pored kriterijuma kašnjenja, koriste se i drugi kriterijumi za određivanje nekvalitetnih kredita (tretiranje kolaterala, restrukturiranje kredita, obnavljanje i produživanje roka otplate kredita i tretman drugih kredita odobrenih istom dužniku) i upravo oni predstavljaju problem prilikom određivanja nekvalitetnih kredita.

Evropsko nadzorno tijelo za bankarstvo (*European Banking Authority* – EBA)[2] predložilo je harmonizaciju definicija i kriterijuma za ocjenu nekvalitetnih kredita bankarske aktive. Polazeći od sveobuhvatne analize kvaliteta aktive banaka u Evropi (analiza je sprovedena 2014. godine i obuhvatila je 130 banaka u Evrozoni, odnosno 82% ukupne bankarske aktive), EBA je kreirala standard za definisanje i mjerenje nekvalitetne izloženosti (eng. *non-performing exposures* – NPE), kao širi pristup od nekvalitetnih kredita i restrukturiranih kredita.

Prema EBA, nekvalitetne izloženosti su one koje zadovoljavaju bilo koji ili oba sljedeća kriterijuma:

- materijalno značajna izloženost koja je dospjela više od 90 dana,
- ocjenjuje se da je malo vjerovatno da će dužnik platiti svoje kreditne obaveze u cjelini, ne uzimajući u obzir realizaciju kolaterala i bez obzira na prisustvo bilo dospjelih obaveza prema banci ili broja dana kašnjenja (EBA, 2014, str. 13).

EBA navodi da izloženost treba da bude kategorizovana kao nekvalitetna za njen cjelokupan iznos, bez obzira da li postoji neki kolateral. Takođe, navedeno je da izloženost obuhvata sve instrumente duga: kredite, avanse, dužničke hartije od vrijednosti i vanbilansnu izloženost, ali ne i izloženosti koje su namijenjene trgovanju. Vanbilansna izloženost „se sastoji od opozivih i neopozivih stavki: obaveze za odobrene kredite, obaveze po osnovu izdatih finansijskih garancija i ostale date obaveze" (EBA, 2014, str. 13). Primjena definicije obezbjeđuje svim finansijskim institucijama da jasno odrede nekvalitetnu izloženost i da porede kvalitet aktive na homogen i uporediv način.

U okviru istraživanja koje je sprovela Radna grupa „Bečke" inicijative, date su definicije nekvalitetnih kredita u trinaest zemalja Centralne, Istočne i Jugoistočne Evrope. Spomenute nacionalne definicije date su u tabeli 1.

---

[1] „Bečka" inicijativa je nastala kao odgovor na globalnu finansijsku krizu i okupila je stručnjake iz Međunarodnog monetarnog fonda, Evropske banke za obnovu i razvoj, Evropske investicione banke, Svjetske banke, Evropske institucije (Evropske komisije i Evropske centralne banke), regulatornih i fiskalnih organa matičnih zemalja i zemalja domaćina velikih međunarodnih bankarskih grupa i iz najveće bankarske grupe koji posluju u Centralnoj, Istočnoj i Jugoistočnoj Evropi (CESEE).

[2] Evropsko nadzorno tijelo za bankarstvo (EBA) je nezavisno tijelo Evropske unije čiji posao je da osigura djelotvoran i dosljedan nivo bonitetne regulative i nadzora nad evropskim bankarskim sektorom. Njegovi glavni ciljevi su održavanje finansijske stabilnosti u Evropskoj uniji i osiguranje cjelovitosti, djelotvornosti i pravilnog funkcionisanja bankarskog sektora.

Tabela 1: Definicije nekvalitetnih kredita (NPL) u različitim zemljama

ZEMLJA	DEFINICIJA
Bosna i Hercegovina	NPL krediti su oni koji ne generišu prihode. NPL krediti su oni koji ispunjavaju sljedeće kriterijume: 1) glavnica i/ili kamata je dospjela i nije naplaćena u periodu dužem od 90 dana (dospjeće preko 90 dana od inicijalnog datuma dospjeća), nakon čega se potraživanje klasifikuje kao „substandardno", „sumnjivo" ili „gubitak" i 2) potraživanje od dužnika po osnovu kamate koja je dospjela prije više od 90 dana od inicijalnog datuma dospjeća, a koja je kapitalizovana.
Bugarska	Standardni krediti su definisani kao krediti koji su u kašnjenju manje od 30 dana. Krediti na posmatranju su krediti u kašnjenju od 30 do 90 dana ili krediti odobreni dužniku čije je finansijsko stanje takvo da se može pogoršati i dovesti u pitanje otplatu kredita u cjelini. NPL su definisani kao krediti koji su u kašnjenju od 91 do 180 dana ili krediti dužnika čije je finansijsko stanje takvo da se može značajno pogoršati i rezultirati nemogućnošću otplate kredita. Krediti klasifikovani kao „gubitak" dospjeli su duže od 180 dana ili kreditni dužnik čije finansijsko stanje karakteriše permanentni nedostatak likvidnih sredstava ili su nastupile druge okolnosti koje predstavljaju osnov da se izloženost, po osnovu koje je nastao kreditni rizik, smatra nenaplativom.
Hrvatska	NPL su: 1) plasmani kod kojih je identifikovano parcijalno obezvređenje (npr. djelimično nadoknadivi plasmani kategorija rizika B1, B2, B3) i 2) plasmani u kojima je identifikovano obezvređenje jednako preostalom iznosu knjigovodstvene vrijednosti plasmana (npr. potpuno nenadoknadivi plasmani). Pod plasmanima se podrazumijeva finansijska aktiva u obliku odobrenih kredita, instrumenata duga i ostalih potraživanja, koja su kreditne institucije klasifikovala u kategoriju finansijskih instrumenata – „krediti i potraživanja" i „aktiva koja se drži do dospjeća".
Estonija	Krediti po osnovu kojih je dužnik u kašnjenju od 90 dana ili krediti koje je banka klasifikovala u kategoriju „*default*" na osnovu drugih informacija.
Mađarska	NPL su plasmani u kašnjenju dužem od 90 dana. U slučaju klasifikovanja plasmana korporativnim klijentima, primjenjuje se princip „klasifikovanja prema dužniku", dok se za klasifikaciju plasmana fizičkim licima primjenjuje princip „klasifikovanja prema dužniku" i princip „klasifikovanja prema ugovoru".
Kosovo	NPL se definišu kao krediti koji su u kašnjenju dužem od 90 dana, a uključuju kategorije klasifikovanih kredita „sumnjivi" i „nenaplativi (gubitak)". Prema podacima Centralne banke Republike Kosovo definicije sumnjivih kredita uključuju kredite čija otplata kasni od 91 do 180 dana, a kategorija kredita gubitak obuhvata kredite čija otplata kasni preko 180 dana.
Letonija	Nije definisan pojam NPL-a. Za potrebe analize u izvještavanju navedene Radne grupe, pod NPL-om se podrazumijevaju krediti koji su u kašnjenju preko 90 dana.
Litvanija	NPL = dospjeli krediti u kašnjenju preko 61 dan koji nisu obezvrijeđeni + obezvrijeđeni krediti + pojedinačna posebna rezervisanja + grupna posebna rezervisanja.
Makedonija	Bilo kakvo potraživanje (gavnica, kamata, naknada) koje nije naplaćeno u periodu dužem od 90 dana od dana dospjeća, a koje banka treba da klasifikuje na posebnim računima za nekvalitetna potraživanja – kredite, kamate i druga potraživanja. Potraživanje može biti isključeno iz kategorije nekvalitetnog jedino ukoliko je iznos dospjelog potraživanja koje je tretirano kao nekvalitetno naplaćeno.
Moldavija	Aktiva – angažovanja klasifikovana kao „substandardna", „sumnjiva" i „nenadoknadiva" smatraju se nekvalitetnim.
Crna Gora	Krediti po osnovu kojih je dužnik u kašnjenju dužem od 90 dana, pri čemu to nije jedini kriterijum. Krediti koje je banka klasifikovala u kategorije „substandardni", „sumnjivi" i „nenaplativi (gubitak)".
Rumunija	Krediti po osnovu kojih je dužnik u kašnjenju dužem od 90 dana i/ili krediti kod kojih su započeti pravni postupci naplate. NPL racio = krediti i kamate u kašnjenju dužem od 90 dana i/ili krediti za koje su započeti pravni postupci naplate / bruto iznos angažovanja po osnovu klasifikovanih kredita i kamata.
Slovenija	NPL podrazumijeva klasifikovana potraživanja u kašnjenu dužem od 90 dana. Klasifikovana potraživanja obuhvataju finansijsku imovinu po amortizovanoj vrijednosti i određene vanbilansne stavke po osnovu kojih je banka potencijalno izložena riziku, a iz kojih može nastati obaveza plaćanja. NPL obuhvata ukupan iznos klasifikovanih potraživanja (u slučaju da je iznos dospjelih obaveza dužnika prema banci preko 1.000 EUR, ukupna izloženost banke prema dužniku se kategorizuje kao nekvalitetna, a ne samo iznos dospjelih potraživanja).

Izvor: (European Banking Coordination "Vienna" Initiative, 2012, str. 15)

Kao što se vidi u tabeli, a u skladu sa pomenutim istraživanjem, date su nacionalne definicije nekvalitetnih kredita u trinaest zemalja Centralne, Istočne i Jugoistočne Evrope, a među njima i definicija koja se koristi u Bosni i Hercegovini (BiH). Na osnovu analize navedenih nacionalnih definicija, zaključuje se da je za najveći broj bankarskih sistema u okruženju, tranzitornim ekonomijama i ekonomijama sličnih performansi, ključna odrednica za kategorizaciju nekvalitetnih kredita broj dana kašnjenja po osnovu salda kreditnih potraživanja – kašnjenja duža od 90 dana. Takođe, osnovica za obračun nekvalitetnih kredita je bruto iznos potraživanja po osnovu kredita za koje dužnik kasni sa plaćanjem obaveze 90 i više dana.

U nekim zemljama je definicija nekvalitetnih kredita zasnovana na klasifikaciji potraživanja po osnovu kredita, pa tada nekvalitetni krediti obuhvataju potraživanja klasifikovana u kategorije „substandardni krediti", „sumnjivi krediti" i „nenadoknadivi krediti (gubitak)", ili, manje restriktivno, kategorije „sumnjivi krediti" i „nenadoknadivi krediti (gubitak)".

U nastavku će biti analizirane nacionalne definicije nekvalitetnih kredita u zemljama sa kojima BiH najčešće ekonomski sarađuje ili sa kojim je ekonomski stručnjaci upoređuju. To su: Austrija, Francuska, Njemačka, Italija i Španija. Da bi se mogao porediti nivo nekvalitetnih kredita u navedenim zemljama i u BiH, neophodno je da se, prilikom definisanja nekvalitetnih kredita, koriste isti ili veoma slični kriterijumi. S obzirom da se u BiH, prilikom definisanja nekvalitetnih kredita koristi definicija Međunarodnog monetarnog fonda, odnosno poštuje se pravilo kašnjenja plaćanja glavnice i/ili kamate od 90 i više dana, neophodno je analizirati da li se i u navedenim zemljama na razvijenim finansijskim tržištima primjenjuje isto pravilo.

U tabeli 2 dati su rezultati analize koja je sprovedena sa ciljem da se odredi da li se u navedenim zemljama primjenjuje pravilo kašnjenja „90 i više dana".

Tabela 2: Analiza nacionalnih definicija nekvalitetnih kredita na razvijenim finansijskim tržištima

Zemlja	Izvor	Pravilo „glavnica i/ili kamata kasne 90 i više dana"
Austrija	Oesterreichische Nationalbank (OeNB)	DA
Francuska	Banque de France	DA
Njemačka	Deutsche Bundesbank	DA
Italija	Banca d' Italia	DA
Španija	Banco de España	DA

Izvor: Izrada autora na osnovu navedenih izvora

Na osnovu analize nacionalnih definicija nekvalitetnih kredita u Austriji, Francuskoj, Njemačkoj, Italiji i Španiji, može se zaključiti da se, kao osnovni element za klasifikaciju nekvalitetnih kredita, koristi pravilo kašnjenja „90 i više dana", odnosno, da su nacionalne definicije koje su analizirane u skladu sa definicijom koju je dao Međunarodni monetarni fornd. To vodi do zaključka da se nivo nekvalitetnih u ukupnim kreditima bankarskog sektora navedenih zemalja može porediti sa nivoom nekvalitetnih kredita u BiH. Takvo poređenje je vrlo značajno jer omogućava da se sagleda položaj bankarskog sektora BiH u odnosu na bankarske sektore razvijenih zemalja.

Veoma važno je i poređenje definicije nekvalitetnih kredita u BiH i zemljama regiona (Crna Gora, Hrvatska, Makedonija, Slovenija i Srbija). Osnovni cilj analize je da se odredi da li su, prilikom klasifikacije nekvalitetnih kredita, korišteni isti kriterijumi i da li se njihov nivo u ovim zemljama može porediti. U analizi se, kao glavna odrednica nekvalitetnih kredita, koristi pravilo kašnjenja „90 i više dana". Rezultati analize dati su u tabeli 3.

Tabela 3: Analiza definicija nekvalitetnih kredita u Crnoj Gori, Hrvatskoj, Makedoniji, Sloveniji i Srbiji

Zemlja	Izvor	Pravilo „glavnica i/ili kamata kasne 90 i više dana"
Bosna i Hercegovina	Centralna banka Bosne i Hercegovine	DA
Crna Gora	Centralna banka Crne Gore	DA
Hrvatska	Hrvatska narodna banka	DA
Makedonija	Narodna banka na Republika Makedonija	DA
Slovenija	Banka Slovenije	DA
Srbija	Narodna banka Srbije	DA

Izvor: Izrada autora na osnovu navedenih izvora

Na osnovu analize definicija nekvalitetnih kredita u BiH i pet zemalja regiona (Crna Gora, Hrvatska, Makedonija, Slovenija i Srbija) može se zaključiti da se, prilikom klasifikacije, koristi pravilo kašnjenja plaćanja glavnice i/ili kamate od 90 i više dana. Zbog sličnosti navedenih definicija moguće je poređenje nivao nekvalitetnih kredita u BiH i navedenim zemljama regiona. Osnovni cilj poređenja jeste sagledavanje kvaliteta kreditnog portfolia ovih balkanskih zemalja jer je kvalitet kreditnog portfolia važna odrednica u budućim strategijama banaka.

S obzirom na činjenicu da se definicije nekvalitetnih kredita u nekim zemljama oslanjaju na klasifikaciju aktive i da podrazumijevaju određeni stepen izdvajanja za rezervisanja za kreditne gubitke, potrebno je navesti i klasifikaciju aktive prema nivou rizika. Greuning i Brajović Bratanović smatraju da je „klasifikacija aktive ključno sredstvo za upravljanje rizicima" i da se „aktiva klasifikuje u vrijeme njenog odobrenja, a potom se revidira i reklasifikuje prema potrebi (u skladu sa nivoom kreditnog rizika) nekoliko puta tokom godine" (Greuning & Brajović Bratanović, 2006, str. 160). Prema ovim autorima, klasifikacija aktive banaka izvršena je u pet kategorija, i to: standardna ili dobra aktiva, aktiva koja zahtijeva posebnu pažnju, aktiva nižeg kvaliteta od standardnog (substandardna), sumnjiva i sporna potraživanja i gubitak (Greuning & Brajović Bratanović, 2006, str. 161 - 165).

Sistem klasifikacije aktive banke određuju samostalno, ali se pri tom moraju pridržavati standarda propisanih od strane nadzorne institucije. U razvijenim bankarskim sistemima banke imaju više potkategorija u okviru standardnih i dobrih kredita. Cilj ove prakse je da se poboljša kvalitet portfolio analize i da se unaprijedi razumijevanje odnosa između profitabilnosti i rizičnih kategorija. Vrijednost aktive treba da se procjenjuje sistematično tokom perioda i na osnovu objektivnih kriterijuma, a sve to treba da bude praćeno adekvatnom dokumentacijom. Međutim, procjena nivoa rezervisanja za kreditne gubitke uključuje određen stepen subjektivnosti, ali diskreciono pravo menadžmenta trebalo bi biti zasnovano na važećim politikama i procedurama.

Kao što je već rečeno, u nekim zemljama se definicija nekvalitetnih kredita veže za klasifikaciju aktive banaka prema nivou rizika. Međunarodna praksa predviđa sistem kategorizacije aktive u pet grupa koje, ujedno, određuju i kvalitet kreditnih plasmana banaka. Kvalitet kreditnog portfolia banke se mjeri putem klasifikacije aktive i rezervisanja za gubitke, sa ciljem da se procijeni vjerovatnoća da li će dužnik vratiti kredit i da li je izvršena adekvatna klasifikacija pojedinačnog plasmana. Plasmani se prate nekoliko puta godišnje, a minimalno onoliko puta koliko je u skladu sa regulatornim zahtjevima centralnih banaka pojedinačnih zemalja. Naravno, banka svojim internim aktima može da propiše i češće praćenje plasmana, a cilj praćenja je sagledavanje performansi i otplatnog kapaciteta dužnika.

U tabeli 4 predstavljena je, prema međunarodnim standardima, klasifikacija kredita koja je u skladu sa klasifikacijom bankarske aktive.

Tabela 4: Klasifikacija kredita u skladu sa klasifikacijom aktive prema međunarodnim standardima

Kategorija	Karakteristike
Standardna ili dobra aktiva	Krediti za koje nisu uočeni problemi prilikom otplate i za koje se ne očekuje materijalizacija rizika u periodu otplate.
Aktiva koja zahtijeva posebnu pažnju	Krediti sa činjeničnim slabostima, ali za koje se, ipak, ne očekuje gubitak ili klasifikovanje u substandardnu kategoriju.
Aktiva nižeg kvaliteta od standardnog (substandardna)	Krediti kod kojih finansijski položaj dužnika, kao ni uspostavljeni kolaterali, banci ne pružaju sigurnu zaštitu od gubitaka.
Sumnjiva i sporna potraživanja	Substandardni krediti sa dodatnim rizicima i za koje su pokušaji banke da naplati potraživanje neizvjesni u mjeri da nadoknadi njen kapital.
Gubitak	Krediti koji se smatraju nenaplativim, za koje dužnici nemaju spremnost i sposobnost za otplatu, a takođe, instrumenti obezbjeđenja ovakvih plasmana su izgubili originalnu vrijednost ili uopšte ne postoje. Za ovakve kredite možda i postoji još neka mogućnost naplate, ali dodatni napori za realizaciju takvih mogućnosti se smatraju nerazumnim ili neopravdanim. Saldo kredita u ovoj kategoriji se otpisuje iz bilansa banke.

Izvor: (IFC Corporation Advisory Services, access to Finance, 2011, str. 3)

Na osnovu svih prethodno navedenih definicija i klasifikacija nekvalitetnih kredita u različitim zemljama, može se zaključiti da ne postoji jednoobrazan i opšteprihvaćen standard za definisanje ove kategorije kreditnih plasmana banaka. Ipak, u najvećem broju slučajeva se, kao osnovna karakteristika nekvalitetnih kredita, navodi broj dana kašnjenja izmirenja obaveze prema banci. U većini nacionalnih definicija riječ je o kašnjenju od „90 i više dana“. Dalje, može se zaključiti da se prilikom obračuna kašnjenja uglavnom uzima u obzir saldo dospjele glavnice i/ili kamate, dok se cjelokupan iznos kredita čije plaćanje kasni kategorizuje kao nekvalitetni. U bankarskom sektoru se, zbog opasnosti koje mogu izazvati nekvalitetni krediti, a koje utiču na poslovne performanse banaka, posebna pažnja posvećuje pravovremenom monitoringu dužnika, plasmana i kolaterala. Banke formiraju i posebne organizacione jedinice koje se bave plasmanima sa identifikovanim povećanim nivoom rizika, jer se samo na taj način mogu pratiti rizični plasmani i smanjiti negativne posljedice koje oni mogu prouzrokovati.

1.2. Definicija nekvalitetnih kredita u Bosni i Hercegovini

U BiH se primjenjuje relativno sličan princip klasifikacije bankarske aktive kao i u bankarskim sistemima razvijenih zemalja. Takođe, za svaku kategoriju aktive se izdvajaju određene rezerve za kreditne gubitke. Centralna banka Bosne i Hercegovine (CBBiH) je „Odlukom o minimalnim standardima za upravljanje kreditnim rizikom i klasifikaciju aktive banaka" propisala minimalne standarde i kriterijume koje je banka dužna da poštuje prilikom klasifikacije svoje aktive.

U skladu sa odredbama Odluke, banka je dužna da klasifikuje stavke aktive koje su izložene kreditnom riziku u pet kategorija i to najmanje jednom kvartalno, a te kategorije su: A – dobra aktiva, B – aktiva sa posebnom napomenom, C – substandardna aktiva, D – sumnjiva aktiva i E – gubitak (CBBiH, 2011, str. 10).

Ovom Odlukom definisana je i nekvalitetna aktiva koja predstavlja aktivu koja ne donosi prihod, a banka je dužna da nekvalitetnom aktivom tretira stavke aktive kada:

- su glavnica i/ili kamata dospjele i nisu naplaćene duže od 90 dana od dana njihovog inicijalno ugovorenog dospjeća, odnosno kada su klasifikovane u kategorije C, D, E,
- su obaveze korisnika po kamati, za koje je dužnik zakasnio sa plaćanjem duže od 90 dana od njihovog inicijalno ugovorenog dospjeća, kapitalizovane (CBBiH, 2011, str. 7).

Važno je napomenuti da je banka dužna „da uspostavi vlastiti sistem za klasifikaciju stavki aktive koji precizno i jasno definiše kriterijume preuzimanja novog i procjene već postojećeg kreditnog rizika" (CBBiH, 2011, str. 6), a minimum tih kriterijuma je utvrđen u navedenoj odluci. Pored toga, banka je dužna da redovno obračunava rezerve za kreditne gubitke, a osnovica za obračun rezervi je bruto knjigovodstvena vrijednost potraživanja.

Banke mogu da vrše refinansiranje ili reprogramiranje kredita, a pod reprogramiranim kreditima se podrazumijevaju oni kod kojih su, zbog korisnikovih promjenljivih uslova i otplatnih sposobnosti, ranije ugovoreni rokovi i/ili uslovi naknadno promijenjeni da bi banke dužniku omogućile da lakše servisira dug (CBBiH, 2011, str. 8).

Na kraju, može se konstatovati da se aktiva banaka u BiH klasifikuje u pet kategorija, što je u skladu sa klasifikacijom po međunarodnim standardima. Takođe, karakteristike pojedinih kategorija su u skladu sa karakteristikama pojedinačnih kategorija koje su klasifikovane po međunarodnim standardima. U BiH su, kao i u razvijenim zemljama, banke dužne da izdvajaju obavezne rezerve za pokriće kreditnih gubitaka, a razlika je jedino u visini stope (zbog nestabilnih tržišnih uslova, u BiH su ove stope veće nego u razvijenim zemljama). Ukoliko korisnik, iz opravdanih razloga, ne može da izmiruje svoje obaveze, banka mu daje jednu ili više olakšica i ustupaka kako bi se problem naplate potraživanja riješio. Takođe, prilikom definisanja nekvalitetnih kredita, poštuje se pravilo kašnjenja plaćanja glavnice i/ili kamate od 90 i više dana, što je takođe u skladu sa međunarodnom praksom. Upravo zbog toga, moguće je porediti nivo nekvalitetnih u ukupnim kreditima bankarskog sektora BiH sa nivoom nekvalitetnih kredita u razvijenim zemljama i zemljama regiona.

1.3. Definicija nekvalitetnih kredita u akademskoj literaturi

Većina ekonomskih analitičara smatra da nekvalitetni krediti predstavljaju jedan od glavnih uzroka ekonomske stagnacije. Svaki nekvalitetni kredit je direktan odraz lošeg stanja klijenta banke, a indirektan odraz lošeg stanja u preduzećima. Nivo nekvalitetnih kredita u aktivi bankarskog sektora utiče na kreditni rejting zemlje. S obzirom na značaj koji nekvalitetni krediti imaju za pojedinačne banke, ali i za cjelokupni bankarski sektor, pa čak i ekonomiju jedne zemlje, česta su tema u mnogim ekonomskim analizama. Većina tih analiza se odnosi na faktore koji utiču na nekvalitetne kredite, a samo pojedini autori definišu ovaj pojam.

Caprio i Klingebiel nekvalitetne kredite definišu kao kredite koji već relativno duži period ne generišu prihode, pri čemu glavnica i/ili kamata na takve kredite nije plaćena određeni broj dana (Caprio & Klingebiel, 1996, str. 23). Prema njihovom mišljenu, iako ne postoji međunarodno priznati standard, često se koristi 90 dana kao prelomni trenutak.

Alton i Hazen nekvalitetne kredite definišu kao one koji su dospjeli prije 90 ili više dana ili one za koje se više ne obračunava razgraničenje kamate (Alton & Hazen, 2001, str. 1).

Hennie takođe smatra da je riječ o kreditima koji ne generišu prihode (Hennie, 2003).

Berge i Boye smatraju da se problematični krediti sastoje od dvije grupe, i to nekvalitetnih kredita i kredita koji nisu u kašnjenju, ali za koje banka smatra da su djelimično sporni (sumnjivi). Autori navode da se pod nekvalitetnim kreditima podrazumijevaju krediti kod kojih kamata i glavnica nisu plaćene o roku dospjeća, a kod ovakvih kredita banka treba da procijeni koliki je mogući gubitak (Berge & Boye, 2007, str. 65 - 66)..

Rottke i Gentgen ističu problem nepostojanja univerzalne definicije nekvalitetnih kredita i smatraju da se oni mogu posmatrati u užem i u širem smislu. Posmatrano u užem smislu, nekvalitetni krediti su krediti koji su dospjeli i nisu naplaćeni više od 90 dana, dok se, posmatrano u širem smislu, pod nekvalitetnim kreditima podrazumijevaju svi krediti lošijih performansi (Rottke & Gentgen, 2008, str. 63 - 64).

Guy navodi da se pod nekvalitetnim kreditima uglavnom podrazumijevaju krediti po kojima su obaveze dospjele prije 90 dana i više, ali nisu izmirene (Guy, 2011). Sa ovim načinom definisanja slažu se i Bexley i Nenninger, koji navode da su to krediti koji su 90 ili više dana u kašnjenju po osnovu dospjele kamate i/ili glavnice, te da se takvi krediti smatraju lošom aktivom u bankarskim evidencijama (Bexley & Nenninger, 2012, str. 46).

Saba, Kouser i Azeem smatraju da su nekvalitetni krediti oni kod kojih dužnik nije izmirio svoju ugovornu obavezu najmanje 90 dana ili oni za koje se sumnja da će biti takvi, a autori smatraju da su šanse da nekvalitetni kredit bude vraćen u cjelosti znatno niže nego što je to slučaj sa kreditima koji nisu tako klasifikovani (Saba, Kouser, & Azeem, 2012, str. 143).

Domaći autori, koji se bave problemom nekvalitetnih kredita, ne definišu ih samostalno, već se uglavnom oslanjaju na definicije Međunarodnog monetarnog fonda i Bazelskog komiteta za superviziju banaka. Takođe, često se u domaćoj bankarskoj praksi, prilikom klasifikacije kredita, koristi definicija koju je dao Institut za međunarodne finansije.

2. PREGLED EMPIRIJSKE LITERATURE O NEKVALITETNIM KREDITIMA

2.1. Osnovne karakteristike studija o nekvalitetnim kreditima

Trend rasta nekvalitetnih kredita je ključni problem sa kojim se suočavaju banke širom svijeta. Rast nekvalitetnih kredita je direktna posljedica povećanog nivoa kreditnog rizika pojedinačnih plasmana, a to se svakako odražava na kvalitet kreditnog portfolia banke, pa čak i na cjelokupan bankarski sektor i ekonomiju jedne zemlje. Upravljanje kreditnim rizikom nije nimalo jednostavno, naprotiv, riječ je o veoma složenom procesu kome treba posvetiti mnogo pažnje, ali adekvatnim upravljanjem ovom vrstom rizika može se smanjiti nivo nekvalitetnih kredita u bankama. Za sve zemlje, a posebno za one sa visokim učešćem nekvalitetnih u ukupnim kreditima, od izuzetne važnosti je razumijevanje ovog problema, prvenstveno zbog definisanja mjera za smanjenje nekvalitetnih kredita u narednom periodu.

Posljednjih godina, problem rasta nekvalitetnih kredita privukao je pažnju akademskih krugova, a da bi se on mogao riješiti, neophodno je sagledati faktore koji utiču na rast nekvalitetnih kredita, i u skladu sa tim, preduzeti adekvatne mjere za smanjenje njihovog učešća u aktivi banaka. Upravo ti faktori su bili predmet istraživanja u mnogim studijama koje se bave problematikom nekvalitetnih kredita. Istraživanja su rađena na različite načine i na različitim nivoima, ali u svim studijama je prikazana teorijska veza između finansijskog sektora i realne ekonomije, odnosno ekonomskih aktivnosti.

Literatura o nekvalitetnim kreditima relativno je opširna, a pruža dragocjene rezultate o faktorima koji utiču na njihov rast, odnosno o faktorima koji utiču na pogoršanje kvaliteta bankarske aktive. Neke studije su sprovedene na nivou jedne zemlje, a druge na nivou više zemalja. Neke od njih rađene su na nivou pojedinačnih banaka, dok su druge rađene na agregatnom nivou bankarskog sektora. Postoji mnogo faktora koji utiču na nekvalitetne kredite, a autori ih obično dijele u dvije grupe: specifični bankarski faktori i makroekonomski faktori. Tanasković i Jandrić navode da se, pored ove dvije grupe, „u novijim radovima mogu primijetiti i pokušaji da se problem problematičnih kredita jednim dijelom objasni i kroz djelovanje institucionalnih faktora koji određuju pravila ponašanja u bankarskom sektoru date zemlje“ (Tanasković & Jandrić, 2017, str. 77). Prilikom definisanja promjenljivih koje se koriste u analizi, obično se nivo nekvalitetnih kredita definiše kao zavisna, a makroekonomski i specifični bankarski faktori kao nezavisne promjenljive.

Specifični bankarski faktori su unutrašnji faktori koji su uzrokovani unutrašnjim funkcijama i aktivnostima banke, a mogu ih kontrolisati njeni menadžeri. U sprovedenim studijama, najčešće analizirani specifični bankarski faktori su:

- koeficijent adekvatnosti kapitala,
- odnos kredita i depozita,
- prinos na aktivu,
- prinos na akcijski kapital,
- kreditni rast,
- aktivna kamatna stopa.

Makroekonomski faktori su spoljašnji faktori koji se odnose na sprovođenje odluka i vladinu politiku, te kao takvi ne mogu biti kontrolisani od strane menadžera banke. Najčešće analizirani makroekonomski faktori su:

- stopa rasta bruto domaćeg proizvoda (BDP-a),
- javni dug kao % bruto domaćeg proizvoda,
- stopa nezaposlenosti,
- stopa inflacije, odnosno stopa rasta potrošačkih cijena.

Zbog što boljeg razumijevanja ovog problema, dat je pregled empirijskih istraživanja koja su sprovedena u pojedinačnim zemljama i u više zemalja, sa posebnim osvrtom na istraživanja koja su sprovedena u BiH. Na žalost, u BiH je sprovedeno jako malo istraživanja o nekvalitetnim kreditima, iako je njihov nivo u pojedinim komercijalnim bankama, ali i u bankarskom sektoru, prilično visok. Neke od studija koje su date u nastavku analiziraju samo specifične bankarske, neke samo makroekonomske, ali u većini studija se analiziraju obe grupe faktora koji utiču na nekvalitetne kredite.

2.2. Studije sprovedene u pojedinačnim zemljama

Literatura o nekvalitetnim kreditima veoma je opširna, a u nastavku je dat hronološki pregled istraživanja koja se bave ovim problemom, a koja su sprovedena u pojedinačnim zemljama. Istraživanja koja su sprovedena u BiH data su u posebnom dijelu disertacije, nakon pregleda istraživanja sprovedenih u više zemalja. Uglavnom, u ovim studijama su analizirani makroekonomski ili specifični bankarski faktori koji utiču na nekvalitetne kredite banaka, ali ima i studija u kojima su analizirane obe grupe faktora. Pored toga, u nekim studijama u analizu su uključeni i faktori koji se ne mogu svrstati u ove dvije grupe.

Keeton i Morris su sproveli prvu empirijsku analizu o faktorima koji utiču na nekvalitetne kredite, pod nazivom „Zašto se kreditni gubici banaka razlikuju?“ (naslov originala: *Why Do Banks' Loan Losses Differ?)* u kojoj su analizirali 2.470 osiguranih komercijalnih banaka u SAD, a korišteni su podaci iz perioda od 1978. do 1985. godine (Keeton & Morris, 1987, str. 3 - 21). Rezultati istraživanja pokazuju da su lokalni ekonomski uslovi i loš rezultat pojedinih privrednih sektora (poput poljoprivrede) glavni uzroci rasta nekvalitetnih kredita. Oni su naveli i da faktori na nivou banaka, poput olakog preuzimanja rizika i svjesnog odobravanja kredita sa velikom vjerovatnoćom nemogućnosti naplate od dužnika, utiču na nivo nekvalitetnih kredita banaka, ali u manjoj mjeri.

Sinkey i Greenawalt su sproveli istraživanje o nekvalitetnim kreditima u komercijalnim bankama u SAD, pod nazivom „Kreditni gubici i rizično ponašanje u velikim komercijalnim bankama“ (naslov originala: *Loan – loss experience and risk – taking behavior at large commercial banks*) (Sinkey & Greenawalt, 1991, str. 43 - 59). Analiza je sprovedena u periodu od 1984. do 1987. godine, a pokazala je da spoljašnji faktori (loši ekonomski uslovi) i unutrašnji faktori (loše kreditne odluke) utiču na nekvalitetne kredite. Autori smatraju da su prekomjerno kreditiranje i visoke kamatne stope glavni faktori koji utiču na rast nekvalitetnih kredita, dok banke sa adekvatnim kapitalom imaju niže stope kreditnih gubitaka.

Gambera je takođe sproveo istraživanje u SAD, pod nazivom „Pojedinačne prognoze kvaliteta bankarskih kredita u poslovnom ciklusu“ (naslov originala: *Simple Forecasts of Bank Loan Quality in the Business Cycle*), koje je obuhvatilo kvartalne podatke o nekvalitetnim kreditima u periodu od 1987. do 1999. godine (Gambera, 2000). Tražeći vezu između makroekonomskih pokazatelja i kvaliteta bankarske aktive, autor je ukazao da dinamika makroekonomskih faktora može ukazati na potencijalni rast nekvalitetnih kredita. Promjenljive koje su uključene u analizu su: broj zahtjeva za proglašenje bankrota, prihodi koji su ostvareni od poljoprivrednog sektora, bruto domaći proizvod, nezaposlenost i broj izdatih građevinskih dozvola.

Arpa, Giulini, Ittner i Paner su sproveli istraživanje u bankarskom sektoru Austrije, pod nazivom „Uticaj makroekonomskih kretanja na banke u Austriji: implikacije za bankarske supervizore“ (naslov originala: *The influence of macroeconomic developments on Austrian banks: implications for banking supervision*) (Arpa, Giulini, Ittner, & Pauer, 2001, str. 91 - 116). Cilj studije je procjena uticaja makroekonomskih kretanja na rizike u austrijskim bankama u desetogodišnjem periodu, odnosno u periodu od 1990. do 1999. godine. Prema dobijenim rezultatima, rezervisanja za rizične kredite, u odnosu na ukupno odobrene kredite, variraju u zavisnosti od kretanja stope rasta realnog BDP-a, stope inflacije, cijena nekretnina i realne kamatne stope.

Salas i Saurina su u studiji pod nazivom „Kreditni rizik u dva institucionalna režima: Španske komercijalne banke i štedionice“ (naslov originala: *Credit Risk in Two Institutional Regimes: Spanish Commercial and Savings Banks*), kako sam naslov kaže, uporedili faktore nekvalitetnih kredita u španskim komercijalnim bankama i štedionicama (Salas & Saurina, 2002). Autori su analizirali uticaj makroekonomskih i specifičnih bankarskih faktora na nekvalitetne kredite, u periodu od 1985. do 1997. godine. Rezultati istraživanja pokazuju da su stopa rasta realnog BDP-a, tržišna snaga, nagla kreditna ekspanzija, zaduženost subjekata, veličina banke, struktura kreditnog portfolia i adekvatnost kapitala faktori koji utiču na nekvalitetne kredite u komercijalnim bankama i štedionicama u Španiji.

Ranjan i Dhal su u studiji pod nazivom „Nekvalitetni krediti i uslovi kreditiranja javnog bankarskog sektora u Indiji: empirijska procjena (naslov originala: *Non-Performing Loans and Terms of Credit of Public Sector Banks in India: An Empirical Assessment*) analizirali faktore nekvalitetnih kredita u bankarskom sektrou Indije, u periodu od 1993. do 2003. godine (Ranjan & Dhal, 2003, str. 81 - 121). Oni smatraju da na nekvalitetne kredite utiču i makroekonomski i finansijski faktori, odnosno da porast kamatnih stopa utiče na povećanje, a rok dospjeća i povoljni makroekonomski i poslovni uslovi (mjereni stopom rasta BDP-a) utiču na smanjenje nivoa nekvalitetnih kredita u bankarskom sektoru Indije.

Jimenez i Saurina su u studiji pod nazivom „Kreditni ciklus, kreditni rizik i regulacija“ (naslov originala: *Credit Cycles, Credit Risk, and Prudential Regulation*) analizirali nekvalitetne kredite u bankarskom sektoru Španije u periodu od 1984. do 2002. godine (Jimenez & Saurina, 2006, str. 65 - 98). Rezultati pokazuju da postoji jaka veza između kreditnog rasta i nekvalitetnih kredita, odnosno da kreditni rast ima značajan i pozitivan uticaj na nekvalitetne kredite. Oni navode da su niži kreditni standardi posljedica brzog kreditnog rasta što vodi ka povećanju nivoa nekvalitetnih kredita u budućnosti, te da rast BDP-a i pad realnih kamatnih stopa vode ka padu nivoa nekvalitetnih kredita u bankarskom sektoru Španije.

Khemraj i Pasha su u svojoj studiji „Determinante nekvalitetnih kredita: empirijska studija u Gvajani“ (naslov originala: *The determinants of non-performing loans: an econometric case study of Guyana*) analizirali faktore koji utiču na nekvalitetne kredite u šest komercijalnih banaka u Gvajani, a korišteni podaci se odnose na period od 1994. do 2004. godine (Khemaj & Pasha, 2009). U istraživanje su bili uključeni i makroekonomski (stopa rasta BDP-a, inflacija i realni efektivni kurs) i specifični bankarski faktori (efektivna kamatna stopa, veličina banke, kreditni rast i odnos kredita u ukupnoj aktivi banaka). Prema ovim autorima, stopa rasta BDP-a je u obrnutoj korelaciji sa nivoom nekvalitetnih kredita, odnosno napredak u realnoj ekonomiji vodi ka njihovom smanjenju. Takođe, rezultati istraživanja su pokazali da negativna veza postoji i između inflacije i nekvalitetnih kredita. Sa druge strane, realni efektivni kurs ima pozitivan odnos sa nekvalitetnim kreditima. Autori takođe navode da banke koje naplaćuju veće kamate imaju i veću vjerovatnoću rasta nekvalitetnih kredita u kreditnom portfoliu, što ukazuje na pozitivan odnos između kamatne stope i nekvalitetnih kredita.

Louzis, Vouldis i Metaxas su sproveli istraživanje o nekvalitetnim kreditima u Grčkoj, a rezultate su predstavili u studiji „Makroekonomske i specifične bankarske determinante nekvalitetnih kredita u Grčkoj: komparativna studija hipotekarnog, privrednog i potrošačkog kreditnog portfolia“ (naslov originala: *Macroeconomic and Bank-Specific Determinants of Non-Performing Loans in Greece: A Comparative Study of Mortgage, Business and Consumer Loan Portfolios*) (Louzis, Vouldis, & Metaxas, 2010). Studija je zasnovana na hipotezi da dvije grupe faktora, odnosno i makroekonomski i specifični bankarski faktori imaju uticaj na kvalitet kredita, a da taj uticaj varira u zavisnosti od vrste kredita. Istraživanje je obuhvatilo devet najvećih grčkih banaka, koje čine oko 90% grčkog bankarskog sektora, u periodu od 2003. do 2009. godine. Autori su posebno analizirali makroekonomske i specifične bankarske faktore koji utiču na tri grupe kredita (hipotekarne, privredne i potrošačke), a nakon toga su ih međusobno uporedili. Rezultati pokazuju da makroekonomski faktori, a posebno stopa rasta BDP-a, nezaposlenost i kamatne stope, imaju snažan uticaj na nekvalitetne kredite svih kategorija. Ipak, rezultati su pokazali da navedeni makroekonomski faktori imaju najmanji uticaj na hipotekarne kredite. Takođe, autori su dokazali da na nekvalitetne kredite, pored makroekonomskih, utiču i specifični bankarski faktori, odnosno da nivo nekvalitetnih kredita zavisi od kvaliteta upravljanja u banci.

Collins i Wanjan su sproveli istraživanje o efektima povećanja kamatnih stopa na nekvalitetnu aktivu banaka u Keniji, a rezultate su prestavili u studiji „Efekti kamatne stope na nekvalitetnu aktivu: slučaj komercijalnih banaka u Keniji“ (naslov originala: *The effects of interest rate spread on the level of non-performing assets: a case of commercial banks in Kenya*) (Collins & Wanjau, 2011, str. 58 - 65). U studiji su korišteni podaci iz ukupno 43 komercijalne banke koji su prikupljeni iz primarnih i sekundarnih izvora u periodu od 1999. do 2008. godine. Autori su zaključili da nivo kamatnih stopa utiče na kvalitet aktive banaka jer povećanje kamatnih stopa povećava i troškove kredita koji se naplaćuju od korisnika. Povećanje troškova kredita vodi ka povećanju nekvalitetnih kredita, pa autori zaključuju da kamatne stope imaju statistički značajan i pozitivan odnos sa nekvalitetnim kreditima. Takođe, autori preporučuju da komercijalne banke u Keniji prvo trebaju procijeniti svoje klijente, te u skladu sa tim formirati i kamatne stope jer neefikasna politika kamatnih stopa može povećati njihov nivo, što će se negativno odraziti na kvalitet aktive banaka.

Adebola, Wan Yusoff i Dahalan su sproveli studiju pod nazivom „ARDL pristup determinantama nekvalitetnih kredita u islamskom bankarskom sektoru u Maleziji“ (naslov originala: *An ARDL Approach to the Determinants of Non-Performing Loans in Islamic Banking System in Malaysia*), sa ciljem da odrede uticaj makroekonomskih faktora na nekvalitetne kredite (Adebola, Wan Yusoff, & Dahalan, 2011, str. 20 - 30). Njihova studija obuhvatila je mjesečne podatke od januara 2007. do decembra 2009. godine, a nezavisne promjenljive koje su uključene u analizu su: aktivna kamatna stopa, stopa rasta potrošačkih cijena i indeks industrijske proizvodnje. Rezultati su pokazali da kamatne stope imaju statistički značajan i pozitivan uticaj na nekvalitetne kredite, stopa rasta potrošačkih cijena ima statistički značajan i negativan uticaj, dok uticaj indeksa industrijske proizvodnje nije statistički značajan.

Saba, Kouser i Azeem su sproveli studiju pod nazivom „Determinante nekvalitetnih kredita: slučaj bankarskog sektora SAD“ (naslov originala: *Determinants of Non Performing Loans: Case of US Banking Sector*) u kojoj su istraživali makroekonomske i specifične bankarske faktore koji utiču na nekvalitetne kredite u bankarskom sektoru SAD-a (Saba, Kouser, & Azeem, 2012, str. 141 - 151). U studiju su uključene tri nezavisne promjenljive: stopa rasta realnog BDP-a, ukupni krediti i aktivna kamatna stopa, a korišteni podaci obuhvataju period od 1985. do 2010. godine. Rezultati pokazuju da sve tri nezavisne promjenljive imaju statistički značajan uticaj na zavisnu promjenljivu, pri čemu ukupni krediti imaju statistički značajan i pozitivan uticaj, dok aktivna kamatna stopa i stopa rasta realnog BDP-a imaju statistički značajan i negativan uticaj na nekvalitetne kredite u ovom bankarskom sektoru.

Swamy je sproveo studiju pod nazivom „Uticaj makroekonomskih i endogenih faktora na nekvalitetnu aktivu banaka“ (naslov originala: *Impact of macroeconomic and endogenous factors on non performing bank assets*) u bankarskom sektoru Indije (Swamy, 2012, str. 27 - 47). Cilj studije je da se ispita uticaj makroekonomskih faktora na nekvalitetnu aktivu različitih bankarskih grupacija na osnovu njihove vlasničke strukture, u periodu od 1997. do 2009. godine. Autor je zaključio da stopa rasta BDP-a, inflacija i kamatne stope utiču na nekvalitetne kredite, te da povoljni makroekonomski uslovi utiču na smanjenje nekvalitetne aktive banaka. Takođe, autor je zaključio da velike i privatne banke, zbog boljeg upravljanja kreditnim rizikom, imaju kvalitetniju aktivu.

Tomak je sproveo studiju pod nazivom „Determinante kredita komercijalnih banaka: dokazi iz Turske“ (naslov originala: *Determinants of Commercial Banks' Lending Behavior: Evidence from Turkey*) na uzorku od 18 (15 privatnih i 3 državne) od ukupno 25 banaka u Turskoj (Tomak, 2013, str. [illegible] - 943). Osnovni cilj istraživanja je identifikacija faktora koji utiču na bankarske kredite u periodu od 2003. do 2012. godine. U analizu je uključeno ukupno šest faktora, od kojih su tri makroekonomska (stopa rasta BDP-a, stopa inflacije i kamatne stope) i tri specifična bankarska (veličina banke, pristup dugoročnim sredstvima i nekvalitetni krediti) faktora. Rezultati pokazuju da je većina navedenih faktora uticala na kredite banaka u Turskoj tokom analiziranog desetogodišnjeg perioda. Pri tom, veličina banke, ukupne obaveze i stopa inflacije imaju statistički značajan i pozitivan, a nekvalitetni krediti imaju statistički značajan i negativan uticaj na bankarske kredite, dok uticaj stope rasta BDP-a i kamatne stope nije statistički značajan.

Ahmad i Bashir su sproveli dvije studije o nekvalitetnim kreditima u komercijalnim bankama u Pakistanu. Prva studija „Objašnjenje uticaja makroekonomskih faktora kao determinanti nekvalitetnih kredita: Dokazi iz Pakistana“ (naslov originala: *Explanatory Power of Macroeconomic Variables as Determinants of Non-Performing Loans: Evidence from Pakistan*) analizira uticaj makroekonomskih faktora na nekvalitetne kredite u 30 od ukupno 34 komercijalne banke u periodu od 1990. do 2011. godine (Ahmad & Bashir (a), 2013, str. 243 - 255). Analizom je obuhvaćeno devet makroekonomskih faktora, a rezultati pokazuju da šest analiziranih faktora ima statistički značajan uticaj na nekvalitetne kredite (stopa rasta BDP-a, kamatna stopa, stopa inflacije, stopa rasta potrošačkih cijena, stopa izvoza i industrijska proizvodnja), dok uticaj tri faktora (nezaposlenost, realni efektivni kurs i strane direktne investicije) nije statistički značajan. Takođe, analiza je pokazala da stopa rasta BDP-a, kamatna stopa, stopa inflacije, stopa izvoza i industrijska proizvodnja imaju statistički značajan i negativan, a stopa rasta potrošačkih cijena statistički značajan i pozitivan uticaj na nekvalitetne kredite. Druga studija „Objašnjenje uticaja specifičnih bankarskih faktora kao determinanti nekvalitetnih kredita: Dokazi iz bankarskog sektora Pakistana“ (naslov originala: *Explanatory Power of Bank Specific variables as Determinants of Non-Performing Loans: Evidence from Pakistan Banking Sector*) analizira uticaj specifičnih bankarskih faktora na nekvalitetne kredite u 30 komercijalnih banaka u Pakistanu (Ahmad & Basir (b), 2013, str. 1200 - 1231). U studiji su korišteni podaci od 2006. do 2011. godine, a testirano je devet hipoteza pomoću deset faktora, i to: loše upravljanje (neefikasnost), nedovoljno ulaganje vremena i novca u posao (neefikasnost), moralni hazard (racio solventnosti i odnos kredita i depozita), veličina (tržišna moć), loše upravljanje II (prinos na akcijski kapital i prinos na aktivu), prociklična kreditna politika (kreditni rast), osnovna ograničenja budžeta (ukupne obaveze u odnosu na prihod), efekat kamatne stope na depozite (stopa depozita) i efekti odnosa kredita i depozita (stopa rezervi). Rezultati pokazuju da su tri hipoteze prihvaćene (moralni hazard, loše upravljanje II i prociklična kreditna politika), pet ih je odbačeno u potpunosti (loše upravljanje, nedovoljno ulaganje vremena i novca u posao, veličina, osnovna ograničenja budžeta i efekat kamatne stope na depozite), a jedna hipoteza (efekti odnosa kredita i depozita) je djelimično odbačena jer je analiza pokazala da ova promjenljiva ima značajnu vezu sa nekvalitetnim kreditima (Ahmad & Basir (b), 2013, str. 1200 - 1231).

Badar i Javid su sproveli studiju pod nazivom „Uticaj makroekonomskih faktora na nekvalitetne kredite: empirijska istraživanja komercijalnih banaka u Pakistanu“ (naslov originala: *Impact of Macroeconomic Forces on Nonperforming Loans: An Empirical Study of Commercial Banks in Pakistan*) u kojoj su analizirali uticaj koji imaju makroekonomski faktori na nekvalitetne kredite u dugom i kratkom roku (Badar & Javid, 2013, str. 40 - 48). Analizirano je 36 komercijalnih banaka u Pakistanu, a korišteni su kvartalni podaci od januara 2002. do decembra 2011. godine. U analizu je uključeno pet makroekonomskih faktora, i to: stopa rasta BDP-a, stopa inflacije, devizni kurs, kamatne stope i novčana masa. Rezultati istraživanja pokazuju da postoji jak dugoročni odnos novčane mase i kamatne stope sa nekvalitetnim kreditima, odnosno, jak kratkoročni odnos inflacije i deviznog kursa sa nekvalitetnim kreditima. Autori navode da kreatori politike treba da propišu fiskalne i monetarne mjere koje će poboljšati finansijsko zdravlje zemlje, a pravilno sprovođenje tih mjera će uticati na smanjenje nekvalitetnih kredita u komercijalnim bankama.

Shingjergji je sproveo dvije studije o nekvalitetnim kreditima u bankarskom sektoru Albanije. Prva studija pod nazivom „Uticaj makroekonomskih promjenljivih na nekvalitetne kredite u bankarskom sektoru Albanije tokom 2005 - 2012“ (naslov originala: *The Impact of Macroeconomic Variables on the Non Performing Loans in the Albanian Banking System During 2005 - 2012*) bavi se analizom makroekonomskih faktora koji utiču na nekvalitetne kredite u 16 privatnih komercijalnih banaka u Albaniji (Shingjergji (a), 2013, str. 335 - 339). Autor ističe da je bankarski sektor Albanije znatno napredovao poslednjih nekoliko godina, ali veliki problem predstavlja visok nivo nekvalitetnih kredita u aktivi banaka. U istraživanju se polazi od hipoteze da makroekonomski faktori utiču na nivo nekvalitetnih kredita u bankarskom sektoru. U analizu su uključene četiri makroekonomske promjenljive (stopa rasta BDP-a, stopa inflacije, devizni kurs i kamatne stope), a rezultati pokazuju da stopa rasta BDP-a, kamatne stope i devizni kurs imaju pozitivan, a inflacija negativan odnos sa nekvalitetnim kreditima. Druga studija pod nazivom „Uticaj specifičnih bankarskih faktora na nekvalitetne kredite u bankarskom sektoru Albanije“ (naslov originala: *The Impact of Bank Specific Variables on the Non Performing Loans Ratio in the Albanian Banking System*) bavi se analizom specifičnih bankarskih faktora koji utiču na nekvalitetne kredite u periodu od 2002. do 2012. godine (Shingjergji (b), 2013, str. 148 - 152). U ovom istraživanju se, za razliku od prethodnog, polazi od hipoteze da specifični bankarski faktori utiču na nivo nekvalitetnih kredita u bankarskom sektoru Albanije. U analizu je uključeno pet specifičnih bankarskih promjenljivih i to: koeficijent adekvatnosti kapitala, ukupni krediti, kamatna marža, prinos na akcijski kapital i odnos kredita i aktive. Rezultati pokazuju da ukupni krediti i kamatna marža imaju statistički značajan i pozitivan uticaj, a koeficijent adekvatnosti kapitala, odnos kredita i aktive i prinos na akcijski kapital statistički značajan i negativan uticaj na nekvalitetne kredite u bankarskom sektoru, dok uticaj koeficijenta adekvatnosti kapitala nije statistički značajan. Shingjergji je, analizirajući nekvalitetne kredite u bankarskom sektoru Albanije, pokazao da na njih utiču i makroekonomski i specifični bankarski faktori.

Otašević je sproveo studiju pod nazivom „Analiza makroekonomskih determinanti kvaliteta kreditnog portfolia banaka u Srbiji“ (naslov originala: *Macroeconomic determinants of the quality of banks' loan portfolio in Serbia*) sa ciljem da ispita uticaj makreokonomskih faktora na realizaciju kreditnog rizika u bankama u Srbiji, mjereći kreditni rizik odnosom rezervisanja za kreditne gubitke u odnosu na ukupne bruto kredite (Otašević, 2013). Pri tom, u istraživanju su uzeti u obzir i veličina banke, kapitalizacija i likvidnost zbog efekta koji imaju na ponašanje kredita. Korišteni su podaci za 33 komercijalne banke, a oni obuhvataju period od trećeg kvartala 2008. do drugog kvartala 2012. godine, pri čemu su posebno analizirani krediti koji su plasirani stanovništvu i krediti koji su plasirani preduzećima. Rezultati pokazuju da pogoršanje poslovnog ciklusa i depresijacija domaće valute utiču na pogoršanje kvaliteta kreditnog portfolia. Takođe, rezultati pokazuju da inflacija utiče na kvalitet kredita privredi i stanovništvu, a kvalitet kredita stanovništvu je dodatno osjetljiv na kretanje kratkoročnih kamatnih stopa, te u skladu sa tim, pogoršanje kreditnog kvaliteta može imati negativne povratne efekte na kreditiranje, realnu ekonomiju i finansijsku stabilnost. Autor je istakao i niz ograničenja sa kojima se suočio prilikom istraživanja, a sva se svode na ograničenje u dostupnosti podataka za detaljniju i dublju analizu jer određeni podaci nisu dostupni ili su dostupni samo za kratki vremenski period.

Jameel je sproveo studiju pod nazivom „Ključni faktori nekvalitetnih kredita – dokazi za bankarski sektor Pakistana“ (naslov originala: *Crucial Factors of Nonperforming loans Evidence from Pakistani Banking Sector*), sa ciljem da ispita koji faktori utiču na nekvalitetne kredite u bankarskom sektoru Pakistana (Jameel, 2014, str. 704 - 710). U svom istraživanju koristio je podatke koji obuhvataju jedanaestogodišnji vremenski period, od 2000. do 2010. godine i sljedeće nezavisne promjenljive: stopa rasta BDP-a, prosječna ponderisana aktivna kamatna stopa, rok dospjeća kredita, odnos kredita i depozita i koeficijent adekvatnosti kapitala. Rezultati pokazuju da stopa rasta BDP-a, prosječna ponderisana aktivna kamatna stopa, rok dospjeća kredita i koeficijent adekvatnosti kapitala imaju statistički značajan uticaj na nekvalitetne kredite komercijalnih banaka u Pakistanu, dok uticaj odnosa kredita i depozita nije statistički značajan. Analiza je pokazala da su nekvalitetni krediti u negativnoj korelaciji sa stopom rasta BDP-a, rokom dospjeća kredita, koeficijentom adekvatnosti kapitala i odnosom kredita i depozita. Dalje, analiza je pokazala da su nekvalitetni krediti u pozitivnoj korelaciji sa prosječno ponderisanom aktivnom kamatnom stopom. U studiji, autor navodi da komercijalne banke u Pakistanu treba da prilagode svoju kreditnu politiku u skladu sa očekivanim promjenama faktora koji utiču na nekvalitetne kredite.

Turan i Koskija sproveli su studiju pod nazivom „Nekvalitetni krediti u Albaniji“ (naslov originala: *Nonperforming Loans in Albania*) u kojoj su analizirali uticaj osnovnih ekonomskih faktora na nekvalitetne kredite u bankarskom sektoru Albanije (Turan & Koskija, 2014, str. 491 - 500). Nivo nekvalitetnih kredita kontinuirano raste i oni predstavljaju veliki problem u ovom sektoru, a posljedica su ekonomske krize i smanjenja prihoda stranaca. U analizu je uključeno pet makroekonomskih faktora (BDP, stopa nezaposlenosti, stopa inflacije, aktivna kamatna stopa i novčane doznake), a korišteni su kvartalni podaci od 2003. do 2013. godine. Rezultati pokazuju da postoji negativan odnos između stope rasta BDP-a, inflacije, aktivne kamatne stope, novčanih doznaka i nekvalitetnih kredita, a pozitivan između stope nezaposlenosti i nekvalitetnih kredita. Autori preporučuju niz mjera koje se mogu preduzeti u cilju smanjenja nivoa nekvalitetnih kredita, prvenstveno plasiranje više malih, a manje velikih kredita i poboljšanje procesa monitoringa kredita.

Pradhan i Pandey su sproveli studiju „Specifične bankarske i makroekonomske promjenljive koje utiču na nekvalitetne kredite komercijalnih banaka u Nepalu“ (naslov originala: *Bank Specific and Macroeconomic Variables affecting Non-Performing Loans of Nepalese Commercial Banks*), sa ciljem da utvrde koji faktori utiču na nekvalitetne kredite komercijalnih banaka u Nepalu (Pradhan & Pandey, 2016). Oni su analizirali pojedinačne podatke iz 21 komercijalne banke, u periodu od 2008. do 2014. godine. U analizu je uključeno pet specifičnih bankarskih faktora (prinos na aktivu, prinos na akcijski kapital, odnos kredita i depozita, koeficijent adekvatnosti kapitala i veličina banke) i tri makroekonomska faktora (stopa rasta BDP-a, inflacija i godišnji rast novčane mase). Rezultati pokazuju da stopa rasta BDP-a, rast novčane mase, veličina banke, odnos kredita i depozita i prinos na aktivu imaju pozitivan, a inflacija, prinos na akcijski kapital i koeficijent adekvatnosti kapitala negativan odnos sa nekvalitetnim kreditim.

Može se konstatovati da je sprovedeno mnogo istraživanja o faktorima koji utiču na nekvalitetne kredite u bankarskim sektorima pojedinačnih zemalja. Hronološki pregled sprovedenih istraživanja dat je u tabeli 5.

Tabela 5: Pregled studija sprovedenih u pojedinačnim zemljama

Autor	Naziv studije	Godina	Zemlja	Period	Faktori	
					M.F.	S.B.F.
ton i Morris	*Why Do Banks' Loan Losses Differ?*	1987	SAD	1978-1985	+	+
Sinkey i nawalt	*Loan – loss experience and risk – taking behavior at large commercial banks*	1991	SAD	1984-1987	+	+
Gambera	*Simple Forecasts of Bank Loan Quality in the iness Cycle*	2000	SAD	1987-1999	+	-
Arpa, Giulini, Ittner i Paner	*The influence of macroeconomic developments on Austrian banks: implications for banking supervision*	2001	Austrija	1990-1999	+	-
Salas i Saurina	*Credit Risk in Two Institutional Regimes: Spanish Commercial and Savings Banks*	2002	Španija	1985-1997	+	+
Ranjan i Dhal	*Non-Performing Loans and Terms of Credit of Public Sector Banks in India: An Empirical Assessment*	2003	Indija	1993-2003	+	-
enez i Saurina	*Credit Cycles, Credit Risk, and Prudential Regulation*	2006	Španija	1984-2002	+	+
mraj i Pasha	*The determinants of non-performing loans: an econometric case study of Guyana*	2009	Gvajana	1994-2004	+	+
Louzis, ldis i Metaxas	*Macroeconomic and Bank-Specific Determinants of Non-Performing Loans in Greece: A Comparative Study of Mortgage, Business and sumer Loan Portfolios*	2010	Grčka	2003-2009	+	+
Collins i Wanjan	*The effects of interest rate spread on the level of non-performing assets: a case of commercial banks in Kenya*	2011	Kenija	1999-2008	+	-
Adebola, Wan soff i Dahalan	*An ARDL Approach to the Determinants of Non-Performing Loans in Islamic Banking System in Malaysia*	2011	Malezija	2007-2009	+	-
a, Kouser i Azeem	*Determinants of Non Performing Loans: Case of Banking Sector*	2012	SAD	1985-2010	+	+
Swami	*Impact of macroeconomic and endogenous factors non performing bank assets*	2012	Indija	1997-2009	+	+
Tomak	*Determinants of Commercial Banks' Lending havior: Evidence from Turkey*	2013	Turska	2003-2012	+	+
Ahmad i Bashir	*Explanatory Power of Macroeconomic Variables as Determinants of Non-Performing Loans: dence from Pakistan*	2013	Pakistan	1990-2011	+	-
Ahmad i Bashir	*Explanatory Power of Bank Specific variables as Determinants of Non-Performing Loans: Evidence from Pakistan Banking Sector*	2013	Pakistan	2006-2011	-	+
Badar i Javid	*Impact of Macroeconomic Forces on Nonperforming Loans: An Empirical Study of mmercial Banks in Pakistan*	2013	Pakistan	2002-2011	+	-
Shingjergji	*The Impact of Macroeconomic Variables on the Non Performing Loans in the Albanian Banking System During 2005 – 2012*	2013	Albanija	2005-2012	+	-
Shingjergji	*The Impact of Bank Specific Variables on the Non Performing Loans Ratio in the Albanian Banking tem*	2013	Albanija	2002-2012	-	+
Otašević	*Macroeconomic determinants of the quality of banks' loan portfolio in Serbia*	2013	Srbija	2008-2012	+	-
Jameel	*rucial Factors of Nonperforming loans Evidence from Pakistani Banking Sector*	2014	Pakistan	2000-2010	+	+
Turan i Koskija	*Nonperforming Loans in Albania*	2014	Albanija	2003-2013	+	-
Pradhan i Pandey	*Bank Specific and Macroeconomic Variables affecting Non-Performing Loans of Nepalese Commercial Banks*	2016	Nepal	2008-2014	+	+

Izvor: Izrada autora

Rezultati prethodno opisanih istraživanja pokazuju da i makroekonomski i specifični bankarski faktori utiču na nekvalitetne kredite banaka, ali je njihov uticaj različit. Zbog toga nije moguće izvući generalni zaključak o uticaju određenog faktora na nekvalitetne kredite i primjenjivati ga u svim zemljama, već je potrebno sprovesti istraživanje u svakoj zemlji posebno kako bi se sa sigurnošću moglo utvrditi koji faktor i na koji način utiče na kvalitet kreditnog portfolia banaka.

U posljednje vrijeme, pored analize faktora koji utiču na nekvalitetne kredite, analizira se i uticaj nekvalitetnih kredita na poslovne performanse banaka. Takvih studija za sada nema mnogo, a pregled sprovedenih istraživanja dat je u nastavku.

Chimkono, Muturi i Njeru su sproveli studiju pod nazivom „Uticaj nekvalitetnih kredita i drugih faktora na rad komercijalnih banaka u Malavi“ (naslov originala: *Effect of Non-Performing Loans and Other Factors on Performance of Commercial Banks in Malawi*) (Chimkono, Muturi, & Njeru, 2016, str. 549 - 563). Kao što sam naslov kaže, osnovni cilj studije je da se ispita kako nekvalitetni krediti i drugi faktori fnansijskog poslovanja utiču na rad komercijalnih banaka u Malavi. Analiza je obuhvatila podatke za 10 komercijalnih banaka, u periodu od 2008. do 2014. godine. Rezultati su pokazali da nekvalitetni krediti imaju statistički značajan i negativan uticaj na profitabilnost banaka, te da kvalitet aktive, energetska efikasnost, stopa obaveznih rezervi i aktivna kamatna stopa imaju statistički značajan uticaj na poslovanje ovih banaka.

Bhattarai je sproveo studiju pod nazivom „Uticaj nekvalitetnih kredita na profitabilnost komercijalnih banaka u Nepalu“ (naslov originala: *Effect of Non-Performing Loan on the Profitability of Commercial Banks in Nepal*), sa ciljem da utvrdi kako nekvalitetni krediti utiču na uspješnost poslovanja banaka (Bhattarai, 2016, str. 435 - 442). U analizu je uključeno 40 komercijalnih banaka, a prikupljeni su podaci od 2010. do 2015. godine. Istraživanje je pokazalo da na profitabilnost komercijalnih banaka utiču nekvalitetni krediti, veličina banke, troškovi kredita i stopa rasta BDP-a, dok stopa inflacije nema statistički značajan uticaj. Takođe, rezultati su pokazali da nekvalitetni krediti imaju negativan uticaj na prinos na aktivu, a pozitivan na prinos na akcijski kapital.

2.3. Studije sprovedene u više zemalja

Literatura o nekvalitetnim kreditima uglavnom obuhvata studije koje su sprovedene u pojedinačnim zemljama, ali ima i onih koje se bave ovim problemom u više zemalja. U ovakvim istraživanjima mogu se koristiti agregatni (na nivou bankarskog sektora) i razdvojeni (na nivou pojedinačnih banaka) podaci, odnosno mjesečni, kvartalni ili godišnji podaci.

U nastavku je dat pregled studija u kojima se analizira uticaj makroekonomskih i/ili specifičnih bankarskih faktora na nekvalitetne kredite u bankarskim sektorima različitih zemalja. U jednu od tih studija uključena je i BiH. Zaključak većine studija je, kao i kod studija koje su sprovedene u pojedinačnim zemljama, da makroekonomski i specifični bankarski faktori utiču na nekvalitetne kredite banaka. Takođe, čest rezultat ovih studija je pozitivan odnos između ekonomskog rasta i kvaliteta aktive, a česta mjera kvaliteta aktive su nekvalitetni krediti.

Boudriga, Taktak i Jellouli su sproveli dva istraživanja o nekvalitetnim kreditima. Prva studija, pod nazivom „Bankarska supervizija i nekvalitetni krediti: analiza u više zemalja“ (naslov originala: *Banking supervision and nonperforming loans: a cross-country analysis*) sprovedena je sa ciljem da se analiziraju faktori nekvalitetnih kredita i potencijalni uticaj supervizora na izloženost kreditnom riziku (Boudriga, Taktak, & Jellouli, 2009, str. 286 - 318). U analizi se koriste agregatni bankarski, ekonomski i finansijski podaci za 59 zemalja, u periodu od 2002. do 2006. godine. Neke od zemalja koje su obuhvaćene analizom su: Australija, Belgija, Bugarska, Kanada, Hrvatska, Estonija, Finska, Francuska, Njemačka, Grčka, Italija, Japan, Meksiko, Norveška, Pakistan, Poljska, Rusija, Slovačka, Španija, Švedska, Turska, SAD i Velika Britanija, a autori su faktore podijelili u dvije grupe: specifične bankarske faktore i faktore bankarske supervizije. Rezultati pokazuju da su nekvalitetni krediti uglavnom pod uticajem specifičnih bankarskih faktora, kao što su koeficijent adekvatnosti kapitala, rezerve za kreditne gubitke, prinos na aktivu i vlasništvo banke, dok je izloženost kreditnom riziku smanjena u zemljama u kojima su poboljšani pravni i institucionalni okviri. Autori navode da je efikasan način da se smanji nivo nekvalitetnih kredita jačanje pravnog sistema i povećanje transparentnosti i demokratije. Isti autori su, godinu dana kasnije, sproveli drugo istraživanje čije rezultate su predstavili u studiji „Specifični bankarski, poslovni i institucionalni faktori nekvalitetnih kredita banaka: dokazi iz MENA zemalja“ (naslov originala: *Bank specific, business and institutional environment determinants of banks nonperforming loans: Evidence from MENA countries*) (Boudriga, Taktak, & Jellouli, 2010). U studiji se analiziraju faktori koji utiču na nekvalitetne kredite i potencijalni uticaj poslovnog i institucionalnog okruženja na izloženost kreditnom riziku banaka. Analiza je obuhvatila podatke iz 46 banaka u dvanaest zemalja (Bahrein, Egipat, Jordan, Kuvajt, Liban, Maroko, Oman, Katar, Saudijska Arabija, Tunis, Ujedinjeni Arapski emirati i Jemen) u periodu od 2002. do 2006. godine. Autori su faktore podijelili u tri grupe: specifične bankarske faktore, faktore poslovnog i faktore institucionalnog okruženja. Rezultati ovog istraživanja pokazuju da kreditni rast i prinos na aktivu imaju negativan, a koeficijent adekvatnosti kapitala i rezervisanja za kreditne gubitke pozitivan uticaj na nekvalitetne kredite. Takođe, rezultati pokazuju da kreditni kvalitet zavisi i od relevantnih informacija koje su objavljene, od institucionalnog okruženja, kontrole korupcije i regulatornih organa.

Espinoza i Prasad su sproveli istraživanje pod nazivom „Nekvalitetni krediti u bankarskom sektoru GCC i njihovi makroekonomski efekti“ (naslov originala: *Nonperforming Loans in the GCC Banking System and their Macroeconomic Effects)* u kome su analizirali faktore nekvalitetnih kredita na regionalnom nivou, u zemljama Savjeta za saradnju u Persijskom zalivu (Espinoza & Prasad, 2010). Studija je sprovedena nad podacima o nekvalitetnim kreditima 80 banaka, u periodu od 1995. do 2008. godine. Rezultati pokazuju da na nekvalitetne kredite utiču i makroekonomski i specifični bankarski faktori. Pri tom, autori su utvrdili da postoji jaka negativna veza između stope rasta realnog BDP-a (umanjenog za doprinos naftne industrije BDP-u) i nekvalitetnih kredita, i snažan, ali kratkotrajan negativni uticaj nekvalitetnih kredita na realnu ekonomiju. Takođe, prema ovim autorima, povezanost makroekonomskih faktora i stabilnosti bankarskog sistema bila je posebno izražena za vrijeme globalne finansijske krize.

Nkusu je sproveo istraživanje pod nazivom „Nekvalitetni krediti i makroekonomska ranjivost u razvijenim ekonomijama“ (naslov originala: *Nonperforming Loans and Macrofinancial Vulnerabilities in Advanced Economic*) sa ciljem da odredi vezu između makroekonomskih faktora i nekvalitetnih kredita (Nkusu, 2011). Korišteni su godišnji podaci iz perioda od 1998. do 2009. godine za 26 razvijenih zemalja, a analizirane promjenljive su: stopa rasta BDP-a, stopa nezaposlenosti, indeks cijena imovine, indeks cijena akcija, stopa inflacije, nominalni efektivni kurs, aktivna kamatna stopa i krediti privatnom sektoru. Rezultati istraživanja pokazuju da je pogoršanje makroekonomskih uslova (prikazano kroz usporavanje rasta ili pad stope BDP-a, povećanje stope nezaposlenosti i pad cijena imovine) povezano sa pogoršanjem kvaliteta kredita i problemima sa finansijskom stabilnošću.

Beck, Jakubik i Piloiu su sproveli istraživanje pod nazivom „Nenaplativi krediti: šta je bitno pored ekonomskog ciklusa?“ (naslov originala: *Non-performing Loans: What matters in Addition to the Economic Cycle?)* sa ciljem da utvrde koji makroekonomski faktori utiču na nekvalitetne kredite (Beck, Jakubik, & Piloiu, 2013). Analizom je obuhvaćeno 75 zemalja, a koriste se podaci od 2000. do 2010. godine. Autori su analizirali samo uticaj makroekonomskih promjenljivih, i to: stopa rasta realnog BDP-a, nominalni efektivni kurs, aktivna kamatna stopa, cijene akcija, međunarodna potraživanja i kapitalizacija berzanskog tržišta. Rezultati pokazuju da stopa rasta BDP-a, cijene akcija, nominalni efektivni kurs i aktivne kamatne stope značajno utiču na nivo nekvalitetnih kredita bankarskih sektora analiziranih zemalja. Autori navode da je pad globalne ekonomske aktivnosti najvažniji rizik za kvalitet aktive banaka, te da depresijacija deviznog kursa može dovesti do povećanja nekvalitetnih kredita u zemljama sa visokim stepenom kreditiranja u stranim valutama, a pad cijena akcija može negativno uticati na kvalitet aktive banaka, posebno u zemljama sa velikim berzama.

Messai i Jouini su sproveli istraživanje pod nazivom „Mikro i makro determinante nekvalitetnih kredita“ (naslov originala: *Micro and Macro Determinants of Non-performing Loans*) sa ciljem da odrede faktore koji utiču na nekvalitetne kredite u bankarskim sektorima Italije, Grčke i Španije (Messai & Jouini, 2013, str. 852 - 860). Analizom je obuhvaćeno 85 banaka, a prikupljeni su podaci od 2004. do 2008. godine. U ovoj studiji, nekvalitetni krediti se objašnjavaju pomoću tri makroekonomska (stopa rasta BDP-a, stopa nezaposlenosti i realna kamatna stopa) i tri specifična bankarska (prinos na aktivu, odnos rezervi za kreditne gubitke u ukupnim kreditima i kreditni rast) faktora. Rezultati istraživanja pokazuju da stopa rasta BDP-a i prinos na aktivu imaju statistički značajan i negativan uticaj, stopa nezaposlenosti, realna kamatna stopa i odnos rezervi za kreditne gubitke u ukupnim kreditima imaju statistički značajan i pozitivan uticaj na nekvalitetne kredite, dok uticaj kreditnog rasta nije statistički značajan.

Jakubik i Reininger su sproveli istraživanje pod nazivom „Determinante nekvalitetnih kredita u Centralnoj, Istočnoj i Jugoistočnoj Evropi“ (naslov originala: *Determinants of Nonperforming Loans in Central, Eastern and Southeastern Europe*) u kome su analizirali uticaj makroekonomskih faktora na nekvalitetne kredite (Jakubik & Reininger, 2013, str. 48 - 66). Obuhvaćeni su podaci iz devet zemalja u periodu od 2004. do 2012. godine. Analizirani su samo makroekonomski faktori, a rezultati pokazuju da je ekonomski rast glavni pokretač koji je u negativnoj vezi sa nekvalitetnim kreditima. Autori smatraju da postoje još dva važna faktora koji utiču na nekvalitetne kredite u ovim zemljama, a riječ je o kreditnom rastu i promjenama deviznog kursa u kombinaciji sa udjelom deviznih u ukupnim kreditima.

Klein je sproveo istraživanje pod nazivom „Nekvalitetni krediti u CESEE: determinante i makroekonomske performanse“ (naslov originala: *Non-Performing Loans in CESEE: Determinants and Impact on Macroeconomic Performance*) u kome je ispitao performanse nekvalitetnih kredita u Centralnoj, Istočnoj i Jugoistočnoj Evropi, u periodu od 1998. do 2011. godine (Klein, 2013). Korišteni su godišnji podaci za deset banaka u svakoj od 16 zemalja koje su analizirane, a jedna od tih zemalja je i BiH. U studiju su uključeni i makroekonomski i specifični bankarski faktori, a autor smatra da postoje i drugi faktori čiji uticaj je na relativno malom nivou. Rezultati istraživanja pokazuju da stopa inflacije ima statistički značajan i pozitivan, stopa rasta kredita i stopa rasta BDP-a statistički značajan i negativan uticaj na nekvalitetne kredite, dok uticaj stope nezaposlenosti nije statistički značajan.

Makri, Tsagkanos i Bellas su sproveli istraživanje pod nazivom „Determinante nekvalitetnih kredita: slučaj Evrozone“ (naslov originala: *Determinants of Non-Performing Loans: The Case of Eurozone*) sa ciljem da identifikuju faktore koji utiču na stopu nekvalitetnih kredita bankarskih sistema Evrozone u periodu od 2000. do 2008. godine (Makri, Tsagkanos, & Bellas, 2014, str. 193 - 206). U istraživanju su korišteni agregatni podaci za bankarske sektore četrnaest zemalja, a analizirani su makroekonomski faktori (stopa rasta BDP-a, javni dug kao % BDP-a, stopa inflacije, stopa nezaposlenosti i budžetski deficit ili suficit kao % BDP-a) i specifični bankarski faktori (koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu i prinos na akcijski kapital). Rezultati pokazuju da stopa rasta BDP-a, koeficijent adekvatnosti kapitala i prinos na akcijski kapital imaju statistički značajan i negativan, a stopa nezaposlenosti i javni dug kao % BDP-a imaju statistički značajan i pozitivan uticaj na nekvalitetne kredite, dok promjenljive odnos kredita i depozita, prinos na aktivu, budžetski deficit ili suficit kao % BDP-a i stopa inflacije nemaju statistički značajan uticaj na nekvalitetne kredite bankarskih sistema Evrozone.

Škarica je sprovela istraživanje pod nazivom „Determinante nekvalitetnih kredita u zemljama Srednje i Istočne Evrope“ (naslov originala: *Determinants of non-performing loans in Central and Eastern European countries*) u kome su analizirani faktori koji utiču na nekvalitetne kredite u sedam zemalja Srednje i Istočne Evrope (Škarica, 2014, str. 37 - 59). Korišteni su kvartalni agregatni podaci na nivou pojedinačnih zemalja, a obuhvataju period od trećeg kvartala 2007. do trećeg kvartala 2012. godine. Analizom su obuhvaćeni makroekonomski i finansijski pokazatelji: stopa rasta realnog BDP-a, stopa nezaposlenosti, nominalni efektivni devizni kurs, stopa rasta potrošačkih cijena, indeksi tržišta kapitala, tromjesečna kamatna stopa na novčanom tržištu i iznos ukupno odobrenih kredita. Rezultati istraživanja pokazuju da je glavni pokretač rasta nekvalitetnih kredita u zemljama Srednje i Istočne Evrope, tokom analiziranog petogodišnjeg perioda, usporavanje rasta ili pad BDP-a. Takođe, rezultati su pokazali da stopa nezaposlenosti, stopa inflacije i kamatna stopa na novčanom tržištu imaju statistički značajan i negativan uticaj na nekvalitetne kredite, dok uticaj indeksa tržišta kapitala, nominalnog efektivnog deviznog kursa i nivoa zaduženosti nije statistički značajan.

Na osnovu navedenih studija koje su sprovedene u različitim zemljama, može se zaključiti da su rezultati istraživanja veoma slični onim koji su dobijeni u sličnim studijama koje su sprovedene u pojedinačnim zemljama. Rezultati pokazuju da na nekvalitetne kredite utiču, u manjoj ili većoj mjeri, makroekonomski i specifični bankarski faktori.

Hronološki pregled istraživanja koja su sprovedena u bankarskim sektorima više zemalja je u tabeli 6, koja je, zbog preglednosti, podijeljena na dva dijela. Prvi dio obuhvata studije koje su sprovedene u periodu od 2009. do 2012. godine (tabela 6a), a drugi studije koje su sprovedene u periodu od 2013. do 2014. godine (tabela 6b).

Tabela 6a: Pregled studija sprovedenih u više zemalja (2009-2012)

Autor	Naziv studije	Godina	Zemlje	Period	Faktori	
					M.F.	S.B.F.
Boudriga, Taktak i Jellouli	*Banking supervision and nonperforming loans: a cross-country analysis*	2009	Australija, Belgija, Bolivija, Bugarska, Kanada, Kolumbija, Kosta Rika, Hrvatska, Češka, Danska, Egipat, Estonija, Finska, Francuska, Njemačka, Gana, Grčka, Madarska, Island, Indija, Indonezija, Izrael, Italija, Japan, Jordan, Kazahstan, Kenija, Korea, Kuvajt, Letonija, Litvanija, Malezija, Meksiko, Maroko, Nigerija, Norveška, Oman, Pakistan, Panama, Paragvaj, Peru, Filipini, Poljska, Portugalija, Rusija, Salvador, Saudijska Arabija, Slovačka, Južna Afrika, Španija, Švedska, Švajcarska, Tajland, Tunis, Turska, SAD, Ugandi, Velika Britanija i Venecuela	2002-2006	-	+
Boudriga, Taktak i Jellouli	*Bank specific, business and institutional environment determinants of banks nonperforming loans: Evidence from MENA countries*	2010	Bahrein, Egipat, Jordan, Kuvajt, Liban, Maroko, Oman, Katar, Saudijska Arabija, Tunis, Ujedinjeni Arapski emirati i Jemen	2002-2006	-	+
Espinoza i Prasad	*Nonperforming Loans in the GCC Banking System and their Macroeconomic Effects*	2010	Bahrein, Kuvajt, Oman, Katar, Saudijska Arabija i Ujedinjeni Arapski emirati	1995-2008	+	+
Nkusu	*Nonperforming Loans and Macrofinancial Vulnerabilities in Advanced Economic*	2011	Australija, Austrija, Belgija, Kanada, Češka, Danska, Finska, Francuska, Njemačka, Grčka, Island, Izrael, Španija, Japan, Korea, Luksemburg, Holandija, Novi Zeland, Norveška, Portugal, Singapur, Španija, Švedska, Francuska, Velika Britanija i Sjedinjene Američke Države	1998-2009	+	-

Izvor: Izrada autora

Tabela 6b: Pregled studija sprovedenih u više zemalja (2013-2014)

Autor	Naziv studije	Godina	Zemlje	Period	Faktori	
					M.F.	S.B.F.
Beck, Jakubik i Piloiu	*Non-performing Loans: What matters in Addition to the Economic Cycle?*	2013	Argentina, Armenija, Australija, Austrija, Belgija, Bolivija, Brazil, Bugarska, Kanada, Čile, Kina, Kolumbija, Kosta, Hrvatska, Češka, Danska, Dominikanska Republika, Ekvador, Egipat, Estonija, Finska, Francuska, Gabon, Gruzija, Njemačka, Gana, Grčka, Hong Kong, Mađarska, Indija, Indonezija, Irska, Izrael, Italija, Japan, Korea, Kuvajt, Letonija, Liban, Litvanija, Luksemburg, Makedonija, Malezija, Meksiko, Moldavija, Maroko, Holandija, Norveška, Oman, Pakistan, Paragvaj, Peru, Filipini, Poljska, Portugal, Rumunija, Rusija, Saudijska Arabija, Singapur, Republika Slovačka, Slovenija, Južna Afrika, Španija, Švedska, Švajcarska, Tajland, Tunis, Turska, Uganda, Ukrajina, Ujedinjeni Arapski emirati, Velika Britanija, SAD, Urugvaj i Venecuela	2000-2010	+	-
Bussai i Jouini	*Micro and Macro Determinants of Non-performing Loans*	2013	Italija, Grčka i Španija	2004-2008	+	+
Jakubik i Reininger	*Determinants of Nonperforming Loans in Central, Eastern and Southeastern Europe*	2013	Bugarska, Hrvatska, Češka, Mađarska, Poljska, Rumunija, Rusija, Slovačka Ukrajina	2004-2012	+	-
Klein	*Non-Performing Loans in CESEE: Determinants and Impact on Macroeconomic Performance*	2013	Bosna i Hercegovina, Bugarska, Mađarska, Hrvatska, Češka, Estonija, Letonija, Litvanija, Makedonija, Poljska, Rumunija, Rusija, Srbija, Slovačka Republika, Slovenija i Ukrajina	1998-2011	+	+
Makri, Tsagkanos i Bellas	*Determinants of Non-Performing Loans: The Case of Eurozone*	2014	Grčka, Italija, Portugal, Španija, Francuska, Irska, Njemačka, Belgija, Finska, Austrija, Holandija, Luksemburg, Estonija i Malta	2000-2008	+	+
Škarica	*Determinants of non-performing loans in Central and Eastern European countries*	2014	Bugarska, Češka, Hrvatska, Letonija, Mađarska, Rumunija i Slovačka	2007-2012	+	-

Izvor: Izrada autora

2.4. Studije sprovedene u Bosni i Hercegovini

Posljednjih godina, nekvalitetni krediti predstavljaju problem i u bankarskom sektoru BiH. Međutim, sprovedeno je vrlo malo istraživanja koja se bave analizom nekvalitetnih kredita i faktorima koji na njih utiču. Sve dok se ovom problemu ne pristupi ozbiljnije, neće se moći preduzeti adekvatne mjere pomoću kojih bi se problem riješio, a njegove posljedice smanjile.

Ganić je sproveo istraživanje pod nazivom „Specifične bankarske determinante kreditnog rizika – empirijska studija u bankarskom sektoru Bosne i Hercegovine" (naslov originala: *Bank Specific Determinants of Credit Risk: An Empirical Study on the Banking Sector of Bosnia and Herzegovina*), sa ciljem da ispita uticaj specifičnih bankarskih faktora na kreditni rizik u kreditnom portfoliu komercijalnih banaka u BiH (Ganić, 2014, str. 428 - 436). Studijom je obuhvaćeno sedamnaest (od ukupno 28) komercijalnih banaka, odnosno 60,7% ukupnog uzorka ili 76,26% bankarske aktive u periodu od 2002. do 2012. godine. Sa ciljem identifikacije faktora koji utiču na kreditni rizik, u istraživanju je korišteno devet promjenljivih: neefikasnost, solventnost, odnos kredita i depozita, tržišna moć, prinos na aktivu, prinos na akcijski kapital, kreditni rast, stopa depozita i odnos rezervi za kreditne gubitke. Rezultati istraživanja pokazuju da postoji statistički značajan odnos između kreditnog rizika i neefikasnosti, prinosa na kapital, kreditnog rasta i stope depozita, a odnos kredita i depozita, tržišna moć, prinos na aktivu i stopa rezervi za kreditne gubitke nisu statistički značajni u smislu kreditnog rizika. Pored toga, rezultati su pokazali da pet promjenljivih ima negativan odnos sa kreditnim rizikom (tržišna moć, prinos na aktivu, kreditni rast, odnos rezervi za kreditne gubitke i neefikasnost), a pozitivan odnos sa kreditnim rizikom imaju četiri promjenljive (solventnost, odnos kredita i depozita, prinos na akcijski kapital i stopa depozita).

Alihodžić je sproveo istraživanje pod nazivom „Analiza kretanja nekvalitetnih kredita i profitabilnosti na bankovnom tržištu u BiH" (Alihodžić, 2014, str. 341 - 359). On je analizirao kretanje nivoa nekvalitetnih kredita u bankarskom sektoru BiH u periodu od 2006. do prvog kvartala 2013. godine i uticaj nekvalitetnih kredita na profitabilnost banaka u ovom sektoru. Profitabilnost banaka je mjerena pomoću dva pokazatelja: prinosa na imovinu i prinosa na kapital. Rezultati pokazuju da je kvalitet aktive banaka opadao, odnosno da je nivo nekvalitetne aktive u ukupnoj aktivi bankarskog sektora rastao od 2006. do početka 2013. godine, što je posljedica povećanja nekvalitetnih kredita u kreditnom portfoliu. Također, rezultati pokazuju da između nekvalitetne aktive i prinosa na imovinu postoji statistički značajan i negativan odnos (povećanje nekvalitetnih kredita utiče na smanjenje prinosa na imovinu), a istovremeno, statistički značajan i negativan odnos postoji i između nekvalitetne aktive i prinosa na kapital (povećanje nekvalitetnih kredita utiče na smanjenje prinosa na kapital).

Na žalost, trenutno su dostupne samo dvije studije o nekvalitetnim kreditima u bankarskom sektoru BiH. S obzirom na značaj koji nekvalitetni krediti imaju u bankarskom sektoru, pa i u cjelokupnoj ekonomiji, ovoj temi bi trebalo posvetiti više pažnje u budućnosti.

3. KONCEPTUALNI OKVIR

Glavni cilj istraživanja je identifikacija faktora koji utiču na nekvalitetne kredite u bankarskom sektoru BiH. Na osnovu cilja istraživanja može se sačiniti konceptualni okvir koji predstavlja model istraživanja i prikazuje odnos između zavisne i nezavisnih promjenljivih. Nezavisnom promjenljivom istraživač manipuliše ili je mjeri da bi odredio efekat te promjenljive na zavisnu promjenljivu, koju istraživač posmatra i mjeri da bi odredio prirodu njenog odnosa sa nezavisnim promjenljivim. Ulogu zavisne promjenljive imaju one pojave koje se žele upoznati, razumjeti i objasniti, dok ulogu nezavisne promjenljive imaju pojave pomoću kojih se žele razumjeti promjene u zavisnoj promjenljivoj.

Kao što je već rečeno u pregledu literature koja se bavi problematikom nekvalitetnih kredita, na njih utiču i makroekonomski (stopa realnog rasta BDP-a, stopa inflacije, javni dug, devizni kurs, novčana masa, kamatne stope, kreditni rast) i specifični bankarski faktori (profitabilnost, koeficijent adekvatnosti kapitala, likvidnost, veličina banke, loša kreditna procjena, loše praćenje kredita, nerazvijena kreditna kultura, blagi kreditni uslovi, nelojalna konkurencija između banaka i slično). Ovih faktora je mnogo, ali zbog ograničenja u dostupnosti podataka, nije ih moguće sve uključiti u istraživanje.

Moody's je objavio metodologiju za određivanje kreditnog rejtinga banaka (*Rating Methodology Banks*) u kojoj je dao detaljan opis kvalitativnih i kvantitativnih faktora koji utiču na bankarski sektor. Analiza koja je sprovedena sa ciljem identifikacije tih faktora obuhvata dva pristupa – makro pristup u kome su identifikovani makroekonomski faktori i finansijski pristup u kome su identifikovani finansijski i kvalitativni faktori. Makro pristup obuhvata operativno i ekonomsko okruženje banke, dok finansijski pristup obuhvata finansijsko stanje banke, ključne pokazatelje solventnosti i likvidnosti, zajedno sa dodatnim finansijskim pokazateljima i ocjenama. Kvantitativni faktori su dopuna finansijskom profilu i odražavaju nefinansijske kvalitativne ocjene.

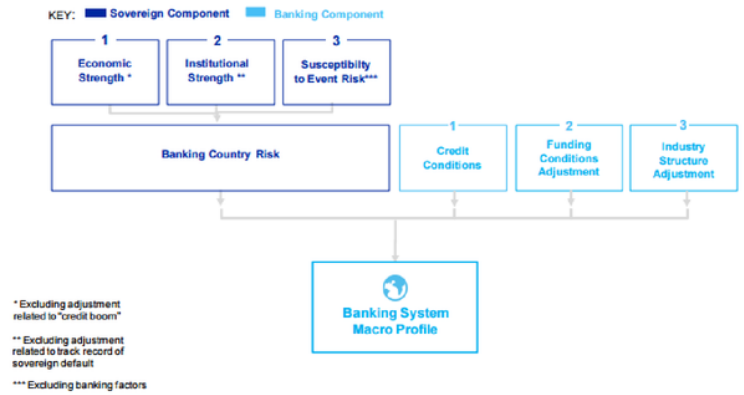
Tokom analize, *Moody's* je koristio javno dostupne podatke i jednostavne metrike kako bi se osigurao globalno uporediv analitički okvir. Ovo jasno odražava *Moody's* - ov stav da su „jednostavni pokazatelji često efikasniji od složenih“ i ukazuje na „neophodnost identifikovanja univerzalno dostupnih koeficijenata“ (Moody's Investors Service, 2016, str. 6)

Prva faza analize koju je sproveo *Moody's* odnosi se na procjenu makro okruženja u kome posluju banke, jer su „neuspjesi banaka veoma često povezani sa sistemskim krizama koje pokreću makroekonomski faktori“ (Moody's Investors Service, 2016, str. 19). Makro faktori koji utiču na bankarski sektor grupisani su u šest kategorija, i to:

- ekonomska snaga,
- institucionalna snaga,
- spoljna ranjivost,
- kreditni uslovi,
- uslovi finansiranja,
- struktura industrije (Moody's Investors Service, 2016, str. 19).

Makro pristup koji je korišten u analizi dat je na slici 1.

Slika 1: Makro pristup (Moody's)



Izvor: (Moody's Investors Service, 2016, str. 19)

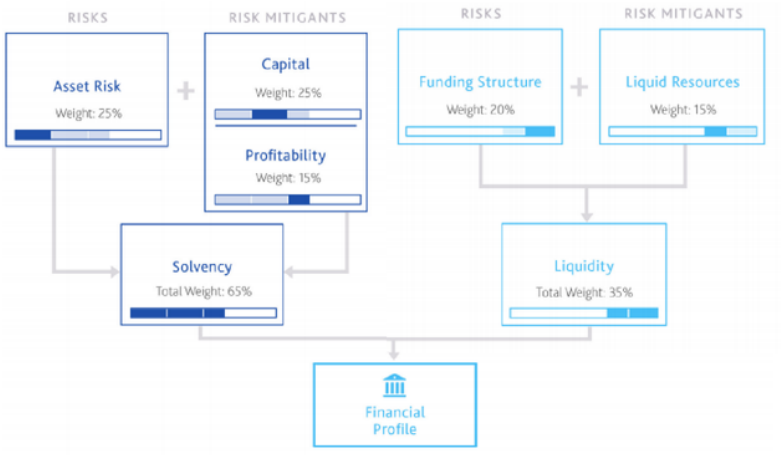
Na slici se vidi da prve tri kategorije (ekonomska snaga, institucionalna snaga i spoljnja ranjivost) sadrže samo suverene komponente, dok preostale tri kategorije (kreditni uslovi, uslovi finansiranja i struktura industrije) sadrže komponente koje odražavaju zajedništvo između bankarskog sektora i suverenih kreditnih sposobnosti. *Moody's* smatra da je ekonomska snaga veoma važna jer su banke visoko izložene, a njihov rad usko povezan sa makroekonomskim faktorima. Ekonomska snaga mjeri se pomoću tri faktora, odnosno preko dinamike rasta, privrednog stanja i nacionalnog dohotka. Institucionalna snaga jedne zemlje je važna jer banke, po svojoj prirodi, zavise od dobrog zakonskog okvira, a svaka nemogućnost izvršenja ugovora ili neka druga institucionalna slabost direktno utiče na bankarski sistem i čini ga nestabilnijim. Institucionalne snage mjere se pomoću dva faktora i to: institucionalni okvir i efektivnost, i politika kredibiliteta i efikasnost. Takođe, i spoljna ranjivost jedne zemlje ima značajan uticaj na ranjivost njenog bankarskog sistema (npr. politički rizik se vrlo brzo može proširiti na bankarski sektor), a ona se mjeri pomoću političkog rizika, rizika likvidnosti vladinih institucija i spoljnih rizika. *Moody's* navodi da „visok nivo duga ili brza kreditna ekspanzija mogu ukazati na probleme u kreditnom kvalitetu koji se mogu kasnije javiti, tako da su kreditni uslovi veoma važni za procjenu snage bankarskog sektora u cjelini“ (Moody's Investors Service, 2016, str. 23). Kreditni uslovi se mjere pomoću dva ključna pokazatelja, a oni su: nivo kredita privatnom sektoru u odnosu na bruto domaći proizvod i rast kredita privatnom sektoru u odnosu na bruto domaći proizvod. Problemi finansiranja se ne razvijaju samo na nivou pojedinačnih banaka, nego i na nivou o se razvijaju na nivou bankarskog sektora, a ne samo na nivou pojedinačne banke, tako da pokazatelji finansiranja jedne zemlje mogu ukazati na problem čak i prije nego što se on vidi na osnovu specifičnih bankarskih pokazatelja. Pokazatelji se odnose na količinu ili troškove finansiranja banaka, variraju od zemlje do zemlje, ali obično sadrže mjere finansiranja na tržištu i bilanse centralnih banaka. Posljednja komponenta makro pristupa je struktura industrije koja se prvenstveno odnosi na hiperkapacitet, finansijske inovacije i pitanje liberalizacije. Navedeni faktori značajno utiču na bankarski sektor, a mjere se pomoću nivoa koncentracije unutar bankarskog sektora, ulogom nekomercijalnih institucija, indikatorima za identifikaciju inovacija i promjenama bankarske regulative.

Druga faza analize koju je sproveo *Moody's* fokusira se na finansijske osnove banke, odnosno na procjenu izloženosti banke šokovima i njenu mogućnost da ih apsorbuje. Procjena izloženosti fokusira se na dvostrukim osnovama solventnosti i likvidnosti, odnosno:

- solventnost – kombinacija bankarskih rizika i kapaciteta da se rizici apsorbuju, odnosno da se gubici pokriju kapitalom i zaradom,
- likvidnost – kombinacija neusklađenosti aktive banke i njenih obaveza, odnosno odražava pouzdanost finansiranja, kao i mogućnost da odlivi gotovine budu iz tekućih rezervi.

Navedeni faktori su međusobno povezani, a pored njih, analizirani su i srodni faktori koji utiču na bankarski sektor. Struktura solventnosti i likvidnosti, prema *Moody's*-u, data je na slici 2.

Slika 2: Struktura solventnosti i likvidnosti (Moody's)

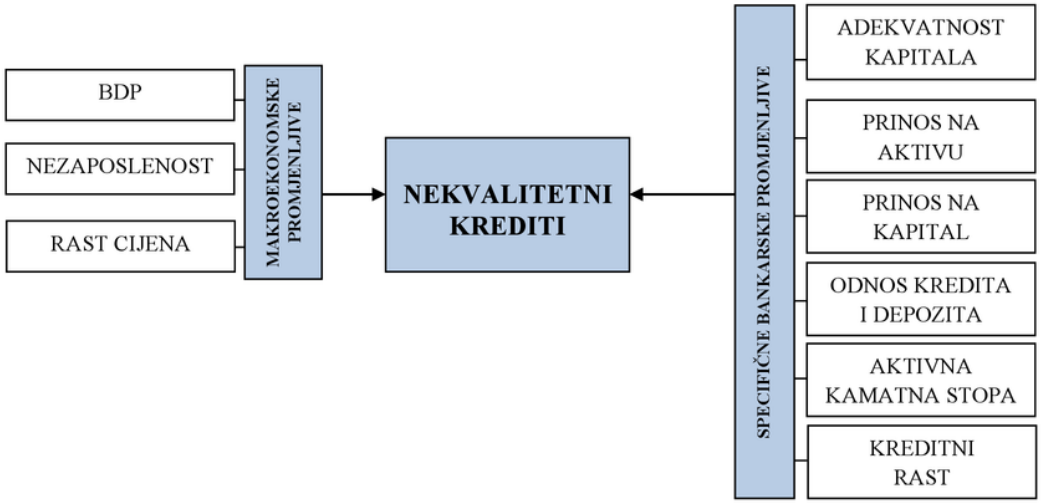


Izvor: (Moody's Investors Service, 2016, str. 32 i 44)

Moody's solventnost mjeri kao kombinaciju bruto rizika (ukupan rizik aktive) i umanjenog rizika (kapital i zarada). Veći naglasak stavljen je na rizičnu aktivu (25%) i kapital (25%) jer se smatra da su oni najveći uzročnici problema solventnosti, a manji naglasak je stavljen na profitabilnost (15%). Procjena likvidnosti je proizvod strukture finansiranja banke (na osnovu koje se procjenjuje vjerovatnoća gubitka sredstava) i likvidnih sredstava. Ukupna likvidnost potiče od strukture finansiranja (25%) i likvidnih sredstava (15%). Konačno, faktori solventnosti čine 65% finansijskog pristupa, dok faktori likvidnosti čine preostalih 35%. Ovo jasno odražava stav da su faktori solventnosti obično uzrok bankarskih neuspjeha, a da su rizici likvidnosti djelimično ublaženi akcijama centralnih banaka u normalnim uslovima poslovanja. Pored navedenih, postoje i drugi faktori koji utiču na bankarski sektor, a koji se ne mogu kvantitativno izmjeriti. Riječ je o kvalitativnim faktorima, a *Moody's* navodi tri: poslovna diverzifikacija, neprozirnost i kompleksnost i korporativno ponašanje.

Moody's-ovim model poslužio je kao osnova za stvaranje konceptualnog okvira za ovo istraživanje. Konceptualni okvir ove studije predstavlja šematski prikaz odnosa između zavisne promjenljive (udio nekvalitetnih u ukupnim kreditima) i nezavisnih promjenljivih. Nezavisne promjenljive su podijeljene, kao i u većini sličnih istraživanja, u dvije grupe: makroekonomske promjenljive (stopa realnog rasta BDP-a, stopa nezaposlenosti i stopa rasta potrošačkih cijena) i specifične bankarske promjenljive (koeficijent adekvatnosti kapitala, prinos na aktivu, prinos na akcijski kapital, odnos kredita i depozita, aktivna kamatna stopa i stopa kreditnog rasta). Odnos između navedenih promjenljivih prikazan je na slici 3.

Slika 3: Konceptualni okvir istraživanja



Izvor: *Izrada autora*

II DIO

IDENTIFIKACIJA FAKTORA KOJI UTIČU NA NEKVALITETNE KREDITE

1. MAKROEKONOMSKI FAKTORI

Trend rasta nekvalitetnih kredita jedan je od ključnih problema sa kojim se suočavaju mnoge ekonomije, uključujući i razvijene ekonomije u svijetu. Da bi se problem nekvalitetnih kredita adekvatno sagledao i da bi se mogle preduzeti konkretne mjere za njegovo rješavanje, neophodno je odrediti faktore koji utiču na njhov rast. Ova problematika privukla je pažnju velikog broja ekonomista koji su pokušali da identifikuju i objasne faktore koji utiču na nekvalitetne kredite. Pregledom literature, kako stranih, tako i domaćih autora, može se zaključiti da se faktori obično dijele na dvije grupe: makroekonomske faktore i specifične bankarske faktore. Neki autori analiziraju samo uticaj koji makroekonomski faktori imaju na nekvalitetne kredite, drugi analiziraju uticaj specifičnih bankarskih faktora, a ima i onih koji su u svoja istraživanja uključili obe grupe faktora. Međutim, rezultati njihovih istraživanja nisu isti, razlikuju se od zemlje do zemlje, tako da nije moguće izvući generalne zaključke o uticaju određenog faktora na nekvalitetne kredite.

Makroekonomski faktori su oni koji su fokusirani na spoljne događaje, odnosno ukupne makroekonomske uslove, koji utiču na sposobnost korisnika kredita da otplati svoj dug. Makroekonomska dešavanja utiču na svakodnevni život ljudi, tako da je izuzetno važno i neophodno dobro razumijevanje makroekonomije, kako za nosioce političke vlasti, tako i za građane. Poznati američki ekonomisti Samuelson i Nordhaus navode da je makroekonomija „proučavanje cjelokupne ekonomije: ona analizira dugoročni rast kao i ciklična kretanja ukupne proizvodnje, nezaposlenosti i inflaciju, ponudu novca i deficit budžeta, i međunarodnu razmjenu i finansije“ (Samuelson & Nordhaus, 2000, str. 399). Makroekonomija pokušava objasniti zašto ukupna proizvodnja (realni bruto domaći proizvod, BDP) raste tokom vremena i zašto njegova vrijednost pokazuje oscilacije, šta uzrokuje nezaposlenost i inflaciju, kako se ponašaju kamate, šta uzrokuje budžetski suficit ili deficit i slično.

U studijama koje su fokusirane na odnos makroekonomskih faktora i nekvalitetnih kredita analizira se više različitih faktora, ali se u većini studija pojavljuju: stopa rasta realnog bruto domaćeg proizvoda, stopa nezaposlenosti, stopa inflacije, aktivna kamatna stopa, cijene akcija, javni dug i budžetski suficit ili deficit. U okviru ovog istraživanja analiziraće se uticaj tri makroekonomska faktora, i to: stopa rasta realnog bruto domaćeg proizvoda, stopa nezaposlenosti i stopa inflacije, mjerena stopom rasta potrošačkih cijena. Istraživanje bi bilo kvalitetnije kada bi se više faktora uključilo, ali zbog ograničenja u dostupnosti podataka, to nije moguće. Potrebno je naglasi da će u istraživanje biti uključena i aktivna kamatna stopa, ali se ovaj faktor u BiH ubraja u grupu specifičnih bankarskih faktora jer je Centralna banka Bosne i Hercegovine, zbog sistema valutnog odbora, ograničena u pogledu realizacije ciljeva monetarne politike. Prema Zakonu o Centralnoj banci Bosne i Hercegovine, ova institucija ne može plasirati kredite, ne određuje diskontnu stopu, niti utiče na nivo kamatnih stopa, tako da se kamatne stope formiraju slobodno u komercijalnim bankama (Zakon o Centralnoj banci Bosne i Hercegovine, 1997).

Keeton i Morris su, među prvima, analizirali faktore koji utiču na nekvalitetne kredite i zaključili su da domaći ekonomski uslovi, zajedno sa lošim rezultatima pojedinih privrednih sektora, objašnjavaju kreditne gubitke banaka (Keeton & Morris, 1987, str. 3 - 21).

Postoji još mnogo studija koje se bave odnosom makroekonomskog okruženja i kvaliteta kredita, odnosno studija u kojima se povezuju faze poslovnog ciklusa sa bankarskom stabilnošću. Neke od tih studija sproveli su: Sinkey i Greenawalt (1991), Gambera (2000), Salas i Saurina (2002), Ranjan i Dhal (2003), Jimenez i Saurina (2006), Khemraj i Pasha (2009), Louzis, Vouldis i Metaxas (2010), Espinoza i Prasad (2010), Collins i Wanjan (2011), Nkusu (2011), Adebola, Wan Yusoff i Dahalan (2011), Saba, Kouser i Azeem (2012), Swami (2012), Tomak (2013), Ahmad i Bashir (2013), Badar i Javid (2013), Beck, Jakubik i Piloiu (2013), Shingjergji (2013), Otašević (2013), Messai i Jouini (2013), Jakubik i Reininger (2013), Klein (2013), Jameel (2014), Turan i Koskija (2014), Makri, Tsagkanos i Bellas (2014), Škarica (2014) i Pradhan i Pandey (2016). Kratak pregled navedenih studija dat je u prethodnom poglavlju.

1.1. Stopa rasta realnog bruto domaćeg proizvoda

U ekonomskoj nauci se razvio čitav niz globalnih i sintetičkih pokazatelja, tzv. makroekonomskih agregata, pomoću kojih se izražava osnovni sadržaj, dinamika, struktura i rezultat ekonomske aktivnosti u određenoj zajednici. Ipak, najčešće korišteni makroekonomski agregat je bruto domaći proizvod (BDP). Slobodno se može reći da je on sveobuhvatni pokazatelj rezultata društvene proizvodnje određene nacionalne zajednice, odnosno, krajnji rezultat proizvodne aktivnosti jednog društva. Veličković i Barać navode da bruto domaći proizvod „predstavlja ukupnu produkciju roba i usluga, ostvarenu u nacionalnoj ekonomiji (domicilnoj zemlji), bez obzira na vlasništvo“ (Veličković & Barać, 2009, str. 108). Ekonomisti vrlo često, prilikom procjene privrednog stanja, koriste stopu rasta realnog BDP-a, a ona je veoma pogodna i za upoređivanje stanja u više zemalja. Stopa rasta BDP-a može se definisati kao „relativni prirast domaćeg proizvoda, tj. kao odnos godišnjeg apsolutnog prirasta domaćeg proizvoda i njegove veličine na kraju prethodnog perioda“ (Madžar & Jovanović, 1990, str. 24).

Stopa rasta realnog BDP-a je obično uključena u studije u kojima se analizira uticaj makroekonomskih faktora na nekvalitetne kredite. Pregledom literature se vidi da je ona uključena u većinu studija koje se bave ovom problematikom, ali stopa rasta realnog BDP-a ne smije biti jedini faktor koji se analizira, jer analizom samo jednog faktora ne može se odrediti zašto dolazi do pojave i rasta nekvalitetnih kredita u bankarskom sektoru.

Odnos stope rasta BDP-a i nekvalitetnih kredita može biti statistički značajan ili beznačajan, pozitivan ili negativan. Rezultati studija koju su do sada sprovedene uglavnom ukazuju na statistički značajan i negativan odnos između stope rasta BDP-a i nekvalitetnih kredita. Ipak, Swami (2012), Tomak (2013) i Pradhan i Pandey (2016) su, analizirajući ovaj odnos, došli do zaključka da uticaj stope rasta BDP-a na nekvalitetne kredite nije statistički značajan u bankarskim sektorima Indije, Turske i Nepala, respektivno.

Rezultati većine istraživanja pokazuju da stopa rasta BDP-a ima statistički značajan i negativan uticaj na nekvalitetne kredite, a do ovakvog rezultata došli su: Salas i Saurina (2002), Ranjan i Dhal (2003), Jimenez i Saurina (2006), Khemraj i Pasha (2009), Louzis, Vouldis i Metaxas (2010), Espinoza i Prasad (2010), Nkusu (2011), Saba, Kouser i Azeem (2012), Ahmad i Bashir (2013), Badar i Javid (2013), Beck, Jakubik i Piloiu (2013), Otašević (2013), Messai i Jouini (2013), Jakubik i Reininger (2013), Klein (2013), Jameel (2014), Turan i Koskija (2014), Makri, Tsagkanos i Bellas (2014) i Škarica (2014).

Ako se pogleda obrazloženje negativnog odnosa koje je dato u literaturi, vidi se da rast BDP-a obično povećava dohodak, koji dalje povećava dužnikovu sposobnost otplate kredita, što vodi ka smanjenju nekvalitetnih kredita (Khemaj & Pasha, 2009). Sa druge strane, kada postoji usporavanje u privredi, dolazi do povećanja nezaposlenosti i dužnici se suočavaju sa teškoćama u otplati kredita, što rezultuje povećanjem nekvalitetnih kredita (Salas & Saurina, 2002).

1.2. Stopa nezaposlenosti

Drugi, veoma važan makroekonomski agregat pomoću koga se prati privreda neke zemlje, jeste stopa nezaposlenosti. Slobodno se može reći da je nezaposlenost jedan od vodećih ekonomskih problema današnjice u većini zemalja, bez obzira na njihovu razvijenost. Veselinović navodi da je nezaposlenost „stanje u kojemu se dio radno sposobnih članova društva ne može zaposliti primjereno svojim sposobnostima i klasifikacijama, uz uobičajenu platu" (Veselinović, 2010, str. 224). Danas, nezaposlenost nije problem samo pojedinca koji je njom pogođen, nego cjelokupnog ekonomskog sistema zemlje.

Nezaposlenost se prikazuje pomoću stope nezaposlenosti koja predstavlja odnos broja nezaposlenih prema veličini radne snage. Pri tom se, pod radnom snagom podrazumijevaju lica koja imaju preko 16 godina, odnosno oni koji u stvari rade, plus oni koji ne rade ali aktivno tragaju za zaposlenjem (Jednak, 1999, str. 270 - 274). Stopa nezaposlenosti je mjera koja se veoma često koristi zbog svoje jednostavnosti, a ona oslikava stanje privrede i uspješnosti privredne politike u zemlji.

Pregledom literature može se vidjeti da se stopa nezaposlenosti veoma često uključuje u studije u kojima se analiziraju faktori koji utiču na nekvalitetne kredite. Rezultati studija pokazuju da stopa nezaposlenosti može, ali ne mora, imati statistički značajan uticaj na nekvalitetne kredite, a njihov međusobni odnos može biti pozitivan ili negativan. Za razliku od rezultata većine studija u kojima stopa nezaposlenosti ima statistički značajan uticaj, Ahmad i Bashir (2013) su pokazali da uticaj stope nezaposlenosti na nekvalitetne kredite nije statistički značajan u komercijalnim bankama u Pakistanu.

Rezultati istraživanja uglavnom ukazuju na pozitivan odnos između stope nezaposlenosti i nekvalitetnih kredita. Takav odnos je sasvim logičan jer povećanjem nezaposlenosti, određeni broj lica ostaje bez ličnih primanja, pa samim tim i bez novčanih sredstava za otplatu kredita. Do ovakvih rezultata došli su Gambera (2000), Louzis, Vouldis i Metaxas (2010), Nkusu (2011), Messai i Jouini (2013), Klein (2013), Turan i Koskija (2014), Makri, Tsagkanos i Bellas (2014) i Škarica (2014).

Teorijsko objašnjenje pozitivnog odnosa između stope nezaposlenosti i nekvalitetnih kredita ukazuje na činjenicu da povećanje nezaposlenosti u zemlji negativno utiče na prihode pojedinaca, odnosno osoba koja je ostala bez posla gubi izvor prihoda i istovremeno gubi mogućnost da vrati kredit. Što se tiče preduzeća, situacija je slična. Povećana nezaposlenost u privredi negativno utiče na tražnju za proizvodima preduzeća što u krajnjoj liniji utiče na proizvodnju i prodaju preduzeća, a to na kraju dovodi do smanjenja prihoda i pogoršanja uslova za servisiranje duga (Louzis, Vouldis, & Metaxas, 2010).

1.3. Stopa inflacije

Pokazatelji privrednog razvoja, zaposlenosti i stabilnosti cijena su ključni pokazatelji kvaliteta makroekonomskih performansi. Slobodno se može reći da su stabilnost cijena, puna zaposlenost i stabilan privredni rast centralni makroekonomski ciljevi. Govoriti o cijenama, a pri tome ne spomenuti inflaciju, potpuno je nemoguće.

Problem inflacije je široko obrađen u ekonomskoj literaturi, njom se bavio veliki broj ekonomista i čini se da je svaki od njih definisao na svoj način. Zbog toga još uvijek ne postoji njena univerzalna definicija, a Veselinović ističe da se sve definicije „u krajnjoj liniji mogu svesti na stav da inflacija predstavlja kontinuirani rast opšteg nivoa apsolutnih cijena ili kontinuirani pad vrijednosti novca" (Veselinović, 2010, str. 236 - 237). Dalje, on naglašava da je prilikom definisanja inflacije veoma bitno naglasiti da se inflacija „odnosi na rast opšteg nivoa cijena", i da ona „postoji kada je rast cijena nepovratan" (Veselinović, 2010, str. 237).

Inflacija razara privredni mehanizam i spada u grupu veoma štetnih pojava. Da bi se sanirale posljedice inflacije, neophodno je prvo izvršiti njenu klasifikaciju, odnosno odrediti da li je riječ o umjerenoj inflaciji, galopirajućoj inflaciji ili hiperinflaciji. Dok umjerena inflacija podrazumijeva lagani rast cijena (jednocifrene godišnje stope), galopirajuća predstavlja dvocifrenu ili trocifrenu inflaciju. Hiperinflacija vodi ka finansijskom kolapsu i potpunom haosu u privredi, a cijene dostižu astronomske cifre. Mnoge privrede uspiju da prežive galopirajuću, ali hiperinflaciju veoma teško.

Najjednostavnije rečeno, inflacija je ekonomska situacija u kojoj nivo ukupnih cijena raste, te se ona može izraziti i pomoću stope rasta potrošačkih cijena. Ovako izraženom inflacijom, odnosno njenim uticajem na nekvalitetne kredite, bavili su se mnogi ekonomisti. Swami (2012) i Makri, Tsagkanos i Bellas (2014) su pokazali da inflacija nema statistički značajan uticaj na nekvalitetne kredite.

Louzis, Vouldis i Metaxas (2010), Saba, Kouser i Azeem (2012), Tomak (2013), Otašević (2013), Klein (2013) i Škarica (2014) su pokazali da inflacija ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima. Sa druge strane, Khemraj i Pasha (2009), Ahmad i Bashir (2013), Badar i Javid (2013), Turan i Koskija (2014) i Pradhan i Pandey (2016) su pokazali da je njihov odnos statistički značajan i negativan.

Ipak, Nkusu (2011) je detaljno objasnio odnos inflacije i nekvalitetnih kredita koji je, po njemu, dvosmislen, odnosno može biti i pozitivan i negativan. On smatra da veća inflacija može povećati dužnikov kapacitet otplate kredita zbog smanjenja realne vrijednosti duga, a povećanje inflacije može i da oslabi sposobnost dužnika da otplati kredit jer može dovesti do smanjenja realnih prihoda (plate) ako su zarade promjenljive (Nkusu, 2011). Dakle, prema literaturi, odnos inflacije i nekvalitetnih kredita može biti pozitivan ili negativan, a zavisi od konkretnog ekonomskog stanja.

2. SPECIFIČNI BANKARSKI FAKTORI

Uzroke nekvalitetnih kredita ne treba tražiti isključivo u makroekonomskim faktorima, jer na njih utiču i specifični bankarski faktori. Osobine bankarskog sistema i politike pojedinačnih banaka u vezi sa njihovim naporima da povećaju efikasnost i poboljšaju upravljanje rizicima takođe mogu uticati na nekvalitetne kredite.

Berger i DeYoung su, među prvima, analizirali vezu između nekvalitetnih kredita i specifičnih bankarskih faktora, a rezultate istraživanja su dali u svom čuvenom radu „Problematični krediti i troškovi efikasnosti u komercijalnim bankama" (naslov originala: „*Problem Loans and Cost Efficiency in Commercial Banks*") (Berger & DeYoung, 1997, str. 849 - 870). Preciznije, autoru su, na uzorku komercijalnih banaka u SAD, testirali hipoteze koje opisuju vezu između nekvalitetnih kredita, cjenovne efikasnosti i finansijskog kapitala, odnosno, oni su kreirali i testirali hipoteze „loše sreće", „lošeg upravljanja", „škrtosti" i „moralnog hazarda".

Prema hipotezi „loše sreće", očekuje se da će rast nekvalitetnih kredita smanjiti cjenovnu efikasnost, a autori smatraju i da dodatni troškovi u vezi sa nekvalitetnim kreditima mogu smanjiti cjenovnu efikasnost. Berger i DeYoung ističu da menadžeri banaka ulažu dodatne napore i imaju dodatne troškove upravljanja nekvalitetnim kreditima. Autori su potvrdili ovu hipotezu, odnosno pokazali su da trend povećanja nekvalitetnih kredita ima tendenciju da bude praćen smanjenjem cjenovne efikasnosti, što ukazuje na činjenicu da visok nivo nekvalitetnih kredita uzrokuje povećanje troškova monitoringa, workout-a[3] i/ili prodaje tih kredita, kao i povećanje aktivnosti upravljanja postojećim portfoliom (Berger & DeYoung, 1997, str. 862 - 865). Dalje, hipoteza sugeriše da su bankrotstva banaka primarno uzrokovana eksternim događajima i ukazuje na to da prudencijalna regulacija i supervizija mogu da smanje rizik bankrotstva ograničavanjem izloženosti banke ili boljom zaštitom banke od eksternih šokova, odnosno događaja koji nisu pod njenom kontrolom.

Prema hipotezi „lošeg upravljanja" niska cjenovna efikasnost je signal loše prakse menadžera banke, koja se reflektuje na svakodnevne operacije i na upravljanje kreditnim portfoliom. Loš menadžment ne vrši adekvatan nadzor i upravljanje procjenom rizika, monitoringom i kontrolom, a takođe nedovoljno kontroliše operativne troškove što se odražava i na nisku cjenovnu efikasnost. Berger i DeYoung su potvrdili i ovu hipotezu, a posebno izdvajaju činjenicu da hipoteza „lošeg upravljanja", za razliku od hipoteze „loše sreće", ukazuje na to da su ključni rizici sa kojima se suočavaju finansijske institucije uzrokovane internim činiocima. Ova hipoteza sugeriše da supervizija banaka treba da uzme u obzir cjenovnu efikasnost zajedno sa ostalim faktorima pomoću kojih se mogu predvidjeti problemi banaka, poput kreditnih gubitaka i visokog kreditnog rizika (Berger & DeYoung, 1997, str. 863).

---

[3] *Workout* je, u bankarskom sektoru, služba za nekvalitetne kredite, a uloga ove službe je da pokuša da prilagodi uslove iz ugovora koji bi klijentima odgovarali i kako bi mogli da otplate glavnicu i kamatu u određenom periodu. Svi krediti čije plaćanje kasni 90 i više dana, smatraju se nekvalitetnim i šalju se u sektor *workout*-a. *Workout* predstavlja dio strukture upravljanja rizicima, a od uspješnosti rada ove službe zavisi i uspješnost poslovanja cijele banke.

Hipoteza „škrtosti“ pretpostavlja da su visoki rizici uzroci većeg broja nekvalitetnih kredita, odnosno da iznos resursa alociranih na aktivnosti procjene rizika monitoringa kredita utiče na kvalitet kredita i cjenovnu efikasnost. Autori smatraju da će manji napori, koji su posvećeni monitoringu dužnika, plasmana i procjeni kolaterala rezultirati nižim troškovima i većom cjenovnom efikašnošću posmatrano na kratak rok. Međutim, posmatrano na duži rok, to će dovesti do povećanja učešća nekvalitetnih u ukupnim kreditima, odnosno, do pogoršanja kreditnog portfolia u cjelini. Hipoteza „škrtosti“ identifikuje interne izvore rizika, ali ukazuje i na činjenicu da regulatori treba da posvete posebnu pažnju na interne procedure banaka u oblasti kreditne kontrole, kao što su praćenje kredita, procjena kolaterala i slično (Berger & DeYoung, 1997, str. 863). Berger i DeYoung nisu pronašli dokaze za ovu hipotezu.

Hipoteza „moralnog hazarda“ prvenstveno je povezana sa neumjerenim preuzimanjem rizika. Prema ovoj hipotezi, banke koje imaju nizak kapital povećavaju rizičnost kreditnog portfolia, a to dovodi do većeg učešća nekvalitetnih u ukupnim kreditima u budućnosti. Prilikom istraživanja, Berger i DeYoung su pretpostavili da nizak finansijski kapital dovodi do povećanja nekvalitetnih kredita. Autori su pronašli dokaze i za hipotezu „moralnog hazarda“ jer neki menadžeri u bankama povećavaju rizičnost svog kreditnog portfolia iako znaju da je banka slabo kapitalizovana.

Još jednu značajnu studiju koja se bavi ovom problematikom sproveli su Louzis, Vouldis i Metaxas. Oni su tražili uzroke nekvalitetnih kredita u grčkom bankarskom sektoru u periodu od prvog kvartala 2003. do trećeg kvartala 2009. godine, a rezultate su predstavili u studiji „Makroekonomske i specifične bankarske determinante nekvalitetnih kredita u Grčkoj: komparativna studija hipotekarnog, privrednog i potrošačkog kreditnog portfolia“ (naslov originala: *Macroeconomic and Bank-Specific Determinants of Non-Performing Loans in Greece: A Comparative Study of Mortgage, Business and Consumer Loan Portfolios*) (Louzis, Vouldis, & Metaxas, 2010). Oni su determinante nekvalitetnih kredita grupisali u tri kategorije i to: makroekonomske faktore, faktore zaduženosti i specifične bankarske faktore.

Oslanjajući se na prethodno spomenuti studiju koju su sproveli Berger i DeYoung, Louzis, Vouldis i Metaxas su testirali sljedeće hipoteze: hipotezu „javnog duga“, hipotezu „lošeg upravljanja“, hipotezu „škrtosti“ i hipotezu „moralnog hazarda“. Samo hipoteza „javnog duga“ se odnosi na faktore zaduženosti, dok se ostale tri hipoteze odnose na specifične bankarske faktore. Pored navedenih, grčki autori su formulisali i testirali još tri hipoteze: hipoteza „efekat veličine“, hipoteza „lošeg upravljanja II“ i hipoteza „procikličnе kreditne politike“. Na osnovu rezultata koje su dobili testiranjem navedenih hipoteza, Louzis, Vouldis i Metaxas su zaključili da performanse i neefikasnost mogu poslužiti kao pokazatelj za buduće nekvalitetne kredite, a s tim u vezi mogu sugerisati regulatornim organima da se usmjere na performanse menadžmenta u cilju detektovanja banaka kod kojih se očekuje potencijalni rast nekvalitetnih kredita (Louzis, Vouldis, & Metaxas, 2010, str. 26). Autori smatraju da bi regulatori trebali posvetiti pažnju sistemu za upravljanje rizicima u banci i procedurama koje se primjenjuju sa ciljem sprečavanja buduće finansijske nestabilnosti.

Louzis, Vouldis i Metaxas su, na osnovu poznate veze između krize javnog duga i bankarske krize, formulisali hipotezu „javnog duga“ i istakli da rastući javni dug izaziva i rast nekvalitetnih kredita. Dalje, autori obrazlažu da hipoteza „škrtosti“ pretpostavlja da visoka izmjerena efikasnost uzrokuje rast broja nekvalitetnih kredita, dok je hipoteza „moralnog hazarda“ zasnovana na tvrdnji da niska kapitalizacija banaka izaziva rast nekvalitetnih kredita.

Takođe, autori su zapazili da diversifikacija bankarskog portfolia može negativno uticati na kvalitet kredita jer ona smanjuje nivo kreditnog rizika. Grčki autori ističu i činjenicu da pojedini autori koriste parametar veličine banke kao zamjenu za mogućnosti diversifikacije, odnosno, smatraju da veće banke imaju veće mogućnosti za diversifikaciju. U vezi sa tim su formulisali hipoteze „diversifikacije" i „previše veliki da bi propali". Dalje, oni obrazlažu da hipoteza „diversifikacije" pretpostavlja da veličina banke i učešće nekamatonosnih u ukupnim prihodima imaju negativnu korelaciju sa nekvalitetnim kreditima, dok je hipoteza „previše veliki da bi propali" zasnovana na tvrdnji da velike banke preuzimaju veći rizik i da zbog toga imaju i veći broj nekvalitetnih kredita. Autori obrazlažu i hipotezu „lošeg upravljanja II" prema kojoj su performanse banke negativno povezane sa povećanjem nekvalitetnih kredita u budućnosti. Hipoteza „prociklične kreditne politike" pretpostavlja da su performanse banke pozitivno povezane sa budućim rastom nekvalitetnih kredita, u smislu refleksije liberalne kreditne politike banaka .

Ahmad i Bashir su se takođe bavili ovom problematikom u studiji „Objašnjenje uticaja specifičnih bankarskih faktora kao determinanti nekvalitetnih kredita: Dokazi iz bankarskog sektora Pakistana (naslov originala: *Explanatory Power of Bank Specific variables as Determinants of Non-Performing Loans: Evidence from Pakistan Banking Sector*) (Ahmad & Basir (b), 2013, str. 1220 - 1231). Oni su, oslanjajući se na studiju koju su sproveli Berger i DeYoung i studiju koju su sproveli Louzis, Vouldis i Metaxas, postavili i testirali devet hipoteza pomoću deset specifičnih bankarskih promjenljivih. Te hipoteze su: hipoteza „loše upravljanje", hipoteza „škrtost", hipoteza „moralni hazard", hipoteza „veličina", hipoteza „loše upravljanje II", hipoteza „prociklična kreditna politika", hipoteza „blaga budžetska ograničenja", hipoteza „efekti stope depozita" i hipoteza „efekti odnosa kredita i depozita".

Prema hipotezi „lošeg upravljanja" visoka efikasnost uzrokuje rast nekvalitetnih kredita, a isti problem, prema hipotezi „škrtosti", uzrokuje niska efikasnost. Prema hipotezi „moralnog hazarda" niska kapitalizacija i visok udio kredita u aktivi banaka uzrokuju povećanje nekvalitetnih kredita. Dalje, prema hipotezi „veličine" povećanje veličine banke rezultuje smanjenje nekvalitetnih kredita. Prema hipotezi „lošeg upravljanja II" povećanje dobrih trenutnih performansi vodi ka povećanju nekvalitetnih kredita u budućnosti. Prema hipotezi „prociklične kreditne politike" kreditni rast takođe uzrokuje povećanje nekvalitetnih kredita u budućnosti. Do rasta nekvalitetnih kredita dolazi i ukoliko su blaga budžetska ograničenja (prema hipotezi „blaga budžetska ograničenja"). Prema hipotezi „efekti stope depozita", rast depozita ima pozitivan uticaj, a prema hipotezi „efekti odnosa kredita i depozita" rast odnosa kredita i depozita ima negativan uticaj na nekvalitetne kredite.

Ahmad i Bashir su, prilikom testiranja navedenih devet hipoteza, koristili deset specifičnih bankarskih promjenljivih jer su prilikom testiranja hipoteza „moralni hazard" i „loše upravljanje II" koristili po dvije različite promjenljive, a prilikom testiranja hipoteza „loše upravljanje" i „škrtost" su koristili jednu zajedničku promjenljivu. Analizirajući nekvalitetne kredite u 30 komercijalnih banaka u Pakistanu, u periodu od 2006. do 2011. godine, autori su pronašli dokaze za tri hipoteze (hipoteza „moralni hazard", hipoteza „loše upravljanje II" i hipoteza „prociklična kreditna politika"), a ostale hipoteze su odbačene. Autori posebno ističu činjenicu da je hipoteza „odnos kredita i depozita" odbačena, ali da promjenljiva pomoću koje je testirana ova hipoteza ima značajan uticaj na nekvalitetne kredite.

Autori smatraju da komercijalne banke mogu koristiti rezultate ovog istraživanja kako bi poboljšale trenutno upravljanje, kontrolisale nivo kreditiranja, te na taj način smanjile nekvalitetne kredite u narednom periodu.

Ahmad i Bashir su u navedenoj studiji dali pregled specifičnih bankarskih promjenljivih koje su koristili prilikom testiranja hipoteza, a pregled korištenih promjenljivih i testiranih hipoteza dat je u tabeli 7.

Tabela 7: Pregled specifičnih bankarskih promjenljivih i testiranih hipoteza

Promjenljiva	Testirana hipoteza	Odnos sa nekvalitetnim kreditima
Neefikasnost	Loše upravljanje	+
Neefikasnost	Škrtost	-
Koeficijent solventnosti	Moralni hazard	-
Odnos kredita i depozita	Moralni hazard	+
Tržišna moć	Veličina	-
Prinos na aktivu	Loše upravljanje II	+
Prinos na akcijski kapital	Loše upravljanje II	+
Kreditni rast	Prociklična kreditna politika	+
Ukupne obaveze u odnosu na prihod	Blaga budžetska ograničenja	+
Stopa depozita	Efekat stope depozita	+
Stopa rezervi	Efekat odnosa kredita i depozita	-

Izvor: (Ahmad & Basir (b), 2013, str. 1224)

U većini studija u kojima se analizira uticaj specifičnih bankarskih faktora na nekvalitetne kredite koriste se sljedeće promjenljive: koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, kreditni rast, stopa depozita i stopa rezervi. U ovom radu će se, zbog ograničenja koje se odnosi na dostupnost podataka, analizirati uticaj sljedećih promjenljivih: koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital i kreditni rast. Pored navedenih, u radu će se analizirati i uticaj prosječne aktivne kamatne stope, jer se u BiH ovaj faktor ubraja u grupu specifičnih bankarskih faktora.

Pored navedenih, postoji još mnogo studija u kojima se analizira uticaj specifičnih bankarskih faktora na nekvalitetne kredite. Neke od njih su sproveli: Keeton i Morris (1987), Sinkey i Greenawalt (1991), Salas i Saurina (2002), Jimenez i Saurina (2006), Khemraj i Pasha (2009), Boudriga, Taktak i Jellouli (2009), Louzis, Vouldis i Metaxas (2010), Boudriga, Taktak i Jellouli (2010), Espinoza i Prasad (2010), Saba, Kouser i Azeem (2012), Swami (2012), Tomak (2012), Ahmad i Bashir (2013), Shingjergji (2013), Messai i Jouini (2013), Klein (2013), Makri, Tsagkanos i Bellas (2014), Jameel (2014) i Pradhan i Pandey (2016).

2.1. Koeficijent adekvatnosti kapitala

Kapital banke predstavlja trajno uloženi izvor u banku, odnosno najstabilniji dio finansijskog potencijala banke. Dušanić navodi da je kapital banke „oblik nedepozitnih izvora sredstava koji je trajno uložen u banku, za razliku od drugih depozitnih i nedepozitnih izvora, kao neophodan uslov za osnivanje banke i uspješno poslovanje“ (Dušanić, 2003, str. 98). Osnovni zadatak kapitala banke je da ublaži nepredviđene gubitke u poslovanju, a regulatorno tijelo propisuje obavezu da banke održavaju adekvatan kapital. Stanišić i Stanojević navode da „adekvatnost kapitala banke predstavlja odnos kapitala banke i zbira aktive ponderisane kreditnim rizikom, deviznim rizikom i ostalim tržišnim rizicima“, te da se pod ostalim tržišnim rizicima koji se uključuju u obračun adekvatnosti kapitala ubrajaju „cjenovni rizik (po osnovu dužničkih hartija od vrijednosti i po osnovu vlasničkih hartija od vrijednosti) i rizik izmirenja / isporuke i rizik druge ugovorne strane“ (Stanišić & Stanojević, 2009, str. 21 - 22).

Koeficijent adekvatnosti kapitala je specifični bankarski faktor koji je često uključen u studije koje se bave problematikom nekvalitetnih kredita. Preciznije, ovaj koeficijent se obično koristi prilikom testiranja hipoteze „moralni hazard“ jer se pomoću njega određuje rizično poslovanje banke.

Rezultati sprovedenih studija uglavnom ukazuju na negativnu vezu između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita, a to podrazumijeva da banke koje imaju nizak koeficijent adekvatnosti kapitala povećavaju rizičnost kreditnog portfolia, a rezultat toga je povećanje nekvalitetnih kredita u narednom periodu. Do ovakvog rezultata došli su Salas i Saurina (2002), Espinoza i Prasad (2010), Swami (2012), Shingjergji (2013), Jameel (2014), Makri, Tsagkanos i Bellas (2014) i Pradhan i Pandey (2016).

Sa druge strane, Boudriga, Taktak i Jellouli (2010) su pokazali da postoji pozitivna veza između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita, a to objašnjavaju činjenicom da visoko kapitalizovane banke nisu pod pritiskom i da su manje sklone riziku (Boudriga, Taktak, & Jellouli, 2010).

2.2. Odnos kredita i depozita

U studije u kojima se analizira uticaj specifičnih bankarskih faktora na nekvalitetne kredite veoma često je uključen pokazatelj odnosa kredita i depozita. Ovaj pokazatelj se veoma često koristi u bankama za mjerenje likvidnosti. Živko i Kandžija navode da „likvidnost banke predstavlja sposobnost banke da udovolji svim predviđenim i nepredviđenim finansijskim zahtjevima svojih klijenata, te osigura dodatne izvore za pribavljanje potrebnih sredstava banke, tj. treba biti sposobna da u kratkom roku i bez prevelikih troškova pribavi dodatna sredstva putem povećanja obaveza, sekjuritizacijom, prodajom aktive ili na neki drugi način“ (Živko & Kandžija, 2014, str. 283). Jednostavnije rečeno, likvidna banka u svakom trenutku treba biti sposobna da izmiri preuzete obaveze, a ukoliko nema likvidnih sredstava, ona treba da bude u stanju da ih pribavi transformišući svoju imovinu u novčani oblik bez većih gubitaka ili da ih pozajmi na tržištu. Nedostatak odgovarajuće likvidnosti je jasan signal da se banka nalazi u problemu jer je upravo likvidnost osnovni uslov za njen opstanak na tržištu.

U skladu sa definicijom likvidnosti i banke mjere sposobnost naplate svojih dospjelih obaveza. Prilikom mjerenja likvidnosti obično se koriste pokazatelji likvidnosti, odnosno racia koja su jednostavna za primjenu i pogodna za poređenje banaka i bankarskih sistema. Rose i Hudgins navode čak jedanaest pokazatelja pomoću kojih bankarski menadžeri mjere likvidnosti. Ti pokazatelji su: pokazatelj gotovinske pozicije, pokazatelj likvidnih hartija od vrijednosti, racio kapaciteta, racio ukupnih depozita, racio uzetih (kupljenih) sredstava, racio bazičnih depozita, racio kredita i depozita, neto nebazični racio finansiranja, racio rezervi, perspektivni racio likvidnosti i racio pokrića (Rose & Hudgins, 2005, str. 363 - 364).

Žager i Žager navode tri pokazatelja kojima se banka služi prilikom mjerenja likvidnosti, a ti pokazatelji su:

1. pokazatelj tekuće likvidnosti koji mjeri odnos kratkoročne aktive i kratkoročne pasive,
2. pokazatelj odnosa datih kredita i primljenih depozita,
3. pokazatelj kratkoročne aktive i ukupnih datih kredita (Žager & Žager, 2008, str. 300).

Na osnovu navedenog se vidi da banke prilikom mjerenja likvidnosti koriste pokazatelj koji određuje odnos kredita i depozita, jer je on važan instrument koji ispituje likvidnost banaka mjerenjem sredstava koja je banka iskoristila za kredite iz prikupljenih depozita. Što je veća vrijednost ovog pokazatelja, veći je i rizik nelikvidnosti jer banka jedan dio kredita finansira iz nestabilnih nedepozitnih izvora.

Iako su Makri, Tsagkanos i Bellas (2014) pokazali da pokazatelj odnosa kredita i depozita nema statistički značajan uticaj na nekvalitetne kredite, rezultati većine studija koje su sprovedene pokazuju da je uticaj ovog pokazatelja ipak statistićki značajan. Louzis, Vouldis i Metaxas (2010), Swami (2012), Ahmad i Bashir (2013), Ganić (2014) i Pradhan i Pandej (2014) su pokazali da je njihov međusobni odnos pozitivan, što znači da bi trajna likvidnost banaka trebala da smanji broj nekvalitetnih kredita u njihovom kreditnom portfoliu. Sa druge strane, Shingjergji (2013) i Jameel (2014) su pokazali da je njihov međusobni odnos negativan.

2.3. Pokazatelji profitabilnosti banke

Koncept profitabilnosti je veoma značajan u bankarskoj praksi jer preko profita banka povećava dividendu svojim akcionarima, a reinvestiranjem u akcije (kapital) stvara uslove za povećanje sopstvenog finansijskog i kreditnog potencijala. Profitabilnost poslovanja zavisi od uspješnosti realizacije mjera poslovne politike banke i upravo zbog toga menadžment mora dobro poznavati njenu bilansnu strukturu. Ukoliko menadžment banke želi da poveća njenu profitabilnost, on se mora susretati sa konfliktom principa profitabilnosti, principa likvidnosti i principa sigurnosti. Ukoliko se nekom od principa poslovanja da prioritet, tada dolazi do sukoba.

U savremenim uslovima poslovanja banka mora pratiti faktore koji mogu uticati na njenu profitabilnost jer jedino na taj način može stvoriti dobre uslove za svoj razvoj. Slobodno se može reći da svaka bankarska operacija ima uticaj na profitabilnost, a takođe postoji i čitav niz spoljnih faktora koji mogu da utiču na profitabilnost pojedinačne banke ili na cjelokupan bankarski sistem. Vunjak i Kovačević, kao najznačajnije faktore, izdvajaju: „top“ menadžment, ekonomske uslove poslovanja, veličinu banke, konkurentske uslove, kretanje kamatnih stopa, stepen uposlenosti resursa, dobitke i gubitke na hartijama od vrijednosti i gubitke na plasmanima i obnavljanju plasmana (Vunjak & Kovačević, 2002, str. 334).

Prilikom izračunavanja i iskazivanja profitabilnosti, banke najčešće polaze od stope prinosa ukupnih sredstava, stope prinosa akcijskog kapitala, stope zarade na ukupna sredstva, zarade po akciji i stope prinosa tuđeg kapitala (Vunjak & Kovačević, 2006, str. 383). Ipak, u literaturi se najčešće koriste opšte prihvaćeni standardi koji se odnose na:

- profitabilnost kao stopu prinosa na ukupnu aktivu (ROA),
- profitabilnost kao stopu prinosa na akcijski kapital (ROE) (Ćurčić, 1999, str. 96).

Menadžment banaka prati svoju profitabilnost i poredi pokazatelje sa odgovarajućim pokazateljima drugih sličnih banaka, kao i sa pokazateljima koje je banka ostvarila u prethodnom periodu. Profitabilnost banke direktno zavisi od kvaliteta njene aktive jer nekvalitetna aktiva sa sobom nosi visok rizik i nedovoljnu profitabilnost. Upravo zbog toga je vrlo važno da se pravilno procijeni kreditna sposobnost klijenata banke, kako bi se banka zaštitila od potencijalnog kreditnog rizika. Može se zaključiti da su kvalitet aktive i profitabilnost banke međusobno povezane, odnosno da pokazatelji profitabilnosti mogu uticati na nekvalitetne kredite. Ova veza potvrđena je u studijama u kojima se analizira uticaj specifičnih bankarskih faktora na nekvalitetne kredite. U studije su obično uključeni opšte prihvaćeni pokazatelji profitabilnosti koji će biti objašnjeni u nastavku.

2.3.1. Prinos na aktivu

Prinos na aktivu (ROA) je veoma značajan pokazatelj profitabilnosti banke jer pokazuje efikasnost upravljanja aktivom. Pokazatelj ROA se dobije kada se stave u odnos neto profit (nakon oporezivanja) i prosječna ukupna aktiva u toku poslovne godine. Pavković smatra da bi bilo idealno kada bi se prilikom izračuna prosječne ukupne aktive „iskazao prosjek dnevnih veličina, no u većini država takve podatke nije moguće osigurati, stoga se koriste mjesečni, pa čak i kvartalni prosjeci“ (Pavković, 2004, str. 180 - 181). Veoma je važno pravilno izračunati stopu prinosa na aktivu, ali je takođe veoma važna i interpretacija ovog pokazatelja. Ako je stopa prinosa na aktivu jednaka ili veća od jedan, tada se investiranje u akcije te banke smatra profitabilnim. S obzirom na činjenicu da pokazatelj ROA primarno pokazuje menadžerske efikasnosti, može se reći da je efikasnost banke na adekvatnom nivou ukoliko je vrijednost ovog pokazatelja u rasponu od 0,5% do 2,0%. Ukoliko je vrijednost ovog pokazatelja ispod 0,5% i iznad 2% smatra se da postoje neprirodne oscilacije u smislu da je efikasnost banke izuzetno niska ako je ROA ispod 0,5%, a ukoliko je ROA iznad 2,5% tada je tržište kontrolisano.

Pokazatelj profitabilnosti banke, mjeren prinosom na aktivu, je uključen u veći broj studija koje se bave problematikom nekvalitetnih kredita, a dobijeni rezultati pokazuju da njihov međusobni odnos može biti različit. Makri, Tsagkanos i Bellas (2014) su pokazali da pokazatelj ROA nema statistički značajan uticaj na nekvalitetne kredite. Swami (2012), Ahmad i Bashir (2013) i Pradhan i Pandey (2016) su pronašli statistički značajnu i pozitivnu vezu između ova dva pokazatelja, a pozitivna veza je rezultat neefikasnog upravljanja imovinom banke. Sa druge strane, Louzis, Vouldis i Metaxas (2010) i Boudriga, Taktak i Jellouli (2010) su pronašli statistički značajnu i negativnu vezu između ROA i nekvalitetnih kredita, a negativna veza ukazuje na činjenicu da su banke sa nižom profitabilnošću manje sklone generisanju prihoda, a samim tim su manje sklone odobravanju rizičnih kredita što rezultuje manjim brojem nekvalitetnih kredita u budućnosti.

2.3.2. Prinos na akcijski kapital

Drugi veoma važan pokazatelj profitabilnosti je prinos na akcijski kapital jer predstavlja interni mehanizam mjerenja akcionarske vrijednosti. Pokazatelj ROE se dobije kada se stave u odnos neto dobit i prosječan akcionarski kapital, a prikazuje direktnu procjenu finansijskog povrata investicije. Ovaj pokazatelj često koriste i ekonomski analitičari jer se oslanja na podatke koji su javno dostupni.

Pokazatelj ROE se može definisati i kao neto profit po jedinici akcionarskog kapitala. Ukoliko se ROE definiše na ovaj način, veoma je važno naglasiti da se u obzir uzima neto profit nakon oporezivanja, a iznos kapitala se uvećava za neraspoređenu dobit i fondove rezervnog kapitala. Niske vrijednosti pokazatelja ROE ukazuju na veoma nisku zaradu banke. Važno je istaći činjenicu da bi vrijednost pokazatelja ROE, u uslovima inflacije, trebala biti najmanje jednaka stopi inflacije jer se jedino na taj način može sačuvati realna vrijednost kapitala.

Pokazatelj profitabilnosti mjeren prinosom na akcijski kapital je takođe uključen u veliki broj studija u kojima se analizira uticaj specifičnih bankarskih faktora na nekvalitetne kredite. Autori su, prilikom istraživanja, došli do različitih rezultata. Ganić (2014) i Alihodžić (2014) su pokazali da je veza između ROE i nekvalitetnih kredita statistički značajna i negativna. Sa druge strane, rezultati većine studija pokazuju da je ova veza statistički značajna i negativna, što se objašnjava činjenicom da prilikom pogoršanja profitabilnosti banke (mjerene pomoću prinosa na akcionarski kapital) dolazi do povećanja nivoa nekvalitetnih kredita. Do ovakvih rezultata došli su Boudriga, Taktak i Jellouli (2009), Louzis, Vouldis i Metaxas (2010), Ahmad i Bashir (2013), Shingjergji (2013), Klein (2013), Makri, Tsagkanos i Bellas (2014) i Pradhan i Pandey (2016).

2.4. Aktivna kamatna stopa

Pregledom literature, vidi se da, pored navedenih, postoji još mnogo faktora koji utiču na nekvalitetne kredite, a jedan od njih je aktivna kamatna stopa. Ovaj faktor se uglavnom svrstava u grupu makroekonomskih faktora, ali u BiH poslovne banke same formiraju kamatne stope tako da se ubraja u grupu specifičnih bankarskih faktora. U suštini, kamata predstavlja naknadu za korištenje tuđih sredstava, a kamatna stopa cijenu koštanja kreditnih i novčanih sredstava na finansijskom tržištu.

Kamata se u bankama javlja u dvostrukoj ulozi pa je potrebno praviti razliku između aktivnih i pasivnih kamatnih stopa. Aktivna kamatna stopa se koristi za obračun aktivne kamate koju banka naplaćuje od svojih klijenata za plasirana sredstva, a pasivna kamatna stopa služi za obračun pasivne kamate koju banka plaća za pribavljena sredstva. Drugim riječima, banke prikupljaju depozite za koje plaćaju pasivnu kamatu i plasiraju kredite za koje naplaćuju aktivnu kamatu. Kod obračuna kamata potrebno je razlikovati prosti i složeni kamatni račun. Horne i Wachowicz smatraju da se složeni kamatni račun može „upotrijebiti za rješavanje mnogobrojnih problema u finansijama“ (Horne & Wachowicz, 2002, str. 39). Kod složenog kamatnog računa koji se u praksi češće koristi, kamata se pripisuje glavnici i na taj način se formira nova glavnica, a iznos kamate je veći od kamate koju daje prost kamatni račun.

Kamata koju plaća korisnik kredita je cijena tog kredita, odnosno naknada za korišćenje tuđih finansijskih sredstava, a Dušanić navodi da je „predstavljena nominlnom kamatnom stopom“ (Dušanić, 2003, str. 180). Nominalna kamatna stopa, zajedno sa svim pratećim troškovima, čini efektivnu kamatnu stopu. Prateći troškovi se uglavnom odnose na troškove obrade zahtjeva za kredit, troškove puštanja kredita u tečaj, godišnju proviziju na ime naknade za administriranje kredita, iznos premije osiguranja, vođenje računa koji su uslov za odobravanje kredita i slične troškove u vezi sa sporednim uslugama koje su uslov za korištenje kredita, a koje snosi korisnik (npr. troškovi izdavanja izvoda iz registra nepokretnosti, troškovi upisa založnog prava – hipoteke, troškovi procjene vrijednosti nepokretnosti i pokretnih stvari). Efektivna kamatna stopa je veoma značajna jer pokazuje klijentu koliko će ga uzeti kredit zaista koštati, a koristi se i prilikom poređenja istog bankarskog proizvoda kod različitih davaoca usluga na finansijskom tržištu.

Prilikom određivanja kamatne stope za određeni kredit banka procjenjuje vjerovatnoću da će kredit biti vraćen, odnosno da kredit neće biti vraćen. Prilikom formiranja kamatnih stopa, banka donosi odluku na osnovu svojih analiza, postavljenih ciljeva i procjene rizika. Uticaj takvih odluka nije važan samo za banku, kao finansijsku instituciju, već i za privredu, odnosno cjelokupnu ekonomiju. Upravo zbog toga, definisanje kvalitetne politike kamatnih stopa je jedan od najtežih bankarskih zadataka.

S obzirom na činjenicu da se kamata veže za svaki kredit, ona ima veliki uticaj na pojavu nekvalitetnih kredita. Upravo zbog toga, aktivna kamatna stopa je uključena u veliki broj studija o nekvalitetnim kreditima. Rezultati sprovedenih istraživanja su različiti. Swami (2012) i Tomak (2012) su, analizirajući nekvalitetne kredite u bankarskom sektoru Indije i Turske, pokazali da aktivna kamatna stopa nema statistički značajan uticaj na nekvalitetne kredite.

Statistički značajnu i pozitivnu vezu između aktivne kamatne stope i nekvalitetnih kredita pronašli su Sinkey i Greenawalt (1991), Ranjan i Dhal (2003), Jimenez i Saurina (2006), Khemraj i Pasha (2009), Louzis, Vouldis i Metaxas (2010), Espinoza i Prasad (2010), Collins i Wanjan (2011), Nkusu (2011), Adebola, Wan Yusoff i Dahalan (2011), Badar i Javid (2013), Beck, Jakubik i Piloiu (2013), Messai i Jouini (2013) i Jameel (2014). Nkusu u svojoj studiji objašnjava ovu pozitivnu vezu i navodi da povećanje kamatne stope slabi dužnikovu mogućnost otplate kredita, što vodi ka povećanju nivoa nekvalitetnih kredita (Nkusu, 2011). Sa druge strane, Saba, Kouser i Azeem (2012), Ahmad i Bashir (2013), Otašević (2013) i Turan i Koskija (2014) su pronašli statistički značajnu i negativnu vezu između aktivne kamatne stope i nekvalitetnih kredita. Negativna veza se objašnjava činjenicom da povećanje aktivne kamatne stope smanjuje sposobnost klijenata da se zadužuju, što smanjuje količinu kredita, a samim tim smanjuje i broj nekvalitetnih kredita.

2.5. Kreditni rast

U posljednjih nekoliko godina većina zemalja se suočila sa problemom ubrzanog kreditnog rasta, odnosno sa kreditnom ekspanzijom. Kreditna ekspanzija predstavlja neodrživ rast kredita koji po završetku ima negativne posljedice za bankarski sektor, ali i za cjelokupnu ekonomiju. Mendoza i Terrones navode da „kreditna ekspanzija predstavlja prekomjerni kreditni bum koji u određenom trenutku naglo prestaje“ (Mendoza & Terrones, 2004, str. 149).

Istraživanja pokazuju da postoji više uzroka kreditnih ekspanzija. Cottarelli, Dell' Ariccia i Vladkova – Hillar smatraju da je liberalizacija finansijskog, odnosno bankarskog sistema glavni uzrok kreditne ekspanzije (Cottarelli, Dell' Ariccia, & Vladkova - Hollar, 2003), a sa njima se slažu i Ottens, Lambregts i Poelhekke (Ottens, Lambregts, & Poelhekke, 2005). Mendoza i Terrones smatraju da je glavni uzrok kreditne ekspanzije pozitivan ekonomski šok (Mendoza & Terrones, 2008). Kiss, Nagy i Vonnak smatraju da su garancije vlade i povećana bankarska konkurencija glavni uzroci kreditne ekspanzije (Kiss, Nagy, & Vonnak, 2006). Veći broj autora, a među njima i Mendoza i Terrones (Mendoza & Terrones, 2008), Elekdag i Wu (Elekdag & Wu, 2013), Calderon i Kubota (Calderon & Kubota, 2012), slaže se sa činjenicom da priliv stranog kapitala predstavlja dobar pokazatelj kreditne ekspanzije. Takođe, ona može biti izazvana i rastom cijena nekretnina na hipotekarnom tržištu, a sa tim se slažu Bernanke, Gertler i Gilchrist (Bernanke, Gertler, & Gilchrist, 1999), Kiyotaki i Moore (Kiyotaki & Moore, 1995), Aiyagari i Gertler (Aiyagari & Gertler, 1999) i Sa (Sa, 2007). Upravo rast cijena nekretnina je jedan od glavnih uzroka globalne finansijske krize iz 2008. godine.

Važno je naglasiti da se svaki prekomjerni kreditni rast ne poistovjećuje sa kreditnom ekspanzijom, a Tornell i Wetermann smatraju da prekomjerni kreditni rast može predstavljati i finansijsko produbljivanje, odnosno pojavu rasta kredita po stopi koja je veća od stope rasta BDP-a (Tornell & Westermann, 2002). Mishin je ukazao na činjenicu da finansijsko produbljivanje dovodi do trajnih promjena finansijskih prilika i povećanih investicija, a to ujedno podstiče i ekonomski rast (Mishkin, 2007). Na ovo se nadovezuju Rousseau i Wachtel koji objašnjavaju da ova relacija raste ili nestaje u periodu finansijske krize (Rousseau & Wachtel, 2011). Takođe, prekomjerni kreditni rast može biti rezultat kreditiranja obrtnog kapitala.

Filipović i Nikolić smatraju da je potrebno razlikovati rast kredita odobrenih stanovništvu od rasta kredita odobrenih privredi, jer „rast kredita prema privredi može pozitivno uticati na makroekonomsku stabilnost preko rasta agregatne ponude, supstitucije uvoza i rasta zaposlenosti, što sve ujedno ima pozitivne efekte na tekući platni bilans, inflaciju i stabilnost valute“, dok „rast kredita stanovništvu stimuliše agregatnu tražnju u uslovima ograničene domaće ponude, vrši pritisak na potrošnju i/ili uvoznu tražnju, što negativno djeluje na trgovinski bilans, izaziva inflatorni pritisak i devalvaciju valute“ (Filipović & Nikolić, 2008, str. 68 - 69)

Jović i Jandrić su, analizirajući determinante kreditnog rasta u bankarskom sektoru Bosne i Hercegovine, pokazali da najveći uticaj na kreditni rast imaju nekvalitetni krediti, stopa rasta BDP-a i inflacija (Jović & Jandrić, 2016). Ipak, i kreditni rast utiče na pojavu i rast nekvalitetnih kredita banaka, a tom problematikom su se bavili mnogi autori. Sinkey i Greenawalt (1991), Salas i Saurina (2002) i Jimenez i Saurina (2006) smatraju da su glavne odrednice nekvalitetnih kredita upravo prekomjerni krediti koje banke nude.

Literatura pokazuje da je brz rast kredita veoma često povezan sa smanjenjem kvaliteta kreditnog portfolia jer, usljed povećanja plasiranih kredita, dolazi do rasta nekvalitetnih kredita. Ovo je potvrđeno u studiji koju je sproveo Shingjergji (2013). Sa druge strane, Khemraj i Pasha (2009), Espinoza i Prasad (2010), Boudriga, Taktak i Jellouli (2010), Klein (2013) i Ganić (2014) su pokazali da kreditni rast ima statistički značajan i negativan odnos sa nekvalitetnim kreditima. Iako su rezultati sprovedenih istraživanja uglavnom ukazali na činjenicu da kreditni rast ima statistički značajan uticaj na nekvalitetne kredite, Louzis, Vouldis i Metaxas (2010) i Messai i Jouini (2013) su pokazali da kreditni rast nema statistički značajan uticaj na nekvalitetne kredite.

III DIO

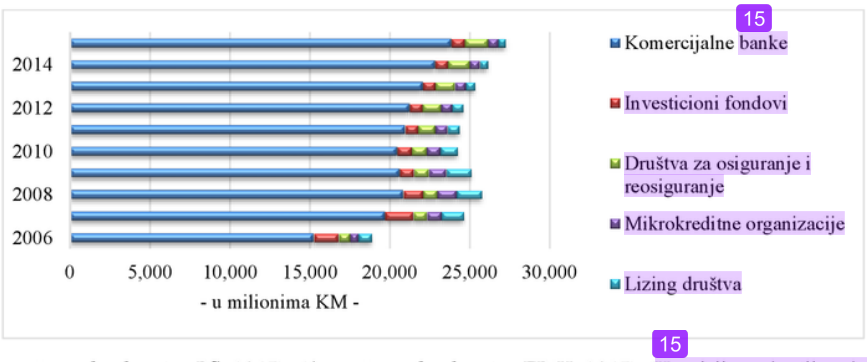
KARAKTERISTIKE I PERFORMANSE BANKARSKOG SEKTORA BOSNE I HERCEGOVINE

1. FINANSIJSKI SEKTOR BOSNE I HERCEGOVINE

Finansijski sektor u BiH čine komercijalne banke, mikrokreditne organizacije, društava za lizing, investicioni fondovi i osiguravajuća društva. Dominantan dio čine komercijalne banke, tako da se slobodno može reći da je finansijski sektor BiH bankocentričan. S obzirom na činjenicu da se BiH sastoji od dva entiteta, finansijski sektor je podijeljen na finansijski sektor Republike Srpske (RS) i finansijski sektor Federacije BiH (FBiH).

Ukupna aktiva finansijskog sektora u BiH, u periodu od 2006. do kraja 2015. godine, prikazana je grafikonom 1. Grafički prikaz jasno pokazuje strukturu finansijskog sektora, čiji dominantan dio čine komercijalne banke, a učešće ostalih finansijskih institucija je gotovo zanemarljivo. Lako je uočljivo da se aktiva finansijskog sektora povećavala u analiziranom periodu, a izuzetak čine samo 2009. i 2010. godina, tokom kojih je aktiva smanjenja. Ipak, detaljniji prikaz aktive finansijskog sektora BiH dat je u tabeli 8.

Grafikon 1: Aktiva finansijskog sektora BiH (2006 – 2015)



Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017), (Komisija za hartije od vrijednosti RS, 2017), (Komisija za vrijednosne papire FBiH, 2017), (Agencija za osiguranje RS, 2017) (Agencija za nadzor osiguranja FBiH, 2017)

Tabela 8: Aktiva finansijskog sektora BiH (2006 – 2015)

- u milionima KM-

FINANSIJSKE INSTITUCIJE	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Komercijalne banke	15.231	19.682	20.821	20.605	20.452	20.953	21.226	22.066	22.821	23.829
Investicioni fondovi	1.553	1.764	1.242	885	898	799	795	761	790	834
Osiguravajuća društva	708	853	889	933	936	1.080	1.174	1.232	1.356	1.466
Mikrokreditne organizacije	522	916	1.210	1.087	856	753	681	670	646	640
Lizing Društva	862	1.417	1.600	1.598	1.108	767	716	597	512	475
UKUPNO ZA SEKTOR	**18.876**	**24.632**	**25.762**	**25.108**	**24.250**	**24.352**	**24.592**	**25.326**	**26.125**	**27.244**

Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017), (Komisija za hartije od vrijednosti RS, 2017), (Komisija za vrijednosne papire FBiH, 2017), (Agencija za osiguranje RS, 2017), (Agencija za nadzor osiguranja FBiH, 2017)

Na osnovu podataka koji su prikazani u tabeli, vidi se da se aktiva finansijskog sektora BiH u analiziranom desetogodišnjem periodu uglavnom povećavala, a izuzetak su samo 2009. i 2010. godina u kojima je došlo do smanjenja aktive. Smanjenje aktive finansijskog sektora je posljedica svjetske finansijske krize koja je, šireći se poput epidemije, zahvatila ekonomije širom svijeta. U BiH kriza se preselila iz zemalja koje su njeni ekonomski i trgovinski partneri, a prema ocjeni ekonomskih stručnjaka najizraženija je bila tokom 2009. godine.

Podaci pokazuju da je ukupna aktiva finansijskog sektora u 2006. godini iznosila 18,876 milijardi KM, a njen najveći dio odnosio se na aktivu komercijalnih banaka. Tokom 2007. godine došlo je do značajnog povećanja aktive finansijskog sektora, tako da je na kraju godine iznosila 30,49% više nego u 2006. godini, a najveći rast zabilježile su mikrokreditne organizacije s povećanjem od 75,48%. Tokom sljedeće, 2008. godine, aktive mikrokreditnih organizacija, lizing društava, komercijalnih banaka i društava za osiguranje i reosiguranje bilježe rast, a aktiva investicionih fondova značajno smanjenje, tako da se ukupna aktiva finansijskog sektora povećala samo za 4,59%. Tokom 2009. godine aktiva finansijskog sektora se smanjila za 2,54% u odnosu na prethodnu godinu, a u tom periodu samo aktiva društava za osiguranje i reosiguranje je zabilježila rast. Trend smanjenja aktive investicionih fondova iz 2008. godine nastavljen je i tokom sljedeće godine, što je direktna posljedica globalne finansijske krize. I u 2010. godini dolazi do smanjenja ukupne aktive finansijskog sektora, a smanjenje aktive za 3,42% je posljedica smanjenja aktive lizing društava, mikrokreditnih organizacija i komercijalnih banaka. Od 2011. godine do kraja analiziranog perioda, odnosno do kraja 2015. godine, aktiva finansijskog sektora BiH raste. U toku 2011. godine aktiva finansijskog sektora je povećana za 2,0%, u toku 2012. godine 0,99% i u toku 2013. godine 2,98%. Istovremeno, povećane su aktive komercijalnih banaka i društava za osiguranje i reosiguranje, a smanjene su aktive investicionih fondova, mikrokreditnih organizacija i lizing društava. U toku 2014. i 2015. godine povećane su aktive komercijalnih banaka, investicionih fondova i društava za osiguranje i reosiguranje, a smanjene su aktive mikrokreditnih organizacija i lizing društava, što je dovelo do povećanja aktive cjelokupnog sektora za 3,15% tokom 2014. godine, odnosno 4,28% tokom 2015. godine.

Struktura sektora finansijskih usluga u BiH prikazana je u tabeli 9.

Tabela 9: Struktura finansijskog sektora BiH (2006 – 2015)

- % -

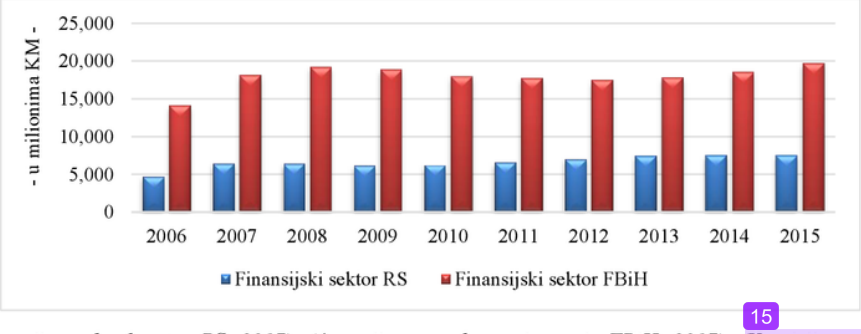
FINANSIJSKE INSTITUCIJE	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Komercijalne banke	80,69	79,90	80,82	82,07	84,34	86,04	86,32	87,14	87,35	87,47
Investicioni fondovi	8,23	7,16	4,82	3,52	3,70	3,29	3,23	3,00	3,02	3,06
Osiguravajuća društva	3,75	3,46	3,45	3,72	3,86	4,43	4,77	4,86	5,19	5,38
Mikrokreditne organizacije	2,77	3,72	4,70	4,33	3,53	3,09	2,77	2,65	2,47	2,35
Lizing Društva	4,56	5,76	6,21	6,36	4,57	3,15	2,91	2,36	1,97	1,74
UKUPNO ZA SEKTOR	**100,00**	**100,00**	**100,00**	**100,00**	**100,00**	**100,00**	**100,00**	**100,00**	**100,00**	**100,00**

Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017), (Komisija za hartije od vrijednosti RS, 2017), (Komisija za vrijednosne papire FBiH, 2017), (Agencija za osiguranje RS, 2017), (Agencija za nadzor osiguranja FBiH, 2017)

Podaci u tabeli prikazuju strukturu finansijskog sektora BiH u periodu od 2006. do kraja 2015. godine. Najveće učešće u ovom sektoru imaju komercijalne banke, čija aktiva čini preko 80% ukupne aktive finansijskog sektora. Na početku analiziranog perioda, 2006. godine, udio komercijalnih banaka iznosio je 80,69%, a učešće ostalih finansijskih institucija iznosilo je 19,31%. Sljedeće, 2007. godine, udio komercijalnih banaka je smanjen, a udio ostalih finansijskih institucija je povećan. Od 2008. godine udio komercijalnih banaka u finansijskom sektoru kontinuirano je rastao, i na kraju 2015. godine iznosio je 87,47%. Za razliku od komercijalnih banaka čiji je udio u finansijskom sektoru rastao tokom analiziranog perioda, udio investicionih fondova se smanjivao – 2006. godine njihovo učešće bilo je 8,23%, a na kraju 2015. godine 3,06%. Učešće društava za osiguranje i reosiguranje u finansijskom sektoru BiH je veoma malo, s obzirom na značaj ovog sektora kao institucionalnog investitora. Učešće mikrokreditnih organizacija je, tokom analiziranog desetogodišnjeg perioda, bilo ispod 5%. Učešće lizing društava u aktivi finansijskog sektora se mijenjalo iz godine u godinu, ali je na kraju analiziranog perioda, odnosno na kraju 2015. godine bilo najmanje i iznosilo je 1,74%.

Analizom strukture finansijskog sektora BiH može se zaključiti da u njemu dominiraju komercijalne banke, a ostale finansijske institucije imaju skoro zanemarljivo učešće. U nastavku dat je pregled finansijskog sektora RS i finansijskog sektora FBiH, odnosno aktive ova dva sektora (grafikon 2) i njihova struktura (grafikon 3 i 4).

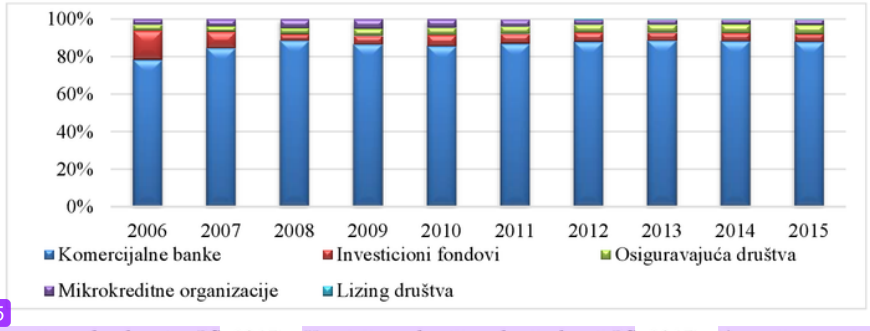
Grafikon 2: Aktiva finansijskog sektora RS i aktiva finansijskog sektora FBiH (2006 – 2015)



Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za nadzor osiguranja FBiH, 2017), (Komisija za hartije od vrijednosti RS, 2017), (Komisija za vrijednosne papire FBiH, 2017), (Agencija za osiguranje RS, 2017), (Agencija za nadzor osiguranja FBiH, 2017)

Na osnovu grafičkog prikaza može se zaključiti da finansijski sektor FBiH ima dominantno učešće u aktivi sektora finansijskih usluga u BiH. U desetogodišnjem analiziranom periodu, aktiva sektora u RS ne doštiže ni 30% ukupne aktive finansijskog sektora BiH, ali uglavnom ima trend rasta (izuzetak su samo 2009. i 2015. godina). Istovremeno, aktiva sektora u FBiH uvijek je činila više od 70% ukupne aktive finansijskog sektora BiH i rasla je tokom 2007., 2008., 2010., 2013. i 2015. godine, a opadala tokom 2009., 2011., 2012. i 2014. godine. Najmanji udio finansijskog sektora RS (24,74%) zabilježen je 2010. godine, a istovremeno, zabilježen je i najveći udio finansijskog sektora FBiH (75,26%), dok je 2013. godine zabilježen najveći udio finansijskog sektora RS (29,54%), a najmanji finansijskog sektora FBiH (70,46%).

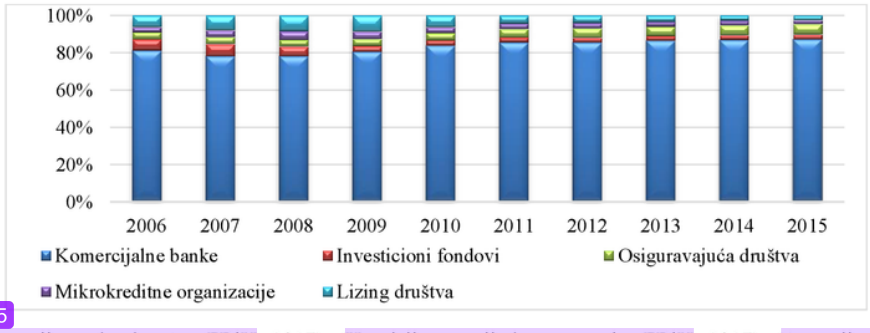
Grafikon 3: Struktura finansijskog sektora RS (2006 – 2015)



Izvor: (Agencija za bankarstvo RS, 2017), (Komisija za hartije od vrijednosti RS, 2017), (Agencija za osiguranje RS, 2017)

Grafikonom 3 prikazana je struktura finansijskog sektora RS u kome komercijalne banke imaju dominantnu ulogu jer imaju više od 80% udjela u ukupnoj aktivi finansijskog sektora RS, a uloga lizing društava skoro je potpuno zanemarljiva (udio lizing društava je manji od 0,5%). Najmanji udio komercijalnih banaka u ukupnoj aktivi finansijskog sektora RS je zabilježen 2006. godine (78,42%), a najveći 2008. godine (88,49%). Ovako visok udio komercijalnih banaka ukazuje na bankocentričnost finansijkog sektora RS, te stabilnost cjelokupnog sektora u najvećoj mjeri zavisi od poslovanja komercijalnih banaka. Na početku analiziranog perioda, odnosno 2006. godine, učešće investicionih fondova je iznosilo 15,42% i značajno je smanjeno u narednih deset godina, tako da je na kraju 2015. godine iznosilo 4,06%. Ukoliko se uzme u obzir značaj koji društava za osiguranje i reosiguranje imaju u razvijenim zemljama svijeta, njihovo učešće u finansijskom sektoru RS je jako malo (ispod 5%), ali je primjetan njihov blagi rast u posljednjih osam godina. I mikrokreditne organizacije malim dijelom učeštvuju u aktivi finansijskog sektora RS - najmanji udio zabilježen je 2012. godine (2,56%), a najveći 2009. godine (5,12%). Zanimljivo je da su lizing društva u RS počela da posluju tek 2010. godine, ali još uvijek nisu zauzela značajno mjesto u finansijskom sektoru, jer je njihovo učešće na kraju 2015. godine iznosilo samo 0,13% ukupne aktive finansijskog sektora RS.

Grafikon 4: Struktura finansijskog sektora FBiH (2006 – 2015)



Izvor: (Agencija za bankarstvo FBiH, 2017), (Komisija za vrijednosne papire FBiH, 2017), (Agencija za nadzor osiguranja FBiH, 2017)

Grafikon 4 prikazuje strukturu finansijskog sektora FBiH koji je po strukturi veoma sličan finansijskom sektoru RS jer se oba sektora sastoje od komercijalnih banaka, investicionih fondova, društava za osiguranje i reosiguranje, mikrokreditnih organizacija i lizing društava. I u FBiH dominantno je učešće komercijalnih banaka, sa preko 78%, ali je nešto manje od učešća komercijalnih banaka u finansijskom sektoru RS. Učešće investicionih fondova, društava za osiguranje i reosiguranje i mikrokreditnih organizacija je slično kao i u finansijskom sektoru RS. Do 2010. godine učešće lizing društava u ukupnoj aktivi finansijskog sektora BiH bilo je iznad 6%, a sve se odnosilo na lizing društva koja posluju u FBiH, jer u tom periodu lizing društva nisu poslovala na teritoriji RS. Od 2010. godine smanjuje se učešće lizing društava i u FBiH i na kraju 2015. godine iznosilo je samo 2,36%.

Na kraju, može se konstatovati da se aktiva finansijskog sektora BiH uglavnom povećavala u periodu od 2006. do kraja 2015. godine, sa izuzetkom u 2009. i 2010. godini kada je zabilježen blagi pad. Otprilike, tri četvrtine ukupne aktive finansijskog sektora BiH se odnosi na finansijski sektor FBiH, a preostala četvrtina na finansijski sektor RS. Po strukturi, finansijski sektori u RS i FBiH su veoma slični. Dominantan udio u oba sektora imaju komercijalne banke, a udio ostalih finansijskih institucija je skoro zanemarljiv. Najmanji udio u aktivi finansijskog sektora BiH imaju lizing društva, a društva za osiguranje i reosiguranje bilježe blagi rast iz godine u godinu. S obzirom na činjenicu da komercijalne banke imaju veoma značajnu ulogu u finansijskom sektoru, odnosno na finansijskom tržištu BiH, bankarskom sektoru BiH je posvećena posebna pažnja.

2. BANKARSKI SEKTOR BOSNE I HERCEGOVINE

2.1. Reforma bankarskog sistema Bosne i Hercegovine

Današnja BiH je država koja je nastala na dijelu teritorije bivše Socijalističke Federativne Republike Jugoslavije (SFRJ). SFRJ je pripadala grupi socijalističkih zemalja, odnosno, bila je država sa dominantno planskom ekonomijom sa obrisima tržišne ekonomije. Finansijski sistem bivše SFRJ je težio da se približi finansijskim sistemima Zapadne Evrope, međutim, zbog konflikata koji su izbili, te reforme nikad nisu implementirane. Nakon raspada SFRJ i odvajanja njenih republika, počele su reforme bankarskih sistema. Tokom rata (period od 1992. do 1995. godine) ekonomija Bosne i Hercegovine je pretrpila ogromne štete, a to je ostavilo posljedice po ukupan ekonomski, a samim tim i bankarski sistem BiH. To potvrđuje i Pehar koji navodi da su „karakteristike bosanskohercegovačkog političkog, pravnog i ekonomskog sistema devedesetih godina direktan rezultat naslijeđa socijalističko-ekonomskog okruženja u kome je egzistirala, kao i dugotrajnih ratnih sukoba" (Pehar, 2010, str. 1).

Nakon završetka ratnih sukoba u BiH došao je period velikih reformi finansijskog sistema, a strategija razvoja je bila okrenuta ka pokretanju proizvodnje. Bankarski sistem BiH nije bio dovoljno razvijen jer je BiH spadala u najnerazvijenije republike bivše SFRJ. Stanje u nerazvijenom bankarskom sistemu BiH je dodatno pogoršano za vrijeme ratnih dešavanja i činilo se da se ovaj bankarski sistem nikada neće oporaviti. Ipak, BiH je, nakon potpisivanja Dejtonskog mirovnog sporazuma 1995. godine, uspjela zauzeti pravac privrednog rasta.

Nakon potpisivanja pomenutog sporazuma, u BiH je uspostavljen novi monetarni sistem, direktno Ustavom. Na osnovu Ustava, donešen je Zakon[4] po kome je osnovana Centralna banka Bosne i Hercegovine (CBBiH), koja radi po sistemu valutnog odbora. Uvođenje sistema valutnog odbora u BiH je bila velika monetarna promjena, kako sa ekonomskog, tako i sa sociopsihološkog aspekta, a ovaj model pokazao je visok stepen uspješnosti funkcionisanja u svim ekonomijama. Valutni odbor ima i pozitivne i negativne strane, tako da ne treba tražiti rješenje za zadržavanje ovog sistema, nego izlazne strategije u ekonomskim promjenama koje bi obezbijedile kredibilitet sistema do faze njegovog napuštanja.

Bankarski sektor BiH nastao je od banaka bivšeg socijalističkog sistema koje su prerasle u banke sa državnim vlasništvom, filijala ranijih udruženih banaka, te od novoosnovanih banaka sa privatnim vlasništvom. Na početku tranzicije bankarski sektor je imao veliki broj banaka u odnosu na ekonomsku snagu zemlje, veliku koncentraciju aktive u malom broju banaka, negativan kapital banaka, većinsko državno vlasništvo (preko 80%), klasičnu strukturu bankarskih proizvoda i usluga (uglavnom kreditiranje), veliki iznos nekvalitetnih kredita (preko tri četvrtine ukupnih kredita), veliki udio neaktivne i nekamatonosne aktive u ukupnoj aktivi (preko 80%), veliki iznos obaveza po osnovu deviznih depozita stanovništva i ino obaveza, veliki uticaj političke vlasti na poslovanje i gubitke u poslovanju banaka (Vilendečić, 2008, str. 240). Naslijeđene karakteristike su zahtijevale hitne reforme, a prije svega kreiranje pravnog okvira, a zatim i privatizaciju banaka i uvođenje savremenih metoda poslovanja. Ovim reformama postignuti su dobri rezultati u bankarskom sektoru, a samim tim i u finansijskom sektoru BiH.

[4] Zakon o Centralnoj banci Bosne i Hercegovine koji je stupio na snagu 11.08.1997. godine

Zahvaljujući reformi bankarskog sektora, privatizaciji državnog kapitala u bankama, ustanovljavanju efikasnog sistema nadziranja i kontrole poslovanja banaka, uspješnom preuzimanju platnog prometa u zemlji od strane banaka[5], uspostavljanju sistema osiguranja depozita banaka, uvođenju novih bankarskih proizvoda, novih metoda upravljanja i savremenih tehnologija u rad banaka vraćeno je povjerenje građana u poslovne banke u BiH, a to je privuklo i niz drugih pozitivnih efekata, tako da su se performanse bankarskog sektora poboljšale, a sektor je ostvario pozitivne rezultate. Danas, bankarski sektor predstavlja najznačajniji finansijski sektor u BiH, a trenutno ima 32 komercijalne banke (CBBiH, 2017).

2.2. Institucionalni okvir

Bankarski sektor BiH sastoji se od Bankarskog sektora Republike Srpske i Bankarskog sektora Federacije Bosne i Hercegovine. N[illegible] državnom nivou, bankarski sektor je regulisan Zakonom o centralnoj banci BiH (Zakon o Centralnoj banci Bosne i Hercegovine, 1997) i Zakonom o osiguranju depozita (Zakon o osiguranju depozita, 2002). Nadzor nad bankarskim sektorom RS vrši Agencija za bankarstvo Republike Srpske, a nadzor nad bankarskim sektorom FBiH Agencija za bankarstvo FBiH. Važno je spomenuti činjenicu da su entitetske regulative koje se odnose na poslovanje banaka harmonizovane i nadzor se obavlja prema istim standardima. Bankarski sistemi obavlja[illegible]unkciju unutarbankarskog i međubankarskog platnog prometa i imaju značajnu ulogu u sprječavanju pranja novca i finansiranja terorističkih aktivnosti. Komercijalne banke iz oba sektora posluju bez ograničenja u cijeloj BiH i kontinuirano unapređuju i modernizuju svoje poslovanje sa ciljem prilagođavanja proizvoda i usluga potrebama klijenata.

Centralna banka Bosne i Hercegovine (CBBiH), koja je osnovana sredinom 1997. godine, počela je sa radom 11.08.1997. godine i od tada ima glavnu ulogu u bankarskom sistemu BiH. CBBiH je kreator monetarnog sistema i odgov[illegible]a je za efikasno sprovođenje monetarne politike u zemlji. Osnovni zadatak CBBiH jeste održavanje monetarne stabilnosti u skladu sa aranžmanom valutnog odbora. Ako se pogleda poslovanje C[illegible]BiH, može se zaključiti da je ona postigla značajne rezultate. Kozarić smatra da je CBBiH u potpunosti izvršila jednu od svojih osnovnih funkcija jer je postigla i očuvala unutrašnju stabilnost domaće valute, a vanjska stabilnost je obezbjeđena uspješnim održavanjem fiksnog deviznog kursa, te redovnim servisiranjem vanjskog duga BiH koji je CBBiH obavljala u ulozi fiskalnog agenta" (Kozarić, 2007, str. 13).

2.3. Komercijalne banke u Bosni i Hercegovini

U Godišnjem izvještaju CBBiH za 2000. godinu navodi se da BiH nema efikasan i djelotvoran bankarski sistem, uz obrazloženje „bankarski sistem u BiH je još uvijek relativno slab i iscepkan i igra samo ograničenu ulogu u ekonomiji, s obzirom na to da je nivo štednje koju stanovništvo drži u bankama nizak, a krediti koje odobravaju banke za finansiranje biznisa ili privatnog sektora također su niski" (CBBiH, 2001, str. 14).

[5] U BiH je 2001. godine unutrašnji platni promet, prema posebnom projektu kojim je rukovodio Međunarodni Monetarni fond, prenešen iz stare Službe društvenog knjigovodstva (SDK) u poslovne banke.

Iako navedeno daje jednu veoma pesimističnu sliku, u nastavku je navedeno da se ova slika počela mijenjati u 2000. godini. Čini se da je 2000. godina bila veoma značajna i uspješna za bankarski sektor jer je platni sistem fundamentalno reformisan, Vlada RS je usvojila amandman na svoj Zakon o bankama čime je otvorila mogućnost banci koja je ovlaštena u jednom entitetu BiH da otvori filijalu u drugom entitetu, većina banaka u državnom vlasništvu je ušla u fazu privatizacije, odnovana je Agencija za osiguranje depozita u FBiH, a i veći broj stranih banaka je počeo sa radom u BiH tako što su direktno podnijele zahtjev za izdavanje dozvole za rad ili kupujući akcije u već postojećoj banci. U tom periodu, ulazak stranih banaka na finansijsko tržište BiH trebao je da pruži deponentima i primaocima kredita veći izbor, a i da primora lokalne banke da unaprijede asortiman i kvalitet bankarskih usluga koje nude. U bankarskom sektoru BiH tokom 2000. godine poslovalo je ukupno 55 komercijalnih banaka.

Bankarski sektor BiH se rapidno razvijao u narednih pet godina, broj banaka se smanjio usljed konsolisacije, a ukupna aktiva se povećala. U godišnjem izvještaju za 2005. godinu navodi se da bankarski sektor zauzima 81% cjelokupne aktive finansijskog sektora i da „prednjači u oblasti modernizacije sektora, naprednog menadžmenta, pokrivenosti teritorije i uvođenju novih proizvoda“ (CBBiH, 2006, str. 66). Na kraju 2015. godine u bankarskom sektoru BiH poslovalo je ukupno 26 komercijalnih banaka. U nastavku je dat pregled broja komercijalnih banaka, vlasničke strukture i ljudskih resursa koji su zaposleni u bankarskom sektoru BiH. Ti podaci prikazaće strukturu bankarskog sektora BiH i stvoriti jasniju sliku o njegovom razvoju.

2.3.1. Broj komercijalnih banaka

Bankarski sektor BiH se sastoji od komercijalnih banaka koje, bez ikakvih ograničenja, posluju na cjelokupnoj teritoriji BiH. Komercijalne banke čije je sjedište u RS, preko svojih organizacionih dijelova, posluju na teritoriji FBiH, i obrnuto, banke čije je sjedište u FBiH posluju na teritoriji RS. Pregled broja komercijalnih banaka koje su poslovale u BiH, odnosno u RS i FBiH, u periodu od 2006. do kraja 2015. godine, dat je u tabeli 10.

Tabela 10: Broj komercijalnih banaka u BiH (2006 – 2015)

ENTITET	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Republika Srpska	9	10	10	10	10	10	10	10	9	9
Federacija BiH	23	22	20	20	19	19	18	17	17	17
Ukupno BiH	**32**	**32**	**30**	**30**	**29**	**29**	**28**	**27**	**26**	**26**

Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017)

Analiza strukture bankarskog sektora BiH, tokom desetogodišnjeg perioda, pokazala je smanjenje broja komercijalnih banaka. Na početku analiziranog perioda, 2006. godine, poslovale su 32 komercijalne banke (9 banaka u RS i 23 banke u FBiH), a 2015. godine poslovalo ih je ukupno 26 (9 banaka u RS i 17 banaka u FBiH). U analiziranom periodu došlo je do spajanja i ukidanja nekih banaka, a nove banke su ulazile na tržište BiH.

Promjene u broju komercijalnih banaka izraženije su u bankarskom sektoru FBiH, nego u bankarskom sektoru RS. Tokom 2006. godine u RS 9 komercijalnih banaka je imalo dozvolu za rad, a u FBiH 23. Sljedeće godine, bankarski sektor RS je postao bogatiji za jednu banku, tako da ih je bilo ukupno 10 i taj broj se zadržao do kraja 2013. godine. Istovremeno, broj komercijalnih banaka u FBiH se smanjivao, a na kraju 2013. godine bilo ih je ukupno 17. U 2014. godini smanjen je broj komercijalnih banaka u RS, a broj banaka u FBiH je ostao isti, tako da je poslovalo ukupno 26 banaka u BiH. Taj broj se nije mijenjao do kraja 2015. godine.

Sa ciljem što kvalitetnijeg pružanja bankarskih usluga i povećanjem profita, komercijalne banke su širile mrežu poslovnih jedinica. U periodu od 2006. do 2009. godine banke su intenzivno širile svoje mreže organizacionih dijelova[6], nakon toga nastupa period blagog širenja, a od 2014. godine stagnacija. Banke su, usljed uticaja globalne finansijske krize, vršile reorganizaciju mreže organizacionih dijelova tako što su spajale i ukidale neke organizacione dijelove. Krajem 2006. godine 32 komercijalne banke su imale ukupno 866 organizacionih dijelova, a krajem 2015. godine 26 komercijalnih banaka imalo je ukupno 980 organizacionih dijelova.

2.3.2. Vlasnička struktura komercijalnih banaka

Ukoliko se komercijalne banke dijele prema kriterijumu vlasništva nad akcionarskim kapitalom, onda u BiH posluju komercijalne banke koju su u državnim i pretežno državnom vlasništvu i komercijalne banke koje su u privatnom i pretežno privatnom vlasništvu. Struktura vlasništva nad bankama u BiH prikazana je u tabeli 11.

Tabela 11: Vlasnička struktura komercijalnih banaka u BiH (2006 – 2015)

VLASNIŠTVO	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Državno vlasništvo	5	3	2	2	1	1	1	2	2	2
Privatno vlasništvo	27	29	28	28	28	28	27	25	24	24
Ukupno banaka u BiH	**32**	**32**	**30**	**30**	**29**	**29**	**28**	**27**	**26**	**26**

Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017)

Analiza strukture vlasništva nad komercijalnim bankama u BiH, prema kriterijumu vlasništva nad akcionarskim kapitalom, pokazuje da vlasničku strukturu karakteriše privatno vlasništvo, a dominantno je učešće stranog privatnog kapitala. Tokom 2006. godine pet komercijalnih banaka u BiH bilo je u državnom ili pretežno državnom vlasništvu, pet godina kasnije samo jedna, a na kraju 2015. godine dvije. U istom periodu, većina komercijalnih banaka bila je u privatnom, odnosno pretežno privatnom vlasništvu. Uporedo sa smanjenjem broja komercijalnih banaka koje su poslovale u BiH, smanjivao se i broj banaka u državnom i pretežno državnom vlasništvu.

[6] Organizacioni dijelovi banke obuhvataju filijale (osnovne poslovne jedinice) i niže organizacione dijelove (koji zavise od filijala), kao što su ekspoziture, šalteri, agencije i slično. Oni nemaju svojstvo pravnog lica, a obavljaju sve poslove ili dio poslova koje može obavljati banka.

U nastavku je dat pregled vlasničke strukture komercijalnih banaka u entitetima BiH, odnosno u RS (tabela 12) i FBiH (tabela 14). Pored broja banaka koje su u državnom, odnosno privatnom vlasništvu, dat je i pregled učešća državnog i privatnog kapitala u akcionarskom kapitalu komercijalnih banaka u RS (tabela 13) i FBiH (tabela 15), čime se dobija jasna slika o vlasničkoj strukturi kapitala u bankarskom sektoru BiH.

Tabela 12: Vlasnička struktura komercijalnih banaka u RS (2006 – 2015)

VLASNIŠTVO	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Državno vlasništvo	0	0	0	0	0	0	0	1	1	1
Privatno vlasništvo	9	10	10	10	10	10	10	9	8	8
Ukupno banaka u RS	**9**	**10**	**10**	**10**	**10**	**10**	**10**	**10**	**9**	**9**

Izvor: (Agencija za bankarstvo RS, 2017)

Tabela 13: Učešće državnog i privatnog kapitala u akcionarskom kapitalu banaka u RS (2006 - 2015)

- % -

VLASNIŠTVO	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Državno vlasništvo	1	1	1	0	2	2	2	7	7	6
Privatno vlasništvo	99	99	99	100	98	98	98	93	93	94
Ukupan kapital RS	**100**	**100**	**100**	**100**	**100**	**100**	**100**	**100**	**100**	**100**

Izvor: (Agencija za bankarstvo RS, 2017)

Podaci pokazuju da do 2013. godine u bankarskom sektoru RS nije bilo banaka koje su u državnom i pretežno državnom vlasništvu, a država je imala skoro zanemarljiv udio (1% u 2006., 2007. i 2008. godini, odnosno 2% u 2010., 2011. i 2012. godini) u ukupnom akcionarskom kapitalu komercijalnih banaka u RS. U 2013. godini devet banaka je bilo u privatnom, a jedna banka u državnom vlasništvu, tako da su se i udjeli privatnog i državnog vlasništva u ukupnom akcionarskom kapitalu promijenili (udio komercijalnih banaka koje su u privatnom vlasništvu je 93%, a udio komercijalnih banaka koje su u vlasništvu države je 3%). Tokom 2014. godine došlo je do smanjenja broja banaka, tako da je osam banaka bilo u privatnom (93%), a jedna banka u državnom vlasništvu (7%). Tokom 2015. godine nije bilo promjena u broju banaka, ali se udio privatnog i državnog kapitala u ukupnom akcionarskom kapitalu promijenio. Na kraju 2015. godine, u RS je poslovalo osam banaka koje su u privatnom vlasništvu (94%) i jedna banka koja je u vlasništvu države (4%).

Na kraju, može se konstatovati da je za bankarski sektor RS karakteristična dominacija stranog privatnog vlasništva, a učešće banke sa državnim kapitalom je malo i nema veliki uticaj na bankarski sektor u cjelini. Dominantno mjesto u vlasničkoj strukturi ima Austrija sa učešćem od oko 47% i većinskim vlasništvom u tri banke.

Tabela 14: Vlasnička struktura komercijalnih banaka u FBiH (2006 – 2015)

VLASNIŠTVO	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Državno vlasništvo	5	3	2	2	1	1	1	1	1	1
Privatno vlasništvo	18	19	18	18	18	18	17	16	16	16
Ukupno banaka u FBiH	**23**	**22**	**20**	**20**	**19**	**19**	**18**	**17**	**17**	**17**

Izvor: (Agencija za bankarstvo FBiH, 2017)

Tabela 15: Učešće državnog i privatnog kapitala u akcionarskom kapitalu banaka u FBiH (2006 - 2015)

- % -

VLASNIŠTVO	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Državno vlasništvo	22	14	10	10	5,3	5,3	5,6	5,9	5,9	5,9
Privatno vlasništvo	78	86	90	90	94,7	94,7	94,4	94,1	94,1	94,1
Ukupan kapital FBiH	**100**	**100**	**100**	**100**	**100**	**100**	**100**	**100**	**100**	**100**

Izvor: (Agencija za bankarstvo FBiH, 2017)

Analiza vlasničke strukture akcionarskog kapitala komercijalnih banaka najbolje prikazuje promjene strukture vlasnika u bankarskom sektoru FBiH. Za razliku od bankarskog sektora RS, u kome sve do 2013. godine nije bilo banaka koje su u državnom vlasništvu, bankarski sektor FBiH je 2006. godine imao čak 6 banaka koje su u državnom vlasništvu (22% ukupnog akcionarskog kapitala bilo je u vlasništvu države) i 18 banaka u privatnom vlasništvu. Već sljedeće godine dolazi do promjene broja banaka, pa su na kraju 2007. godine poslovale 3 banke koje su u državnom vlasništvu (14% ukupnog akcionarskog kapitala) i 19 banaka koje su u privatnom vlasništvu (86% ukupnog akcionarskog kapitala). U 2008. godini broj banaka u bankarskom sektoru FBiH se smanjuje, tako da ih je bilo ukupno 20, pri čemu su 2 banke bile u državnom vlasništvu (10% ukupnog akcionarskog kapitala) i 18 u privatnom vlasništvu (90% ukupnog akcionarskog kapitala). Tokom 2009. godine nisu zabilježene promjene u vlasničkoj strukturi komercijalnih banaka u FBiH, ali već 2010. godine smanjen je broj banaka koje su u državnom vlasništvu. Od 2010. godine pa do kraja 2015. godine poslovala je jedna banka koja je bila u državnom vlasništvu (oko 5% ukupnog akcionarskog kapitala), a broj banaka koje su u privatnom vlasništvu se mijenjao. Na kraju 2015. godine u privatnom i pretežno privatnom vlasništvu je bilo 13 banaka (oko 95% ukupnog akcionarskog kapitala), a taj broj se nije mijenjao od 2013. godine.

Vlasnička struktura bankarskog sektora FBiH se, na prvi pogled, razlikuje od vlasničke strukture bankarskog sektora RS. Međutim, činjenica je da je u oba sektora dominantno učešće stranog privatnog kapitala, tako da se vlasnička struktura ipak mnogo ne razlikuje. Bankarski sektor RS i bankarski sektor FBiH se razlikuju po broju banaka koje su u državnom i pretežno državnom vlasništvu. Na kraju 2015. godine po jedna banka u RS i FBiH je bila u državnom vlasništvu, ali je tržišni udio banke u državnom vlasništvu bio duplo veći u FBiH (u FBiH iznosio je 16%, a u RS 8%).

2.4.3. Ljudski resursi u komercijalnim bankama

Komercijalne banke ne mogu uspješno poslovati bez kvalitetnih kadrova koji su u njima zaposleni. U bankarskom sektoru FBiH posluje više banaka nego u bankarskom sektoru RS, tako da komercijalne banke u FBiH imaju više zaposlenih. Broj zaposlenih u komercijalnim bankama u BiH, po entitetima, prikazan je u tabeli 16.

Tabela 16: Broj zaposlenih u bankarskom sektoru BiH (2006 – 2015)

ENTITET	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Republika Srpska	2.558	2.849	3.063	2.939	2.933	2.993	3.206	3.306	3.213	3.236
Federacija BiH	6.606	7.361	7.997	7.656	7.388	7.369	7.130	7.051	6.960	6.683
Ukupno BiH	**9.164**	**10.210**	**11.060**	**10.595**	**10.321**	**10.362**	**10.336**	**10.357**	**10.173**	**9.919**

Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017)

Analiza podataka koji prikazuju broj zaposlenih u bankarskom sektoru BiH pokazuje da bankarski sektor FBiH broji više zaposlenih od bankarskog sektora RS. U bankarskom sektoru BiH, tokom 2006. godine zaposlena su bila 9.164 radnika, a u 2007. i 2008. godini broj zaposlenih je povećan za 1.046 ili 10,2%, odnosno 850 ili 7,7%, respektivno. Racionalizacija i smanjenje broja zaposlenih posebno su došli do izražaja tokom 2009. godine kada je smanjen broj radnika za 465 ili 4,4%. I u 2010. godini smanjen je broj radnika za 274 ili 2,7%, a tokom 2011. godine dolazi do blagog povećanja broja radnika za 41 ili 0,4%. Dalje, tokom 2012. godine došlo je do blagog smanjenja broja radnika za 26 ili 0,3%, a već u sljedećoj godini do blagog povećanja radnika za 21 ili 0,2%. Tokom 2014. i 2015. godine smanjen je broj zaposlenih za 184 ili 1,8%, odnosno, 254 ili 2,6%. Iako se broj zaposlenih u bankarskom sektoru BiH naizmjenično povećavao i smanjivao, na kraju 2015. godine zaposleno je bilo ukupno 9.919 radnika, odnosno 755 ili 7,6% radnika više nego u 2006. godini.

Ukoliko se posmatra samo bankarski sektor RS, može se primijetiti da je broj zaposlenih uglavnom rastao, a izuzetak su 2009. i 2014. godina u kojima se broj zaposlenih smanjio. Tokom 2006. godine zaposleno je bilo 9.164 radnika, a 2007. godine broj radnika se povećao za 291 ili 10,2%, dok se 2008. broj zaposlenih povećao za 214 ili 7%. Globalna finansijska kriza negativno je uticala i na bankarski sektor RS, pa je tokom 2009. godine broj zaposlenih smanjen za 124 ili 4,2%, a u 2010. godini broj radnika se smanjio za 6 ili 0,2%. Od 2011. godine pa sve do kraja 2013. godine broj zaposlenih se povećavao (u 2011. godini za 60 ili 2%, u 2012. godini za 213 ili 6,6%, a u 2013. godini za 100 ili 3%), a 2014. godine je došlo do blagog smanjenja broja radnika za 93 ili 2,8%. Tokom 2015. godine broj zaposlenih se blago povećao za 23 ili za 0,71%. Na kraju, može se konstatovati da se broj zaposlenih, uprkos navedenim smanjenjima, povećao za 678 ili 21% u odnosu na 2006. godinu.

Za razliku od bankarskog sektora RS, u kome je broj zaposlenih uglavnom imao trend rasta, u bankarskom sektoru FBiH broj zaposlenih se smanjivao. Od 2006. godine, kada je bilo zaposleno 6.606 radnika, do kraja 2008. godine zabilježeno je povećanje broja zaposlenih, i to u 2007. godini za 755 ili 10,3%, a u 2008. godini za 636 ili 8%. Globalna finansijska kriza negativno je uticala i na bankarski setor FBiH, pa je tokom 2009. godine broj zaposlenih smanjen za 341 ili 4,5%. I u narednom periodu broj zaposlenih se kontinuirano smanjuje, jer su banke, zbog dugogodišnjeg negativnog uticaja ekonomske krize, preduzele mjere u cilju racionalizacije poslovanja. U 2010. godini broj zaposlenih je smanjen za 268 ili 3,6%, u 2011. godini zabilježeno je blago smanjenje za 19 ili 0,3%, a već u 2012. godini broj zaposlenih je značajno smanjen za 239 ili 3,4%. U 2013. godini smanjen je broj zaposlenih, i to za 79 ili 1,1%, a u 2014. godini za 91 ili 1,3%. Na kraju 2015. godine zaposleno je bilo 6.683 radnika, odnosno 277 ili 4,1% radnika manje nego u 2014. godini, odnosno 77 ili 1,2% radnika više nego u 2006. godini.

Sumirajući prethodno navedeno, može se naglasiti da se broj zaposlenih u bankarskom sektoru BiH mijenjao tokom analiziranog. Uprkos tome, na kraju 2015. godine bilo je 7,6% više zaposlenih nego u 2006. godini. Ukoliko se posmatra kretanje zaposlenih u komercijalnim bankama entiteta, može se primijetiti da se broj zaposlenih povećao i u RS i u FBiH. Ipak, u bankarskom sektoru RS zabilježeno je značajno povećanje od 21% u periodu od 2006. do kraja 2015. godine, a istovremeno, povećanje zaposlenih u bankarskom sektoru FBiH iznosilo je 1,2%.

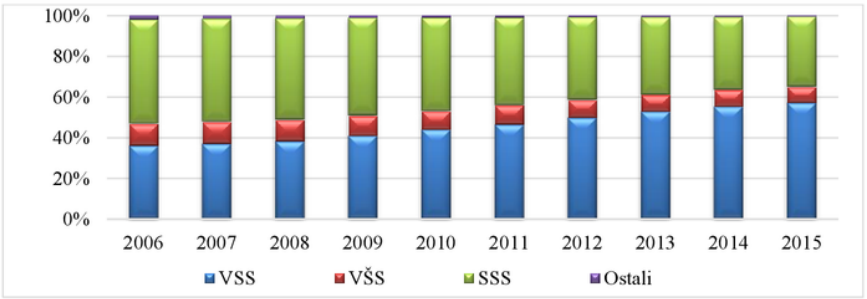
Kvalifikaciona struktura zaposlenih u bankarskom sektoru BiH prikazana je u tabeli 17, a učešće pojedinih kvaklifikacija jasno se vidi na grafikonu 5.

Tabela 17: Kvalifikaciona struktura zaposlenih u bankarskom sektoru BiH (2006 – 2015)

STRUČNA SPREMA	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
VSS	3.319	3.791	4.245	4.339	4.538	4.838	5.155	5.473	5.632	5.673
VŠS	990	1.103	1.164	1.045	949	975	914	864	837	780
SSS	4.696	5.175	5.512	5.096	4.735	4.465	4.195	3.958	3.651	3.424
Ostali	159	141	139	115	99	84	72	62	53	42
Ukupno BiH	**9.164**	**10.210**	**11.060**	**10.595**	**10.321**	**10.362**	**10.336**	**10.357**	**10.173**	**9.919**

Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017)

Grafikon 5: Kvalifikaciona struktura zaposlenih u bankarskom sektoru BiH (2006 – 2015)



Izvor: (Agencija za bankarstvo RS, 2017), (Agencija za bankarstvo FBiH, 2017)

Na osnovu analize podataka koji su predstavljeni tabelarno i grafički može se zaključiti da je prisutan dugogodišnji trend poboljšanja kvalifikacione strukture zaposlenih. Najveće promjene, u analiziranom periodu, uočljive su kod zaposlenih sa srednjom i visokom stručnom spremom. Tokom 2006. godine, najbrojniji su bili zaposleni sa srednjom stručnom spremom (51,24%), a za njima zaposleni sa visokom stručnom spremom (36,22%). Na kraju 2015. godine, najbrojniji su bili zaposleni sa visokom stručnom spremom (57,19%), a zatim zaposleni sa srednjom stručnom spremom (34,52%). Porast zaposlenih koji imaju visoku stručnu spremu je pozitivan trend, ukoliko se to posmatra sa stanovišta kontinuiranog razvoja i unapređivanja bankarskog sektora, a istovremeno je i posljedica velike ponude nezaposlenih radnika tog profila, tako da dio poslova srednje stručne spreme obavlja kadar sa visokom stručnom spremom. Od 2009. godine primjetno je smanjenje broja zaposlenih sa višom stručnom spremom, a kad se pogleda povećanje broja kadrova sa visokom stručnom spremom, može se zaključiti da se određeni dio radnika posvetio dodatnom obrazovanju i usavršavanju.

3. FINANSIJSKI POKAZATELJI POSLOVANJA BANKARSKOG SEKTORA BOSNE I HERCEGOVINE

Nadzor i kontrolu finansijskog stanja i stabilnosti poslovanja komericijalnih banaka u BiH obavljaju agencije za bankarstvo koje vrše kontrolu na licu mjesta i analiziraju izvještaje koje im banke dostavljaju. Komercijalne banke i druge finansijske institucije dostavljaju izvještaje Agenciji za bankarstvo RS i Agenciji za bankarstvo FBiH, a ti izvještaji čine bazu podataka. Agencije za bankarstvo analiziraju izvještaje koje im dostavljaju komercijalne banke i kvartalno objavljuju informacije o stanju u bankarskom sistemu RS i FBiH. CBBiH objavljuje Godišnji izvještaj i Izvještaj o finansijskoj stabilnosti, u kojima su objedinjene informacije entitetskih agencija.

U FBiH, prema Zakonu o početnom bilansu stanja banaka, banke sa većinskim državnim kapitalom imaju obavezu da izvještavaju Agenciju za bankarstvo FBiH na bazi „punog" bilansa stanja raščlanjenog na pasivni, neutralni i aktivni podbilans, a državne banke u „punom" bilansu iskazuju pasivne i neutralne stavke, koje će po izvršenju programa privatizacije preuzeti država (Agencija za bankarstvo FBiH, 2007, str. 14).

Sa ciljem pojačanog nadzora nad poslovanjem banaka i praćenja tekuće likvidnosti, Agencija za bankarstvo RS je privremeno uvela dodatne izvještajne zahtjeve. Oni su uvedeni 2009. godine, prvenstveno zbog uticaja globalne finansijske krize na bankarski sektor RS, a uključuju: dnevni izvještaj o stanju i valutnoj strukturi novčanih sredstava, dnevni izvještaj o štednji građana, mjesečni izvještaj o sektorskoj i ročnoj strukturi kredita, mjesečni izvještaj o sektorskoj i ročnoj strukturi depozita i mjesečni izvještaj o ročnoj usklađenosti finansijske aktive i pasive (Agencija za bankarstvo RS, 2010, str. 12).

3.1. Struktura bilansa banaka

Komercijalne banke, kao i sve ostale finansijske institucije, moraju da sastavljaju finansijske izvještaje za poslovnu godinu, sa uporednim podacima za prethodnu godinu. Dva osnovna finansijska izvještaja, koja su mjerilo uspješnosti poslovanja menadžmentu banke, klijentima i zakonodavnim organima, su bilans stanja i bilans uspjeha. Između ova dva bilansa postoji uska povezanost jer je bilans uspjeha rezultat politike i efekata bilansa stanja, a i finansijski rezultat, koji je prikazan u bilansu uspjeha, unosi se u bilans stanja preduzeća.

Bilans stanja banke daje sliku o njenim finansijskim pozicijama, odnosno daje sliku o sredstvima u aktivi i obevezama u pasivi, kao i o kapitalu kao posebnom obliku izvora sredstava. Konsolidovani bilans komercijalnih banaka u BiH daje sliku finansijskog položaja bankarskog sektora na kraju poslovne godine. Podaci za period od 2006. do kraja 2015. godine su bazirani na aktivnom podbilansu banaka s većinskim državnim kapitalom iz FBiH, pri čemu je isključen pasivni podbilans. U procesu privatizacije, pasivni podbilans će preuzeti Ministarstvo finansija FBiH, kao što je već urađeno kod prethodno privatizovanih banaka. Pasivni podbilans sadrži obaveze po inostranim kreditima i staroj deviznoj štednji građana do 31.03.1992. godine, tako da ne oslikava aktuelno poslovanje banaka. Izvršena revizija u većoj mjeri je uticala na smanjenje kredita javnim preduzećima u stranoj valuti, smanjenje strane pasive i smanjenje ostalih stavki aktive i pasive po osnovu stare devizne štednje.

Aktiva bankarskog sektora BiH prikazana je u tabeli 18.

Tabela 18: Konsolidovani bilans komercijalnih banaka u BiH (2006 – 2015) - AKTIVA
- u milionima KM-

AKTIVA								
Godina	Rezerve	Strana aktiva	Potraživanja od generalne vlade	Potraživanja od nefinansijskih javnih preduzeća	Potraživanja od nefinansijskih privatnih preduzeća	Potraživanja od ostalih finansijskih institucija	Potraživanja od ostalih domaćih sektora	UKUPNO
1	2	3	4	5	6	7	8	9 = 2 +...+ 8
2006	3.063,6	2.356,1	69,8	248,3	4.086,1	89,4	4.448,9	**14.362,2**
2007	4.022,9	3.558,6	127,5	271,3	5.315,7	159,6	5.791,7	**19.247,3**
2008	3.393,3	3.106,1	265,5	256,4	6.751,6	169,2	6.802,8	**20.744,9**
2009	3.632,0	3.190,3	355,5	268,2	6.682,5	103,0	6.409,8	**20.641,1**
2010	3.679,8	2.814,2	465,4	351,3	6.965,5	80,2	6.423,0	**20.779,3**
2011	3.469,7	2.724,5	904,7	360,2	7.166,9	94,0	6.768,9	**21.488,9**
2012	3.370,4	2.507,8	1.236,2	390,9	7.473,1	73,7	6.873,3	**21.925,4**
2013	3.843,7	2.637,3	1.379,4	451,6	7.556,4	67,4	7.131,8	**23.067,7**
2014	4.115,0	2.626,3	1.854,5	443,6	7.452,0	61,3	7.501,7	**24.054,3**
2015	4.511,7	2.471,0	2.133,3	400,0	7.478,9	74,6	7.874,7	**24.944,2**

Izvor: (CBBiH, 2016, str. 120)

Analizom aktive komercijalnih banaka u BiH utvrđen je njen kontinuirani rast, sa izuzetkom 2009. godine u kojoj je, usljed uticaja globalne finansijske krize, aktiva bankarskog sektora malo smanjena. Aktiva bankarskog sektora BiH je, na kraju 2006. godine, iznosila 14,36 milijardi KM, a već u sljedećoj godini povećana je za 13,11 milijardi KM, odnosno za 34,01%. Aktiva bankarskog sektora povećana je i tokom 2008. godine i to za 1,5 milijardu KM, odnosno za 7,78%, tako da je iznosila 20,74 milijardi KM. Usljed globalne finansijske krize koja je pogodila i ekonomiju u BiH, tokom 2009. godine aktiva bankarskog sektora smanjena je na 20,64 milijardi KM, odnosno za 0,5%. Od 2010. godine aktiva komercijalnih banaka u BiH je kontinuirano rasla, pa je na kraju 2010. godine iznosila 20,78 milijardi KM, što je za 0,7% više nego u prethodnoj godini. U 2011. godini povećana je aktiva bankarskog sektora za 3,41%, u 2012. godini za 2,03%, dok je tokom 2013. godine povećana za 5,21% u odnosu na prethodnu godinu. I u 2014. godini je zabilježeno povećanje aktive za 4,28%. Trend rasta aktive bankarskog sektora, koji je počeo 2010. godine, nastavljen je i dalje, pa je na kraju 2015. godine aktiva iznosila 24,94 milijarde KM, što je za 0,89 milijardi KM ili 3,67% više nego u 2014. godini, a 10,59 milijardi KM ili 73,68% više nego u 2006. godini.

Analiza aktive komercijalnih banaka u BiH pokazala je da se strana aktiva uglavnom smanjivala u analiziranom desetogodišnjem periodu, a istovremeno, domaća aktiva se povećavala. Strana aktiva bilježi rast samo tokom 2009. i 2013. godine. Najveće učešće u ukupnoj aktivi bankarskog sektora BiH imaju potraživanja od ostalih domaćih sektora i od nefinansijskih privatnih preduzeća. Od 2006. do 2015. godine zabilježen je porast potraživanja od generalne vlade, nefinansijskih javnih i privatnih preduzeća. Tokom analiziranog perioda nije bilo značajnih promjena u strukturi aktive, zabilježeno je samo povećanje učešća potraživanja nefinansijskih javnih preduzeća i smanjenje učešća potraživanja od generalne vlade, dok su sve ostale stavke aktive ostale na približno istom nivou.

Tokom 2015. godine stupili su na snagu novi regulatorni propisi u Evropskoj uniji kojim je uređeno poslovanje i nadzor banaka, a prema njima, i BiH podliježe pravilu da matične banke moraju da izdvajaju kapitalne rezerve za sredstva koja njihovi supsidijari drže na računu kod CBBiH. U skladu sa tim, moglo se očekivati da komercijalne banke, koje su u većinskom vlasništvu stranih grupacija, smanje sredstva koja drže na računu rezervi i višak sredstava usmjere u investicije sa većim prinosom. Ipak, takve promjene se nisu desile zbog izostanka jačih kreditnih aktivnosti u zemlji, regulatornih propisa o likvidnosti i internih politika bankarskih grupacija o koncentraciji rizika (to se prvenstveno odnosi na domaće dužničke hartije od vrijednosti).

Pasiva bankarskog sektora BiH prikazana je u tabeli 19.

Tabela 19: Konsolidovani bilans komercijalnih banaka u BiH (2006 – 2015) - PASIVA

- u milionima KM-

PASIVA											
Godina	Depoziti centralne vlade	Prenosivi depoziti drugih domaćih sektora u domaćoj valuti	Prenosivi depoziti drugih domaćih sektora u stranoj valuti	Ostali depoziti drugih domaćih sektora u domaćoj valuti	Ostali depoziti drugih domaćih sektora u stranoj valuti	Hartije od vrijednosti	Krediti	Strana pasiva	Akcije i drugi kapital	Ostale stavke (neto)	UKUPNO
1	2	3	4	5	6	7	8	9	10	11	12=2+...11
2006	853,3	2.751,0	691,3	1.365,4	3.105,4	0,0	114,0	3.695,4	1.596,3	190,2	**14.362,2**
2007	2.335,0	2.534,4	833,8	1.726,5	3.661,1	5,2	106,1	4.817,5	1.968,6	259,1	**19.247,3**
2008	1.749,7	3.381,4	1.107,2	1.776,2	3.864,7	17,9	264,3	5.999,0	2.271,6	312,9	**20.744,9**
2009	1.397,9	3.530,3	1.078,0	1.844,3	4.241,0	13,6	446,7	5.386,1	2.319,4	383,9	**20.641,1**
2010	1.121,7	3.680,5	1.209,8	1.991,0	4.526,4	9,1	595,1	4.395,7	2.508,4	741,7	**20.779,3**
2011	955,7	3.807,9	1.100,1	2.285,7	4.846,1	0,0	675,3	3.778,6	3.045,1	994,3	**21.488,9**
2012	847,2	3.714,8	1.052,9	2.672,7	5.041,4	0,0	712,4	3.558,6	3.191,3	1.134,1	**21.925,4**
2013	717,8	4.137,4	1.189,3	3.006,3	5.202,4	0,0	707,9	3.329,9	3.348,9	1.427,8	**23.067,7**
2014	981,3	4.458,2	1.301,2	3.377,3	5.280,0	0,0	681,0	2.960,0	3.408,5	1.606,8	**24.054,3**
2015	1.014,1	5.073,9	1.360,4	3.562,6	5.543,3	8,0	599,2	2.613,3	3.586,4	1.583,1	**24.944,2**

Izvor: (CBBiH, 2016, str. 120)

Uporedo sa rastom (padom) aktive komercijalnih banaka u BiH rasla je (opadala) i pasiva, koja daje sliku o izvorima sredstava koja su predstavljena u aktivi. Analizom pasive bilansa stanja komercijalnih banaka u BiH može se uočiti da je učešće depozita u ukupnoj aktivi najveće, dok najmanje učešće imaju hartije od vrijednosti. Takođe, dominantno je učešće domaće pasive, iako je strana pasiva zabilježila značajan rast u periodu od 2006. do 2009. godine. Interesantna je činjenica da u 2006. godini, a i u periodu od 2011. do kraja 2014. godine u pasivi komercijalnih banaka u BiH nije bilo hartija od vrijednosti. Analizom se može uočiti da skoro sve vrste depozita (osim depozita centralne vlade), imaju trend rasta u periodu od 2006. do kraja 2015. godine.

Takođe, kapital komercijalnih banaka se kontinuirano povećavao, pa je tokom analiziranog perioda povećan za 1,99 milijardu KM ili 124,67%. U prvih pet godina kapital je povećan za 0,91 milijardu KM ili 57,14%, a u narednih pet godina povećan je za 1,08 milijardu KM ili 42,98%. Povećanje kapitala komercijalnih banaka koje posluju u BiH pozitivno je uticalo na stabilnost bankarskog sektora.

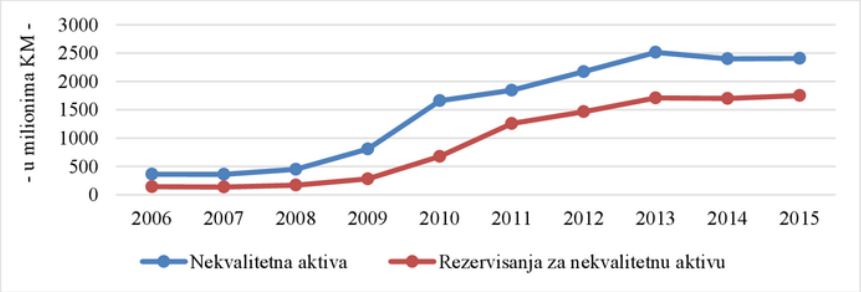
Na osnovu datih podataka, zaključuje se da u strukturi pasive bankarskog sektora BiH nije bilo značajnijih oscilacija, a zabilježeno je kontinuirano smanjenje učešća strane pasive, blago povećanje učešća akcija i drugog kapitala i ostalih stavki (neto), dok je učešće ostalih stavki bilo na približno istom nivou tokom analiziranog desetogodišnjeg perioda.

3.2. Kvalitet aktive komercijalnih banaka

Kvalitet aktive banaka i izdvojene rezerve za nekvalitetnu aktivu predstavljaju veoma važne pokazatelje stabilnosti banaka i uspješnosti njihovog poslovanja. Po pravilu, nekvalitetna aktiva je ona koja ne donosi prihode. Prema Metodologiji za kompiliranje indikatora finansijskog zdravlja CBBiH, „nekvalitetnom aktivom tretiraju se stavke aktive kada su glavnica i/ili kamata dospjele i nisu naplaćene duže od 90 dana od dana njihovog inicijalno ugovorenog dospjeća, odnosno kada su klasifikovane u kategorije C, D i E ili kada su obaveze korisnika po kamati, za koje je dužnik (korisnik) zakasnio s plaćanjem duže od 90 dana od njihovog inicijalno ugovorenog dospjeća, kapitalizovane“ (CBBIH, 2017, str. 8). Prema istoj metodologiji „rezerve za nekvalitetnu aktivu predstavljaju rezerve koje je banka dužna da formira za stavke aktive i stavke vanbilansa koje su izložene riziku naplate, odnosno riziku mogućih gubitaka po datim kreditima, drugim plasmanima, izvršenim ulaganjima i potencijalnim vanbilansnim obavezama, i to pojedinačno po svakom korisniku, odnosno grupi povezanih lica“ (CBBIH, 2017, str. 8).

Nekvalitetna aktiva i rezervisanja za nekvalitetnu aktivu u bankarskom sektoru BiH prikazani su grafikonom 6.

Grafikon 6: Nekvalitetna aktiva i rezervisanja za nekvalitetnu aktivu u BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

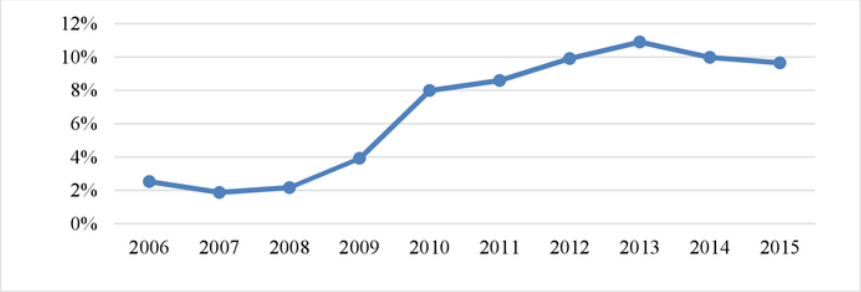
Predstavljeni podaci pokazuju trend kretanja nekvalitetne aktive komercijalnih banaka BiH i rezervisanja koja su banke izdvojile za nekvalitetnu aktivu. Analizom podataka može se uočiti da se nekvalitetna aktiva uglavnom povećavala u periodu od 2006. do kraja 2015. godine, sa izuzetkom 2007. i 2014. godine, tokom kojih je zabilježeno blago smanjenje u odnosu na 2006., odnosno 2013. godinu. Rezervisanja za nekvalitetnu aktivu su se mijenjala u skladu sa promjenom nekvalitetne aktive, tako da se iznos rezervi smanjio u toku 2007. i 2013. godine, a u svim ostalim godinama zabilježen je rast u odnosu na prethodnu godinu.

Najveći dio nekvalitetne aktive (preko 90%) se odnosi na nekvalitetne kredite, odnosno kredite čiji korisnici kasne sa otplatom. Nekvalitetni krediti negativno utiču na kvalitet kreditnog portfolia banaka. Već je rečeno da postoje različite definicije nekvalitetnih kredita, a definicija koja se koristi u BiH data je u prvom dijelu.

Na kraju 2015. godine većina sistemski važnih banaka imala je učešće nekvalitetnih u ukupnim kreditima ispod prosjeka bankarskog sektora. Ipak, dvije sistemski važne banke, iz iste grupacije, imale su visoko učešće nekvalitetnih u ukupnim kreditima pa su se susretale sa problemima u poslovanju. U 2015. godini u ovim bankama došlo je do povećanja učešća nekvalitetnih u ukupnim kreditima, prvenstveno zbog pogoršanja kvaliteta postojećeg kreditnog portfolia, ali i zbog izostanka većeg obima kreditnih aktivnosti. Sredinom 2015. godine završen je proces reprivatizacije ovih banaka, promjenjena je poslovna politika kroz fokusiranost na određeni segment bankarskog tržišta, pa bi se mogao očekivati rast plasmana i bolje pozicioniranje banke na tržištu. Pošto se radi o sistemski važnim bankama, ove promjene bi pozitivno uticale na kvalitet aktive bankarskog sektora, ali i na finansijsku stabilnost u BiH. Kod manjih banaka, visok nivo nekvalitetnih u ukupnim kreditima posljedica je neadekvatnih kreditnih politika i lošeg upravljanja kreditnim rizikom.

Učešće nekvalitetne aktive u ukupnoj aktivi bankarskog sektora BiH prikazano je grafikonom 7.

Grafikon 7: Učešće nekvalitete u ukupnoj aktivi bankarskog sektora BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Na kraju 2006. godine nekvalitetna aktiva činila je 2,52% ukupne aktive komercijalnih banaka u BiH. Tokom 2007. godine kvalitet aktive komercijalnih banaka je poboljšan, tako da je nekvalitetna aktiva činila 1,87% ukupne aktive. Već u narednoj, 2008. godini neto aktiva je blago povećana, pa je učešće u ukupnoj aktivi iznosilo 2,16%. Od 2009. godine pa sve do kraja 2013. godine kvalitet aktive komercijalnih banaka u BiH se pogoršavao zbog rasta nenaplativih potraživanja. Na kraju 2009. godine učešće nekvalitetne u ukupnoj aktivi iznosilo je 3,91%, a u 2010. godini nekvalitetna aktiva je značajno povećana tako da je njeno učešće iznosilo 7,99%. Na kraju 2011. godine nekvalitetna aktiva činila je 8,59%, a na kraju 2012. godine 9,91% ukupne aktive. Trend rasta nekvalitetne aktive nastavljen je i tokom 2013. godine. Kvalitet aktive poboljšan je tokom 2014. godine, tako da je udio nekvalitetne u ukupnoj aktivi smanjen sa 10,90% u 2013. godini na 9,98%. Već u narednoj godini, kvalitet aktive blago je pogoršan pa je na kraju 2015. godine učešće nekvalitetne u ukupnoj aktivi iznosilo 9,65%.

Udio nekvalitetne u ukupnoj aktivi komercijalnih banaka prilično je visok, a to je rezultat visokog nivoa nekvalitetnih kredita u portfoliu banaka i nepostojanja adekvatnog rješenja za ovaj problem. Ovako visok udio nekvalitetnih kredita u aktivi komercijalnih banaka je posljedica globalne finansijske krize. Pogoršanje kvaliteta aktive komercijalnih banaka posebno je izraženo od 2009. godine. Razvoj bankarskog sektora BiH u narednom periodu zavisiće u velikoj mjeri od spremnosti velikih evropskih banakarskih grupacija da kreditiraju domaću privredu i sektor stanovništva. Takođe, zavisiće i od načina rješavanja problema nekvalitetnih kredita i od konkretnih mjera domaćih nadležnih institucija.

3.3. Kapital komercijalnih banaka

S obzirom na činjenicu da komercijalne banke u BiH imaju visok udio nekvalitetnih u ukupnim kreditima, onda one moraju biti sposobne da apsorbuju gubitke. Pokazatelj sposobnosti banke da apsorbuje gubitke koji su nastali usljed nekvalitetnih kredita jeste koeficijent adekvatnosti kapitala koji predstavlja odnos neto kapitala i ukupnog rizika aktive. Osnovnim kapitalom banke, koji je zakonski definisan, mjeri se maksimalna izloženost banke kreditnom i ostalim rizicima, a ovaj kapital u svakom trenutku mora biti raspoloživ za apsorbovanje gubitaka i svih obaveza banke. Ukupan rizik aktive predstavlja zbir rizika aktive bilansa i vanbilansa, ponderisanog operativnog rizika i ponderisanog tržišnog rizika. Minimalna propisana vrijednost koeficijenta adekvatnosti kapitala u BiH iznosi 12%.

Osnovni kapital, neto kapital i ukupan rizik aktive komercijalnih banaka u BiH predstavljeni su u tabeli 20. Na osnovu navedenih podataka obračunat je koeficijent adekvatnosti kapitala bankarskog sektora BiH.

Tabela 20: Osnovni kapital, neto kapital i ukupan rizik aktive bankarskog sektora BiH (2006 - 2015)

- u milionima KM -

GODINA	OSNOVNI KAPITAL	NETO KAPITAL	UKUPAN RIZIK AKTIVE
2006	1.429,63	1.860,79	10.498,77
2007	1.725,65	2.345,12	13.698,59
2008	1.950,02	2.637,41	16.245,07
2009	2.038,55	2.642,82	16.450,33
2010	2.133,92	2.730,08	16.882,10
2011	2.246,42	2.826,38	16.555,18
2012	2.327,59	2.821,35	16.551,67
2013	2.556,87	2.994,86	16.783,74
2014	2.441,75	2.767,53	17.021,31
2015	2.415,81	2.608,80	17.555,18

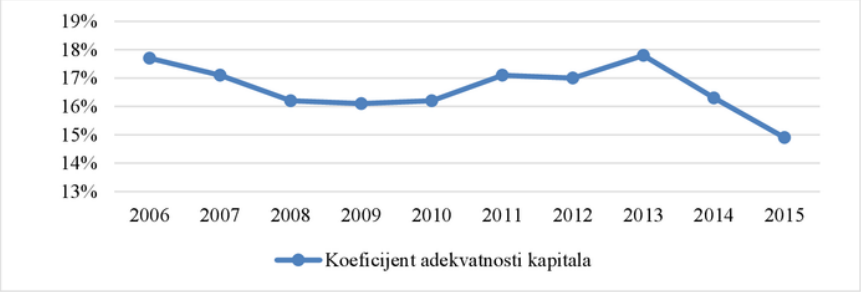
Izvor: (CBBiH, 2017)

Na osnovu predstavljenih podataka koje je objavila CBBiH, vidi se da osnovni kapital bankarskog sektora BiH ima trend rasta u periodu od 2006. do kraja 2013. godine, dok je tokom 2014. i 2015. godine osnovni kapital blago smanjen. Na početku analiziranog perioda, osnovni kapital bankarskog sektora iznosio je 1,43 milijardi KM, a nakon sedmogodišnjeg rasta na kraju 2013. godine 2,55 milijardi KM. Na kraju 2015. godine osnovni kapital iznosio je 2,41 milijardu KM, što je za 986,18 miliona KM ili 68,9% više nego u 2006. godini.

Uporedo sa promjenama osnovnog kapitala, mijenjao se i neto kapital komercijalnih banaka koje posluju u BiH. Neto kapital bankarskog sektora BiH je, na kraju 2006. godine, iznosio 1,86 milijardi KM, a nakon kontinuiranog rasta koji je trajao sve do kraja 2013. godine povećan je za 1,13 milijardi KM, odnosno za 60,9%. Tokom 2014. godine neto kapital bankarskog sektora BiH smanjen je za 7,6% u odnosu na 2013. godinu, a tokom 2015. godine za 5,7% u odnosu na 2014. godinu. Na kraju 2015. godine neto kapital bankarskog sektora BiH iznosio je 2,60 milijardi KM, odnosno 748,01 miliona KM ili 40,2% više nego u 2006. godini.

Koeficijent adekvatnosti kapitala bankarskog sektora BiH, u desetogodišnjem periodu koji je analiziran, prikazan je grafikonom 8.

Grafikon 8: Koeficijent adekvatnosti kapitala bankarskog sektora BiH (2006 – 2015)



Izvor: Obračun autora na osnovu podataka koji su predstavljeni u tabeli 20

Predstavljeni podaci pokazuju trend kretanja koeficijenta adekvatnosti kapitala bankarskog sektora BiH. Može se konstatovati da se vrijednost ovog koeficijenta smanjivala od 2006. do kraja 2009. godine, tako da je sa 17,7% (vrijednost na kraju 2006. godine) smanjena na 16,1% (vrijednost na kraju 2009. godine). Tokom 2010. i 2011. godine koeficijent adekvatnosti kapitala bankarskog sektora BiH je povećan, a tokom 2012. godine zabilježeno je blago smanjenje njegove vrijednosti. Na kraju 2013. godine koeficijent adekvatnosti kapitala iznosio je 17,8%, što je ujedno i njegova maksimalna vrijednost koja je zabilježena tokom analiziranog perioda. U naredne dvije godine zabilježeno je značajno smanjenje koeficijenta adekvatnosti kapitala koji je iznosio 16,3% na kraju 2014., odnosno 14,9% na kraju 2015. godine. To je ujedno i minimalna vrijednost koja je zabilježena tokom analiziranog perioda.

Navedeni podaci pokazuju da se, uprkos povremenim smanjenima, osnovni kapital bankarskog sektora BiH povećao u periodu od 2008. do kraja 2015. godine. Uporedo sa povećanjem (smanjenjem) osnovnog kapitala povećavao se (smanjivao) i neto kapital, tako da je i on povećan tokom istog perioda. Važno je napomenuti da je povećanje kapitala bankarskog sektora BiH, koje je zabilježeno na kraju 2008. godine, rezultat dokapitalizacije komercijalnih banaka. Tokom analiziranog perioda zabilježene su i značajne promjene koeficijenta adekvatnosti kapitala koji je na kraju 2015. godine iznosio 14,9%, što je za 2,8% manje nego na kraju 2006. godine. Smanjenje stope adekvatnosti kapitala nije dobro za bankarski sektor BiH jer je on najbolji pokazatelj sposobnosti komercijalnih banaka da apsorbuju gubitke koji nastaju zbog nekvalitetnih kredita u kreditnom portfoliu. Ipak, tokom analiziranog desetogodišnjeg perioda koeficijent adekvatnosti kapitala bio je iznad zakonski propisanog minimuma koji iznosi 12%.

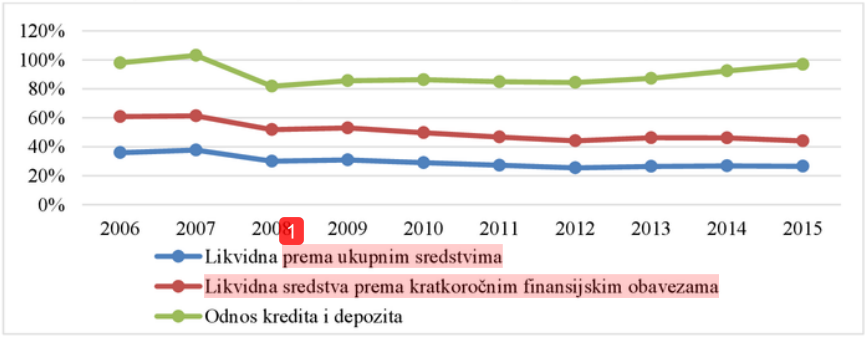
3.4. Likvidnost komercijalnih banaka

Održavanje likvidnosti i upravljanje rizikom likvidnosti je veoma složen i važan zadatak komercijalnih banaka, a samim tim i bankarskog sektora u cjelini. Upravo od kvaliteta upravljanja rizikom likvidnosti i sposobnosti održavanja likvidne pozicije zavisi stabilnost poslovanja komercijalnih banaka, izgradnja povjerenja kod klijenata i njihova tržišna pozicija. Zbog uticaja globalne finansijske krize, fokus komercijalnih banaka u BiH je usmjeren na strogo držanje pod kontrolom tekuće likvidnosti, ali i na povećanje stepena opreznosti kod planiranja buduće pozicije likvidnosti u uslovima povećanog broja nekvalitetnih kredita, odnosno u uslovima pogoršanja kvaliteta aktive. Iako je provođenje politike likvidnosti na menadžmentu banke i organima koji upravljaju bankom, značajan uticaj na likvidnost banaka ima i strogo postavljeni regulatorni okvir za održavanje i planiranje likvidnosti.

Dva osnovna pokazatelja likvidnosti bankarskog sektora BiH su pokazatelj odnosa likvidnih prema ukupnim sredstvima i pokazatelj odnosa likvidnih sredstava prema kratkoročnim finansijskim obavezama. Pored osnovnih pokazatelja, u bankarskom sektoru BiH se koriste i dva dodatna, i to pokazatelj kratkoročnih finansijskih obeveza prema ukupnim finansijskim obavezama i pokazatelj depozita prema kreditima.

Navedeni pokazatelji likvidnosti bankarskog sektora BiH, u periodu od 2006. do kraja 2015. godine, prikazani su grafikonom 9.

Grafikon 9: Pokazatelji likvidnosti bankarskog sektora BiH (2006 - 2015)



Izvor: (CBBiH, 2017)

Na osnovu analize pokazatelja koji su predstavljeni grafikonom, može se konstatovati da je likvidnost bankarskog sektora bila na zadovoljavajućem nivou u periodu od 2006. do kraja 2015. godine, te da su komercijalne banke bile sposobne da izmiruju svoje obaveze o roku dospjeća. Ipak, vrijednosti pokazatelja likvidnosti komercijalnih banaka su, na kraju 2015. godine, bile znatno niže nego na kraju 2006. godine. U periodu od 2006. do kraja 2009. godine pokazatelji likvidnosti bili su na visokom nivou, tako da je udio likvidnih u ukupnim sredstvima bio iznad 30%, a odnos likvidnih sredstava prema kratkoročnim finansijskim obavezama iznad 50%. Od 2009. godine pokazatelji likvidnosti imaju trend pada, tako da je, na kraju 2015. godine pokazatelj odnosa likvidnih prema ukupnim sredstvima iznosio 26,5%, a pokazatelj odnosa likvidnih sredstava prema kratkoročnim finansijskim obavezama 44,0%.

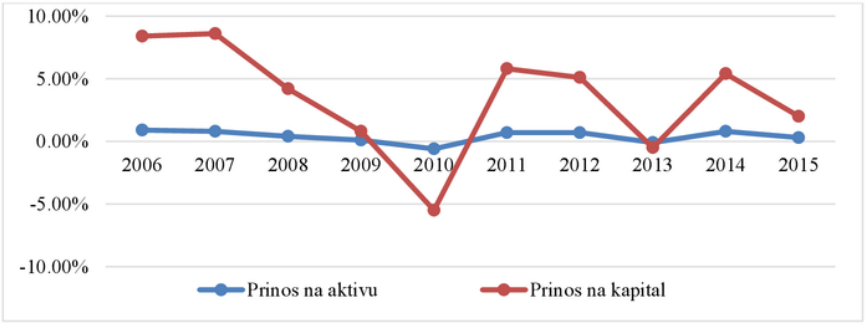
Rezultati sprovedenih istraživanja o faktorima koji utiču na nekvalitetne kredite pokazuju da odnos kredita i depozita ima uticaj na pojavu i rast nekvalitetnih kredita, tako da je i ovaj pokazatelj veoma važan za dalje istraživanje. Odnos kredita i depozita, koji pokazuje koliko je banka sposobna da depozitima podrži rast kreditnog portfolia, bio je približno isti na početku i na kraju analiziranog perioda (na kraju 2006. godine iznosio je 97,9%, a na kraju 2015. godine 96,9%), a u periodu od 2008. do kraja 2013. godine bio je ispod 90%. Uprkos značajnom smanjenju vrijednosti pokazatelja, komercijalne banke u BiH uspjele su da održe likvidnost na zadovoljavajućem nivou.

3.5. Profitabilnost komercijalnih banaka

Zdrav bankarski sistem izgrađen je na profitabilnim i adekvatno kapitalizovanim bankama, a bilans uspjeha banke je ključni izvor podataka o njenoj profitabilnosti. Dva osnovna pokazatelja profitabilnosti su prinos na aktivu i prinos na kapital.

Pokazatelji profitabilnosti bankarskog sektora BiH prikazani su grafikonom 10.

Grafikon 10: Pokazatelji profitabilnosti bankarskog sektora BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Ukupna dobit bankarskog sektora u BiH, na kraju 2006. godine, iznosila je 112,39 miliona KM, a prinos na aktivu iznosio je 0,9% i prinos na kapital 8,4%. Pokazatelji profitabilnosti nisu baš na zavidnom nivou, ali ovako niska vrijednost pokazatelja je karakteristična za zemlje u kojima bankarski sektor ima obilježja komercijalnog bankarstva i koji karakteriše visoka zaduženost, kao što je slučaj u BiH.

Na kraju 2007. godine ukupna neto dobit iznosila je 143,42 miliona KM, što je za 31,03 milion KM, odnosno 26,61% više nego na kraju prethodne godine. Povećanje dobiti ukazivalo je na stabilizaciju komercijalnih banaka, jer u 2007. godini nije bilo banaka sa velikim gubicima. Istovremeno, prinos na aktivu smanjen je za 0,1% u odnosu na 2006., tako da je na kraju godine iznosio 0,8%, a prinos na kapital je povećan za 0,2% i na kraju godine je iznosio 8,6%.

U toku 2008. godine komercijalne banke su ostvarile znatno lošije rezultate, pa je ukupna neto dobit na kraju godine iznosila 81,03 milion KM, odnosno 62,39 miliona KM ili 43,50% manje nego u prethodnoj godini. Prinos na aktivu iznosio je 0,4%, što je duplo manje nego u prethodnoj godini, a prinos na kapital smanjen je za 4,4% i iznosio je 4,2%.

Na kraju 2009. godine neto dobit komercijalnih banaka u BiH iznosila je 18,21 miliona KM, što je za 62,81 miliona KM manje nego u 2008. godini. Ovako loš finansijski rezultat komercijalnih banaka posljedica je uticaja globalne finansijske krize, a čak devet banaka (od ukupno 30) poslovalo je sa gubitkom. I profitabilnost banaka značajno je pogoršana, tako da je prinos na aktivu iznosio 0,1% (0,3% manje nego u 2008. godini), a prinos na kapital 0,8% (3,4% manje nego u 2008. godini).

Najlošiji rezultati poslovanja bankarskog sektora BiH zabilježeni su 2010. godine, u kojoj je ostvaren negativan finansijski rezultat u iznosu od 124,29 miliona KM, što je za 142,50 miliona KM manje nego u prethodnoj godini. Ipak, 23 komercijalne banke su ostvarile dobit, a šest banaka je iskazalo gubitak u poslovanju, tako da bankarski sektor nije bio ozbiljno ugrožen ovako lošim poslovnim rezultatima. Jedna od glavnih karakteristika bankarskog sektora BiH u ovoj godini jeste pad profitabilnosti. Prinos na aktivu iznosio je -0,6%, odnosno 0,7% manje nego u 2009. godini, a prinos na kapital bio je negativan i iznosio je -5,5% što predstavlja smanjenje za 6,3%.

Nakon veoma lošeg finansijskog rezultata koji je zabilježen u 2010. godini, finansijski rezultat u 2011. godini ukazuje na značajno poboljšanje poslovanja komercijalnih banaka u BiH. Na kraju 2011. godine ukupna neto dobit iznosila je 139,55 miliona KM, odnosno 263,84 miliona KM više nego u prethodnoj godini. I pokazatelji profitabilnosti pokazuju značajno poboljšanje, tako da je prinos na aktivu povećan za 1,3% i iznosio je 0,7%, a prinos na kapital povećan je za 11,3% i iznosio je 5,8%.

Bankarski sektor BiH je i u 2012. godini ostvario pozitivan finansijski rezultat koji je iznosio 125,99 miliona KM, odnosno 13,56 miliona KM ili 9,71% manje nego u prethodnoj godini. Istovremeno, pokazatelji profitabilnosti su ostalipribližno isti kao i u prethodnoj godini, tako da je prinos na aktivu iznosio 0,7%, a prinos na kapital 5,1% (za 0,7% manje nego u 2011. godini).

Na kraju sljedeće, 2013. godine, većina komercijalnih banaka iskazala je pozitivan finansijski rezultat, a pet banaka je poslovalo sa gubitkom, tako da je bankarski sektor poslovnu godinu završio sa negativnim finansijsim rezultatom u iznosu od 38,56 miliona KM. Istovremeno, pogoršani su i pokazatelji profitabilnosti, pa je prinos na aktivu iznosio -0,1% (0,8% manje nego u 2012. godini), a prinos na kapital -0,5% (5,6% manje).

Bankarski sektor BiH je 2014. godinu završio sa znatno boljim finansijskim rezultatom, odnosno, neto dobitkom u iznosu od 143,65 miliona KM. Uporedo sa poboljšanjem finansijskog rezultata, poboljšani su i pokazatelji profitabilnosti komercijalnih banaka, pa je prinos na aktivu veći za 0,9% u odnosu na prethodnu godinu, a prinos na kapital veći je za 5,9%.

I sljedeću poslovnu godinu bankarski sektor je završio sa pozitivnim finansijskim rezultatom, a neto dobitak iznosio je 31,63 milion KM. Ostvareni neto dobitak manji je za 112,02 miliona KM od dobitka koji je ostvaren u prethodnoj godini, a lošiji finansijski rezultat uticao je na profitabilnost komercijalnih banaka. Na kraju 2015. godine, prinos na aktivu iznosio je 0,3% i manji je za 0,5% nego u 2014. godini, a prinos na kapital iznosio je 2,0% i manji je za 3,4%.

Analizom profitabilnosti bankarskog sektora BiH utvrđeno je da su se pokazatelji profitabilnosti do kraja 2015. godine znatno pogoršali u odnosu na 2006. godinu. Prinos na aktivu, koji je na kraju 2015. godine iznosio 0,3% smanjen je tri puta, odnosno za 0,6% u odnosu na 2006. godinu u kojoj je iznosio 0,9%. Prinos na kapital iznosio je 2,0% na kraju 2015. godine, a u odnosu na 2006. godinu, u kojoj je iznosio 8,4%, smanjen je za 6,4%. Pokazatelji profitabilnosti imali su negativen predznak na kraju 2010. i 2013. godine, kada je bankarski sektor BiH ostvario negativan finansijski rezultat.

4. DEPOZITNI I KREDITNI POTENCIJAL BANKARSKOG SEKTORA BOSNE I HERCEGOVINE

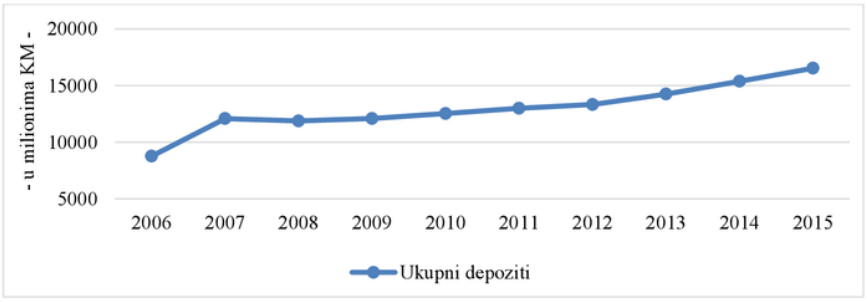
4.1. Depoziti komercijalnih banaka

Depoziti su primarni izvor finansiranja komercijalnih banaka u BiH tako da obim poslovanja, planiranje i vođenje poslovne politike banaka direktno zavise od nivoa, strukture i ročnosti depozita. Ukupni depoziti bankarskog sektora su depoziti svih rezidentnih sektora kod banaka koje su uključene u finansijske aktivnosti, a dijele se na prenosive i ostale depozite (CBBiH, 2016).

Prenosivi depoziti su depoziti koji su raspoloživi na zahtjev bez naknada i ograničenja i mogu se direktno upotrijebiti za plaćanja trećim licima, a uključuju i posebne štedne račune s kojih je dozvoljen prenos sredstava na prenosive depozite, dok ostale depozite čine depoziti koji dozvoljavaju automatsko povlačenje sredstava, ali ne i plaćanje trećim licima, štedni i oročeni depoziti i ostali (CBBiH, 2016, str. 126 - 127).

Trend kretanja ukupnih depozita bankarskog sektora BiH predstavljen je grafikonom 11.

Grafikon 11: Ukupni depoziti bankarskog sektora BiH (2006 – 2015)



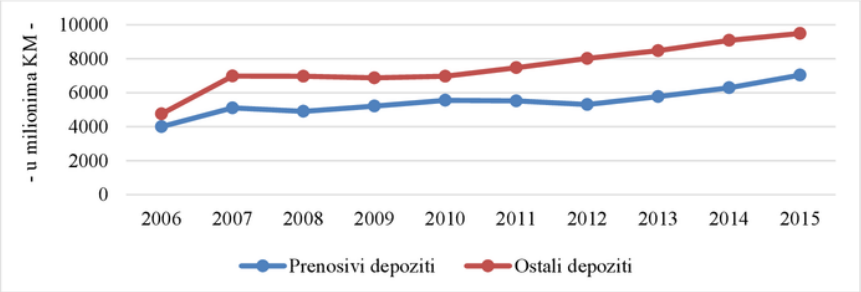
Izvor: (CBBiH, 2017)

Predstavljeni podaci pokazuju da su ukupni depoziti bankarskog sektora BiH imali trend rasta u periodu od 2006. do kraja 2015. godine, sa izuzetkom 2008. godine u kojoj je zabilježeno blago smanjenje. Na kraju 2015. godine ukupni depoziti iznosili su 16,63 milijardi KM, odnosno 7,76 milijardi KM ili 88,65% više nego u 2006. godini kada su iznosili 8,73 milijardi KM. Ovo značajno povećanje depozita ukazuje na činjenicu da je vraćeno povjerenje u komercijalne banke koje posluju na teritoriji BiH.

Kao što je već rečeno, ukupne depozite bankarskog sektora BiH čine prenosivi i ostali depoziti. Ipak, manje učešće u ukupnim depozitima imaju prenosivi depoziti, a veće učešće ostali depoziti. Na kraju 2015. godine prenosivi depoziti činili su 42,58% ukupnih depozita bankarskog sektora BiH (u poređenju sa 2006. godinom, učešće je smanjeno za 3,12%), a ostali depoziti činili su 57,42% ukupnih depozita (u poređenju sa 2006. godinom, učešće je povećano za 3,12%).

Trend kretanja prenosivih i ostalih depozita bankarskog sektora BiH prikazan je grafikonom 12.

Grafikon 12: Prenosivi i ostali depoziti bankarskog sektora BiH (2006 – 2015)



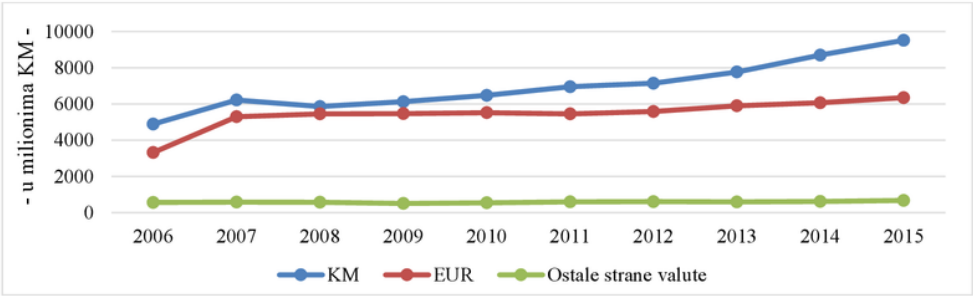
Izvor: (CBBiH, 2017)

Podaci pokazuju da su prenosivi depoziti uglavnom imali trend rasta u analiziranom periodu, sa izuzetkom 2008., 2011. i 2012. godine, kada je zabilježeno njihovo smanjenje. I ostali depoziti su uglavnom imali trend rasta u periodu od 2006. do kraja 2015. godine, sa izuzetkom 2008. i 2009. godine kada je zabilježen njihov pad. Na kraju analiziranog perioda prenosivi depoziti iznosili su 7,03 milijardi KM, odnosno 3,03 milijarde KM ili 75,77% više nego u 2006. godini, kada su iznosili 4,00 milijarde KM, a ostali depoziti su iznosili 9,49 milijardi KM, odnosno 4,73 milijarde KM ili 99,49% više nego u 2006. godini (na kraju 2006. godine iznosili su 4,75 milijarde KM).

Ukupne depozite bankarskog sektora BiH čine depoziti u domaćoj valuti i depoziti u stranoj valuti. Depozite u stranoj valuti uglavnom čine depoziti u evrima, dok se manji dio odnosi na depozite u ostalim stranim valutama.

Valutna struktura depozita prikazana je grafikonom 13.

Grafikon 13: Valutna struktura depozita bankarskog sektora BiH (2006 – 2015)

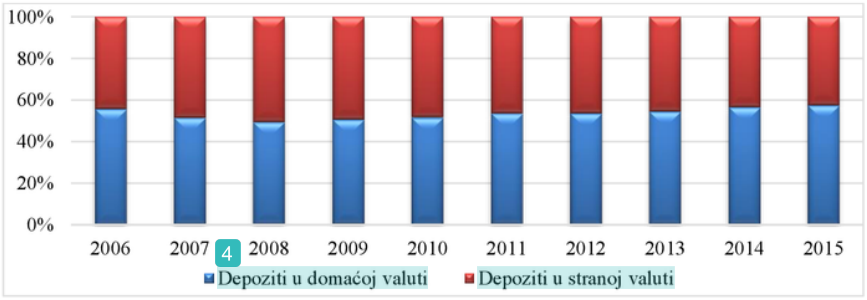


Izvor: (CBBiH, 2017)

Predstavljeni podaci pokazuju da su depoziti u domaćoj valuti (KM) imali trend rasta tokom analiziranog perioda, sa izuzetkom 2008. godine u kojoj su malo smanjeni. Takođe, i depoziti u stranim valutama su uglavnom imali trend rasta, mada su tokom 2007., 2009. i 2011. godine smanjeni u odnosu na prethodnu godinu. Najveći dio depozita u stranoj valuti odnosi se na depozite u evrima koji su, tokom analiziranog desetogodišenjeg perioda imali trend rasta, sa izuzetkom 2011. godine u kojoj je zabilježeno blago smanjenje.

Učešće depozita u domaćoj i stranoj valuti u ukupnim depozitima bankarskog sektora BiH prikazano je grafikonom 14.

Grafikon 14: Učešće depozita u domaćoj i stranoj valuti u ukupnim depozitima (2006 – 2015)



Izvor: (CBBiH, 2017)

Podaci pokazuju da su depoziti u domaćoj valuti imali veće učešće u ukupnim depozitima bankarskog sektora, a izuzetak je samo 2008. godina u kojoj je bilo veće učešće depozita u stranoj valuti. Od 2009. godine učešće depozita u domaćoj valuti kontinuirano se povećavalo, dok se učešće depozita u stranim valutama smanjivalo. Osnovni razlog smanjenja depozita u stranim valutama su veoma niske kamatne stope.

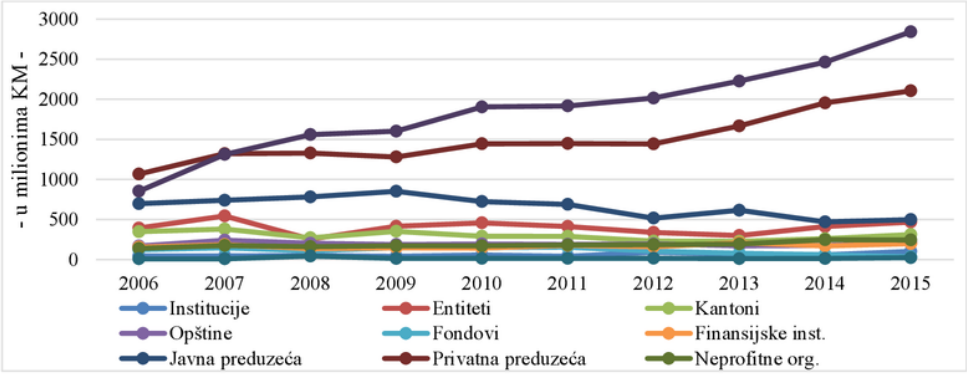
Podaci pokazuju da su ukupni depoziti bankarskog sektora BiH uglavnom imali trend rasta u analiziranom desetogodišnjem periodu. Najveći rast ukupnih depozita bankarskog sektora BiH zabilježen je tokom 2007. godine, a najmanji tokom 2009. godine, kada su povećani samo za 1,83%. Ovako mali rast depozita svakako je posljedica globalne finansijske krize, ali se ipak može zaključiti da kriza nije imala veliki uticaj na štednju u bankarskom sektoru BiH.

4.1.1. Sektorska struktura prenosivih depozita

Kao što je već rečeno, prenosivi depoziti su raspoloživi na zahtjev bez naknada i ograničenja (mogu se direktno upotrijebiti za plaćanja trećim licima) i posebni štedni računi s kojih je dozvoljen prenos sredstava na prenosive depozite, a njih čine depoziti institucija BiH, vlada entiteta, kantona i opština, depoziti fondova socijalne zaštite, depoziti ostalih finansijskih institucija, depoziti nefinansijskih javnih i privatnih preduzeća, depoziti neprofitnih organizacija, depoziti domaćinstava i ostali depoziti (CBBiH, 2016, str. 126).

Sektorska struktura prenosivih depozita bankarskog sektora BiH prikazana je grafikonom 15.

Grafikon 15: Sektorska struktura prenosivih depozita bankarskog sektora BiH (2006 – 2015)



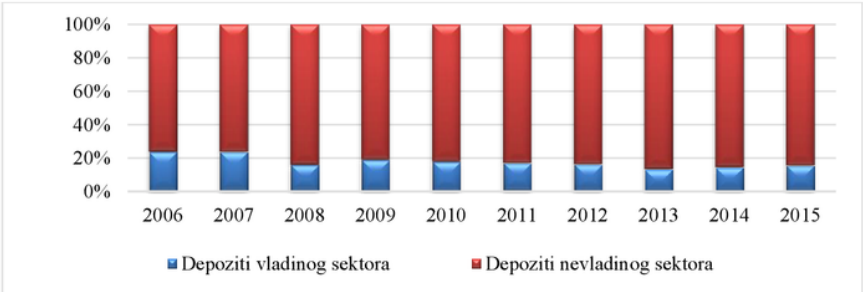
Izvor: (CBBiH, 2017)

Predstavljeni podaci pokazuju da su ukupni depoziti, tokom analiziranog perioda, imali trend rasta, a izuzetak su 2008. i 2012. godina u kojima je zabilježen bladi pad. Depoziti nevladinog sektora su kontinuirano rasli, a izuzetak je 2012. godina u kojoj je zabilježeno smanjenje od 2,94%. Sa druge strane, smanjenje depozita vladinog sektora zabilježeno je na kraju 2008., 2011., 2012. i 2013. godine. Najveće povećanje depozita vladinog sektora zabilježeno je na kraju 2009. godine (rast od 27,44%). Sa druge strane, najveće povećanje depozita nevladinog sektora zabilježeno je na kraju 2007. godine (rast od 27,71%).

Depoziti vladinog sektora su, na kraju 2015. godine, iznosili 1,09 milijardi KM, odnosno 14,17% više nego u 2006. godini. Krajem 2015. godine povećani su depoziti vladinog sektora, a to je prvenstveno rezultat izdavanja trezorskih zapisa i obveznica oba entiteta. Istovremeno, povećani su i depoziti nevladinog sektora, koji su na kraju 2015. godine iznosili 5,94 milijardi KM, odnosno 95,11% više nego u 2006. godini. Značajno povećanje depozita nevladinog sektora je uticalo na rast prenosivih depozit, ali i na rast ukupnih depozita bankarskog sektora BiH.

Učešće depozita vladinog i nevladinog sektora u prenosivim depozitim predstavljeno je grafikonom 16.

Grafikon 16: Prenosivi depoziti vladinog i nevladinog sektora u bankarskom sektoru BiH (2006 – 2015)



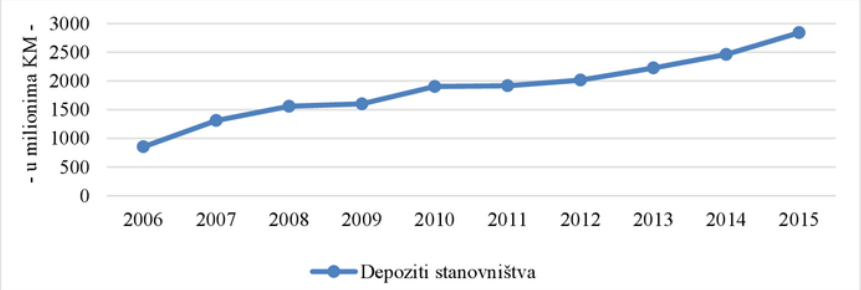
Izvor: (CBBiH, 2017)

Navedeni podaci pokazuju da je učešće depozita nevladinog sektora u ukupnim prenosivim depozitima znatno veće od učešća depozita vlade. Tokom analiziranog periodu, učešće depozita vladinog sektora bilo je ispod 25%, dok je, sa druge strane, učešće depozita nevladinog sektora bilo iznad 75%. Najveće učešće depozita vlade u ukupnim prenosivim depozitima zabilježeno je na početku analiziranog perioda (23,88%), a najveće učešće depozita nevladinog sektora zabilježeno je na kraju 2013. godine (86,72%). Na kraju 2015. godine, depoziti vladinog sektora činili su 15,51%, dok su depoziti nevladinog sektora činili 84,49% ukupnih prenosivih depozita.

U depozitima vladinog sektora, u periodu od 2006. do kraja 2015. godine, najveće učešće imali su depoziti vlada entiteta, a u depozitima nevladinog sektora najveće učešće, do kraja 2007. godine, imali su depoziti nefinansijskih privatnih institucija, a nakon toga depoziti stanovništva. Na kraju 2015. godine najveće učešće u ukupnim prenosivim depozitima imali su depoziti stanovništva i oni su u najvećoj mjeri doprinijeli rastu ukupnih depozita bankarskog sektora BiH.

Trend kretanja depozita stanovništva prikazan je grafikonom 17.

Grafikon 17: Prenosivi depoziti stanovništva u bankarskom sektoru BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

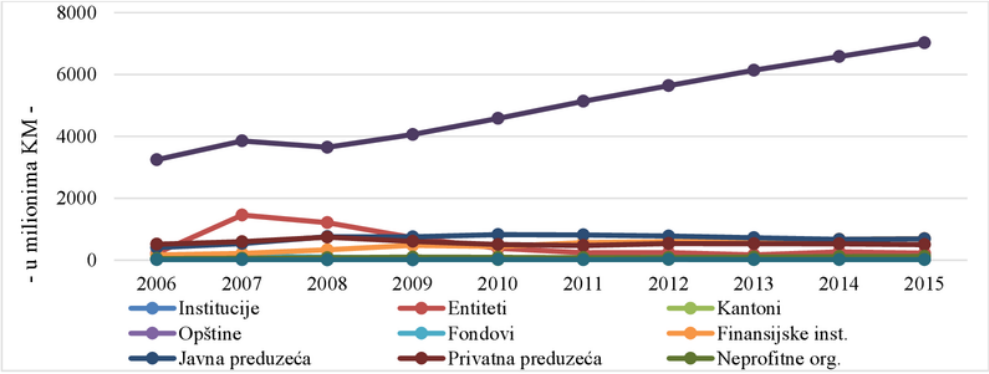
Depoziti stanovništva imaju kontinuirani trend rasta u periodu od 2006. do kraja 2015. godine. Depoziti stanovništva su, na kraju 2006. godine, iznosili 853,3 miliona KM i činili su 27,99% nevladinih depozita, odnosno 21,31% ukupnih prenosivih depozita. Nakon kontinuiranog desetogodišnjeg rasta, depoziti stanovništva povećani su za 1,98 milijardu KM ili 233,01% i na kraju 2015. godine iznosili su 2,84 milijarde KM. Istovremeno, povećano je učešće depozita stanovništva koji su, na kraju 2015. godine činili 47,78% depozita nevladinog sektora, odnosno 40,37% ukupnih prenosivih depozita. Najveći rast depozita stanovništva zabilježen je tokom 2007. i 2015. godine.

4.1.2. Sektorska struktura ostalih depozita

Ostali depoziti u bankarskom sektoru BiH su depoziti koji dozvoljavaju automatsko povlačenje sredstava, ali ne i plaćanje trećim licima, štedni i oročeni depoziti, ostali depoziti – ostalo, a u ostale depozite bankarskog sektora BiH ubrajaju se: depoziti institucija BiH, vlada entiteta, kantona i opština, depoziti fondova socijalne zaštite, depoziti ostalih finansijskih institucija, depoziti nefinansijskih javnih i privatnih preduzeća, depoziti neprofitnih organiacija, depoziti domaćinstava i ostali depoziti (CBBiH, 2016, str. 127).

Sektorska struktura ostalih depozita komercijalnih banaka u BiH prikazana je grafikonom 18.

Grafikon 18: Sektorska struktura ostalih depozita bankarskog sektora BiH (2006 – 2015)



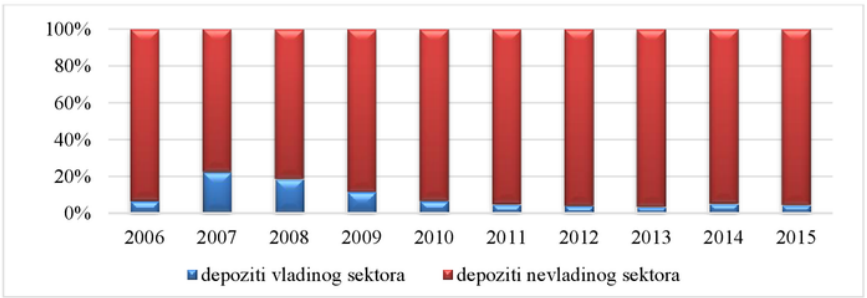
Izvor: (CBBiH, 2017)

Ostali depoziti bankarskog sektora BiH, kao i prenosivi depoziti, obuhvataju depozite vladinog i nevladinog sektora. U analiziranom periodu, depoziti sektora vlade imali su uglavnom trend pada, sa izuzetkom 2007. i 2014. godine kada je zabilježen njihov rast. Najveće povećanje depozita vladinog sektora zabilježeno je na kraju 2007. godine, tokom koje su povećani za čak 401,59% u odnosu na prethodnu godinu. Depoziti nevladinog sektora kontinuirano su rasli u periodu od 2006. do kraja 2015. godine, otprilike za pola miliona godišnje. Najveći rast depozita nevladinog sektora zabilježen je 2007. godine, kada su povećani za 21,67% u odnosu na prethodnu godinu.

Na kraju 2015. godine depoziti vladinog sektora iznosili su 4[illegible]5,7 miliona KM, odnosno 32,56% više nego na početku analiziranog perioda. Istovremeno, depoziti nevladinog sektora iznosili su 9,07 milijardi KM, odnosno 104,21% više nego u 2006. godini. Povećanje depozita nevladinog sektora je, u velikoj mjeri, uticalo na povećanje ostalih depozita bankarskog sektora.

Učešće depozita vladinog i nevladinog sektora u ostalim depozitim bankarskog sektora BiH predstavljeno je grafikonom 19.

Grafikon 19: Ostali depoziti vladinog i nevladinog sektora u bankarskom sektoru BiH (2006 – 2015)



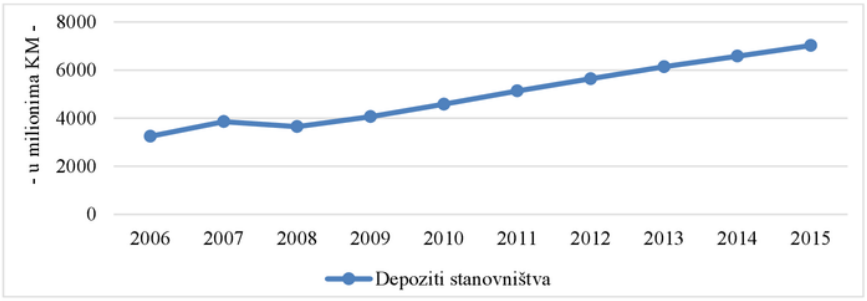
Izvor: (CBBiH, 2017)

Ostali depoziti bankarskog sektora BiH odnose se, manjim dijelom, na depozite vladinog, a većim dijelom na depozite nevladinog sektora. Od 2010. do kraja 2015. godine učešće vladinih depozita nije dostizalo ni 10%, a učešće depozita nevladinog sektora bilo je iznad 90%. Najveće učešće vladinih depozita zabilježeno je na kraju 2007. godine, kada su činili 22,53% ukupnih ostalih depozita. Sa druge strane, najmanje učešće vladinih (3,32%) i najveće učešće depozita nevladinog sektora (96,68%) zabilježeno je na kraju 2013. godine.

U depozitima vladinog sektora najveće učešće imali su depoziti vlada entiteta, a u depozitima nevladinog sektora depoziti stanovništva, koji su ujedno imali dominantno učešće i u ukupnim ostalim depozitima bankarskog sektora BiH.

Trend kretanja depozita stanovništva prikazan je grafikonom 20.

Grafikon 20: Ostali depoziti stanovništva u bankarskom sektoru BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Ostali depoziti stanovništva su, na kraju 2006. iznosili 3,24 milijarde KM, a na kraju 2015. godine 7,02 milijardi KM, odnosno 116,30% više nego u 2006. godini. Ostali depoziti stanovništva imali su trend rasta u periodu od 2006. do kraja 2015. godine, sa izuzetkom 2008. godine u kojoj je zabilježeno smanjenje od 5,38%. Zbog visokog učešća depozita stanovništva u ostalim depozitima, oni su u velikoj mjeri uticali na rast ostalih depozita nevladinog sektora, ali i ukupnih depozita.

Na kraju, može se konstatovati da su depoziti stanovništva imali najveće učešće u prenosivim i ostalim depozitima, pa samim tim i u ukupnim depozitima bankarskog sektora. Na kraju 2015. godine ukupni depoziti stanovništva iznosili su 9,86 milijardi KM, odnosno 5,76 milijardi KM ili 140,56% više nego u 2006. godini kada su iznosili 4,10 milijarde KM. Upravo zbog toga, depoziti stanovništva su primarni izvor finansiranja komercijalnih banaka u BiH.

Značajno povećanje depozita stanovništva tokom 2014. i 2015. godine nije se odnosilo na klasičnu štednju. Naplata stare devizne štednje i nova kreditna zaduženja su, u velikoj mjeri, uticali na navedeno povećanje depozita stanovništva. Pojedine komercijalne banke koje posluju u BiH zahtijevaju deponovanje određenog iznosa od odobrenog kredita, kao instrument obezbjeđenja tog kredita, a to svakako utiče i na visok udio oročenih u ukupnim depozitima stanovništva. Ovo povećanje depozita uticalo je i na odnos kredita i depozita, odnosno na likvidnost bankarskog sektora BiH.

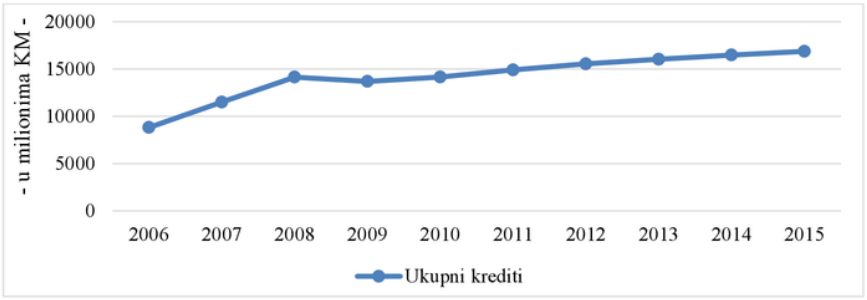
Trend rasta depozita stanovništva pozitivno je uticao na rast depozita nevladinog sektora, ali i na rast ukupnih depozita bankarskog sektora. Od 2006. godine, nakon dužeg perioda, u bankarskom sektoru BiH zabilježen je rast depozita u domaćoj valuti. Tokom analiziranog perioda, više od polovine ukupnih depozita stanovništva bili su oročeni depoziti, a preostali depoziti bili su depoziti po viđenju i depoziti na transakcionim računima.

4.2. Krediti komercijalnih banaka

Veoma važan pokazatelj obima poslovanja svake banke, ali i bankarskog sektora u cjelini, jeste nivo ukupnih kredita. Krediti su najveći generator potencijalnog rizika u bankarskom poslovanju. Sa druge strane, klijenti koji imaju potrebu da finansiraju svoje aktivnosti, a nemaju dovoljno finansijskih sredstava, oslanjaju se na bankarske kredite.

Trend kretanja ukupnih kredita bankarskog sektora BiH predstavljen je grafikonom 21.

Grafikon 21: Ukupni krediti bankarskog sektora BiH (2006 – 2015)

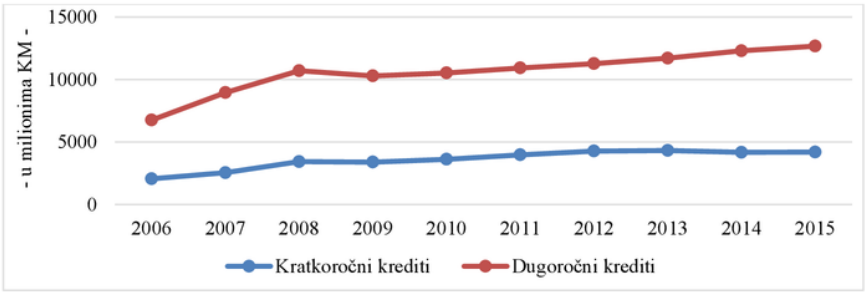


Izvor: (CBBiH, 2017)

Podaci pokazuju da su ukupni krediti imali trend rasta tokom analiziranog perioda, sa izuzetkom 2009. godine tokom koj su smanjene kreditne aktivnosti banaka. Na kraju 2015. godine ukupni krediti bankarskog sektora iznosili su 16,86 milijardi KM i veći su za 8,05 milijardi KM ili 91,34% nego u 2006. godini, kada su iznosili 8,81 milijardi KM. Najveće povećanje kredita zabilježeno je na kraju 2007. godine, tokom koje su povećani za 30,44%.

Trend kretanja kratkoročnih i dugoročnih kredita prikazan je grafikonom 22.

Grafikon 22: Kratkoročni i dugoročni krediti bankarskog sektora BiH (2006 – 2015)

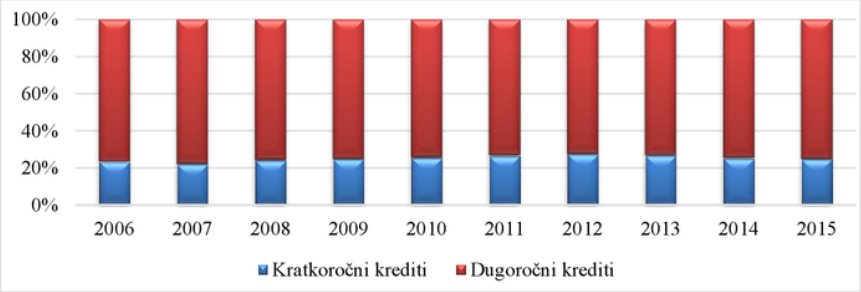


Izvor: (CBBiH, 2017)

Ukoliko se analizira trend kretanja kratkoročnih i dugoročnih kredita bankarskog sektora BiH može se uočiti da on prati trend kretanja kredita. Tokom analiziranog perioda, kratkoročni i dugoročni krediti komercijalnih banaka u BiH imali su trend rasta, sa izuzetkom 2009. godine u kojoj je zabilježeno smanjenje i kratkoročih i dugoročnih kredita i 2014. godine u kojoj je zabilježeno smanjenje kratkoročnih kredita.

Učešće kratkoročnih i dugoročnih kredita u ukupnim kreditima bankarskog sektora BiH prikazano je grafikonom 23.

Grafikon 23: Učešće kratkoročnih i dugoročnih kredita u ukupnim kreditima bankarskog sektora BiH (2006 – 2015)

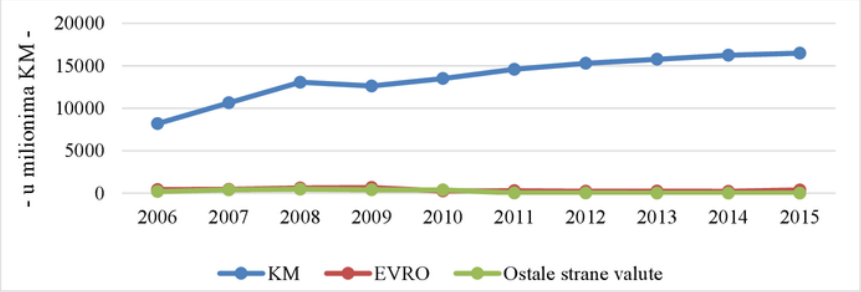


Izvor: (CBBiH, 2017)

Dugoročni krediti imaju znatno veće učešće u ukupnim kreditima bankarskog sektora BiH, koje se nije značajno mijenjalo u periodu od 2006. do kraja 2015. godine. Tokom analiziranog perioda učešće kratkoročnih u ukupnim kreditima nije dostiglo 30%, a učešće dugoročnih nije bilo manje od 70%. Najveće učešće kratkoročnih u ukupnim kreditima zabilježeno je na kraju 2012. godine, a najmanje na kraju 2007. godine. Na kraju 2015. godine kratkoročni krediti činili su 24,86% ukupnih kredita, odnosno 1,52% više nego u 2006. godini, kada su činili 23,34%. Na kraju iste godine, dugoročni krediti činili su 75,14% ukupnih kredita, odnosno 1,52% manje nego u 2006. godini.

Ukupne kredite bankarskog sektora BiH čine krediti koje su komercijalne banke plasirale u domaćoj valuti (KM) i krediti koje su plasirale u stranoj valuti. Valutna struktura kredita prikazana je grafikonom 24.

Grafikon 24: Valutna struktura kredita bankarskog sektora BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Podaci pokazuju da je većina kredita bankarskog sektora BiH, tokom analiziranog perioda, bila u domaćoj valuti. Krediti koji su plasirani u stranoj valuti uglavnom se odnose na evro, a učešće ostalih valuta je veoma malo. Tokom analiziranog desetogodišnjeg perioda, krediti koje su komercijalne banke plasirale u domaćoj valuti imali su trend rasta, a izuzetak je samo 2009. godina u kojoj je zabilježeno njihovo smanjenje. Sa druge strane, krediti koje su komercijalne banke plasirale u stranim valutama uglavnom su imali trend pada, a njihovo povećanje zabilježeno je na kraju 2007., 2008., 2013. i 2015. godine. Pri tom su krediti koji su plasirani u evrima uglavnom imali trend rasta (sa izuzetkom 2010., 2012. i 2014. godine), a krediti plasirani u ostalim stranim valutama imali su trend pada (sa izuzetkom 2007. i 2008. godine). Krediti plasirani u stranim valutama su se, od 2009. godine, kontinuirano smanjivali, a posebno krediti plasirani u ostalim stranim valutama čije učeće u ukupnim kreditima je skoro zanemarljivo.

Za razliku od depozita, kod kojih je skoro polovina bila u stranim valutama, krediti su uglavnom bili u domaćoj valuti (KM). Tokom analiziranog perioda, više od 90% ukupnih kredita bankarskog sektora BiH bilo je u domaćoj valuti, dok je manje od 10% bilo u stranim valutama. Pri tom je učešće kredita koji su plasirani u evrima bilo veće od učešća kredita koji su plasirani u ostalim stranim valutama.

Podaci pokazuju da su komercijalne banke koje posluju na teritoriji BiH uglavnom plasirale kredite u domaćoj valuti, a manji dio plasiranih kredita bio je u evrima i drugim stranim valutama. Smanjenje kredita koji su plasirani u stranim valutama posebno je izraženo od 2009. godine, a trend smanjenja nastavljen je do kraja analiziranog perioda. Istovremeno, krediti plasirani u domaćoj valuti imali su trend rasta. Na kraju 2015. godine krediti plasirani u domaćoj valuti činili su 97,73% ukupnih kredita, odnosno 4,77% više nego u 2006. godini, kada su činili 92,96% ukupnih kredita.

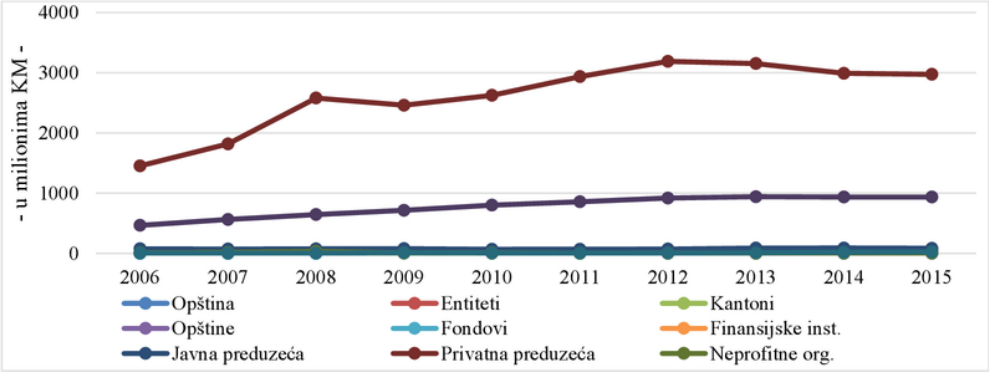
Na kraju, može se konstatovati da su ukupni krediti bankarskog sektora BiH kontinuirano rasli tokom analiziranog perioda, sa izuzetkom 2009. godine, u kojoj su kreditne aktivnosti u BiH bile smanjene. Smanjenje kreditnih aktivnosti posljedica je uticaja globalne finansijske krize, jer je smanjena potrošnja, a smanjen je i obim poslovnih aktivnosti preduzeća, tako da je smanjena i potražnja za novim kreditima. Sektorska struktura plasiranih kredita, prema ročnosti, data je u nastavku.

4.2.1. Sektorska struktura kratkoročnih kredita

Kratkoročni krediti bankarskog sektora BiH predstavljaju potraživanja komercijalnih banaka od svih domaćih institucionalnih sektora do godinu dana, u domaćoj i stranoj valuti, a obuhvataju kredite institucijama BiH, kredite vladama entiteta, kantona i opština, kredite fondovima socijalne zaštite, kredite ostalim finansijskim istitucijama, kredite nefinansijskim javnim i privatnim preduzećima, kredite neprofitnim organizacijama, kredite stanovništvu i ostale kredite (CBBiH, 2016, str. 125, 128).

Sektorska struktura kratkoročnih kredita bankarskog sektora BiH predstavljena je grafikonom 25.

Grafikon 25: Sektorska struktura kratkoročnih kredita bankarskog sektora BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Podaci pokazuju da su se kratkoročni krediti povećavali u analiziranom periodu, sa izuzetkom 2009. i 2014. godine u kojima je zabilježeno njihovo blago smanjenje. Kratkoročni krediti bankarskog sektora obuhvataju kratkoročne kredite koje su banke plasirale vladinom i nevladinom sektoru. U toku analiziranog perioda, kratkoročni krediti plasirani vladinom sektoru imali su trend rasta, mada je njihovo smanjenje zabilježeno na kraju 2007., 2010., i 2012. godine. Sektor vlade je, tokom 2013. godine, povećao svoje zaduženje prema komercijalnim bankama za 110,20% u odnosu na prethodnu godinu. Iako su tokom 2013. godine povećani i dugoročni krediti vladinog sektora, oko 80% ukupnih zaduženja vlade odnosi se na kratkoročne kredite. Kratkoročni krediti plasirani nevladinom sektoru takođe su imali trend rasta, a njihovo smanjenje zabilježeno je na kraju 2009., 2014. i 2015. godine. Najveće povećanje kredita koje su komercijalne banke plasirale nevladinom sektoru zabilježeno je tokom 2008. godine.

Na kraju 2015. godine kratkoročna zaduženja sektora vlade iznosila su 98,8 miliona KM, odnosno 30% više nego u 2006. godini. U istom periodu, kratkoročna zaduženja nevladinog sektora iznosila su 4,09 milijarde KM, odnosno 99,98% više nego u 2006. godini. Povećanje kredita nevladinog sektora najviše je uticalo na povećanje kratkoročnih kredita bankarskog sektora BiH.

Učešće kratkoročnih kredita koje su komercijalne banke plasirale sektoru vlade bilo je skoro zanemarljivo (ispod 3%) tokom analiziranog perioda. Prema tome, dominantno učešće u ukupnim kratkoročnim kreditima imali su krediti plasirani nevladinom sektoru. Na kraju 2015. godine, kratkoročni krediti plasirani vladinom sektoru činili su 2,36%, a nevladinom sektoru 97,64% ukupnih kratkoročnih kredita.

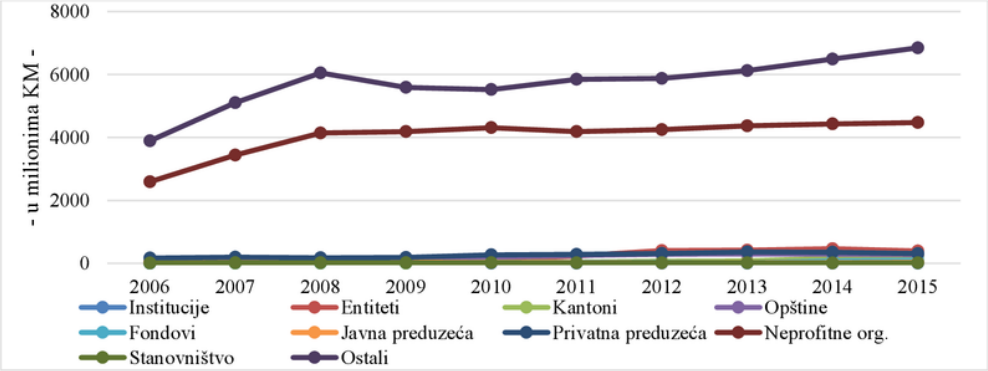
U kratkoročnim kreditima koji su plasirani sektoru vlade dominantno učešće imaju krediti vladama opština, a u kreditima koji su plasirani nevladinom sektoru krediti nefinansijskim privatnim preduzećima i krediti stanovništvu. Kratkoročni krediti koji su plasirani stanovništvu kontinuirano su rasli tokom analiziranog perioda, sa izuzetkom 2014. godine, u kojoj je zabilježen blagi pad. Na kraju 2006. godine krediti stanovništvu iznosili su 466,6 miliona KM, a deset godina kasnije bili su veći za 470,4 miliona KM ili 100,81% i iznosili su 937,0 miliona KM. Iako su kratkoročni krediti uglavnom imali trend rasta, od 2012. godine kreditne aktivnosti su značajno usporene. Najveći udio u ukupnim kratkoročnim kreditima imaju krediti plasirani nefinansijskim privatnim preduzećima.

4.2.2. Sektorska struktura dugoročnih kredita

Dugoročni krediti predstavljaju potraživanja komercijalnih banaka od svih domaćih institucionalnih sektora preko godinu dana, u domaćoj ili stranoj valuti, a obuhvataju kredite institucijama BiH, vladama entiteta, kantona i opština, kredite fondovima socijalne zaštite, ostalim finansijskim institucijama, nefinansijskim javnim i privatnim preduzećima, neprofitnim organizacijama, stanovništvu i ostale kredite (CBBiH, 2016, str. 129).

Sektorska struktura dugoročnih kredita komercijalnih banaka u BiH predstavljena je grafikonom 26.

Grafikon 26: Sektorska struktura dugoročnih kredita bankarskog sektora BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Kao što je već rečeno, dugoročni krediti bankarskog sektora BiH su se povećavali u periodu od 2006. do kraja 2015. godine, sa izuzetkom 2009. godine na kraju koje je zabilježeno njihovo smanjenje. Dugoročni krediti se, poput kratkoročnih, sastoje od dugoročnih kredita koje su banke plasirale vladinom i nevladinom sektoru. U periodu od 2006. do kraja 2014. godine zabilježeno je povećanje dugoročnih kredita koje su komercijalne banke plasirale sektoru vlade, a samo na kraju 2015. godine zabilježeno je njihovo smanjenje. Takođe, u analiziranom periodu povećani su i dugoročni krediti koje su komercijalne banke plasirale nevladinom sektoru, sa izuzetkom 2009. godine tokom koje su smanjeni.

Tokom analiziranog perioda, dugoročni krediti plasirani sektoru vlade značajno su povećani, a najveće povećanje bilo je tokom 2008. godine kada su povećani za 124,20%. Na kraju 2015. godine dugoročni krediti sektora vlade iznosili su 897,7 miliona KM (1450,43% više nego u 2006. godini), a krediti nevladinog sektora 11,77 milijardi KM (75,83% više nego u 2006. godini).

Struktura dugoročnih kredita se nije mnogo razlikovala od strukture kratkoročnih kredita. Krediti plasirani nevladinom sektoru imali su dominantno učešće i u ukupnim dugoročnim kreditima, ali je ipak učešće kredita plasiranih sektoru vlade bilo veće od njihovog učešća u ukupnim kratkoročnim kreditima. Ipak, učešće vladinih dugoročnih kredita u ukupnim dugoročnim kreditima se povećavalo, sa izuzetkom 2015. godine, u kojoj je učešće smanjeno. Na kraju 2015. godine dugoročni krediti plasirani sektoru vlade činili su 7,08% ukupnih dugoročnih kredita, a dugoročni krediti plasirani nevladinom sektoru preostalih 92,92%.

U strukturi dugoročnih kredita koji su plasirani sektoru vlade najveće učešće, od 2006. do kraja 2011. godine, imali su krediti vladama opština, a od 2012. do kraja 2015. godine krediti vladama entiteta. U strukturi dugoročnih kredita koji su plasirani nevladinom sektoru najveće učešće imali su krediti stanovništvu, koji su imali trend rasta u analiziranom periodu (izuzetak su samo 2009. i 2010. godina). Na kraju 2006. godine krediti stanovništvu iznosili su 3,89 milijarde KM, a deset godina kasnije 6,84 milijardi KM, odnosno 1,32 milijardu KM ili 75,88% više.

Krediti u bankarskom sektoru BiH uglavnom su imali trend rasta u analiziranom periodu, ali su od 2012. godine kreditne aktivnosti komercijalnih banaka usporene. Komercijalne banke su, u ovom periodu, provodile restriktivniju politiku prilikom odobravanja novih kredita, a to je jedan od najvećih ograničavajućih faktora za plasiranje novih kredita. Takođe, do smanjenja kreditnih aktivnosti došlo je i zbog negativnog uticaja globalne finansijske krize na privredu i cjelokupnu ekonomiju, a uticaj je rezultirao smanjenjem potrošnje i usporavanjem privrednih aktivnosti. Krediti koji su plasirani stanovništvu uglavnom su imali trend rasta, a to ukazuje na činjenicu da se stanovništvo, kada ima potrebu za dodatnim finansijskim sredstvima, uglavnom oslanja na kredite banaka jer nema alternativnih izvora finansiranja.

IV DIO

ANALIZA FAKTORA KOJI UTIČU NA NEKVALITETNE KREDITE U BANKARSKOM SEKTORU BOSNE I HERCEGOVINE

1. METODOLOGIJA ISTRAŽIVANJA

Disertacija ima za cilj da ispita makroekonomske i specifične bankarske faktore koji utiču na nekvalitetne kredite bankarskog sektora BiH. Pored toga, sprovedena je komparativna analiza kretanja nivoa nekvalitetnih kredita na finansijskom tržištu Bosne i Hercegovine i finansijskim tržištima zemalja regiona (Srbija, Crna Gora, Hrvatska, Slovenija i Makedonija), kao i na finansijskim tržištima razvijenih zemalja (SAD, Njemačka, Španija, Francuska, Italija i Austrija). U skladu sa tim, opisan je postupak istraživanja koje je sprovedeno.

Istraživanje počinje razmatranjem kompletne situacije i instrumenata za prikupljanje podataka, a zatim su predstavljene metode koje su korištene i način na koji su podaci analizirani. Konačno, dat je i opis promjenljivih koje su korištene, način na koji su mjerene i izmjerene vrijednosti u periodu od 2006. do 2015. godine.

1.1. Način istraživanja i pristup

Prije sprovođenja istraživanja, potrebno je napraviti detaljan plan koji sadrži metode i procedure za prikupljanje i analizu potrebnih podataka. Zbog složenosti problema istraživanja korištene su osnovne metode, opštenaučne metode i metode prikupljanja podataka. Od osnovnih metoda korištene su analitičke (analiza, apstrakcija, specijalizacija i dedukcija) i sintetičke (sinteza, konkretizacija, generalizacija i indukcija) osnovne metode. Od opštenaučnih metoda korištena je hipotetičko – deduktivna metoda. Od metoda i tehnika prikupljanja podataka korištena je metoda analize sadržaja dokumenata.

Istraživanje je podijeljeno na dva dijela, a cilj koji se želi postići osnova je za određivanje istraživačkog pristupa. Prvi dio istraživanja odnosi se na identifikaciju faktora koji utiču na nekvalitetne kredite, a drugi dio istraživanja odnosi se na analizu podataka koji su prikupljeni direktno od menadžera i rukovodioca komercijalnih banaka u BiH, pomoću anketnog upitnika.

Faktori koji utiču na nekvalitetne kredite imaju brojčanu vrijednost, tako da se u tom slučaju koristi kvantitativni istraživački pristup, a rezultati se upoređuju sa rezultatima iz empirijske literature koja se bavi ovom problematikom. Podaci koji se prikupljaju pomoću ankete nemaju brojčanu vrijednost, pa se koristi kvalitativni istraživački pristup. Pri tom se koristi rezonovanje, i to deduktivno kod kvantitativnog istraživanja, a induktivno kod kvalitativnog istraživanja. Deduktivno rezonovanje polazi od zakona ili principa i generalizuje ih na konkretnom slučaju, dok induktivno rezonovanje polazi od posmatranih podataka i generalizuje ih na osnovu teorijskih činjenica.

1.2. Podaci i instrumenti za prikupljanje podataka

Podaci koji su neophodni za istraživanje koje se odnosi na faktore koji utiču na nekvalitetne kredite u bankarskom sektoru BiH potiču iz sekundarnih izvora. U istraživanju su korišteni agregatni podaci o nekvalitetnim kreditima u bankarskom sektoru BiH, jer podaci za sve individualne banke nisu dostupni. Stakić navodi da se „reprezentativniji uzorak može dobiti ukoliko se uzme u obzir cjelokupan bankarski sektor“, a to opravdava činjenicom da sve banke imaju različite poslovne performanse (Stakić, 2014).

Podaci o nekvalitetnim kreditima u bankarskom sektoru BiH predstavljaju zvanične podatke koje je objavila Centralna banka BiH, a riječ je o kvartalnim podacima koji se odnose na period od prvog kvartala 2006. do kraja četvrtog kvartala 2015. godine. Na entitetskom nivou, podaci o nekvalitetnim kreditima prikupljeni su iz izvještaja nadležnih agencija za bankarstvo. Podaci o nekvalitetnim kreditima u bankarskim sektorima zemalja regiona i u bankarskim sektorima razvijenih zemalja prikupljeni su od Svjetske banke, a riječ je o godišnjim podacima iz perioda od 2006. do kraja 2015. godine.

Makroekonomski podaci potiču iz tri izvora, a uključuju podatke koje je objavila Centralna banka BiH, podatke koje je objavila Agencija za statistiku BiH i podatke koje je objavila Agencija za rad i zapošljavanje BiH. Podaci koji se odnose na specifične bankarske faktore su podaci koje je objavila Centralna banka BiH. Svi podaci koji se koriste u ovom dijelu istraživanja su kvartalni podaci, a obuhvataju period od prvog kvartala 2006. godine do kraja četvrtog kvartala 2015. godine.

Drugu grupu podataka čine primarni podaci koji su prikupljeni pomoću anketnog upitnika koji je dizajniran tako da se pomoću njega analiziraju faktori koji utiču na nekvalitetne kredite bankarskog sektora BiH. Cilj anketriranja je dolazak do saznanja o uzrocima nastanka rizičnih kreditnih plasmana, ali i identifikacija faktora koji utiču na pojavu nekvalitetnih kredita u komercijalnim bankama u BiH. Anketni upitnik dostavljen je rukovodiocima, menadžerima, zaposenim u odjeljenjima za kredi i rizik i onima koji su uključeni u postupak odobravanja kredita. Anketiranje je sprovedeno u komercijalnim bankama na cijeloj teritoriji BiH u periodu od 16.01.2017. do 16.05.2017. godine, a odgovori od anketiranih prikupljeni su lično u komercijalnim banakama ili putem Interneta.

1.3. Analiza i prezentacija podataka

Sekundardni podaci prikupljeni su iz različitih izvora (Svjetska banka, Centralna banka BiH, Agencija za statistiku BiH, Agencija za rad i zapošljavanje BiH, Agencija za bankarstvo RS i Agencija za bankarstvo FBiH). Primarni podaci koji su korišteni u istraživanju prikupljeni su pomoću anketnog upitnika lično u komercijalnim bankama koje posluju u BiH ili putem Interneta. Podaci su obrađeni pomoću programskog paketa SPSS (*Statistical Package for Social Sciences*) i pomoću *Microsoft Excel*-a.

Zbog prirode kvantitativnog istraživanja korištene su statističke metode za testiranje formulisanih hipoteza, koje su postavljene na početku istraživanja. U kvantitativnom istraživanju je korištena deskriptivna statistička analiza, korelaciona analiza i regresiona analiza. Prilikom istraživanja međusobnih veza između promjenljivih korištene su metode proste korelacione analize i metode proste i višestruke regresione analize, a dobijeni rezultati upoređeni su sa rezultatima iz literature koja se bavi ovom problematikom.

Deskriptivna statistička analiza predstavlja skup metoda pomoću kojih se vrši izračunavanje, prikazivanje i opisivanje osnovnih karakteristika statističkih serija, a njen zadatak je grupisanje, sređivanje i prikazivanje statističkih podataka, kao i određivanje osnovnih pokazatelja statističkih serija. Rezultati deskriptivne statistike pokazuju minimalnu i maksimalnu vrijednost, srednju vrijednost i standardnu devijaciju promjenljivih koje se analiziraju, odnosno daju njihove opšte karakteristike.

Za korelaciju je najjednostavnije reći da predstavlja povezanost između promjenljivih, a koeficijent korelacije mjeru na osnovu koje se zaključuje o stepenu njihove povezanosti. Konkretno, prilikom analize faktora koji utiču na nekvalitetne kredite korištena je prosta linearna korelacija, a rezultati su predstavljeni tabelarno sa odgovarajućim statističkim podacima i objašnjenjima.

Pomoću regresione analize može se utvrditi oblik veze između posmatranih pojava, a to se postiže pomoću odgovarajućeg regresionog modela. Takođe, pomoću regresionog modela mogu se ocijeniti i predvidjeti vrijednosti zavisne promjenljive pomoću odabranih objašnjavajućih promjenljivih. Za razliku od korelacione analize, kod koje se obično promjenljive označavaju kao zavisna i nezavisne promjenljive, kod regresione analize analize promjenljive se označavaju kao zavisna i objašnjavajuće promjenljive, jer se pomoću njih pokušavaju objasniti varijacije zavisne promjenljive. Konkretno, u ovom istraživanju korištene su prosta i višestruka regresija, a rezultati su predstavljeni tabelarno sa odgovarajućim statističkim podacima i objašnjenjima.

Kvalitativno istraživanje sprovedeno je pomoću upitnika koji se sastoji od standardizovanih i smisaono povezanih pitanja datih u pisanoj formi, sa ciljem da se ispitaju stavovi i mišljenja zaposlenih u komercijalnim bankama u BiH. Pitanja u upitniku bila su zatvorenog tipa, a ispitanik je mdoogao da odabere jedan ili više ponuđenih odgovora koji u najvećoj mjeri oslikavaju njegove stavove o pojavama koje su predmet istraživanja. Rezultati anketiranja predstavljeni su tabelarno i grafički, uz prateća objašnjenja.

1.4. Promjenljive u istraživanju

Prilikom istraživanja faktora koji utiču na nekvalitetne kredite u bankarskom sektoru BiH korišteno je više promjenljivih, od kojih je jedna zavisna, a ostale su nezavisne promjenljive. Zavisna promjenljiva u istraživanju je promjenljiva nekvalitetni krediti, a mjeri se odnosom nekvalitetnih u ukupnim bruto kreditima. Nezavisne promjenljive podijeljene su u dvije grupe. Prvu grupu čine makroekonomske promjenljive i to: stopa rasta realnog bruto domaćeg proizvoda, stopa nezaposlenosti i stopa inflacije. Drugu grupu čine specifične bankarske promjenljive i to: koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, aktivna kamatna stopa i stopa kreditnog rasta. Sve promjenljive detaljno su opisane u drugom dijelu disertacije.

1.4.1. Zavisna promjenljiva

Nekvalitetni krediti (NPL) su zavisna promjenljiva koja se koristi u istraživanju. U BiH, pod nekvalitetnim kreditima se podrazumijevaju krediti koji su klasifikovani u kategorije C, D i E, odnosno krediti čija dospjela glavnica i/ili kamata nije naplaćena duže od 90 dana od dana od njihovog ugovorenog dospjeća ili krediti kod kojih su obaveze po kamati koja nije naplaćena u tom periodu kapitalizovane (CBBIH, 2017, str. 8).[7]

[7] U skladu s Odlukama o izmjenama i dopunama odluka o minimalnim standardima za upravljanje kreditnim rizikom, banke u RS su dužne od 31.12.2010. godine, a banke u FBiH od 31.12.2011. godine, da kredite klasifikovane u E kategoriju iskazuju u bilansu stanja sve do konačnog otpisa ili naplate, dok su se, u prethodnom periodu, krediti klasifikovani u E kategriju iskazivali vanbilansno i nisu bili uključeni u stavku nekvalitetni krediti (CBBIH, 2017, str. 8).

Nekvalitetni krediti su izmjereni, a njihov iznos je prikazan kao udio nekvalitetnih u ukupnim bruto kreditima bankarskog sektora u BiH. Podaci o nekvalitetnim kreditima u bankarskom sektoru BiH, koji su korišteni u istraživanju, su kvartalni podaci koje je objavila Centralna banka BiH, a obuhvataju period od 2006. do kraja 2015. godine.

1.4.2. Nezavisne promjenljive

Nezavisne promjenljive objašnjavaju zavisnu promjenljivu, a pomoću njih će se dokazati ili odbaciti posebne hipoteze koje su postavljene na početku rada. U nezavisne promjenljive koje su uključene u istraživanje spadaju i makroekonomske i specifične bankarske promjenljive. Makroekonomske promjenljive koje su uključene u istraživanje su: stopa rasta realnog bruto domaćeg proizvoda, stopa nezaposlenosti i stopa inflacije. Specifične bankarske promjenljive koje su uključene u istraživanje su: koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, aktivna kamatna stopa i stopa kreditnog rasta. Navedene promjenljive su korištene u većini istraživanja koja se odnose na faktore koji utiču na nekvalitetne kredite, a rezultati tih istraživanja pokazuju da njihov uticaj na nekvalitetne kredite može, ali ne mora biti statistički značajan. Ukoliko se pokaže da promjenljiva ima statistički značajan uticaj na nekvalitetne kredite, tada taj uticaj može biti pozitivan ili negativan. Detaljan opis navedenih promjenljivih dat je u drugom dijelu disertacije, a ovde su date samo osnovne karatkeristike i njihov očekivani uticaj na nekvalitetne kredite.

Stopa rasta realnog bruto domaćeg proizvoda (GDP) je nezavisna promjenljiva koja spada u grupu makroekonomskih promjenljivih. Ona se izražava u procentima, a predstavlja odnos godišnjeg apsolutnog prirasta domaćeg proizvoda i njegove veličine na kraju prethodnog perioda. Podaci o stopi rasta bruto domaćeg proizvoda koji se koriste u istraživanju su podaci koje je objavila Agencija za statistiku Bosne i Hercegovine. Podaci koji obuhvataju period od 2006. do kraja 2015. godine usklađeni su prema godišnjem obračunu BDP-a za navedeni period, a stope rasta izvedene su iz serije bazičnih lančanih indeksa, pri čemu je 2010. godine referentna godina (2010. = 100). Kvartalne procjene BDP-a zasnovane su na istim izvorima i metodama koje se koriste prilikom procjene BDP-a na godišnjem nivou.

Rezultati sprovedenih istraživanja pokazuju da stopa rasta realnog bruto domaćeg proizvoda može imati pozitivan i negativan odnos sa nekvalitetnim kreditima. U ovom istraživanju se polazi od činjenice da stopa rasta realnog bruto domaćeg proizvoda ima negativan odnos sa nekvalitetnim kreditima komercijalnih banaka. To znači da bi povećanje stope rasta realnog bruto domaćeg proizvoda moglo uticati na smanjenje nekvalitetnih kredita, i obrnuto, smanjenje stope rasta realnog bruto domaćeg proizvoda moglo bi uticati na povećanje nekvalitetnih kredita u bankarskom sektoru BiH.

Stopa nezaposlenosti (UNEMP) je nezavisna promjenljiva koja takođe spada u grupu makroekonomskih promjenljivih. Ona se izražava u procentima, a predstavlja odnos broja nezaposlenih prema veličini radne snage. Podaci o stopi nezaposlenosti u BiH, u periodu od 2006. do kraja 2015. godine, prikupljeni su iz publikacija o stanju tržišta rada u BiH, koje je objavila Agencija za rad i zapošljavanje BiH.

Rezultati sprovedenih istraživanja u kojima se analizira odnos stope nezaposlenosti i nekvalitetnih kredita pokazuju da on može biti pozitivan i negativan. U ovom istraživanju polazi se od stava da stopa nezaposlenosti ima pozitivan odnos sa nekvalitetnim kreditima, a to znači da bi, u slučaju rasta stope nezaposlenosti moglo doći do povećanja nekvalitetnih kredita, odnosno da bi, u slučaju smanjenja stope nezaposlenosti, moglo doći do smanjenja nekvalitetnih kredita u bankarskom sektoru BiH.

Stopa inflacije je posljednja nezavisna promjenljiva koja spada u grupu makroekonomskih promjenljivih, a riječ je o ekonomskoj situaciji u kojoj nivo ukupnih cijena raste. Inflacija se obično određuje pomoću **stope rasta potrošačkih cijena (ICP)**, koja pokazuje promjenu cijena robe široke potrošnje i usluga kupljenih od strane stanovništva. U ovom istraživanju, podaci o stopi rasta potrošačkih cijena odnose se na period od 2006. do kraja 2015. godine, a prikupljeni su iz publikacija koje je objavila Centralna banka BiH.

U literaturi se mogu naći rezultati koji pokazuju negativan odnos stope inflacije (mjerene pomoću stope rasta potrošačkih cijena) i nekvalitetnih kredita i rezultati koji pokazuju pozitivan odnos između ovih promjenljivih. U ovom istraživanju polazi se od stava da stopa rasta potrošačkih cijena ima pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. To znači da bi, u slučaju povećanja stope rasta potrošačkih cijena, moglo doći do povećanja nekvalitetnih kredita, a istovremeno važi i obrnuto, u slučaju smanjenja stope rasta potrošačkih cijena moglo bi doći do smanjenja nekvalitetnih kredita u bankarskom sektoru BiH.

Koeficijent adekvatnosti kapitala (CAR) je nezavisna promjenljiva koja se ubraja u grupu specifičnih bankarskih promjenljivih. Ovaj koeficijent predstavlja odnos između kapitala i rizične aktive banaka, odnosno sposobnost banke da apsorbuje gubitke nastale zbog nekvalitetnih kredita. Podaci o adekvatnosti kapitala u bankarskom sektoru BiH preuzeti su od Centralne banke BiH, a riječ je o kvartalnim podacima koji obuhvataju period od 2006. do kraja 2015. godine.

Rezultati sprovedenih istraživanja pokazuju da odnos koeficijenta adekvatnosti kapitala i nekvalitetnih kredita može biti pozitivan ili negativan. U ovom istraživanju polazi se od stava da koeficijent adekvatnosti kapitala ima negativan odnos sa nekvalitetnim kreditima, odnosno da dobro kapitalizovane banke imaju manje nekvalitetnih kredita jer su manje sklone rizikovanju. Naravno, važi i obrnuto, banke koje su slabije kapitalizovane imaju više nekvalitetnih kredita jer su sklone rizikovanju.

Odnos kredita i depozita (LTD) je nezavisna promjenljiva koja takođe spada u grupu specifičnih bankarskih promjenljivih. Odnos kredita i depozita daje informaciju o sposobnosti banke da rast kreditnog portfolia podrži depozitima. Podaci odnosa kredita i depozita u bankarskom sektoru BiH preuzeti su od Centralne banke BiH, a takođe je riječ o kvartalnim podacima koji se odnose na period od 2006. do kraja 2015. godine.

Rezultati istraživanja koja su sprovedena do sada, pokazuju da postoji pozitivan i negativan odnos pokazatelja odnosa kredita i depozita i nekvalitetnih kredita. U ovom istraživanju polazi se od stava da pokazatelj odnosa kredita i depozita ima pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka, odnosno očekuje se da bi trajna likvidnost komercijalnih banaka mogla da utiče na smanjenje nekvalitetnih kredita u bankarskom sektoru BiH.

Prinos na aktivu (ROA) takođe spada u grupu specifičnih bankarskih promjenljivih, a riječ je o nezavisnoj promjenljivoj koja pokazuje profitabilnost banke. Prinos na aktivu izražava se u procentima, a pokazuje efikasnost upravljanja aktivnom, odnosno pokazuje koliko banka zarađuje na svojoj imovini. Podaci o prinosu na aktivu u bankarskom sektoru BiH, koji su korišteni u istraživanju, preuzeti su od Centralne banke BiH, a odnose se na period od 2006. do kraja 2015. godine.

U istraživanjima koja su do sada sprovedena, jedna grupa autora je pronašla pozitivan, a druga grupa negativan odnos prinosa na aktivu i nekvalitetnih kredita. U ovom istraživanju polazi se od stava da prinos na aktivu ima negativan odnos sa nekvalitetnim kreditima komercijalnih banaka, jer se smatra da visoko profitabilne banke imaju manji podsticaj da se uključe u visokorizične aktivnosti. To znači da bi banke koje imaju veći prinos na aktivu mogle imati manje nekvalitetnih kredita i obrnuto, kod banaka koje ostvaruju manji prinos na aktivu može se očekivati više nekvalitetnih kredita.

Prinos na akcijski kapital (ROE) je nezavisna promjenljiva koja je, kao i prethodna, pokazatelj profitabilnosti banke i spada u grupu specifičnih bankarskih promjenljivih. Prinos na akcijski kapital pokazuje akcionarima banke kolika je dobit banke na njihov uloženi kapital. Podaci o prinosu na akcijski kapital u bankarskom sektoru BiH su kvartalni podaci iz perioda od 2006. do kraja 2015. godine, a preuzeti su od Centralne banke BiH.

Kao i kod prethodnih promjenljivih, u dosadašnjim istraživanjima pronađen je pozitivan ili negativan odnos između prinosa na akcijski kapital i nekvalitetnih kredita. U ovom istraživanju polazi se od stava da prinos na akcijski kapital ima negativan odnos sa nekvalitetnim kreditima komercijalnih banaka. To znači da se kod banaka koje ostvaruju veći prinos na akcijski kapital očekuje manje nekvalitetnih kredita, jer su manje sklone visokorizičnim aktivnostima. Važi i obrnuto, banke kod kojih je prinos na akcijski kapital manji, imaju više nekvalitetnih kredita jer su sklonije visokorizičnim aktivnostima.

Aktivna kamatna stopa (IR) je nezavisna promjenljiva koja se u istraživanjima obično ubraja u grupu makroekonomskih promjenljivih, ali u BiH komercijalne banke same formiraju kamatne stope tako da se ubraja u specifične bankarske promjenljive. Aktivna kamatna stopa se izražava u procentima, a predstavlja cijenu koštanja kreditnih sredstava na finansijskom tržištu. Podaci o aktivnoj kamatnoj stopi koji su korišteni u istraživanju su kvartalni podaci koji obuhvataju period od početka 2006. do kraja 2015. godine, a preuzeti su od Centralne banke BiH. Kvartalne kamatne stope su aritmetička sredina mjesečnih ponderisanih kamatnih stopa na kredite koje su plasirale komercijalne banke.

Rezultati studija koje su sprovedene pokazuju da odnos aktivne kamatne stope i nekvalitetnih kredita može biti pozitivan ili negativan, a u ovom istraživanju se polazi od stava da aktivna kamatna stopa ima pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. To znači da bi se, u slučaju povećanja aktivne kamatne stope moglo očekivati i povećanje nekvalitetnih kredita, odnosno, da bi smanjenje aktivne kamatne stope moglo uticati na smanjenje nekvalitetnih kredita u bankarskom sektoru BiH.

Stopa kreditnog rasta (CG) je posljednja nezavisna promjenljiva koja spada u grupu specifičnih bankarskih promjenljivih koje su uključene u istraživanje. Ona se izražava u procentima, a pokazuje povećanje kredita koje su plasirale komercijalne banke. U ovom istraživanju korišteni su kvartalni podaci o stopi kreditnog rasta koji obuhvataju period od 2006. do kraja 2015. godine, a preuzeti su od Centralne banke BiH.

Rezultati sprovedenih istraživanja pokazuju da odnos stope kreditnog rasta i nekvalitetnih kredita može biti pozitivan ili negativan. U ovom istraživanju polazi se od stava da stopa kreditnog rasta ima pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. To znači da bi rast plasiranih kredita komercijalnih banaka mogao uticati i na povećanje nekvalitetnih kredita i obrnuto, da bi smanjenje plasiranih kredita moglo uticati na smanjenje nekvalitetnih kredita u bankarskom sektoru BiH.

Pregled svih nezavisnih makroekonomskih i specifičnih bankarskih promjenljivih koje su uključene u istraživanje, sa očekivanim predznakom između promjenljive i nekvalitetnih kredita prikazan je u tabeli 21. Takođe, za svaku promjenljivu naveden je izvor iz koga su prikupljeni podaci koji su korišteni u istraživanju. Važno je napomenuti da pozitivan znak „+“ ukazuje na pozitivan odnos, a negativan znak „-„ na negativan odnos između nezavisne promjenljive i nekvalitetnih kredita, kao zavisne promjenljive. Predznak odnosa između nezavisnih i zavisne promjenljive predviđen je na osnovu rezultata sprovedenih istraživanja, mada se na osnovu njih ne mogu izvući generalni zaključci o faktorima koji utiču na nekvalitetne kredite jer se dobijeni rezultati razlikuju.

Tabela 21: Pregled nezavisnih promjenljivih, očekivani predznak i izvor iz koga su prikupljeni podaci

PROMJENLJIVA	OPIS PROMJENLJIVE	OČEKIVANI PREDZNAK	IZVOR
GDP	stopa rasta realnog BDP-a	-	Agencija za statistiku BiH
UNEMP	stopa nezaposlenosti	+	Agencija za rad i zapošljavanje BiH
ICP	stopa rasta potrošačkih cijena	+	Centralna banka BiH
CAR	koeficijent adekvatnosti kapitala	-	Centralna banka BiH
LTD	odnos kredita i depozita	+	Centralna banka BiH
ROA	prinos na aktivu	-	Centralna banka BiH
ROE	prinos na akcijski kapital	-	Centralna banka BiH
IR	aktivna kamatna stopa	+	Centralna banka BiH
CG	stopa kreditnog rasta	+	Centralna banka BiH

Izvor: Izrada autora

1.5. Specifikacija modela

U disertaciji se analizira uticaj makroekonomskih i specifičnih bankarskih faktora na nekvalitetne kredite bankarskog sektora BiH. Prilikom istraživanja, kao zavisna promjenljiva koristi se udio nekvalitetnih u ukupnim bruto kreditima (NPL), a nezavisne promjenljive su razvrstane u dvije grupe: makroekonomske promjenljive i specifične bankarske promjenljive.

Podaci za makroekonomske promjenljive iskazani su na tromjesečnom (kvartalnom) nivou, a u ovu grupu spadaju: stopa rasta realnog bruto domaćeg proizvoda, stopa nezaposlenosti i stopa rasta potrošačkih cijena. Podaci za specifične bankarske promjenljive su agregatni, odnosno vrijednosti se odnose na cjelokupni bankarski sektor BiH. Oni su također iskazani na tromjesečnom (kvartalnom) nivou. U grupu specifičnih bankarskih promjenljivih spadaju: koeficijen adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, aktivna kamatna stopa i stopa kreditnog rasta.

Podaci koji su korišteni u prvom dijelu istraživanja, odnosno prilikom testiranja pojedinačnih hipoteza postavljenih na početku istraživanja, prikupljeni su iz različitih izvora, a riječ je o kvartalnim podacima od početka 2006. do kraja 2015. godine. Podaci su obrađeni pomoću statističkog programa *IBM SPSS Statistics Version 20*. Osnovne karakteristike promjenljivih (minimalna i maksimalna vrijednost, aritmetička sredina i standardna devijacija) dobijene su pomoću deskriptivne statistike. Odnosi između zavisne i nezavisnih promjenljivih, kao i jačina njihove povezanosti, dobijeni su pomoću korelacione i regresione analize.

Prije sprovođenja korelacione i regresione analize konstruisan je dijagram raspršenosti koji prikazuje vezu između dvije kvantitativne promjenljive. Pomoću dijagrama raspršenosti može se zaključiti da li između pojava postoji kvantitativno slaganje, te ako postoji, koji je njegov oblik (linearni ili krivolinijski), smjer (direktni ili inverzni) i koja je jačina tog slaganja. Ukoliko se dijagram rasprešenosti ne konstruiše, mogu se dobiti potpuno nevalidni rezultati, a na osnovu njih izvesti pogrešni zaključci. Modeli istraživanja postavljeni su i za korelacionu i za regresionu analizu. Važno je napomenuti da su, kod regresione analize, postavljena dva modela – jedan za prostu, a drugi za višestruku linearnu regresiju.

Podaci koji se koriste u drugom dijelu istraživanja, odnosno prilikom testiranja posebnih hipoteza, su podaci koji su prikupljeni metodom anketiranja. Anketiranje je sprovedeno pomoću anketnog upitnika koji je sadržao 20 pitanja zatvorenog tipa. Rezultati anketiranja prikazani su pomoću tabela i grafikona koji su kreirani u *Microsoft Excel*-u.

1.5.1. Specifikacija modela korelacione analize

Korelacija opisuje jačinu i smjer veze između dvije ili više promjenljivih, a u ovom istraživanju korištena je prosta linearna korelacija, jer su ispunjeni svi uslovi za njenu primjenu. Koeficijent korelacije je stepen povezanosti iskazan brojem, odnosno kvantitativni pokazatelj pomoću koga se izražava stepen saglasnosti, tj. jačina i smjer povezanosti dvije ili više kvantitativnih promjenljivih.

Izračunavanje korelacije bilo kojom metodom daje koeficijent korelacije koji je predstavljen brojem, a njegova vrijednost može biti u intervalu od -1 do +1. Algebarski predznak korelacije određuje kvalitet povezanosti, odnosno pozitivnu ili negativnu povezanost. Veličina broja koji predstavlja izračunati koeficijent govori o jačini inteziteta korelacije između promjenljivih. Značajnost dobijenog koeficijenta određuje *p vrijednost*. Linearna korelacija koja je korištena u ovom istraživanju izražava se pomoću Pearsonovog koeficijenta linearne korelacije (*Pearson Correlation*) koji je oblik izražavanja korelacionih odnosa između obilježja dvije pojave.

Osnovna formula za njegovo izračunavanje je:

$$r_{XY} = \frac{\Sigma(\frac{x}{\sigma x}+\frac{y}{\sigma y})}{N-1}$$

Pri tome je $x = X - M_x$ i $y = Y - M_y$ (odstupanje od aritmetičkih sredina), a N je veličina uzorka, odnosno broj parova podataka.

Transformacijom osnovne formule dobija se sljedeća formula za izračunavanje korelacije iz sirovih ili negrupisanih podataka:

$$r_{XY} = \frac{N\sum XY - (\sum X)(\sum Y)}{\sqrt{[N\sum X^2 - (\sum X)^2]\,[N\sum Y^2 - (\sum Y)^2]}}$$

Prednost ove formule je u tome što je potrebno da se znaju samo sirovi podaci za X i Y, a standardne devijacije nisu potrebne.

Stepen vjerovatnoće (*p vrijednost*) je kriterijum pouzdanosti, odnosno greška sa kojom se prihvata ili odbacuje postavljena statistička hipoteza. Ukoliko je koeficijent korelacije značajan s obzirom na postavljenu granicu značajnosti (uobičajeno, $p < 0{,}05$) može se zaključiti da je koeficijent korelacije statistički značajan i da se smije tumačiti. Sa druge strane, ako je vrijednost *p* veća od postavljene granice značajnosti, može se zaključiti da koeficijent korelacije nije statistički značajan i ne smije se tumačiti. Stepen vjerovatnoće u istraživanju precizno je utvrđen pomoću korištenog statističkog programa, kako se ne bi izveli pogrešni zaključci o uticaju analiziranih faktora na nekvalitetne kredite u bankarskom sektoru BiH.

1.5.2. Specifikacija modela regresione analize

Regresiona analiza je korištena da bi se odredio statistički model pomoću koga se može formulisati regresioni model na osnovu koga se može opisati, predvidjeti i kontrolisati zavisna promjenljiva na osnovu jedne ili više objašnjavajućih promjenljivih. U istraživanju se prvo posmatraju dvije promjenljive između kojih postoji linearna povezanost (zavisna i nezavisna promjenljiva), tako da se koristi prosta linearna regresija. Nakon toga, posmara se povezanost između zavisne promjenljive i svih nezavisnih promjenljivih koje su uključene u istraživanje, tako da se koristi i višestruka linearna regresija. Pri tom je, i kod proste i kod višestruke regresije, korištena standardna regresija jer se pomoću nje može odrediti koliki dio jedinstvene varijanse zavisne promjenljiva objašnjava svaka od nezavisnih promjenljivih posebno. Pošto se kod regresije najčešće, umjesto termina „nezavisna promjenljiva“ koristi termin „objašnjavajuća promjenljiva“, on će biti korišten u nastavku.

Cilj regresione analize je da se ispita da li objašnjavajuća promjenljiva objašnjava značajan dio varijabiliteta zavisne promjenljive, odnosno da se ispita da li postoji veza i da se odredi koji dio varijabiliteta zavisne promjenljive može biti objašnjen objašnjavajućom promjenljivom. Takođe, pomoću regresione analize može se predvidjeti vrijednost zavisne promjenljive u narednom periodu.

Prosti linearni regresioni model, koji se koristi kod stohastičkih veza, može se predstaviti sljedećom jednačinom:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

Pri tom je:
Y – zavisna promjenljiva,
X – objašnjavajuća promjenljiva,
β_0 – regresioni parametar, odnosno odsječak ili slobodni član,
β_1 – regresioni parametar, odnosno nagib,
ε - stohastički član ili slučajna greška.

Potrebno je napomenuti da regresioni parametar β_0, odnosno odsječak, pokazuje prosječnu vrijednost zavisne promjenljive Y za nultu vrijednost objašnjavajuće promjenljive X. Regresioni parametar β_1, odnosno nagib, pokazuje prosječnu promjenu zavisne promjenljive Y kada se objašnjavajuća promjenljiva X poveća za jednu svoju jedinicu. Stohastički član ili slučajna greška ε je, po statističkoj prirodi, slučajna promjenljiva.

Regresiona analiza počinje procjenom regresionih parametara, a za njihovu ocjenu načešće se koristi metoda najmanjih kvadrata (*Ordinary Least Squares*, OLS metoda). Metoda najmanjih kvadrata zasniva se na minimiziranju kvadrata odstupanja svih empirijskih tačaka od regresione linije, odnosno prave kod koje je zbir vertikalnih odstupanja jednak nuli. Međutim, broj takvih pravih je neograničen, a osnovna ideja metoda najmanjih kvadrata je da se od svih mogućih pravih linija odabere ona koja ima najmanju sumu kvadrata vertikalnih odstupanja.

Regresiona linija izražava se jednačinom regresije:

$$Y = a + b * X$$

Pri tom je:
Y – zavisna promjenljiva,
X – objašnjavajuća promjenljiva,
a – regresiona konstanta,
b – koeficijent regresije.

Promjenljiva Y je zavisna promjenljiva koja se izračunava na osnovu poznate vrijednosti objašnjavajuće promjenljive X, a regresiona konstanta i koeficijent regresije određuju se pomoću metoda najmanjih kvadrata. Regresiona konstanta određuje regresionu pravu, a predstavlja početnu vrijednost zavisne promjenljive Y, odnosno vrijednost prije nego što je objašnjavajuća promjenljiva X počela da djeluje. Sa druge strane, koeficijent regresije određuje nagib regresione prave.

Nakon ocjene regresionih parametara i konstrukcije regresione linije, potrebno je odrediti kvalitet korištenog modela. Uspješnost regresionog modela u opisivanju zavisnosti između pojava vidi se na osnovu dva pokazatelja, i to na osnovu standardne greške regresije i koeficijenta determinacije. Standardna greška regresije je apsolutna mjera koja pokazuje odstupanje empirijskih podataka od regresione linije, a koeficijent determinacije je relativna mjera koja pokazuje učešće varijabiliteta u ukupnom. Ako se prvo radi korelaciona analiza, koeficijent determinacije se može dobiti i kvadriranjem koeficijenta korelacije jer je koeficijent proste linearne korelacije jednak kvadratnom korjenu koeficijenta determinacije.

Sljedeći korak u regresionoj analizi odnosi se na testiranje značajnosti regresione veze koja se u prostoj linearnoj regresiji svodi na testiranje hipoteze da li je parametar nagiba β_1 jednak nuli. Regresioni parametar β_1, odnosno nagib, jednak je nuli kada promjenljive nisu linearno povezane i u tom slučaju se regresiona linija ne smije koristiti u cilju predviđanja vrijednosti zavisne promjenljive.

I posljednji korak regresione analize, koji je ujedno i njen cilj, je predviđanje vrijednosti zavisne promjenljive. Međutim, da bi se prosti linearni model mogao koristiti za predviđanje moraju biti zadovoljena tri uslova. Prvi uslov koji se mora ispuniti vezan je za vrijednost koeficijenta determinacije koja mora biti relativno visoka, a drugi uslov je da je ocjena nagiba statistički značajna. I posljednji, treći uslov koji mora biti ispunjen je da nema prekomjerne ekstrapolacije, koja se javlja ako se prilikom predviđanja zavisne promjenljive koriste vrijednosti objašnjavajuće promjenljive koje su ili manje od minimalne ili veće od maksimalne.

Višestruka regresiona analiza vrši se na isti način kao i prosta, samo se regresioni model i regresiona jednačina razlikuju od modela i jednačine kod proste linearne regresije. Pomoću višestruke linearne regresije može se odrediti povezanost između nezavisne promjenljive i više objašnjavajućih promjenljivih. U modelu višestruke linearne regresije važe sve pretpostavke kao i kod prostog modela, ali moraju biti zadovoljene još dvije dodatne pretpostavke da bi ocjene parametara bile tačne. Pored svega prethodno navedenog, kod višestruke regresije obim uzorka mora biti veći od broja parametara za ocjenjivanje, a objašnjavajuće promjenljive ne treba da budu međusobno korelisane, odnosno linearno zavisne.

Višestruka linearna regresija češće se koristi u praksi, jer ona mnogo realnije opisuje zavisnu promjenljivu na osnovu objašnjavajućih promjenljivih koje na nju utiču. U suštini, višestruka regresija zasniva se na korelaciji, ali omogućuje sofisticiranije istraživanje međusobnih veza između promjenljivih. Ona pokazuje koliko dobro određeni skup promjenljivih predviđa zavisnu promjenljivu, odnosno konkretni ishod. Takođe, višestruka regresija daje ocjenu modela kao cjeline i relativan doprinos svih pojedinačnih promjenljivih od kojih se model sastoji.

Model višestruke linearne regresije može se predstaviti sljedećom jednačinom:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + \varepsilon$$

Pri tom je:
Y – zavisna promjenljiva,
$X_1, X_2, \ldots, X_k$ – objašnjavajuće promjenljive,
$\beta_0, \beta_1, \beta_2, \ldots, \beta_k$ – regresioni parametri,
ε - stohastički član ili slučajna greška,
k – broj objašnjavajućih promjenljivih.

Regresioni parametri se, i u višestrukoj linearnoj regresiji, ocjenjuju metodom najmanjih kvadrata. Vrijednosti regresionih parametara uz objašnjavajuće promjenljive pokazuju koliko se prosječno promijeni zavisna promjenljiva kada se posmatrana objašnjavajuća promjenljiva poveća za jednu svoju jedinicu, a sve druge objašnjavajuće promjenljive ostanu nepromijenjene.

Kod višestruke linearne regresije regresiona linija se izražava jednačinom višestruke regresije:

$$Y = a + b_1X_1 + b_2X_2 + \cdots + b_kX_k$$

Pri tom je:

Y – zavisna promjenljiva,

X_1, X_2, ..., X_k – objašnjavajuće promjenljive,

a – regresiona konstanta,

b_1, b_2, ..., b_k – koeficijenti regresije,

k – broj objašnjavajućih promjenljivih.

Zavisna promjenljiva Y određuje se na osnovu poznatih vrijednosti objašnjavajućih promjenljivih X_1, X_2, ..., X_k, a regresiona konstanta i koeficijenti regresije metodom najmanjih kvadrata.

Multikolinearnost je problem koji se veoma često pojavljuje u višestrukoj regresiji, a pokazuje kolika je međuzavisnost između objašnjavajućih promjenljivih. Ukoliko je multikolinearnost velika, tada se ne može tačno odrediti koliki je relativni uticaj objašnjavajućih promjenljivih. Jedan od pokazatelja multikolinearnosti su koeficijenti proste linearne korelacije, a ako je njihova vrijednost veća od 0,7, tada postoji ozbiljan problem.

2. REZULTATI ISTRAŽIVANJA

U ovom poglavlju dati su rezultati istraživanja, a na osnovu njih formulisan je zaključak. U prvom dijelu poglavlja dat je pregled kretanja vrijednosti makroekonomskih i specifičnih bankarskih promjenljivih u BiH, u periodu od 2006. do kraja 2015. godine. U drugom dijelu poglavlja dati su rezultati deskriptivne statistike, a u trećem su predstavljeni dijagrami raspršenosti koji prikazuju veze između analiziranih promjenljivih. Nakon toga, u četvrtom dijelu dati su rezultati korelacione analize, dok su rezultati regresione analize dati u petom dijelu ovog poglavlja. U šestom dijelu poglavlja dat je trend kretanja nekvalitetnih kredita u bankarskom sektoru BiH, odnosno bankarskim sektorima u RS i FBiH, u periodu od 2006. do kraja 2015. godine. Kvantitativni podaci koji su korišteni u istraživanju preuzeti su od Centralne banke BiH, Agencije za statistiku BiH i Agencije za rad i zapošljavanje BiH, a obrađeni su pomoću statističkog programa *IBM SPSS Statistics Version 20*. U posljednjem, sedmom dijelu ovog poglavlja dati su rezultati sprovedenog anketiranja, a predstavljeni su pomoću tabela i grafikona koji su kreirani pomoću *Microsoft Excel*-a.

2.1. Promjenljive u istraživanju

U literaturi postoji mnogo studija u kojima se analizira uticaj makroekonomskih i/ili specifičnih bankarskih faktora na nekvalitetne kredite u bankama i bankarskim sektorima širom svijeta, ali nema mnogo studija koje su sprovedene u BiH. Upravo zbog toga sprovedeno je ovo istraživanje, a autor se nada da će rezultati istraživanja doprinijeti postojećoj literaturi. U ovom istraživanju zavisna promjenljiva je udio nekvalitetnih u ukupnim bruto kreditima, a nezavisnih, odnosno objašnjavajućih promjenljivih ima ukupno devet (tri makroekonomske i šest specifičnih bankarskih promjenljivih). Detaljan opis svih promjenljivih dat je u drugom dijelu disertacije, a očekivani uticaj nezavisnih na zavisnu promjenljivu dat je u prethodnom poglavlju.

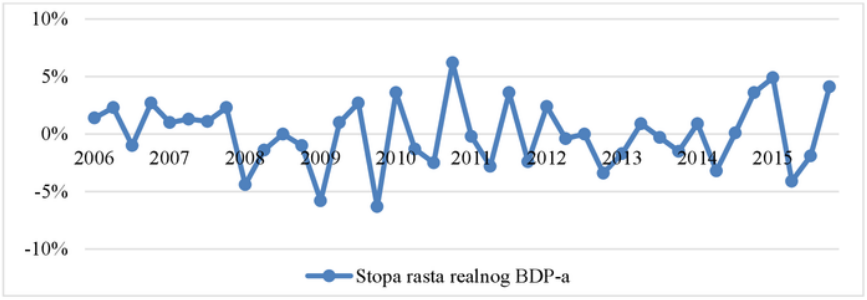
U nastavku je dat pregled glavnih ekonomskih indikatora u BiH u periodu od prvog kvartala 2006. do kraja četvrtog kvaratala 2015. godine. Takođe, dat je i pregled osnovnih karakteristika bankarskog sektora BiH u istom periodu. Navedeni podaci korišteni su prilikom analize faktora koji utiču na nekvalitetne kredite u bankarskom sektoru BiH.

2.1.1. Ekonomska kretanja u Bosni i Hercegovini

Glavni ekonomski indikatori u BiH najbolje oslikavaju njena ekonomska kretanja. U ovo istraživanje uključene su tri makroekonomske promjenljive i to: stopa rasta realnog bruto domaćeg proizvoda, stopa nezaposlenosti i stopa rasta potrošačkih cijena kao mjera inflacije. Podaci o stopi rasta bruto domaćeg proizvoda preuzeti su od Agencije za statistiku BiH, podaci o nezaposlenosti od Agencije za rad i zapošljavanje BiH, a podaci o stopi rasta potrošačkih cijena od Centralne banke BiH. Svi podaci izraženi su kvartalno, a obuhvataju period od početka 2006. do kraja 2015. godine.

Stopa rasta realnog bruto domaćeg proizvoda prikazana je grafikonom 27 i oslikava stanje privrede u BiH tokom analiziranog desetogodišnjeg perioda.

Grafikon 27: Stopa rasta realnog BDP-a u BiH (2006 – 2015)

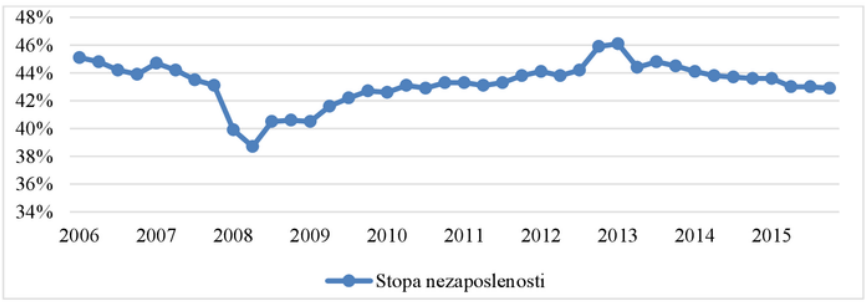


Izvor: (Agencija za statistiku BiH, 2017)

Predstavljeni podaci pokazuju da je stopa rasta realnog BDP-a u BiH, tokom analiziranog desetogodišnjeg perioda, kontinuirano mijenjala vrijednost. Na kraju prvog kvartala 2006. godine iznosila je 1,4%, a na kraju četvrtog kvartala 2015. godine 4,1%, odnosno 2,7% više nego na početku analiziranog perioda. Na kraju četvrtog kvartala 2010. godine zabilježena je najveća stopa rasta realnog BDP-a (6,2%), a najniža stopa rasta, odnosno pada realnog BDP-a (-6,3%) zabilježena je godinu dana prije, odnosno na kraju 2009. godine.

Stopa nezaposlenosti prikazana je grafikonom 28.

Grafikon 28: Stopa nezaposlenosti u BiH (2006 – 2015)

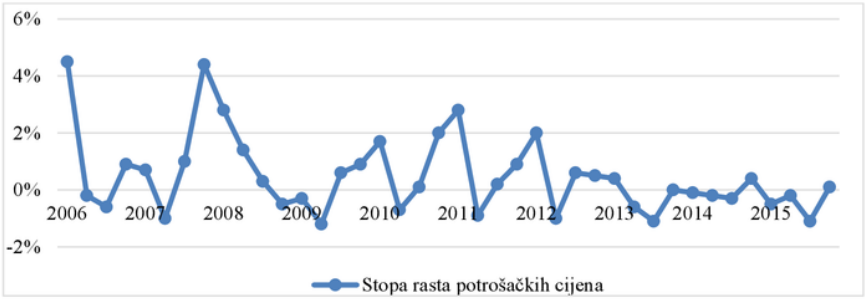


Izvor: (Agencija za rad i zapošljavanje BiH, 2017)

Sudeći po stopi nezaposlenosti, može se konstatovati da je nezaposlenost jedan od većih problema u BiH. Predstavljeni podaci pokazuju da je stopa nezaposlenosti, tokom analiziranog desetogodišnjeg perioda, bila iznad 40%, a izuzetak su samo prvi i drugi kvartal 2008. godine kada je iznosila 39,9%, odnosno 38,7%, respektivno. Najveća nezaposlenost zabilježena je tokom 2013. godine. Na kraju 2015. godine stopa nezaposlenosti iznosila je 42,9%, što je za 2,2% manje nego na početku analiziranog perioda (prvi kvartal 2006. godine).

Stopa inflacije u BiH iskazuje se preko stope rasta potrošačkih cijena. Trend kretanja stope rasta potrošačkih cijena prikazan je grafikonom 29.

Grafikon 29: Stopa rasta potrošačkih cijena u BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Predstavljeni podaci pokazuju trend kretanja stope rasta potrošačkih cijena u BiH tokom analiziranog desetogodišnjeg perioda. Vidi se da je najveća stopa rasta potrošačkih cijena zabilježena na kraju prvog kvartala 2006. godine kada je iznosila 4,5%, a deset godina kasnije, na kraju četvrtog kvartala 2015. godine iznosila je 0,1%, odnosno 4,4% manje nego na početku analiziranog perioda. Najniža stopa rasta potrošačkih cijena zabilježena je za vrijeme globalne finansijske krize, odnosno na kraju drugog kvartala 2009. godine, kada je deflacija iznosila 1,2%.

Na osnovu prethodno navedenog može se stvoriti slika o stanju i ekonomskim aktivnostima u BiH tokom analiziranog perioda. Ekonomiju BiH u 2006. godini obilježio je jedan važan događaj, a to je uvođenje PDV-a. Takođe, u istoj godini zabilježeno je povećanje stope rasta realnog BDP-a, nezaposlenost je bila prilično visoka, a poslije dužeg perioda niske inflacije zabilježeno je značajno povećanje, što se vidi na osnovu stope rasta potrošačkih cijena koja je na kraju godine iznosila 0,9%. Ovo povećanje nije uzrokovano isključivo uvođenjem PDV-a, na povećanje je uticao i rast cijena energenata i sezonsko kretanje cijena.

Sljedeću, 2007. godinu obilježilo je blago povećanje stope rasta realnog BDP-a, pa je godišnja stopa rasta iznosila 5,7% i veća je za 0,3% u odnosu na godišnju stopu iz 2006. godine. Tokom iste godine stopa nezaposlenosti je blago smanjenja, ali je stopa rasta potrošačkih cijena značajno povećana u odnosu na 2006. godinu.

Ekonomski ambijent u 2008. godini bio je znatno drugačiji u donosu na prethodne godine, a ekonomski rast, mjeren godišnjom stopom rasta relanog BDP-a iznosio je - 6,8% i bio je za 12,5% manji nego u 2007. godini. Tokom iste godine nezaposlenost u BiH, mjerena stopom nezaposlenosti, bila je najniža u analiziranom desetogodišnjem periodu. Iako je stopa rasta potrošačkih cijena imala pozitivnu vrijednost do kraja trećeg kvartala, na kraju godine zabilježena je deflacija od 0,5%.

Ekonomija u BiH je, tokom 2009. godine imala izraženu kontrakciju uzrokovanu globalnom finansijskom krizom. Iako su se prvi znaci globalne finansijske krize u BiH osjetili već 2008. godine, posljedice krize odrazile su se u prvoj polovini 2009. godine. Tokom ove godine nastavljeno je povećanje stope pada realnog BDP-a, a povećana je i stopa nezaposlenosti. Usljed uticaja globalne finansijske krize došlo je do usporavanja ukupnih ekonomskih aktivnosti i pada tražnje na svjetskim tržištima, što je uslovilo i pad cijena energenata i hrane, tako da je u većem dijelu 2009. godine u BiH zabilježena negativna inflacija, odnosno deflacija.

Nakon negativnih trendova koji su uzrokovani globalnom finansijskom krizom, u 2010. godini zabilježen je blagi oporavak. Realni ekonomski rast koji je ostvaren u 2010. godini iznosio je 6,0%, ali je tokom godine povećana nezaposlenost. Zabilježen je i postepeni oporavak vodećih svjetskih ekonomija koji prati blaga inflacija, a na kraju 2010. godine inflacija u BiH bila je približno ista kao i u Evropskoj uniji (u BiH stopa rasta potrošačkih cijena iznosila je 2,0%, a u Evropskoj uniji 2,1%).

Ekonomska kretanja u 2011. godini bila su manje dinamična od kretanja u 2009. i 2010. godini, a trend blagog oporavka ekonomije nakon globalne finansijske krize je nastavljen. Stopa rasta realnog BDP-a tokom 2011. godine bila je manja od očekivane jer su na realni ekonomski rast u velikoj mjeri uticala inflatorna kretanja. Prosječaj rast cijena tokom 2011. godine bio je naglašeniji nego u prethodnoj godini, a blago je povećana i stopa nezaposlenosti.

Pozitivna ekonomska kretanja i postepeni oporavak ekonomije naglo je zaustavljen tokom 2012. godine, što je posljedica recesionih kretanja u evrozoni i u zemljama regiona. To je dovelo i do recesionih kretanja u BiH, tako da je godišnji realni pad BDP-a iznosio 1,4%. Tokom 2012. godine ekonomija u BiH nije bila izložena inflatornim pritiscima, tako da je stopa rasta potrošačkih cijena smanjena. Ipak, tokom godine povećana je stopa nezaposlenosti.

Tokom 2013. godine došlo je do blagog oporavka ekonomske aktivnosti u BiH, odnosno došlo je do povećanja godišnje stope pada realnog BDP-a i smanjenja stope nezaposlenosti. Trend usporavanja inflacije iz 2012. godine je nastavljen, tako da je u 2013. godini godišnja inflacija, mjerena stopom rasta potrošačkih cijena, bila – 1,3%.

Nezapamćene poplave tokom 2014. godine usporile su ekonomske aktivnosti u BiH, pa je stopa rasta realnog BDP-a iznosila 1,4%, odnosno 4,0% više nego u prethodnoj godini. Došlo je i do blagog smanjenja stope nezaposlenosti, mada je nezaposlenost u BiH još uvijek veoma velika. Deflatorni pritisci iz 2013. godine su popustili, ali su, uprkos tome, opšte potrošačke cijene bile niže nego u prethodnoj godini.

Tokom 2015. godine ekonomija u BiH zabilježila je pozitivna kretanja koja se ogledaju u povećanju godišnje stope rasta realnog BDP-a koja je iznosila 3,0%, odnosno 1,6% više nego u 2014. godini. Takođe, zabilježeno je blago smanjenje nezaposlenosti, a smanjenje su i prosječne potrošačke cijene, što je uglavnom diktirano spoljnim cijenama nafte i hrane.

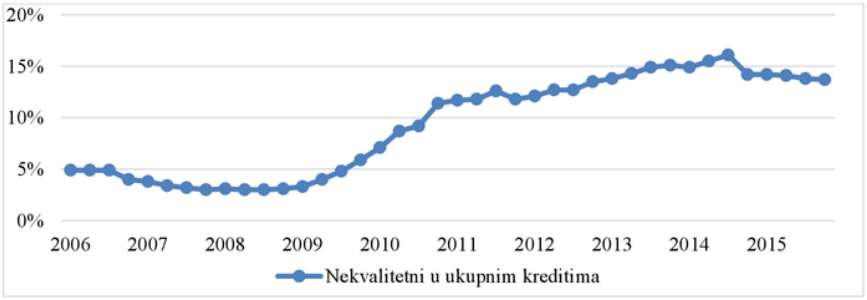
2.1.2. Bankarski sektor

Glavni pokazatelji bankarskog sektora u BiH najbolje prikazuju stanje sektora tokom analiziranog desetogodišnjeg perioda. Iako ih ima više, u ovo istraživanje je uključeno ukupno sedam promjenljivih koje oslikavaju stanje u bankarskom sektoru BiH. Specifične bankarske promjenljive koje su uključene u istraživanje su: nekvalitetni u ukupnim kreditima, koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, aktivna kamatna stopa i kreditni rast. Pri tom je jedna promjenljiva zavisna (nekvalitetni krediti), a ostale promjenljive su nezavisne u korelacionoj, odnosno objašnjavajuće u regresionoj analizi.

Svi podaci o specifičnim bankarskim promjenljivim koje su uključene u istraživanje preuzeti su od Centralne banke BiH, a izraženi su na tromjesečnom (kvartalnom) nivou. Prikupljeni su svi podaci od prvog kvartala 2006. do kraja četvrtog kvartala 2015. godine.

Trend kretanja nekvalitetnih u ukupnim bruto kreditima bankarskog sektora BiH prikazan je grafikonom 30.

Grafikon 30: Nekvalitetni krediti bankarskog sektora BiH (2006 – 2015)

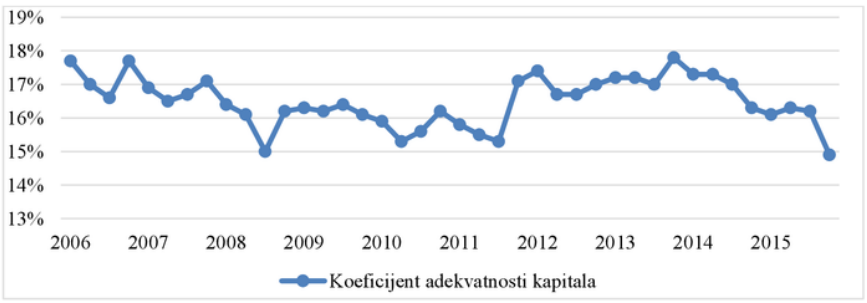


Izvor: (CBBiH, 2017)

Predstavljeni podaci pokazuju da su nekvalitetni krediti u bankarskom sektoru BiH, tokom analiziranog desetogodišnjeg perioda, uglavnom imali trend rasta. Izuzetak je period od četvrtog kvartala 2006. do kraja četvrtog kvartala 2007. godine i od drugog kvartala 2015. godine do kraja analiziranog perioda, kada je zabilježeno blago smanjenje udjela nekvalitetnih u ukupnim bruto kreditima. Udio nekvalitetnih kredita je, sa početnih 4,9% na kraju prvog kvartala 2006. godine, postepeno rastao, da bi na kraju analiziranog perioda iznosio 13,7%, odnosno 8,8% više. Najveći udio nekvalitetnih u ukupnim kreditima zabilježen je na kraju trećeg kvartala 2015. godine. Povećanje učešća nekvalitetnih u ukupnim kreditima posebno je izraženo od sredine 2009. godine, što je direktna posljedica globalne finansijske krize.

Koeficijent adekvatnosti kapitala bankarskog sektora BiH prikazan je na grafikonu 31.

Grafikon 31: Koeficijent adekvatnosti kapitala bankarskog sektora BiH (2006 – 2015)

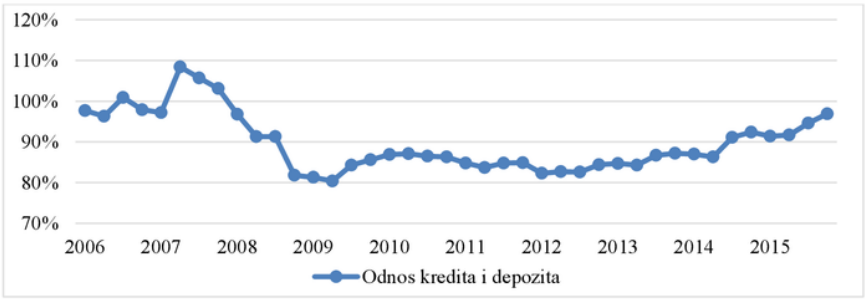


Izvor: (CBBiH, 2017)

Koeficijent adekvatnosti kapitala je, sa početnih 17,7% na kraju prvog kvartala 2006. godine smanjen na 14,9% na kraju četvrtog kvartala 2015. godine, odnosno 2,8%. Bankarski sektor najbolje je bio kapitalizovan na kraju četvrtog kvartala 2013. godine, a najslabije na kraju analiziranog perioda. Važno je istaći činjenicu da je koeficijent adekvatnosti kapitala, tokom cjelokupnog analiziranog perioda, bio iznad 12%, koliko iznosi zakonski propisani minimum.

Odnos kredita i depozita je jedan od pokazatelja likvidnosti, a vrijednost ovog pokazatelja prikazana je grafikonom 32.

Grafikon 32: Odnos kredita i depozita u bankarskom sektoru BiH (2006 – 2015)

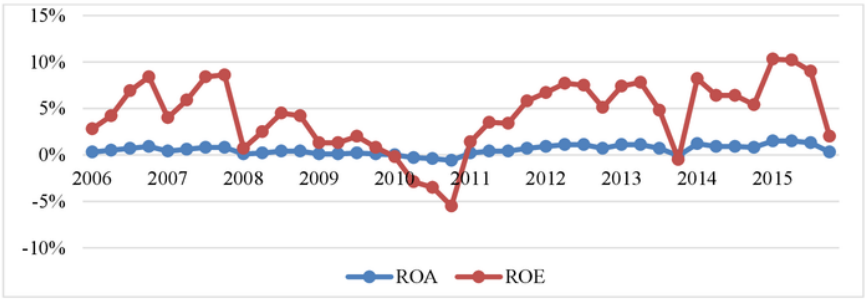


Izvor: (CBBiH, 2017)

Odnos kredita i depozita bankarskog sektora BiH je, na početku analiziranog perioda, iznosio 97,7%, a njegova vrijednost je bila približno ista i na kraju analiziranog perioda, kada je iznosio 96,9%. Najveću vrijednost ovaj pokazatelj likvidnosti dostigao je na kraju drugog kvartala 2007. godine (108,4%), a najmanju na kraju drugog kvartala 2009. godine (80,4%).

Pokazatelji profitabilnosti bankarskog sektora BiH, odnosno prinos na aktivu i prinos na akcijski kapital, prikazani su na grafikonu 33.

Grafikon 33: Prinos na aktivu i prinos na akcijski kapital u bankarskom sektoru BiH (2006 – 2015)

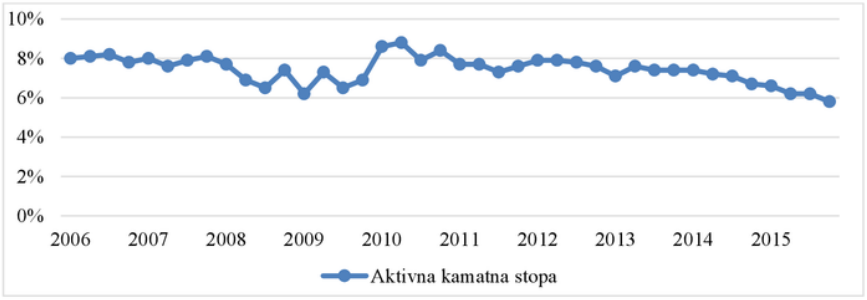


Izvor: (CBBiH, 2017)

Pokazatelji profitabilnosti bankarskog sektora BiH imali su negativnu vrijednost tokom 2010. i na kraju 2013. godine, kada je bankarski sektor BiH ostvario negativan finansijski rezultat, odnosno gubitak. Najveća profitabilnost u bankarskom sektoru BiH ostvarena je tokom 2015. godine. Na početku analiziranog perioda prinos na aktivu iznosio je 0,3%, a isto toliko iznosio je i na kraju 2015. godine. Prinos na akcijski kapital iznosio je 2,8% na početku, 2,0% na kraju analiziranog perioda, odnosno 0,8% manje.

Visina aktivnih kamatnih stopa po kojima su komercijalne banke plasirale kredite prikazana je grafikonom 34.

Grafikon 34: Aktivna kamatna stopa u bankarskom sektoru BiH (2006 – 2015)

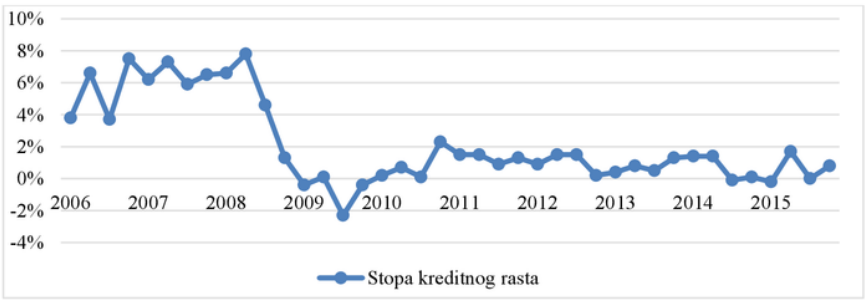


Izvor: (CBBiH, 2017)

Aktivna kamatna stopa, po kojoj su komercijalne banke obračunavale kamatu koju su naplaćivale za plasirane kredite pravnim i fizičkim licima, iznosila je 8,0% na kraju prvog kvartala 2006. godine. Na kraju četvrtog kvartala 2015. godine bila je za 2,2% manja i iznosila je 5,8%. Od početka 2014. godine aktivne kamatne stope kontinuirano su se smanjivale, tako da su sa 7,4% (na kraju prvog kvartala 2014. godine) smanjenje na 5,8% (na kraju četvrtog kvartala 2015. godine). Na osnovu navedenog, vidi se da su komercijalne banke smanjile aktivnu kamatnu stopu, što je posebno značajno korisnicima kredita.

I posljednja promjenljiva koja opisuje stanje u bankarskom sektoru BiH je kreditni rast. Stopa kreditnog rasta prikazana je na grafikonu 35.

Grafikon 35: Kreditni rast u bankarskom sektoru BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

Predstavljeni podaci pokazuju da su kreditne aktivnosti komercijalnih banaka bile izraženije na početku analiziranog perioda, kada je stopa kreditnog rasta bila iznad 3,5%, a na kraju drugog kvartala 2008. godine dostigla je vrijednost od 7,8%. Od tada, kreditne aktivnosti komercijalnih banaka se značajno smanjuju, pa je, na kraju prvog kvartala 2009. godine, zabilježena stopa pada od 0,4%. Najveća stopa pada zabilježena je krajem trećeg kvartala 2009. godine, što je posljedica globalne finansijske krize. Od 2010. godine kreditne aktivnosti u bankarskom sektoru su usporene, što se vidi po stopi kreditnog rasta koja do kraja 2015. godine nije bila iznad 1,7%. Na kraju analiziranog perioda stopa kreditnog rasta iznosila je 0,8%, odnosno 3,0% manje nego na početku analiziranog perioda.

Na kraju, može se konstatovati da je udio nekvalitetnih u ukupnim bruto kreditima bankarskog sektora BiH značajno povećan tokom analiziranog perioda. Ipak, tokom 2015. godine učešće nekvalitetnih kredita je smanjeno u odnosu na 2014. godinu. Međutim, ovo smanjenje je vjerovatno odraz različite procjene kvaliteta kredita pojedinačnih banaka, restrukturiranja poslovanja i otpisa iz prethodnih godina, a ne sistemskog poboljšanja kvaliteta kredita.

Tokom analiziranog desetogodišnjeg perioda promijenjeni su i ostali pokazatelji stanja u bankarskom sektoru BiH. Koeficijent adekvatnosti kapitala se mijenjao u analiziranom periodu, a na kraju 2015. godine bio je manji nego na kraju 2006. godine. Iako je koeficijent adekvatnosti kapitala smanjen, njegova vrijednost je uvijek, tokom analiziranog perioda, bila veća od zakonski propisane minimalne vrijednosti od 12%. I pokazatelji profitabilnosti su značajno smanjeni u analiziranom periodu, a dva puta su imali negativnu vrijednost, zbog gubitka koji je ostvaren u bankarskom sektoru BiH. Aktivna kamatna stopa po kojoj banke obračunavaju kamate za plasirane kredite smanjena je u analiziranom periodu. Takođe, smanjene su i kreditne aktivnosti komercijalnih banaka, a najveće smanjenje zabilježeno je tokom 2008. i 2009. godine, što je direktna posljedica globalne finansijske krize.

Na kraju, važno je napomenuti da su navedene vrijednost svih makroekonomskih i specifičnih bankarskih promjenljivih korištene prilikom analiziranja faktora koji utiču na nekvalitetne kredite u bankarskom sektoru BiH, odnosno u korelacionoj i regresionoj analizi.

2.2. Deskriptivna statistika

Metode deskriptivne statistike primijenjene su za sve promjenljive koje se koriste u istraživanju, odnosno za jednu zavisnu promjenljivu (nekvalitetni krediti) i devet nezavisnih, odnosno objašnjavajućih promjenljivih (stopa rasta realnog BDP-a, stopa nezaposlenosti, stopa rasta potrošačkih cijena, koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, aktivna kamatna stopa i stopa kreditnog rasta). Rezultati deskriptivne statistike pokazuju broj zapažanja (*N*), minimalnu (*Minimum*) i maksimalnu (*Maximum*) vrijednost, aritmetičku sredinu (*Mean*) i standardnu devijaciju[8] (*Std. Deviation*) za sve promjenljive koje se koriste u istraživanju.

Za svaku promjenljivu prikupljeno je po 40 zapažanja jer su analizirani kvartalni podaci koji obuhvataju period o početka 2006. do kraja 2015. godine. Prikupljene su sve vrijednosti za sve promjenljive tokom analiziranog desetogodišnjeg perioda, tako da nema nedostajućih podataka.

Rezultati deskriptivne statistike prikazani su u tabeli 22.[9]

[8] Standardna devijacija pokazuje odstupanje od aritmetičke sredine

[9] U tekstu u kome se opisuju rezultati deskriptivne statistike, dobijeni pomoću softverskog programa *IBM SPSS Statistics Version 20*, koji su dati u tabeli 28, brojevi su odvojeni zarezom, a ne tačkom (kao što je navedeno u tabeli), kako bi se postigla jednoobraznost u tekstu.

Tabela 22: Rezultati deskriptivne statistike

	N	Minimum	Maximum	Mean	Std. Deviation
NPL	40	3.0	16.1	9.305	4.8162
GDP	40	-6.3	6.2	.013	2.8796
UNEMP	40	38.7	46.1	43.277	1.5475
ICP	40	-1.2	4.5	.467	1.3723
CAR	40	14.9	17.8	16.500	.7334
LTD	40	80.4	108.4	89.783	7.1043
ROA	40	-.6	1.5	.550	.5028
ROE	40	-5.5	10.3	4.323	3.7670
IR	40	5.8	8.8	7.425	.6949
[illegible]	40	-2.3	7.8	2.137	2.6567
Valid N (listwise)	40				

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Rezultati deskriptivne statistike pokazuju da se udio nekvalitetnih u ukupnim bruto kreditima (promjenljiva NPL) bankarskog sektora BiH kretau u intervalu od 3,0% do 16,1% tokom analiziranog desetogodišnjeg perioda. Minimalna vrijednost zabilježena je na kraju četvrtog kvartala 2007. i na kraju drugog i trećeg kvartala 2008. godine, a maksimalna vrijednost zabilježena je na kraju trećeg kvartala 2014. godine. Srednja vrijednost udjela nekvalitetnih u ukupnim bruto kreditima, tokom analiziranog perioda, iznosila je 9,31%, a odstupanje od srednje vrijednosti (standardna devijacija) 4,82%.

Stopa rasta realnog BDP-a (promjenljiva GDP) bila je u intervalu od - 6,3% do 6,2% tokom analiziranog perioda. Stopa pada realnog BDP-a od 6,3% zabilježena je na kraju četvrtog kvartala 2009. godine, a najveća stopa rasta realnog BDP-a zabilježena je na kraju četvrtog kvartala 2010. godine. Srednja vrijednost stope rasta realnog BDP-a tokom analiziranog desetogodišnjeg perioda iznosila je 0,01%, a odstupanje od srednje vrijednosti iznosilo je 2,88%.

Stopa nezaposlenosti (promjenljiva UNEMP) u BiH kretala se u intervalu od 38,7% do 46,1% tokom analiziranog perioda. Najniža stopa nezaposlenosti zabilježena je na kraju drugog kvartala 2008. godine, a najviša na kraju prvog kvartala 2013. godine. Srednja vrijednost stope nezaposlenosti iznosila je 43,28%, sa odstupanjem od srednje vrijednosti u iznosu od 1,55%.

Inflacija u BiH, mjerena stopom rasta potrošačkih cijena (promjenljiva ICP), kretala se u intervalu od -1,2% do 4,5%. Najniža stopa inflacije, odnosno stopa deflacije od 1,2% zabilježena je na kraju drugog kvartala 2009. godine, a najveća inflacija zabilježena je na početku analiziranog perioda, odnosno na kraju prvog kvartala 2006. godine. Prosječna inflacija tokom analiziranog perioda iznosila je 0,47%, a odstupanje od prosječne vrijednosti iznosilo je 1,37%.

Koeficijent adekvatnosti kapitala (promjenljiva CAR) bankarskog sektora BiH kretao se u intervalu od 14,9% do 17,8% tokom analiziranog perioda. Najniža vrijednost koeficijenta adekvatnosti kapitala zabilježena je na kraju analiziranog perioda, odnosno na kraju četvrtog kvartala 2015. godine, a najviša vrijednost zabilježena je na kraju četvrtog kvartala 2013. godine. Srednja vrijednost ovog koeficijenta, tokom analiziranog desetogodišnjeg perioda, iznosila je 16,50%, a odstupanje od srednje vrijednosti bilo je veoma malo i iznosilo je 0,73%.

Pokazatelj likvidnosti bankarskog sektora, promjenljiva LTD koja pokazuje odnos kredita i depozita, kretao se u intervalu od 80,4% do 108,4%. Najniža vrijednost ovog pokazatelja likvidnosti zabilježena je na kraju drugog kvartala 2009. godine, a najviša vrijednost zabilježena je dvije godine ranije, odnosno na kraju drugog kvartala 2007. godine. Srednja vrijednost odnosa kredita i depozita tokom analiziranog perioda iznosila je 89,78%, sa odstupanjem od srednje vrijednosti u iznosu od 7,10%.

Profitabilnost bankarskog sektora BiH, mjerena prinosom na aktivu (promjenljiva ROA), kretala se u intervalu od -0,6% do 1,5% tokom analiziranog desetogodišnjeg perioda. Bankarski sektor BiH je poslovnu 2010. godinu završio sa negativnim finansijskim rezultatom, tako da je tada zabilježena najniža vrijednost prinosa na aktivu, a najveću profitabilnost bankarski sektor ostvario je tokom 2015. godine, kada je prinos na aktivu iznosio 1,5%. Srednja vrijednost prinosa na aktivu tokom analiziranog perioda iznosila je 0,55, sa odstupanjem od srednje vrijednosti u iznosu od 0,50%.

Profitabilnost bankarskog sektora, mjerena prinosom na akcijski kapital (promjenljiva ROE) kretala se u intervalu od -5,5% do 10,3% tokom analiziranog perioda. Prinos na akcijski kapital bio je najniži na kraju četvrtog kvartala 2010. godine, a najviši na kraju prvog kvartala 2015. godine. Prosječna vrijednost prinosa na akcijski kapital iznosila je 4,32%, sa odstupanjem od prosječne vrijednosti u iznosu od 3,77%.

Aktivna kamatna stopa, po kojoj su komercijalne banke u BiH obračunavale kamatu koju su naplaćivale za plasirane kredite, kretala se u intervalu od 5,8% do 8,8%. Najnižu kamatnu stopu komercijalne banke su imale na kraju analiziranog perioda, odnosno na kraju četvrtog kvartala 2015. godine, dok je najviša kamatna stopa po kojoj su plasirani krediti u bankarskom sektoru BiH zabilježena je na kraju drugog kvartala 2010. godine. Prosječna aktivna kamatna stopa u toku analiziranog desetogodišnjeg perioda iznosila je 7,43%, sa odstupanjem od prosječne vrijednosti od 0,69%.

Stopa kreditnog rasta (promjenljiva CG) kretala se u intervalu od -2,3% do 7,8%. Najveća stopa kreditnog pada zabilježena je na kraju trećeg kvartala 2009. godine, a najveća stopa kreditnog rasta na kraju drugog kvartala 2008. godine. Prosječna vrijednost stope kreditnog rasta tokom analiziranog desetogodišnjeg perioda iznosila je 2,14%, a odstupanje od prosječne vrijednosti iznosilo je 2,66%.

Na kraju, može se konstatovati da je najveće odstupanje (7,10%) od prosječne vrijednosti zabilježeno kod promjenljive LTD, koja pokazuje odnos kredita i depozita, a najmanje odstupanje (0,50%) zabilježeno je kod promjenljive ROA, koja pokazuje prinos na aktivu. Takođe, može se primijetiti da su komercijalne banke ostvarile veći prinos na akcijski kapital, nego što su ostvarile prinos na aktivu. Prosječna vrijednost koeficijenta adekvatnosti kapitala iznosila je 16,50% i veća je od zakonski propisanog minimuma od 12%.

Prosječna vrijednost udjela nekvalitetnih u ukupnim kreditima je na visokom nivou i iznosi 9,30%, tako da nekvalitetni krediti predstavljaju ozbiljnu prijetnju finansijskom rezultatu bankarskog sektora BiH, ali i njegovoj finansijskoj stabilnosti. Upravo zbog toga, neophodno je identifikovati faktore koji utiču nekvalitetne kredite, kako bi se mogle odrediti konkretne mjere za upravljanje kreditnim rizikom u bankarskom sektoru BiH. To je urađeno pomoću korelacione i regresione analize koja je sprovedena nad prethodno navedenim podacima koji prikazuju ekonomska kretanja i stanje u bankarskom sektoru u BiH.

2.3. Procjena normalnosti raspodjele i transformacija promjenljivih

Prije sprovođenja korelacione i regresione analize potrebno je provjeriti da li su ispunjeni svi neophodni uslovi za njihovu primjenu. Tu se prije svega misli na procjenu normalnosti raspodjele, jer se ove dvije statističke tehnike zasnivaju na pretpostavci da je raspodjela promjenljivih normalna. Normalna raspodjela je simetrična, zvonolika kriva sa najvećim brojem rezultata u sredini, a manjim brojem rezultata na krajevima zvona.

Procjena normalnosti raspodjele za sve promjenljive koje su uključene u istraživanje izvršena je pomoću statističkog programa *IBM SPSS Statistics Version 20*. Procjena normalnosti raspodjele zasniva se na testovima normalnosti (*Tests of Normality*), a na osnovu vrijednosti *Kolmogorov – Smirnov* pokazatelja zaključuje se da li određena promjenljiva ima ili nema normalnu raspodjelu. Normalnost se pokazuje statistički neznačajnim, odnosno slučajnim odstupanjem od normanosti, tj. iznosom Sig. većim od 0,05.

Rezultati testova normalnosti koji su sprovedeni nad zavisnom i nezavisnim, odnosno objašnjavajućim promjenljivim koje su uključene u istraživanje dati su u tabeli 23.

Tabela 23: Rezultati testova normalnosti raspodjele

	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
NPL	.195	40	.001	.846	40	.000
GDP	.071	40	.200*	.992	40	.991
UNEMP	.179	40	.002	.919	40	.007
ICP	.151	40	.022	.877	40	.000
CAR	.102	40	.200*	.973	40	.456
LTD	.217	40	.000	.905	40	.003
ROA	.092	40	.200*	.983	40	.783
ROE	.084	40	.200*	.963	40	.217
IR	.124	40	.120	.969	40	.331
CG	.270	40	.000	.845	40	.000

*. This is a lower bound of the true significance.
a. Lilliefors Significance Correction

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Rezultati pokazuju da pet promjenljivih ima normalnu raspodjelu, a te promjenljive su: stopa rasta realnog BDP-a (promjenljiva GDP), koeficijent adekvatnosti kapitala (promjenljiva CAR), prinos na aktivu (promjenljiva ROA), prinos na akcijski kapital (promjenljiva ROE) i aktivna kamatna stopa (promjenljiva IR). Sa druge strane, kod nekvalitetnih kredita (promjenljiva NPL), stope nezaposlenosti (promjenljiva UNEMP), stope rasta potrošačkih cijena (promjenljiva ICP), odnosa kredita i depozita (promjenljiva LTD) i stope kreditnog rasta (promjenljiva CG) nije potvrđena normalnost raspodjele.

Da bi se i ove promjenljive mogle uključiti u korelacionu i regresionu analizu, neophodno ih je prvo transformisati. Transformacija promjenljivih podrazumijeva primjenu različitih matematičkih funkcija koje modifikuju rezultate, kako bi se raspodjela približno normalizovala. U istraživanju su izvršene transformacije kod pet promjenljivih (promjenljive NPL, UNEMP, ICP, LTD i CG), nakon kojih je postignuta i njihova normalna raspodjela, tako da nije bilo potrebe za podjelu promjenljivih ili za primjenu neparametarskih tehnika u istraživanju. Transformacija ovih promjenljivih takođe je izvršena pomoću statističkog programa *IBM SPSS Statistics Version 20*, a pregled korištenih transformacija, sa odgovarajućom matematičkom formulom, dat je u tabeli 24.

Tabela 24: Transformacije promjenljivih

STARA PROMJENLJIVA	TRANSFORMACIJA	FORMULA	NOVA PROMJENLJIVA
NPL	Sinus	TNPL = SIN (NPL)	TNPL
UNEMP	Preslikavanje i logaritam	TUNEMP = LG10(K[10] – UNEMP)	TUNEMP
ICP	Logaritam	TICP = LG10 (ICP)	TICP
LTD	Sinus	TLTD = SIN (LTD)	TLTD
CG	Logaritam	TCG = LOG10 (CG)	TCG

Izvor: Izrada autora

Nakon izvršenih transformacija promjenljivih, ponovo je sprovedena procjena normalnosti raspodjele, a rezultati su prikazani u tabeli 25.

Tabela 25: Rezultati testova normalnosti raspodjele nakon transformacije promjenljivih

	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
TNPL	.122	40	.138	.917	40	.006
GDP	.071	40	.200*	.992	40	.991
TUNEMP	.122	40	.137	.943	40	.045
TICP	.079	40	.200*	.965	40	.595
CAR	.102	40	.200*	.973	40	.456
TLTD	.122	40	.137	.928	40	.014
ROA	.092	40	.200*	.983	40	.783
ROE	.084	40	.200*	.963	40	.217
IR	.124	40	.120	.969	40	.331
T	.127	40	.182	.919	40	.015

*. This is a lower bound of the true significance.
a. Lilliefors Significance Correction

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

[10] K = najveća moguća vrijednost promjenljive + 1

Transformacijom promjenljivih postignuta je normalna raspodjela, a i broj zapažanja je ostao isti. Nije rijedak slučaj da se transformacijom podataka smanji broj zapažanja. Ipak, u ovom slučaju broj zapažanja je ostao isti, tako da sve promjenljive u istraživanju, i nakon transformacije, imaju po 40 zapažanja. Dalje u istraživanju, umjesto promjenljivih nekvalitetni krediti (promjenljiva NPL), stopa nezaposlenosti (promjenljiva UNEPM), stope rasta potrošačkih cijena (promjenljiva ICP), odnos kredita i depozita (promjenljiva LTD) i stope kreditnog rasta (promjenljiva CG) koristiće se transformisane promjenljive, odnosno promjenljive TNPL, TUNEMP, TICP, TLTD i TCG, redom.

Pored normalnosti raspodjele, potrebno je odrediti da li je veza između dvije analizirane promjenljive linearna, tj. da li je veza između zavisne i nezavisne, odnosno objašnjavajuće promjenljive, linearna. To se može uraditi pomoću dijagram raspršenosti koji prikazuje vezu između dvije kvantitativne promjenljive, a prilikom konstruisanja dijagrama raspršenosti na apscisnu osu nanose se jedinice pojave koja je označena kao nezavisna u korelacionoj, odnosno objašnjavajuća u regresionoj analizi (promjenljiva X), a na ordinatnu osu jedinice zavisne promjenljive (promjenljiva Y). Pregledom dijagrama raspršenosti može se steći bolja predstava o prirodi veze između analiziranih promjenljivih, odnosno može se odrediti da li između njih postoji veza ili je nema, da li je riječ o linearnoj ili nelinearnoj vezi, da li je smjer veze pozitivan ili negativan i da li je veza jaka ili slaba.

Dijagrami raspršenosti konstruisani su u pravouglom koordinatnom sistemu pomoću statističkog programa *IBM SPSS Statistics Version 20*. Ucrtavanjem svih empirijskih parova podataka za zavisnu i nezavisne promjenljive, utvrđeno je da je riječ o linearnoj povezanosti. S obzirom da promjenljive koje se koriste u istraživanju imaju normalnu raspodjelu, a da je veza između zavisne i nezavisnih promjenljivih linearna, ispunjeni su uslovi za primjenu korelacione i regresione analize, a rezultati su dati u nastavku.

2.4. Korelaciona analiza

U cilju određivanja makroekonomskih i specifičnih bankarskih faktora koji utiču na nekvalitetne kredite, odnosno u cilju dokazivanja pojedinačnih hipoteza u istražvanju, sprovedena je korelaciona analiza. Kvantitativni podaci koji su korišteni u istraživanju prikupljeni su iz više izvora, a obrađeni su pomoću statističkog programa *IBM SPSS Statistics Version 20*. Korelaciona analiza je primjenjena da bi se donijeli zaključci o kvantitativnim faktorima koji utiču na nekvalitetne kredite bankarskog sektora BiH.

Nezavisne promjenljive koje su uključene u korelacionu analizu su: stopa rasta realnog bruto domaćeg proizvoda (GDP), stopa nezaposlenosti (TUNEMP), stopa inflacije mjerena stopom rasta potrošačkih cijena (TICP), koeficijent adekvatnosti kapitala (CAR), odnos kredita i depozita (TLDT), prinos na aktivu (ROA), prinos na akcijski kapital (ROE), aktivna kamatna stopa (IR) i stopa kreditnog rasta (TCG). Važno je napomenuti da se u korelacionoj analizi koriste transformisane[11], a ne izvorne vrijednosti za zavisnu i četiri nezavisne promjenljive.

[11] Izvršena je transformacija promjenljivih kako bi se zadovoljio uslov normalnosti raspodjele.

Istraživanje je sprovedeno sa ciljem da se odredi koja od navedenih nezavisnih promjenljivih utiče na zavisnu promjenljivu (TNPL), odnosno na nekvalitetne kredite u bankarskom sektoru BiH. Obično se u ovakvim istraživanjima testiraju istraživačke hipoteze koje su postavljene na početku istraživanja, a uopšteno se razlikuju dvije vrste hipoteza: nulta koja se označava sa H_0 i sadrži tvrdnju o nepostojanju statističke značajnosti pojave nađene na uzorku, dok afirmativnih hipoteza može biti više i označavaju se sa H_n, gdje je n redni broj hipoteze. Alternativne hipoteze govore o nekim potvrdnim pretpostavkama koje se donose. Prilikom primjene statističkih testova postavlja se i nivo značajnosti, odnosno nivo sigurnosti sa kojim se može tvrditi da je nešto onako kako se tvrdi. Kao standardni nivo pouzdanosti obično se koristi nivo $p = 0,05$, a kao veći stepen pouzdanosti koristi se nivo $p = 0,01$.

Na osnovu *p vrijednosti* koja je dobijena u istraživanju, testira se postojanje linearne korelacije između promjenljivih koje su uključene u istraživanje. Dobijeni rezultat za *p vrijednost* se tumači u skladu sa postavljenim nivoom značajnosti, pa ukoliko je izračunata *p vrijednost* manja od nivoa značajnosti, tada se nulta hipoteza odbacuje. Ukoliko se utvrdi da između pojava postoji korelacija, potrebno je odrediti da li je riječ o pozitivnoj ili negativnoj korelaciji. U slučaju pozitivne korelacije između analiziranih promjenljivih (zavisne i nezavisne promjenljive), pad zavisne promjenljive uzrokuje i pad nezavisnih promjenljivih i obrnuto, a u slučaju negativne korelacije pad zavisne promjenljive izaziva rast nezavisnih promjenljivih. Kada je koeficijent korelacije statistički značajan, rezultat ukazuje na povezanost između analiziranih pojava.

Da bi se postavljene hipoteze dokazale ili odbacile, pomoću koeficijenta proste linearne korelacije će se odrediti stepen zavisnosti između zavisne promjenljive i nezavisnih promjenljivih. Cjelokupna analiza uradiće se po istom principu. Na samom početku definisaće se nulta i alternativna hipoteza, kako bi se ispitao uticaj nezavisne na zavisnu promjenljivu. Ukoliko se utvrdi da između zavisne i nezavisne promjenljive postoji linearna korelacija, nulta hipoteza se odbacuje, a prihvata se alternativna. Altrnativna hipoteza ukazuje samo na postojanje linearne korelacije između analiziranih promjenljivih, ali ništa ne govori o njenoj jačini, tako da se u sljedećem koraku određuje da li je riječ o jakoj ili slaboj, odnosno pozitivnoj ili negativnoj korelaciji. Nakon toga, testirana je značajnost koeficijenta linearne korelacije, odnosno određena je greška sa kojom se prihvata ili odbacuje postavljena hipoteza. Ovaj postupak ponovljen je devet puta, za svaku nezavisnu promjenljivu posebno.

Rezultati istraživanja pokazeće da li makroekonomski i specifični bankarski faktori utiču na nekvalitetne kredite, odnosno kvalitet kreditnog portfolia bankarskog sektora BiH. U nastavku je izvršena korelaciona analiza i dati su njeni rezultati.[12] Prvo je analiziran uticaj makroekonomskih, a zatim specifičnih bankarskih faktora na nekvalitetne kredite bankarskog sektora BiH. Potrebno je napomenuti da su izvorne vrijednosti korištene kod stope rasta realnog BDP-a, koeficijenta adekvatnosti kapitala, prinosa na aktivu, prinosa na akcijski kapital i aktivne kamatne stope, dok su transformisane vrijednosti korištene kod nekvalitetnih kredita, stope nezaposlenosti, stope rasta potrošačkih cijena, odnosa kredita i depozita i stope kreditnog rasta.

[12] Potrebno je napomenuti da će se u tekstu koji opisuje rezultate korelacione analize, koji su dobijeni pomoću softverskog programa *IBM SPSS Statistics Version 20*, brojevi odvajati zarezom, a ne tačkom kao što je navedeno u tabelama, kako bi se postigla jednoobraznost u tekstu.

2.4.1. Analiza makroekonomskih faktora koji utiču na nekvalitetne kredite

U ovom dijelu biće prikazani rezultati analize u kojoj se ispituje uticaj makroekonomskih faktora na nekvalitetne kredite bankarskog sektora BiH. U skladu sa tim, sprovedena je korelaciona analiza, a u nju su, pored zavisne promjenljive (transformisana promjenljiva TNPL koja pokazuje udio nekvalitetnih u ukupnim bruto kreditima) uključene tri makroekonomske promjenljive, i to: stopa rasta realnog BDP-a (promjenljiva GDP), stopa nezaposlenosti (TUNEMP) i stopa inflacije mjerena stopom rasta potrošačkih cijena (TICP). Korelaciona analiza sprovedena je za svaku nezavisnu promjenljivu posebno, a rezultati sprovedene analize dati su u nastavku.

Stopa rasta realnog BDP-a

Da bi se odredilo da li stopa rasta relanog BDP-a ima uticaj na nekvalitetne kredite bankarskog sektora BiH formulisane su sljedeće hipoteze:

H_0: Ne postoji linearna korelacija između stope rasta realnog BDP-a i nekvalitetnih kredita.

H_1: Postoji linearna korelacija između stope rasta realnog BDP-a i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između navedenih promjenljivih primjenjen je model proste linearne korelacije koji je prethodno opisan. Pri tom je kao Y promjenljiva označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a kao X promjenljiva označena je ona koja pokazuje stopu rasta realnog BDP-a (promjenljiva GDP).

Koeficijent linearne korelacije izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat je dat u tabeli 26.

Tabela 26: Korelacija – rezultat istraživanja za stopu rasta realnog BDP-a (promjenljiva GDP)

		TNPL	GDP
TNPL	Pearson Correlation	1	-.079
	Sig. (2-tailed)		.630
	N	40	40
GDP	Pearson Correlation	-.079	1
	Sig. (2-tailed)	.630	
	N	40	40

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = -0{,}079$$

Stepen zavisnosti između analiziranih promjenljivih utvrđen je prostom linearnom korelacijom, a dobijeni koeficijent linearne korelacije iznosi – 0,079. Vrijednost koeficijenta je mala i ukazuje na neznatnu povezanost analiziranih promjenljivih. Iako je povezanost skoro neznatna, ona ipak postoji. Dobijeni koeficijent linearne korelacije ukazuje da postoji negativna korelacija između stope rasta realnog BDP-a i nekvalitetnih kredita, odnosno da bi povećanje stope rasta realnog BDP-a moglo uticati na smanjenje nekvalitetnih kredita, a da bi smanjenje stope rasta realnog BDP-a moglo uticati na povećanje nekvalitetnih kredita u bankarskom sektoru BiH.

Da bi se to sa sigurnošću moglo tvrditi, potrebno je testirati značajnost dobijene ocjene, kako bi se dokazale ili odbacile postavljene hipoteze. Statistički značaj stepena zavisnosti između analiziranih promjenljivih određuje se pomoću *p vrijednosti*, a testiranje je urađeno pomoću statističkog programa *IBM SPSS Statistics Version 20.* Rezultat pokazuje da je:

$$p\ vrijednost = 0{,}630$$

Dobijena *p vrijednost* pokazuje da je koeficijent linearne korelacije značajan na nivou od 0,630. Da bi se odredilo da li je korelacija stope rasta realnog BDP-a i nekvalitetnih kredita statistički značajna, potrebno je dobijenu *p vrijednost* uporediti sa postavljenom granicom značajnosti ($p = 0{,}05$) i na osnovu toga donijeti odluku o prihvatanju ili odbacivanju postavljenih hipoteza. Pošto je dobijena *p vrijednost* veća od postavljene granice značajnosti, nulta hipoteza se prihvata i zaključuje se da ne postoji linearna korelacija između stope rasta realnog BDP-a i nekvalitetnih kredita. Drugim riječima, promjena stope rasta realnog BDP-a neće uticati na kvalitet kreditnog portfolia u bankarskom sektoru BiH.

Stopa nezaposlenosti

Druga makroekonomska promjenljiva koja je uključena u analizu je stopa nezaposlenosti. Da bi se odredilo da li stopa nezaposlenosti utiče na nekvalitetne kredite bankarskog sektora BiH formulisane su sljedeće hipoteze:

$\boldsymbol{H_0}$: Ne postoji linearna korelacija između stope nezaposlenosti i nekvalitetnih kredita.

$\boldsymbol{H_1}$: Postoji linearna korelacija između stope nezaposlenosti i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između navedenih promjenljivih, a u skladu sa modelom proste linearne korelacije koja se koristi u istraživanju, promjenljiva koja pokazuje udio nekvalitetnih u ukupnim bruto kreditima (promjenljiva TNPL) označena je sa Y, a promjenljiva koja pokazuje stopu nezaposlenosti (promjenljiva TUNEMP) označena je sa X promjenljiva.

Koeficijent linearne korelacije između stope nezaposlenosti i nekvalitetnih kredita izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat je dat u tabeli 27.

Tabela 27: Korelacija – rezultat istraživanja za stopu nezaposlenosti (promjenljiva TUNEMP)

		TNPL	TUNEMP
TNPL	Pearson Correlation	1	-.120
	Sig. (2-tailed)		.461
	N	40	40
TUNEMP	Pearson Correlation	-.120	1
	Sig. (2-tailed)	.461	
	N	40	40

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = -0{,}120$$

Stepen zavisnosti između analiziranih promjenljivih utvrđen je prostom linearnom korelacijom, a dobijeni koeficijent iznosi - 0,120. Vrijednost koleficijenta ukazuje na postojanje slabe povezanosti između stope nezaposlenosti i nekvalitetnih kredita. Iako je povezanost mala, ona ipak postoji. Koeficijent linearne korelacije ukazuje na slabu i negativnu korelaciju između stope nezaposlenosti i nekvalitetnih kredita. S obzirom na činjenicu da dobijeni koeficijent ukazuje na postojanje negativne korelacije između navedenih promjenljivih, to znači da bi povećanje stope nezaposlenosti moglo uticati na smanjenje nekvalitetnih kredita, odnosno, da bi smanjenje stope nezaposlenosti moglo uticati na njihovo povećanje.

Da bi se to sa sigurnošću moglo tvrditi, potrebno je testirati značajnost dobijene ocjene, a testiranje je izvršeno pomoću statističkog programa *IBM SPSS Statistics Version 20*. Rezultat pokazuje da je:

$$p\ vrijednost = 0{,}461$$

Dobijena *p vrijednost* pokazuje da je koeficijent linearne korelacije značajan na nivou od 0,461. Ipak, nakon što se dobijena vrijednost uporedi sa postavljenom granicom značajnosti (p = 0,05) vidi se da je ona veća od granične, tako da se može nulta hipoteza prihvata i zaključuje se da ne postoji korelacija između stope nezaposlenosti i nekvalitetnih kredita. Drugim riječima, stopa nezaposlenosti nema statistički značajan uticaj na nekvalitetne kredite i sa sigurnošću se može tvrditi da promjena stope nezaposlenosti nema uticaj na kvalitet kreditnog portfolia u bankarskom sektoru BiH.

Stopa rasta potrošačkih cijena

Posljednja makroekonomska promjenljiva koja je uključena u istraživanje je stopa rasta potrošačkih cijena. Da bi se odredilo da li stopa inflacije, mjerena stopom rasta potrošačkih cijena, utiče na nekvalitetne kredite bankarskog sektora BiH formulisane su sljedeće hipoteze:

H_0: Ne postoji linearna korelacija između stope rasta potrošačkih cijena i nekvalitetnih kredita.

H_1: Postoji linearna korelacija između stope rasta potrošačkih cijena i nekvalitetnih kredita.

Da bi se izmjerio stepen kvantitativne zavisnosti između navedenih promjenljivih korišten je prethodno opisani model proste linearne korelacije. U skladu sa navedenim modelom, sa Y je označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a sa X je označena nezavisna promjenljiva koja pokazuje stopu inflacije mjerenu stopom rasta potrošačkih cijena (promjenljiva TICP).

Kao i u prethodnim slučajevima, koeficijent korelacije između stope inflacije i nekvalitetnih kredita izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*. Stepen zavisnosti između analiziranih promjenljivih utvrđen je prostom linearnom korelacijom, a rezultat analize dat je u tabeli 28.

Tabela 28: Korelacija – rezultat istraživanja za stopu inflacije (promjenljiva TICP)

		TNPL	TICP
TNPL	Pearson Correlation	1	-.475*
	Sig. (2-tailed)		.025
	N	40	22
TICP	Pearson Correlation	-.475*	1
	Sig. (2-tailed)	.025	
	N	22	22

*. Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = -0{,}475$$

Dobijeni koeficijent korelacije pokazuje da postoji povezanost između stope rasta potrošačkih cijena, odnosno stope inflacije i nekvalitetnih kredita. Vrijednost koeficijenta linearne korelacije ukazuje na negativnu povezanost srednjeg inteziteta, a ovakva povezanost navedenih promjenljivih podrazumijeva da povećanje stope rasta potrošačkih cijena može da utiče na smanjenje nekvalitetnih kredita. Takođe, smanjenje stope rasta potrošačkih cijena moglo bi da utiče na povećanje nekvalitetnih kredita bankarskog sektora.

Da bi se to sa sigurnošću moglo tvrditi, potrebno je testirati značajnost dobijene ocjene, a testiranje je urađeno pomoću statističkog programa *IBM SPSS Statistics Version 20*. Dobijeni rezultat pokazuje da je:

$$p \text{ vrijednost} = 0{,}025$$

Dobijena *p vrijednost* pokazuje da je koeficijent linearne korelacije značajan na nivou od 0,025. Kada se *p vrijednost* uporedi sa postavljenom granicom značajnosti ($p = 0{,}05$) može se vidjeti da je ona manja od granične i zbog toga se odbacuje nulta hipoteza, a prihvata se alternativna. Na osnovu toga, može se zaključiti da postoji negativna korelacija između stope rasta potrošačkih cijena i nekvalitetnih kredita, odnosno da stopa inflacije ima statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru BiH.

2.4.2. Analiza specifičnih bankarskih faktora koji utiču na nekvalitetne kredite

U ovom dijelu disertacije prikazani su rezultati analize koja je sprovedena sa ciljem da se odredi uticaj specifičnih bankarskih faktora na nekvalitetne kredite bankarskog sektora BiH. Da bi se ostvario cilj, sprovedena je korelaciona analiza, a u nju je, pored zavisne promjenljive (promjenljiva TNPL koja pokazuje udio nekvalitetnih u ukupnim bruto kreditima) uključeno još šest nezavisnih promjenljivih, i to: koeficijent adekvatnosti kapitala (CAR), odnos kredita i depozita (TLTD), prinos na aktivu (ROA), prinos na akcijski kapital (ROE), aktivna kamatna stopa (IR) i stopa kreditnog rasta (TCG). Korelaciona analiza sprovedena je za svaku nezavisnu promjenljivu posebno, kao što je to urađeno i prilikom analize uticaja makroekonomskih faktora na nekvalitetne kredite. Rezultati sprovedene korelacione analize dati su u nastavku.

Koeficijent adekvatnosti kapitala

Prva specifična bankarska promjenljiva koja je uključena u analizu je koeficijent adekvatnosti kapitala. Da bi se odredilo da li koeficijent adekvatnosti kapitala ima uticaj na nekvalitetne kredite bankarskog sektora BiH formulisane su sljedeće hipoteze:

H₀: Ne postoji linearna korelacija između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita.

H₁: Postoji linearna korelacija između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između zavisne i nezavisne promjenljive, a u skladu sa modelom proste linearne korelacije koji je postavljen na početku istraživanja, sa Y je označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a sa X je označena nezavisna promjenljiva koja pokazuje koeficijent adekvatnosti kapitala (promjenljiva CAR).

Koeficijent linearne korelacije između navednih promjenljivih izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat analize dat je u tabeli 29.

Tabela 29: Korelacija – rezultat istraživanja za koeficijent adekvatnosti kapitala (promjenljiva CAR)

		TNPL	CAR
TNPL	Pearson Correlation	1	-.128
	Sig. (2-tailed)		.432
	N	40	40
CAR	Pearson Correlation	-.128	1
	Sig. (2-tailed)	.432	
	N	40	40

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = -0{,}128$$

Stepen zavisnosti između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita utvrđen je prostom linearnom korelacijom, a dobijeni koeficijent iznosi – 0,128. Vrijednost koeficijenta linearne korelacije ukazuje da postoji negativna i niska povezanost između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita. Negativna povezanost podrazumijeva da bi povećanje koeficijenta adekvatnosti kapitala moglo da utiče na smanjenje nekvalitetnih kredita i obrnuto, da bi smanjenje koeficijenta adekvatnosti kapitala moglo da utiče na povećanje nekvalitetnih kredita u bankarskom sektoru.

Da bi se to sa sigurnošću moglo tvrditi, potrebno je testirati statističku značajnost dobijenog koeficijenta, a testiranje je izvršeno pomoću statističkog programa *IBM SPSS Statistics Version 20*. Dobijeni rezultat pokazuje da je:

$$p \text{ vrijednost} = 0{,}432$$

Dobijena *p vrijednost* pokazuje da je koeficijent linearne korelacije značajan na nivou od 0,432, a nakon što se dobijena vrijednost uporedi sa postavljenom granicom značajnosti (p = 0,05) može se konstatovati da koeficijent adekvatnosti kapitala nema statistički značajan uticaj na nekvalitetne kredite. U skladu sa dobijenom *p vrijednošću*, prihvata se nulta hipoteza i sa sigurnošću se može tvrditi da promjena koeficijenta adekvatnosti kapitala neće uticati na promjenu nekvalitetnih kredita, odnosno na kvalitet kreditnog portfolia bankarskog sektora BiH.

Odnos kredita i depozita

Da bi se odredilo da li likvidnost bankarskog sektora, mjerena odnosom kredita i depozita, ima uticaj na nekvalitetne kredite formulisane su sljedeće hipoteze:

H_0: Ne postoji linearna korelacija između odnosa kredita i depozita i nekvalitetnih kredita.

H_1: Postoji linearna korelacija između odnosa kredita i depozita i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između analiziranih promjenljivih, a u skladu sa modelom proste linearne korelacije koji je postavljen na početku istraživanja, sa Y je označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a sa X je označena nezavisna promjenljiva koja pokazuje likvidnost bankarskog sektora mjerenu odnosom kredita i depozita (promjenljiva TLTD).

Koeficijent korelacije izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat je dat u tabeli 30.

Tabela 30: Korelacija – rezultat istraživanja za odnos kredita i depozita (promjenljiva TLTD)

		TNPL	TLTD
TNPL	Pearson Correlation	1	-.188
	Sig. (2-tailed)		.245
	N	40	40
TLTD	Pearson Correlation	-.188	1
	Sig. (2-tailed)	.245	
	N	40	40

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = -0{,}188$$

Dobijena vrijednost koeficijenta linearne korelacije je mala i ukazuje na postojanje niske povezanosti između likvidnosti i nekvalitetnih kredita bankarskog sektora. Predznak koeficijenta ukazuje na negativnu povezanost između zavisne i nezavisne promjenljive, odnosno pokazuje da bi povećanje odnosa kredita i depozita moglo uticati na smanjenje nekvalitetnih kredita i obrnuto, da bi smanjenje odnosa kredita i depozita moglo uticati na povećanje nekvalitetnih kredita. Drugim riječima, usljed poboljšanja likvidnosti bankarskog sektora moglo bi doći i do poboljšanja kvaliteta kreditnog portfolia, jer će se u tom slučaju nekvalitetni krediti smanjiti.

Da bi se ispoštovao postavljeni metodološki okvir za dokazivanje postavljenih hipoteza, odnosno da bi se odredilo da li je dobijeni koeficijent linearne korelacije statistički značajan, testirana je njegova statistička značajnost. Pomoću statističkog programa *IBM SPSS Statistics Version 20* određena je *p vrijednost*, a ona iznosi:

$$p\ vrijednost = 0{,}245$$

Dobijena vrijednost pokazuje da je koeficijent linearne korelacije značajan na nivou od 0,245. Kada se njegova vrijednost uporedi sa postavljenom granicom značajnosti ($p = 0{,}05$) može se vidjeti da je dobijena vrijednost veća od postavljene granice značajnosti, pa se, u skladu sa tim, nulta hipoteza prihvata i može se konstatovati da odnos kredita i depozita nema statistički značajan uticaj na nekvalitetne kredite. Drugim riječima, promjena likvidnosti, mjerena odnosom kredita i depozita, ne bi trebala uticati na promjenu kvaliteta kreditnog portfolia bankarskog sektora BiH.

Prinos na aktivu

Profitabilnost bankarskog sektora mjeri se stopom prinosa na aktivu i stopom prinosa na akcijski kapital. Obe promjenljive koje pokazuju profitabilnost bankarskog sektora BiH su uključene u istraživanje. Da bi se odredilo da li prinos na aktivu ima uticaj na nekvalitetne kredite formulisane su sljedeće hipoteze:

H_0: Ne postoji linearna korelacija između prinosa na aktivu i nekvalitetnih kredita.

H_1: Postoji linearna korelacija između prinosa na aktivu i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između analiziranih promjenljivih, a u skladu sa modelom proste linearne korelacije koji je postavljen na početku istraživanja, sa Y je označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a sa X je označena nezavisna promjenljiva koja pokazuje profitabilnost bankarskog sektora mjerenu prinosom na aktivu (promjenljiva ROA).

Koeficijent linearne korelacije izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat je dat u tabeli 31.

Tabela 31: Korelacija – rezultat istraživanja za prinos na aktivu (promjenljiva ROA)

		TNPL	ROA
TNPL	Pearson Correlation	1	.367*
	Sig. (2-tailed)		.020
	N	40	40
ROA	Pearson Correlation	.367*	1
	Sig. (2-tailed)	.020	
	N	40	40

*. Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = 0{,}367$$

Vrijednost koeficijenta korelacije ukazuje na postojanje niske povezanosti između analiziranih promjenljivih. Koeficijent korelacije od 0,367 ukazuje na postojanje pozitivne veze između zavisne i nezavisne promjenljive, odnosno da povećanje prinosa na aktivu može uticati na povećanje nekvalitetnih kredita i obrnuto, da smanjenje prinosa na aktivu može uticati na smanjenje nekvalitetnih kredita. Drugim riječima, poboljšanje profitabilnosti bankarskog sektora može negativno uticati na kvalitet kreditnog portfolia, jer povećanje prinosa na aktivu može uticati i na povećanje nekvalitetnih kredita.

Nakon što je utvrđeno postojanje niske i pozitivne povezanosti između analiziranih promjenljivih (promjenljive TNPL i promjenljive ROA), testirana je statistička značajnost dobijene ocjene kako bi se dokazale ili odbacile postavljene hipoteze. Statistički značaj stepena zavisnosti između zavisne i nezavisne promjenljive određen je pomoću *p vrijednosti*, a testiranje je izvršeno pomoću statističkog programa *IBM SPSS Statistics Version 20*. Dobijeni rezultat pokazuje da je:

$$p \text{ vrijednost} = 0{,}020$$

Dobijena *p vrijednost* pokazuje da je koeficijent korelacije značajan na nivou od 0,020. Da bi se odredilo da li prinos na aktivu ima statistički značajan uticaj na nekvalitetne kredite, potrebno je dobijenu *p vrijednost* uporediti sa postavljenom granicom značajnosti ($p = 0{,}05$). Pošto je dobijena *p vrijednost* manja od postavljene granice značajnosti, nulta hipoteza se odbacuje i prihvata se alternativna. Na osnovu dobijenog koeficijenta linearne korelacije i *p vrijednosti* zaključuje se da je pozitivna korelacija između prinosa na aktivu i nekvalitetnih kredita statistički značajna, odnosno da će promjena profitabilnosti bankarskog sektora, mjerena prinosom na aktivu, uticati na kvalitet kreditnog portfolia. Pri tom će se poboljšanje profitabilnosti negativno odraziti na kvalitet kreditnog portfolia, jer povećanje prinosa na aktivu može uticati na povećanje nekvalitetnih kredita u bankarskom sektoru BiH.

Prinos na akcijski kapital

Drugi pokazatelj profitabilnosti bankarskog sektora je prinos na akcijski kapital. Da bi se odredilo da li ovaj pokazatelj utiče na nekvalitetne kredite bankarskog sektora BiH formulisane su sljedeće hipoteze:

H_0: Ne postoji linearna korelacija između prinosa na akcijski kapital i nekvalitetnih kredita.

H_1: Postoji linearna korelacija između prinosa na akcijski kapital i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između navedenih promjenljivih, a u skladu sa modelom proste linearne korelacije koji se koristi u istraživanju, sa Y je označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a sa X je označena nezavisna promjenljiva koja pokazuje profitabilnost bankarskog sektora mjerenu prinosom na akcijski kapital (promjenljiva ROE).

Koeficijent linearne korelacije između prinosa na akcijski kapital i nekvalitetnih kredita izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat je dat u tabeli 32.

Tabela 32: Korelacija – rezultat istraživanja za prinos na akcijski kapital (promjenljiva ROE)

		TNPL	ROE
TNPL	Pearson Correlation	1	.251
	Sig. (2-tailed)		.118
	N	40	40
ROE	Pearson Correlation	.251	1
	Sig. (2-tailed)	.118	
	N	40	40

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = 0{,}251$$

Dobijena vrijednost koeficijenta linearne korelacije ukazuje da između prinosa na akcijski kapital i nekvalitetnih kredita postoji povezanost srednjeg inteziteta. Koeficijent linearne korelacije ukazuje na postojanje pozitivne povezanosti između promjenljivih, odnosno da bi povećanje prinosa na akcijski kapital moglo uticati na povećanje nekvalitetnih kredita.

Da bi se ispoštovao postavljeni metodološki okvir za dokazivanje postavljenih hipoteza, odnosno da bi se odredilo da li je dobijeni koeficijent korelacije statistički značajan, potrebno je odrediti *p vrijednost* i uporediti je sa postavljenom granicom značajnosti ($p = 0{,}05$). Pomoću statističkog programa *IBM SPSS Statistics Version 20* određena je *p vrijednost* i ona iznosi:

$$\text{p vrijednost} = 0{,}118$$

Dobijeni rezultat pokazuje da je koeficijent linearne korelacije između prinosa na akcijski kapital i nekvalitetnih kredita značajan na nivou od 0,118. Međutim, nakon što se dobijena *p vrijednost* uporedi sa postavljenom granicom značajnosti, može se vidjeti da je ona veća od granične. U skladu sa tim, prihvata se nulta hipoteza i može se zaključiti da prinos na akcijski kapital nema statistički značajan uticaj na nekvalitetne kredite, odnosno da profitabilnost bankarskog sektora ne utiče na kvalitet kreditnog portfolia. S obzirom na činjenicu da prinos na akcijski kapital nema statistički značajan uticaj na nekvalitetne kredite bankarskog sektora BiH, postojanje pozitivne korelacije je rezultat slučajnosti.

Aktivna kamatna stopa

Jedna specifična bankarska promjenljiva koja je uključena u analizu je aktivna kamatna stopa. Da bi se odredilo da li aktivna kamatna stopa ima uticaj na nekvalitetne kredite formulisane su sljedeće hipoteze:

H_0: Ne postoji linearna korelacija između aktivne kamatne stope i nekvalitetnih kredita.

H_1: Postoji linearna korelacija između aktivne kamatne stope i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između zavisne i nezavisne promjenljive, a u skladu sa modelom proste linearne korelacije koji je postavljen na početku istraživanja, sa Y je označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a sa X je označena nezavisna promjenljiva, odnosno aktivna kamatna stopa (promjenljive IR) po kojoj komercijalne banke obračunavaju kamatu na plasirane kredite.

Kao i u prethodnim slučajevima, koeficijent linearne korelacije izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat je dat u tabeli 33.

Tabela 33: Korelacija – rezultat istraživanja za aktivnu kamatnu stopu (promjenljiva IR)

		TNPL	IR
TNPL	Pearson Correlation	1	-.347*
	Sig. (2-tailed)		.028
	N	40	40
IR	Pearson Correlation	-.347*	1
	Sig. (2-tailed)	.028	
	N	40	40

*. Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = - 0,347$$

Stepen zavisnosti između aktivne kamatne stope i nekvalitetnih kredita utvrđen je linearnom korelacijom, a dobijeni koeficijent ukazuje da postoji povezanost između analiziranih promjenljivih. Vrijednost koeficijenta linearne korelacije između aktivne kamatne stope i nekvalitetnih kredita ukazuje na negativnu povezanost niskog inteziteta. Negativna povezanost podrazumijeva da bi povećanje aktivne kamatne stope moglo uticati na smanjenje nekvalitetnih kredita i obrnuto, da bi smanjenje aktivne kamatne stope moglo uticati na povećanje nekvalitetnih kredita.

Da bi se to sa sigurnošću moglo tvrditi, potrebno je testirati značajnost dobijene ocjene, a testiranje je urađeno pomoću statističkog programa *IBM SPSS Statistics Version 20*. Dobijeni rezultat pokazuje da je:

$$p\ vrijednost = 0{,}028$$

Dobijena *p vrijednost* pokazuje da je koeficijent linearne korelacije značajan na nivou od 0,028, a nakon što se dobijena vrijednost uporedi sa postavljenom granicom značajnosti ($p = 0{,}05$) vidi se da je ona manja od granične. U skladu sa tim, nulta hipoteza se odbacuje i prihvata se alternativna. Na osnovu koeficijenta linearne korelacije i *p vrijednosti* može se zaključiti da između aktivne kamatne stope i nekvalitetnih kredita postoji statistički značajna i pozitivna korelacija. Drugim riječima, promjena aktivne kamatne stope po kojoj komercijalne banke u BiH obračunavaju kamatu na plasirane kredite može uticati na kvalitet kreditnog portfolia. Povećanje aktivne kamatne stope može uticati i na povećanje nekvalitetnih kredita što se negativno odražava na kvalitet kreditnog portfolia. Sa druge strane, aktivna kamatna stopa može i pozitivno uticati na kvalitet kreditnog portfolia jer smanjenje aktivne kamatne stope može uticati na smanjenje nekvalitetnih kredita bankarskog sektora BiH.

Stopa kreditnog rasta

Posljednja specifična bankarska promjenljiva koja je uključena u analizu je stopa kreditnog rasta. Da bi se odredilo da li stopa kreditnog rasta ima uticaj na nekvalitetne kredite formulisane su sljedeće hipoteze:

$\boldsymbol{H_0}$: Ne postoji linearna korelacija između stope kreditnog rasta i nekvalitetnih kredita.

$\boldsymbol{H_1}$: Postoji linearna korelacija između stope kreditnog rasta i nekvalitetnih kredita.

Kako bi se izmjerio stepen kvantitativne zavisnosti između analiziranih promjenljivih, a u skladu sa modelom proste linearne korelacije koji je postavljen na početku istraživanja, sa Y je označena zavisna promjenljiva koja pokazuje udio nekvalitetnih u ukupnim kreditima (promjenljiva TNPL), a sa X je označena nezavisna promjenljiva koja pokazuje stopu kreditnog rasta u bankarskom sektoru (promjenljiva TCG).

Koeficijent korelacije izračunat je pomoću statističkog programa *IBM SPSS Statistics Version 20*, a rezultat je dat u tabeli 34.

Tabela 34: Korelacija – rezultat istraživanja za stopu kreditnog rasta (promjenljiva TCG)

		TNPL	TCG
TNPL	Pearson Correlation	1	-.458**
	Sig. (2-tailed)		.006
	N	40	34
TCG	Pearson Correlation	-.458**	1
	Sig. (2-tailed)	.006	
	N	34	34

**. Correlation is significant at the 0.01 level (2-tailed).

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Koeficijent linearne korelacije iznosi:

$$r = -0{,}458$$

Stepen zavisnosti između stope kreditnog rasta i nekvalitetnih kredita utvrđen je prostom linearnom korelacijom. Dobijena vrijednost koeficijenta linearne korelacije ukazuje na negativnu i srednju povezanost analiziranih promjenljivih. Negativna korelacija između stope kreditnog rasta i nekvalitetnih kredita podrazumijeva da bi povećanje stope kreditnog rasta moglo uticati na smanjenje nekvalitetnih kredita u bankarskom sektoru BiH.

Da bi se to sa sigurnošću moglo tvrditi, potrebno je testirati značajnost dobijene ocjene, a na osnovu toga prihvatiti ili odbaciti postavljene hipoteze. Statistički značaj stepena zavisnosti između analiziranih promjenljivih određuje se pomoću *p vrijednosti*, a testiranje je urađeno pomoću statističkog programa *IBM SPSS Statistics Version 20.* Rezultat pokazuje da je:

$$p\ vrijednost = 0{,}006$$

Dobijena *p vrijednost* pokazuje da je koeficijent linearne korelacije značajan na nivou od 0,006. Da bi se odredilo da li je korelacija stope kreditnog rasta i nekvalitetnih kredita statistički značajna, potrebno je dobijenu *p vrijednost* uporediti sa postavljenom granicom značajnosti (p = 0,05) i na osnovu toga donijeti odluku o prihvatanju ili odbacivanju postavljenih hipoteza. Pošto je dobijena *p vrijednost* manja od postavljene granice značajnosti, nulta hipoteza se odbacuje i prihvata se alternativna. Na osnovu koeficijenta linearne korelacije i *p vrijednosti* može se zaključiti da postoji negativna i statistički značajna korelacija između stope kreditnog rasta i nekvalitetnih kredita. To znači da bi povećanje stope kreditnog rasta moglo uticati na smanjenje nekvalitetnih kredita i obrnuto, smanjenje stope nekvalitetnih kredita moglo bi uticati na povećanje nekvalitetnih kredita u bankarskom sektoru BiH.

Na kraju sprovedene korelacione analize može se zaključiti da su četiri nezavisne promjenljive koje su uključene u istraživanje u korelaciji sa nekvalitetnim kreditima bankarskog sektora BiH. Pri tom je, korelacionom analizom, utvrđeno da su stopa inflacije, mjerena stopom rasta potrošačkih cijena (promjenljiva TICP), prinos na aktivu (promjenljiva ROA) i aktivna kamatna stopa (promjenljiva IR) u pozitivnoj, a stopa kreditnog rasta (promjenljiva TCG) u negativnoj korelaciji sa nekvalitetnim kreditima bankarskog sektora BiH.

Iako je koeficijent linearne korelacije ukazao na negativnu korelaciju između pet nezavisnih promjenljivih (promjenljive GDP, TUNEMP, CAR, TLTD i ROE) i nekvalitetnih kredita i na pozitivnu korelaciju između jedne promjenljive (promjenljiva ROE) i nekvalitetnih kredita, testiranjem značajnosti dobijene ocjene utvrđeno je da uticaj nezavisne na zavisnu promjenljivu nije statistički značajan. S obzirom na činjenicu da stopa rasta realnog BDP-a, stopa nezaposlenosti, koeficijent adekvatnosti kapitala, odnos kredita i depozita i prinos na akcijski kapital nemaju statistički značajan uticaj na nekvalitetne kredite bankarskog sektora BiH, postojanje korelacije je rezultat slučajnosti.

2.5. Prosta regresiona analiza

U cilju određivanja vrijednosti zavisne promjenljive na osnovu vrijednosti objašnjavajućih promjenljivih, sprovedena je regresiona analiza. U regresionoj analizi korišteni su prethodno predstavljeni podaci, odnosno podaci koji su korišteni i u korelacionoj analizi. Podaci su obrađeni pomoću statističkog programa *IBM SPSS Statistics Version 20*. Regresiona analiza sprovedena je sa ciljem da se kroz ocjenu parametara regresionog modela ocijene prosječne vrijednosti zavisne promjenljive i da se predvide njene pojedinačne vrijednosti.

Već je rečeno da se u regresionoj analizi, umjesto termina „nezavisna promjenljiva" koristi termin „objašnjavajuća promjenljiva". U istraživanje su uključene tri makroekonomske objašnjavajuće promjenljive (stopa rasta realnog BDP-a, stopa nezaposlenosti i stopa inflacije mjerena stopom rasta potrošačkih cijena) i šest specifičnih bankarskih promjenljivih (koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, aktivna kamatna stopa i stopa kreditnog rasta). I u regresionoj anaizi korištene su transformisane vrijednosti određenih promjenljivih, kako bi se zadovoljio uslov njihove normalne raspodjele.

Pored korelacione analize, čiji rezultati su prethodno dati, sprovedena je i regresiona analiza, odnosno određene su linearne regresione jednačine pomoću kojih se može predvidjeti ponašanje nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Regresija pokazuje koliki je dio varijanse zavisne promjenljive objašnjen varijansom objašnjavajućih promjenljivih, a daje i pokazatelj relativnog doprinosa svake nezavisne promjenljive. Korišteni statistički program *IBM SPSS Statistics Version 20* generiše više tabela, ali su tri veoma bitne za interpretaciju rezultata tako da će se njima posvetiti posebna pažnja u nastavku. Takođe, dati su i dogovarajući dijagrami (*Normal P–P of the Regression Standardised Residual* i *Scatterplot*) koji prikazuju raspodjelu vrijednosti promjenljivih, kao i raspored reziduala. Pomoću dijagrama *Normal P–P Plot* provjerava se normalnost raspodjele i kod njega bi tačke trebalo da budu raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama. Drugi dijagram je dijagram rasturanja standardizovanih odstupanja, odnosno dijagram *Scatterplot,* na kome bi odstupanja trebala biti prilično pravougaono raspoređena i većina rezultata nagomilana u centru (oko tačke 0). Pomoću ovog dijagrama može se utvrditi da li ima netipičnih tačaka, a Tabachnick i Fidell definišu netipične tačke kao slučajeve koji imaju standardizovano odstupanje, na dijagramu rasturanja, veći od 3,3 i manji od - 3,3 (Tabachnick & Fidell, 2007).

Cjelokupna regresiona analiza uradiće se po istom principu, a koraci regresione analize opisani su u nastavku. Na samom početku dati su regresioni dijagrami, odnosno dijagram *Normal P-P Plot* i dijagram *Scatterplot*, koji su sastavni dio analize.

Nakon toga, izvršeno je vrednovanje modela, odnosno provjera da li je model dobar. Statistički program *IBM SPSS Statistics Version 20* generiše tabelu *Model Summary*, koja se sastoji od četiri vrijednosti, odnosno četiri pokazatelja. Ti pokazatelji su: pokazatelj *R*, odnosno apsolutna vrijednost koeficijenta linearne korelacije pomoću koga se određuje kvalitet predviđanja zavisne promjenljive, pokazatelj *R Square*, odnosno koeficijent determinacije koji predstavlja koeficijent odlučivanja, pokazatelj *Adjusted R Square* koji predstavlja korigovani koeficijent determinacije i manje je pristrasna ocjena od nekorigovanog pokazatelja *R Square* i pokazatelj *Std. Error of the Estimate*, odnosno standardna greška koja govori o preciznosti regresionog modela.

Sljedeći korak regresione analize je testiranje značajnosti regresione veze, odnosno provjera da li je objašnjavajuća promjenljiva relevantna za opisivanje ponašanja zavisne promjenljive. Drugim riječima, provjerava se da li postoji linearno slaganje između varijacija posmatranih promjenljivih. U prostoj regresionoj analizi to se svodi na testiranje hipoteze da li je parametar nagiba jednak nuli. U skladu sa tim, biće postavljene nulta i alternativna hipoteza, koje će se testirati pomoću *F testa*. Rezultati testiranja prikazani su u tabeli *ANOVA*, a na osnovu *F vrijednosti* i *p vrijednosti* se određuje da li objašnjavajuće promjenljive statistički dobro predviđaju kretanje zavisne promjenljive. Ukoliko se dokaže da je nulta hipoteza tačna, odnosno da je parametar nagiba nula, tada se ta regresiona linija ne može koristiti u cilju predviđanja zavisne promjenljive. Kao i kod korelacione analize, prihvatanje, odnosno odbacivanje postavljenih hipoteza vrši se na osnovu *p vrijednosti* iz tabele *ANOVA*. Ukoliko je *p vrijednost* manja od postavljene granice značajnosti (korištena je standardna granica značajnosti $p = 0,05$), tada se nulta hipoteza odbacuje, a prihvata se alternativna i prelazi se na sljedeći korak regresione analize jer u tom slučaju ima smisla koristiti regresioni model za objašnjenje zavisne promjenljive. Ukoliko se dokaže nulta hipoteza, odnosno pokaže se da je parametar nagiba nula, regresiona analiza za tu objašnjavajuću promjenljivu se završava i prelazi se na analizu sljedeće objašnjavajuće promjenljive.

Sljedeći korak regresione analize je ocjena koeficijenata modela i vrednovanje objašnjavajuće promjenljive. Pomoću *t testa* provjerava se koliko je značajna objašnjavajuća promjenljiva u modelu, a rezultati su dati u tabeli *Coefficients*. Ukoliko je dobijena *p vrijednost* manja od postavljene granice značajnosti ($p < 0,05$) zaključuje se da je objašnjavajuća promjenljiva potrebna u istraživanju. Nakon toga se može konstruisati regresiona jednačina, a za njeno konstruisanje koristi se nestandardizovani koeficijent *B*. Još jedan bitan pokazatelj iz tabele *Coefficients* je standardizovani koeficijent *Beta* koji pokazuje koliko objašnjavajuća promjenljiva doprinosi objašnjavanju zavisne promjenljive. Pored toga, standardizovani koeficijent *Beta* pokazuje broj standardnih devijacija (odstupanja) za koji bi se vrijednosti zavisne promjenljive promijenili kada se objašnjavajuća promjenljiva promijeni za jednu jedinicu standardnog odstupanja.

Na kraju se, na osnovu jednačine linearne regresije koja je sastavljena na osnovu modela mogu predvidjeti vrijednosti zavisne promjenljive pomoću proizvodnih vrijednosti objašnjavajuće promjenljive. Rezultati regresione analize pokazaće na osnovu kojih makroekonomskih i specifičnih bankarskih faktora se mogu predvidjeti nekvalitetni krediti bankarskog sektora BiH u narednom periodu.

U nastavku su dati rezultati regresione analize.[13] Prvo je analizirana veza između makroekonomskih faktora i nekvalitetnih kredita, a zatim veza između specifičnih bankarskih faktora i nekvalitetnih kredita bankarskog sektora BiH. Potrebno je napomenuti da su za pet promjenljivih (stopa rasta realnog BDP-a, koeficijent adekvatnosti kapitala, prinos na aktivu, prinos na akcijski kapital i aktivna kamatna stopa) korištene izvorne vrijednosti, a transformisane vrijednosti korištene su za preostalih pet promjenljivih koje su uključene u istraživanje (nekvalitetni krediti, stopa nezaposlenosti, stopa rasta potrošačkih cijena, odnos kredita i depozita i stopa kreditnog rasta).

2.5.1. Analiza makroekonomskih faktora koji utiču na nekvalitetne kredite

U ovom dijelu biće prikazani rezultati analize koja je sprovedena sa ciljem da se odrede makroekonomski faktori koji utiču na nekvalitetne kredite i da se, na osnovu tih faktora, predvide nekvalitetni krediti bankarskog sektora BiH u narednom periodu. U skladu sa ovim ciljem, sprovedena je regresiona analiza u koju je, pored zavisne promjenljive koja pokazuje udio nekvalitetnih u ukupnim kreditima bankarskog sektora (promjenljiva TNPL) uključeno još devet objašnjavajućih promjenljivih, od kojih su tri makroekonomske promjenljive. Makroekonomske promjenljive koje su uključene u regresionu analizu su: stopa rasta realnog BDP-a (promjenljiva GDP), stopa nezaposlenosti (TUNEMP) i stopa inflacije mjerena stopom rasta potrošačkih cijena (TICP).

Sprovedena je prosta regresiona analiza, odnosno regresiona analiza za svaku objašnjavajuću promjenljivu posebno, u skladu sa prethodno opisanim modelom. Rezultati proste linearne regresije u koju su uključene zavisna i objašnjavajuće makroekonomske promjenljive dati su u nastavku.

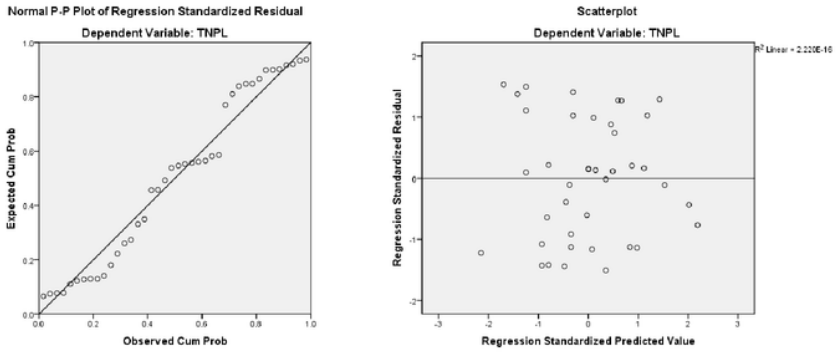
Stopa rasta realnog BDP-a

Prva makroekonomska promjenljiva koja je uključena u regresionu analizu je stopa rasta realnog BDP-a (promjenljiva GDP). Pomoću proste linearne regresije odrediće se da li se ova objašnjavajuća promjenljiva može koristiti za određivanje vrijednosti zavisne promjenljive, odnosno da li se na osnovu vrijednosti stope rasta realnog BDP-a može predvidjeti vrijednost nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Prvi korak regresione analize je crtanje dijagrama pomoću kojih se može provjeriti normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka (dijagrami *Normal P-P Plot* i *Scatterplot*). Na *Scatterplot* dijagram dodata je i regresiona linija. Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a predstavljeni su na slici 1.

[13] Potrebno je napomenuti da će se u tekstu koji opisuje rezultate regresione analize, koji su dobijeni pomoću softverskog programa *IBM SPSS Statistics Version 20*, brojevi odvajati zarezom, a ne tačkom kao što je navedeno u tabelama, kako bi se postigla jednoobraznost u tekstu.

Slika 4: Normal P-P Plot i Scatterplot dijagrami (promjenljiva GDP)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* može se vidjeti da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama, tako da nema velikih odstupanja od normalnosti. To je takođe prethodno potvrđeno i pomoću testa normalnosti. Na dijagramu *Scatterplot* može se vidjeti da nema netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3, ali ni veća od 3,3.

Nakon crtanja dijagrama, potrebno je provjeriti da li je korišteni model dobar. Statistički softver *IBM SPSS Statistics Version 20* generiše tabelu *Model Summary*, a model se vrednuje na osnovu pokazatelja iz ove tabele. Parametri na osnovu kojih se vrednuje model dati su u tabeli 35.

Tabela 35: Prosta regresija – Model Summary (promjenljiva GDP)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.079[a]	.006	-.020	.68753

a. Predictors: (Constant), GDP
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R*, odnosno apsolutna vrijednost koeficijenta korelacije, ukazuje na neznatnu povezanost između stope rasta realnog BDP-a i nekvalitetnih kredita. Pokazatelj *R Square*, odnosno koeficijent determinacije, je veoma nizak i pokazuje da se samo 0,6% varijabiliteta zavisne promjenljive (promjenljiva TNPL) može objasniti pomoću ove objašnjavajuće promjenljive. Sa druge strane, pokazatelj *Adjusted R Square* koriguje vrijednost pokazatelja *R Square* i daje bolju procjenu stvarne vrijednosti koeficijenta determinacije. U ovom slučaju vrijednost pokazatelja *Adjusted R Square* takođe je mala, i pokazuje da se samo 2% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope rasta realnog BDP-a. Standardna greška, koja ukazuje na preciznost modela iznosi 0,687.

Nakon vrednovanja modela, testirana je značajnost regresione veze. Drugim riječima, testirano je da li je stopa rasta realnog BDP-a relevantna za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora BiH. Da bi se testirala značajnost regresione veze neophodno je postaviti hipoteze pomoću kojih će se testirati da li objašnjavajuća promjenljiva statistički dobro predviđa kretanje zavisne promjenljive. U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, tako da su postavljene sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Hipoteze su testirane pomoću *F testa,* a rezultati su prikazani u tabeli 36.

Tabela 36: Prosta regresija – ANOVA (promjenljiva GDP)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	.112	1	.112	.236	.630[b]
	Residual	17.963	38	.473		
	Total	18.074	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), GDP

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 0{,}236$$

$$p \text{ vrijednost} = 0{,}630$$

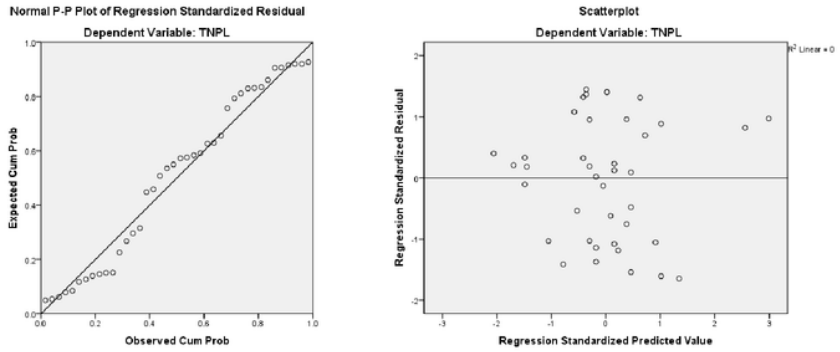
Na osnovu navedenih vrijednosti, može se odrediti da li stopa rasta realnog BDP-a statistički dobro predviđa kretanje nekvalitetnih kredita. Kao i kod korelacione analize, na osnovu dobijene *p vrijednosti* se prihvataju ili odbacuju postavljene hipoteze. S obzirom da je dobijena *p vrijednost* (p = 0,630) veća od postavljene granice značajnosti (p = 0,05), nulta hipoteza se prihvata i može se zaključiti da je parametar nagiba nula, odnosno da nema smisla koristiti regresioni model za objašnjenje nekvalitetnih kredita na osnovu stope rasta realnog BDP-a. To potvrđuje i regresiona linija koja je prikazana na dijagramu *Scatterplot.*

Stopa nezaposlenosti

Sljedeća makroekonomska promjenljiva koja je uključena u regresionu analizu je stopa nezaposlenosti (promjenljiva TUNEMP), a pomoću proste linearne regresije odrediće se da li se ova promjenljiva može koristiti za određivanje vrijednosti nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Prvi korak regresione analize je crtanje dijagrama (*Normal P-P Plot* i *Scatterplot*) pomoću kojih se može provjeriti normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka. Dijagram *Scatterplot* je malo dorađen, odnosno na njega je dodata regresiona linija. Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a predstavljeni su na slici 5.

Slika 5: Normal P-P Plot i Scatterplot dijagrami (promjenljiva TUNEMP)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* može se vidjeti da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama, tako da nema velikih odstupanja od normalnosti. To je potvrđeno i pomoću testa normalnosti koji je sproveden nakon transformacije promjenljive UNEMP. Na dijagramu rasturanja standardizovanih odstupanja, odnosno dijagramu *Scatterplot,* može se vidjeti da su odstupanja približno pravougaono raspoređena i da je većina rezultata nagomilana u centru, oko tačke 0, a nema ni netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3 ili veća od 3,3.

Sljedeći korak regresione analize je vrednovanje modela, odnosno provjera da li je korišteni regresioni model dobar. Model se vrednuje na osnovu parametara iz tabele *Model Summary* koju generiše statistički softver *IBM SPSS Statistics Version 20.* Parametri na osnovu kojih se vrednuje model su parametri *R, R Square, Adjusted R Square* i *Std. Error of the Estimate*, a dati su u tabeli 37.

Tabela 37: Prosta regresija – Model Summary (promjenljiva TUNEMP)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.120[a]	.014	-.012	.68469

a. Predictors: (Constant), TUNEMP
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R* je apsolutna vrijednost koeficijenta korelacije i ukazuje na slabu povezanost stope nezaposlenosti i nekvalitetnih kredita bankarskog sektora. Sljedeći pokazatelj iz tabele je pokazatelj *R Square*, odnosno koeficijent determinacije, koji je u ovom slučaju prilično nizak i pokazuje da se samo 1,4% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope nezaposlenosti. Sa druge strane, pokazetelj *Adjusted R Square* koriguje vrijednost pokazatelja *R Square* i daje bolju procjenu stvarne vrijednosti koeficijenta determinacije. U ovom slučaju vrijednost pokazatelja *Adjusted R Square* je još manja i pokazuje da se samo 1,2% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope nezaposlenosti. Standardna greška, koja ukazuje na preciznos modela iznosi 0,684.

Nakon vrednovanja modela, potrebno je testirati značajnost regresione veze. Drugim riječima, potrebno je testirati da li je stopa nezaposlenosti relevantna za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora BiH. Da bi se testirala značajnost regresione veze neophodno je postaviti hipoteze pomoću kojih će se testirati da li objašnjavajuća promjenljiva statistički dobro predviđa kretanje zavisne promjenljive. U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, tako da su postavljene sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Testiranje hipoteza vrši se pomoću *F testa,* a rezultati su prikazani u tabeli 38.

Tabela 38: Prosta regresija – ANOVA (promjenljiva TUNEMP)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	.260	1	.260	.554	.461[b]
	Residual	17.815	38	.469		
	Total	18.074	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), TUNEMP

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 0{,}554$$

$$p \text{ vrijednost} = 0{,}461$$

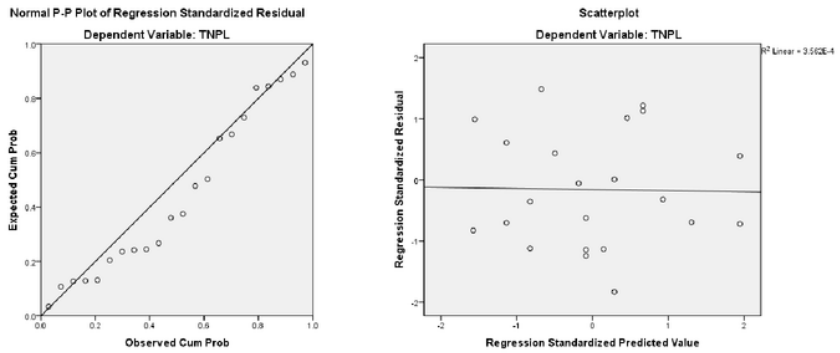
Na osnovu navedenih vrijednosti, određuje se da li stopa nezaposlenosti statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Odluka o prihvatanju ili odbacivanju hipoteza donosi se na osnovu *p vrijednosti*. Dobijena *p vrijednost* iznosi 0,461, a nakon što se ona uporedi sa postavljenom granicom značajnosti ($p = 0{,}05$), može se vidjeti da je dobijena vrijednost veća od granične. U skladu sa tim prihvata se nulta hipoteza i zaključuje se da je parametar nagiba nula. Pošto je parametar nagiba nula, nema smisla koristiti regresioni model za objašnjenje nekvalitetnih kredita pomoću stope nezaposlenosti. To potvrđuje i regresiona linija koja je prikazana na dijagramu *Scatterplot*.

Stopa rasta potrošačkih cijena

I posljednja makroekonomska promjenljiva koja je uključena u regresionu analizu je stopa rasta potrošačkih cijena (promjenljiva TICP) pomoću koje se mjeri stopa inflacije. Prostom linearnom regresijom odredićе se da li se navedena objašnjavajuća promjenljiva može koristiti za određivanje vrijednosti zavisne promjenljive. Drugim riječima, pomoću proste linearne regresije odredićе se da li se na osnovu vrijednosti stope rasta potrošačkih cijena može predvidjeti vrijednost nekvalitetnih kredita u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Kao što je već rečeno, prvi korak regresione analize je crtanje dijagrama pomoću kojih se može provjeriti normalnost i linearnost raspodjele, ali i postojanje netipičnih tačaka (dijagrami *Normal P-P Plot* i *Scatterplot*). Dijagram *Scatterplot* je dorađen i na njega je dodata regresiona linija. Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a predstavljeni su na slici 6.

Slika 6: Normal P-P Plot i Scatterplot dijagrami (promjenljiva TICP)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* vidi se da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama, a to znači da nema velikih odstupanja od normalnosti. To je potvrđeno i testom normalnosti koji je sproveden nakon transformacije promjenljive ICP. Na dijagramu *Scatterplot,* odnosno dijagramu rasturanja standardizovanih odstupanja, vidi se da su odstupanja približno pravougaono raspoređena i da je većina rezultata nagomilana u centru (oko tačke 0) i da nema netipičnih tačaka (nema slučajeva koji imaju odstupanja manja od – 3,3 ili veća od 3,3).

Sljedeći korak regresione analize je vrednovanje modela, odnosno provjera da li je korišteni regresioni model dobar. Model se vrednuje na osnovu parametara iz tabele *Model Summary* koju generiše statistički softver *IBM SPSS Statistics Version 20.* Parametri na osnovu kojih se vrednuje model su parametri *R, R Square, Adjusted R Square* i *Std. Error of the Estimate*, a dati su u tabeli 39.

Tabela 39: Prosta regresija – Model Summary (promjenljiva TICP)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.475[a]	.226	.187	.61368

a. Predictors: (Constant), TICP
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R*, odnosno apsolutna vrijednost koeficijenta korelacije, ukazuje na srednju povezanost između stope rasta potrošačkih cijena i nekvalitetnih kredita. Pokazatelj *R Square*, odnosno koeficijent determinacije, iznosi 0,226 i pokazuje da se 22,6% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope inflacije mjerene stopom rasta potrošačkih cijena. Sa druge strane, pokazetelj *Adjusted R Square* daje bolju procjenu stvarne vrijednosti koeficijenta determinacije jer koriguje vrijednost pokazatelja *R Square*. U ovom slučaju vrijednost pokazatelja *Adjusted R Square* pokazuje da se 18,7% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope rasta potrošačkih cijena. Standardna greška, koja ukazuje na preciznost modela iznosi 0,613.

Nakon vrednovanja modela, potrebno je testirati značajnost regresione veze. Drugim riječima, potrebno je testirati da li je stopa rasta potrošačkih cijena relevantna za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Da bi se testirala značajnost regresione veze neophodno je postaviti hipoteze pomoću kojih će se testirati da li objašnjavajuća promjenljiva (promjenljiva TICP) statistički dobro predviđa kretanje zavisne promjenljive (promjenljiva TNPL). U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, tako da su postavljene sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Hipoteze se testiraju pomoću *F testa,* a rezultati su prikazani u tabeli 40.

Tabela 40: Prosta regresija – ANOVA (promjenljiva TICP)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2.200	1	2.200	5.842	.025[b]
	Residual	7.532	38	.377		
	Total	9.732	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), TICP

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F\ vrijednost = 5{,}842$$

$$p\ vrijednost = 0{,}025$$

Na osnovu *F vrijednosti* i *p vrijednosti* može se odrediti da li stopa inflacije mjerena stopom rasta potrošačkih cijena statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Prihvatanje, odnosno odbacivanje postavljenih hipoteza vrši se na osnovu dobijene *p vrijednosti*. U ovom slučaju, dobijena *p vrijednost* iznosi 0,025 i kada se njena vrijednost uporedi sa postavljenom granicom značajnosti ($p = 0{,}05$) vidi se da je ona manja od granične. Na osnovu toga, nulta hipoteza se odbacuje, a prihvata se alternativna i može se zaključiti da je parametar nagiba različit od nule. Pošto je parametar nagiba različit od nule, zaključuje se da je regresioni model dobar, odnosno da se može koristiti za predviđanje vrijednosti zavisne promjenljive (promjenljiva TNPL) na osnovu vrijednosti objašnjavajuće promjenljive (promjenljiva TICP). To se vidi i pomoću regresione linije koja je prikazana na dijagramu *Scatterplot*.

Nakon što je vrednovan regresioni model i nakon što je utvrđeno da se može koristiti za predviđanje vrijednosti nekvalitetnih kredita na osnovu vrijednosti stope rasta potrošačkih cijena, potrebno je ocijeniti koeficijente modela i vrednovati objašnjavajuću promjenljivu. Značajnost objašnjavajuće promjenljive u modelu provjerava se pomoću *t testa*, a rezultati su prikazani u tabeli 41 (tabela *Coefficients*).

Tabela 41: Prosta regresija – Coefficients (promjenljiva TICP)

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-.024	.133		-.179	.860
	TICP	-.689	.285	-.475	-2.417	.025

a. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Ukoliko se, na osnovu *p vrijednosti* utvrdi da je objašnjavajuća promjenljiva potrebna u istraživanju, konstruiše se regresiona jednačina. U ovom slučaju, dobijena *p vrijednost* iznosi 0,025 i kada se uporedi sa postavljenom granicom značajnosti ($p = 0{,}05$) vidi se da je manja od granične, tako da se stopa rasta potrošačkih cijena može koristiti i dalje u istraživanju. Pomoću podataka iz tabele *Coefficients*, odnosno pomoću nestandardizovanog koeficijenta *B*, konstruisana je regresiona jednačina:

$$TNPL = -0{,}024 - 0{,}689 * TICP$$

Na osnovu regresione jednačine može se očekivati da će, u slučaju povećanja stope rasta potrošačkih cijena, doći do smanjenja nekvalitetnih kredita u narednom periodu. Međutim, ako se stopa rasta potrošačkih cijena smanji, doći će do povećanja nekvalitetnih kredita u bankarskom sektoru. S obzirom na činjenicu da povećanju objašnjavajuće promjenljive odgovara opadanje zavisne promjenljive, riječ je o inverznoj vezi.

Još jedan važan pokazatelj iz tabele *Coefficients* je standardizovani koeficijent *Beta* koji iznosi 0,475 (posmatra se njegova apsolutna vrijednost). Vrijednost koeficijenta *Beta* pokazuje koliko stopa rasta potrošačkih cijena doprinosi objašnjavanju nekvalitetnih kredita bankarskog sektora. Takođe, ovaj koeficijent pokazuje i broj standardnih devijacija za koji bi se vrijednosti nekvalitnih kredita promijenile kada se stopa rasta potrošačkih cijena promijeni za jednu jedinicu standardnog odstupanja.

2.5.2. Analiza specifičnih bankarskih faktora koji utiču na nekvalitetne kredite

U ovom dijelu biće prikazani rezultati analize koja je sprovedena sa ciljem da se odredi koji specifični bankarski faktori imaju uticaj na nekvalitetne kredite i da se, na osnovu tih faktora, predvidi kretanje nekvalitetnih kredita u narednom periodu. U skladu sa navedenim ciljem, sprovedena je regresiona analiza u koju je, pored zavisne promjenljive koja pokazuje udio nekvalitetnih u ukupnim kreditima bankarskog sektora (promjenljiva TNPL) uključeno još šest specifičnih bankarskih promjenljivih i to: koeficijent adekvatnosti kapitala (promjenljiva CAR), odnos kredita i depozita (promjenljiva TLTD), prinos na aktivu (promjenljiva ROA), prinos na akcijski kapital (promjenljiva ROE), aktivna kamatna stopa (promjenljiva IR) i stopa kreditnog rasta (promjenljiva TCG).

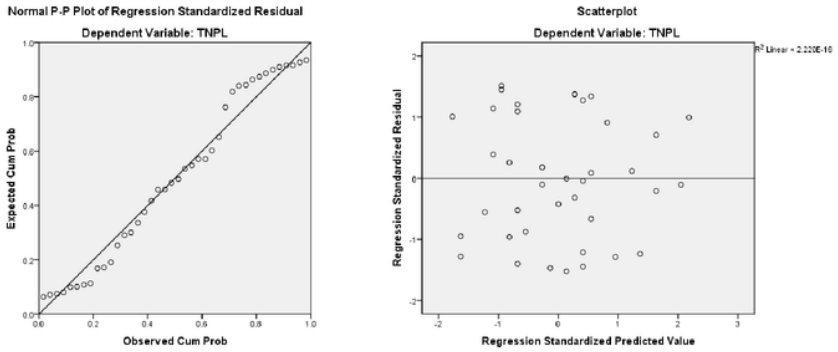
Sprovedena je prosta regresiona analiza, odnosno regresiona analiza za svaku objašnjavajuću promjenljivu posebno, kao što je to urađeno i prilikom sprovođenja regresione analize u koju su uključene zavisna i makroekonomske objašnjavajuće promjenljive. Prilikom analize korišten je prethodno opisani model proste linearne regresije. Rezultati regresione analize u koju su uključene zavisna i objašnjavajuće specifične bankarske promjenljive dati su u nastavku.

Koeficijent adekvatnosti kapitala

Prva specifična bankarska promjenljiva koja je uključena u regresionu analizu je koeficijent adekvatnosti kapitala (promjenljiva CAR). Pomoću proste linearne regresije odrediće se da li se ova objašnjavajuća promjenljiva može koristiti za određivanje vrijednosti zavisne promjenljive, odnosno da li se na osnovu vrijednosti koeficijenta adekvatnosti kapitala može predvidjeti vrijednost nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije, na isti način kao što je sprovedena i regresiona analiza u koju su, pored zavisne promjenljive, bile uključene tri objašnjavajuće makroekonomske promjenljive.

Kao što je prethodno opisano, prvi korak regresione analize je crtanje dijagrama pomoću kojih se može provjeriti normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka (dijagrami *Normal P-P Plot* i *Scatterplot*). Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a dijagram *Scatterplot* je dorađen, odnosno na njega je dodata regresiona linija. Navedeni dijagrami prikazani su na slici 7.

Slika 7: Normal P-P Plot i Scatterplot dijagrami (promjenljiva CAR)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* vidi se da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama tako da nema velikih odstupanja od normalnosti. Takođe, to je potvrđeno i prethodno sprovedenim testom normalnosti. Na dijagramu *Scatterplot,* odnosno dijagramu rasturanja standardizovanih odstupanja, vidi se da su odstupanja približno pravougaono raspoređena, a većina rezultata nagomilana je u centru, oko tačke 0. Takođe, na ovom dijagramu se može vidjeti da nema netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3 ili veća od 3,3.

Nakon crtanja dijagrama, potrebno je vrednovati regresioni model, odnosno provjeriti da li je on dobar. Model se vrednuje na osnovu parametara iz tabele *Model Summary* koju generiše statistički softver *IBM SPSS Statistics Version 20.* Parametri na osnovu kojih se vrednuje regresioni model dati su u tabeli 42.

Tabela 42: Prosta regresija – Model Summary (promjenljiva CAR)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.128[a]	.016	-.010	.68402

a. Predictors: (Constant), CAR
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R*, odnosno apsolutna vrijednost koeficijenta korelacije, ukazuje na nisku povezanost između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita. Drugi pokazatelj *R Square*, odnosno koeficijent determinacije, iznosi 0,016 i pokazuje da se samo 1,6% varijabiliteta nekvalitetnih kredita može objasniti pomoću koeficijenta adekvatnosti kapitala. Treći pokazatelj, odnosno pokazetelj *Adjusted R Square* daje bolju procjenu stvarne vrijednosti koeficijenta determinacije jer koriguje vrijednost pokazatelja *R Square.* U ovom slučaju vrijednost pokazatelja *Adjusted R Square* pokazuje da se samo 1,0% varijabiliteta nekvalitetnih kredita može objasniti pomoću koeficijenta adekvatnosti kapitala. Standardna greška, koja ukazuje na preciznost modela iznosi 0,684.

Sljedeći korak regresione analize odnosi se na testiranje značajnosti regresione veze. Konkretno, u ovom slučaju, testirano je da li je koeficijent adekvatnosti kapitala relevantan za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora u narednom periodu. Prilikom testiranja značajnosti regresione veze neophodno je postaviti hipoteze pomoću kojih se testira da li objašnjavajuća promjenljiva (promjenljiva CAR) statistički dobro predviđa kretanje zavisne promjenljive (promjenljiva TNPL). U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, tako da su postavljene sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Hipoteze su testirane pomoću *F testa,* a rezultati su prikazani u tabeli 43.

Tabela 43: Prosta regresija – ANOVA (promjenljiva CAR)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	.294	1	.294	.629	.432[b]
	Residual	17.780	38	.468		
	Total	18.074	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), CAR

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 0{,}629$$

$$p \text{ vrijednost} = 0{,}432$$

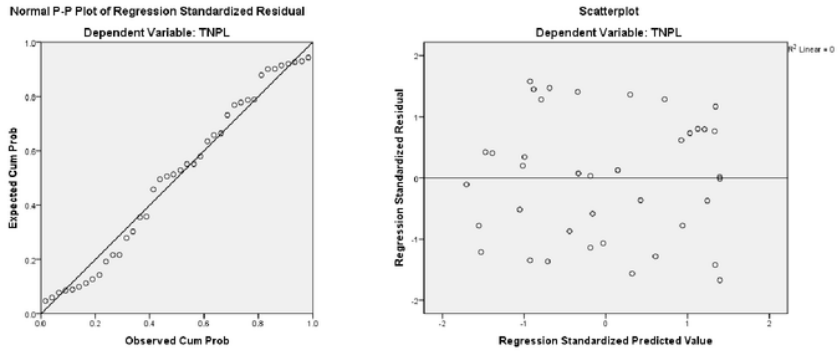
Na osnovu navedenih vrijednosti, određuje se da li koeficijent adekvatnosti kapitala statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Odluka o prihvatanju ili odbacivanju hipoteza donosi se na osnovu *p vrijednosti.* U ovom slučaju, dobijena *p vrijednost* koja iznosi 0,432 je veća od postavljene granice značajnosti (p = 0,05) tako da se nulta hipoteza prihvata. S obzirom da je parametar nagiba nula, nema smisla koristiti regresioni model za objašnjenje nekvalitetnih kredita pomoću koeficijenta adekvatnosti kapitala. To potvrđuje i regresiona linija koja je prikazana na dijagramu *Scatterplot.*

Odnos kredita i depozita

Druga specifična bankarska promjenljiva koja je uključena u regresionu analizu je odnos kredita i depozita (promjenljiva TLTD), odnosno promjenljiva koja je jedan od pokazatelja likvidnosti bankarskog sektora. Pomoću proste linearne regresije odrediće se da li se ova promjenljiva može koristiti za određivanje vrijednosti nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Prvi korak regresione analize je crtanje dijagrama pomoću kojih se provjerava normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka (dijagram *Normal P-P Plot* i dijagram *Scatterplot*). Dijagram *Scatterplot* je dorađen jer je na njega dodata regresiona linija. Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a predstavljeni su na slici 8.

Slika 8: Normal P-P Plot i Scatterplot dijagrami (promjenljiva TLTD)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* može se vidjeti da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama, tako da nema velikih odstupanja od normalnosti. To je potvrđeno i testom normalnosti koji je sproveden nakon transformacije promjenljive LTD. Na dijagramu rasturanja standardizovanih odstupanja, odnosno dijagramu *Scatterplot,* može se vidjeti da nema netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3, a ni veća od 3,3.

Nakon crtanja dijagrama, potrebno je vrednovati model, odnosno provjeriti da li je korišteni regresioni model dobar. Model se vrednuje na osnovu parametara iz tabele *Model Summary* koju generiše statistički softver *IBM SPSS Statistics Version 20.* Parametri na osnovu kojih se vrednuje model su parametri *R, R Square, Adjusted R Square* i *Std. Error of the Estimate*, a dati su u tabeli 44.

Tabela 44: Prosta regresija – Model Summary (promjenljiva TLTD)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.188[a]	.035	.010	.67733

a. Predictors: (Constant), TLTD
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R* koji pokazuje apsolutnu vrijednost koeficijenta korelacije ukazuje na nisku povezanost između odnosa kredita i depozita i nekvalitetnih kredita. Pokazatelj *R Square* je koeficijent determinacije, a pokazuje da se samo 3,5% varijabiliteta nekvalitetnih kredita može objasniti pomoću odnosa kredita i depozita. Sličan, ali precizniji pokazatelj je *Adjusted R Square* koji predstavlja korigovanu vrijednost pokazatelja *R Square*. Pokazatelj *Adjusted R Square* daje bolju procjenu stvarne vrijednosti koeficijenta determinacije, a u ovom slučaju pokazuje da se samo 1,0% varijabiliteta nekvalitetnih kredita može objasniti pomoću odnosa kredita i depozita. Standardna greška iznosi 0,677 i ukazuje na preciznost modela.

Sljedeći korak, nakon vrednovanja modela, je testiranje značajnosti regresione veze. Drugim riječima, potrebno je testirati da li je odnos kredita i depozita relevantan za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora u narednom periodu. Da bi se testirala značajnost regresione veze neophodno je postaviti hipoteze pomoću kojih će se testirati da li objašnjavajuća promjenljiva (promjenljiva TLTD) statistički dobro predviđa kretanje zavisne promjenljive (promjenljiva TNPL). U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, a postavljene su sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Hipoteze su testirane pomoću *F testa,* a rezultati su prikazani u tabeli 45.

Tabela 45: Prosta regresija – ANOVA (promjenljiva TLTD)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	.641	1	.641	1.397	.245[b]
	Residual	17.434	38	.459		
	Total	18.074	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), TLTD

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 1{,}397$$

$$p \text{ vrijednost} = 0{,}245$$

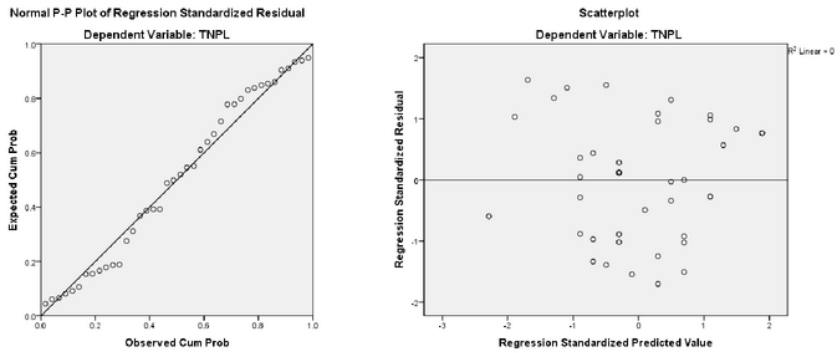
Na osnovu *F vrijednosti* i *p vrijednosti* može se odrediti da li odnos kredita i depozita statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Koja hipoteza će biti prihvaćena, a koja odbačena, određuje se na osnovu dobijene *p vrijednosti*. U ovom slučaju *p vrijednost* iznosi 0,245 i potrebno je uporediti sa postavljenom granicom značajnosti (p = 0,05). Pošto je dobijena *p vrijednost* veća od postavljene granice značajnosti, nulta hipoteza se prihvatiti i može se zaključiti da je parametar nagiba nula. Kada je parametar nagiba nula, onda nema smisla koristiti regresioni model za objašnjenje zavisne promjenljive. To potvrđuje i regresiona linija koja je prikazana na dijagramu *Scatterplot*.

Prinos na aktivu

Jedan od pokazatelja profitabilnosti bankarskog sektora je prinos na aktivu, a to je sljedeća specifična bankarska promjenljiva koja je uključena u regresionu analizu (promjenljiva ROA). Pomoću proste linearne regresije odredićе se da li se ova objašnjavajuća promjenljiva može koristiti za određivanje vrijednosti zavisne promjenljive, odnosno da li se na osnovu vrijednosti prinosa na aktivu može predvidjeti vrijednost nekvalitetnih kredita bankarskog sektora u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Prvi korak regresione analize je crtanje dijagrama pomoću kojih se provjerava normalnost i linearnost raspodjele, ali i postojanje netipičnih tačaka. To su dijagrami *Normal P-P Plot* i Scatterplot, koji su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20.* Dijagram *Scatterplot* je dorađen, odnosno na njega je dodata regresiona linija. Navedeni dijagrami prikazani su na slici 9.

Slika 9: Normal P-P Plot i Scatterplot dijagrami (promjenljiva ROA)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* vidi se da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama, a to znači da nema velikih odstupanja od normalnosti. To je potvrđeno i testom normalnosti koji je prethodno sproveden. Na dijagramu *Scatterplot,* odnosno dijagramu rasturanja standardizovanih odstupanja, vidi se da su odstupanja približno pravougaono raspoređena i da je većina rezultata nagomilana u centru, oko tačke 0, a nema netipičnih tačaka, odnosno nema slučajeva koji imaju odstupanja manja od – 3,3 i veća od 3,3.

Sljedeći korak regresione analize je vrednovanje modela, odnosno provjera da li je korišteni regresioni model dobar. Model se vrednuje na osnovu parametara iz tabele *Model Summary* koju generiše statistički softver *IBM SPSS Statistics Version 20.* Na osnovu parametara *R, R Square, Adjusted R Square* i *Std. Error of the Estimate* vrši se vrednovanje regresionog modela, a ti parametri dati su u tabeli 46.

Tabela 46: Prosta regresija – Model Summary (promjenljiva ROA)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.367[a]	.135	.112	.64146

a. Predictors: (Constant), ROA
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R* je apsolutna vrijednost koeficijenta korelacije i ukazuje na nisku povezanost između prinosa na aktivu i nekvalitetnih kredita bankarskog sektora. Sljedeći pokazatelj iz tabele je pokazatelj *R Square*, odnosno koeficijent determinacije, koji u ovom slučaju iznosi 0,135 i pokazuje da se 13,5% varijabiliteta nekvalitetnih kredita može objasniti pomoću prinosa na aktivu. Sa druge strane, pokazetelj *Adjusted R Square* koriguje vrijednost pokazatelja *R Square* i daje bolju procjenu stvarne vrijednosti koeficijenta determinacije. U ovom slučaju vrijednost pokazatelja *Adjusted R Square* je 0,112 i pokazuje da se 11,2% varijabiliteta zavisne promjenljive može objasniti pomoću ove objašnjavajuće promjenljive. Standardna greška, koja ukazuje na preciznos modela, u ovom slučaju iznosi 0,641.

Nakon vrednovanja modela, potrebno je testirati značajnost regresione veze, odnosno potrebno je testirati da li je prinos na aktivu relevantan za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora BiH. Da bi se testirala značajnost regresione veze neophodno je postaviti hipoteze pomoću kojih će se testirati da li objašnjavajuća promjenljiva statistički dobro predviđa kretanje zavisne promjenljive. U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, tako da su postavljene sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Hipoteze su testirane pomoću *F testa,* a rezultati su prikazani u tabeli 47.

Tabela 47: Prosta regresija – ANOVA (promjenljiva ROA)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2.438	1	2.438	5.925	.020[b]
	Residual	15.636	38	.411		
	Total	18.074	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), ROA

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 5{,}925$$

$$p \text{ vrijednost} = 0{,}020$$

Na osnovu *F vrijednosti* i *p vrijednosti* može se odrediti da li prinos na aktivu statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Koja hipoteza će biti prihvaćena, a koja odbačena, određuje se na osnovu dobijene *p vrijednosti*. U ovom slučaju *p vrijednost* iznosi 0,020, a potrebno je uporediti sa postavljenom granicom značajnosti (p = 0,05). Nakon poređenja, može se zaključiti da je dobijena *p vrijednost* manja od granične, tako da se nulta hipoteza odbacuje, a prihvata se alternativna. Pošto je prihvaćena alternativna hipoteza, može se zaključiti da je parametar nagiba različit od nule, tako da se regresioni model može koristiti za predviđanje vrijednosti zavisne promjenljive (promjenljiva TNPL) na osnovu vrijednosti objašnjavajuće promjenljive (promjenljiva ROA). To se vidi i pomoću regresione linije koja je prikazana na dijagramu *Scatterplot*.

Nakon što je vrednovan regresioni model i nakon što je utvrđeno da se može koristiti za predviđanje vrijednosti nekvalitetnih kredita na osnovu vrijednosti prinosa na aktivu, potrebno je ocijeniti koeficijente modela i vrednovati objašnjavajuću promjenljivu. Značajnost objašnjavajuće promjenljive u modelu provjerava se pomoću *t testa*, a rezultati su prikazani u tabeli 48 (tabela *Coefficients*).

Tabela 48: Prosta regresija – Coefficients (promjenljiva ROA)

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-.238	.151		-1.574	.124
	ROA	.497	.204	.367	2.434	.020

a. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Ukoliko se, na osnovu *p vrijednosti* utvrdi da je objašnjavajuća promjenljiva potrebna u istraživanju, kao što je slučaj sa promjenljivom prinos na aktivu, potrebno je konstruisati regresionu jednačinu. U ovom slučaju, dobijena *p vrijednost* iznosi 0,020, a nakon što se uporedi sa postavljenom granicom značajnosti (p = 0,05) može se zaključiti da je dobijena *p vrijednost* manja od granične, tako da je objašnjavajuća promjenljiva prinos na aktivu potrebna u istraživanju. Regresiona jednačina je konstruisana na osnovu podataka iz tabele *Coefficients*, a konstruisana je pomoću nestandardizovanog koeficijenta *B*. Konstruisana regresiona jednačina je:

$$TNPL = -0{,}238 + 0{,}494 * ROA$$

Na osnovu regresione jednačine može se očekivati da će, u slučaju povećanja prinosa na aktivu, doći i do povećanja nekvalitetnih kredita u narednom periodu. Međutim, u slučaju smanjenja prinosa na aktivu, smanjiće se i nekvalitetni krediti u bankarskom sektoru. Pošto povećanju objašnjavajuće promjenljive odgovara povećanje zavisne promjenljive, riječ je o direktnoj vezi.

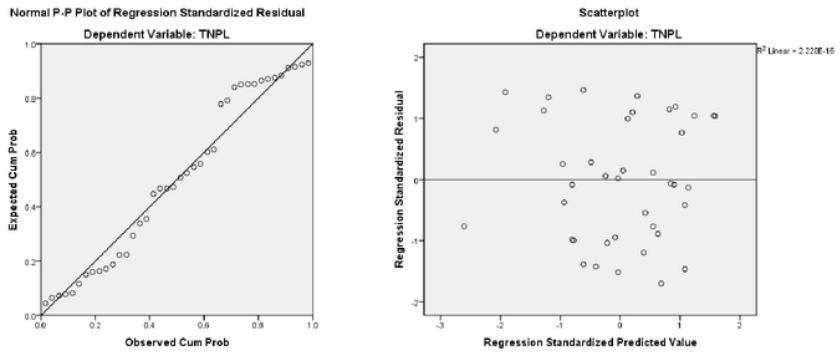
Još jedan važan pokazatelj iz tabele *Coefficients* je standardizovani koeficijent *Beta* koji iznosi 0,367. Vrijednost koeficijenta *Beta* pokazuje koliko prinos na aktivu doprinosi objašnjavanju nekvalitetnih kredita bankarskog sektora. Takođe, ovaj koeficijent pokazuje i broj standardnih devijacija za koji bi se vrijednosti nekvalitnih kredita promijenile kada se prinos na aktivu promijeni za jednu jedinicu standardnog odstupanja.

Prinos na akcijski kapital

Drugi pokazatelj profitabilnosti bankarskog sektora je prinos na akcijski kapital, a to je sljedeća specifična bankarska promjenljiva koja je uključena u regresionu analizu (promjenljiva ROE). Pomoću proste linearne regresije odrediće se da li se ova objašnjavajuća promjenljiva može koristiti za određivanje vrijednosti zavisne promjenljive, odnosno da li se na osnovu prinosa na akcijski kapital može predvidjeti vrijednost nekvalitetnih kredita bankarskog sektora u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Kao i u ostalim slučajevima, prvo su nacrtani dijagrami pomoću kojih se provjerava normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka (dijagrami *Normal P-P Plot* i *Scatterplot*). Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a dijagram *Scatterplot* je dorađen, odnosno na njega je dodata regresiona linija. Navedeni dijagrami prikazani su na slici 10.

Slika 10: Normal P-P Plot i Scatterplot dijagrami (promjenljiva ROE)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* može se vidjeti da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama, što znači da nema većih odstupanja od normalnosti. To je potvrđeno i prethodno sprovedenim testom normalnosti. Na dijagramu *Scatterplot,* odnosno dijagramu rasturanja standardizovanih odstupanja, vidi se da su odstupanja približno pravougaono raspoređena i da je većina rezultata nagomilana u centru (oko tačke 0), a nema ni netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3 i veća od 3,3.

Sljedeći korak regresione analize je vrednovanje modela, a on se vrednuje na osnovu parametara iz tabele *Model Summary* koju generiše statistički softver *IBM SPSS Statistics Version 20.* Vrijednosti parametara na osnovu kojih se procjenjuje da li je regresioni model dobar date su u tabeli 49.

Tabela 49: Prosta regresija – Model Summary (promjenljiva ROE)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.251[a]	.063	.038	.66755

a. Predictors: (Constant), ROE
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R*, odnosno apsolutna vrijednost koeficijenta korelacije, ukazuje na srednju povezanost između prinosa na akcijski kapital i nekvalitetnih kredita. Drugi pokazatelj *R Square*, odnosno koeficijent determinacije, pokazuje da se 6,3% varijabiliteta nekvalitetnih kredita može objasniti pomoću prinosa na akcijski kapital. Treći pokazatelj je pokazetelj *Adjusted R Square*, a on daje bolju procjenu stvarne vrijednosti koeficijenta determinacije jer koriguje vrijednost pokazatelja *R Square.* U ovom slučaju vrijednost pokazatelja *Adjusted R Square* pokazuje da se samo 3,8% varijabiliteta zavisne promjenljive može objasniti pomoću objašnjavajuće promjenljive. Standardna greška, koja ukazuje na preciznost modela iznosi 0,667.

Nakon vrednovanja modela, potrebno je testirati značajnost regresione veze. Konkretno, u ovom slučaju, testirano je da li je prinos na akcijski kapital relevantan za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora u narednom periodu. Prilikom testiranja značajnosti regresione veze potrebno je postaviti hipoteze pomoću kojih se testira da li objašnjavajuća promjenljiva (promjenljiva ROE) statistički dobro predviđa kretanje zavisne promjenljive (promjenljiva TNPL). U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, tako da su postavljene sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Hipoteze su testirane pomoću *F testa,* a rezultati su prikazani u tabeli 50.

Tabela 50: Prosta regresija – ANOVA (promjenljiva ROE)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1.141	1	1.141	2.560	.118[b]
	Residual	16.934	38	.446		
	Total	18.074	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), ROE

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 2{,}560$$

$$p \text{ vrijednost} = 0{,}118$$

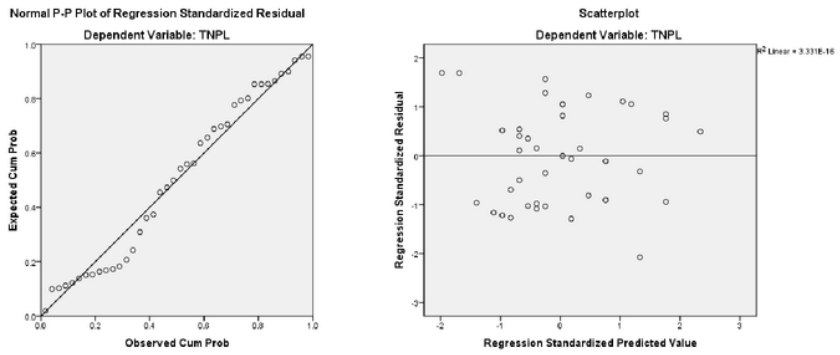
Na osnovu navedenih vrijednosti, može se odrediti da li prinos na akcijski kapital statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Odluka o prihvatanju ili odbacivanju hipoteza donosi se na osnovu *p vrijednosti*, koja u ovom slučaju iznosi 0,118. Da bi se mogla donijeti konačna odluka, potrebno je dobijenu *p vrijednost* uporediti sa postavljenom granicom značajnosti (p = 0,05). Nakon poređenja, vidi se da je dobijena *p vrijednost* veća od granične, tako da se nulta hipoteza prihvata. S obzirom na činjenicu da je parametar nagiba nula, nema smisla koristiti regresioni model za objašnjavanje nekvalitetnih kredita pomoću prinosa na akcijski kapital. To potvrđuje i regresiona linija koja je prikazana na dijagramu *Scatterplot.*

Aktivna kamatna stopa

Još jedna specifična bankarska promjenljiva koja je uključena u regresionu analizu je aktivna kamatna stopa (promjenljiva IR) pomoću koje komercijalne banke obračunavaju kamatu na plasirane kredite. Prostom linearnom regresijom odrediće se da li se ova promjenljiva može koristiti za određivanje vrijednosti nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Prvi korak regresione analize je crtanje dijagrama pomoću kojih se provjerava normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka (dijagram *Normal P-P Plot* i dijagram *Scatterplot*). Dijagram *Scatterplot* je dorađen jer je na njega dodata regresiona linija. Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a predstavljeni su na slici 11.

Slika 11: Normal P-P Plot i Scatterplot dijagrami (promjenljiva IR)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* vidi se da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama tako da nema velikih odstupanja od normalnosti. To je potvrđeno i prethodno sprovedenim testom normalnosti. Na dijagramu rasturanja standardizovanih odstupanja, vidi se da su odstupanja približno pravougaono raspoređena. Takođe, na ovom dijagramu se vidi da je većina rezultata nagomilana u centru, odnosno oko tačke 0 i da nema netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3 i veća od 3,3.

Sljedeći korak regresione analize je vrednovanje regresionog modela, odnosno provjera da li je regresioni model dobar. On se vrednuje na osnovu parametara iz tabele *Model Summary* koju generiše statistički softver *IBM SPSS Statistics Version 20.* Parametri na osnovu kojih se vrednuje regresioni model su *R*, *R Square*, *Adjusted R Square* i *Std. Error of the Estimate,* a dati su u tabeli 51.

Tabela 51: Prosta regresija – Model Summary (promjenljiva IR)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.347[a]	.120	.097	.64678

a. Predictors: (Constant), IR
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Aproslutna vrijednost koeficijenta korelacije (parametar *R*) pokazuje da postoji niska povezanost između aktivne kamatne stope i nekvalitetnih kredita u bankarskom sektoru. Koeficijent determinacije (parametar *R Square*) pokazuje da se 12,0% varijabiliteta nekvalitetnih kredita može objasniti pomoću aktivne kamatne stope. Korigovani koeficijent determinacije (parametar *Adjusted R Square*) daje bolju procjenu stvarne vrijednosti koeficijenta determinacije, a on pokazuje da se 9,7% varijabiliteta zavisne promjenljive može objasniti pomoću ove objašnjavajuće promjenljive. Standardna greška, koja ukazuje na preciznost modela iznosi 0,646.

Sljedeći korak regresione analize podrazumijeva testiranje značajnosti regresione veze. Drugim riječima, potrebno je testirati da li je aktivna kamatna stopa relevantna za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora u narednom periodu. Prilikom testiranja značajnosti regresione veze potrebno je postaviti hipoteze, a pomoću njih se testira da li objašnjavajuća promjenljiva (promjenljiva IR) statistički dobro predviđa kretanje zavisne promjenljive (promjenljiva TNPL). Kao što je već rečeno, u prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba. Postavljene su sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Kao i u prethodnim slučajevima, postavljene hipoteze su testirane pomoću *F* testa, a rezultati testiranja dati su u tabeli 52.

Tabela 52: Prosta regresija – ANOVA (promjenljiva IR)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2.178	1	2.178	5.206	.028[b]
	Residual	15.896	38	.418		
	Total	18.074	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), IR

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 5{,}206$$

$$p \text{ vrijednost} = 0{,}028$$

Na osnovu navedenih vrijednosti može se odrediti da li aktivna kamatna stopa statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Odluka o prihvatanju, odnosno odbacivanju postavljenih hipoteza donosi se na osnovu dobijene *p vrijednosti*. Dobijena *p vrijednost* iznosi 0,028, a kada se uporedi sa postavljenom granicom značajnosti (p = 0,05), može se zaključiti da je dobijena *p vrijednost* manja od granične. U skladu sa tim, nulta hipoteza se odbacuje, a prihvata se alternativna i može se zaključiti da je parametar nagiba različit od nule. Pošto je parametar nagiba različit od nule, regresioni model se može koristiti za predviđanje vrijednosti nekvalitetnih kredita na osnovu vrijednosti aktivne kamatne stope. To se vidi i pomoću regresione linije koja je prikazana na dijagramu *Scatterplot*.

Nakon što je vrednovan regresioni model i nakon što je utvrđeno da se može koristiti za predviđanje vrijednosti zavisne promjenljive (promjenljiva TNPL) na osnovu vrijednosti objašnjavajuće promjenljive (promjenljiva IR) potrebno je ocijeniti koeficijente modela i vrednovati objašnjavajuću promjenljivu. Značajnost objašnjavajuće promjenljive u modelu provjerava se pomoću *t testa*, a rezultati su prikazani u tabeli 53 (tabela *Coefficients*).

Tabela 53: Prosta regresija – Coefficients (promjenljiva IR)

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	T	Sig.
		B	Std. Error	Beta		
1	(Constant)	2.560	1.111		2.304	.027
	IR	-.340	.149	-.347	-2.282	.028

a. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na osnovu *p vrijednosti* može se utvrditi da li je objašnjavajuća promjenljiva potrebna u istraživanju. U ovom slučaju, dobijena *p vrijednost* iznosi 0,028 i manja je od postavljene granice značajnosti (p = 0,05) tako da se može zaključiti da je ova objašnjavajuća promjenljiva potrebna u istraživanju. Na osnovu podataka iz tabele *Coefficients*, odnosno pomoću nestandardizovanog koeficijenta *B*, konstruisana je regresiona jednačina:

$$TNPL = 2{,}560 - 0{,}340 * IR$$

Na osnovu regresione jednačine može se očekivati da će, u slučaju povećanja aktivne kamatne stope, doći do smanjenja nekvalitetnih kredita u narednom periodu. Sa druge strane, u slučaju smanjenja aktivne kamatne stope, doći će do povećanja nekvalitetnih kredita u bankarskom sektoru. S obzirom na činjenicu da povećanju objašnjavajuće promjenljive odgovara smanjenje zavisne promjenljive, riječ je o inverznoj vezi.

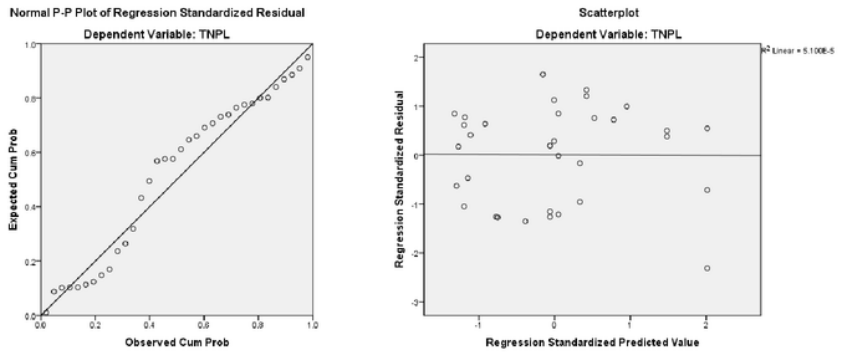
Još jedan važan pokazatelj iz ove tabele je standardizovani koeficijent *Beta* koji iznosi 0,347 (njegova apsolutna vrijednost). Vrijednost koeficijenta *Beta* pokazuje koliko aktivna kamatna stopa doprinosi objašnjavanju nekvalitetnih kredita bankarskog sektora, a ovaj koeficijent pokazuje i broj standardnih devijacija za koji bi se vrijednosti zavisne promjenljive promijenile kada se objašnjavajuća promjenljiva promijeni za jednu jedinicu standardnog odstupanja.

Stopa kreditnog rasta

I posljednja specifična bankarska promjenljiva koja je uključena u regresionu analizu je stopa kreditnog rasta (promjenljiva TCG). Pomoću proste linearne regresije odrediće se da li se pomoću stope kreditnog rasta može odrediti vrijednost nekvalitetnih kredita bankarskog sektora u narednom periodu. Regresiona analiza sprovedena je u skladu sa prethodno opisanim modelom proste linearne regresije.

Prvi korak regresione analize je crtanje dijagrama pomoću kojih se provjerava normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka (dijagram *Normal P-P Plot* i dijagram *Scatterplot*). Dijagram *Scatterplot* je dorađen tako što je na njega dodata regresiona linija. Dijagrami su nacrtani pomoću statističkog programa *IBM SPSS Statistics Version 20*, a predstavljeni su na slici 12.

Slika 12: Normal P-P Plot i Scatterplot dijagrami (promjenljiva TCG)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* može se vidjeti da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama, tako da nema velikih odstupanja od normalnosti. To je takođe prethodno potvrđeno i pomoću testa normalnosti koji je sproveden nakon transformacije promjenljive CG. Na dijagramu *Scatterplot* može se vidjeti da nema netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3 ili veća od 3,3.

Nakon crtanja dijagrama, potrebno je provjeriti da li je korišteni model dobar. Statistički softver *IBM SPSS Statistics Version 20* generiše tabelu *Model Summary*, a model se vrednuje na osnovu pokazatelja koji su dati u ovoj tabeli. Parametri na osnovu kojih se vrednuje model dati su u tabeli 54.

Tabela 54: Prosta regresija – Model Summary (promjenljiva TCG)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.458[a]	.210	.185	.61448

a. Predictors: (Constant), TCG
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Aproslutna vrijednost koeficijenta korelacije (parametar *R*) pokazuje da postoji srednja povezanost između stope kreditnog rasta i nekvalitetnih kredita u bankarskom sektoru. Koeficijent determinacije (parametar *R Square*) pokazuje da se 21,0% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope kreditnog rasta. Korigovani koeficijent determinacije (parametar *Adjusted R Square*) daje bolju procjenu stvarne vrijednosti koeficijenta determinacije, a u ovom slučaju pokazuje da se 18,5% varijabiliteta zavisne promjenljive može objasniti pomoću ove objašnjavajuće promjenljive. Standardna greška, koja ukazuje na preciznost modela iznosi 0,614.

Nakon vrednovanja modela, potrebno je testirati značajnost regresione veze, odnosno provjeriti da li je stopa kreditnog rasta relevantna za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora u narednom periodu. Prilikom testiranja značajnosti regresione veze potrebno je postaviti hipoteze, a pomoću njih se provjerava da li objašnjavajuća promjenljiva (promjenljiva TCG) statistički dobro predviđa kretanje zavisne promjenljive (promjenljiva TNPL). U prostoj regresionoj analizi to se svodi na testiranje vrijednosti parametra nagiba, a postavljene su sljedeće hipoteze:

H_0: Parametar nagiba je nula.

H_1: Parametar nagiba je različit od nule.

Kao i u prethodnim slučajevima, postavljene hipoteze su testirane pomoću *F testa*, a rezultati su prikazani u tabeli 55.

Tabela 55: Prosta regresija – ANOVA (promjenljiva TCG)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.211	1	3.211	8.503	.006[b]
	Residual	12.083	38	.378		
	Total	15.294	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), TCG

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 8{,}503$$

$$p \text{ vrijednost} = 0{,}006$$

Na osnovu *F vrijednosti* i *p vrijednosti* može se odrediti da li stopa kreditnog rasta statistički dobro predviđa kretanje nekvalitetnih kredita bankarskog sektora u narednom periodu. Odluka o prihvatanju ili odbacivanju hipoteza donosi se na osnovu *p vrijednosti*, koja u ovom slučaju iznosi 0,006. Da bi se mogla donijeti konačna odluka, potrebno je dobijenu *p vrijednost* uporediti sa postavljenom granicom značajnosti (p = 0,05). Nakon poređenja, vidi se da je dobijena *p vrijednost* manja od granične, tako da se nulta hipoteza odbacuje, a prihvata se alternativna. Pošto je parametar nagiba različit od nule, zaključuje se da se regresioni model može koristiti za objašnjenje nekvalitetnih kredita pomoću stope kreditnog rasta. To potvrđuje i regresiona linija koja je prikazana na dijagramu *Scatterplot*.

Nakon što je vrednovan regresioni model i nakon što je utvrđeno da se može koristiti za predviđanje vrijednosti nekvalitetnih kredita na osnovu vrijednosti stope kreditnog rasta, potrebno je ocijeniti koeficijente modela i vrednovati objašnjavajuću promjenljivu. Značajnost objašnjavajuće promjenljive u modelu provjerava se pomoću *t testa*, a rezultati su prikazani u tabeli 56 (tabela *Coefficients*).

Tabela 56: Prosta regresija – Coefficients (promjenljiva TCG)

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	T	Sig.
		B	Std. Error	Beta		
1	(Constant)	.114	.109		1.046	.304
	TCG	-.550	.189	-.458	-2.916	.006

a. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na osnovu *p vrijednosti* može se utvrditi da li je stopa kreditnog rasta potrebna u istraživanju. U ovom slučaju, dobijena *p vrijednost* iznosi 0,006 i manja je od postavljene granice značajnosti (p = 0,05) tako da se može zaključiti da je ova objašnjavajuća promjenljiva potrebna u istraživanju. Na osnovu podataka iz tabele *Coefficients*, odnosno pomoću nestandardizovanog koeficijenta *B*, konstruisana je regresiona jednačina:

$$TNPL = 0{,}114 - 0{,}550 * TCG$$

Na osnovu regresione jednačine može se očekivati da će, u slučaju povećanja stope kreditnog rasta, doći do smanjenja nekvalitetnih kredita u narednom periodu. Važi i obrnuto, odnosno, u slučaju smanjenja stope kreditnog rasta, doći će do povećanja nekvalitetnih kredita u bankarskom sektoru. S obzirom na činjenicu da povećanju stope kreditnog rasta odgovara smanjenje nekvalitetnih kredita, riječ je o inverznoj vezi.

Još jedan važan pokazatelj iz ove tabele je standardizovani koeficijent *Beta* koji iznosi 0,458 (njegova apsolutna vrijednost). Vrijednost koeficijenta *Beta* pokazuje koliko stopa kreditnog rasta doprinosi objašnjavanju nekvalitetnih kredita bankarskog sektora, a ovaj koeficijent pokazuje i broj standardnih devijacija za koji bi se vrijednosti zavisne promjenljive promijenile kada se objašnjavajuća promjenljiva promijeni za jednu jedinicu standardnog odstupanja.

Na kraju sprovedene proste regresione analize, može se zaključiti da se četiri objašnjavajuće promjenljive mogu koristiti za objašnjavanje kretanja nekvalitetnih kredita u bankarskom sektoru BiH. Regresiona analiza pokazala je da se pomoću vrijednosti stope rasta potrošačkih cijena (promjenljiva TICP), prinosa na aktivu (promjenljiva ROA), aktivne kamatne stope (promjenljiva IR) i stope kreditnog rasta (promjenljiva TCG) može predvidjeti vrijednost nekvalitetnih kredita u narednom periodu. Pri tom je utvrđeno da će, u slučaju povećanja prinosa na aktivu, doći i do povećanja nekvalitetnih kredita. Sa druge strane, u slučaju povećanja stope inflacije mjerene stopom rasta potrošačkih cijena, aktivne kamatne stope i stope kreditnog rasta, doći će do smanjenja nekvalitetnih kredita bankarskog sektora u narednom periodu.

Takođe, regresionom analizom je utvrđeno da se stopa rasta realnog BDP-a (promjenljiva GDP), stopa nezaposlenosti (promjenljiva TUNEMP), koeficijent adekvatnosti kapitala (promjenljiva CAR), odnos kredita i depozita (promjenljiva TLTD) i prinos na akcijski kapital (promjenljiva ROE) ne mogu koristiti za objašnjavanje ponašanja nekvalitetnih kredita bankarskog sektora BiH u narednom periodu.

2.6. Višestruka regresiona analiza

Višestruka regresiona analiza se, u praksi, češće koristi od proste, jer na pojave obično djeluje više faktora istovremeno. U cilju određivanja vrijednosti zavisne promjenljive na osnovu više objašnjavajućih promjenljivih koje na nju utiču istovremeno, sprovedena je višestruka regresiona analiza. I u višestrukoj regresionoj analizi korišteni su prethodno predstavljeni podaci koji su obrađeni pomoću statističkog programa *IBM SPSS Statistics Version 20*.

Korištena je standardna višestruka regresija, tako da su sve promjenljive istovremeno uključene u istraživanje. Pomoću višestruke regresione analize odredиće se koje makroekonomske i specifične bankarske promjenljive utiču na nekvalitetne kredite bankarskog sektora BiH. Takođe, analiza će pokazati i na koji način objašnjavajuće promjenljive utiču na zavisnu promjenljivu. U višestruku regresionu analizu su, pored zavisne promjenljive koja pokazuje udio nekvalitetnih u ukupnim kreditima, uključene tri makroekonomske promjenljive (stopa rasta realnog BDP-a, stopa nezaposlenosti i stopa inflacije mjerena stopom rasta potrošačkih cijena) i šest specifičnih bankarskih promjenljivih (koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, prinos na akcijski kapital, aktivna kamatna stopa i stopa kreditnog rasta). Potrebno je napomenuti da su i u višestrukoj regresionoj analizi korištene transformisane vrijednosti pojedinih promjenljivih, kako bi se zadovoljio uslov njihove normalne raspodjele.

Cjelokupna regresiona analiza sprovedena je po istim principima kao i prosta, samo što je još dodatno provjereno da li se javlja problem multikolinearnosti, odnosno provjereno je da li su objašnjavajuće promjenljive međusobno korelirane. Multikolinearnost je provjerena pomoću statističkog softvera *IBM SPSS Statistics Version 20*, a rezultati su prikazani u tabeli *Coefficients*. Da bi se odredilo da li postoji problem multikolinearnosti u istraživanju, potrebno je analizirati vrijednosti *Tolerance* i *VIF* iz tabele *Coefficients*, koju generiše korišteni softver. Vrijednost *Tolerance* pokazuje koliki dio varijanse date objašnjavajuće promjenljive nije objašnjen varijansama drugih objašnjavajućih promjenljivih u modelu, a kada je ova vrijednost jako mala (manja od 0,10) onda postoji korelacija sa drugim promjenljivim. Vrijednost *VIF* je faktor povećanja varijanse, a kada je ova vrijednost iznad 10 tada postoji problem multikolinearnosti.

Ostatak višestruke regresione analize sproveden je na isti način kao što je sprovedena i prosta regresiona analiza. Prvo su nacrtani odgovarajući dijagrami (*Normal P–P of the Regression Standardised Residual* i *Scatterplot*) pomoću kojih se provjerava normalnost i linearnost raspodjele, kao i raspored odstupanja. Nakon toga, vrednovan je regresioni model, a rezultati su dati u tabeli *Model Summary*. Takođe, testirana je i značajnost regresione veze, odnosno provjereno je da li postoji linearno slaganje između varijacija analiziranih promjenljivih, a rezultati su dati u tabeli *ANOVA*. Nakon testiranja značajnosti regresione veze, provjereno je koliko su pojedinačne objašnjavajuće promjenljive značajne u modelu, a rezultati su dati u tabeli *Coefficients*.

Na osnovu pokazatelja iz ove tabele konstruisana je i regresiona jednačina pomoću koje se mogu predvidjeti vrijednosti zavisne promjenljive na osnovu proizvoljnih vrijednosti objašnjavajućih promjenljivih koje imaju uticaj na zavisnu promjenljivu. Drugim riječima, višestruka regresiona analiza pokazaće na osnovu kojih makroekonomskih i specifičnih bankarskih faktora se mogu objasniti i predvidjeti nekvalitetni krediti bankarskog sektora BiH. Potrebno je napomenuti da su u analizu istovremeno uključene sve objašnjavajuće promjenljive, odnosno tri makroekonomske i šest specifičnih bankarskih promjenljivih. Rezultati sprovedene višestruke linearne regresione analize dati su u nastavku.[14]

[14] Potrebno je napomenuti da će se u tekstu koji opisuje rezultate višestruke regresione analize, koji su dobijeni pomoću softverskog programa *IBM SPSS Statistics Version 20*, brojevi odvajati zarezom, a ne tačkom kao što je navedeno u tabelama, kako bi se postigla jednoobraznost u tekstu.

Kao što je već rečeno, prvi korak višestruke regresione analize je provjera važenja pretpostavki, odnosno provjera multikolinearnosti, normalnosti, linearnosti i netipičnih tačaka. Prvo je provjereno da li postoji velika korelacija između objašnjavajućih promjenljivih, a rezultati su prikazani u tabeli 57 (tabela *Coefficients).*

Tabela 57: Višestruka regresija – Coefficients (provjera multikolinearnosti)

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	-20.886	15.456		-1.351	.187		
	GDP	.078	.161	.046	.483	.633	.831	1.204
	TUNEMP	1.155	.453	.371	2.550	.016	.363	2.754
	TICP	-.033	.364	-.009	-.090	.029	.716	1.397
	CAR	-.328	.835	-.050	-.392	.698	.475	2.104
	TLTD	-.090	.105	-.132	-.852	.401	.319	3.135
	ROA	21.413	4.705	2.236	4.551	.000	.032	31.386
	ROE	-2.605	.627	-2.037	-4.154	.000	.032	31.285
	IR	-.882	.886	-.127	-.996	.327	.470	2.126
	TCG	.139	.312	-.077	-.447	.058	.260	3.841

a. Dependent Variable: NPL

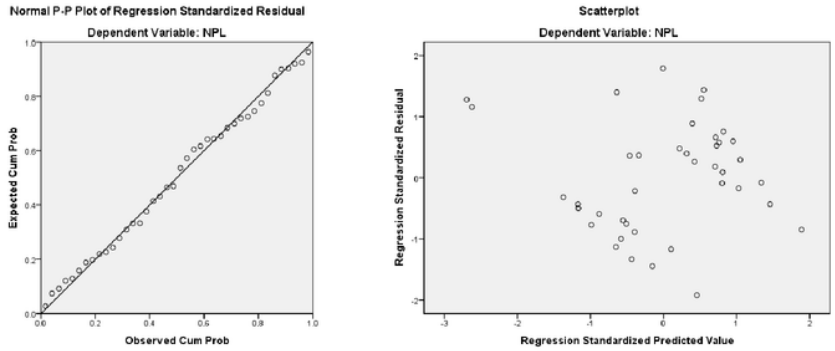
Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na osnovu pokazatelja *Tolerance* i *VIF* iz tabele *Coefficients* može se zaključiti da je problem multikolinearnosti ipak prisutan. Kada nema multikolinearnosti, tada su je vrijednost pokazatelja *Tolerance* ispod 0,10, a vrijednost pokazatelja *VIF* iznad 10. Dobijene vrijednosti pokazuju da postoji velika korelacija između pokazatelja profitabilnosti bankarskog sektora, odnosno da su promjenljive koje pokazuju prinos na aktivu (promjenljiva ROA) i prinos na akcijski kapital (promjenljiva ROE) međusobno korelirane.

Da bi rezultati regresione analize bili tačni, neophodno je prvo riješiti problem multikolinearnosti. Ovaj problem riješiće se izbacivanjem jedne objašnjavajuće promjenljive, odnosno izbacivanjem promjenljive ROE, jer je koeficijent korelacije između prinosa na akcijski kapital (promjenljiva ROE) i nekvalitetnih kredita manji od koeficijenta korelacije između prinosa na aktivu (promjenljiva ROA) i nekvalitetnih kredita. Iako je promjenljiva koja pokazuje prinos na akcijski kapital bankarskog sektora isključena iz višestruke regresione analize, može se odrediti da li profitabilnost bankarskog sektora utiče na nekvalitetne kredite jer je u istraživanje uključen drugi pokazatelj profitabilnosti, odnosno promjenljiva koja pokazuje prinos na aktivu.

Izbacivanjem promjenljive ROE, problem multikolinearnosti je riješen. Nakon provjere multikolinearnosti, provjereno je da li su ispunjene ostale pretpostavke koje su neophodne za regresionu analizu. Dijagrami pomoću kojih se provjerava normalnost i linearnost raspodjele, kao i postojanje netipičnih tačaka, predstavljeni su na slici 13.

Slika 13: Normal P-P Plot i Scatterplot dijagrami (višestruka linearna regresija)



Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Na dijagramu *Normal P-P Plot* može se vidjeti da su tačke raspoređene u približno pravoj dijagonalnoj liniji od donjeg lijevog do gornjeg desnog ugla dijagrama i može se zaključiti da je zadovoljen kriterijum normalnosti. Na drugom dijagramu, odnosno dijagramu *Scatterplot,* može se vidjeti da nema netipičnih tačaka jer nema slučajeva koji imaju odstupanja manja od – 3,3 ili veća od 3,3. Takođe, na ovom dijagramu se vidi da su odstupanja prilično pravougaono raspoređena, a većina rezultata je nagomilana u centru, odnosno oko tačke 0.

Nakon provjere pretpostavki, potrebno je provjeriti da li je korišteni regresioni model dobar. To je urađeno pomoću statističkog softvera *IBM SPSS Statistics Version 20*, a rezultati su dati u tabeli 58 (tabela *Model Summary*).

Tabela 58: Višestruka regresija – Model Summary

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.798[a]	.637	.543	3.2561

a. Predictors: (Constant), TCG, ROA, GDP, CAR, TICP, IR, TUNEMP, TLTD
b. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Pokazatelj *R*, odnosno apsolutna vrijednost koeficijenta korelacije, ukazuje na visoku povezanost između zavisne promjenljive (promjenljiva TNPL) i objašnjavajućih promjenljivih (promjenljive GDP, TUNEMP, TICP, CAR, TLTD, ROA, IR i TCG). Drugi pokazatelj, pokazatelj *R Square*, odnosno koeficijent determinacije iznosi 0,637 i pokazuje da se 63,7% varijabiliteta zavisne promjenljive (promjenljiva TNPL) može objasniti pomoću analiziranih objašnjavajućih promjenljivih. Sa druge strane, pokazetelj *Adjusted R Square* koriguje vrijednost pokazatelja *R Square* i daje bolju procjenu stvarne vrijednosti koeficijenta determinacije. Vrijednost pokazatelja *Adjusted R Square* je 0,543 i pokazuje da se 54,3% varijabiliteta nekvalitetnih kredita može objasniti pomoću navedenih objašnjavajućih promjenljivih. Standardna greška, koja ukazuje na preciznost modela iznosi 3,2561.

Nakon što je model vrednovan, potrebno je testirati i značajnost regresione veze, odnosno potrebno je testirati da li su stopa rasta BDP-a, stopa nezaposlenosti, stopa rasta potrošačkih cijena, koeficijent adekvatnosti kapitala, odnos kredita i depozita, prinos na aktivu, aktivna kamatna stopa i stopa kreditnog rasta relevantne za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Testiranje je izvršeno pomoću *F testa*, a rezultati su dati u tabeli 59 (tabela *ANOVA*).

Tabela 59: Višestruka regresija – ANOVA

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	575.943	8	71.993	6.790	.000[b]
	Residual	328.676	31	10.602		
	Total	904.619	39			

a. Dependent Variable: TNPL
b. Predictors: (Constant), TCG, ROA, GDP, CAR, TICP, IR, TUNEMP, TLTD

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

Podaci iz tabele *ANOVA* pokazuju da je:

$$F \text{ vrijednost} = 6{,}790$$

$$p \text{ vrijednost} = 0{,}000$$

Dobijena *p vrijednosti* iznosi 0,000, a nakon poređenja sa postavljenom granicom značajnosti ($p = 0{,}05$) može se zaključiti da je ona manja od granične i da je model statistički značajan. Drugim riječima, korišteni regresioni model je praktično upotrebljiv jer se pomoću određenih makroekonomskih i specifičnih bankarskih promjenljivih može predvidjeti kretanje nekvalitetnih kredita bankarskog sektora BiH u narednom periodu.

Nakon što je utvrđeno da se model višestruke linearne regresije može koristiti za predviđanje vrijednosti nekvalitetnih kredita na osnovu makroekonomskih i specifičnih bankarskih promjenljivih, potrebno je odrediti koje su to tačno promjenljive na osnovu čije vrijednosti se može predvidjeti vrijednost nekvalitetnih kredita u narednom periodu. Drugim riječima, potrebno je ocijeniti koeficijente modela i vrednovati objašnjavajuće promjenljive. Značajnost objašnjavajuće promjenljive u modelu provjerava se pomoću *t testa*, a rezultati su prikazani u tabeli *Coefficients*. Takođe, u ovoj tabeli ponovo su dati pokazatelji *Tolerance* i *VIF*, pomoću kojih se testira da li je prisutna multikolinearnost između objašnjavajućih promjenljivih. Problem multikolinearnosti bio je prisutan kada je u istraživanje bila uključena još jedna specifična bankarska promjenljiva, odnosno promjenjiva koja pokazuje prinos na akcijski kapital u bankarskom sektoru. Rezultati testiranja značajnosti objašnjavajućih promjenljivih u modelu dati su u tabeli 60.

Tabela 60: Višestruka regresija – Coefficients

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	T	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	-19.279	19.077		-1.011	.320		
	GDP	.074	.199	.045	.375	.710	.831	1.204
	TUNEMP	1.613	.542	.518	2.975	.953	.386	2.591
	TICP	-1.026	.449	.008	.059	.006	.717	1.394
	CAR	-.917	1.016	-.140	-.903	.374	.489	2.044
	TLTD	-.202	.126	-.298	-1.612	.117	.342	2.927
	ROA	2.444	1.401	.255	1.745	.001	.548	1.824
	IR	-1.129	1.092	-.163	-1.034	.009	.472	2.117
	TCG	-1.426	.375	-.235	-1.137	.014	.274	3.651

a. Dependent Variable: TNPL

Izvor: Izrada autora pomoću IBM SPSS Statistics Version 20

U tabeli *Coefficients* ima više pokazatelja čije vrijednosti je potrebno analizirati. Vrijednosti pokazatelja *Tolerance* i *VIF* potvrđuju da je, elimisanjem promjenljive ROE, problem multikolinearsnosti riješen jer vrijednosti pokazatelja *Tolerance* nisu manje od 0,1, a vrijednosti pokazatelja *VIF* nisu veće od 10.

Da bi se odredilo koja od analiziranih objašnjavajućih promjenljivih je potrebna u istraživanju, potrebno je pogledati *p vrijednost* za svaku promjenljivu posebno. Ukoliko je *p vrijednost* manja od postavljene granice značajnosti ($p = 0,05$), tada se može zaključiti da je promjenljiva potrebna u istraživanju jer daje statistički značajan i jedinstven doprinos u regresionoj jednačini, odnosno može se koristiti za objašnjenje nekvalitetnih kredita u bankarskom sektoru. Sa druge strane, ukoliko je *p vrijednost* veća od postavljene granice značajnosti ($p = 0,05$), može se zaključiti da se promjenljiva ne može koristiti za objašnjenje nekvalitetnih kredita i isključuje se iz istraživanja.

Na osnovu *p vrijednosti* zaključuje se da se stopa rasta potrošačkih cijena, prinos na aktivu, aktivna kamatna stopa i stopa kreditnog rasta mogu koristiti za objašnjavanje ponašanja nekvalitetnih kredita bankarskog sektora, kao i za predviđanje vrijednosti nekvalitetnih kredita u narednom periodu. Sa druge strane, stopa rasta BDP-a, stopa nezaposlenosti, koeficijent adekvatnosti kapitala i odnos kredita i depozita nisu relevantne za objašnjenje nekvalitetnih kredita bankarskog sektora BiH.

Pomoću nestandardizovanog koeficijenta *B*, iz tabele *Coefficients*, konstruisana je regresiona jednačina:

$$TNPL = -1{,}206 * TICP + 2{,}444 * ROA - 1{,}129 * IR - 1{,}426 * TCG$$

Na osnovu regresione jednačine može se zaključiti da će, u slučaju povećanja inflacije, odnosno stope rasta potrošačkih cijena, doći do smanjenja nekvalitetnih kredita, ako ostale promjenljive ostanu na istom nivou. Važi i obrnuto, odnosno može se očekivati da će se nekvalitetni krediti povećati ako se stopa rasta potrošačkih cijena smanji, a ostale promjenljive ostanu na istom nivou. S obzirom na činjenicu da povećanju (smanjenju) stope inflacije odgovara smanjenje (povećanje) nekvalitetnih kredita, riječ je o inverznoj vezi.

Na osnovu regresione jednačine može se zaključiti da će, u slučaju povećanja prinosa na aktivu, doći i do povećanja nekvalitetnih kredita, ako ostale promjenljive ostanu na istom nivou. Važi i obrnuto, odnosno, u slučaju smanjenja prinosa na aktivu, smanjiće se i nekvalitetni krediti u bankarskom sektoru, pod uslovom da ostale promjenljive ostanu na istom nivou. Pošto povećanju (smanjenju) prinosa na aktivu odgovara povećanje (smanjenje) nekvalitetnih kredita, riječ je o direktnoj vezi.

Dalje, može se zaključiti da će, u slučaju smanjenja aktivne kamatne stope doći do povećanja nekvalitetnih kredita, naravno ako ostale promjenljive ostanu na istom nivou. Svakako, važi i obrnuto, jer će se nekvalitetni krediti smanjiti ako se aktivna kamatna stopa poveća, ali pod uslovom da ostale promjenljive ostanu na istom nivou. Kao što se vidi, povećanju (smanjenju) aktivne kamatne stope odgovara smanjenje (povećanje) nekvalitetnih kredita, tako da je riječ o inverznoj vezi.

Na kraju, može se zaključiti da će se, u slučaju povećanja stope kreditnog rasta smanjiti nekvalitetni krediti, ako pri tom ostale promjenljive ostanu nepromijenjene. Isto tako, može se očekivati da će, u slučaju smanjenja stope kreditnog rasta, doći do povećanja nekvalitetnih kredita u narednom periodu, naravno, ako ostale promjenljive ostanu na istom nivou. Pošto povećanju (smanjenju) stope kreditnog rasta odgovara smanjenje (povećanje) nekvalitetnih kredita, riječ je o inverznoj vezi.

I posljednji važan pokazatelj iz tabele *Coefficients* je standardizovani koeficijent *Beta* koji pokazuje koliko pojedinačne promjenljive u modelu doprinose objašnjavanju nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Na osnovu vrijednosti *Beta* koeficijenta može se zaključiti da najveći doprinos prilikom objašnjavanja nekvalitetnih kredita ima prinos na aktivu, zatim stopa kreditnog rasta i aktivna kamatna stopa. Sa druge strane, najmanji doprinos prilikom objašnjavanja nekvalitetnih kredita ima stopa inflacije mjerena stopom rasta potrošačkih cijena. *Beta* koeficijent pokazuje i broj standardnih devijacija za koji bi se vrijednosti zavisne promjenljive promijenile kada se objašnjavajuća promjenljiva promijeni za jednu jedinicu standardnog odstupanja.

Višestruka regresiona anliza pokazala je da se nekvalitetni krediti bankarskog sektora BiH mogu objaniti pomoću četiri promjenljive, od kojih je jedna makroekonomska (stopa rasta potrošačkih cijena), a tri su specifične bankarske promjenljive (prinos na aktivu, aktivna kamatna stopa i stopa kreditnog rasta). Takođe, višestruka regresiona analiza pokazala je da se stopa rasta realnog BDP-a, stopa nezaposlenosti, koeficijent adekvatnosti kapitala i odnos kredita i depozita ne mogu koristiti za objašnjenje kretanja nekvalitetnih kredita u narednom periodu. Isti rezultati dobijeni su i pomoću proste regresione analize. Jedina razlika odnosi se na promjenljivu koja pokazuje prinos na akcijski kapital, za koju je u prostoj korelacionoj analizi utvrđeno da nije relevantna za objašnjavanje nekvalitetnih kredita. Ova promjenljiva nije bila uključena u višestruku regresionu analizu jer je u velikoj korelaciji sa drugim pokazateljem profitabilnosti bankarskog sektora, odnosno prinosom na aktivu, tako da je isključena iz istraživanja.

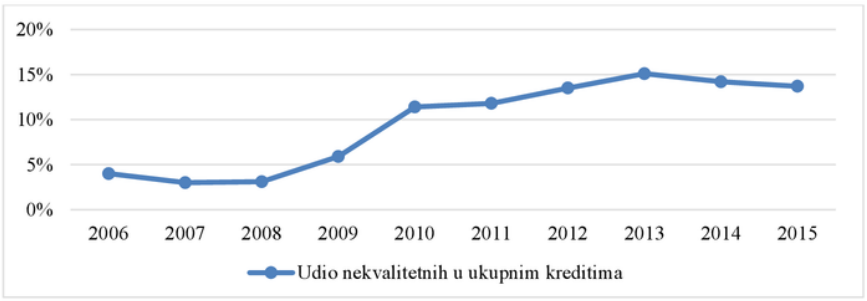
2.7. Analiza kretanja nekvalitetnih kredita

Poslednjih godina, rast nekvalitetnih kredita je jedan od većih problema sa kojim se suočava bankarski sektor BiH. Međutim, nekvalitetni krediti nisu problem samo u bankarskom sektoru BiH, već se sa istim problemom suočavaju i bankarski sektori razvijenih zemalja. Ovaj problem je posebno došao do izražaja nakon izbijanja globalne finansijske krize, kada se kvalitet kreditnog portfolia značajno pogoršao u većini zemalja. Oporavak bankarskog sektora BiH, od posljedica globalne finansijske krize je veoma spor i još uvijek traje, a udio nekvalitetnih u ukupnim kreditima je još uvijek veoma visok.

U nastavku je dat pregled kretanja nivoa nekvalitetnih kredita bankarskog sektora BiH, u periodu od 2006. do kraja 2015. godine. Navedeni period omogućava da se sagleda stanje prije, za vrijeme i nakon globalne finansijske krize, te da se utvrdi da li je ona uticala na pojavu i rast nekvalitetnih kredita u bankarskom sektoru BiH. S obzirom na činjenicu da pojedinačni podaci o nivou nekvalitetnih kredita u komercijalnim bankama koje posluju na cjelokupnoj teritoriji BiH nisu bili dostupni, u analizi su korišteni agregatni podaci za bankarski sektor. Navedeni podaci su godišnji podaci, a preuzeti su od Centralne banke BiH.

Na grafikonu 36 prikazan je trend kretanja nekvalitetnih kredita bankarskog sektora BiH u periodu od 2006. do kraja 2015. godine.

Grafikon 36: Trend kretanja nekvalitetnih kredita u bankarskom sektoru BiH (2006 – 2015)



Izvor: (CBBiH, 2017)

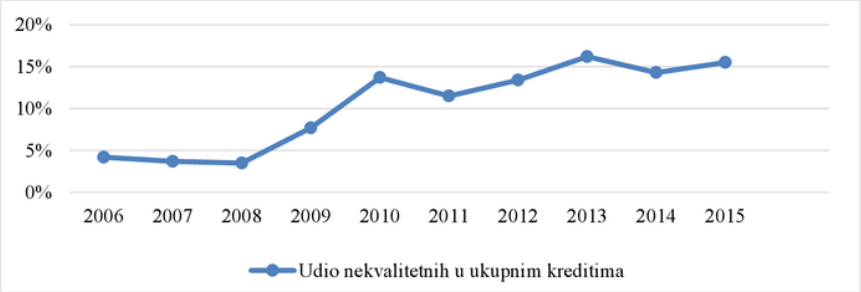
Na početku analiziranog perioda, odnosno na kraju 2006. godine udio nekvalitetnih u ukupnim bruto kreditima bankarskog sektora BiH iznosio je 4,0%. Tokom 2007. godine udio nekvalitetnih kredita smanjen je za 1,0%, a slično stanje bilo je i na kraju 2008. godine, kada je udio nekvalitetnih u ukupnim bruto kreditima iznosio 3,1%. Uticaj globalne finansijske krize u bankarskom sektoru BiH osjetio se već krajem 2009. godine, tokom koje je udio nekvalitetnih kredita povećan za 2,8% u odnosu na 2008. godinu. Značajno povećanje nekvalitetnih kredita zabilježeno je na kraju 2010. godine kada su oni iznosili 11,4%, odnosno 5,5% više nego u prethodnoj godini. Rast nekvalitetnih kredita nastavljen je tokom sljedeće tri godine, tako da su na kraju 2013. godine činili 15,1% ukupnih kredita. Tokom 2014. i 2015. godine udio nekvalitetnih u ukupnim kreditima je smanjen, tako da su na kraju 2015. godine činili 13,7% ukupnih kredita.

Može se konstatovati da su nekvalitetni krediti u analiziranom desetogodišnjem periodu uglavnom imali trend rasta, a izuzetak su samo 2007., 2014. i 2015. godina u kojima je zabilježeno blago smanjenje nekvalitetnih u ukupnim bruto kreditima bankarskog sektora BiH. Najveće učešće nekvalitetnih u ukupnim kreditima bankarskog sektora BiH zabilježeno je na kraju 2013. godine, a najmanje na kraju 2007. godine. Iako je tokom 2015. godine zabilježeno smanjenje udjela nekvalitetnih u ukupnim kreditima, oni su bili veoma visoki i iznosili su 13,7%, odnosno 9,7% više nego u 2006. godini.

Analiza je pokazala i da se udio nekvalitetnih u ukupnim kreditima bankarskog sektora BiH povećao za vrijeme globalne finansijske krize, čiji se vrhunac osjetio tokom 2009. godine. Da se bankarski sektor BiH sporo oporavlja od posljedica globalne finansijske krize najbolje pokazuje visok udio nekvalitenih u ukupnim kreditima.

Nekvalitetne kredite bankarskog sektora BiH čine nekvaitetni krediti bankarskog sektora RS i nekvalitetni krediti bankarskog sektora FBiH. Trend kretanja nekvalitetnih kredita bankarskog sektora RS prikazan je grafikonom 37.

Grafikon 37: Trend kretanja nekvalitetnih kredita u bankarskom sektoru RS (2006 – 2015)



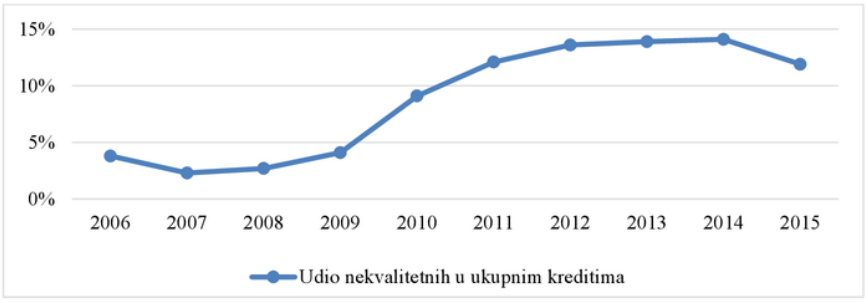
Izvor: (Agencija za bankarstvo RS, 2017)

Predstavljeni podaci pokazuju da su nekvalitetni krediti bankarskog sektora RS uglavnom imali trend rasta tokom analiziranog perioda, sa izuzetkom 2007., 2008., 2011. i 2014. godine tokom kojih je smanjeno učešće nekvalitetnih u ukupnim kreditima. Najveće učešće nekvalitetnih u ukupnim kreditima bankarskog sektora RS zabilježeno je na kraju 2013. godine kada je iznosilo 16,2%, a najmanje na kraju 2008. godine kada je iznosilo 3,5%. Na kraju 2010. godine zabilježeno je najveće povećanje učešća nekvalitetnih u ukupnim kreditima, a tokom godine učešće je povećano za 8,0%. Na kraju 2015. godine nekvalitetni krediti činili su 15,5% ukupnih kredita bankarskog sektora RS, odnosno 11,3% više nego u 2006. godini.

Globalna finansijska kriza negativno je uticala i na bankarski sektor RS u kome je udio nekvalitetnih u ukupnim kreditima značajno povećan tokom 2009. i 2010. godine. Ovaj sektor se još uvijek nije oporavio od posljedica krize, a to se vidi i po udjelu nekvalitetnih kredita koji su na veoma visokom nivou. U analiziranom periodu veći dio nekvalitetnih kredita odnosio se na nekvalitetne kredite pravnih lica, tako da su na kraju 2015. godine nekvalitetni krediti pravnih lica činili 18,3% ukupnih kredita koje su komercijalne banke plasirale pravnim licima, a nekvalitetni krediti stanovništva činili su 11,7% kredita koje su banke plasirale fizičkim licima.

Trend kretanja nekvalitetnih kredita bankarskog sektora FBiH prikazan je grafikonom 38.

Grafikon 38: Trend kretanja nekvalitetnih kredita u bankarskom sektoru FBiH (2006 – 2015)



Izvor: (Agencija za bankarstvo FBiH, 2007)

Podaci pokazuju da su i nekvalitetni krediti bankarskog sektora FBiH imali trend rasta tokom analiziranog desetogodišnjeg perioda, sa izuzetkom 2007. i 2015. godine tokom kojih je udio nekvalitetnih u ukupnim kreditima smanjen. Najveće učešće nekvalitetnih kredita zabilježeno je na kraju 2014., a najmanje na kraju 2007. godine. Na kraju 2015. godine nekvalitetni krediti činili su 11,9% ukupnih kredita bankarskog sektora FBiH, odnosno 8,1% više nego u 2006. godini.

Globalna finansijska kriza negativno je uticala i na bankarski sektor FBiH, u kome se učešće nekvalitetnih u ukupnim kreditima kontinuirano povećavalo od 2009. do kraja 2014. godine. Kao i u bankarskom sektoru RS, veći dio ukupnih nekvalitetnih kredita bankarskog sektora FBiH odnosio se na nekvalitetne kredite koje su komercijalne banke plasirale pravnim licima. Na kraju 2015. godine, od ukupnih kredita plasiranih pravnim licima na nekvalitetne kredite odnosilo se 16,7%, a od ukupnih kredita plasiranih stanovništvu na nekvalitetne kredite odnosilo se 9,0% (Agencija za bankarstvo FBiH, 2017).

Na kraju, može se konstatovati da su nekvalitetni krediti bankarskog sektora BiH, a samim tim i bankarskih sektora RS i FBiH, uglavnom imali trend rasta u periodu od 2006. do kraja 2015. godine. Tokom analiziranog perioda učešće nekvalitetnih u ukupnim kreditima bankarskog sektora FBiH bilo je niže od učešća nekvalitetnih u ukupnim kreditima bankarskog sektora RS, sa izuzetkom 2011. i 2012. godine. Globalna finansijska kriza uticala je na bankarske sektore RS i FBiH u kojima je od 2009. godine primjetno značajno povećanje nekvalitetnih kredita.

Udio nekvalitetnih kredita u bankarskom sektoru BiH je, na kraju 2015. godine bio prilično visok i to ukazuje na činjenicu da se ovaj sektor još uvijek nije oporavio od posljedica globalne finansijske krize. U četvrtom dijelu disertacije izvršena je komparativna anakliza udjela nekvalitetnih u ukupnim kreditima u bankarskom sektoru BiH i bankarskim sektorima zemalja regiona, a takođe i u bankarskim sektorima razvijenih zemalja. Komparativna analiza omogućava da se sagleda položaj bankarskog sektora BiH u odnosu na region i razvijene države.

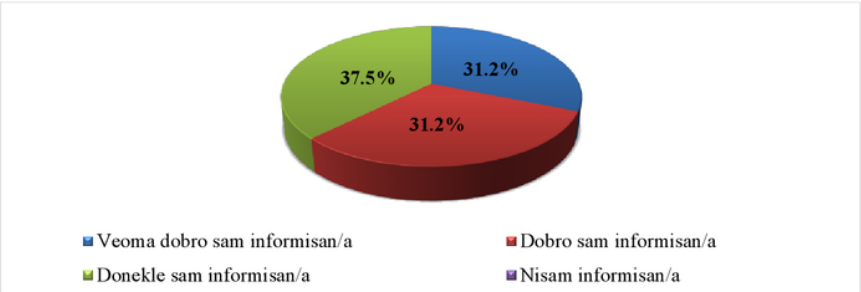
2.8. Rezultati sprovedenog anketiranja

Anketiranje u komercijalnim bankama koje posluju na cjelokupnoj teritoriji BiH sprovedeno je sa ciljem da se dođe do saznanja o uzrocima nastanka rizičnih kreditnih plasmana, ali i o načinu upravljanja kreditnim rizikom. Anketni upitnik dostavljen je rukovodiocima i menadžerima komercijalnih banaka, ali i zaposlenima u odjeljenjima za upravljanje kreditnim rizikom i onima koji su uključeni u proces odobravanja kredita. Anketni list sadržao je devet pitanja o ispitaniku i dvadeset pitanja zatvorenog tipa o upravljanju kreditnim rizikom i nekvalitetnim kreditima u komercijalnim bankama. Anketiranje je sprovedeno u periodu od 16.01.2017. do 16.05.2017. godine, a prikupljeno je ukupno 178 anketnih upitnika, lično ili putem Interneta. Ipak, rezultati anketiranja odnose se na 160 anketnih listova jer su ostali bili nepotpuni i nisu dali jasnu sliku o nekvalitetnim kreditima i upravljanju kreditnim rizikom u komercijalnim bankama. Anketni upitnik dat je u prilozima (prilog br. 5).

Nakon obrade popunjenih anketnih upitnika (ukupno 160 anketnih upitnika), vidi se da je u anketiranju učestvovalo ukupno 160 osoba. Od toga, 68,8% osoba je muškog pola, a 31,2% ženskog pola. Najveći broj ispitanika (43,7%) pripada skupini koja ima između 36 i 45 godina, 37,5% ispitanika pripada skupini koja ima između 26 i 35 godina, 12,5% ispitanika ima između 46 i 55 godina, a najmanje (6,3%) je onih koji imaju između 56 i 65 godina. Većina ispitanika ima završen fakultet u trajanju od tri, odnosno četiri godine (njih 62,5%), a 37,5% ispitanika ima završene master / magistarske ili doktorske studije. Manje od 5 godina rada u banci ima 18,8% ispitanika, njih 50% u banci radi između 5 i 10 godina, a 31,2% ispitanika u banci radi između 11 i 20 godina. Oko dvije trećine ispitanika (68,7%) pohađalo je seminare ili programe edukacije koji se odnose na upravljanje kreditnim rizikom i rizičnim plasmanima, a njih 31,3% nije ih pohađalo. Većina ispitanika koji su učestvovali u anketiranju (75,0%) radi na poziciji rukovodioca, dok je manji broj onih koji rade na poziciji službenika (25,0%). Polovina ispitanika (50,0%) radi u sektoru upravljanja rizicima, 25,0% radi u sektoru poslova sa stanovništvom, 18,7% radi u sektoru poslova sa privredom, a 6,3% u odjeljenu interne revizije. U Republici Srpskoj radi 62,5%, a u Federaciji BiH 37,5% ispitanika. Sjedište banke u kojoj radi 31,3% ispitanika nalazi se u Republici Srpskoj, dok se sjedište banke u kojoj radi 68,7% ispitanika nalazi u Federaciji BiH. Rezultati sprovedenog anketiranja, odnosno odgovori na 20 pitanja iz anketnog upitnika sa odgovarajućim objašnjenjima, prikazani su u nastavku.

Pitanje 1: Procijenite koliko ste informisani o problematici nekvalitetnih kredita.

Grafikon 39: Rezultati ankete - procjena informisanosti o nekvalitetnim kreditima

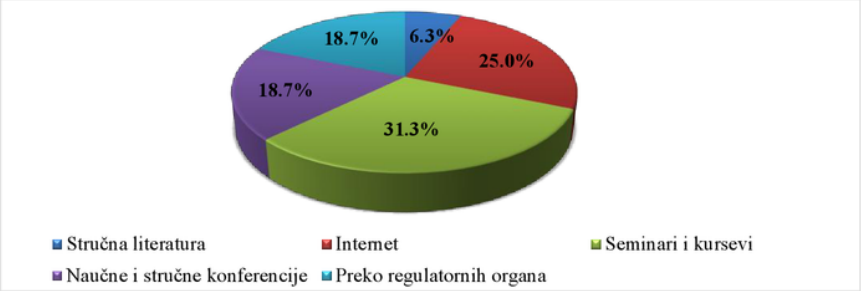


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Kao odgovor na ovo pitanje anketirani su mogli da izaberu jedan od ponuđena četiri odgovora kako bi ocijenili svoju informisanost o nekvalitetnim kreditima. Rezultati pokazuju da 31,2% ispitanika smatra da je veoma dobro informisano, a isto toliko ispitanika smatra da je dobro informisano o nekvalitetnim kreditima. O nekvalitetnim kreditima donekle je informisano 37,5% ispitanika, a nije bilo onih koji nisu informisani o ovom problemu.

Pitanje 2: Koji je Vaš glavni izvor pomoću koga se informišete o problematici nekvalitetnih kredita, odnosno kreditnom riziku uopšte?

Grafikon 40: Rezultati ankete - izvor informacija o nekvalitetnim kreditima

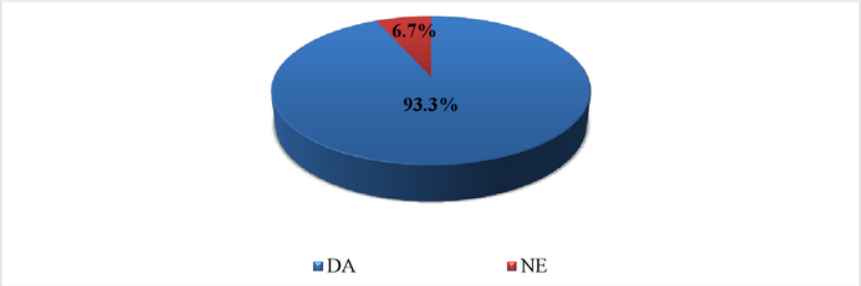


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Na osnovu odgovora na pitanje o izvoru informisanja o nekvalitetnim kreditima i kreditnom riziku vidi se da anketirani dolaze do određenih saznanja na različite načine. Najveći broj anketiranih (31,3%) informacije prikuplja na raznim seminarima i kursevima, a malo manje anketiranih (25,0%) do informacija dolazi uz pomoć Interneta. Regulatorni organi, ali i naučne i stručne konferencije su izvor informacija za 18,7% ispitanika, u oba slučaja, a stručna literatura (knjige, stručni članci i slično) privlači samo 6,3% ispitanika. Važno je napomenuti da su anketirani imali mogućnost da izaberu samo jedan od ponuđenih pet izvora informisanja.

Pitanje 3: Da li se, u banci u kojoj radite, upravlja kreditnim rizikom, a samim tim i nekvalitetnim kreditima?

Grafikon 41: Rezultati ankete - upravljanje kreditnim rizikom u komercijalnim bankama

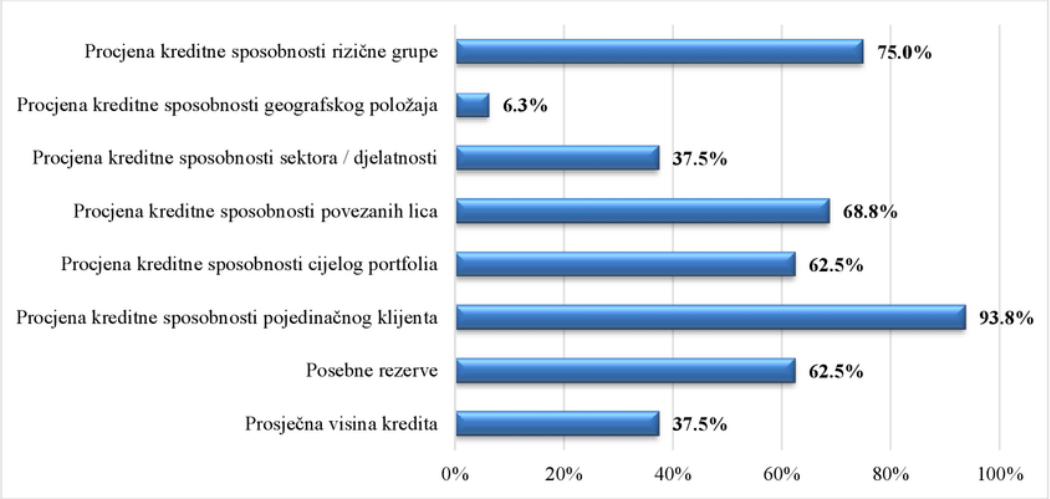


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Treće pitanje u anketnom upitniku odnosilo se na upravljanje kreditnim rizikom, odnosno nekvalitetnim kreditima u komercijalnim bankama u BiH. Kao što se i očekivalo, 93,3% anketiranih odgovorilo je potvrdno na ovo pitanje, a samo 6,7% anketiranih reklo je da se u komercijalnim bankama u kojima su zaposleni ne upravlja kreditnim rizikom, a samim tim ni nekvalitetnim kreditima. Ovo ukazuje na činjenicu da su komercijalne banke u BiH svjesne posljedica koje kreditni rizik nosi sa sobom i da preduzimaju određene mjere za upravljanje kreditnim rizikom, kako bi nivo nekvalitetnih kredita u kreditnom portfoliu smanjile, ili bar održale na istom nivou.

Pitanje 4: Šta se, u banci u kojoj radite, mjeri unutar kreditnog rizika?

Grafikon 42: Rezultati ankete – mjerenje kreditnog rizika u komercijalnim bankama

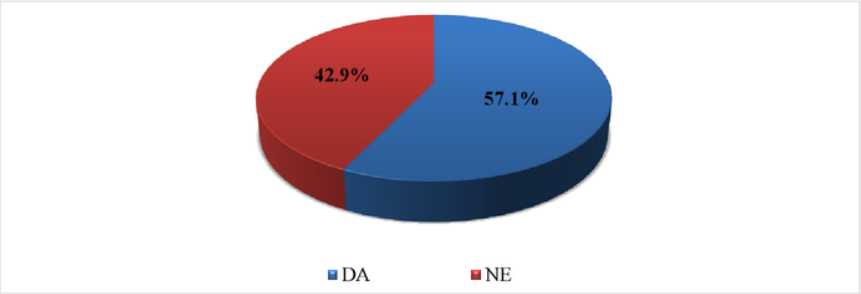


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Četvrto pitanje anketnog upitnika odnosilo se na način mjerenja kreditnog rizika u komercijalnim bankama. Anketirani su mogli da izaberu više ponuđenih odgovora, odnosno da navedu šta se sve mjeri unutar kreditnog rizika u komercijalnim bankama u kojima su zaposleni. Većina ispitanika (93,8%) navela je da se vrši procjena kreditne sposobnosti pojedinačnog klijenta, ali i procjena kreditne sposobnosti rizične grupe (75,0%). Takođe, veći broj ispitanika (68,8%) je naveo da se, u bankama u kojima su zaposleni, vrši procjena kreditne sposobnosti povezanih lica, a 62,5% ispitanika navelo je da se vrši procjena kreditne sposobnosti cijelog portfolia i da se mjere posebne rezerve. U komercijalnim bankama u BiH vrši se i procjena kreditne sposobnosti sektora / djelatnosti i mjeri se prosječna visina kredita, a 37,5% ispitanika navelo je da se to radi u bankama u kojima su zaposleni. Najmanji broj ispitanika (6,3%) naveo je da se vrši procjena kreditne sposobnosti geografskog položaja.

Pitanje 5: Smatrate li da je važeća zakonska regulativa u domenu upravljanja kreditnim rizikom, uključujući upravljanje nekvalitetnim kreditima, dobra?

Grafikon 43: Rezultati ankete – zakonska regulativa u domenu upravljanja kreditnim rizikom

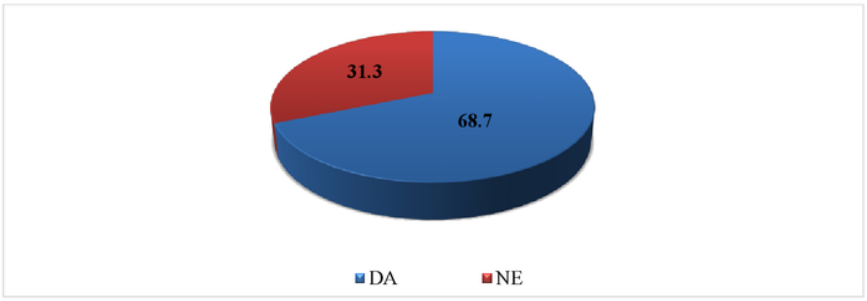


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Rezultati pokazuju da je 57,1% menadžera, rukovodioca i zaposlenih u komercijalnim bankama u BiH zadovoljno važećom zakonskom regulativom koja se odnosi na upravljanje kreditnim rizikom, a samim tim i nekvalitetnim kreditima, dok 42,9% nije zadovoljno važećim propisima.

Pitanje 6: Imajući u vidu problematiku nekvalitetnih kredita komercijalnih banaka u Bosni i Hercegovini, da li smatrate da je potrebno, u cilju unapređenja upravljanja kreditnim rizikom, modifikovati i preciznije definisati pravila i kriterijume za klasifikaciju dužnika i stopu izdvajanja obaveznih rezervi?

Grafikon 44: Rezultati ankete – unapređenje upravljanja kreditnim rizikom

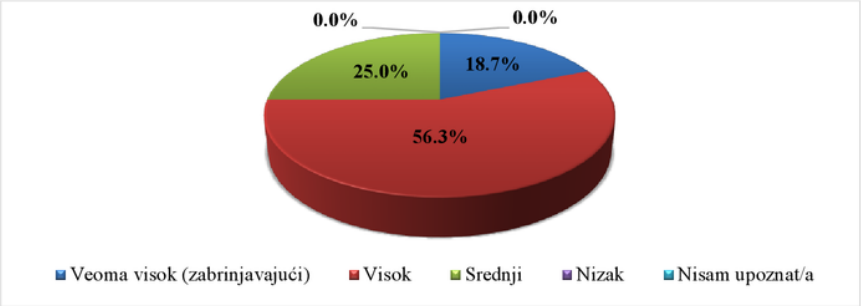


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Rezultati anketiranja pokazuju da 68,7% ispitanika smatra da je potrebno modifikovati i preciznije definisati pravila i kriterijume za klasifikaciju dužnika i stopu izdvajanja obaveznih rezervi, a sve to sa ciljem unapređenja upravljanja kreditnim rizikom i nekvalietnim kreditima. Ostali ispitanici, odnosno njih 31,3% smatra da nije potrebno mijenjati postojeća pravila i kriterijume.

Pitanje 7: Nivo nekvalitetnih kredita u bankarskom sektoru Bosne i Hercegovine je:

Grafikon 45: Rezultati ankete – nivo nekvalitetnih kredita u bankarskom sektoru BiH

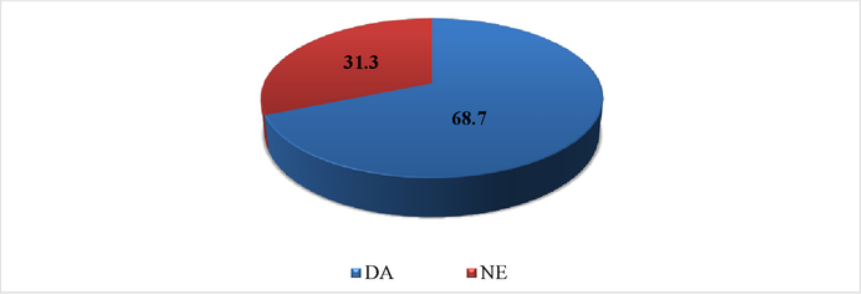


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Ispitanici su trebali da navedu kakav je, po njihovom mišljenju, nivo nekvalitetnih kredita u bankarskom sektoru BiH. Prilikom određivanja nivoa nekvalitetnih kredita mogli su da izaberu jedan od ponuđenih odgovora i to: veoma visok (zabrinjavajući), visok, srednji, nizak ili da navedu da nisu upoznati sa nivoom nekvalitetnih kredita u bankarskom sektoru BiH. Rezultati pokazuju da 18,7% ispitanika smatra da je nivo nekvalitetnih kredita veoma visok, 56,3% ispitanika smatra da je visok, a 25,0% smatra da je nivo nekvalitetnih kredita srednji, odnosno da nije ni visok, a ni nizak. Takođe, rezultati pokazuju da su svi anketirani upoznati sa nivoom nekvalitetnih kredita u bankarskom sektoru BiH.

Pitanje 8: Smatrate li da nivo i trendovi kretanja nekvalitetnih kredita mogu ugroziti stabilnost finansijskog sistema Bosne i Hercegovine u kratkom roku?

Grafikon 46: Rezultati ankete – narušavanje stabilnosti finansijskog sistema BiH



Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Rezultati pokazuju da 68,7% ispitanika smatra da nivo i trendovi kretanja nekvalitetnih kredita mogu da ugroze stabilnost bankarskog sistema u kratkom roku, dok 31,3% ispitanika smatra da ovo ipak nije moguće.

Pitanje 9: Koji su osnovni kriterijumi koji opredjeljuju nadležne organe banke u kojoj radite da određeni plasman klasifikuju kao rani rizični plasman, nekvalitetni plasman srednjeg ranga rizičnosti i nekvalitetni plasman visokog nivoa rizika?

Tabela 59: Rezultati ankete – faktori koji utiču na nekvalitetne kredite

R.B.	FAKTOR	VISOK UTICAJ	SREDNJI UTICAJ	NIZAK UTICAJ	NEMA UTICAJ
1.	Nivo i kretanje BDP-a	56,3%	31,2%	12,5%	0,0%
2.	Nezaposlenost	68,8%	18,7%	12,5%	0,0%
3.	Inflacija	43,8%	31,2%	25,0%	0,0%
4.	Javni dug	50,0%	25,0%	25,0%	0,0%
5.	Odnos kredita i depozita banaka	43,8%	18,8%	37,4%	0,0%
6.	Adekvatnost kapitala banaka	43,8%	32,2%	25,0%	0,0%
7.	Profitabilnost banaka	50,0%	43,8%	6,2%	0,0%
8.	Nivo kamatnih stopa	62,5%	25,0%	12,5%	0,0%
9.	Moralni hazard	50,0%	32,2%	18,8%	0,0%

Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Deveto pitanje u anketnom upitniku odnosilo se na faktore koji utiču na nekvalitetne kredite u bankarskom sektoru BiH. U istraživanje su uključeni i makroekonomski i specifični bankarski faktori, a ispitanici su trebale da odrede da li, i u kojoj mjeri navedeni faktori utiču na nekvalitetne kredite. Svi ispitanici smatraju da navedeni faktori imaju uticaj na nekvalitetne kredite. Više od polovine ispitanika (56,3%) smatra da nivo i kretanje bruto domaćeg proizvoda ima visok uticaj, 31,2% ispitanika smatra da je uticaj srednji, dok 12,5% misli da je uticaj ipak nizak. Veliki broj ispitanika (68,8%) smatra da nezaposlenost ima visok uticaj na nekvalitetne kredite, ali i inflacija (43,8% ispitanika). Polovina ispitanika (50,0%) smatra da javni dug države ima visok uticaj na nekvalitetne kredite, a po 25,0% ispitanika misli da je ovaj uticaj srednji, odnosno nizak. Ispitanici smatraju da adekvatnost kapitala ima visok (43,8% ispitanika), srednji (32,2% ispitanika) ili nizak (25,0%) uticaj na nekvalitetne kredite, a uticaj ima i profitabilnost banaka (50,0% ispitanika smatra da je ovaj uticaj visok, 43,8% smatra da je uticaj srednji i 6,2% smatra da je riječ o niskom uticaju). Rukovodioci, menadžeri i zaposleni u komercijalnim bankama s[118]raju da nivo kamatnih stopa ima visok uticaj na nekvalitetne kredite (62,5% isptanika), a ima i onih koji smatraju da je ovaj uticaj srednji (25,0% ispitanika) ili nizak (12,5% ispitanika). I posljednji faktor koji je bio uključen u istraživanje spada u grupu specifičnih bankarskih faktora, a odnosi se na hazardno ponašanje prilikom plasiranja kredita. Polovina ispitanika (50,0%) smatra da hazardno ponašanje ima visok uticaj na nekvalitetne kredite, nešto manje ispitanika (32,2%) smatra da je uticaj srednji, a najmanji broj je onih koji smatraju da je riječ o niskom uticaju na nekvalitetne kredite (18,8% ispitanika).

Pitanje 10: Da li je u banci u kojoj radite izvršena podjela rizičnih plasmana na: rani rizični plasmani, nekvalitetni plasmani srednjeg ranga rizičnosti i nekvalitetni plasmani visokog nivoa rizika?

Interesantno je da su na ovo pitanje svi ispitanici odgovorili potvrdno, odnosno da je u komercijalnim bankama u kojima su zaposleni izvršena podjela rizičnih plasmana.

Pitanje 11: Koji je osnovni kriterijum koji opredjeljuje nadležne organe banke u kojoj radite da određeni plasman klasifikuju kao rani rizični plasman, nekvalitetni plasman srednjeg ranga rizičnosti i nekvalitetni plasman visokog nivoa rizika?

Grafikon 47: Rezultati ankete – kriterijumi za klasifikaciju nekvalitetnih plasmana



Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Kao osnovni kriterijum koji opredjeljuje nadležne organe komercijalnih banaka da određeni plasman klasifikuju kao rani rizični, odnosno nekvalitetni plasman srednjeg ili visokog nivoa rizika, ispitanici navode broj dana kašnjenja (81,3% ispitanika), a kao drugi kriterijum navode identifikovano pogoršanje određenih finansijskih pokazatelja (18,7%). Nijedan ispitanik nije naveo da je nepoštovanje kovenanta, odnosno ugovornih ograničenja nametnutih od srane banke sa ciljem smanjenja rizika neizmirenja obaveza.

Pitanje 12: Izvještaji o kreditnom riziku, a samim tim i o nivou nekvalitetnih kredita u kreditnom portfoliu banke u kojoj radite je na:

Grafikon 48:Rezultati ankete – objavljivanje izvještaja o kreditnom riziku

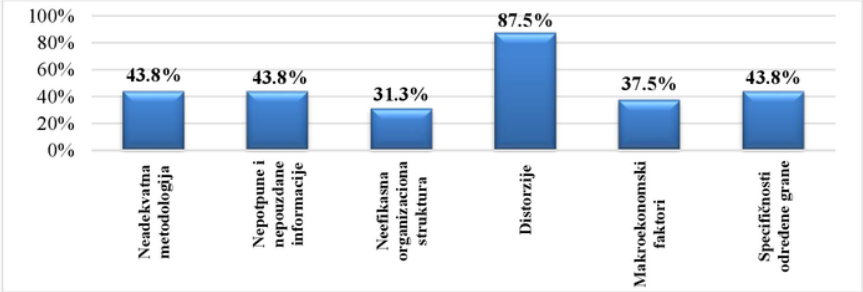


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Rezultati pokazuju da se izvještaji o kreditnom riziku i nekvalitetnim kreditima u kreditnom portfoliu izrađuju u svim komercijalnim banakama u BiH. Ovi izvještaji se uglavnom rade na mjesečnom nivou (81,3% ispitanika), sedmičnom nivou (12,5% ispitanika) ili na kvartalnom nivou (6,2% ispitanika).

Pitanje 13: Odaberite ključne uzroke nastanka nekvalitetnih kredita, odnosno uzroke migracije kreditnih plasmana u nekvalitetne kreditne plasmane.

Grafikon 49: Rezultati ankete – ključni uzroci nastanka nekvalitetnih kredita

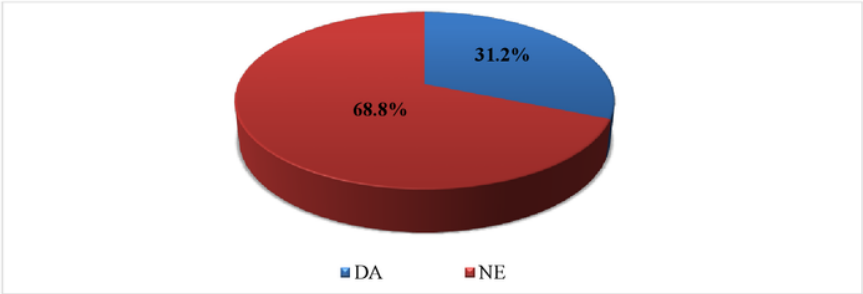


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Na grafikonu su prikazani faktori koji su, prema mišljenju anketiranih, ključni uzroci nastanka nekvalitetnih kredita. Pri tom, anketirani su mogli da izaberu više faktora, a ne samo da se opredjele za jedan, koji je po njima ključni. Većina ispitanika (87,5%) smatra da su distorzije u kreditnom procesu, odnosno odobravanje plasmana pod uticajem određenih interesnih grupa i odobravanje plasmana veoma visokog stepena rizika, ključni uzroci nastanka nekvalitetnih kredita. Takođe, veći broj ispitanika (43,8%) smatra da su neadekvatna metodologija za procjenu kreditnog rizika, nepotpune i nepouzdane kreditne informacije i specifičnosti određene privredne ili industrijske grane, faktori koji utiču na nekvalitetne kredite. Ispitanici smatraju da na nekvalitetne kredite, pored navedenih, utiču i makroekonomski faktori (37,5% ispitanika) i neefikasna organizaciona struktura (31,3% ispitanika).

Pitanje 14: Smatrate li da je dosadašnji proces sanacije rizičnih plasmana u Bosni i Hercegovini, preko različitih modaliteta (npr. restrukturiranje kredita), uspješan?

Grafikon 50: Rezultati ankete – uspješnost procesa sanacije rizičnih plasmana u BiH

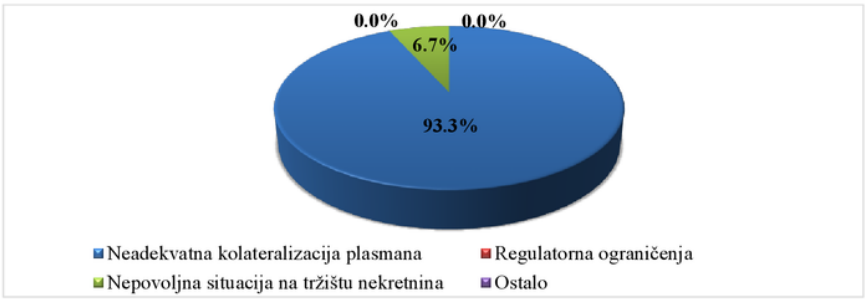


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Iako je u BiH počeo proces sanacije rizičnih plasmana preko različitih modaliteta, 68,8% ispitanika smatra da taj proces još uvijek nije uspješan, dok 31,2% ispitanika smatra da je riječ o uspješnom procesu.

Pitanje 15: Koji je, po Vama, najznačajniji razlog koji utiče na efikasnost rješavanja problema nekvalitetnih kredita?

Grafikon 51: Rezultati ankete – efikasnost rješavanja problema nekvalitetnih kredita

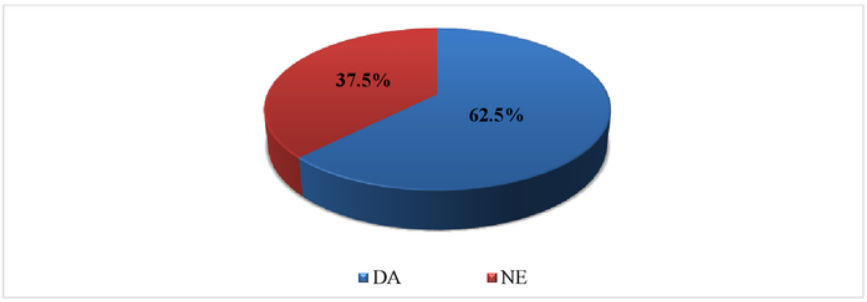


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Prema mišljenju 93,3% anketiranih, neadekvatna kolateralizacija plasmana i nemogućnost naplate iz sekundarnih izvora su najznačajniji razlozi koji utiču na efikasnost rješavanja problema nekvalitetnih kredita. Kao još jedan razlog koji utiče na efikasnost ovog problema, anketirani (9,7%) su naveli nepovoljnu situaciju na tržištu nekretnina u BiH, koja se odnosi na nemogućnost naplate hipotekarnih kredita. Prema mišljenju anketiranih, regulatorna ograničenja nemaju nikakav uticaj na efikasnost rješavanja problema nekvalitetnih kredita.

Pitanje 16: Da li je, u banci u kojoj radite, planirano da se u narednom periodu promijeni i unaprijedi proces upravljanja kreditnim rizikom?

Grafikon 52: Rezultati ankete – promjena procesa upravljanja kreditnim rizikom

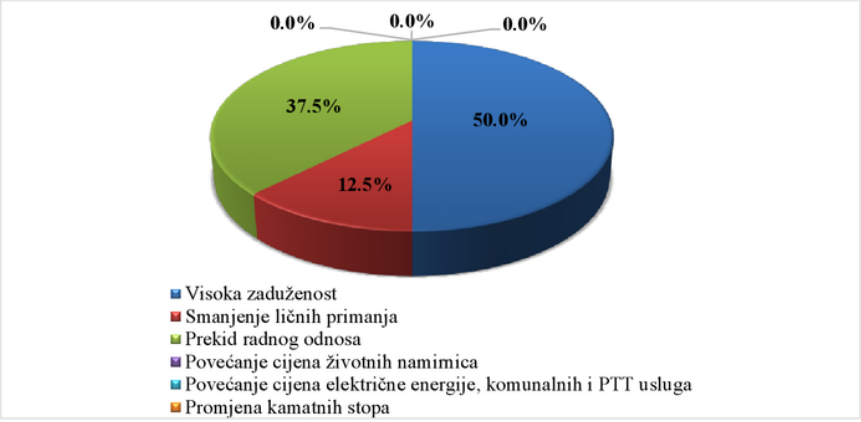


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

S obzirom na činjenicu da je 93,3% ispitanika navelo da se u komercijalnim bankama u kojima su zaposleni upravlja kreditnim rizikom, postavilo se sasvim logično pitanje koje se odnosi na unapređenje procesa upravljanja kreditnim rizikom u narednom periodu. Više od polovine ispitanika (62,5%) navelo je da je, u narednom periodu, planirano da se izmijeni i unaprijedi proces upravljanja kreditnim rizikom. Sa druge strane, 37,5% ispitanika navelo je da se neće mijenjati proces upravljanja kreditnim rizikom u komercijalnim bankama u kojima su zaposleni.

Pitanje 17: Posmatrajući samo plasmane fizičkim licima, odredite koji je osnovni faktor koji utiče na pojavu nekvalitetnih kredita.

Grafikon 53: Rezultati ankete – faktori koji utiču na kvalitet plasmana fizičkim licima

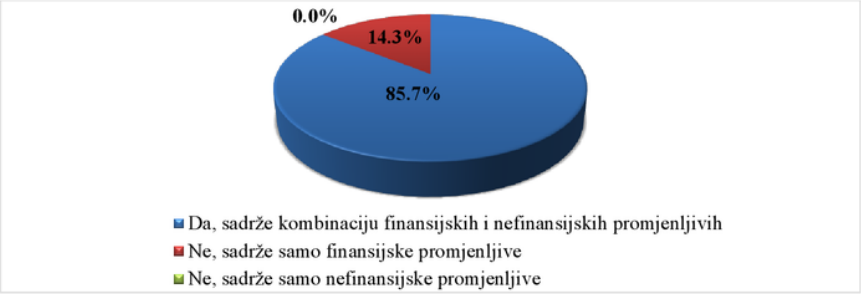


Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Ovo pitanje odnosilo se isključivo na plasmane fizičkim licima, odnosno na faktore koji utiču na kvalitet tih plasmana. Tom prilikom, anketirani su mogli da izaberu samo jedan od ukupno šest faktora za koji smatraju da u najvećoj mjeri utiče na pojavu i rast nekvalitetnih kredita kod fizičkih lica. Polovina ispitanika (50,0%) smatra da je visoka zaduženost fizičkih lica osnovni uzrok nastanka nekvalitetnih kredita, njih 37,5% misli da na pojavu nekvalitetnih kredita utiče prekid radnog odnosa fizičkog lica (odnosno nezaposlenost), a 12,5% smatra da ipak smanjenje ličnih primanja fizičkog lica uzrokuje nekvalitetne kredite. Interesanstno je da ispitanici nisu naveli da su povećanje cijena osnovnih životnih namirnica, povećanje cijena električne energije, komunalnih i PTT usluga i promjena kamatnih stopa osnovni faktori koji utiču na pojavu nekvalitetnih kredita kod fizičkih lica. Vjerovatno bi i ovi faktori bili uključeni da su anketirani mogli da navedu više faktora koji utiču na pojavu nekvalitetnih kredita, umjesto što su se morali opredjeliti za samo jedan od navedenih faktora.

Pitanje 18: Posmatrajući samo plasmane pravnim licima, navedite da li modeli kreditnog rejtinga sadrže kombinaciju finansijskih i nefinansijskih promjenljivih.

Grafikon 54: Rezultati ankete – modeli kreditnog rejtinga



Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Za razliku od prethodnog pitanja koje se odnosilo samo na plasmane fizičkim licima, ovo pitanje se odnosi isključivo na plasmane pravnim licima. Anketirani su trebali da navedu da li model kreditnog rejtinga sadrži samo finansijske promjenljive, samo nefinansijske promjenljive ili njihovu kombinaciju. Većina ispitanika (84,7%) je navela da model kreditnog rejtinga sadrži kombinaciju finansijskih i nefinansijskih promjenljivih, dok je 14,3% ispitanika navelo da modeli kreditnog rejtinga u komercijalnim bankama u kojima su zaposleni sadrže samo finansijske promjenljive.

Pitanje 19: Ocijenite značaj finansijskih promjenljivih za procjenu kreditnog rizika privrednog subjekta.

Tabela 62: Rezultati ankete – značaj finansijskih promjenljivih za procjenu kreditnog rizika

R.B.	PROMJENLJIVA	Nije značajna	Nizak nivo značaja	Srednji nivo značaja	Visok nivo značaja	Veoma visok nivo značaja
1.	Racio tekuće likvidnosti	6,2%	6,2%	43,8%	12,5%	25,0%
2.	Tokovi gotovine iz poslovnih aktivnosti / kratkoročne finansijske obaveze	0,0%	6,2%	37,5%	25,0%	18,8%
3.	Tokovi gotovine iz poslovnih aktivnosti / ukupna aktiva	0,0%	18,8%	25,0%	18,8%	25,0%
4.	EBITDA / tokovi gotovine iz poslovnih aktivnosti	0,0%	12,5%	25,0%	18,8%	25,0%
5.	Kratkoročne obaveze / obrtna imovina	0,0%	12,5%	31,2%	6,2%	31,2%
6.	Neto obrtni kapital / ukupna aktiva	0,0%	25,0%	31,2%	31,2%	6,25%
7.	Ukupan dug / EBITDA	0,0%	0,0%	43,8%	6,2%	25,0%
8.	Dugoročne obaveze / EBITDA	0,0%	12,5%	37,5%	6,2%	25,0%
9.	Ukupne obaveze / ukupna aktiva	6,2%	18,8%	31,2%	12,5%	25,0%
10.	Racio pokrića kamata	0,0%	18,8%	37,5%	18,8%	6,2%
11.	Kapital / osnovna sredstva	6,2%	18,8%	31,2%	12,5%	12,5%

Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Rukovodioci, menadžeri i zaposleni u komercijalnim bankama u BiH trebali su da ocijene značaj finansijskih promjenljivih koje se koriste prilikom procjene kreditnog rizika kod privrednih subjekata. Analizirano je ukupno jedanaest finansijskih promjenljivih, a ispitanici smatraju da su navedene promjenljive značajne za ocjenu kreditnog rizika, samo se nivo značajnosti razlikuje. Rezultati pokazuju da navedene promjenljive uglavnom imaju srednji nivo značaja za ocjenu kreditnog rizika privrednih subjekata, što vodi do zaključka da je, prilikom ocjene kreditnog rizika, potrebno uključiti više promjenljivih, a ne donijeti odluku na osnovu samo jedne od njih.

Pitanje 20: Ocijenite značaj nefinansijskih promjenljivih za procjenu kreditnog rizika privrednog subjekta.

Tabela 63: Rezultati ankete – značaj nefinansijskih promjenljivih za procjenu kreditnog rizika

R.B.	PROMJENLJIVA	Nije značajna	Nizak nivo značaja	Srednji nivo značaja	Visok nivo značaja	Veoma visok nivo značaja
1.	Starost preduzeća	12,5%	12,5%	25,0%	31,2%	6,2%
2.	Veličina (posmatrana preko ukupne aktive)	0,0%	12,5%	31,2%	31,2%	12,5%
3.	Veličina (posmatrana preko broja zaposlenih)	12,5%	18,8%	43,8%	0,0%	6,2%
4.	Veličina (posmatrana preko ukupnih prihoda)	12,5%	25,0%	37,5%	18,8%	0,0%
5.	Vrsta djelatnosti	0,0%	18,8%	31,2%	25,0%	6,2%

Izvor: Izrada autora na osnovu odgovora iz anketnog upitnika

Ovo pitanje odnosilo se na nefinansijske promjenljive koje se koriste prilikom procjene kreditnog rizika privrednih subjekata, a uključeno je ukupno pet promjenljivih. Nefinansijske promjenljive koje je potrebno analizirati prilikom procjene kreditnog rizika odnose se na starost preduzeća, veličinu preduzeća mjerenu preko ukupne aktive, broja zaposlenih i ukupnih prihoda, i vrsta djelatnosti kojom se preduzeće bavi. Manji dio ispitanika (12,5%) smatra da nefinansijske promjenljive koje pokazuju starost preduzeća i veličinu mjerenu preko broja zaposlenih i ukupnih prihoda nisu značajne prilikom ocjene kreditnog rizika privrednih subjekata. Ipak, 31,2% ispitanika smatra da starost preduzeća ima visok nivo značaja, 43,8% ispitanika smatra da veličina preduzeća, posmatrana preko broja zaposlenih, ima srednji nivo značaja, a 37,5% ispitanika smatra da veličina preduzeća, mjerena preko ukupnih prihoda, takođe ima srednji značaj prilikom procjene kreditnog rizika.

Rezultati ankete pokazuju da se u komercijalnim bankama u BiH upravlja kreditnim rizikom, a samim tim i nekvalitetnim kreditima. To je veoma važno za stailnost bankarskog sektora, a samim tim i cjelokupnog finansijskog sistema BiH. Takođe, rezultati pokazuju da zaposleni u komercijalnim bankama u BiH uspijevaju da identifikuju faktore koji utiču na nekvalitetne kredite u kreditnom portfoliu banaka. To svakako pomaže rukovodiocima i menadžerima prilikom odabira mjera za procjenu kreditnog rizika, ali i prilikom odabira adekvatnih mjera za upravljanje kreditnim rizikom.

3. DISKUSIJA

U prethodnom poglavlju prikazani su rezultati istraživanja koje je sprovedeno sa ciljem identifikacije makroekonomskih i sprecifičnih bankarskih faktora koji utiču na nekvalitetne kredite u bankarskom sektoru BiH. Takođe, cilj istraživanja je i identifikacija makroekonomskih i specifičnih bankarskih faktora pomoću kojih se može predvidjeti kretanje nekvalitetnih kredita u narednom periodu. Istraživanje je bilo podijeljeno na dva dijela. Prvi dio istraživanja sproveden je pomoću analize korelacije i regresije, a rezultati su pokazali koji od analiziranih faktora i na koji način utiču na nekvalitetne kredite bankarskog sektora BiH. Slično istraživanje sprovedeno je u većem broju studija koje se bave ovom problematikom, tako da će rezultati koji su dobijeni u ovom istraživanju biti upoređeni sa rezultatima iz empirijske literature. Drugi dio istraživanja sproveden je pomoću anketnog upitnika, a rezultati anketiranja pokazali su način na koji se upravlja kreditnim rizikom u komercijalnim bankama u BiH. Ispitanici su takođe naveli faktore koji utiču na nekvalitetne kredite u komercijalnim bankama u kojima su zaposleni.

U nastavku je dato objašnjenje rezultata svake analizirane promjenljive, uključujući i njen uticaj na nekvalitetne kredite bankarskog sektora BiH. Rezultati istraživanja su upoređeni sa rezultatima koji su dobijeni u sličnim istraživanjima koja su sprovedena u jednoj ili više zemalja, a koji su dostupni u empirijskoj literaturi.

3.1. Makroekonomski faktori koji utiču na nekvalitetne kredite

Na početku istraživanja pretpostavilo se da tri makroekonomske promjenljive imaju statistički značajan uticaj na nekvalitetne kredite bankarskog sektora BiH. Ipak, rezultati su pokazali da uticaj dvije makroekonomske promjenljive (stopa rasta realnog BDP-a i stopa nezaposlenosti) nije statistički značajan, dok jedna promjenljiva (stopa inflacije, mjerena stopom rasta potrošačkih cijena) ima statistički značajan uticaj na nekvalitetne kredite. Obrazloženje dobijenih rezultata za sve makroekonomske promjenljive koje su uključene u analizu dato je u nastavku. Takođe, dobijeni rezultati su upoređeni sa rezultatima koji su dobijeni u sličnim istraživanjima, a koji se nalaze u dostupnoj literaturi.

Stopa rasta realnog BDP-a ima negativan odnos sa nekvalitetnim kreditima i to pokazuje koeficijent linearne korelacije, a dobijeni rezultat je u skladu sa očekivanim. Negativan odnos između stope rasta realnog BDP-a i nekvalitetnih kredita podrazumijeva da će, u slučaju ekonomskog rasta, doći do smanjenja nekvalitetnih kredita, i obrnuto, u slučaju smanjenja privrednih aktivnosti, nekvalitetni krediti će se povećati. Međutim, nakon testiranja značajnosti dobijene ocjene, utvrđeno je da uticaj stope rasta realnog BDP-a nema statistički značajan uticaj na nekvalitetne kredite (dobijena *p vrijednost* je veća od postavljene granice značajnosti od 0,05). Takođe, regresiona analiza je pokazala da se stopa rasta realnog BDP-a ne može koristiti za opsivanje kretanja nekvalitetnih kredita bankarskog sektoru u narednom periodu. Drugim riječima, potencijalna vrijednost stope rasta realnog BDP-a ne može se koristiti za određivanje vrijednosti nekvalitetnih kredita.

Ovaj rezultat je u skladu sa rezultatima do kojih su došli Swami (2012), Tomak (2013) i Pradhan i Pandey (2016) analizirajući faktore koji utiču na nekvalitetne kredite u pojedinačnim zemljama. Ipak, većina sprovedenih istraživanja je pokazala da stopa rasta realnog BDP-a ima statistički značajan uticaj na nekvalitetne kredite, a on može biti pozitivan ili negativan.

Stopa nezaposlenosti ima negativan odnos sa nekvalitetnim kreditima, a to potvrđuje dobijeni koeficijent linearne korelacije. Međutim, dobijeni rezultat nije u skladu sa očekivanim jer se na početku istraživanja pretpostavilo da stopa nezaposlenosti ima pozitivan odnos sa nekvalitetnim kreditima. Negativan odnos između navedenih promjenljivih podrazumijeva da bi povećanje stope nezaposlenosti moglo uticati na smanjenje nekvalitetnih kredita, odnosno da bi smanjenje stope nezaposlenosti moglo uticati na povećanje nekvalitetnih kredita u bankarskom sektoru. Ipak, testiranjem značajnosti dobijene ocjene utvrđeno je da uticaj stope nezaposlenosti na nekvalitetne kredite bankarskog sektora BiH nije statistički značajan. To potvrđuje dobijena *p vrijednost*, koja je veća od postavljene granice značajnosti ($p = 0,05$). Sprovedena regresiona analiza pokazala je da se stopa nezaposlenosti ne može koristiti prilikom objašnjavanja kretanja nekvalitetnih kredita u narednom periodu. Takođe, regresiona analiza pokazala je da nema smisla koristiti regresioni model za objašnjenje nekvalitetnih kredita pomoću stope nezaposlenosti.

Analizirajući faktore koji utiču na nekvalitetne kredite u pojedinačnim zemljama, Ahmad i Basir (2013) takođe su pokazali da stopa nezaposlenosti nema statistički značajan uticaj na nekvalitetne kredite, odnosno da promjena stope nezaposlenosti neće uticati na nekvalitetne kredite bankarskog sektora (Ahmad & Bashir (a), 2013).

Stopa inflacije, mjerena stopom rasta potrošačkih cijena, ima negativan odnos sa nekvalitetnim kreditima, a to pokazuje dobijeni koeficijent linearne korelacije. Dobijeni rezultat nije u skladu sa očekivanim, jer se na početku istraživanja pretpostavilo da je odnos stope inflacije i nekvalitetnih kredita pozitivan. Negativna veza između navedenih promjenljivih podrazumijeva da bi se nekvalitetni krediti mogli smanjiti u ekonomskoj situaciji u kojoj nivo ukupnih cijena raste. Nakon testiranja značajnosti dobijene ocjene, utvrđeno je da je uticaj stope rasta potrošačkih cijena na nekvalitetne kredite bankarskog sektora BiH statistički značajan. To potvrđuje dobijena *p vrijednost* koja je manja od postavljene granice značajnosti ($p = 0,05$). Regresiona analiza pokazala je da je stopa rasta potrošačkih cijena relevantna za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora u narednom periodu. Višestruka regresiona analiza, odnosno korigovani koeficijent determinacije, pokazao je da se 18,7% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope rasta potrošačkih cijena. Regresiona analiza potvrdila je da će povećanje stope rasta potrošačkih cijena pozitivno uticati na kvalitet kreditnog portfolia, jer će se, u tom slučaju, nekvalitetni krediti smanjiti. Sa druge strane, ukoliko se stopa rasta potrošačkih cijena smanji, nekvalitetni krediti će se povećati, a to će se negativno odraziti na kvalitet kreditnog portfolia bankarskog sektora BiH.

Dobijeni rezultat je u skladu sa rezultatima do kojih su došli Khemraj i Pasha (2009), Ahmad i Bashir (2013), Badar i Javid (2013), Turan i Koskija (2014) i Pradhan i Pandey (2016) analizirajući faktore koji utiču na nekvalitetne kredite bankarskih sektora u pojedinačnim zemljama.

Na osnovu navedenog, može se zaključiti da samo stopa inflacije, mjerena stopom rasta potrošačkih cijena, ima statistički značajan i negativan odnos sa nekvalitetnim kreditima. Takođe, može se zaključiti da nema smisla koristiti regresioni model za objašnjenje nekvalitetnih kredita bankarskog sektora pomoću stope rasta realnog BDP-a i stope nezaposlenosti.

3.2. Specifični bankarski faktori koji utiču na nekvalitetne kredite

Na početku istraživanja pretpostavljeno je da šest specifičnih bankarskih promjenljivih, koje su uključene u istraživanje, ima statistički značajan uticaj na nekvalitetne kredite. Međutim, rezultati istraživanja su pokazali da tri specifične bankarske promjenljive (prinos na aktivu, aktivna kamatna stopa i stopa kreditnog rasta) imaju statistički značajan uticaj na nekvalitetne kredite, dok uticaj tri specifične bankarske promjenljive (koeficijent adekvatnosti kapitala, odnos kredita i depozita i prinos na akcijski kapital) na nekvalitetne kredite nije statistički značajan. Objašnjenje dobijenih rezultata istraživanja dato je u nastavku. Takođe, dobijeni rezultati su upoređeni sa odgovarajućim rezultatima sprovedenih istraživanja koja su dostupna u literaturi. Važno je naglasiti da su prilikom istraživanja korišteni agregatni podaci na nivou bankarskog sektora jer pojedinačni podaci nisu dostupni.

Koeficijent adekvatnosti kapitala ima negativan odnos sa nekvalitetnim kreditima, a to potvrđuje koeficijent linearne korelacije. Ovaj rezultat je u skladu sa očekivanim. Negativan odnos između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita podrazumijeva da banke koje imaju nizak koeficijent adekvatnosti kapitala povećavaju rizičnost kreditnog portfolia, tako da se udio nekvalitetnih u ukupnim kreditima povećava. Iako je koeficijent korelacije ukazao na negativnu povezanost između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita, nakon testiranja značajnosti dobijenog rezultata, utvrđeno je da koeficijent adekvatnosti kapitala nema statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru BiH. To pokazuje dobijena *p vrijednost* koja je mnogo veća od postavljene granice značajnosti ($p = 0,05$). U skladu sa tim, može se zaključiti da promjena koeficijenta adekvatnosti kapitala neće uticati na nekvalitetne kredite u bankarskom sektoru BiH. Nakon sprovedene regresione analize zaključeno je da nema smisla koristiti regresioni model za objašnjenje nekvalitetnih kredita pomoću koeficijenta adekvatnosti kapitala.

Sličan rezultat istraživanja nije pronađen u dostupnoj literaturi jer je u većini sprovedenih studija koeficijent adekvatnosi kapitala imao statistički značajan uticaj na nekvalitetne kredite.

Odnos kredita i depozita ima negativan odnos sa nekvalitetnim kreditima, a to pokazuje koeficijent linearne korelacije. Međutim, dobijeni rezultat nije u skladu sa očekivanim, jer se na početku istraživanja pretpostavilo da postoji pozitivan odnos između ove dvije promjenljive. S obzirom na činjenicu da je odnos kredita i depozita jedan od pokazatelja likvidnosti, njegov negativni odnos sa nekvalitetnim kreditima podrazumijeva da će se likvidnije banke suočiti sa više nekvalitetnih kredita u svom portfoliu. Dalja analiza pokazala je da je uticaj odnosa kredita i depozita nema statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru BiH. To pokazuje dobijena *p vrijednost* koja je veća od postavljene granice značajnosti ($p = 0,05$). Nakon sprovedene korelacione i regresione analize, može se zaključiti da se odnos kredita i depozita ne može koristiti za objašnjenje ponašanja nekvalitetnih kredita, niti se proizvoljna vrijednost ovog pokazatelja likvidnosti može koristiti za određivanje vrijednosti nekvalitetnih kredita u narednom periodu.

Iako rezultat većine studija koje su sprovedene pokazuje da odnos kredita i depozita ima statistički značajan uticaj na nekvalitetne kredite, Makri, Tsagkanos i Bellas (2014) su, analizirajući faktore koji utiču na nekvalitetne kredite u više zemalja, pokazali da odnos kredita i depozita nema statistički značajan uticaj na nekvalitetne kredite (Makri, Tsagkanos, & Bellas, 2014).

Prinos na aktivu ima pozitivan odnos sa nekvalitetnim kreditima, a to potvrđuje dobijeni koeficijent linearne korelacije. Dobijeni rezultat nije u skladu sa očekivanim, jer se na početku istraživanja pretpostavilo da postoji negativan odnos između prinosa na aktivu i nekvalitetnih kredita. Pozitivan odnos između analiziranih promjenljivih ukazuje na činjenicu da banke koje ostvaruju veći prinos na aktivu imaju više nekvalitetnih kredita u svom portfoliu. Drugim riječima, banke koje ostvaruju veću profitabilnost mjerenu prinosom na aktivu više su sklone riziku, što se negativno odražava na kvalitet kreditnog portfolia, odnosno na kvalitet cijelokupne aktive. Nakon testiranja značajnosti dobijene ocjene, pomoću *p vrijednosti* utvrđeno je da je odnos prinosa na aktivu i nekvalitetnih kredita bankarskog sektora statistički značajan jer je dobijena *p vrijednost* manja od postavljene granice značajnosti (p = 0,05). Regresiona analiza pokazala je da je prinos na aktivu relevantan za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Korigovani koeficijent determinacije pokazao je da se 11,2% varijabiliteta nekvalitetnih kredita može objasniti pomoću prinosa na aktivu. Regresiona analiza potvrdila je da će povećanje prinosa na aktivu negativno uticati na kvalitet kreditnog portfolia, jer će se, u tom slučaju, nekvalitetni krediti povećati. Sa druge strane, ukoliko se prinos na aktivu smanji, smanjiće se i nekvalitetni krediti što će se pozitivno odraziti na kvalitet kreditnog portfolia bankarskog sektora BiH. Slobodno se može reći da je pozitivna veza prinosa na aktivu i nekvalitetnih kredita rezultat neefikasnog upravljanja imovinom banke.

Da prinos na aktivu ima pozitivan i statistički značajan uticaj na nekvalitetne kredite pokazali su i Swami (2012), Ahmad i Bashir (2013) i Pradhan i Pandey (2013).

Prinos na akcijski kapital ima pozitivan odnos sa nekvalitetnim kreditima i to pokazuje dobijeni koeficijent linearne korelacije. Ovaj rezultat nije u skladu sa očekivanim jer se na početku istraživanja pretpostavilo da između analiziranih promjenljivih postoji negativan odnos. Pozitivan odnos između pokazatelja profitabilnosti banke, mjerenog prinosom na akcijski kapital, i nekvalitetnih kredita podrazumijeva da će prilikom pogoršanja profitabilnosti banke doći do povećanja kvaliteta kreditnog portfolia, jer će se u tom slučaju smanjiti nekvalitetni krediti. Sa druge strane, ukoliko se poboljša profitabilnost banaka, nekvalitetni krediti će se povećati, tako da će se smanjiti kvalitet kreditnog portfolia i bankarske aktive. Dalja analiza pokazala je da uticaj prinosa na akcijski kapital nema statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru BiH. To pokazuje dobijena *p vrijednost* koja je veća od postavljene granice značajnosti (p = 0,05). Takođe, i regresiona analiza je pokazala da prinos na akcijski kapital nije relevantan za opisivanje ponašanja nekvalitetnih kredita u narednom periodu. Potrebno je naglasiti da promjenljiva koja pokazuje prinos na akcijski kapital bankarskog sektora nije bila uključena u višestruku regresionu analizu, zbog velike korelacije sa drugom promjenljivom koja takođe pokazuje profitabilnost bankarskog sektora, odnosno prinosom na aktivu. U skladu sa ovim, može se zaključiti da profitabilnost, mjerena prinosom na akcijski kapital, ne utiče na kvalitet kreditnog portfolia bankarskog sektora.

Sličan rezultat istraživanja nije pronađen u dostupnoj literaturi koja se bavi ovom problematikom, jer je u sprovedenim studijama prinos na akcijski kapital imao statistički značajan uticaj na nekvalitetne kredite.

Aktivna kamatna stopa ima negativan odnos sa nekvalitetnim kreditima i to pokazuje dobijeni koeficijent linearne korelacije. Dobijeni rezultat nije u skladu sa očekivanim jer se na početku istraživanja pretpostavilo suprotno. Negativan odnos navedenih promjenljivih podrazumijeva da će povećanje aktivne kamatne stope uticati na smanjenje nekvalitetnih kredita. To se može objasniti činjenicom da se istovremeno sa povećanjem aktivne kamatne stope smanjuje sposobnost klijenata da se zadužuju, tako da se smanjuje količina plasiranih sredstava. Čim se smanjuje broj kredita u bankarskom sektoru, može se očekivati da će se smanjiti i broj nekvalitetnih kredita. Testiranje značajnosti dobijene ocjene, odnosno dobijena *p vrijednost* koja je manja od postavljene granice značajnosti ($p = 0,05$), pokazala je da je odnos između ove dvije promjenljive statistički značajan. To je potvrđeno i u regresionoj analizi koja je pokazala da se na osnovu vrijednosti aktivne kamatne stope može predvidjeti vrijednost nekvalitetnih kredita bankarskog sektora u narednom periodu. Regresiona analiza je pokazala da se 9,7% varijabiliteta nekvalitetnih kredita može objasniti pomoću aktivne kamatne stope.

Dobijeni rezultat je potvrđen i u empirijskoj literaturi. Saba, Kouser i Azeem (2012), Ahmad i Bashir (2013), Otašević (2013) i Turan i Koskija (2014) su, analizirajući faktore koji utiču na nekvalitetne kredite u komercijalnim bankama pojedinačnih zemalja, pokazali da aktivna kamatna stopa ima negativan i statistički značajan odnos sa nekvalitetnim kreditima.

Stopa kreditnog rasta je posljednja specifična bankarska promjenljiva koja je uključena u istraživanje. Rezultati pokazuju da stopa kreditnog rasta ima negativan odnos sa nekvalitetnim kreditima, a to pokazuje dobijeni koeficijent linearne korelacije. Dobijeni rezultat nije u skladu sa očekivanim, jer se na početku istraživanja pretpostavilo da je odnos stope kreditnog rasta i nekvalitetnih kredita pozitivan. Negativna veza između navedenih promjenljivih podrazumijeva da bi se nekvalitetni krediti mogli smanjiti kada se količina plasiranih kredita bankarskog sektora poveća. Nakon testiranja značajnosti dobijene ocjene, utvrđeno je da je uticaj stope kreditnog rasta na nekvalitetne kredite statistički značajan. To potvrđuje dobijena *p vrijednost* koja je manja od postavljene granice značajnosti ($p = 0,05$). Rsprovedena regresiona analiza pokazala je da je stopa kreditnog rasta relevantna za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora, odnosno da se na osnovu potencijalne vrijednosti stope kreditnog rasta može predvidjeti vrijednost nekvalitetnih kredita u narednom periodu. Višestruka regresiona analiza, odnosno korigovani koeficijent determinacije, pokazao je da se 18,5% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope kreditnog rasta. Regresiona analiza potvrdila je da će povećanje stope kreditnog rasta pozitivno uticati na kvalitet kreditnog portfolia, jer će se nekvalitetni krediti smanjiti. Sa druge strane, ukoliko se stopa kreditnog rasta smanji, nekvalitetni krediti će se povećati i to će se negativno odraziti na kvalitet kreditnog portfolia bankarskog sektora BiH.

Dobijeni rezultat je potvrđen i u prethodno sprovedenim istraživanjima koja se bave problematikom nekvalitetnih kredita. Khemraj i Pasha (2009) i Ganić (2014) su, analizirajući nekvalitetne kredite u pojedinačnim zemljama, pokazali da stopa kreditnog rasta ima negativan i statistički značajan uticaj na nekvalitetne kredite. Takođe, do istog rezultata su došli i Espinoza i Prasad (2010), Boudriga, Taktak i Jellouli (2010) i Klein (2013) analizirajući faktore koji utiču na nekvalitetne kredite bankarskih sektora u više zemalja.

Na osnovu navedenog, može se zaključiti da tri specifične bankarske promjenljive imaju statistički značajan uticaj na nekvalitetne kredite bankarskog sektora BiH. Korelaciona i regresiona analiza su pokazale da se nekvalitetni krediti mogu objasniti pomoću prinosa na aktivu, aktivne kamatne stope i stope kreditnog rasta. Pri tom, prinos na aktivu ima pozitivan i statistički značajan odnos sa nekvalitetnim kreditima, a aktivna kamatna stopa i stopa kreditnog rasta imaju negativan i statistički značajan odnos sa nekvalitetnim kreditima. Na osnovu rezultata sprovedene regresione analize može se zaključiti da nema smisla koristiti regresioni model za objašnjenje nekvalitetnih kredita bankarskog sektora pomoću koeficijenta adekvatnosti kapitala, odnosa kredita i depozita i prinosa na akcijski kapital.

Na kraju se, na osnovu rezultata višestruke regresione analize, može zaključiti da se 54,3% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope rasta potrošačkih cijena, prinosa na aktivu, aktivne kamatne stope i stope kreditnog rasta jer je u istraživanju dokazano da ove promjenljive imaju statistički značajan uticaj na nekvalitetne kredite bankarskog sektora BiH.

Rezultati sprovedenog istraživanja upoređeni su sa rezultatima koji su dostupni u empirijskoj literaturi, a sumirani su u tabeli 64.

Tabela 64: Pregled analiziranih promjenljivih i dobijenih rezultata istraživanja

Faktor	Očekivani uticaj	Rezultat istraživanja	Statistički značaj	Isti rezultat
Stopa rasta realnog BDP-a	-	-	NE	Swami (2012) Tomak (2013) Pradhan i Pandey (2016)
Stopa nezaposlenosti	+	-	NE	Ahmad i Bashir (2013)
Stopa rasta potrošačkih cijena	+	-	DA	Khemraj i Pasha (2009) Ahmad i Bashir (2013) Badar i Javid (2013) Turan i Koskija (2014) Pradhan i Pandey (2016)
Koeficijent adekvatnosti kapitala	-	-	NE	-
Odnos kredita i depozita	+	-	NE	Makri, Tsagkanos i Bellas (2014)
Prinos na aktivu	-	+	DA	Swami (2012) Ahmad i Bashir (2013) Pradhan i Pandey (2016)
Prinos na akcijski kapital	-	+	NE	-
Aktivna kamatna stopa	+	-	DA	Saba, Kouser i Azeem (2012) Ahmad i Bashir (2013) Otašević (2013) Turan i Koskija (2014)
Stopa kreditnog rasta	+	-	DA	Khemraj i Pasha (2009) Espinoza i Prasad (2010) Boudriga, Taktak i Jellouli (2010) Klein (2013) Ganić (2014)

Izvor: Izrada autora

V DIO

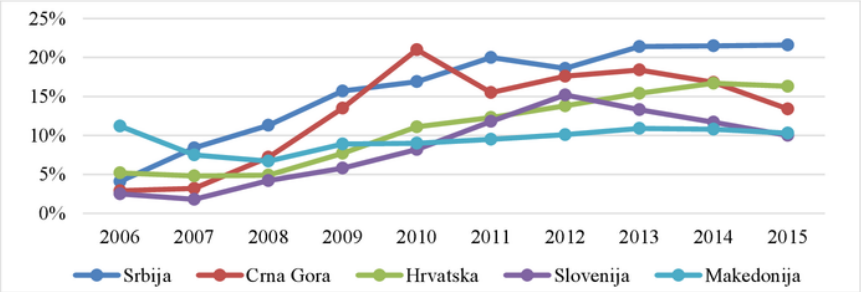
KOMPARATIVNA ANALIZA TRENDOVA KRETANJA NEKVALITETNIH KREDITA NA FINANSIJSKOM TRŽIŠTU BOSNE I HERCEGOVINE, ZEMALJA REGIONA I RAZVIJENIM FINANSIJSKIM TRŽIŠTIMA

1. NEKVALITETNI KREDITI NA FINANSIJSKIM TRŽIŠTIMA ZEMALJA REGIONA

Nekvalitetni krediti nisu problem samo u bankarskom sektoru BiH, oni su problem i u bankarskim sektorima zemalja regiona, pa čak i u razvijenim zemljama. To potvrđuje i Jeremić koji navodi da je osnivni problem bankarskih sektora u regionu „rast neneplativih kredita uz stagnaciju kreditne aktivnosti kako u korporativnom dijelu, tako i u kreditiranju stanovništva" (Jeremić, 2014, str. 47). Kvalitet kreditnog portfolia u većini bankarskih sektora zemalja regiona pogoršan je za vrijeme globalne finansijske krize. Slobodno se može reći da se ove zemlje još uvijek nisu u potpunosti oporavile od posljedica globalne finansijske krize, a to se vidi i po nekvalitetnim kreditima koji su još uvijek na visokom nivou.

Trend kretanja nekvalitetnih kredita u bankarskim sektorima Srbije, Crne Gore, Hrvatske, Slovenije i Makedonije predstavljen je na grafikonu 55.

Grafikon 55: Trend kretanja nekvalitetnih kredita u zemljama regiona (2006 – 2015)



Izvor: (Svjetska banka, 2017)

Predstavljeni podaci daju jasnu sliku o kretanju nekvalitetnih kredita u navedenim zemljama tokom analiziranog desetogodišnjeg perioda. Na osnovu navedenih podataka, zaključuje se da je nivo nekvalitetnih kredita, na kraju analiziranog perioda, bio značajno veći u odnosu na nivo koji je zabilježen na početku analiziranog perioda. Izuzetak je samo bankarski sektor Makedonije, u kome nisu zabilježene velike oscilacije u kretanju nivoa nekvalitetnih kredita koji su čak na kraju 2015. godine bili niži nego u 2006. godini. Najveći rast udjela nekvalitetnih u ukupnim kreditima zabilježen je u bankarskom sektoru Srbije, koji je na kraju 2015. godine imao i najveći nivo nekvalitetnih kredita u kreditnom portfoliu. Velike oscilacije nivoa nekvalitetnih kredita u analiziranom desetogodišnjem periodu zabilježene su u bankarskom sektoru Crne Gore, u kome su nekvalitetni krediti dostigli maksimalnu vrijednost od 21,0% na kraju 2010. godine, odnosno 6,5% više nego na kraju prethodne godine. U bankarskim sektorima Hrvatske i Slovenije zabilježen je postepeni rast nivoa nekvalitetnih kredita u analiziranom periodu.

U nastavku dat je tabelarni pregled udjela nekvalitetnih u ukupnim kreditima u bankarskim sektorima zemalja regiona, odnosno u Srbiji, Crnoj Gori, Hrvatskoj, Sloveniji i Makedoniji. Svi podaci preuzeti su od Svjetske banke.

Tabela 65: Nekvalitetni krediti u bankarskim sektorima zemalja regiona (2006 - 2015)

- % -

ZEMLJA	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
SRBIJA	4,1	8,4	11,3	15,7	16,9	20,0	18,6	21,4	21,5	21,6
CRNA GORA	2,9	3,2	7,2	13,5	21,0	15,5	17,6	18,4	16,8	13,4
HRVATSKA	5,2	4,8	4,9	7,7	11,1	12,3	13,8	15,4	16,7	16,3
SLOVENIJA	2,5	1,8	4,2	5,8	8,2	11,8	15,2	13,3	11,7	10,0
MAKEDONIJA	11,2	7,5	6,7	8,9	9,0	9,5	10,1	10,9	10,8	10,3

Izvor: (Svjetska banka, 2017)

U bankarskom sektoru Srbije zabilježen je kontinuiran rast nekvalitetnih kredita tokom analiziranog perioda, sa izuzetkom 2012. godine u kojoj je zabilježen pad. Na kraju 2006. godine udio nekvalitetnih u ukupnim kreditima iznosio je 4,1%, a pet godina kasnije, na kraju 2010. godine 16,9%, odnosno 12,8% više. Na kraju 2015. godine ovaj udio iznosio je 21,6%, što je za 4,7% više nego na kraju 2010., odnosno 17,5% više nego na kraju 2006. godine. Iako je nivo nekvalitetnih kredita značajno povećan, od 2013. godine zabilježen je blagi rast od 0,1% godišnje, tako da se u narednom periodu očekuje smanjenje nivoa nekvalitetnih kredita u bankarskom sektoru Srbije.

Najveće oscilacije u kretanju nivoa nekvalitetnih kredita zabilježene su u bankarskom sektoru Crne Gore, u kome je, na kraju 2006. godine, udio nekvalitetnih u ukupnim kreditima iznosio 2,9%. U narednih pet godina nekvalitetni krediti su kontinuirano rasli, a na kraju 2010. godine udio nekvalitetnih u ukupnim kreditima iznosio je 21,0%, odnosno 18,1% više nego na kraju 2006. godine. Na kraju analiziranog perioda, udio nekvalitetnih kredita iznosio je 13,4%, što je za 7,6% manje nego u 2010., ali za 10,5% više nego u 2006. godini. Tokom 2014. i 2015. godine zabilježen je pad nivoa nekvalitetnih kredita, ali uprkos smanjenju, oni su još uvijek na visokom nivou.

U bankarskom sektoru Hrvatske nivo nekvalitetnih kredita kontinuirano je rastao u periodu od 2006. do kraja 2014. godina, tako da je sa početnih 5,2% (na kraju 2006. godine) povećan na 16,7% (na kraju 2014. godine). Na kraju 2015. godine udio nekvalitetnih u ukupnim kreditima iznosio je 16,3%, što je za 0,4% manje nego u prethodnoj godini, ali za 11,1% više nego u 2006. godini. Iako je nivo nekvaitetnih kredita u bankarskom sektoru Hrvatske manji nego u bankarskim sektorima Srbije i Crne Gore, i ona je još uvijek na visokom nivou.

Na kraju 2006. godine, udio nekvalitetnih u ukupnim kreditima najmanji je bio u bankarskom sektoru Slovenije i iznosio je 2,5%. Sljedeće godine, udio je smanjen za 0,7% i na kraju 2007. godine iznosio je 1,8%, a nakon toga kontinuirano raste sve do kraja 2013. godine kada je iznosio 15,2%. Već od sljedeće godine nivo nekvalitetnih kredita se smanjuje, tako da je na kraju 2015. godine iznosio 10,0%, što je za 7,5% više nego u 2006. godini. Iako je na kraju analiziranog perioda nivo nekvalitetnih kredita u bankarskom sektoru Slovenije bio najniži u poređenju sa ostalim zemljama regiona, i on je još uvijek visok.

Za razliku od bankarskih sektora Srbije, Crne Gore, Hrvatske i Slovenije, u kojima je nivo nekvalitetnih kredita značajno povećan, u bankarskom sektoru Makedonije nivo nekvalitetnih kredita na kraju 2015. godine bio je manji nego u 2006. godini. U bankarskom sektoru Makedonije udio nekvalitetnih kredita iznosio je 11,2% na kraju 2006. godine, a u naredne dvije godine zabilježeno je smanjenje, tako da su nekvalitetni krediti činili 6,7% ukupnih kredita na kraju 2008. godine. Od 2009. do kraja 2013. godine nivo nekvalitetnih kredita blago raste, tako da su oni na kraju 2013. godine iznosili 10,9%. Nakon perioda blagog rasta, nivo nekvalitetnih kredita počinje da se smanjuje, tako da je na kraju 2015. godine iznosio 10,3%, odnosno 0,9% manje nego u 2006. godini.

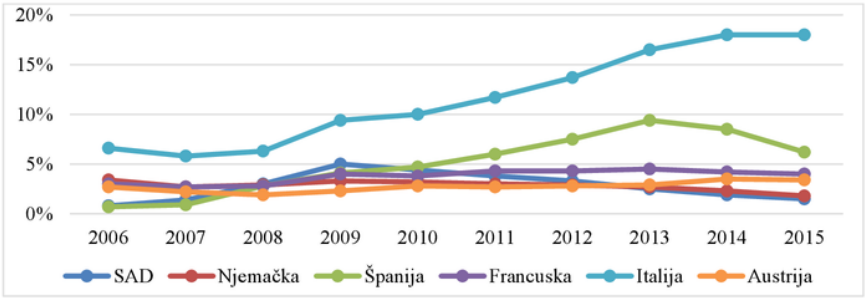
Globalna finansijska kriza uticala je na nivo nekvalitetnih kredita u analiziranim bankarskim sektorima. Tokom 2008. godine, udio nekvalitetnih u ukupnim kreditima povećan je u bankarskim sektorima Srbije, Crne Gore, Hrvatske i Slovenije, a globalna finansijska kriza nije uticala na nekvalitetne kredite samo u bankarskom sektoru Makedonije. Tokom 2009. i 2010. godine nivo nekvalitetnih kredita povećan je u bankarskim sektorima svih zemalja, što je direktna posljedica globalne finansijske krize. Tek od 2012. godine bankarski sektori analiziranih zemalja počinju da se oporavljaju od posljedica krize, pa se i nivo nekvalitetnih kredita polako smanjuje. Ipak, oporavak bankarskih sektora je spor i dugotrajan proces, a to svjedoči udio nekvalitetnih u ukupnim kreditima koji je još uvijek visok u svim zemljama regiona.

2. NEKVALITETNI KREDITI NA FINANSIJSKIM TRŽIŠTIMA RAZVIJENIH ZEMALJA

Globalna finansijska kriza uticala je i na bankarske sektore razvijenih zemalja, a to se odrazilo i na kvalitet kreditnog portfolia koji je pogoršan u većini zemalja. U analizu je uključeno šest razvijenih zemalja, i to: SAD, Njemačka, Španija, Francuska, Italija i Austrija. Podaci o nivou nekvalitetnih kredita u bankarskim sektorima navedenih zemalja preuzeti su od Svjetske banke, a obuhvataju period od 2006. do kraja 2015. godine.

Trend kretanja nekvalitetnih kredita u bankarskim sektorima razvijenih zemalja predstavljen je na grafikonu 56.

Grafikon 56:Trend kretanja nekvalitetnih kredita u razvijenim zemljama (2006 – 2015)



Izvor: (Svjetska banka, 2017)

Već na prvi pogled, zaključuje se da je nivo nekvalitetnih kredita u bankarskom sektoru Italije znatno veći nego u ostalim bankarskim sektorima. Nivo nekvalitetnih kredita u bankarskom sektoru Italije dostigao je čak 18,0%, za razliku od bankarskih sektora SAD-a, Njemačke, Francuske i Austrije u kojima nekvalitetni krediti nisu dostigli ni nivo od 5%. U bankarskom sektoru Španije maksimalni nivo nekvalitetnih kredita iznosio je 9,4%. Takođe, na osnovu datih podataka može se zaključiti da je na kraju analiziranog perioda nivo nekvalitetnih kredita bio veći nego na početku u većini zemalja, a izuzetak je bankarski sektor Njemačke u kome je nivo nekvalitetnih kredita smanjen.

Globalna finansijska kriza uticala je i na bankarske sektore razvijenih zemalja, tako da je kvalitet kreditnog portfolia pogoršan. Tokom 2008. godine nivo nekvalitetnih kredita povećan je u bankarskim sektorima SAD-a, Njemačke, Španije, Francuske i Italije, a tokom 2009. godine u svim analiziranim zemljama. Od 2010. godine bankarski sektori SAD-a, Njemačke i Francuske polako se počinju oporavljati od posljedica globalne finansijske krize. Sa druge strane, u bankarskim sektorima Španije, Italije i Austrije nivo nekvalitetnih kredita nastavlja da raste. Ipak, globalna finansijska kriza najmanje je uticala na nivo nekvalitetnih kredita u bankarskim sektorima Njemačke i Austrije, u kojima nije bilo većih oscilacija u periodu od 2006. do kraja 2015. godine.

Tabelarni pregled nivoa nekvalitetnih kredita u bankarskim sektorima SAD-a, Njemačke, Španije, Francuske, Italije i Austrije dat je u nastavku.

Tabela 66: Nekvalitetni krediti u bankarskim sektorima razvijenih zemalja (2006 - 2015)

- % -

ZEMLJA	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
SAD	0,8	1,4	3,0	5,0	4,4	3,8	3,3	2,5	1,9	1,5
NJEMAČKA	3,4	2,7	2,9	3,3	3,2	3,0	2,9	2,7	2,3	1,8
ŠPANIJA	0,7	0,9	2,8	4,1	4,7	6,0	7,5	9,4	8,5	6,2
FRANCUSKA	3,0	2,7	2,8	4,0	3,8	4,3	4,3	4,5	4,2	4,0
ITALIJA	6,6	5,8	6,3	9,4	10,0	11,7	13,7	16,5	18,0	18,0
AUSTRIJA	2,7	2,2	1,9	2,3	2,8	2,7	2,8	2,9	3,5	3,4

Izvor: (Svjetska banka, 2017)

Na kraju 2006. godine nivo nekvalitetnih kredita u bankarskom sektoru SAD-a iznosio je 0,8%, a nakon toga počinje postepeno da se povećava da bi na kraju 2009. godine dostigao nivo od 5,0%. Od 2010. godine udio nekvalitetnih u ukupnim kreditima bankarskog sektora SAD-a se smanjuje, pa je na kraju 2015. godine iznosio 1,5%, što je za 3,5% manje nego na kraju 2009. godine, ali za 0,7% više nego u 2006. godini.

U bankarskom sektoru Njemačke nivo nekvalitetnih kredita, na kraju 2006. godine, iznosio je 3,4%, i smanjen je u naredne dvije godine. Ipak, pod uticajem globalne finansijske krize došlo je do povećanja nivoa nekvalitetnih kredita tokom 2009. godine, tako da su nekvalitetni krediti činili 3,3% ukupnih kredita. Od 2010. godine nivo nekvalitetnih kredita u bankarskom sektoru Njemačke kontinuirano se smanjuje, tako da je na kraju 2015. godine iznosio 1,8%, što je za 1,6% manje nego u 2006. godini.

Značajno povećanje nivoa nekvalitetnih kredita zabilježeno je u bankarskom sektoru Španije u kome je, sa početnih 0,7% na kraju 2006. godine dostignut nivo od 9,4% na kraju 2013. godine. Tokom naredne dvije godine kvalitet kreditnog portfolia je poboljšan, tako da su na kraju 2015. godine nekvalitetni krediti činili 6,2% ukupnih kredita koji su plasirani u bankarskom sektoru Španije, a to je za 5,5% više nego u 2006. godini.

U bankarskom sektoru Francuske udio nekvalitetnih u ukupnim kreditima iznosio je 3,0% na kraju 2006. godine, a tokom naredne dvije godine zabilježeno je smanjenje nekvalitetnih kredita. Globalna finansijska kriza uticala je i na bankarski sektor Francuske, što se odrazilo i na nekvalitetne kredite koji su dostigli nivo od 4,0% na kraju 2009. godine. Isti nivo zabilježen je i na kraju 2015. godine, iako je nivo nekvalitetnih kredita oscilirao u periodu od 2010. do 2015. godine.

Kao što je već rečeno, najveći nivo nekvalitetnih kredita, ali i najveće oscilacije, zabilježene su u bankarskom sektoru Italije. Na kraju 2006. godine, udio nekvalitetnih u ukupnim kreditima iznosio je 6,6%. Nakon smanjenja nivoa nekvalitetnih kredita koje je zabilježeno na kraju 2007. i 2008. godine, slijedi trend rasta sve do kraja 2014. godine, kada su nekvalitetni krediti dostigli nivo od 18,0%. Takođe, na kraju 2015. godine udio nekvalitetnih u ukupnim kreditima iznosio je 18,0%, što je veoma visoko u poređenju sa nivoom koji je zabilježen u bankarskim sektorima SAD-a, Njemačke, Španije, Francuske i Austrije.

Najmanje oscilacije u nivou nekvalitetnih kredita zabilježene su u bankarskom sektoru Austrije. Na kraju 2006. godine udio nekvalitetnih u ukupnim kreditima iznosio je 2,7%, a maksimalna vrijednost od 3,5% zabilježena je na kraju 2014. godine. Na kraju 2015. godine nivo nekvalitetnih kredita iznosio je 3,4%.

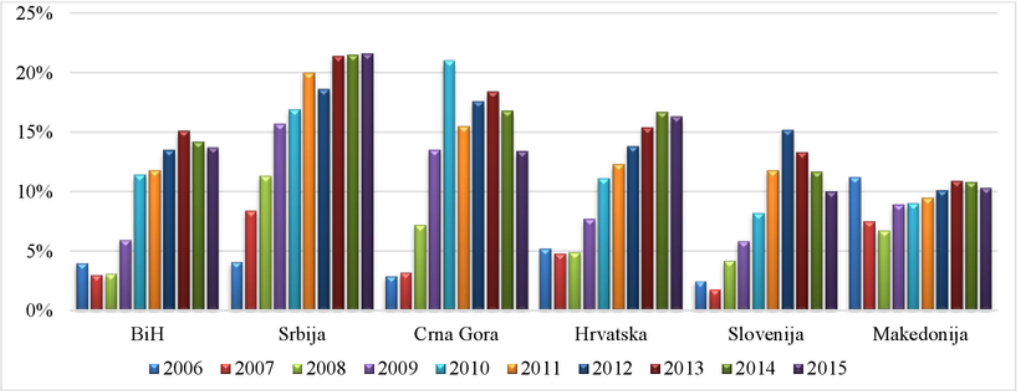
3. KOMPARATIVNA ANALIZA NEKVALITETNIH KREDITA

Podaci o udjelu nekvalitetnih u ukupnim kreditima u bankarskom sektoru BiH, u bankarskim sektorima zemalja regiona i bankarskim sektorima razvijenih zemalja već su dati. Međutim, sami po sebi, podaci ne govore mnogo. Da bi se stvorila realna slika o nekvalitetnim kreditima u bankarskom sektoru BiH, potrebno ih je uporediti sa nekvalitetnim kreditima zemalja iz okruženja, ali i sa nekvalitetnim kreditima razvijenih zemalja. U nastavku su dati rezultati komparativne analiza koja je sporvedena u bankarskom sektoru BiH i bankarskim sektorima zemalja regiona, odnosno u bankarskom sektoru BiH i bankarskim sektorima razvijenih zemalja.

Komparativna analiza nivoa nekvalitetnih kredita u bankarskom sektoru BiH i bankarskim sektorima Srbije, Crne Gore, Hrvatske, Slovenije i Makedonije pokazaće kakav je kvalitet kreditnog portfolia u BiH u odnosu na kvalitet kreditnog portfolia zemalja regiona. U periodu od 2006. do 2015. godine nekvalitetni krediti u navedenim zemljama uglavnom su imali trend rasta, koji je posebno bio izražen za vrijeme globalne finansijske krize. Iako su se bankarski sektori navedenih zemalja počeli oporavljati od posljedica krize 2012. godine, udio nekvalitetnih kredita bio je visok i na kraju 2015. godine.

Rezultati komparativne analize nivoa nekvalitetnih kredita u bankarskom sektoru BiH i bankarskim sektorima zemalja regiona predstavljeni su grafikonom 57.

Grafikon 57: Učešće nekvalitetnih u ukupnim kreditima bankarskih sektora BiH i zemalja regiona



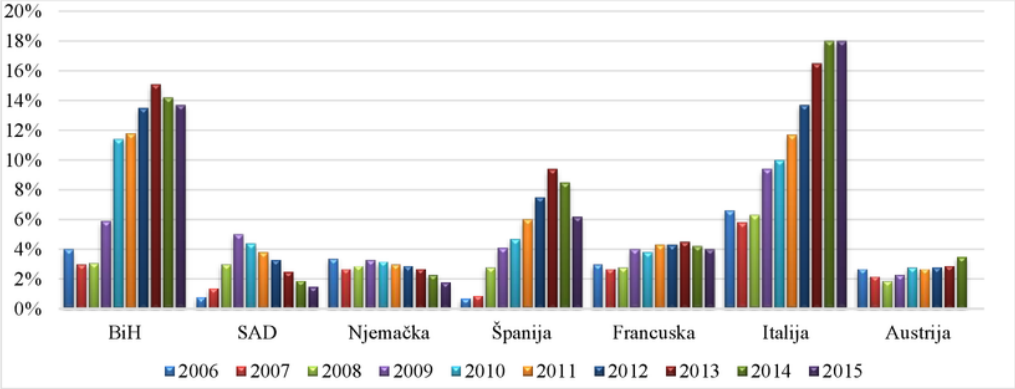
Izvor: (Svjetska banka, 2017)

Navedeni podaci još jednom potvrđuju da je nivo nekvalitetnih kredita u bankarskim sektorima BiH, Srbije, Crne Gore, Hrvatske, Slovenije i Makedonije na visokom nivou. U tom ipak prednjači bankarski sektor Srbije u kom je nivo nekvalitetnih kredita bio najviši tokom analiziranog perioda. Iako je nivo nekvalitetnih kredita u bankarskom sektoru BiH uglavnom imao trend rasta od 2008. godine, on je ipak, na kraju 2015. godine bio niži od nivoa nekvalitetnih kredita u bankarskim sektorima Srbije i Hrvatske, ali viši od nivoa nekvalitetnih kredita u bankarskim sektorima Crne Gore, Slovenije i Makedonije.

Nivo nekvalitetnih kredita bankarskog sektora BiH upoređen je i sa nivoom nekvalitetnih kredita u bankarskim sektorima SAD-a, Njemačke, Španije, Francuske, Italije i Austrije, sa ciljem da se odredi da li je bankarski sektor BiH u mnogo većem problemu od bankarskih sektora razvijenih zemalja.

Rezultati komparativne analize nivoa nekvalitetnih kredita u bankarskom sektoru BiH i bankarskim sektorima razvijenih zemalja predstavljeni su grafikonom 58.

Grafikon 58: Učešće nekvalitetnih u ukupnim kreditima bankarskih sektora BiH i razvijenih zemalja



Izvor: (Svjetska banka, 2017)

Podaci pokazuju da je naveći nivo nekvalitetnih kredita, tokom analiziranog desetogodišnjeg perioda, zabilježen u bankarskom sektoru Italije. Nivo nekvalitetnih kredita u bankarskom sektoru BiH je manji od nivoa u bankarskom sektoru Italije, ali je ipak mnogo veći od nivoa u bankarskim sektorima SAD-a, Njemačke, Španije, Francuske i Italije. U analiziranom periodu, učešće nekvalitetnih u ukupnim kreditima bankarskih sektora Njemačke i Austrije bilo je manje od 5%, a u bankarskom sektoru BiH učešće je bilo i iznad 15%.

Na osnovu navedenih podataka vidi se da postoje značajne razlike u dinamici rasta i učešću nekvalitetnih u ukupnim kreditima bankarskih sektora BiH, zemalja regiona i razvijenih zemalja. Učešće nekvalitetnih u ukupnim kreditima bankarskog sektora BiH, kao i trend rasta koji je bio posebno izražen za vrijeme globalne finansijske krize, sličan je kao u bankarskim sektorima zemalja regiona, ai se razlikuje od nivoa i trenda rasta u bankarskim sektorima razvijenih zemaljma. U skladu sa tim, potrebno je preduzeti niz mjera za upravljanje kreditnim rizikom u komercijalnim bankama BiH, kako bi se nivo nekvalitetnih kredita u kreditnom protfoliu smanjio. Smanjenjem nekvalitetnih kredita pozitivno bi se odrazilo na stabilnost bankarskog, odnosno finansijskog sektora u BiH. Predlog mjera za smanjenje nekvalitetnih kredita u komercijalnim bankama u BiH dat je uz zaključna razmatranja.

ZAKLJUČNA RAZMATRANJA

Zaključna razmatranja podijeljena su na dva dijela. U prvom dijelu sumirani su rezultati sprovedenog istraživanja koje se odnosi na nekvalitetne kredite u bankarskom sektoru BiH. S obzirom na rezultate istraživanja, koji pokazuju da je udio nekvalitetnih u ukupnim kreditima bankarskog sektora BiH visok, predložene su mjere za rješavanje ovog problema. Predlog mjera za rješavanje nekvalitetnih kredita dat je u drugom dijelu.

1. Zaključak

Glavni cilj disertacije bila je identifikacija faktora koji utiču na nekvalitetne kredite bankarskog sektora BiH. U skladu sa ciljem, na početku istraživanja postavljena je generalna hipoteza istraživanja, ali i dvije posebne i devet pojedinačnih hipoteza. Takođe, prikupljeni su podaci iz primarnih i sekundarnih izvora, pri tom su podaci iz primarnih izvora prikupljeni anketiranjem, a podaci koji su prikupljeni iz sekundarnih izvora obuhvataju period od prvog kvartala 2006. do kraja četvrtog kvartala 2015. godine. U istraživanju su korišteni kvartalni podaci, a prilikom obrade podataka korišten je statistički program *IBM SPSS Statistics Version 20.*

Na osnovu rezultata istraživanja precizno su izvedeni zaključci koji mogu biti interesantni širokom krugu čitalaca. Autor se nada da će rezultati istraživanja pomoći rukovodiocima i menadžerima komercijalnih banaka u BiH da sagledaju faktore koji utiču na nekvalitetne kredite, te da će preduzeti konkretne mjere za poboljšanje upravljanja kreditnim rizikom.

Generalna hipoteza istraživanja uspješno je dokazana izvođenjem nedvosmislenih zaključaka koji su dokazali da postoje makroekonomski i specifični bankarski faktori koji imaju statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru Bosne i Hercegovine. Zaključci su testirani pomoću pojedinačnih hipoteza koje polaze od pretpostavke da određeni makroekonomski ili specifični bankarski faktor ima statistički značajan i pozitivan ili negativan odnos sa nekvalitetnim kreditima komercijalnih banaka. U istraživanje su uključena tri makroekonomska i šest specifičnih bankarskih faktora, tako da je testirano ukupno devet pojedinačnih hipoteza.

Prva pojedinačna hipoteza polazi od stava da stopa rasta realnog BDP-a ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka. Prilikom testiranja navedene hipoteze, zavisna promjenljiva odnosila se na udio nekvalitetnih u ukupnim kreditima bankarskog sektora BiH, a nezavisna promjenljiva na stopu rasta realnog BDP-a u BiH. Uticaj nezavisne na zavisnu promjenljivu testiran je pomoću analize korelacije i analize regresije. Dobijeni koeficijent linearne korelacije ukazao je na negativan odnos između analiziranih promjenljivih. Međutim, stepen zavisnosti između analiziranih promjenljivih (*p vrijednost*) pokazuje da uticaj stope rasta realnog BDP-a na nekvalitetne kredite nije statistički značajan. Iako je koeficijent linearne korelacije ukazao na negativan odnos između stope rasta realnog BDP-a i nekvalitetnih kredita, *p vrijednost* je pokazala da on nije statistički značajan, tako da se navedena hipoteza ne može u potpunosti ni prihvatiti, a ni odbaciti. Dobijeni rezultat istraživanja koji pokazuje da privredne aktivnosti zemlje nemaju statistički značajan uticaj na nekvalitetne kredite potvrđen je u sprovedenim studijama koje se bave ovom problematikom.

Druga pojedinačna hipoteza polazi od stava da stopa nezaposlenosti ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. Prilikom dokazivanja navedene hipoteze, zavisna promjenljiva odnosila se na udio nekvalitetnih u ukupnim kreditima bankarskog sektora BiH, a nezavisna promjenljiva na stopu nezaposlenosti. Hipoteza je testirana pomoću analize korelacije i analize regresije, a dobijeni rezultati pokazali su da navedena hipoteza ne može biti potvrđena. Koeficijent linearne korelacije ukazao je na negativan odnos između stope nezaposlenosti i nekvalitetnih kredita, što je suprotno od očekivanog, a stepen zavisnosti između analiziranih promjenljivih pokazao je da uticaj nezavisne na zavisnu promjenljivu nije statistički značajan. I regresiona anliza je pokazala da se stopa nezaposlenosti ne može koristiti za opisivanje kretanja nekvalitetnih kredita u bankarskom sektoru BiH. U skladu sa tim, može se zaključiti da promjena nezaposlenosti u BiH neće uticati na kvalitet kreditnog portfolia bankarskog sektora BiH. Ovaj rezultat je u skladu sa rezultatima koji su dostupni u empirijskoj literaturi.

Treća pojedinačna hipoteza polazi od stava da stopa rasta potrošačkih cijena ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. Ovom hipotezom se ispituje veza između inflacije i nekvalitetnih kredita, pri čemu se stopa inflacije mjeri stopom rasta potrošačkih cijena. Tesiranje hipoteze takođe je izvršeno pomoću analize korelacije i analize regresije. Rezultati pokazuju da stopa rasta potrošačkih cijena ima statistički značajan uticaj na nekvalitetne kredite bankarskog sektora BiH. Koeficijent linearne korelacije ukazao je na negativan odnos između analiziranih promjenljivih, što je u suprotnosti od očekivanog. U skladu sa dobijenim rezultatima, može se zaključiti da navedena hipoteza ne može biti prihvaćena u potpunosti, ali se ne može ni odbaciti, jer je analiza pokazala da postoji statistički značajan odnos između stope rasta potrošačkih cijena i nekvalitetnih kredita, ali je on negativan, što je u suprotnosti od očekivanog. Ipak, regresiona analiza pokazala je da se stopa rasta potrošačkih cijena može koristiti za objašnjavanje kretanja nekvalitetnih kredita, odnosno da se na osnovu njene potencijalne vrijednosti može predvidjeti vrijednost nekvalitetnih kredita u narednom periodu. Dobijeni rezultat potvrđen je i u empirijskoj literaturi.

Pomoću prethodno navedenih pojedinačnih hipoteza testiran je uticaj makroekonomskih faktora na nekvalitetne kredite. Od ukupno tri pojedinačne hipoteze koje su testirane, dvije ne mogu biti ni prihvaćene u potpunosti, ali ni odbačene, a jedna hipoteza se odbacuje. Rezultati testiranja prve pojedinačne hipoteze pokazuju da postoji negativan odnos između stope rasta realnog BDP-a i nekvalitetnih kredita, što je u skladu sa očekivanim, ali taj odnos nije statistički značajan, što je suprotno od očekivanog. Rezultati testiranja druge pojedinačne hipoteze pokazuju da postoji negativan odnos između stope nezaposlenosti i nekvalitetnih kredita i da njihov odnos nije statistički značajan, što je u suprotnosti od očekivanog, tako da se ova hipoteza odbacuje. Rezultati testiranja treće pojedinačne hipoteze pokazuju da postoji negativan odnos između stope rasta potrošačkih cijena i nekvalitetnih kredita, što je suprotno od očekivanog, ali ovaj odnos je statistički značajan, što je u skladu sa očekivanim. Regresiona analiza je pokazala da se vrijednost stope rasta potrošačkih cijena može koristiti za određivanje vrijednosti nekvalitetnih kredita u narednom periodu, dok stopa rasta realnog BDP-a i stopa nezaposlenosti nisu relevantne za objašnjavanje ponašanja nekvalitetnih kredita u bankarskom sektoru BiH. Rezultati su pokazali da samo jedan makroekonomski faktor, od tri analizirana, ima statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru BiH.

Uticaj specifičnih bankarskih faktora na nekvalitetne kredite bankarskog sektora BiH testiran je pomoću preostalih šest pojedinačnih hipoteza. Prilikom testiranja tih hipoteza korišteni su agregatni podaci, odnosno podaci na nivou bankarskog sektora, a ne na nivou pojedinačnih komercijalnih banaka, jer ti podaci nisu dostupni autoru. Sprovedene su korelaciona i regresiona analiza, kao i prilikom testiranja uticaja makroekonomskih faktora na nekvalitetne kredite, a rezultati testiranja su dati u nastavku.

Četvrta pojedinačna hipoteza polazi od stava da koeficijent adekvatnosti kapitala ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka. I ova hipoteza testirana je pomoću analize korelacije, a dobijeni koeficijent linearne korelacije ukazuje na negativan odnos između navedenih promjenljivih, što je u sladu sa očekivanim. Međutim, testiranjem stepena značajnosti rezultata utvrđeno je da ovaj odnos nije statistički značajan, što je u suprotnosti od očekivanog. U skladu sa tim, ova hipoteza se ne može prihvatiti u potpunosti, ali se ne može ni odbaciti. Regresiona analiza je potvrdila da promjena adekvatnosti kapitala nema statistički značajan uticaj na nekvalitetne kredite, tako da se ova promjenljiva ne može koristiti za objašnjavanje ponašanja nekvalitetnih kredita bankarskog sektora BiH u narednom periodu. Sličan rezultat nije pronađen u dostupnoj literaturi koja se bavi ovom problematikom, jer rezultati sprovedenih istraživanja pokazuju da koeficijent adekvatnosti kapitala ima statistički značajan uticaj na nekvalitetne kredite.

Peta pojedinačna hipoteza polazi od stava da odnos kredita i depozita ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. Kao i u prethodnim slučajevima, hipoteza je testirana pomoću analize korelacije i pomoću analize regresije. Dobijeni koeficijent linearne korelacije ukazuje na negativan odnos između odnosa kredita i depozita i nekvalitetnih kredita, što je u suprotnosti od očekivanog. Nakon testiranja značajnosti dobijenog rezultata, utvrđeno je da njihov odnos nije statistički značajan, što je takođe u suprotnosti od očekivanog. U skladu sa tim, ova hipoteza se odbacuje. I regresiona analiza je pokazala da se odnos kredita i depozita ne može koristiti za objašnjavanje ponašanja nekvalitetnih kredita bankarskog sektora BiH. Ovakav rezultat potvrđen je i u empirijskoj literaturi, odnosno u studijama koje se bave ovom problematikom.

Šesta pojedinačna hipoteza polazi od stava da prinos na aktivu ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka. Uticaj ovog pokazatelja profitabilnosti na nekvalitetne kredite u bankarskom sektoru BiH testiran je pomoću analize korelacije i analize regresije. Rezultati korelacione analize, odnosno koeficijent linearne korelacije, ukazuje na pozitivan odnos između prinosa na aktivu i nekvalitetnih kredita, što je suprotno od očekivanog. Stepen zavisnosti između analiziranih promjenljivih (*p vrijednost*) pokazao je da je ovaj odnos statistički značajan, što je u skladu sa očekivanim rezultatom. Pošto je odnos između prinosa na aktivu i nekvalitetnih kredita statistički značajan i pozitivan, ova hipoteza se ne može prihvatiti u potpunosti, ali se ne može ni odbaciti. Dalje, regresiona analiza pokazala je da je prinos na aktivu relevantan pokazatelj koji se može koristiti za objašnjavanje ponašanja nekvalitetnih kredita bankarskog sektora BiH, te da se, na osnovu njegove proizvoljne vrijednosti može predvidjeti vrijednost nekvalitetnih kredita u narednom periodu. U empirijskoj literaturi koja se bavi ovom problematikom potvrđeno je da prinos na aktivu ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima.

Sedma pojedinačna hipoteza polazi od stava da prinos na akcijski kapital ima statistički značajan i negativan odnos sa nekvalitetnim kreditima komercijalnih banaka. Uticaj stope prinosa na akcijski kapital na nekvalitetne kredite testiran je pomoću analize korelacije i analize regresije. Rezultati korelacione analize, odnosno koeficijent linearne korelacije, ukazuje na pozitivan odnos između analiziranih promjenljivih, što je u suprotnosti od očekivanog. Nakon testirana značajnosti dobijenog rezultata, utvrđeno je da odnos prinosa na akcijski kapital i nekvalitetnih kredita bankarskog sektora nije statistički značajan, što je takođe u suprotnosti od očekivanog. Na osnovu toga može se zaključiti da se sedma pojedinačna hipoteza odbacuje. Pomoću proste regresione analize još jednom je potvrđeno da prinos na akcijski kapital nije relevantan pokazatelj za opisivanje ponašanja nekvalitetnih kredita bankarskog sektora BiH. Ovaj pokazatelj profitabilnosti nije bio uključen u višestruku regresionu analizu, jer je uzrokovao problem multikolinearnosti. S obzirom da rezultati prethodno sprovedenih istraživanja koja se bave problematikom nekvalitetnih kredita ukazuju na statistički značajan odnos između prinosa na akcijski kapital i nekvalitetnih kredita, ovaj rezultat nije potvrđen u dostupnoj empirijskoj literaturi.

Osma pojedinačna hipoteza polazi od stava da aktivna kamatna stopa ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. Navedena hipoteza testirana je pomoću analize korelacije i analize regresije. Dobijeni koeficijent linearne korelacije ukazuje na negativan odnos aktivne kamatne stope i nekvalitetnih kredita, što je suprotno od očekivanog. Stepen zavisnosti između analiziranih promjenljivih (*p vrijednost*) potvrdio je da je ovaj odnos statistički značajan, što je u skladu sa očekivanim rezultatom istraživanja. S obzirom da je odnos aktivne kamatne stope i nekvalitetnih kredita statistički značajan i negativan, navedena hipoteza ne može se u potpunosti prihvatiti, ali se ne može ni odbaciti. Takođe, pomoću regresione analize je utvrđeno da se aktivna kamatna stopa može koristiti za objašnjavanje ponašanja nekvalitetnih kredita bankarskog sektora BiH, a i njena proizvoljna vrijednost se može koristiti za predviđanje vrijednosti nekvalitetnih kredita u narednom periodu. Dobijeni rezultat je u skladu sa rezultatima koji su dostupni u empirijskoj literaturi.

Deveta pojedinačna hipoteza polazi od stava da stopa kreditnog rasta ima statistički značajan i pozitivan odnos sa nekvalitetnim kreditima komercijalnih banaka. Tesiranje hipoteze izvršeno je, kao i u prethodnim slučajevima, pomoću analize korelacije i analize regresije. Rezultati korelacione analize, odnosno koeficijent linearne korelacije, ukazuje na negativan odnos između stope kreditnog rasta i nekvalitetnih kredita, što je suprotno od očekivanog. Stepen zavisnosti između analiziranih promjenljivih (*p vrijednost*) potvrdio je da je odnos stope kreditnog rasta i nekvalitetnih kredita statistički značajan, a to je u skladu sa očekivanim rezultatom. Pošto su rezultati pokazali da stopa kreditnog rasta ima statistički značajan i negativan odnos sa nekvalitetnim kreditima bankarskog sektora BiH, navedena hipoteza se ne može odbaciti, ali se ne može ni prihvatiti u potpunosti. Sprovedena regresiona analiza potvrdila je da se stopa kreditnog rasta može koristiti za objašnjavanje kretanja nekvalitetnih kredita u bankarskom sektoru BiH. Rezultati regresione analize pokazuju i da se potencijalna vrijednost stope kreditnog rasta može koristiti za predviđanje vrijednosti nekvalitetnih kredita u narednom periodu. Ovaj rezultat je u skladu sa rezultatima sprovedenih istraživanja koji su dostupni u empirijskoj literaturi.

Pomoću navedenih hipoteza testiran je uticaj specifičnih bankarskih faktora na nekvalitetne kredite u bankarskom sektoru BiH. Testirano je ukupno šest pojedinačnih hipoteza, od kojih su dvije odbačene, a preostale četiri se ne mogu u potpunosti prihvatiti, ali ni odbaciti. Rezultati testiranja četvrte pojedinačne hipoteze pokazuju da postoji negativan odnos između koeficijenta adekvatnosti kapitala i nekvalitetnih kredita, što je u skladu sa očekivanim, ali taj odnos nije statistički značajan, tako da se ova hipoteza ne može ni prihvatiti, ali ni odbaciti. Rezultati testiranja pete pojedinačne hipoteze pokazuju da postoji pozitivan odnos između odnosa kredita i depozita i nekvalitetnih kredita i da njihov odnos nije statistički značajan, što je u suprotnosti od očekivanog, tako da se ova hipoteza odbacuje. Rezultati testiranja šeste pojedinačne hipoteze pokazuju da postoji pozitivan odnos između prinosa na aktivu i nekvalitetnih kredita, što je suprotno od očekivanog, ali je ovaj odnos statistički značajan, tako da se hipoteza ne može odbaciti, ali se ne može ni prihvatiti u potpunosti. Rezultati testiranja sedme pojedinačne hipoteze pokazuju da postoji pozitivan odnos između prinosa na akcijski kapital i nekvalitetnih kredita i da njihov odnos nije statistički značajan, što je u suprotnosti od očekivanog, tako da se i ova hipoteza odbacuje. Rezultati testiranja osme pojedinačne hipoteze pokazuju da postoji negativan odnos između aktivne kamatne stope i nekvalitetnih kredita, što je suprotno od očekivanog, ali je ovaj odnos statistički značajan, tako da se hipoteza ne može odbaciti, ali se ne može ni prihvatiti u potpunosti. I na kraju, rezultati testiranja devete pojedinačne hipoteze pokazuju da postoji negativan odnos između stope kreditnog rasta i nekvalitetnih kredita, što je suprotno od očekivanog, ali je ovaj odnos statistički značajan, tako da se ni ova hipoteza ne može u potpunosti prihvatiti, ali ni odbaciti. Rezultati su pokazali da tri specifična bankarska faktora, od analiziranih šest, imaju statistički značajan uticaj na nekvalitetne kredite u bankarskom sektoru BiH.

Regresiona analiza pokazala je da se 54,3% varijabiliteta nekvalitetnih kredita može objasniti pomoću stope rasta potrošačkih cijena, prinosa na aktivu, aktivne kamatne stope i stope kreditnog rasta. Pri tom, najveći uticaj na nekvalitetne kredite ima stopa rasta potrošačkih cijena, dok je uticaj aktivne kamatne stope najmanji. Takođe, na osnovu proizvoljnih vrijednosti navedenih promjenljivih može se predvidjeti vrijednost nekvalitetnih kredita u narednom periodu. Regresiona analiza je pokazala da se stopa rasta realnog BDP-a, stopa nezaposlenosti, koeficijent adekvatnosti kapitala, odnos kredita i depozita i prinos na akcijski kapital ne mogu koristiti za objašnjavanje ponašanja nekvalitetnih kredita u bankarskom sektoru BiH.

Dokazujući pojedinačne hipoteze, dokazana je i generalna hipoteza istraživanja, odnosno istraživanje je pokazalo da postoje makroekonomski i specifični bankarski faktori koji utiču na nekvalitetne kredite u bankarskom sektoru BiH. Iako se na početku istraživanja pretpostavilo da tri makroekonomska i šest specifičnih bankarskih faktora ima uticaj na nekvalitetne kredite, analiza je pokazala da je uticaj samo jednog makroekonomskog i tri specifična bankarska faktora statistički značajan. Ipak, pomoću ova četiri faktora može se objasniti ponašanje nekvalitetnih kredita bankarskog sektora BiH. Takođe, na osnovu potencijalnih vrijednosti navedenih faktora može se predvidjeti vrijednost nekvalitetnih kredita u narednom periodu.

Dobijeni rezultati istraživanja upoređeni su sa rezultatima sličnih istraživanja koja su sprovedena u pojedinačnim zemljama ili u više zemalja, čime je još jednom potvrđen uticaj navedenih faktora na nekvalitetne kredite.

Pored generalne i pojedinačnih hipoteza, formulisane su i dvije posebne hipoteze. Prva posebna hipoteza polazi od stava da se udio nekvalitetnih u ukupnim kreditima komercijalnih banaka u BiH povećao u periodu globalne finansijske krize. Analizom trenda kretanja nivoa nekvalitetnih kredita, u periodu od 2006. do kraja 2015. godine, pokazalo se da se nivo nekvalitetnih kredita značajno povećao tokom 2009. godine. Povećanje nivoa nekvalitetnih kredita, koje je počelo 2009. godine, nastavilo se i u narednim godinama, a završeno je tek na kraju 2013. godine. Trend rasta nivoa nekvalitetnih kredita posljedica je globalne finansijske krize kojoj ni bankarski sektor BiH nije odolio. Na osnovu navedenog, prihvaćena je prva posebna hipoteza.

Druga posebna hipoteza polazi od stava da poslovne banke mogu da identifikuju faktore koji dovode do nastanka nekvalitetnih kredita. Da bi se ova hipoteza dokazala sprovedena je anketa u komercijalnim bankama koje posluju na teritoriji BiH. Anketni list koji se sastojao od 20 pitanja zatvorenog tipa dostavljen je rukovodiocima, menadžerima i zaposlenima u komercijalnim bankama kako bi se i na ovaj način identifikovali faktori koji utiču na pojavu i rast nekvalitetnih kredita. Rezultati anketiranja pokazali su da se u komercijalnim bankama u BiH upravlja kreditnim rizikom, a samim tim i nekvalitetnim kreditima, ali da je njihov nivo još uvijek visok. Takođe, rezultati su pokazali da se u komercijalnim bankama u BiH mogu identifikovati faktori koji utiču na nekvalitetne kredite, čime je navedena hipoteza dokazana.

Na kraju, može se zaključiti da BiH, kao i većina zemalja u tranziciji, ima visok udio nekvalitetnih kredita u bankarskom portfoliu. Nekvalitetni krediti nisu problem samo pojedinačnih banaka nego cjelokupnog bankarskog sektora, finansijskog sistema zemlje pa čak i cjelokupne ekonomije. Oporavak bankarskog sektora BiH od posljedica globalne finansijske krize je spor i dugotrajan proces, a to se vidi i po kvalitetu kreditnog portfolia komercijalnih banaka. Komparativna analiza trendova kretanja nekvalitetnih kredita pokazala je da se bankarski sektor BiH ne razlikuje mnogo od bankarskih sektora zemalja regiona (Srbija, Hrvatska, Crna Gora, Slovenija i Makedonija). Istovremeno, analiza je pokazala da je potrebno uložiti još mnogo truda oko upravljanja kreditnim rizikom u komercijalnim bankama, kako bi se bankarski sektor BiH približio bankarskim sektorima razvijenih zemalja (SAD-a, Njemačke, Španije, Francuske i Austrije).

U BiH nije urađeno mnogo istraživanja koja se bave pitanjem nekvalitetnih kredita, ali u razvijenim zemlja, ovo je vrlo česta tema studija. Na osnovu iskustava i saznanja iz istraživanja koja su sprovedena u različitim zemljama, moglo bi se uraditi više istraživanja u BiH, sa ciljem smanjenja udjela nekvalitetnih u ukupnim kreditima komercijalnih banaka. I ovo istraživanje sprovedeno je po uzoru na istraživanja koja su sprovedena u razvijenim zemljama, a rezultati tih istraživanja poslužila su kao osnova za istraživanje koje je sprovedeno u bankarskom sektoru BiH.

U skladu sa dobijenim rezultatima istraživanja, predložene su konkretne mjere za upravljanje kreditnim rizikom u komercijalnim bankama koje posluju u BiH, kako bi se poboljšao kvalitet kreditnog portfolia, odnosno smanjio udio nekvalitetnih u ukupnim kreditima bankarskog sektora. Autor se nada da će rezultati istraživanja, kao i predložene mjere za smanjenje nekvalitetnih kredita pomoći rukovodiocima, menadžerima i zaposlenim u komercijalnim bankama, te da će pomoću njih poboljšati kvalitet kreditnog portfolia komercijalnih banaka, što bi pozitivno uticalo na stabilnost bankarskog sistema.

2. Predlog mjera za smanjenje nekvalitetnih kredita

Za stabilnost bankarskog, a i finansijskog sistema, od ključnog značaja je rješavanje problema nekvalitetnih kredita. Za rješavanje ovog problema ne postoji jedinstven model, već je model za rješavanje potrebno prilagoditi konkretnoj komercijalnoj banci, odnosno bankarskom sistemu. Rješavanje problema visokog učešća nekvalitetnih u ukupnim kreditima veliki je izazov i za komercijalne banke, ali i za nosioce ekonomske politike. Udio nekvalitetnih u ukupnim kreditima bankarskog sektora BiH je visok, tako da je rješavanju ovog problema potrebno pristupiti što prije, jer će njegovo ignorisanje na kraju biti skupo plaćeno novcem poreskih obveznika.

Zadržavanje većeg iznosa nekvalitetnih kredita nije preporučljivo za banke jer, kako Jović navodi, to „ometa njihovo normalno poslovanje jer su im značajni resursi praktično blokirani (nevraćeni krediti plus rezervacije)“, a „banke nemaju dovoljno mogućnosti da se fokusiraju na normalno kreditiranje privrede i stanovništva jer troše energiju na naplatu neperformansnih zajmova“ (Jović Z. , 2013, str. 347). Međutim, u bankama obično nema dovoljno stručnog kadra za upravljanje nekvalitetnim kreditima, a i sistem rješavanja nekvalitetnih kredita praćen je nizom pravnih, regulatornih i poreskih nedostataka. Marković navodi da „neefikasan pravni institucionalni okvir, predugo trajanje prinudne naplate kolaterala i otežano odvijanje sudskih procesa predstavljaju trajnu prepreku efikasnom rješavanju pitanja nekvalitetnih kredita“ (Mirković, 2016, str. 8).

Pravci prevazilaženja problema nekvalitetnih kredita mogu biti interni i eksterni, a Jović i Vićentijević navode da „interni pravac podrazumijeva segmentiranje kreditnog portfolia po granama privrednih djelatnosti i po vrstama kredita plasiranih stanovništvu i utvrđivanje odgovarajućeg pondera rizika za svaki pojedinačni segment“ (Jović & Vićentijević, 2015, str. 473). Utvrđivanje pondera rizika podrazumijeva da rizične aktivnosti treba da dobiju više pondere rizika jer je nerealno sve aktivnosti tretirati istim ponderom rizika. Jović i Visentijević navode da eksterni pravci rješavanja problema nagomilanih nekvalitetnih kredita „podrazumijevaju angažovanje spoljnih faktora van pojedinačnih banaka, koji mogu biti na nivou države, vlade, centralne banke i slično“ (Jović & Vićentijević, 2015, str. 473). Prilikom rješavanja problema nekvalitetnih kredita potrebno je slijediti oba navedena pravca, jer komercijalne banke ovaj problem ne mogu riješiti samostalno, odnosno bez pomoći države, vlade ili centralne banke. Sa druge strane, ni država ne može samostalno riješiti ovaj problem.

Ranisavljević i Hadžić smatraju da se učešće nekvalitetnih u ukupnim kreditima može smanjiti na dva načina: povećanjem ukupnog kreditnog portfolia i suzbijanjem – smanjenjem iznosa nekvalitetnih kredita (Ranisavljević & Hadžić, 2015, str. 457). Smanjenje nekvalitetnih kredita povećanjem ukupnog kreditnog portfolia podrazumijeva povećanje kreditnih aktivnosti komercijalnih banaka. Pri tom se mora voditi računa o kreditnom riziku, jer novoodobreni krediti mogu, vrlo brzo, i sami postati nekvalitetni. Prilikom povećanja kreditnih aktivnosti, komercijalne banke ne bi trebale pribjegavati promjeni metodologije (u smislu labavljenja kriterijuma za odobravanje kredita privredi i stanovništvu), nego prilagoditi svoju poslovnu politiku (npr. sniziti aktivne kamatne stope i naknade, kako bi krediti bili tržišno atraktivniji i pristupačniji za klijente).

Drugi način se odnosi na aktivnosti koje preduzimaju banke sa ciljem smanjenja nekvalitetnih kredita, prvenstveno restruktuiranje nekvalitetnih kredita, zatim aktiviranje instrumenata obezbjeđenja kredita u cilju naplate i ustupanje kreditnog potraživanja. Restruktuiranje kredita je najčešće korišteni način za rješavanje ovog problema, a on omogućava da se kreditne obaveze dužnika grupišu u jedan kreditni aranžman, najčešće dužeg roka dospjeća tako da klijent ima niže mjesečne obaveze što mu omogućava lakšu otplatu kredita. Ukoliko ovaj postupak nije moguće sprovesti, banke moraju inicirati sudski spor i aktivirati instrumente obezbjeđenja. Realizacija instrumenata obezbjeđenja obično traje duži vremenski period (izuzetak su samo instrumenti obezbjeđenja koji su naplativi i bez sudskog spora, npr. depoziti klijenta), tako da banke prije odobravanja kredita moraju posebno voditi računa o naplativosti kreditnih obezbjeđenja. Pored navedenih načina za smanjenje nekvalitetnih kredita, komercijalne banke mogu ustupiti potraživanja drugim institucijama (vladi, centralnoj banci ili specijalizovanim ustanovama).

U međunarodnoj praksi, prilikom rješavanja problema nekvalitetnih kredita, obično se koriste dva metoda. Prvi metod se oslanja na pomoć države koja osniva posebnu banku ili agenciju koja otkupljuje nekvalitetne kredite i tako uklanja nekvalitetnu aktivu iz bilansa komercijalnih banaka, odnosno bilansa bankarskog sektora. Funkcionisanje ove banke ili agencije finansira država izdavanjem obveznica ili garancija. Ipak, ovaj način rješavanja nekvalitetnih kredita nije pogodan za države koje imaju problema sa javnim finansijama jer se teret rješavanja problema stavlja na račun poreskih obveznika. Drugi metod podrazumijeva kreiranje uslova koji omogućavaju bankama da samostalno rješavaju problem nekvalitetnih kredita pomoću restrukturiranja dugova, otpisa u slučaju stečaja preduzeća ili prodajom ovih kredita trećim licima. Jović smatra da prodaja nekvalitetnih kredita ima i prednosti i nedostatke, a to objašnjava činjenicom da „gotov novac omogućava bankama obnavljanje kreditne aktivnosti i veću profitabilnost, ali istovremeno na makro nivou podstiče monetarnu ekspanzivnost i uzrokuje monetarne distorzije“ (Jović Z. , 2013, str. 347).

Navedene mjere značajne su i na nivou komercijalnih banaka, ali i na nivou države. Primjenom jedne ili više navedenih mjera za smanjenje nekvalitetnih kredita, komercijalne banke smanjuju gubitke, povećavaju prihode usljed smanjenja potraživanja, povećavaju stopu prinosa na kapital (jer kapital ne koriste za pokriće gubitaka koji nastaju zbog nekvalitetnih kredita) i povećavaju likvidnost. Zahvaljujući tome, komercijalne banke postaju stabilne finansijske institucije koje mogu dalje da posluju, odnosno odobravaju kredite privredi i stanovništvu.

LITERATURA

Knjige i udžbenici:

1. Andevski, M., & Kundačina, M. (2008). *Praktikum iz metodologije: Vežbe iz metodologije istraživanja u menadžmentu.* Novi Sad: Cekom books.
2. Baker, H., & Powel, G. (2005). *Understanding financial management: a practical guide.* Oxford: Blackwell Publishing.
3. Barjaktarović, L. (2009). *Upravljanje rizikom.* Beograd: Univerzitet Singidunum.
4. Bessis, J. (2002). *Risk Management in Banking.* New York: John Weley & Sons, Ltd.
5. Bjelica, V. (2001). *Bankarstvo, teorija i praksa.* Novi Sad: Štamparija Budućnost.
6. Bruhn, M. (1996). *Qualitatsmanagement for Deinstleistungen Grundlagen, Konzepte, Methoden.* Berlin: Heidelberg.
7. Chapman, J. (2006). *Simple Tools and Techniques for Enterprise Risk Management.* England: John Wiley & Sons, Ltd.
8. Cvetinović, M. (2008). *Upravljanje rizicima u finansijskom poslovanju.* Beograd: Univerzitet Singidunum.
9. Ćirović, M. (2007). *Bankarstvo.* Beograd: BridgeCompany.
10. Ćurčić, U. (1999). *Strategijsko planiranje u bankarstvu - oblikovanje uspješne profitne strategije.* Novi Sad: Feljton.
11. Ćurčić, U., & Barjaktarović, M. (2008). *Bankarski portfolio menadžment.* Beograd: Fakultet za trgovinu i bankarstvo "Janićije i Danica Karić", Univerzitet "Braća Karić".
12. Dušanić, J. (2003). *Poslovno bankarstvo.* Srpsko Sarajevo i Beograd: Consseco institut.
13. Đukić, Đ., Bjelica, V., & Ristić, Ž. (2003). *Bankarstvo.* Beograd: Ekonomski fakultet.
14. Gautrieaud, S. (2001). *Le risque pays: approche conceptuelle et approche pratique.* Bordeaux: ATER - Centre d'Economie du Developpement - Universite Montesquieu Bordeaux IV.
15. Gitman, L. (1991). *Principes of Managering Finance.* New York: Harper Collins Publishers.
16. Gregurek, M., & Vidaković, N. (2013). *Bankarsko poslovanje.* Zagreb: Visoko učilište Effectus - visoka škola za financije i pravo.
17. Greuning, H., & Brajović Bratanović, S. (2006). *Analiza i upravljanje bankovnim rizicima.* Zagreb: Mate.
18. Hadžić, M. (2009). *Bankarstvo.* Beograd: Univerzitet Singidunum.
19. Heffernan, S. (1996). *Modern Banking in Theory and Practice.* Chichester: John Wiley & Sons Ltd.

20. Hennie, V. (2003). *Analyzing and Managing Banking Risk: A Framework for Assessing Corporate Governance and Financial Risk.* Washington: World Bank Publications.
21. Horne, V., & Wachowicz, J. (2002). *Osnove financijskog menadžmenta.* Zagreb: Mate.
22. Ivaniš, M., & Jeremić, L. (2005). *Osnovi finansija.* Beograd: Univerzitet Singidunum.
23. Jazić, V. (2008). *Rizici u bankarskom poslovanju.* Beograd: Stubovi kulture.
24. Jednak, J. (1999). *Osnovi ekonomije.* Beograd: PA.
25. Jović, Z. (2008). *Menadžment finansijskih institucija.* Beograd: Univerzitet Singidunum.
26. Kapor, P. (2007). *Bankarstvo sa osnovama bankarskog poslovanja i međunarodnim bankarstvom.* Beograd: Megatrend Univerzitet.
27. Katunarić, A. (1988). *Banka: principi i praksa bankovnog poslovanja.* Zagreb: Centar za informacije i publikacije.
28. Komazec, S., & Ristić, Ž. (1997). *Monetarne i javne finansije.* Beograd: Čigoja.
29. Komazec, S., & Ristić, Ž. (2010). *Međunarodno bankarstvo i institucionalni investitori.* Beograd: EtnoStil.
30. Komazec, S., & Ristić, Ž. (2012). *Monetarna ekonomija i bankarski menadžment.* Beograd: EtnoStil.
31. Labus, M. (1997). *Osnovi ekonomije.* Beograd: Jugoslovenska knjiga.
32. Lloyd, B. (2005). *Money, Banking and Financial Markets* (First edition izd.). London: South - Western College Pub.
33. Madžar, L., & Jovanović, A. (1990). *Osnovi teorije razvoja i planiranja.* Beograd: Savremena administracija.
34. Matejić, M., & Jovanović, M. (1977). *Banke i krediti.* Beograd.
35. Mishkin, F. (2007). *The economics of money, banking, and financial markets.* Pearson Education.
36. Mrnjavac, Ž. (1996). *Mjerenje nezaposlenosti.* Split: Ekonomski fakultet.
37. Myers, J., & Mullet, G. (2003). *Managerial applications of multivariate analysis in marketing.* Chicago: American Marketing Association.
38. Pehar, Ž. (2010). *Bosnia and Herzegovinas Business Environment.* London, UK: GMB Publishing LTD.
39. Petrović, P. (2000). *Menadžment rizicima na tržištu kapitala.* Beograd: Institut ekonomskih nauka.
40. Risk Management Glossary. (1985). *Risk and Insurance Management Society.* New York.
41. Rose, P. (2002). *Comercial bank management.* Irwin: McGraw Hill.
42. Rose, P., & Hudgins, S. (2005). *Bankarski menadžment i finansijske usluge.* Beograd: Data status.
43. Samuelson, P., & Nordhaus, W. (1995). *Economics.* Mc Grow Hill.

44. Samuelson, P., & Nordhaus, W. (2000). *Ekonomija* (15 izd.). Zagreb: Mate.

45. Stanišić, M., & Stanojević, L. (2009). *Metodologija revizije banaka.* Beograd: Univerzitet Singidunum.

46. Tabachnick, B., & Fidell, L. (2007). *Using multivariate statistics* (5 izd.). Boston: Pearson Education.

47. Veličković, D., & Barać, S. (2009). *Makroekonomija.* Beograd: Univerzitet Singidunum.

48. Veselinović, P. (2010). *Ekonomija.* Beograd: Univerzitet Singidunum, Fakultet za turistički i hotelijerski menadžment.

49. Vilendečić, S. (2004). *Napuštanje sistema valutnog odbora u tranzicionim ekonomijama.* Istočno Sarajevo: Zavod za udžbenike i nastavna sredstva.

50. Vilendečić, S. (2008). *Monetarna politika, devizni kurs i monetarna unija.* Banja Luka: Besjeda.

51. Vučković, M. (1958). *Bankarstvo.* Beograd.

52. Vunjak, N. (1999). *Finansijski menadžment.* Beograd: Ekonomski fakultet.

53. Vunjak, N. (2008). *Finansijski menadžment - poslovne finansije.* Subotica: Ekonomski fakultet.

54. Vunjak, N., & Kovačević, L. (2002). *Poslovno bankarstvo: savremeni trendovi.* Bečej i Subotica: Proleter i Milen.

55. Vunjak, N., & Kovačević, L. (2006). *Bankarstvo, bankarski menadžment.* Bečej i Subotica: Proleter i Ekonomski fakultet.

56. Žager, K., & Žager, L. (2008). *Analiza finansijskih izvještaja.* Zagreb: Masmedia.

57. Žiravac Mladenović, M. (2011). *Uvod u poslovne finansije.* Banja Luka: Univerzitet za poslovni inženjering i menadžment.

58. Živko, I., & Kandžija, V. (2014). *Upravljanje bankama.* Rijeka, Mostar: Ekonomski fakultet Sveučilišta u Rijeci, Sveučilište i Ekonomski fakultet Sveučilišta u Mostaru.

Stručni članci i izvještaji:

1. Adebola, S., Wan Yusoff, S., & Dahalan, J. (2011). An ARDL Approach to the Determinants of Non-Performing Loans in Islamic Banking System in Malaysia. *Kuwait Chapter of Arabian Journal of Business and Management Review, 1*(2), 20 - 30.

2. Ahmad , F., & Bashir (a), T. (2013). Explanatory Power of Macroeconomic Variables as Determinants of Non-Performing Loans: Evidence from Pakistan. *World Applied Sciences Journal, 22*(2), 243 - 255.

3. Ahmad, F., & Basir (b), T. (2013). Explanatory Power of Bank Specific Variables as Determinants of Non-Performing Loans: Evidence from Pakistan Banking Sector. *World Applied Sciences Journal, 22*(9), 1200 - 1231.

4. Aiyagari, S., & Gertler, M. (1999). „Overreaction" of assets prices in general equilibrium. *Review of Economic Dynamics, 1*(2), 3 - 35.

5. Alihodžić, A. (2014). Analiza kretanja nekvalitetnih kredita i profitabilnosti na bankovnom tržištu u BiH. *Ekonomske teme, 52*(3), 341 - 359.

6. Alton, R., & Hazen, J. (2001). *As Economy Flounders, Do We See A Rise in Problem Loans?* St. Louis: Federal Reserve Bank of St. Louis.

7. Arpa, M., Giulini, I., Ittner, A., & Pauer, F. (2001). The influence of macroeconomic developments on Austrian banks: implications for banking supervision. *BIS Papers, 1*, str. 91 - 116.

8. Badar, M., & Javid, A. (2013). Impact of Macroeconomic Forces on Nonperforming Loans: an Empirical Study of Commercial Banks in Pakistan. *Journal of Transaction on Business and Economics, 10*(1), 40 - 48.

9. Barisitz, S. (2011). *Nonperforming Loans in CESEE - What Do They Comprise?* Preuzeto 16. 08. 2016 iz Focus on European Economic Integration Q4/11: https://www.oenb.at/dam/jcr:ba2e567b-97ab-4240-868c-419a226b9def/feei_2011_q4_studies_1_tcm16-241680.pdf

10. Barisitz, S. (2013). *Nonperforming Loans in CESEE - An Even Deeper Definitional Comparison.* Preuzeto 16. 08. 2016 iz Focus on European Economic Integration Q3/13: https://www.oenb.at/dam/jcr:07a8cd6f-9be6-4472-8ecf-51a5336c5977/feei_2013_q3_studies_barisitz_tcm16-257381.pdf

11. Barisitz, S. (2013). *Nonperforming Loans in Western Europe - A Selective Comparison of Countries and National Definitions.* Preuzeto 16. 08. 2016 iz Focus on European Economic Integration Q1/13: https://www.oenb.at/dam/jcr:bef7ec58-d7de-4bf1-a39d-accf0d339f3e/feei_2013_q1_studies_barisitz_tcm16-253775.pdf

12. Beck, R., Jakubik, P., & Piloiu, A. (2013). Non-performing Loans: What Matters in Addition to the Economic Cycle? *ECB Working Paper Series, 1515*.

13. Bejaković, P. (2003). Nezaposlenost. *Finansijska teorija i praksa, 4*(27), 659 - 661.

14. Berge, T., & Boye, K. (2007). *An analysis of bank's problem loan.* Nouges Bank Economic Balletin.

15. Berger, A., & DeYoung, R. (1997). Problem Loans and Cost Efficiency in Commercial Banks. *Journal of Banking and Finance, 21*, 849 - 870.

16. Bernanke, B., Gertler, M., & Gilchrist, S. (1999). The financial accelerator in a quantitative business cycle framework. *Handbook of macroeconomics, No. 1*.

17. Bexley, J., & Nenninger, S. (2012). Financial Institutions and the Economy. *Journal of Accounting and Finance, 12*(1).

18. Bhattarai, Y. (2016). Effect of Non-Performing Loan on the Profitability of Commercial Banks in Nepal. *The International Journal of Business & Management, 4*(6), 435 - 442.

19. Block, F. (1981). Unemployment: causes and cures. *Coto Institute Policy Analysis, 4*.

20. Boudriga, A., Taktak, N., & Jellouli, S. (2009). Banking supervision and nonperforming loans a cross-country analysis. *Journal of Financial Economic Policy, 1*(4), 286 - 318.

21. Boudriga, A., Taktak, N., & Jellouli, S. (2010). Bank specific, business and institutional environment determinants of banks nonperforming loans: Evidence from MENA countries. *Working Paper Series, 547*.

22. Calderon, C., & Kubota, M. (2012). Gross Inflows Gone Wild: Gross Capital Inflows, Credit Booms and Crises. *World Bank Policy Research Working Paper, No. 6270*.

23. Caprio, G., & Klingebiel, D. (1996). Bank Insolvency: Bad Luck, Bad Policy or Bad Banking. *Annual World Bank Conference on Development Economics*. The International Bank for Reconstruction and Development.

24. Chimkono, E., Muturi, W., & Njeru, A. (2016). Effect of Non-Performing Loans and Other Factors on Performance of Commercial Banks in Malawi. *International Journal of Economics, Commerce and Management*, 549 - 563.

25. Collins, N., & Wanjau, K. (2011). Collins,The effects of interest rate spread on the level of non-performing assets: A case of commercial banks in Kenya. *International Journal of Business and Public Management, 1*(1), 58 - 65.

26. Cottarelli, C., Dell' Ariccia, G., & Vladkova - Hollar, I. (2003). Early Birds, Late Risers and Sleeping Beauties: Bank Credit Growth to the Private Sector in Central and Eastern Europe and the Balkans. *IMF Working Paper, 213/03*.

27. Dell' ariccia, G., Igan, D., Leaven, L., & Tong, H. (2012). Policies for Macrofinancial Stability: How to Deal with Credit Booms. *IMF Staff Discussion Note, No. 12/06*.

28. Đoković, N. (2008). Operativni rizici u bankarskom poslovanju: vjerovatnoća ostvarivanja gubitaka. *Magazin CGekonomist, 10*.

29. Elekdag, S., & Wu, Y. (2013). Rapid Credit Growth in Emerging Markets: Boom or Boom – Bust? *Emerging Markets Finance and trade, 5*(45), 45 - 62.

30. Espinoza, R., & Prasad, A. (2010). Nonperforming Loans in the GCC Banking System and their Macroeconomic Effects. *IMF Working Paper, 224/10*.

31. Filipović, S., & Nikolić, I. (2008). Kreditna ekspanzija vs. makroekonomska (ne)stabilnost. *Industrija, 3/2008*, 61 - 78.

32. Gambera, M. (2000). Simple Forecasts of Bank Loan Quality in the Business Cycle. *Emerging Issues Series*.

33. Ganić, M. (2014). Bank Specific determinants of Credit Risk - An Empirical Study on the Banking Sector of Bosnia and Herzegovina. *International Journal of Economic Practices and Theories, 4*(4), 428 - 436.

34. Guy, K. (2011). Non - performing Loans. *The Central Bank of Barbados Economic Review, XXXVII*(1).

35. Ivaniš, M. (2012). Rizici u bankarskom poslovanju. *Pravno - Ekonomski Pogledi*(3/2012), 1 - 15.

36. Jakubik, P., & Reininger, T. (2013). Determinants of Nonperforming Loans in Central, Eastern and Southeastern Europe. *Focus on European Economic Integration, Q3/13*, str. 48 - 66.

37. Jameel, K. (2014). Crucial Factors of Nonperforming loans Evidece from Pakistani Banking Sector. *International Journal of Scientific & Engineering Research, 5*(7), 704 - 710.

38. Jeremić, Z. (2014). Bankarstvo u Srbiji u periodu 2000 – 2013. *130 godina Narodne banke Srbije - Ko je ko u finansijskom sektoru*, 34 - 51.

39. Jimenez, G., & Saurina, J. (2006). Credit Cycles, Credit Risk and Prudential Regulation. *International Journal of Central Banking, 2*(2), 65 - 98.

40. Jović, D., & Jandrić, M. (2016). Determinante kreditnog rasta u bankarskom sektoru Bosne i Hercegovine. *Emc Review – Časopis za ekonomiju i tržišne komunikacije, 2*(6), 233 - 348.

41. Jović, Z. (2013). Uticaj kvaliteta aktive na adekvatnost kapitala banaka u Srbiji. *Zbornik radova sa 12. Međunarodnog naučnog skupa „Sinergija 2013“*. Bijeljina: Univerzitet Sinergija.

42. Jović, Z., & Vićentijević, K. (2015). Sektorska struktura problematičnih plasmana u Srbiji. *Zbornik radova Međunarodne naučne konferencije iz oblasti informacionih tehnologija i savremenog poslovanja „Synthesis 2015“*. Beograd: Univerzitet Singidunum.

43. Keeton, W., & Morris, C. (1987). *Why Do Banks' Loan Losses Differ.* Preuzeto 22. 08. 2016 iz Economic Review: http://www.kansascityfed.org/PUBLICAT/ECONREV/EconRevArchive/1987/2q87keet.pdf

44. Khemaj, T., & Pasha, S. (2009). The determinants of non-performing loans: an econometric case study of Guyana. *Munich Personal RePEc Archive, Paper No. 53128*.

45. Kiss, G., Nagy, M., & Vonnak, B. (2006). Credit growth in Central and Eastern Europe: Convergence or boom? *MNB Working Papers, No. 10/2006*.

46. Kiyotaki, N., & Moore, J. (1995). Credit cycle. *NBER Working Paper Series, No. 5083*, 211 - 248.

47. Klein, N. (2013). Non-Performing Loans in CESEE: Determinants and Impact on Macroeconomic Performance. *IMF Working Paper, 72/13*.

48. Lane, C. (2002). *An analysis of the Causes of Unemployment.* Preuzeto 02. 03. 2017 iz Scribd: https://www.scribd.com/document/47409218/An-Analysis-of-the-Causes-of-Unemployment

49. Levine, M., & Hoffmann, D. (2000). Enriching the Universe of Operational Risk Data: Getting Started on Risk Profiling. *Operational Risk*, 25 - 39.

50. Kozarić, K. (2007). Modeli monetarne politike sa osvrtom na valutni odbor Bosne i Hercegovine. *Specijalne teme istraživanja, STI/01/07*.

51. Kožul, N. (2012). Metodologija kreditnog rejtinga za suverene i korporacije. *Bankarstvo*(1/2012), 36 - 55.

52. Louzis, D., Vouldis, A., & Metaxas, V. (2010). Macroeconomic and Bank-Specific Determinants of Non-Performing Loans in Greece: A Comparative Study of Mortgage, Business and Consumer Loan Portfolios. *Bank of Greece Working Paper, 118*.

53. Ljumović, I., Marinković, S., & Pejović, B. (2011). Efikasnost i profitabilnost banaka - koliko su koncepti međusobno isključivi? *Industrija, 4*, 43 - 56.

54. Makri, V., Tsagkanos, A., & Bellas, A. (2014). Determinants of Non-Performing Loans: The Case of Eurozone. *Panoeconomicus, 2*, 193 - 206.

55. Mendoza, E., & Terrones, M. (2004). Are credit booms in emerging markets a concern. *World Economic Outlook*.

56. Mendoza, E., & Terrones, M. (2008). An Anatomy of Credit Booms: Evidence from Macro Aggregates and Micro Data. *NBER Working Paper, No. 14049*.

57. Messai, A., & Jouini, F. (2013). Micro and Macro Determinants of Non-performing Loans. *International Journal of Economics and Financial Issues, 3*(4), 852 - 860.

58. Milošević, M. (2014). Upravljanje rizikom likvidnosti. *Bankarstvo*(1/2014), 12 - 27.

59. Mirković, V. (2016). Rješavanje problema nenaplativih potraživanja kao esencijalni faktor stabilnosti bankarskog sistema. Preuzeto 25. 05. 2017 iz http://www.meste.org/fbim/fbim_srpski/FBIM_najava/IVK_Mirkovic.pdf

60. Nkusu, M. (2011). Nonperforming Loans and Macrofinancial Vulnerabilities in Advanced Economies. *IMF Working Paper, 161/11*.

61. Otašević, D. (2013). *Macroeconomic determinants of the quality of banks' loan portfolio in Serbia.* Preuzeto 2016 iz Narodna banka Srbije: http://www.nbs.rs/internet/english/90/90_0/2013_27_DO.pdf

62. Ottens, D., Lambregts, E., & Poelhekke, S. (2005). *Credit Booms in Emerging Market Economies: A Recipe for Banking Crises?* Amsterdam: De Nederlandsche Bank.

63. Pavković, A. (2004). Instrumenti vrednovanja uspješnosti poslovnih banaka. *Zbornik ekonomskog fakulteta u Zagrebu* (str. 179 - 192). Zagreb: Ekonomski fakultet.

64. Pelagidis, T. (1998). European Unemployment: Myths and Realities. *Challenge: The Magazine of Economic Affairs, 41*(4), 76 - 89.

65. Pradhan, R., & Pandey, A. (2016). *Bank Specific and Macroeconomic Variables Affecting Non-Performing Loans of Nepalese Commercial Banks.* Preuzeto 23. 08. 2016 iz Social Science Research Network: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2793495

66. Prošić, D. (2014). Kamate i skrivene zamke metoda obračuna kamate. *Bankarstvo, 3/2014*, 38 - 81.

67. Ranisavljević, D., & Hadžić, M. (2015). Problematični krediti stanovništva u Srbiji. *Zbornik radova Međunarodne naučne konferencije iz oblasti informacionih tehnologija i savremenog poslovanja „Synthesis 2015“*. Beograd: Univerzitet Singidunum.

68. Ranjan, R., & Dhal, S. (2003). Non-Performing Loans and Terms of Credit of Public Sector Banks in India: An Empirical Assessment. *Reserve Bank of India Occasional Papers, 24*(3), 81 - 121.

69. Rottke, N., & Gentgen, J. (2008). Workout management of non-performing loans, A formal model based on transaction cost economics. *Journal of Property Investment & Finance, 26*(1), 59 - 79.

70. Rousseau, P., & Wachtel, P. (2011). What Is Happening to the Impact of Financial Deepening on Economic Growth? *Economic Inquiry, 49*(1), 276 - 288.

71. Sa, S. (2007). Capital flows and credit booms in emerging market economies. *Financial Stability Review, No. 9*.

72. Saba, I., Kouser, R., & Azeem, M. (2012). Determinants of Non-performing Loans: Case of US Banking Sector. *The Romanian Economic Journal, 44*.

73. Salas, V., & Saurina, J. (2002). Credit Risk in Two Institutional Regimes: Spanish Commercial and Savings Banks. *Journal of Financial Services Research, 22*(3).

74. Shingjergji (a), A. (2013). The Impact of Macroeconomic Variables on the Non Performing Loans in the Albanian Banking System During 2005 – 2012. *Academic Journal of Interdisciplinary Studies, 2*(9), 335 - 339.

75. Shingjergji (b), A. (2013). The Impact of Bank Specific Variables on the Non Performing Loans in the Albanian Banking System. *Research Journal of Finance and Accounting, 4*(7), 148 - 152.

76. Sinkey, J., & Greenawalt, M. (1991). Loan – loss experience and risk – taking behavior at large commercial banks. *Journal of Financial Services Research, 5*(1), 43 - 59.

77. Stakić, N. (2014). Determinante kretanja nivoa problematičnih kredita u bankarskom sektoru Srbije. *Bankarstvo, 4/2014*, 122 - 145.

78. Swamy, V. (2012). Impact of macroeconomic and endogenous factors on non performing bank assets. *International Journal of Banking and Finance, 9*(1), 27 - 47.

79. Škare, M. (2001). Nezaposlenost u Hrvatskoj i determinante potražnje za radim. *Revija za socijalnu politiku, 8*(1), 19 - 34.

80. Škarica, B. (2014). Determinants of non-performing loans in Central and Eastern European countries. *Financial Theory and Practice, 38*(1), 37 - 59.

81. Tanasković, S., & Jandrić, M. (2017). Problematični krediti: determinante rasta i moguća rješenja. *Kvartalni monitor, 39*, 75 - 85.

82. Todorović, T. (2009). Upravljanje kreditnim rizikom u banci. *Ekonomski horizonti, 11*(2), 81 - 99.

83. Tomak, S. (2013). Determinants of Commercial Banks Lending Behavior: Evidence from Turkey. *Asian Journal of Empirical Research, 3*(8), 933 - 943.

84. Tornell, A., & Westermann, F. (2002). Boom – Bust Cycles in Middle Income Countries: Facts and Explanation. *IMF Staff Papers, 9*.

85. Tuce, N. (2012). Politika kamatnih stopa. *Zbornik radova 13.-tog Međunarodnog simpozija: Fiskalni okvir i održivi razvoj BiH* (str. 553 - 568). Sarajevo: Revicon.

86. Turan, G., & Koskija, A. (2014). Nonperforming Loans in Albania. *Academic Journal of Interdisciplinary Studies, 3*(3), 491 - 500.

87. Vunjak, N., & Antonijević, S. (2012). Strategija upravljanja kreditnim portfoliom banke. *Montenegrin Journal of Economics, 04*(07), 47 - 54.

88. Živko, I. (2006). Kamatni rizik u bankarstvu - izvori i učinci. *Ekonomska misao i praksa, 2*, 199 - 214.

Neautorizovani izvori:

1. Agencija za bankarstvo FBiH. (2007). *Informacija o bankarskom sistemu Federacije Bosne i Hercegovine 31.12.2006.* Sarajevo: Agencija za bankarstvo Federacije Bosne i Hercegovine.
2. Agencija za bankarstvo RS. (2010). *Izvještaj o stanju u bankarskom sistemu Republike Srpske za period 01.01.2009. - 31.12.2009.* Banja Luka: Agencija za bankartsvo Republike Srpske.
3. Basel Committee on Banking Supervision. (2003). *Principales for the Management and Supervision of Interest Rate.* Bank for International Settlements.
4. BIS. (2006). *Basel II: International Convergence of Capital Measurement and Capital Standards, A revised Framework, Comprehensive Version.* Preuzeto 16. 08. 2016 iz Basel Commitee on Banking Supervision: http://www.bis.org/publ/bcbs118.htm
5. CBBiH. (2001). *Godišnji izvještaj 2000.* Sarajevo: Centralna banka Bosne i Hercegovine.
6. CBBiH. (2006). *Godišnji izvještaj 2005.* Sarajevo: Centralna banka Bosne i Hercegovine.
7. CBBiH. (2015). *Strateški plan 2016 - 2021.* Preuzeto 18. 04. 2017 iz Centralna banka BiH: http://www.cbbh.ba/Content/Read/1024
8. CBBiH. (2016). *Godišnji izvještaj 2015.* Sarajevo: Centralna banka Bosne i Hercegovine.
9. CBBIH. (2017). Metodologija za kompiliranje indikatora finansijskog zdravlja. Sarajevo: Centralna banka Bosne i Hercegovine.
10. Consulting Barents Group. (2003). *Osnovni principi Bazel I.*
11. EBA. (2014). *EBA Final draft Implementing Technical Standards: On Supervisory reporting on forbearance and non-performing exposures under article 99 (4) of Regulation (EU) No 575/2013.* Preuzeto 18. 08. 2016 iz European Banking Authority - EBA: https://www.eba.europa.eu/documents/10180/449824/EBA-ITS-2013-03+Final+draft+ITS+on+Forbearance+and+Non-performing+exposures.pdf
12. European Banking Coordination "Vienna" Initiative. (mart 2012). *Working Group on NPLs in Central, Eastern and Souteastern Europe.* Preuzeto 18. 08. 2016 iz https://www.imf.org/external/region/eur/pdf/2012/030112.pdf
13. IFC Corporation Advisory Services, access to Finance. (2011). *Corporate and SME Workouts: A manual of Best Practice.* Washington: International Finance Corporation.
14. IIF. (1999). *Report of the Working Group on Loan Quality.* Preuzeto 16. 08. 2016 iz Institute for International Finance: https://www.iif.com/

15. IMF. (2006). *The Financial Soundness Indicators Compilation Guide of March 2006.* Preuzeto 16. 08. 2016 iz International Monetary Fund: https://www.imf.org/external/pubs/ft/fsi/guide/2006/pdf/fsiFT.pdf

16. Moody's Investors Service. (2016). *Rating Methodology Banking.* Preuzeto 05. 06. 2017 iz Moody's Investors Service: https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_186998

Zakoni:

1. CBBiH. (2011). Odluka o minimalnim standardima za upravljanje kreditnim rizikom i klasifikaciju aktive banaka. Službeni glasnik RS, br. 49/13 i Službene novine Federacije BiH, br. 85/11, 33/12, 110/12, 15/13.
2. Zakon o bankama. (1998). Zakon o bankama - nezvanično prečišćen tekst. Službene novine Federacije BiH.
3. Zakon o bankama Republike Srpske. (2017). Zakon o bankama Republike Srpske. Službeni glasnik RS.
4. Zakon o Centralnoj banci Bosne i Hercegovine. (1997). Zakon o Centralnoj banci Bosne i Hercegovine. Službeni glasnik BiH.
5. Zakon o osiguranju depozita. (2002). Zakon o osiguranju depozita - prečišćen tekst. Službeni glasnik BiH.

Internet izvori:

1. Agencija za bankarstvo FBiH: http://www.fba.ba
2. Agencija za bankarstvo RS: http: //www.abrs.ba
3. Agencija za nadzor osiguranja FBiH: http://www.nados.ba
4. Agencija za osiguranje RS: http://azors.rs.ba
5. Centralna banka BiH: http://www.cbbh.ba
6. Statistički portal Centralne banke Bosne i Hercegovine: http://statistics.cbbh.ba:4444/Panorama/novaview/SimpleLogin_sr.aspx
7. Fitch Ratings: https://www.fitchratings.com/site/home
8. Komisija za hartije od vrijednosti RS: http://www.secrs.gov.ba
9. Komisija za vrijednosne papire FBiH: http://www.komvp.gov.ba
10. Standard and Poor's: https://standardandpoors.com
11. World bank: http://www.worldbank.org

PRILOZI

1. Popis tabela

Tabela 1: Definicije nekvalitetnih kredita (NPL) u različitim zemljama 17

Tabela 2: Analiza nacionalnih definicija nekvalitetnih kredita na razvijenim finansijskim tržištima 18

Tabela 3: Analiza definicija nekvalitetnih kredita u Crnoj Gori, Hrvatskoj, Makedoniji, Sloveniji i Srbiji 19

Tabela 4: Klasifikacija kredita u skladu sa klasifikacijom aktive prema međunarodnim standardima 20

Tabela 5: Pregled studija sprovedenih u pojedinačnim zemljama 31

Tabela 6a: Pregled studija sprovedenih u više zemalja (2009-2012) 36

Tabela 6b: Pregled studija sprovedenih u više zemalja (2013-2014) 37

Tabela 7: Pregled specifičnih bankarskih promjenljivih i testiranih hipoteza 51

Tabela 8: Aktiva finansijskog sektora BiH (2006 – 2015) 59

Tabela 9: Struktura finansijskog sektora BiH (2006 – 2015) 60

Tabela 10: Broj komercijalnih banaka u BiH (2006 – 2015) 66

Tabela 11: Vlasnička struktura komercijalnih banaka u BiH (2006 – 2015) 67

Tabela 12: Vlasnička struktura komercijalnih banaka u RS (2006 – 2015) 68

Tabela 13:Učešće državnog i privatnog kapitala u akcionarskom kapitalu banaka u RS (2006 - 2015) 68

Tabela 14: Vlasnička struktura komercijalnih banaka u FBiH (2006 – 2015) 69

Tabela 15: Učešće državnog i privatnog kapitala u akcionarskom kapitalu banaka u FBiH (2006 - 2015) 69

Tabela 16: Broj zaposlenih u bankarskom sektoru BiH (2006 – 2015) 70

Tabela 17: Kvalifikaciona struktura zaposlenih u bankarskom sektoru BiH (2006 – 2015) 71

Tabela 18: Konsolidovani bilans komercijalnih banaka u BiH (2006 – 2015) – AKTIVA 74

Tabela 19: Konsolidovani bilans komercijalnih banaka u BiH (2006 – 2015) – PASIVA 75

Tabela 20: Osnovni kapital, neto kapital i ukupan rizik aktive bankarskog sektora BiH (2006 - 2015) 78

Tabela 21: Pregled nezavisnih promjenljivih, očekivani predzanak i izvor iz koga su prikupljeni podaci 104

Tabela 22: Rezultati deskriptivne statistike 118

Tabela 23: Rezultati testova normalnosti raspodjele 120

Tabela 24: Transformacija promjenljivih 121

Tabela 25: Rezultati testova normalnosti raspodjele nakon transformacije promjenljivih 121

Tabela 26: Korelacija – rezultat istraživanja za stopu rasta realnog BDP-a (promjenljiva GDP) ... 124
Tabela 27: Korelacija – rezultat istraživanja za stopu nezaposlenosti (promjenljiva TUNEMP) ... 126
Tabela 28: Korelacija – rezultat istraživanja za stopu inflacije (promjenljiva TICP) ... 127
Tabela 29: Korelacija – rezultat istraživanja za koeficijent adekvatnosti kapitala (promjenljiva CAR) ... 128
Tabela 30: Korelacija – rezultat istraživanja za odnos kredita i depozita (promjenljiva TLTD) ... 129
Tabela 31: Korelacija – rezultat istraživanja za prinos na aktivu (promjenljiva ROA) ... 131
Tabela 32: Korelacija – rezultat istraživanja za prinos na akcijski kapital (promjenljiva ROE) ... 132
Tabela 33: Korelacija – rezultat istraživanja za aktivnu kamatnu stopu (promjenljiva IR) ... 133
Tabela 34: Korelacija – rezultati istraživanja za stopu kreditnog rasta (promjenljiva TCG) ... 135
Tabela 35: Prosta regresija – *Model Summary* (promjenljiva GDP) ... 135
Tabela 36: Prosta regresija – *ANOVA* (promjenljiva GDP) ... 140
Tabela 37: Prosta regresija – *Model Summary* (promjenljiva TUNEMP) ... 141
Tabela 38: Prosta regresija – *ANOVA* (promjenljiva TUNEMP) ... 142
Tabela 39: Prosta regresija – *Model Summary* (promjenljiva TICP) ... 143
Tabela 40: Prosta regresija – *ANOVA* (promjenljiva TICP) ... 144
Tabela 41: Prosta regresija – *Coefficients* (promjenljiva TICP) ... 145
Tabela 42: Prosta regresija – *Model Summary* (promjenljiva CAR) ... 147
Tabela 43: Prosta regresija – *ANOVA* (promjenljiva CAR) ... 148
Tabela 44: Prosta regresija – *Model Summary* (promjenljiva TLTD) ... 149
Tabela 45: Prosta regresija – *ANOVA* (promjenljiva TLTD) ... 150
Tabela 46: Prosta regresija – *Model Summary* (promjenljiva ROA) ... 152
Tabela 47: Prosta regresija – *ANOVA* (promjenljiva ROA) ... 152
Tabela 48: Prosta regresija – *Coefficients* (promjenljiva ROA) ... 153
Tabela 49: Prosta regresija – *Model Summary* (promjenljiva ROE) ... 155
Tabela 50: Prosta regresija – *ANOVA* (promjenljiva ROE) ... 155
Tabela 51: Prosta regresija – *Model Summary* (promjenljiva IR) ... 157
Tabela 52: Prosta regresija – *ANOVA* (promjenljiva IR) ... 158
Tabela 53: Prosta regresija – *Coefficients* (promjenljiva IR) ... 158
Tabela 54: Prosta regresija – *Model Summary* (promjenljiva TCG) ... 160
Tabela 55: Prosta regresija – *ANOVA* (promjenljiva TCG) ... 161
Tabela 56: Prosta regresija – *Coefficients* (promjenljiva TCG) ... 161
Tabela 57: Višestruka regresija – *Coefficients* (provjera multikolinearnosti) ... 164

Tabela 58: Višestruka regresija – *Model Summary* 165
Tabela 59: Višestruka regresija – *ANOVA* 166
Tabela 60: Višestruka regresija – *Coefficients* 167
Tabela 61: Rezultati ankete – faktori koji utiču na nekvalitetne kredite 177
Tabela 62: Rezultati ankete – značaj finansijskih promjenljivih za procjenu kreditnog rizika 182
Tabela 63: Rezultati ankete – značaj nefinansijskih promjenljivih za procjenu kreditnog rizika 183
Tabela 64: Pregled analiziranih promjenljivih i dobijenih rezultata istraživanja 189
Tabela 65: Nekvalitetni krediti u bankarskim sektorima zemalja regiona (2006 - 2015) 192
Tabela 66: Nekvalitetni krediti u bankarskim sektorima razvijenih zemalja (2006 - 2015) 195

2. Popis grafikona

Grafikon 1: Aktiva finansijskog sektora BiH (2006 – 2015) 59
Grafikon 2: Aktiva finansijskog sektora RS i aktiva finansijskog sektora FBiH (2006 – 2015) 61
Grafikon 3: Struktura finansijskog sektora RS (2006 – 2015) 62
Grafikon 4: Struktura finansijskog sektora FBiH (2006 – 2015) 62
Grafikon 5: Kvalifikaciona struktura zaposlenih u bankarskom sektoru BiH (2006 – 2015) 71
Grafikon 6: Nekvalitetna aktiva i rezervisanja za nekvalitetnu aktivu u BiH (2006 – 2015) 76
Grafikon 7: Učešće nekvalitete u ukupnoj aktivi bankarskog sektora BiH (2006 – 2015) 77
Grafikon 8: Koeficijent adekvatnosti kapitala bankarskog sektora BiH (2006 – 2015) 79
Grafikon 9: Pokazatelji likvidnosti bankarskog sektora BiH (2006 – 2015) 80
Grafikon 10: Pokazatelji profitabilnosti bankarskog sektora BiH (2006 – 2015) 81
Grafikon 11: Ukupni depoziti bankarskog sektora BiH (2006 – 2015) 84
Grafikon 12: Prenosivi i ostali depoziti bankarskog sektora BiH (2006 – 2015) 85
Grafikon 13: Valutna struktura depozita bankarskog sektora BiH (2006 – 2015) 85
Grafikon 14: Učešće depozita u domaćoj i stranoj valuti u ukupnim depozitima (2006 – 2015) 86
Grafikon 15: Sektorska struktura prenosivih depozita bankarskog sektora BiH (2006 – 2015) 87
Grafikon 16: Prenosivi depoziti vladinog i nevladinog sektora u bankarskom sektoru BiH (2006 – 2015) 87
Grafikon 17: Prenosivi depoziti stanovništva u bankarskom sektoru BiH (2006 – 2015) 88
Grafikon 18: Sektorska struktura ostalih depozita bankarskog sektora BiH (2006 – 2015) 89
Grafikon 19: Ostali depoziti vladinog i nevladinog sektora u bankarskom sektoru BiH (2005 – 2015) 89
Grafikon 20: Ostali depoziti stanovništva u bankarskom sektoru BiH (2006 – 2015) 90
Grafikon 21: Ukupni krediti bankarskog sektora BiH (2006 – 2015) 91
Grafikon 22: Kratkoročni i dugoročni krediti bankarskog sektora BiH (2006 – 2015) 91
Grafikon 23: Učešće kratkoročnih i dugoročnih kredita u ukupnim kreditima (2006 – 2015) 92
Grafikon 24: Valutna struktura kredita bankarskog sektora BiH (2006 – 2015) 92
Grafikon 25: Sektorska struktura kratkoročnih kredita bankarskog sektora BiH (2006 – 2015) 94
Grafikon 26: Sektorska struktura dugoročnih kredita bankarskog sektora BiH (2006 – 2015) 95
Grafikon 27: Stopa rasta realnog BDP-a u BiH (2006 – 2015) 111
Grafikon 28: Stopa nezaposlenosti u BiH (2006 – 2015) 111
Grafikon 29: Stopa rasta potrošačkih cijena BiH (2006 – 2015) 112

Grafikon 30: Nekvalitetni krediti bankarskog sektora BiH (2006 – 2015) 114
Grafikon 31: Koeficijent adekvatnosti kapitala bankarskog sektora BiH (2006 – 2015) 114
Grafikon 32: Odnos kredita i depozita bankarskog sektora BiH (2006 – 2015) 115
Grafikon 33: Prinos na aktivu i prinos na akcijski kapital u bankarskom sektoru BiH (2006 – 2015) 115
Grafikon 34: Aktivna kamatna stopa u bankarskom sektoru BiH (2006 – 2015) 116
Grafikon 35: Kreditni rast u bankarskom sektoru BiH (2006 – 2015) 116
Grafikon 36: Trend kretanja nekvalitetnih kredita u bankarskom sektoru BiH (2006 – 2015) 169
Grafikon 37: Trend kretanja nekvalitetnih kredita u bankarskom sektoru RS (2006 – 2015) 170
Grafikon 38: Trend kretanja nekvalitetnih kredita u bankarskom sektoru FBiH (2006 – 2015) 171
Grafikon 39: Rezultati ankete - procjena informisanosti o nekvalitetnim kreditima 172
Grafikon 40: Rezultati ankete - izvor informacija o nekvalitetnim kreditima 173
Grafikon 41: Rezultati ankete - upravljanje kreditnim rizikom u komercijalnim bankama 173
Grafikon 42: Rezultati ankete – mjerenje kreditnog rizika u komercijalnim bankama 174
Grafikon 43: Rezultati ankete – zakonska regulativa u domenu upravljanja kreditnim rizikom 175
Grafikon 44: Rezultati ankete – unapređenje upravljanja kreditnim rizikom 175
Grafikon 45: Rezultati ankete – nivo nekvalitetnih kredita u bankarskom sektoru BiH 176
Grafikon 46: Rezultati ankete – narušavanje stabilnosti finansijskog sistema BiH 176
Grafikon 47: Rezultati ankete – kriterijumi za klasifikaciju nekvalitetnih plasmana 178
Grafikon 48: Rezultati ankete – objavljivanje izvještaja o kreditnom riziku 178
Grafikon 49: Rezultati ankete – ključni uzroci nastanka nekvalitetnih kredita 179
Grafikon 50: Rezultati ankete – uspješnost procesa sanacije rizičnih plasmana u BiH 179
Grafikon 51: Rezultati ankete – efikasnost rješavanja problema nekvalitetnih kredita 180
Grafikon 52: Rezultati ankete – promjena procesa upravljanja kreditnim rizikom 180
Grafikon 53: Rezultati ankete – faktori koji utiču na kvalitet plasmana fizičkim licima 181
Grafikon 54: Rezultati ankete – modeli kreditnog rejtinga 182
Grafikon 55: Trend kretanja nekvalitetnih kredita u zemljama regiona (2006 – 2015) 191
Grafikon 56: Trend kretanja nekvalitetnih kredita u razvijenim zemljama (2006 – 2015) 194
Grafikon 57: Učešće nekvalitetnih u ukupnim kreditima bankarskih sektora BiH i zemalja regiona 196
Grafikon 58: Učešće nekvalitetnih u ukupnim kreditima bankarskih sektora BiH i razvijenih zemalja 197

3. Popis slika

Slika 1: Makro pristup (*Moody's*) 40
Slika 2: Struktura solventnosti i likvidnosti (*Moody's*) 41
Slika 3: Konceptualni okvir istraživanja 42
Slika 4: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva GDP) 139
Slika 5: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva TUNEMP) 141
Slika 6: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva TICP) 143
Slika 7: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva CAR) 147
Slika 8: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva TLTD) 149
Slika 9: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva ROA) 151
Slika 10: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva ROE) 154
Slika 11: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva IR) 156
Slika 12: *Normal P-P Plot* i *Scatterplot* dijagrami (promjenljiva TCG) 159
Slika 13: *Normal P-P Plot* i *Scatterplot* dijagrami (višestruka linearna regresija) 165

4. Upitnik za bankarske menadžere

UPITNIK

Poštovani,

pred Vama se nalazi upitnik koji se odnosi na nekvalitetne kredite komercijalnih banaka u Bosni i Hercegovini. Upitnik se dostavlja rukovodiocima, menadžerima i radnicima komercijalnih banaka, sa ciljem dolaska do saznanja o uzrocima nastanka rizičnih kreditnih plasmana, kao i sa ciljem identifikacije faktora koji utiču na pojavu nekvalitetnih kredita.

Upitnik se sastoji od 20 pitanja sa više ponuđenih odgovora. Podaci će biti analizirani, a rezultati istraživanja će biti predstavljeni u doktorskoj disertaciji, u agregatnom obliku, tako da specifični podaci banke u kojoj ste zaposleni neće biti objavljeni ili korišteni u druge svrhe.

Molim Vas da na pitanja odgovorite iskreno i što preciznije, kako bi rezultati i zaključci ovog istraživanja pomogli da se poboljša upravljanje kreditnim rizikom u komercijalnim bankama, a samim tim smanji nivo nekvalitetnih kredita, kako u pojedinačnim bankama, tako i u cjelokupnom bankarskom sektoru Bosne i Hercegovine.

Hvala Vam na saradnji!

PODACI O ISPITANIKU

Pol:

a) muški
b) ženski

Starost:

a) manje od 20 godina
b) 20 – 25 godina
c) 26 – 35 godina
d) 36 – 45 godina
e) 56 – 55 godina
f) 56 – 65 godina

Obrazovanje:

a) srednja škola
b) viša škola (2 godine)
c) fakultet (3 – 4 godine)
d) postdiplomski studij (master / magistar / doktor nauka – *molim zaokružite*)

Koliko godina radite u banci?

a) manje od 5 godina
b) 5 – 10 godina
c) 11 – 20 godina
d) 21 – 30 godina
e) 31 – 40 godina

Da li ste pohađali seminare ili programe edukacije koji se odnose na upravljanje kreditnim rizikom i rizičnim plasmanima?

a) da
b) ne

Koja je Vaša pozicija u banci? _____

U kom organizacionom dijelu banke radite? _____

Banka u kojoj radite nalazi se u:

a) Republici Srpskoj
b) Federaciji Bosne i Hercegovine
c) Distriktu Brčko

Sjedište banke u kojoj radite je u:

a) Republici Srpskoj
b) Federaciji Bosne i Hercegovine
c) Distriktu Brčko

PITANJA O NEKVALITETNIM KREDITIMA

1. Procijenite koliko ste informisani o problematici nekvalitetnih kredita.

a) veoma dobro sam informisan/a
b) dobro sam informisan/a
c) donekle sam informisan/a
d) nisam informisan/a

2. Koji je Vaš glavni izvor pomoću koga se informišete o problematici nekvalitetnih kredita, odnosno o kreditnom riziku uopšte?

a) stručna literatura (knjige, stručni članci i slično)
b) internet
c) seminari i kursevi
d) naučne i stručne konferencije
e) preko regulatornih organa
f) na drugi način (*molim navedite*) _____

3. Da li se, u banci u kojoj radite, upravlja kreditnim rizikom, a samim tim i nekvalitetnim kreditima?

a) da
b) ne

4. Šta se, u banci u kojoj radite, mjeri unutar kreditnog rizika? ***Napomena: možete izabrati više ponuđenih odgovora.***

a) prosječna visina kredita
b) posebne rezerve
c) procjena kreditne sposobnosti pojedinačnog klijenta
d) procjena kreditne sposobnosti cijelog portfolia
e) procjena kreditne sposobnosti grupe povezanih lica
f) procjena kreditne sposobnosti sektora/djelatnosti
g) procjena kreditne sposobnosti geografskog položaja
h) procjena kreditne sposobnosti rizične grupe

5. Smatrate li da je važeća zakonska regulativa u domenu upravljanja kreditnim rizikom, uključujući upravljanje nekvalitetnim kreditima, dobra?

a) da
b) ne

6. Imajući u vidu problematiku nekvalitetnih kredita komercijalnih banaka u Bosni i Hercegovini, da li smatrate da je potrebno, u cilju unapređenja upravljanja kreditnim rizikom, modifikovati i preciznije definisati pravila i kriterijume za klasifikaciju dužnika i stopu izdvajanja obeveznih rezervi?

a) da
b) ne

7. Nivo nekvalitetnih kredita u bankarskom sektoru Bosne i Hercegovine je:

a) veoma visok (zabrinjavajući)
b) visok
c) srednji
d) nizak
e) nisam upoznat/a

8. Smatrate li da nivo i trendovi kretanja nekvalitetnih kredita mogu ugroziti stabilnost finansijskog sistema Bosne i Hercegovine u kratkom roku?

a) da
b) ne

9. Ocijenite značaj uticaja faktora koji su navedeni u tabeli na nivo nekvalitetnih kredita u bankarskom sektoru Bosne i Hercegovine.

R.B.	FAKTOR	VISOK UTICAJ	SREDNJI UTICAJ	NIZAK UTICAJ	NEMA UTICAJ
1.	Nivo i kretanje BDP-a				
2.	Nezaposlenost				
3.	Inflacija				
4.	Javni dug				
5.	Odnos kredita i depozita banaka				
6.	Adekvatnost kapitala banaka				
7.	Profitabilnost banaka				
8.	Nivo kamatnih stopa				
9.	Moralni hazard				

10. Da li je u banci u kojoj radite izvršena podjela rizičnih plasmana na: rani rizični plasmani, nekvalitetni plasmani srednjeg ranga rizičnosti i nekvalitetni plasmani visokog nivao rizika?

a) da
b) ne

11. Koji je osnovni kriterijum koji opredjeljuje nadležne organe banke u kojoj radite da određeni plasman klasifikuju kao rani rizični plasman, nekvalitetni plasman srednjeg ranga rizičnosti i nekvalitetni plasman visokog nivoa rizika.

a) broj dana kašnjenja
b) identifikovano pogoršanje određenih finansijskih pokazatelja
c) identifikovano nepoštovanje kovenanta (ugovornih ograničenja nametnutih od strane banke sa ciljem smanjenja rizika neizmirenja obaveza)

12. Izvještavanje o kreditnom riziku, a samim tim i o nivou nekvalitetnih kredita u kreditnom portfoliu banke u kojoj radite, je na:

a) sedmičnom nivou
b) mjesečnom nivou
c) kvartalnom nivou
d) godišnjem nivou
e) ovakvi izvještaji ne postoje

13. Odaberite ključne uzroke nastanka nekvalitetnih kredita, odnosno uzroke migracije kreditnih plasmana u nekvalitetne kreditne plasmane. ***Napomena: možete izabrati više ponuđenih odgovora.***

a) neadekvatna metodologija za procjenu kreditnog rizika
b) nepotpune i nepouzdane kreditne informacije
c) neefikasna organizaciona struktura
d) distorzije u kreditnom procesu (npr. odobravanje plasmana pod uticajem određenih interesnih grupa, odobravanje plasmana veoma visokog stepena rizika i slično)
e) makroekonomski faktori
f) specifičnosti određene privredne ili industrijske grane

14. Smatrate li da je dosadašnji proces sanacije rizičnih plasmana u Bosni i Hercegovini, preko različitih modaliteta (npr. restrukturiranje kredita), uspješan?

a) da
b) ne

15. Koji je, po Vama, najznačajniji razlog koji utiče na efikasnost rješavanja problema nekvalitetnih kredita?

a) neadekvatna kolateralizacija plasmana i nemogućnost naplate iz sekundarnih izvora
b) regulatorna ograničenja
c) nepovoljna situacija na tržištu nekretnina u Bosni i Hercegovini
d) drugo (*molim navedite*): _____

16. Da li je, u banci u kojoj radite, planirano da se u narednom periodu promijeni i unaprijedi proces upravljanja kreditnim rizikom ?

a) da
b) ne

17. Posmatrajući samo plasmane fizičkim licima, odredite koji je osnovni faktor koji utiče na pojavu nekvalitetnih kredita.

a) visoka zaduženost fizičkog lica
b) smanjenje ličnih primanja fizičkog lica
c) prekid radnog odnosa fizičkog lica
d) povećanje cijena osnovnih životnih namirnica
e) povećanje cijena električne energije, komunalnih i PTT usluga
f) promjena (povećanje) kamatnih stopa

18. Posmatrajući samo plasmane pravnim licima, navedite da li modeli kreditnog rejtinga sadrže kombinaciju finansijskih i nefinansijskih promjenljivih.

a) da, sadrže kombinaciju finansijskih i nefinansijskih promjenljivih
b) ne, sadrže samo finansijske promjenljive
c) ne, sadrže samo nefinansijske promjenljive

19. Ocijenite značaj finansijskih promjenljivih za procjenu kreditnog rizika privrednog subjekta.

R.B.	PROMJENLJIVA	1 – nije značajna	2 – nizak nivo značaja	3 – srednji nivo značaja	4 – visok nivo značaja	5 – veoma visok nivo značaja
1.	Racio tekuće likvidnosti					
2.	Tokovi gotovine iz poslovnih aktivnosti / kratkoročne finansijske obaveze					
3.	Tokovi gotovine iz poslovnih aktivnosti / ukupna aktiva					
4.	EBITDA / tokovi gotovine iz poslovnih aktivnosti					
5.	Kratkoročne obaveze / obrtna imovina					
6.	Neto obrtni kapital / ukupna aktiva					
7.	Ukupan dug / EBITDA					
8.	Dugoročne obaveze / EBITDA					
9.	Ukupne obaveze / ukupna aktiva					
10.	Racio pokrića kamata					
11.	Kapital / osnovna sredstva					

20. Ocijenite značaj nefinansijskih promjenljivih za procjenu kreditnog rizika privrednog subjekta.

R.B.	PROMJENLJIVA	1 – nije značajna	2 – nizak nivo značaja	3 – srednji nivo značaja	4 – visok nivo značaja	5 – veoma visok nivo značaja
1.	Starost preduzeća					
2.	Veličina (posmatrana preko ukupne aktive)					
3.	Veličina (posmatrana preko broja zaposlenih)					
4.	Veličina (posmatrana preko ukupnih prihoda)					
5.	Vrsta djelatnosti					

ANALIZA FAKTORA KOJI UTIČU NA RAST NEKVALITETNIH KREDITA U BANKARSKOM SEKTORU BOSNE I HERCEGOVINE

ORIGINALITY REPORT

7%

SIMILARITY INDEX

PRIMARY SOURCES

1	www.cbbh.ba Internet	543 words — 1%
2	www.fba.ba Internet	299 words — < 1%
3	www.blc.edu.ba Internet	268 words — < 1%
4	cbbh.ba Internet	241 words — < 1%
5	union.edu.rs Internet	205 words — < 1%
6	www.taylors.edu.my Internet	184 words — < 1%
7	nardus.mpn.gov.rs Internet	179 words — < 1%
8	darhiv.ffzg.unizg.hr Internet	150 words — < 1%
9	www.ijf.hr Internet	117 words — < 1%
10	www.cbcg.me Internet	110 words — < 1%

11	www.singipedia.singidunum.ac.rs Internet	106 words —	< 1%
12	id.scribd.com Internet	96 words —	< 1%
13	www.fren.org.rs Internet	92 words —	< 1%
14	open.uct.ac.za Internet	89 words —	< 1%
15	www.azobih.gov.ba Internet	88 words —	< 1%
16	etd.gsu.edu Internet	82 words —	< 1%
17	Zorana Agić. "Negativni efekti globalne finansijske krize u bankarskom sektoru Bosne i Hercegovine", Proceedings of the International Scientific Conference - Synthesis 2015, 2015 Crossref	71 words —	< 1%
18	www.bankofengland.co.uk Internet	67 words —	< 1%
19	www.mendeley.com Internet	65 words —	< 1%
20	fr.scribd.com Internet	62 words —	< 1%
21	www.eknfak.ni.ac.rs Internet	62 words —	< 1%
22	cbcg.me Internet	57 words —	< 1%
23	idoc.vn Internet	56 words —	< 1%

24	nemir.weebly.com Internet	55 words — < 1%
25	e-lib.efst.hr Internet	52 words — < 1%
26	ideas.repec.org Internet	50 words — < 1%
27	www.crocc.org Internet	48 words — < 1%
28	www.qurtuba.edu.pk Internet	48 words — < 1%
29	www.meste.org Internet	47 words — < 1%
30	www-wds.worldbank.org Internet	45 words — < 1%
31	portal.sinteza.singidunum.ac.rs Internet	44 words — < 1%
32	fov.uni-mb.si Internet	44 words — < 1%
33	Eftychia Nikolaidou, Sofoklis Vogiazas. "Credit risk determinants in Sub-Saharan banking systems: Evidence from five countries and lessons learnt from Central East and South East European countries", Review of Development Finance, 2017 Crossref	43 words — < 1%
34	www.jofamericanscience.org Internet	42 words — < 1%
35	www.scribd.com Internet	41 words — < 1%
36	0350-0373, 2008	

Publications

40 words — < 1 %

37 pt.slideshare.net
Internet

40 words — < 1%

38 Awatef Louhichi, Younes Boujelbene. "Credit risk, managerial behaviour and macroeconomic equilibrium within dual banking systems: Interest-free vs. interest-based banking industries", Research in International Business and Finance, 2016
Crossref

37 words — < 1%

39 repository.uinjkt.ac.id
Internet

36 words — < 1%

40 Zeljko Racic, Lidija Barjaktarovic. "Analysis of empirical determinants of credit risk in the banking sector of the Republic of Serbia", Bankarstvo, 2016
Crossref

35 words — < 1%

41 eprints.undip.ac.id
Internet

34 words — < 1%

42 Us, Vuslat. "Dynamics of non-performing loans in the Turkish banking sector by an ownership breakdown: The impact of the global crisis", Finance Research Letters, 2016.
Crossref

34 words — < 1%

43 Nuhanović, Senija. "MONETARNA POLITIKA BOSNE I HERCEGOVINE KAO PRETPOSTAVKA MAKROEKONOMSKE STABILNOSTI", Pregled/00327271, 20090901
Publications

33 words — < 1%

44 Vesna Prorok. "Empirijska analiza validnosti Okunovog zakona na tržištu Makedonije", Proceedings of the International Scientific Conference - Synthesis 2015, 2015
Crossref

33 words — < 1%

45	www.sebonp.com Internet	31 words — < 1%
46	Uma Murthy, Naail Mohammed Kamil, Paul Anthony Mariadas, Dilashenyi Devi. "Factors Influencing Non-Performing Loans in Commercial Banks: The Case of Banks in Selangor", International Journal of Business and Management, 2017 Crossref	31 words — < 1%
47	irti.org Internet	30 words — < 1%
48	nepjol.info Internet	30 words — < 1%
49	Jovic, Dragan. "NPLs modeling in the banking sector of Bosnia and Herzegovina", Bankarstvo, 2015. Crossref	30 words — < 1%
50	scindeks-clanci.ceon.rs Internet	29 words — < 1%
51	mpra.ub.uni-muenchen.de Internet	29 words — < 1%
52	www.kho.edu.tr Internet	26 words — < 1%
53	tcmb.gov.tr Internet	26 words — < 1%
54	islambosna.ba Internet	26 words — < 1%
55	Weterings, Wim. "Possible conflicts of interest with D&O insurance in event of shareholders' class actions", Evropska revija za pravo osiguranja, 2013. Crossref	24 words — < 1%

56	www.slideshare.net Internet	23 words —	< 1%
57	www.mku.ac.ke Internet	22 words —	< 1%
58	Klapić, Muharem; Nuhanović, Amra and Omerhodžić, Sead. "STANJE I PROGNOZE DALJNJEG KRETANJA EKONOMIJE BOSNE I HERCEGOVINE", Pregled, 2013. Publications	21 words —	< 1%
59	Badjun, Marijana. "Izazov reformi javnih sustava mirovinskog osiguranja", Aktualni osvrti, 2012. Crossref	21 words —	< 1%
60	statistics.ats.ucla.edu Internet	20 words —	< 1%
61	www.gvi.hu Internet	20 words —	< 1%
62	www.fzs.ba Internet	20 words —	< 1%
63	Stakic, Nikola. "Determinants of the nonperforming loans level movement in the banking sector of Serbia", Bankarstvo, 2014. Crossref	20 words —	< 1%
64	www.internationalresearchjournaloffinanceandeconomics.com Internet	20 words —	< 1%
65	bs.scribd.com Internet	20 words —	< 1%
66	Ratkovic, Tatjana. "The expatriates in multinational companies: A trend in Serbia", Megatrend revija, 2014. Crossref	19 words —	< 1%

67	www.mocbilja.rs Internet	19 words — < 1%
68	olah-data-statistik-spss.com Internet	19 words — < 1%
69	sh.wikipedia.org Internet	19 words — < 1%
70	Alihodzic, Almir. "Mutual dependence of banking and real sector performance in the Republic of Serbia", Bankarstvo, 2015. Crossref	18 words — < 1%
71	eknjiznica.unipu.hr Internet	18 words — < 1%
72	jimfeb.ub.ac.id Internet	18 words — < 1%
73	www.pula.hr Internet	17 words — < 1%
74	www.hnb.hr Internet	17 words — < 1%
75	eprints.uny.ac.id Internet	17 words — < 1%
76	dep.gov.ba Internet	17 words — < 1%
77	ano.me Internet	17 words — < 1%
78	0013-3264, 2006 Publications	17 words — < 1%
79	Radovan Kastratovic. "The influence of foreign direct investments on economic and social development of Serbia", Bankarstvo, 2016	17 words — < 1%

Crossref

80	www.issr-journals.org Internet	17 words — < 1%
81	www.scmn.me Internet	17 words — < 1%
82	ponude.biz Internet	16 words — < 1%
83	www.wseas.org Internet	16 words — < 1%
84	www.bis.org Internet	16 words — < 1%
85	Ciric, Maja, and Svetlana Ignjatovic. "Analysing the components of attitude in a function of improving consumer protection in the Republic of Serbia", Marketing, 2014. Crossref	15 words — < 1%
86	thesis.eur.nl Internet	15 words — < 1%
87	www.hta.ac.uk Internet	14 words — < 1%
88	www.ukessays.com Internet	14 words — < 1%
89	www.usimr.org Internet	14 words — < 1%
90	Todorović, Marija. "Criteria and procedures for companies to get loans from commercial banks in Montenegro", Entrepreneurial Economy/14516659, 20051215 Publications	14 words — < 1%
91	Mitrovic, Ranka. "Non performing loans: Obstacles within financial and economy sector", Megatrend	13 words — < 1%

revija, 2014.
Crossref

92	repository.unhas.ac.id Internet	13 words — < 1%
93	www.revicon.info Internet	13 words — < 1%
94	Baselga-Pascual, Laura, Antonio Trujillo-Ponce, and Clara Cardone-Riportella. "Factors influencing bank risk in Europe: Evidence from the financial crisis", The North American Journal of Economics and Finance, 2015. Crossref	13 words — < 1%
95	www.bankar.me Internet	13 words — < 1%
96	Lekovic, Miljan. "Regional differences in development of the investment funds industry in Serbia and Croatia", Bankarstvo, 2014. Crossref	12 words — < 1%
97	www.jubmes.rs Internet	12 words — < 1%
98	Jošić, Hrvoje and Jošić, Mislav. "ODRŽIVOSTNEKAMATONOSNOGA TEKUĆEG RAČUNA BILANCE PLAĆANJA U HRVATSKOJ", Ekonomski Vjesnik, 2011. Publications	12 words — < 1%
99	fintp.ijf.hr Internet	12 words — < 1%
100	Milosevic, Milos. "Liquidity risk management", Bankarstvo, 2014. Crossref	11 words — < 1%
101	nbp.pl Internet	11 words — < 1%

102	www.agenrzbh.gov.ba Internet	10 words — < 1%
103	Bruno Ćurko, Ivana Kragić. "Uporaba pričā u radionicama filozofije za djecu", Acta Iadertina, 2017 Crossref	10 words — < 1%
104	www.icsd.eu Internet	10 words — < 1%
105	Zaklan, Damir. "Commercial banking in the conditions of deregulation vs. reregulation", Bankarstvo, 2014. Crossref	10 words — < 1%
106	Veljko Marinkovic. "Effects of the Republic of Serbia's citizens' patriotism and animosity towards the European Union on consumer ethnocentrism", Ekonomski horizonti, 2017 Crossref	9 words — < 1%
107	Bungin, Sanja. "Assessment of the monetary policy transmission mechanism in the new EU member states", Bankarstvo, 2016. Crossref	9 words — < 1%
108	"CRNOGORSKI EKONOMSKI TRENDOVI", Montenegro Economic Trends/14513617, 20100401 Publications	9 words — < 1%
109	facta.junis.ni.ac.yu Internet	9 words — < 1%
110	bs.wikipedia.org Internet	9 words — < 1%
111	Nataša Spahić, Petar Tomić. "Profitabilnost bankarskog sektora Srbije – pre i tokom krize", Proceedings of the International Scientific Conference - Synthesis 2015, 2015 Crossref	9 words — < 1%

112	Vesna Prorok, Slađana Paunović. "TEHNIČKA ANALIZA SPOLJNOTRGOVINSKE RAZMJENE BOSNE I HERCEGOVINE NA BAZI ARIMA MODELA", SOCIOECONOMICA, 2015 Crossref	9 words — < 1%
113	www.nba.az Internet	9 words — < 1%
114	www.parlament.ba Internet	9 words — < 1%
115	0579-6431, 2002 Publications	8 words — < 1%
116	"ULOGA ODRŽIVE STOPE RASTA U UPRAVLJANJU KORPORATIVNIM FINANSIJAMA", Proceedings of the 1st International Scientific Conference - FINIZ 2015, 2015. Crossref	8 words — < 1%
117	www.cafe.ba Internet	8 words — < 1%
118	katolici.org Internet	8 words — < 1%
119	cpcd.lokalni.net Internet	8 words — < 1%
120	www.montenegro-gay.me Internet	8 words — < 1%
121	Janjušević, Jelena. "Model tržišta kapitala Crne Gore", Entrepreneurial Economy/14516659, 20061230 Publications	8 words — < 1%
122	www.tritonia.fi Internet	8 words — < 1%

123	Mihailovic, Lidija, Darko Stanojevic, and Aleksandar Tanaskovic. "Determining the level of service quality vocational training and seminar by the Institute for the Advancement of Education and Upbringing", Tehnika, 2015. Crossref	8 words — < 1%
124	www.hgk.hr Internet	8 words — < 1%
125	"Postupno usporavanje", Economic Trends & Economic Policy/1330187X, 20071101 Publications	8 words — < 1%
126	Subotić, Slobodan and Mitrović, Goran. "POZICIJA OSIGURAVAJUĆIH DRUŠTAVA NA FINANSIJSKOM TRŽIŠTU BIH", Business Consultant / Poslovni Konsultant, 2012. Publications	8 words — < 1%
127	www.parlamentfbih.gov.ba Internet	8 words — < 1%
128	www.regus.hr Internet	8 words — < 1%
129	cris.uns.ac.rs Internet	8 words — < 1%
130	Bajramović mr., Azra. "EFEKTI PRIMJENE INFORMACIONIH TEHNOLOGIJA NA STRUKTURU BANKARSKOG SEKTORA", Zbornik Radova/05817439, 20070101 Publications	8 words — < 1%
131	Ranka Mitrovic, Milica Nestorovic, Marijana Ljubic. "Relationship between macroeconomic aggregates and bank performance", Megatrend revija, 2016 Crossref	8 words — < 1%
132	Pazun, Brankica. "Equilibrium exchange rate assessment in Serbia using the IMF external sustainability	

approach", Megatrend revija, 2014.
Crossref

8 words — < 1%

133 Bogičević, Vesna. "ANALIZA RIZIKA U OBRAZOVNOM SISTEMU BOSNE I HERCEGOVINE", Business Consultant / Poslovni Konsultant, 2013.
Publications

8 words — < 1%

134 0352-5732, 2006
Publications

8 words — < 1%

135 Drašković, Veselin. "POLITIKA CILJANE INFLACIJE : SVJETSKA ISKUSTVA I CRNOGORSKE SPECIFIČNOSTI", Economics / Ekonomija/13300636, 20080601
Publications

7 words — < 1%

136 Skoko, Branimir and Kandžija, Tomislav. "UTJECAJ KOMPONENTI ISTRAŽIVANJA I ZNANJA NA RAST BDP-A EUROPSKIH REGIJA", Ekonomski Vjesnik, 2013.
Publications

7 words — < 1%

137 "Nepovoljni trendovi", Economic Trends & Economic Policy/1330187X, 20090201
Publications

7 words — < 1%

138 Pajić, Denis, and Sunčica Vejzović. "Money Laundering and the Financing of Terrorist Activities with Emphasis on the Role of the Financial Intelligence Department", Drustveni ogledi, 2014.
Crossref

7 words — < 1%

139 Deljkić, Irma; Fazlić, Adnan and Vatreš, Admir. "ISTRAŽIVANJE I DOKAZVANJE NEOVLAŠTENE PROIZVODNJE I STAVLJANJA U PROMET OPOJNIH DROGA U KANTONU SARAJEVO", Journal of Criminal Justice Issues (Kriminalisticke teme), 2013.
Publications

7 words — < 1%

140	Đonlagić dr., Dženan. "TENDENCIJE KRETANJA MONETARNIH AGREGATA U BOSNI I HERCEGOVINI", Zbornik Radova/05817439, 20070101 Publications	7 words — < 1%
141	Omerčić, Seakif. "DEFICIT PLATNOG BILANSA I NJEGOV UTICAJ NA NACIONALNU PRIVREDU SA POSEBNIM OSVRTOM NA BIH", Business Consultant / Poslovni Konsultant, 2014. Publications	6 words — < 1%
142	0013-3264, 2003 Publications	6 words — < 1%

EXCLUDE QUOTES	OFF	EXCLUDE MATCHES	< 5 WORDS
EXCLUDE BIBLIOGRAPHY	ON		