STATISTIČKA ANALIZA BANKARSKOG SEKTORA RH PRIJE, TIJEKOM I NAKON FINANCIJSKE KRIZE

Barešić-Nikić, Irena

Master's thesis / Diplomski rad

2016

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:349439

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

STATISTIČKA ANALIZA BANKARSKOG SEKTORA RH PRIJE, TIJEKOM I NAKON FINANCIJSKE KRIZE

Mentor:
Prof. dr. sc. Ante Rozga

Student:
Irena Barešić-Nikić

Split, lipanj 2016.

SADRŽAJ

1. UVOD 1

1.1. Problem istraživanja 1
1.2. Predmet istraživanja 2
1.3. Istraživačke hipoteze 3
1.4. Svrha i ciljevi istraživanja 3
1.5. Metodologija istraživanja 4
1.6. Doprinos istraživanja 4
1.7. Struktura rada 5

2. GLOBALNA FINANCIJSKA KRIZA 6

2.1. Općenito o globalnoj financijskoj krizi 6
2.2. Uzroci financijske krize 8
2.3. Tijek financijske krize 9
2.4. Mehanizmi širenja financijske krize 20
2.5. Utjecaj financijske krize na bankarske sustave u svijetu 24
2.5.1. Krediti i profitabilnost banaka u svijetu 27

3. BANKARSKI SEKTOR REPUBLIKE HRVATSKE 32

3.1. Važnost bankarskog sektora za gospodarstva zemalja 32
3.2. Struktura bankarskog sektora RH 33
3.3. Utjecaj financijske krize na bankarski sektor RH 41
3.3.1. Krediti i profitabilnost banaka u RH 41
3.3.2. Mehanizmi širenja krize na bankarski sektor RH 46

4. EMPIRIJSKO ISTRAŽIVANJE O UTJECAJU FINANCIJSKE KRIZE NA BANKARSKI SEKTOR REPUBLIKE HRVATSKE 48

4.1. Metodološki aspekt istraživanja 48
4.2. Opis korištenih podataka i varijabli 50
4.3. Regresijska analiza 50
4.4. Osvrt na rezultate istraživanja i istraživačku hipotezu 59

5. ZAKLJUČAK 60

POPIS SLIKA, GRAFOVA I TABLICA 61

LITERATURA 63

PRILOZI 68

SAŽETAK 69

SUMMARY 70

1. UVOD

1.1. Problem istraživanja

Financijski sustav neke zemlje čine njezina valuta, platni sustav, financijska tržišta, financijske institucije, te institucije koje reguliraju i nadziru njihov rad (HNB, 2011). Funkcije koje financijski sustav obavlja u gospodarstvu svake zemlje brojne su. Tako se, primjerice, često u prvi plan ističe funkcija alokacije sredstava od štedno suficitarnih ka štedno deficitarnim subjektima, što pak čini temelj većine investicija u gospodarstvu omogućavajući njegov napredak. Postoji još cijeli niz drugih funkcija koje financijski sustav obavlja međutim, sama njihova srž može se pronaći u uvijek prisutnoj asimetriji informacija, moralnom hazardu i transakcijskim troškovima, koje postojanje financijskog sustava svodi na minimum. Stoga se, bez pretjerivanja, može zaključiti da je financijski sustav krvotok svakog gospodarstva, te da je zbog toga od iznimnog značaja da isti bude stabilan i „zdrav".

U financijskom sustavu Republike Hrvatske, ali i u financijskim sustavima drugih tranzicijskih zemalja, dominiraju banke odnosno, financijski sustavi su im bankocentrični (Dalić, 2002). U financijskom sustavu s dominantnim bankarskim sektorom, upravo banke predstavljaju najbitniji „kanal" za financiranje potreba realne ekonomije. Navedeno pak implicira da problemi u funkcioniranju bankarskog sektora mogu dovesti do brojnih makroekonomskih i mikroekonomskih posljedica (Živko i Kandžija, 2013).

U globaliziranom svijetu, navedeni problem još više dolazi do izražaja. Naime, u uvjetima globalizacije problem u jednoj banci rijetko je problem samo te banke i/ili problem bankarskog sektora jedne zemlje. Naime, kako ističe Šonje (2002), zbog uključenosti banaka u sustav platnog prometa i zbog njihove izloženosti na međubankarskom tržištu može se dogoditi da se problem u jednoj banci prelije na druge banke u istom bankarskom sektoru ili, u najgorem scenariju, na banke u bankarskim sektorima drugih zemalja. Ovakav tzv. domino efekt dogodio se i s financijskom krizom iz 2008. godine, koja je vrlo brzo poprimila epitet „globalna". Naime, u svega godinu dana kriza, kojoj je ishodište bilo puknuće mjehura cijena na tržištu nekretnina u SAD-u 2007. godine proširila se prvo na financijski sustav SAD-a, zatim na financijske sustave diljem svijeta, te se u konačnici manifestirala u gospodarsku krizu u brojnim razvijenim, i u zemljama u razvoju (Letica, 2010; Prohaska et al, 2012). Time je još jednom potvrđena izreka „kad SAD kihne, svijet dobije upalu pluća".

Glavni krivci međunarodne transmisije financijske krize iz 2008. godine bile su banke, koje su, prema mišljenju mnogih, „pretjerale“ s korištenjem strukturiranih financijskih proizvoda poput sekuritizacije (HUB, 2008).[1] Međutim, banke su bile i najveći gubitnici globalne financijske krize. Naime, rast globalnog nepovjerenja ulagača i povećana averzija prema riziku drastično su smanjili kapitalne tokove (Ferreti i Tille, 2011). U tim uvjetima banke su teže dolazile do novih sredstava čineći sredstva kojima raspolažu teže dostupnima i skupljima. Posljedično, ona gospodarstva koja u velikoj mjeri ovise o stranom financiranju bila su značajno pogođena ovakvim razvojem situacije. Tako je primjerice, u Republiku Hrvatsku u 2009. godini ušlo čak duplo manje izravnih stranih ulaganja u odnosu na godinu ranije (Jovančević i Globan, 2011).[2] Najteže pak bilo je privatnom sektoru u tim gospodarstvima koji, primjerice, samo u Hrvatskoj čak 30 posto svojih potreba za financiranjem zadovoljava zaduživanjem u inozemstvu. Imajući na umu da je privatni sektor generator gospodarskog razvoja, posljedice financijske krize na gospodarstva ovakvih zemalja jasne su. Preciznije rečeno, financijska kriza bitno je usporila gospodarsku aktivnost i međunarodnu razmjenu (Bokan et al, 2010). Problemi zabilježeni u gospodarstvima zemalja diljem svijeta, kao bumerang vratili su se nazad bankama u obliku još lošijih kreditnih zahtjeva pojačavajući inicijalni negativni efekt financijske krize na bankarske sektore diljem svijeta. Na ovaj način, globalna financijska kriza, a potom i gospodarska kriza su u proteklih nekoliko godina utjecale na usporavanje poslovanja banaka, te na smanjenje njihove dobiti.

Dok SAD i zapadnoeuropske zemlje danas izlaze iz krize, u manje razvijenim zemljama kriza je još uvijek glavna tema svih gospodarsko-političkih rasprava (Krivačić et al., 2012). Time je opravdan argument Ferreti-a i Tille-a (2011) da se, gore navedeno, drastično smanjenje kapitalnih tokova pokazalo poprilično heterogenim fenomenom, i to kako preko regija, tako i tijekom vremena.

1.2. Predmet istraživanja

Iz prethodno definiranog problema istraživanja, moguće je definirati predmet istraživanja. Predmet istraživanja je kvantificirati intenzitet utjecaja kojeg je globalna financijska kriza imala na poslovanje banaka u Republici Hrvatskoj.

[1] Strukturirani financijski proizvodi tek su jedan od uzroka financijske krize. Ovaj, kao i ostali uzroci detaljno su objašnjeni u prvom potpoglavlju drugog dijela ovog rada.
[2] Kriza se u Republiku Hrvatsku prelila s određenim vremenskim pomakom.

1.3. Istraživačke hipoteze

Na temelju prethodno definiranog problema i predmeta istraživanja, postavljena je sljedeća radna hipoteza:

RH: Financijska kriza negativno je utjecala na poslovanje banaka u Hrvatskoj.

Kako je već ranije navedeno, banke su bile najveći gubitnici globalne financijske krize. Međutim, mišljenja o utjecaju financijske krize na bankarski sektor Republike Hrvatske podijeljena su. Naime, zbog ostvarenih visokih profita u godinama krize, percepcija javnosti bila je da su banke u Hrvatskoj imune na krizu (Krivačić et al, 2012). Pritom, mnogi autori zasluge za tu „imunost" pripisivali su djelovanju monetarne politike Hrvatske (Bokan et al, 2010; Živko i Kandžija, 2013). U prilog ovoj tezi ide činjenica da hrvatski bankarski sustav nije u tolikoj mjeri razvijen kao kod ostalih zemlja, u smislu korištenja financijskih derivata i općenito financijskog inženjeringa za koje se često smatra da su među glavnim uzrocima nastanka globalne financijske krize. S druge strane, postoje autori koji smatraju da je bankarski sektor RH itekako pogođen globalnom financijskom krizom. Tako, primjerice, Babić (2008) daje dobar argument ovoj tezi ističući činjenicu kako su banke u Hrvatskoj čak 93% u stranim rukama, te da kao takve ne mogu biti izolirane od poremećaja na svjetskom bankarskom tržištu. Dodatno, hrvatsko bankarstvo karakterizira mali broj banaka, a glavnina poslovanja koncentrirana je u svega četiri banke, koje su pak u stranim rukama. Prohaska et al (2012) dodaju kako je bankarski sustav Hrvatske zabilježio pojave karakteristične i za druge države obuhvaćene krizom, a to su trend pada kredita, te sve veći udio loših kredita.

1.4. Svrha i ciljevi istraživanja

Kao što je već ranije naglašeno, drastično smanjenje međunarodnih kapitalnih tokova pokazalo se poprilično heterogenim fenomenom kako preko regija, tako i tijekom vremena. To znači da, iako je globalna financijska kriza potresla cijeli svijet, ona nije u istom intenzitetu i u isto vrijeme djelovala na sve zemlje, odnosno na bankarske sustave tih zemalja. Tako je, primjerice, istraživanje Berkmen et al. (2009) pokazalo da su zemlje s većim stupnjem financijske poluge financijskog sustava i bržim kreditnim rastom bile više pogođene. Isto istraživanje pokazalo je da utjecaj krize ovisi i o nizu makroekonomskih uvjeta u zemlji koji se, naravno, razlikuju od zemlje do zemlje.

U skladu s navedenim, glavna svrha ovog rada jest prvo, pregledom postojeće relevantne literature, pružiti uvid u sve moguće mehanizme kojima je globalna financijska kriza mogla

utjecati na poslovanje bankarskog sektora u Republici Hrvatskoj, te zatim u empirijskom dijelu i identificirati smjer i kvantificirati intenzitet (potencijalnog) utjecaja koji je globalna financijska kriza mogla imati na isti.

Glavni cilj je analizirati poslovanje bankarskog sektora Republike Hrvatske, prije tijekom i nakon financijske krize, kako bi se sa sigurnošću moglo uočiti je li kriza, i u kojoj mjeri, utjecala na poslovanje bankarskog sektora Hrvatske, kada se usporedi s poslovanjem istog u periodu prije i nakon globalne financijske krize. Stoga, glavni cilj ovog rada jest pružiti odgovor na sljedeća pitanja:

1) Koji su sve mehanizmi preko kojih je globalna financijska kriza mogla utjecati na poslovanje bankarskog sektora Republike Hrvatske?

2) Je li financijska kriza negativno utjecala na poslovanje bankarskog sektora u Republike Hrvatske?

3) Razlikuje li se poslovanje bankarskog sektora i u kojoj mjeri u periodu prije i nakon krize, u usporedi s razdobljem tijekom krize?

1.5. Metodologija istraživanja

Diplomski rad sastoji se od teorijskog i empirijskog dijela. Teorijski dio rada temelji se na analizi postojeće relevantne literature i empirijskih istraživanja. Metode korištene u izradi ovog dijela rada su: metoda indukcije i dedukcije, metoda analize, metoda sinteze, metoda klasifikacije, metoda kompilacije, te metoda deskripcije.

U empirijskom dijelu rada, a s ciljem testiranja istraživačke hipoteze, prvo su se metodom desk istraživanja prikupili svi potrebni podaci i to iz financijskih izvještaja poslovnih banaka, te iz izvještaja HNB-a. Metodom sinteze dobiveni podaci su se grupirali za potrebe statističke obrade. Nakon toga primjenom modela višestruke regresije, u kojem je globalna financijska kriza prezentirana dummy varijablom, ispitan je utjecaj koji je ista imala na poslovanje bankarskog sektora Republike Hrvatske.

1.6. Doprinos istraživanja

Postoji jako velik broj radova koji su ispitivali utjecaj globalne financijske krize na gospodarstva zemalja diljem svijeta, kao i na njihove financijske sustave. Naravno, to nije ni čudno budući da je ovo najveća kriza još od vremena krize iz 1929. godine. Međutim, broj radova koji su izučavali utjecaj globalne financijske krize na bankarski sektor Republike Hrvatske nije velik, te se ovaj rad pridružuje manjem broju tih radova.

Nadalje, prilikom izrade ovog rada autorici je na raspolaganju bio duži vremenski period, te je ovo najnovije istraživanje utjecaja globalne financijske krize na bankarski sektor Hrvatske, u kojem se mogu vidjeti efekti krize nakon dužeg vremenskog perioda.

1.7. Struktura rada

Diplomski rad sastoji se od pet dijelova. U prvom dijelu rada prezentirani su problem i predmet istraživanja, istraživačke hipoteze, svrha i ciljevi istraživanja, metodološki aspekti istraživanja, te doprinos istraživanja.

U drugom dijelu rada obrađena je globalna financijska kriza. U sklopu ovog dijela opisano je kako je nastala globalna financijska kriza, kao i njezina glavna obilježja. Zatim su navedeni i opisani svi mehanizmi kojima se globalna financijska kriza širila, kao i utjecaji koje je ista imala na bankarske sustave u svijetu. Pritom, poseban naglasak stavljen je na utjecaj financijske krize na europski bankarski sustav.

Treći dio rada fokusiran je na bankarski sektor Republike Hrvatske. U sklopu ovog dijela kratko je izložena važnost bankarskog sektora za gospodarstva zemalja. Zatim je opisana struktura bankarskog sektora Republike Hrvatske, te su opisane njegove ostale karakteristike i specifičnosti. Također su opisani mehanizmi preko kojih je globalna financijska kriza utjecala na bankarski sektor Republike Hrvatske.

Četvrti dio rada sadržava empirijsku analizu. U ovom dijelu detaljno su opisani metodološki aspekti empirijskog istraživanja, te sve korištene varijabli i podaci. Zatim je specificiran model višestruke regresije. Ovaj dio završava usporedbom dobivenih rezultata s radnom hipotezom postavljenoj u početnoj fazi ovog istraživanja.

Peti dio rada ukratko prezentira temeljna saznanja i rezultate teorijskog i empirijskog dijela.

2. GLOBALNA FINANCIJSKA KRIZA

2.1. Općenito o globalnoj financijskoj krizi

Financijska kriza koja je počela 2007. godine prva je globalna financijska kriza u 21. stoljeću (Felton i Reinhart, 2008). Baletić (2009) objašnjava kako teorijski aspekti uzroka, karaktera i dinamike ekonomskih kriza danas općenito nisu dobro poznati, jer se u posljednjih pedesetak godina toj problematici nije poklanjala potrebna pozornost. Nadalje, isti autor ističe kako o pravilnosti ponavljanja kriza postoje različita tumačenja, te da je nužno istaknuti činjenicu da svaki ciklus ima specifičnu konfiguraciju, ovisno o realnim povijesnim okolnostima u kojima su ti ciklusi nastali i odvijali se, a posebno ovisno o stupnju tehnološkoga razvitka, opsega, strukture i organizacije tržišta, zamjene istrošenoga fiksnoga kapitala. Dodatno, Baletić (2009) naglašava kako ipak svi ciklusi izražavaju osnovnu logiku modernoga kapitalističkoga poslovanja. Tablica 1 daje prikaz dosadašnjih najznačajnijih svjetskih kriza.

Tablica 1: Pregled najznačajnih gospodarskih kriza 20. i 21. stoljeća

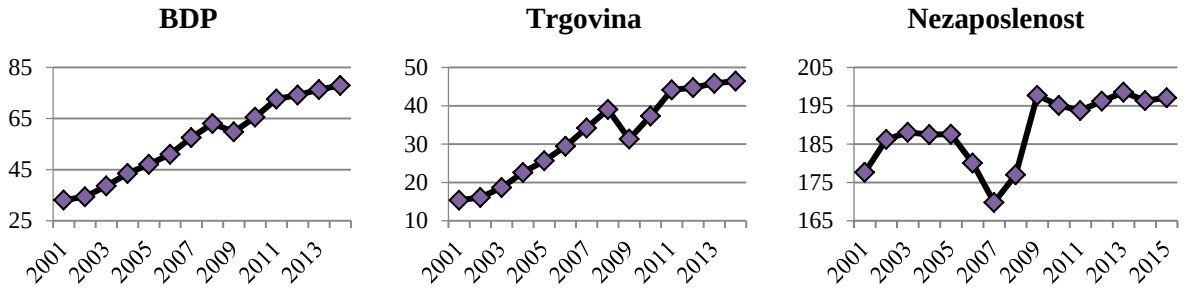
NAZIV KRIZE	OPIS	RAZDOBLJE
Velika depresija	Velika ekonomska kriza ili Velika depresija nazivi su teškog sloma cijelih nacionalnih gospodarstva, a trajala je dugih 12 godina.	1929.-1941.
1. i 2. naftni šok	Pretpostavka za oba naftna šoka je bila su da su potrebe za naftom bile veće od ponude. Oba naftna šoka su izazvala recesije u industrijskim zemljama.	1973., 1979./1980.
Crni ponedjeljak	U ponedjeljak 19. listopada 1987. burze diljem svijeta su doživjele krah, gubljenjem velike vrijednosti u veoma kratkom razdoblju.	1987.
Azijska financijska kriza	Kriza je zahvatila devizna tržišta i tržišta dionica (Tajland, Filipini, Singapur, Malezija, Indonezija i Južna Koreja). Uzroci su bili: slabost financijskog sektora, problem vanjske neravnoteže, te efekt prijenosa (zaraze).	1997.
Dot-com mjehur	Špekulativni mjehur koji pokriva razdoblje od 1995.-2000., tijekom kojeg su burze u razvijenim zemljama svjedočile naglom rastu njihovih kapitalnih vrijednosti. Taj mjehur je puknuo u petak, 10. ožujka 2000.	2000.
Svjetska financijska kriza 2007./2008.	Označava bankarsku krizu koja je počela 2007. godine krizom tržišta nekretnina u SAD-u. S obzirom na preprodaje kredita bankama u cijelom svijetu, kriza se proširila u globalnu financijsku krizu.	2007.-2009.

Izvor: Izrada autorice na temelju Štefulić i Radman Peša (2012).

Kada je u pitanju obim i iznos gubitaka od krize većina autora se slaže da su posljedice nesagledive i teško mjerljive, te da će se osjećati još dugo. Razne procjene gubitaka trenutno postoje. Tako, primjerice, Adelson (2013) procjenjuje da je trošak krize negdje između 5 i 15

trilijuna američkih dolara. Samo je cjelokupna tržišna burzovna vrijednost, koja je dosegla vrhunac u posljednjem kvartalu 2007. (oko 62,5 trilijuna dolara), pala na najnižu vrijednost u prvom kvartalu 2009. kada je iznosila oko 25,5 trilijuna dolara, što predstavlja gubitak vrijednosti od 37 trilijuna dolara u apsolutnim terminima. Ipak, u četvrtom kvartalu 2010. godine opravlja se do vrijednosti od oko 50 trilijuna dolara, te od tada fluktuira u rasponu od 45 do 55 trilijuna dolara po čemu se može zaključiti da šteta globalne financijske krize otprilike iznosi 10 do 12 trilijuna dolara (Adelson, 2013).

Kriza je prouzročila i brojne druge negativne posljedice. Mlikotić (2011) ističe kako je povlačenje kapitala i zaoštravanje kreditnih uvjeta kao direktne posljedice financijske krize, globaliziranu ekonomiju stajalo pada potrošnje, proizvodnje i opsega trgovine, uzrokujući rast nezaposlenosti s potencijalno opasnim posljedicama po socijalnu stabilnost velikog dijela nacionalnih država. Nadalje, navodi kako već 2008. godine dolazi do smanjenja industrijske proizvodnje i opsega trgovine, te da se takvi trendovi u 2009. dodatno zaoštravaju. Također, isti autor objašnjava kako su kriza financijskog sektora i njome izazvani poremećaji u opskrbi kreditima, uz povećane stope štednje prouzročili smanjenje ulaganja u fiksni kapital i potrošačka dobra što objašnjava ubrzan pad globalne potražnje. Posljedično, globalna industrijska proizvodnja bilježi pad od 13% u razdoblju od rujna 2008. do ožujka 2009. godine. Ovi događaju rezultirali su time da su se razvijene zemlje sučile s recesijom, a zemlje u razvoju sa znatnim usporavanjem gospodarskog rasta. Graf 1 prikazuje utjecaj krize na svjetski BDP, svjetsku trgovinu i svjetsku nezaposlenost.



Graf 1: Utjecaj krize na svjetski BDP i svjetsku trgovinu (u trilijunima dolara u tekućim cijenama), te na svjetsku nezaposlenost (u milijunima nezaposlenih)
Izvor: Izrada autorice na temelju podataka sa Svjetske banke (2016) i Međunarodne organizacije rada (2016).

Kao što se može vidjeti na Grafu 1, u 2009. godini su se osjetili efekti krize. Naime, na globalnoj razini BDP je u 2009. (u odnosu na 2008.) pao za oko 3,3 trilijuna dolara u apsolutnim terminima, odnosno relativno za 5,2 posto. Obim svjetske trgovine se smanjio za

čak 770 milijardi dolara što predstavlja relativni pad od oko 20 posto. Kada je nezaposlenost u pitanju, može se uočiti da je čak oko 27 milijuna ljudi (16 posto) ostalo bez posla u prve tri godine krize. Iako su se svjetski BDP i svjetska trgovina poprilično oporavili i nastavili rasti, broj nezaposlenih, od kada se s oko pretkriznih 170 milijuna popeo na oko 200 milijuna, u post kriznim godinama je ostao na otprilike istoj razini (od oko 200 milijuna nezaposlenih uz manje oscilacije).

2.2. Uzroci financijske krize

Financijska kriza započela je u kolovozu 2007. godine. Tijekom 2008. Godine kriza se raspršila, da bi već početkom 2009. godine globalni financijski sustav i globalna ekonomija tonuli sve više i više. U tim trenucima primarni fokus politika čelnih zemalja svijeta postao je zaustavljanje krize i velike recesije koju je ista uzrokovala (Jickling, 2009). Prema analizi Hrvatske udruge banaka (HUB, 2010) o uzrocima krize i dan danas postoje veliki prijepori. Naime, postoje dva gledišta. S jednog gledišta, odgovornost je na pohlepnim bankarima koji su zanemarili upravljanje rizicima i dugoročnu perspektivu radi kratkoročne zarade. U prilog ovom gledištu idu anegdotalna iskustva o nestanku starog tipa bankarstva u kojem su bankari poznavali svoje klijente i savjetovali ih u njihovom najboljem interesu, a u korist novog, transakcijskog tipa bankarstva u kojem se velike svote sredstava prenose medu anonimnim tržišnim sudionicima. S drugog aspekta odgovornost leži na kreatorima politike koji su aktivno promicali agresivno ponašanje banaka kreiranjem izdašne likvidnosti, (pre)niskim kamatnim stopama, te regulacijom koja je napuhala poticaje za hipotekarno kreditiranje.

Generalno, prevladava mišljenje da je kriza započela pucanjem tzv. „balona“ (*eng. bubble*) na američkom tržištu nekretnina što je pokrenulo krizni scenarij. Poznati ekonomist i nobelovac Stiglitz (2009) iznosi 5 glavnih događaja zbog kojih je došlo do krize u SAD-u. To su:

1. Odluka predsjednika Reagana iz 1987. godine da smjeni dotadašnjeg guvernera FED-a Paula Volckera u korist, protivnika svakog oblika regulacije, Alana Greenspana;
2. Usvajanje zakona 1999. godine kojim se ukida razlika između komercijalnih i investicijskih banaka;
3. Nova ekonomska i vojna politika Georga W. Busha nakon 2001. godine[3];
4. Slom klasičnog računovodstvenog i revizorskog sustava sredinom 2002. godine[4]; te

[3] Ključni elementi te politike bili su smanjenje poreza, posebice poreza na kapitalnu dobit, smanjenje kamatnih stopa središnje banke, proširenje kruga poreznih olakšica na sve investicije, pa i one u nekretnine, te vođenje rata u Iraku koje je za posljedicu imalo nagli rast cijena nafte, a time i radikalno povećanje proračunskog deficita SAD-a (Štefulić i Radman Peša, 2012).

5. Paket sanacijskih mjera kao odgovor na krizu koji je imao samo tri stranice i bio iznimno površno pripremljen, a kojeg je Bushov ministar financija, Henry Paulson, objavio 3. listopada 2008. i koji je imao lošu realizaciju, ali i slab efekt na smirivanje krize.

Jickling (2009) pak ističe kako su korijeni krize znatno dublji i kompliciraniji, a njegovo mišljenje dijele i Benić (2012), te Adelson (2013) koji smatraju da je kriza stvarana desetljećima. Naime, Benić (2012) objašnjava kako je kriza prvenstveno rezultat omjera udjela rada i kapitala u BDP-u, te da se udio rada smanjivao u korist kapitala. Tako je, primjerice, u razvijenim zemljama krajem šezdesetih i početkom sedamdesetih godina prošloga stoljeća udio rada iznosio oko 75 posto, da bi početkom 21. stoljeća iznosio između 65 i 68 posto. Pored ovog „dubljeg" razloga nastanka krize, Adelson (2013) navodi još minimalno 5 „dubljih" razloga koji su doveli do nastanka globalne financijske krize, a to su:

1. Preslagivanje tvrtki koje posluju vrijednosnim papirima (*eng. securities firms*) iz partnerstava u korporacije;
2. Deregulacija financijskog tržišta u posljednjih 30-ak godina;
3. Zloupotreba novonastalih kvantitativnih metoda pri dizajniranju i analizi financijskih proizvoda;
4. Prodiranje „kulture rizika" u tradicionalno konzervativne financijske instituicije; te
5. Globalizacija.

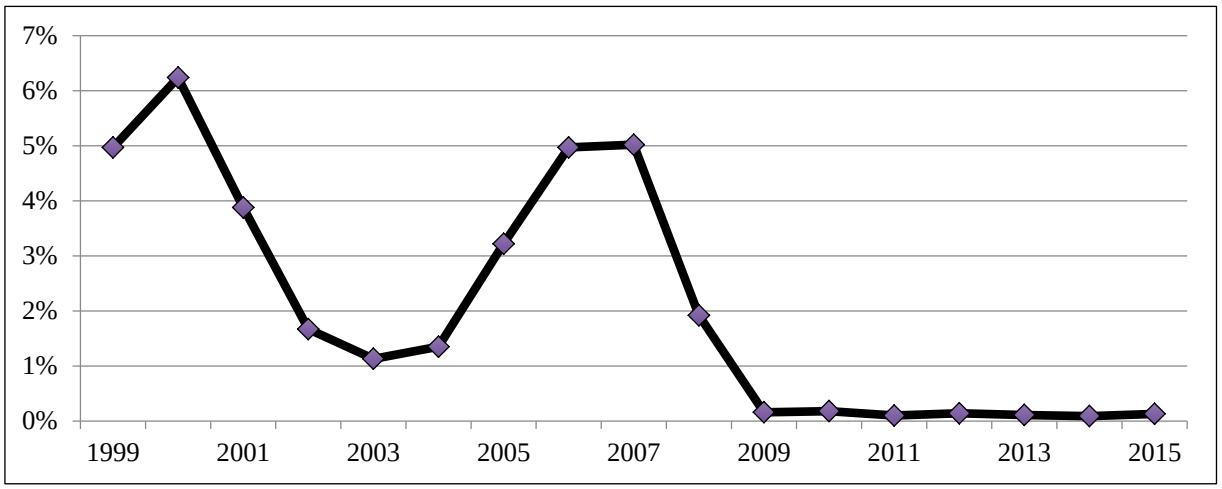
2.3. Tijek financijske krize

Prethodno su spomenuti neki od razloga koji su tijekom prošlog stoljeća stvarali preduvjete za razvoj prve financijske krize 21. Stoljeća. U tekstu koji slijedi opisan je tijek razvoja globalne financijske krize.[5]

Na početku novog milenija u središtu pozornosti bili su tzv. „dot-com" slom, ratovi na Bliskom istoku, te rušenje Blizanaca, tj. tragični događaj 11. rujna. Zbog svih navedenih događanja SAD-u je prijetila recesija, pa je tadašnji guverner FED-a Alan Greenspan donio odluku o provođenju mjera ekspanzivne monetarne politike u vidu smanjenja kamatnih stopa (Benolić, 2012). Kako se može primijetiti na Grafu 2 kamatna stopa FED-a tijekom 2000. godine bila je 6,24 posto, a već u narednoj godini gotovo je prepolovljena te je iznosila 3,88 posto. Ovaj trend smanjivanja nastavio se, te je u 2002. kamatna stopa spuštena na 1,67 posto,

[4] Štefulić i Radman Peša (2012) objašnjavaju da su opcijske dionice poticale menadžere svih financijskih institucija na friziranje završnih računa jer je njihova zarada ovisila o papirnatom knjigovodstvenom uspjehu.
[5] U ovom dijelu zanemari su, svakako mogući, dublji uzroci nastanka globalne financijske krize.

dok je tijekom 2003. godine iznosila 1,13 posto. U lipnju iste godine je u jednom trenutku čak pala i ispod 1 posto što je u tom trenutku, u zadnjih 50 godina bila službeno najniža zabilježena razina (Belkaid, 2008)[6]. Ovakvi potezi FED-a bili su motivirani željom za pokretanjem gospodarske aktivnosti, a pogotovo se htjela zaustaviti prijeteća deflacija, kao i rast broja nezaposlenih (Benolić, 2012).



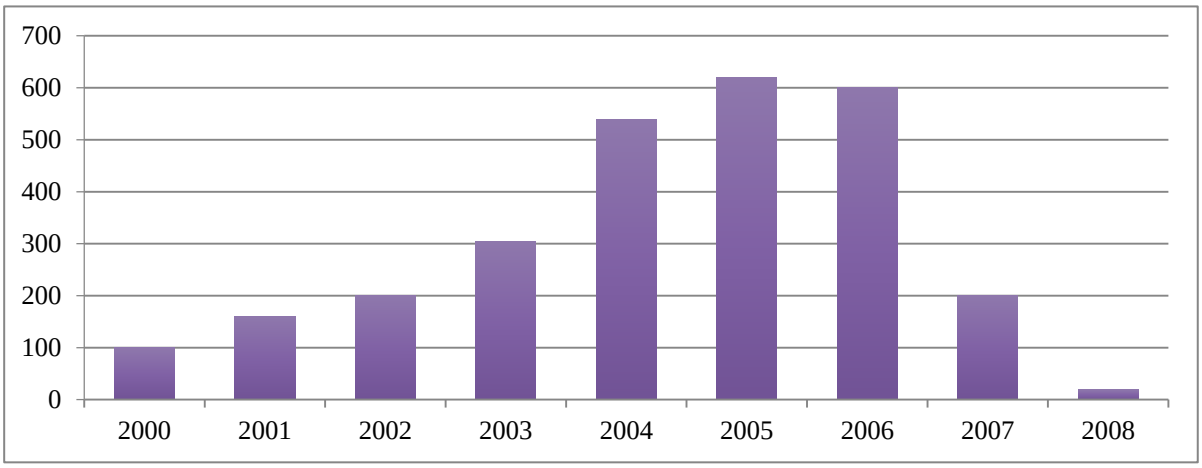
Graf 2: Kretanje kamatne stope FED-a
Izvor: Izrada autorice na temelju podataka sa FED (2016).

Navedeno smanjivanje kamatnih stopa pogodovalo je lakšem dodjeljivanju kredita kućanstvima (Mlikotić, 2011), pa su mnogi Amerikanci prepoznali svoju priliku za stjecanje vlastitog doma, što im se do tada činilo nedostižnim. Naime, prosječne cijene stanova između 1994. i 2006. godine u SAD-u su porasle za gotovo 200% (DeBoer, 2000), što je znatno otežalo kupnju nekretnina. Stoga su, upravo niske kamatne stope donjim slojevima društva omogućile lakši pristup potrošnim dobrima, te podizanje kredita za kupnju automobila i stanova. Budući da je cijena nekretnina kontinuirano rasla kroz relativno dug vremenski period, očekivalo se da će se taj trend i nastaviti, što je također utjecalo na potražnju (tako da je pozitivno poticalo na motivaciju stanovnika na kupnju), a prilika da kreditom steknu nekretninu pružena je i kućanstvima s niskim prihodima, čija je mogućnost otplate od početka bila upitna, što je rezultiralo plasmanom velikog broja rizičnih bankarskih proizvoda odnosno drugorazrednih hipoteka[7] (*eng. subprime mortgage*) (Mlikotić, 2011).

[6] U Benolić (2012).
[7] Objašnjenje drugorazredne hipoteke - pri podizanju stambenih kredita, zajmoprimac treba raspolagati s određenim instrumentima osiguranja (npr. hipoteka, jamac, sigurnost prihoda i zaposlenja, postotak od dohotka koji rata kredita ne smije prelaziti itd.), a u svrhu privlačenja novih klijenata, banke su ublažavale uvjete koje je trebalo zadovoljiti pri podizanju kredita, čime se povećavao rizik ogluhe, ali je iz tog razloga rasla i cijena, odnosno profit (Mlikotić, 2011).

Mlikotić (2011) objašnjava kako su popunjavajući svoje rezerve, banke zatim prodavale ugovore o hipotekarnim zajmovima (hipoteke uz diskont) investicijskim bankama na sekundarnom tržištu. Na ovaj način na tržište je plasiran velik broj drugorazrednih hipoteka 2005. i 2006.godine s ukupnom vrijednošću od preko 1000 milijardi dolara samo u te dvije godine.

Na Grafu 3 nalazi se prikaz kretanja vrijednosti subprime hipotekarnih kredita u milijardama dolara. Može se uočiti kako je još na početku stoljeća bilo izdano oko 100 milijardi dolara vrijednosti subprime hipotekarnih kredita, dok je taj broj dramatično narastao u razdoblju između 2004. i 2006. godine kada je iznosio oko 600 milijardi dolara.



Graf 3: Kretanje *subprime mortgage* kredita (u milijardama dolara)
Izvor: Izrada autorice na temelju Financial Crisis Inquiry Commission Report (2011).

Štefulić i Radman Peša (2012) navode kako bi zatim investicijske banke te kredite zajedno pakirale u tzv. pakete posebnih namjena *(eng. special purpose vehicle*s) i prodavale ih. Ti paketi imaju fiksnu kamatu stopu i uključuju: *asset-backed securities* (ABS)[8], *residential mortgage-backed securities* (RMBS)[9], *commercial mortgage-backed securities* (CMBS)[10], *collateralized debt-obligations* (CDOs)[11] i *collateralized mortgage obligations* (CMOs)[12].

[8] ABS su sekuritizacijom stvorena pokretna vrijednost koja se oslanja na aktivu; ponekad se sastoje od portfelja hipotekarnih stambenih kredita (Atalli, 2009 u Štefulić i Radman Peša, 2012).
[9] RMBS je vrijednosnica vezana za skup hipotekarnih stambenih kredita (npr. subprime, Alt-A ili prime). Vlasnik dobiva povrat glavnice i kamate na sekuritizirane stambene kredite (Atalli, 2009 u Štefulić i Radman Peša, 2012).
[10] CMBS je vrsta hipotekarne vrijednosnice koja je vezana za kredit na komercijalnu imovinu (Investopedia, 2016 u Štefulić i Radman Peša, 2012).
[11] CDO je dužnička vrijednosnica zasnovana na vrijednosnicama nekoliko aktiva, obično ABS-ova, dionica i obveznica(Atalli, 2009 u Štefulić i Radman Peša, 2012). .
[12] CMO je vrsta hipotekarne vrijednosnice koja kreira odvojene bazene prolaznih stopa za različite vrste obvezničara s različitim rokovima dospijeća, pod nazivom tranše (Investopedia, 2016 u Štefulić i Radman Peša, 2012).

Tiller (2010) ističe kako su tisuće hipotekarnih kredita, nakon što su bili upakirani, poslani na procjenu rizičnosti u obliku vrijednosnica kreditnim rejting agencijama gdje su u velikom broju slučajeva bili označeni trostrukim A (AAA – najveća ocjena koja označuje da je instrument siguran), iako njihovo podrijetlo možda nije ni bilo jasno kreditnim rejting agencijama. Benolić (2012) objašnjava razloge preoptimističnog ocjenjivanja. Investitorima je, naravno, u interesu da rizik u koji se upuštaju bude što je moguće objektivnije procijenjen, zbog čega i postoje rejting agencije, koje procjenjuju i ocjenjuju rizičnost ulaganja. No, bitno je istaknuti kako se radi o privatnim tvrtkama, koje plaćaju upravo tvrtke čije je proizvode potrebno procijeniti, te se lako da zaključiti da je sukob interesa vrlo lako moguć. Naime, u slučaju da tvrtka-poslodavac nije zadovoljna dobivenom ocjenom, ne postoji zapreka da se obrati drugoj rejting agenciji. Upravo kada su u pitanju strukturirane financije prijeti najveća opasnost od sukoba interesa jer agencija ima mogućnost prvotno ponuditi savjet o tome kako će izgledati rejting vrijednosnice, a tek nakon toga objaviti finalni rejting (time zarađuje dva puta). Benolić (2012) zaključuje kako je upravo neregulacija djelatnosti rejting agencija zajedno sa mogućim sukobom interesa bila osnova za neobjektivno i preoptimistično procjenjivanje što je utjecalo i na nekvalitetne informacije kojima su investitori raspolagali.

Po završetku procesa pakiranja i analize, investicijske banke su prodavale te vrijednosnice svojim klijentima, a što se prema Attaliju (2009) naziva sekuritizacijom. Sekuritizacija se može definirati kao proces emitiranja dužničkih vrijednosnih papira temeljem nekih potraživanja, a uključuje potraživanje ili drugu vrstu financijske imovine koja se tijekom vremena pretvara u novac. Sekuritizacija hipotekarnih kredita je relativno novi mehanizam koji se počeo koristiti prije četrdestak godina. Naime, 1968. godine osnovan je *Government National Mortgage Association* - GNMA (Dwight, 2008) koji predstavlja ishodišnu točku u razvoju suvremenih hipotekarnih vrijednosnica (*eng. mortgage-backed security* - MBS)[13]. Benolić (2012) objašnjava kako je tako kreiran standardizirani mehanizam za okupljanje hipoteka u obliku vrijednosnih papira što je uvelike olakšalo njihovu prodaju zainteresiranim investitorima.

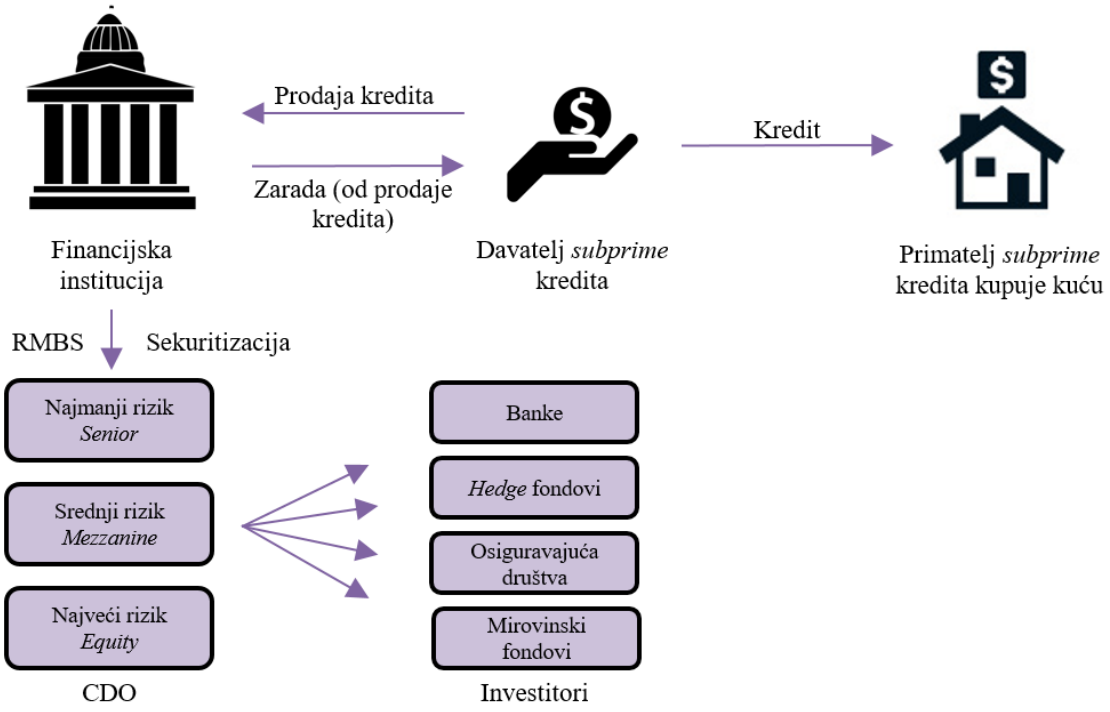
Ove financijske inovacije objeručke su bile prihvaćene, naročito zato što je država bila jamac za isplatu kamata i glavnice. Tržište je vrlo brzo postalo prepuno paletama sličnih vrijednosnih papira, što je za posljedicu imalo ubrzani rast tržišta vrijednosnih dužničkih papira, a daljnja ekspanzija je postavila temelj za budući razvoj hedge fondova. Ubrzo su

[13] MBS predstavlja vrijednosnice s hipotekarnim pokrićem (Mark, 2009 u Benolić, 2012)

dvije velike američke tvrtke (sponzorirane od strane vlade) Fannie Mae i Freddie Mac (čija je misija bila promicanje vlasništva nad nekretninama) stvorile i vlastite MBS pakete te tako omogućile povoljnije kredite. Iako investitorima potonjih paketa nije jamčila država, tvrtke su garantirale isplatu kamata i glavnica na temelju vlastitih MBS-a za koje je jamčila država, a što su investitori shvaćali kao garanciju države. Tijekom sredine 1980-ih na tržište su lansirani i prvi potpuno „privatni“ MBS programi, gdje su ulagači na sebe preuzimali rizik u potpunosti zato što nije postojala ni neposredna ni posredna veza s državnim jamstvima (Benolić, 2012).

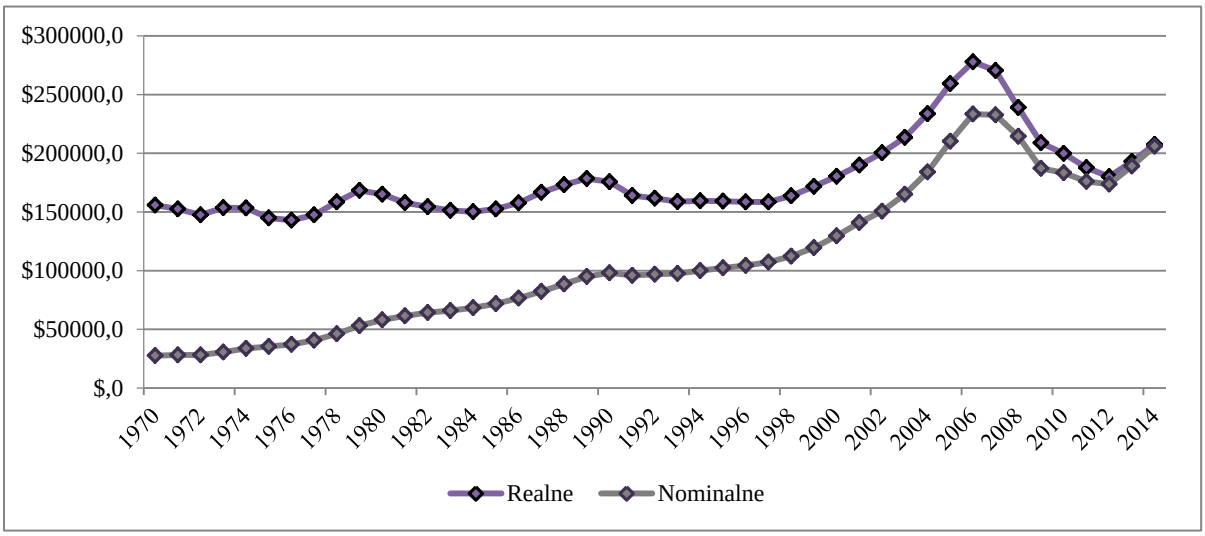
U datim je okolnostima (prije „eksplodiranja“ prve krize u 21. stoljeću) sekuritizacija bila gotovo savršeno financijsko sredstvo. Naime, prodavanjem vrijednosnih papira i derivata temeljenih na drugorazrednim kreditima bankama su pristizala likvidna sredstva koje su one dalje iskorištavale za kreditiranje novih zajmoprimaca, dok se druge strane sekuritizacijom rizik raspršuje, tj. preciznije rizik se prenosi s institucije koja je odobrila kredit, na investitore putem različitih financijskih mehanizama. Benolić (2012) ističe kako je sekuritizacija primamljiva stoga što omogućuje korištenje financijske poluge, odnosno načela prema kojem se isplati koristiti dugom u financiranju poslovanja ako je profitabilnost veća od kamatne stope na dugove, te tako ulagači dobivaju bolji dugoročniji položaj, prilikom čega je njihov očekivani profit viši, ali svakako i rizičniji. Negativna strana sekuritizacije očituje se u slabljenju motivacije financijskih posrednika da nadziru ponašanje prvotnog zajmoprimca.

Radi rentabilnosti koja se obećava kupcima ovih vrijednosnica, sekuritizacija u vrlo kratkom roku postiže uspjeh, te gotovo svi institucionalni štediše svijeta žele te sekuritizirane proizvode za sebe, ili kako bi ih plasirali među svojim klijentima. Iznos tih vrijednosnica, bile one vezane za nekretnine ili ne, uskoro premašuje iznos američkih državnih obveznica, a to čine Freddie Mac i Fannie Mae, ostavljajući dio tih hipotekarnih kredita u svojim bilancama dok ostale prodaju u obliku RMBS-ova pa se tako polovica tih sekuritiziranih subprime kredita našla u neameričkim bankama, dok je druga polovica prodana njihovim neameričkim klijentima. (Štefulić i Radman Peša, 2012).



Slika 1: Proces prodaje subprime hipotekarnih kredita
Izvor: Murali (2007).

Na Slici 1 prikazan je prethodno opisani proces prodaje subprime hipotekarnih kredita i sekuritizacije tih vrijednosnica, što je u konačnici dovelo do brzog širenja subprime hipotekarne krize. Tiller (2010) ističe kako je ishod ovog niza događaja bio puknuće „balona" (tzv. *bubble*) na američkom tržištu nekretnina.



Graf 4: Prikaz kretanja realnih i nominalnih cijena nekretnina u SAD-u u razdoblju 1970.-2014.
Izvor: Parsons (2016).
Napomena: Bazna godina je 2010.

Kretanje cijena nekretnina na američkom tržištu prikazano u indeksima može se vidjeti na gore na grafu 4. Još tijekom 1970-ih godina prosječna (realna) cijena nekretnine u SAD-u iznosila je oko 150 000 dolara, a do 1998. nije se pretjerano mijenjala. No, od tada do 2006. godine prosječni rast bio je čak oko 10 posto na godišnjoj razini što je povećalo prosječnu cijenu nekretnina do enormnih 275 000 dolara (Tiller, 2010). Zbog pritiska povećanja cijena nekretnina i lakših uvjeta kreditiranja, sve veći broj Amerikanaca se zaduživao iznad svojih mogućnosti, tj. rast zaduženosti kućanstava se odvijao u ozračju koje nije omogućavalo povećanje dohodaka. U razdoblju od 1980. do 2006. dug kućanstava SAD-a je povećan s 50 na 100 posto BDP-a (Mlikotić, 2011). Štefulić i Radman Peša (2012) objašnjavaju kako se problemi počinju javljati u 2006. godini, kad je kamatna stopa značajno porasla, tj. kada je FED povećao kamatnu stopu s 1 na 5,25 posto što je dovelo do kaosa na tržištu nekretnina, a ubrzo i na financijskim tržištima: prvo na američkom, a potom i diljem svijeta. Došlo je do toga da oko šest milijuna vlasnika nekretnina s drugorazrednim zajmovima u prvoj polovici 2007. godine više nije moglo otplaćivati prispjele kreditne rate, tako da je cijena nekretnina već u kolovozu 2007. pala za više od 21 posto. Tijekom 2008. zabilježen je nastavak pada cijena nekretnina od 17 posto, a 40 posto drugorazrednih hipoteka iz 2006. godine postalo je problematično do druge polovice 2008. (WESP, 2009). Nadalje, Mlikotić (2011) uočava kako je Gillian Tett, jedna od rijetkih osoba koja je prognozirala krizu, identificirala tri pogrešne pretpostavke na kojima su se temeljile financije 21. stoljeća:

- prevladavanje uvjerenje da su moderna tržišta kapitala postala toliko napredna da je rizik moguće prodati dalje,
- oslanjanje na nepouzdana izvješća agencija za procjenu,
- vjerovanje da je proces slicing and dicing duga učinio financijski sustav stabilnijim.

Iako je država energično intervenirala (slučajevi u SAD-u, Japanu i Europi), tijekom 2008. kriza se proširila i zahvatila globalno financijsko tržište. Situacija je postala alarmantno ozbiljna kada je došlo do kraha Bearn Stearnsa, pete najveće investicijske banke u SAD-u, koja je u ožujku ipak sanirana zajedničkom intervencijom FED-a (jamstvo u iznosu od 30 milijardi dolara) i JPMorgan Chasea (koji je preuzima za 2 dolara po dionici, nasuprot cijeni od 60 dolara unazad nekoliko mjeseci (Felton i Reinhart, 2008 u Mlikotić, 2011).

Tijekom rujna 2008. godine kriza je eskalirala. Naime, došlo je do teške kreditne kontrakcije, pada vrijednosti na burzama diljem svijeta i kolapsa nekih od najvećih financijskih institucija. Nadalje, povjerenja u kreditnu sposobnost partnera više nije bilo, cijene vrijednosnica su

padale, dok s druge strane kamatne stope na međubankovne kredite i državne vrijednosnice u rujnu i listopadu popele su se na najviše razine u posljednjih nekoliko desetljeća. Zbog sve većeg manjka povjerenja u investitore, kojemu, kada se pridodaju sve lošiji i lošiji rezultati realnog sektora, dolazi do nove panične prodaje vrijednosnica na globalnoj razini pri kraj rujna i tijekom listopada. Prema podatcima *World Economic Situation and Prospects-a* (WESP, 2009), u samo prvih desetak dana listopada vrijednost dionica se srozala preko 10 000 milijardi dolara.

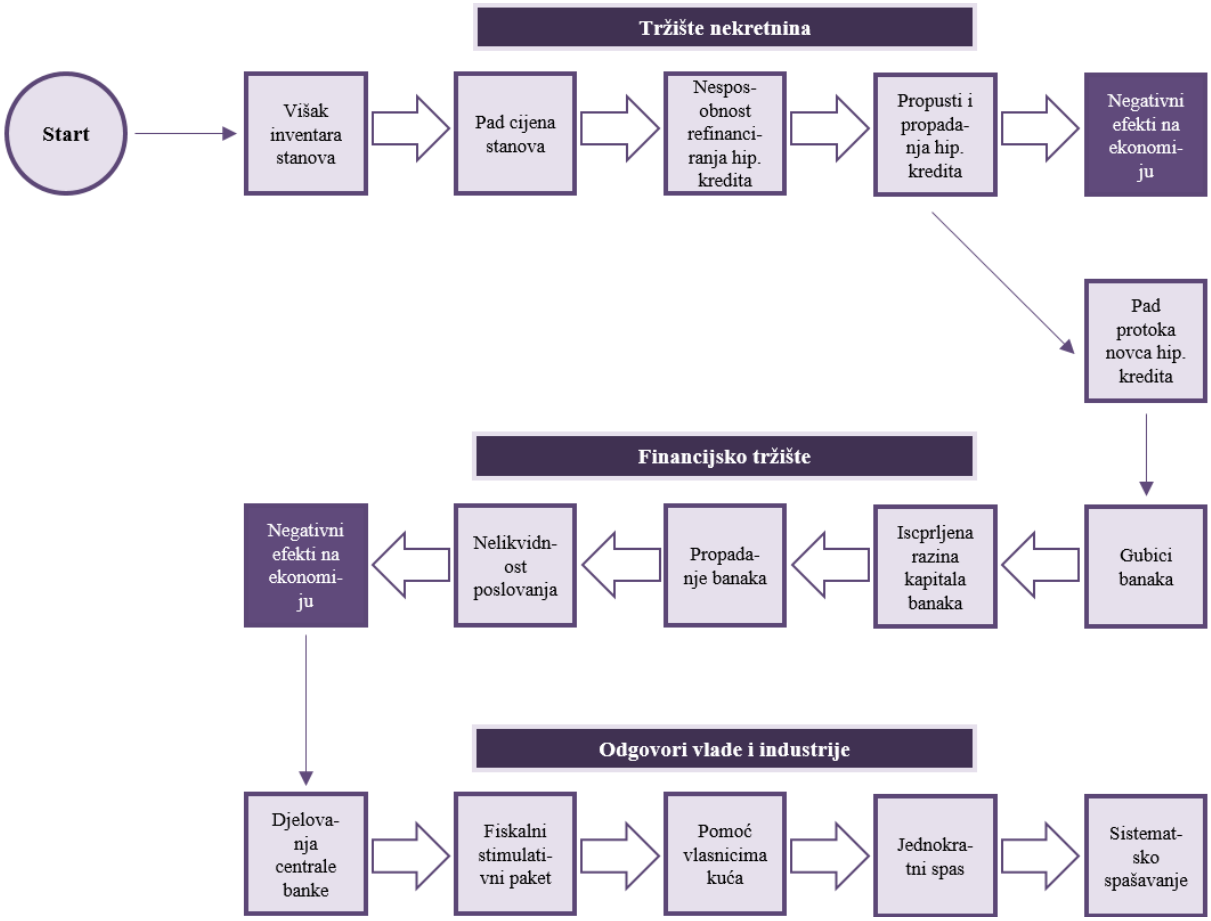
U velikoj opasnosti od propadanja su bile najvažnije institucije SAD-a, redom: Fannie Mae i Freddie Mac (poduzeća „sponzorirana" od strane vlade) koja su raspolagala s otprilike polovicom svih hipotekarnih zajmova u SAD-u, u vrijednosti od 5 000 milijardi dolara). Zatim, American International Group (AIG - s oko 1 000 milijardi dolara predstavlja jedno od globalno najvećih osiguravajućih društava), Citigroup, Lehman Brothers, Washington Mutual itd. Sukladno procjeni države da ako AIG i Citigroup propadnu (rizici u vidu nesagledivih posljedica po američku i globalnu financijsku stabilnost), država se odlučuje na intervenciju i sudjeluje sa 150 milijardi dolara u spašavanju AIG-a, te tako postaje 80%-tni vlasnik, a nakon toga jamstvom u iznosu od 306 milijardi dolara te direktnom investicijom od 20 milijardi dolara spašava i Citigroup. S druge strane, Lehman Brothers i Washington Mutual nisu opstali, te su bili prisiljeni proglasiti bankrot. Lehman Brothers je najveća kompanija, dok je Washington Mutual najveća banka koja je ikada propala u američkoj povijesti. Ova događanja su označila kraj institucija koje su najviše profitirale od deregulacije financijskog sustava posljednjih desetljeća što je praktički označilo kraj neovisnog investicijskog bankarstva u SAD-u (Mlikotić, 2011).

Nadalje, Mlikotić (2011) navodi da je kriza zahvatila i japanski, te europski financijski sustav. Tako je npr. samo u prosincu 2007. godine Europska središnja banka intervenirala i europskim poslovnim bankama posudila 500 milijardi dolara. Bankrot je prijetio brojnim poznatim financijskim institucijama poput nizozemsko – belgijskog Fortis-a, francusko – belgijske Dexia-e, britanskog Bradford & Bingley-a i Northern Rock-a, njemačkog Hypo Real Estate-a, nizozemskog ING-a i Aegon-a i dr. Također, brojne države su zatražile pomoć MMF-a, kao npr. Island, Mađarska, Ukrajina, Bjelorusija i Srbija.

Ukratko, pri kraju 2008. financijski sustav na svjetskoj razini našao se pred kolapsom i bile su nužne državne intervencije kako bi se ponovno pokrenuo, u vidu: državnih jamstava za štedne depozite i međubankovne posudbe, dokapitalizacijom banaka javnim fondovima i preuzimanjem rizičnih plasmana, odobravanjem fiskalnih olakšica, utjecanjem na visinu

kamatnih stopa te poduzimanjem raznih drugih mjera čija se vrijednost procjenjuje na oko 4 000 milijarde dolara (Mlikotić, 2011). Kolaps globalnog financijskog sustava je spriječen, no posljedice ove krize zasigurno će se osjećati još dugo (Štefulić i Radman Peša, 2012).

Cjelokupni tijek krize prikazan je na Slici 2.

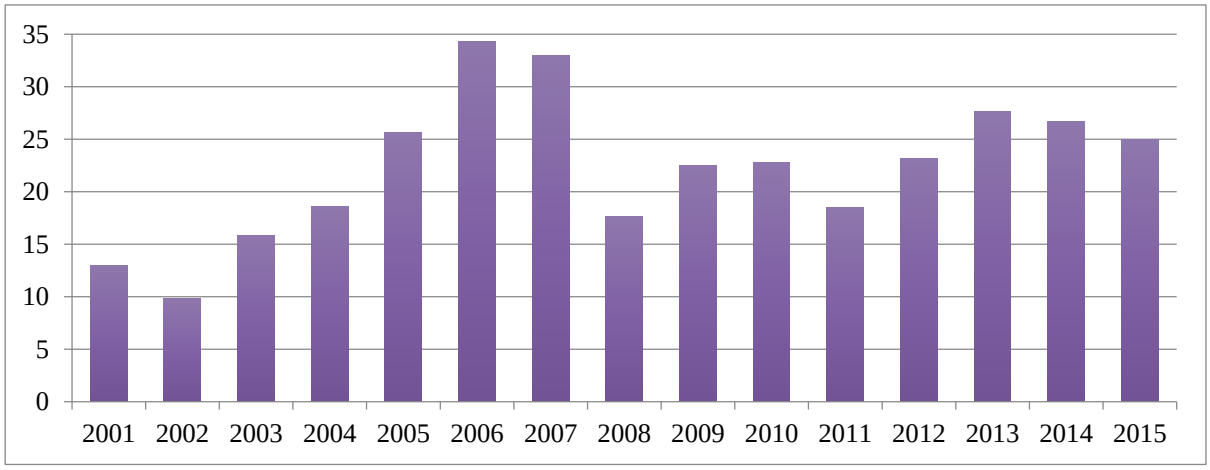


Slika 2: Prikaz tijeka financijske krize
Izvor: Izrada autorice na temelju Demiter Reider (2010).

Uz prethodno opisani proces puknuća „mjehura“, tzv. bubble-a na tržištu nekretnina u SAD-u, značajan doprinos razvoju krize imali su i **menadžerski bonusi**. Štefulić i Radman Peša (2012) upravo menadžerske kompenzacije (prvenstveno kompezacije CEO-vima banaka) smatraju jednim od temeljnih uzroka financijske krize (uz sve navedeno prije što je dovelo do krize).

Kirwan-Taylor (2010) ističe kako su zaposlenicima od svih mogućih vrsta bonusa (npr. parkirno mjesto, članstvo u teretani, plaćeni i neplaćeni dopusti, masaže i odmori, „team

building“ izleti i sl.) daleko najdraži bonusi na plaću.[14] Oni potiču ljude da riskiraju previše, čak i da prekrše zakon, a nakon nekog vremena nisu više učinkoviti jer ih zaposlenici očekuju kao i plaću. Kompenzacije osoba zaposlenih u bankama sačinjene su od dva dijela: osnovne plaće kao stabilnog dijela i varijabilnih poticanja (Heller, 2008). Štefulić i Radman Peša (2012) objašnjavaju kako se u velikoj mjeri bonusi isplaćuju u novcu, dok se manji dio dijeli u dionicama i opcijama. Nadalje, u godinama koje su prethodile krizi, kada su se ostvarivali visoki profiti, bonusi su značajno porasli čak do te mjere da je zbroj doprinosa bonusa u investicijskom bankarstvu premašio dividende isplaćene dioničarima. Prema BBC News-u (2010) primarni razlog zbog kojeg su bankarski bonusi toliko izdašni jest taj, što su, u financijskim terminima, bankarske transakcije bile iznimno velike pa je maleni postotak bonusa na zaključen posao predstavljao veliki iznos.



Graf 5: Prikaz ukupnih isplata bonusa na Wall Streetu u razdoblju od 2001.-2015.
Izvor: Office of the State Comptroller (2016).

Na Grafu 5 može se primijetiti kako je razina bonusa na Wall Streetu konstantno rasla (izuzev 2002. godine), a kada se usporedi 2001. i 2007. godina može se uočiti da je porasla za preko 150 posto, s razine od 13 milijardi dolara na preko 33 milijarde dolara. U 2008. godini bonusi značajno opadaju, no u 2009. opet rastu i to za popriličan iznos (oko 5 milijardi dolara) uzevši u obzir stanje financijskog sustava i svjetske ekonomije u datom trenutku.

Slična situacija s bonusima bila je i na City of London burzi. Mathews i Mathews (2010) ističu da su bonusi tamo također konstantno rasli (samo ne u 2002.) Usporedbom 2001. i 2007. Godine na City of London burzi zaključuje se da je iznos narastao preko 160 posto (s

[14] u Štefulić i Radman Peša (2010).

3,9 milijarde funti bonusa na preko 10 milijardi funti) no već je u razdoblju od godine dana (do 2008.) pao za taj cjelokupni iznos (bonusi su se spustili na razinu od 4 milijarde funti).

Već je prije spomenuto kako je Lehman Brothers najveća kompanija u američkoj povijesti koja je propala. Bebchuk et al. (2009) navode kako su pet izvršnih timova Lehman Brothersa, te još jedne velike kompanije (Bear Stearnsa) unovčili velike iznose kompenzacija vezanih uz performanse u razdoblju od 2000. do 2008. Naime, izveli su novčane tokove od čak 1,4 milijarde dolara te još milijardu dolara novčanih bonusa i prodaja kapitala. Štefulić i Radman Peša (2012) ističu kako su ovi novčani tokovi značajno prešli početne vrijednosti fondova izvršnih menadžera s početka ovog razdoblja, dok su izvršene neto isplate za to razdoblje bez ikakve sumnje pozitivne. Nadalje, Acosta (2009) ističe kako je Richard Fuld, izvršni direktor Lehman Brothersa, u siječnju 2008. iskoristio priliku da isplati 10 milijardi dolara kapitala kao bonus na kraju godine, te je odbio prijedlog da se ti bonusi ne isplate menadžerima kompanije za dobrobit kompanije.

Ovakve isplate bonusa naljutile su medije i javnost, te su upućivane kritike izvršnim direktorima Wall Streeta zbog besramnih preplaćivanja. Kako Park (2010) navodi, izvršni direktori bili su zaštićeni od dugoročnih štetnih učinaka poduzetih rizika. Uz politiku jeftinog novca koja je bila temelj (Benolić, 2012), u ovome se ogleda činjenica koja je poticala menadžere na moralni hazard[15], tj. poticala ih je na rizične poteze u svrhu poboljšanja kratkoročnih izvedbi kako bi u konačnici ostvarili ogromne isplate godišnjih bonusa (Štefulić i Radman Peša, 2012). Na BBC Newsu (2010) se objašnjava da se menadžerski bonusi najčešće pravdaju po tržišnoj osnovi, tj. u svrhu zadržavanja svojih najboljih menadžera, banke (i ostala poduzeća) su „prisiljena“ isplaćivati kompenzacije sukladno stanju na tržištu. Ipak, kolike su bile zloupotrebe svjedoči šokantan podatak kojeg navodi Letica (2010), a to je da su prije krize neki menadžeri u jednom danu zaradili koliko prosječan stanovnik SAD-a zaradi u cijeloj godini.[16] Sharfman (2009) ističe kontroverznu činjenicu o spremnosti poduzeća na isplaćivanje milijardi dolara kompenzacijskih bonusa, i to čak u raspadajućim financijskim i gospodarskim uvjetima, pa je tako 5 vodećih Wall Street poduzeća (Goldman Sachs, Merrill Lynch, Morgan Stanley, Lehman Brothers i Bear Stearns) isplatilo rekordne bonuse od 39 milijardi dolara u 2007., a samo godinu prije su ti bonusi iznosili jednako nevjerojatnih 36 milijardi dolara. Kao posljedica navedenog, Lehman Brothers je 2008. Bankrotirao, dok su Merrill Lynch i Bear bili primorani pronaći partnere za spajanje zbog

[15] Moralni hazard - situacija kada se određena strana (pojedinac ili institucija) izolirana od rizika ponaša drugačije nego da je u situaciji u kojoj je u potpunosti suočena s rizikom (IJF, 2016)
[16] u Štefulić i Radman Peša (2012).

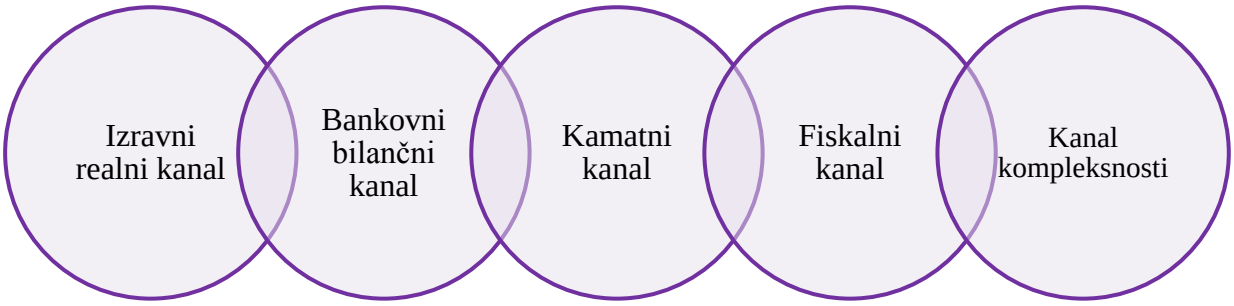
ekstremnih financijskih poteškoća u kojima su se našli. Nevjerojatno besramna odluka Merrill Lyncha od 29. prosinca iz 2008. Godine jest da odobri isplatu 3,6 milijardi dolara zaposlenima, i to samo nekoliko dana prije spajanja s Bank of America i nakon što je već bilo poznato da Bank of America traži dodatnih 20 milijardi dolara od savezne vlade kako bi spasila Merrill Lynch. Sharfman (2009) uočava da su se u ovim, te drugim Wall Street kompanijama suzdržali od isplate ovoliko velikih kompenzacija menadžerima, a pogotovo u godinama kada su (sekundarna) hipotekarna tržišta bila u osjetnom padu, vjerojatno bi negativni ekonomski utjecaj krize bio manji. Mlikotić (2011) ističe da posljedice neodgovornosti pojedinaca (koji su takvim ponašanjem gomilali nevjerojatne profite) mora snositi čitavo društvo, zbog proste činjenice što su novci poreznih obveznika, i to milijarde, korišteni pri saniranju raznih kompanija). Stoga, Štefulić i Radman Peša (2012) u konačnici zaključuju kako je kompenzacije potrebno regulirati kako bi se u buduće obeshrabrilo pretjerano poduzimanje rizika od strane menadžera.

2.4. Mehanizmi širenja financijske krize

Kao što je navedeno u prošlom potpoglavlju svjetska financijska kriza iz 2007./2008. godine inicijalno je započela puknućem mjehura cijena na američkom tržištu nekretnina.[17] Pitanje koje se logički nameće jest kako je „okidač“ u samo jednom sektoru imao ogromne posljedice na ostale realne i financijske sektore i to ne samo u SAD-u, nego i u zemljama diljem svijeta?

Kao što je već ranije naglašeno, u uvjetima globalizacije problem u jednoj banci rijetko je problem samo te banke i/ili problem bankarskog sektora jedne zemlje. Stoga, domino efekt kakav je zabilježen u svijetu nakon izbijanja globalne financijske krize zbog snažne povezanosti financijskih tržišta, institucija i sustava diljem svijeta, nije ni čudan, a naročito kada se u obzir uzme svjetska velesila od koje je sve i počelo. Upravo je globalizacija omogućila širenje krize, i to kanalima i mehanizmima koji su prije bili nezamislivi. Kako navode iz Hrvatske udruge banaka (HUB, 2010) o mehanizmima kojima se financijska kriza širila manje je prijepora nego oko uzroka koji su do iste doveli. Prohaska et al. (2012) tako su identificirali pet glavnih mehanizama kojima se financijska kriza iz SAD-a proširila po cijelome svijetu (Slika 3), koji su navedeni i objašnjeni u nastavku teksta.

[17] U ovom dijelu zanemaruju se mogući i vrlo vjerojatni dublji uzroci nastanka krize.



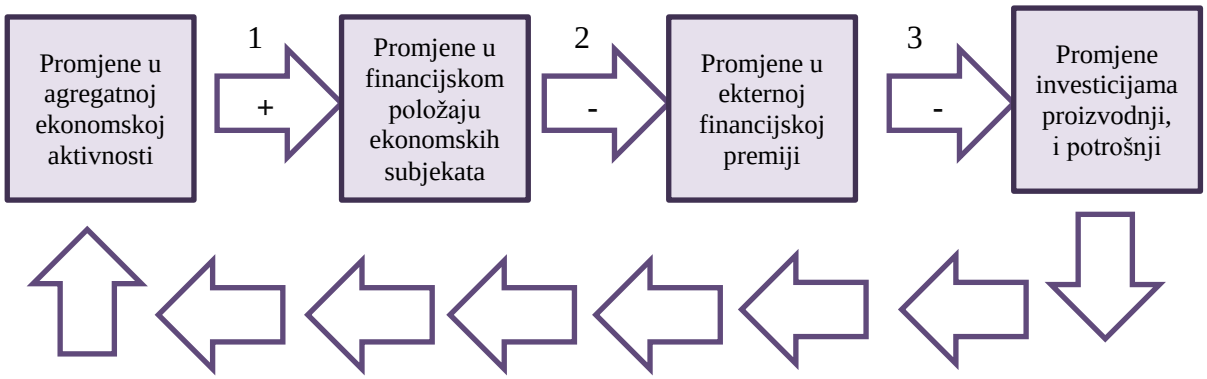
Slika 3: Mehanizmi širenja financijske krize
Izvor: Izrada autorice na temelju podataka iz Prohaska et.al. (2012).

Izravni realni kanal potaknut financijskim akceleratorom/deceleratorom

Pojam financijskog akceleratora u makroekonomiji odnosi se na ideju da distorzije na kreditnim tržištima mogu povećati ekonomske šokove (Čorić i Pugh, 2009). Ovaj mehanizam je, kako ističu Roger i Dolignon (2010) samodrživ te korijene ima u nesavršenostima tržišta kapitala, i to u prvom redu u asimetriji informacija između zajmodavaca i zajmoprimaca. Nesavršenosti tržišta kapitala reflektiraju se u eksternim financijskim premijama koje zahtijevaju investitori.[18] Pritom, financijska premija negativno je povezana s financijskim položajem zajmoprimca, koji se pak najčešće mjeri preko vrijednosti njegovog kolaterala. Tako, što je veća vrijednost kolaterala financijska premija je niža, i obrnuto. Stoga, kada vrijednosti kolaterala, najčešće nekretnina, padnu, kao što je to bio slučaj s američkim tržištem nekretnina i dionica 2007. godine, kapacitet privatnog sektora za zaduživanje se smanjuje. Navedeno posljedično vodi do rasta štednje i pada investicija, proizvodnje i dohotka, što u „novom krugu“ može dodatno smanjiti vrijednost kolaterala. U priči o globalnoj financijskoj krizi, ovaj mehanizam rezultirao je smanjenjem dohodaka ne samo u SAD-u, već i u svim zemljama koje izravno ili neizravno ovise o američkim kupnjama, da bi onda i u tim zemljama počeo djelovati negativni akcelerator jer je vrijednost imovine i kod njih pala.

Opisani mehanizam financijskog akceleratora prikazan je sljedećom slikom.

[18] Eksterna financijska premija može se definirati kao razlika troška za dužnika nastalog vanjskim zaduživanjem i oportunitetnog troška vlastitih sredstava. Više u Bernanke (2007).



Slika 4: Efekt financijskog akceleratora
Izvor: Izrada autorice na temelju Čorić (2011).

Bankovni bilančni kanal (kanal gubitka)

Ovaj mehanizam usko je povezan s prethodnim mehanizmom. Naime, zbog pada vrijednosti nekretnina kakav je i zabilježen na tržištu nekretnina u SAD-u 2007. godine, udio nenaplativih kredita u bilancama banaka u SAD-u porastao je. Dva su razloga zbog kojih se to dogodilo. Kako ističu iz Hrvatske udruge banaka (HUB, 2008), prvi razlog jest taj što vrijednost nekretnina predstavlja jednu od najvažnijih odrednica ponašanja kućanstava u pogledu urednosti otplate hipotekarnih kredita. U tom smislu, veća vrijednost povećava sigurnost naplate od strane banaka. Drugi razlog nalaže sama logika, a taj je da zbog smanjenja vrijednosti kolaterala, banke ne mogu u potpunosti povratiti iznos odobrenog kredita naplatom iz kolaterala. Gubitci američkih banaka prenijeli su se i na europske banke 2008. godine, i to preko nekoliko kanala: izravnim izlaganjem američkim hipotekarnim instrumentima, izlaganjem nesolventnim američkim financijskim institucijama, te izlaganjem europskim klijentima koji zbog duboke recesije nisu mogli vraćati kredite (Prohaska et. al., 2012).[19]

Kamatni kanal

Prethodno opisan mehanizam širenja krize djelovao je putem kreditnog rizika s kojim se banke redovito susreću u svom poslovanju, a koji se odnosi na rizik da osobe koje su pozajmile sredstva neće ista vratiti o roku dospijeća, nikako ili u cijelom iznosu. Kamatni kanal pak djelovao je preko kamatnog rizika koji predstavlja drugu vrsta rizika kojemu su

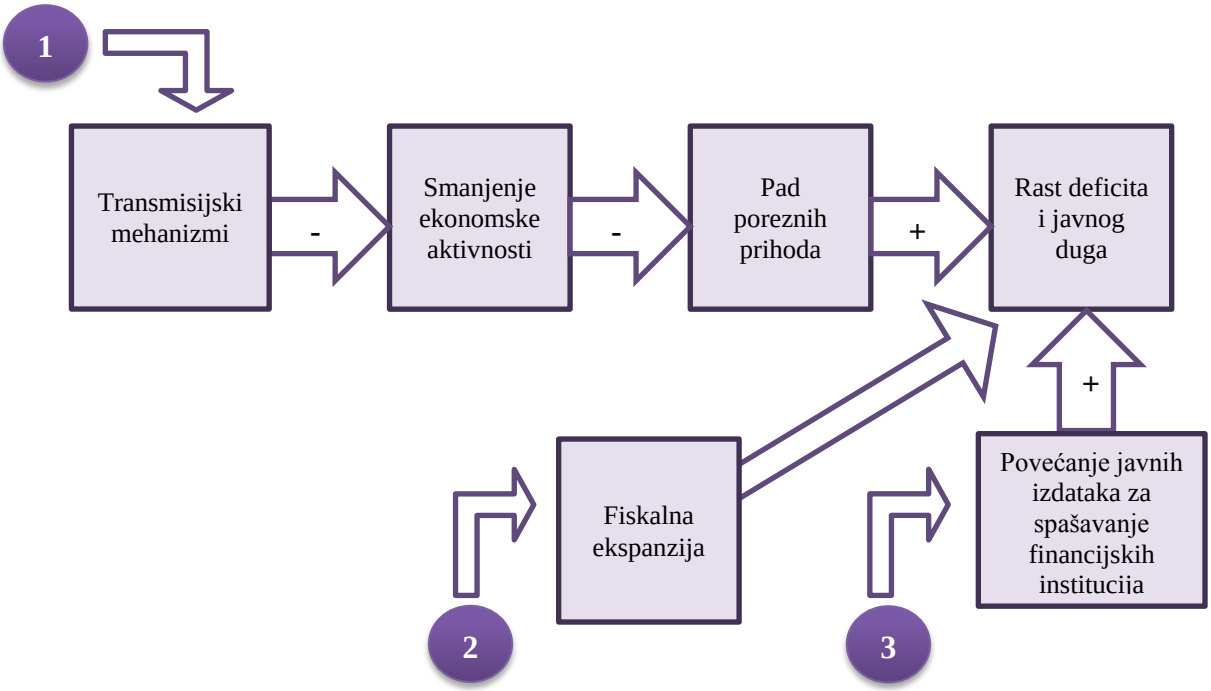
[19] Sredinom 2008. Financijska kriza koja se iz SAD-a prelila na Europu, u većini europskih zemalja prerasla je i u gospodarsku krizu što je samo mulitipliciralo inicijalni negativan šok.

banke konstantno izložene. Kako navodi Živko (2006) kamatni rizik za banku se pojavljuje pri transformaciji kratkoročno pribavljenih sredstava u dugoročne plasmane. Tako, kada kamatne stope rastu, prihodi banke mogu padati kada ona svoje obveze otplaćuje po višim kamatnim stopama nego što su one koje naplaćuje na svoju aktivu. Kod financijske krize dogodila se situacija da su se kamatne stope na međubankarskom tržištu zadržavale visoko, pa su mnoge banke bilježile gubitke koji su kod pojedinih banaka rezultirali nelikvidnošću i stečajem.[20] Prohaska et. al. (2012) navode primjer britanske banke Northern Rock, kao i pojedine banke na Islandu. Zbog djelovanja ovog mehanizma stradale su i mnoge druge banke koje nisu imale značajniju izloženost rizicima američkog hipotekarnog tržišta.

Fiskalni kanal

Kako ističu iz Hrvatske udruge banaka (2010) kanal koji povezuje bankovnu i fiskalnu krizu vrlo je složen jer počiva na tri vrste veza. Prva veza proizlazi iz pada ekonomske aktivnosti, kao direktnoj posljedici prethodno opisanih mehanizama, zbog čega država bilježi pad poreznih prihoda i posljedično povećava državni deficit a time i javi dug. Javni dug povećava se i kada se država zadužuje kako bi pomogla u spašavanju financijskih institucija znatno pogođenih financijskom krizom. Konačno, treća veza odnosi se na reakacije vlade putem ekspanzivne fiskalne politike u nadi da će potaknuti rast agregatne potražnje. Međutim, i ova akcija povećava deficit i javni dug, što onda sve skupa otvara pitanje dugoročne održivosti takve politike. Kanal koji povezuje bankovnu i fiskalnu krizu slikovito dočarava slika 5.

[20] Riječ je o kamatnim stopama po kojima banke posuđuju jedna drugoj poput LIBOR-a i EURIBOR-a. Ove kamatne stope utvrđuju se svaki dan. Pitanje koje se logički nameće u ovom slučaju jest zašto su banke u tim uvjetima posuđivale jedna od druge, a ne primjerice od središnje banke. Postoji jak razlog tome. Naime, posuđivanje banke od središnje banke može kod klijenata te banke stvoriti osjećaj da je banka u problemima, što se u konačnici može manifestirati u još većim problemima za banku poput pojačanj povlačenja depozita.



Slika 5: Kanal koji povezuje bankovnu i fiskalnu krizu
Izvor: Izrada autorice na temelju HUB (2010).

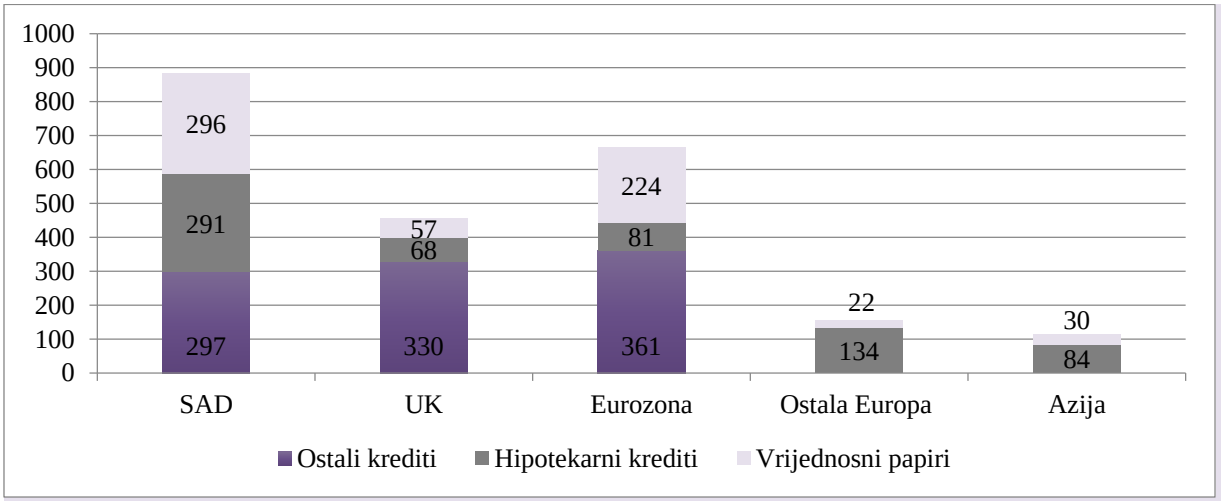
Kanal kompleksnosti

Kanal kompleksnosti odnosi se na interakciju gore, prethodno navedenih kanala, koji sami po sebi djeluju linearno. Primjer djelovanja ovog mehanizma može se nasloniti na priču u okviru prvog mehanizma. Naime, kako je već ranije spomenuto pad vrijednosti financijskih imovina uzrokuju pad outputa i zaposlenosti. Zbog djelovanja financijskog akceleratora navedeno može prijeći u novi krug dodatnog smanjenja cijena financijskih imovina što na isti način opet smanjuje output i zaposlenost. Opetovanim ponavljanjem ovih krugova može doći do spirale pada neto vrijednosti koja pak može dodatno povecati rizike i uzrokovati rast kamatnih stopa, što pak može pogoršati negativne ucinke koji djeluju kroz bilančni, kamatni i fiskalni kanal.

2.5. Utjecaj financijske krize na bankarske sustave u svijetu

Godinama nakon financijske krize zbrajali su se gubici od iste. Pritom, u prvih par godina, orijentacija je uglavnom bila na mjerljivim, novčanim gubicima od krize. Tako je Međunarodni monetarni fond (MMF, 2010) 3 godine nakon krize procijenio ukupne gubitke banaka od iste na ogromnih 2,8 bilijuna američkih dolara. Sljedeći graf prikazuje na koga se tih 2,8 bilijuna dolara gubitka odnose po geografskoj osnovi. Tako se, iz grafa 6 može uočiti

da su daleko najveće gubitke zabilježile banke u SAD-u (884 milijarde dolara), što zapravo nije ni čudno jer je kriza tamo i počela. Odmah iza SAD-a nalazi se Eurozona s nekih 666 milijardi dolara gubitka. Najmanje gubitke u prve tri godine krize zabilježile su azijske banke. S obzirom na vrstu kredita, može se uočiti da najveći dio uglavnom otpada na ostale kredite koji se uglavnom odnose na izloženosti prema inozemstvu.



Graf 6: MMF-ove procjene gubitaka banaka (2007.-2010.)
Izvor: Izrada autorice na temelju MMF (2010).

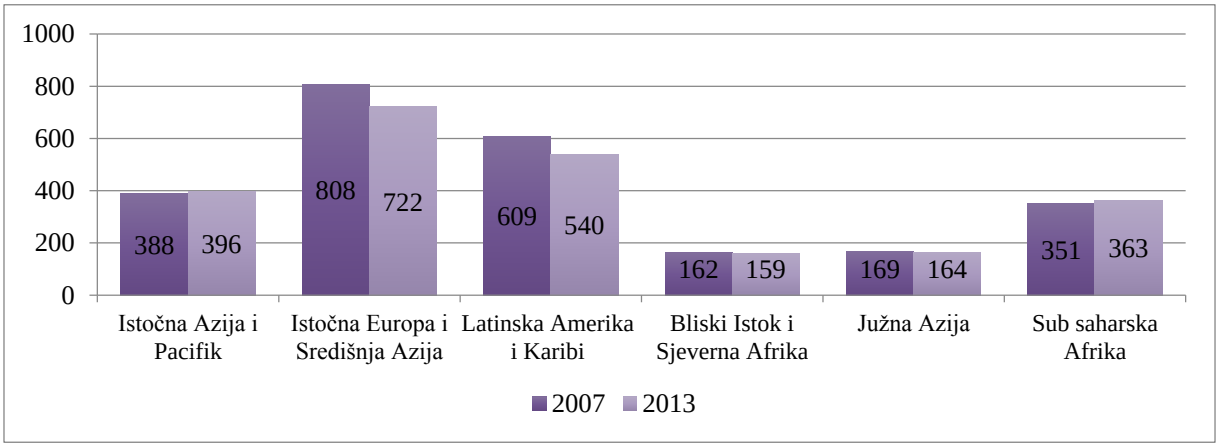
Novija istraživanja i radovi nisu orijentirani isključivo na gubitke banaka. Naime, prepoznalo se da globalna financijska kriza iz 2007./2008. godine nije bila obična financijska kriza. Tako primjerice Atkinson et al (2013) navode četiri kategorije troškova od globalne financijske krize, a to su: troškovi ekonomskog outputa, financijskog bogatstva, psiholoških posljedica i pada vještina zbog produžene nezaposlenosti, te troškovi koji se ogledaju u značajnom rastu državnih intervencija. Prema ovim autorima, kada bi se sve navedene kategorije troškova uzele u obzir, došlo bi se do podatka da je samo u SAD-u ukupni gubitak bio veći od jednogodišnjeg BDP-a.

U nastavku teksta, a u skladu s temom istraživanja, orijentacija je isključivo utjecaj globalne financijske krize na bankarske sektore u svijetu.

Globalna financijska kriza, zahvaljujući gospodarskoj velesili od koje je i potekla i njezinu utjecaju koje ima na ostale zemlje preko brojih kanala, odrazila se na bankarske sektore diljem zemaljske kugle. Sljedeća dva grafa potkrjepljuju navedenu tvrdnju.

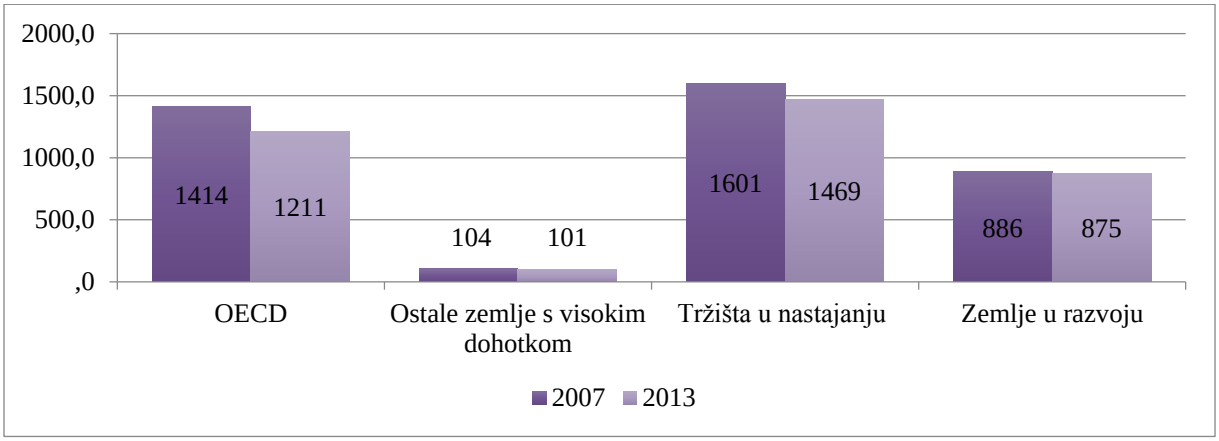
Graf 7 prikazuje broj banaka u glavnim svjetskim regijama u 2007., i u 2013. godini. Može se uočiti da su sve regije osim Istočne Azije i Pacifika, te Sub saharske Afrike zabilježile manji

broj banaka u 2013., u odnosu na 2007. godinu. Pritom, na istom grafu može se uočiti da je najveći pad zabilježen u Istočnoj Europi i Središnjoj Aziji gdje je u sedmogodišnjem periodu propalo čak 86 banaka, dok je najmanji pad zabilježen u Južnoj Aziji gdje je u istom periodu propalo samo 5 banaka.



Graf 7: Ukupan broj banaka po regijama (2007. i 2013.)
Izvor: Izrada autorice na temelju podataka iz Claessens i van Horen (2014).

Graf 8 prikazuje isto što i graf 1, s tim da su ovaj put u obzir uzeti dohodovni razredi. Zanimljivo, u promatranom sedmogodišnjem periodu najviše banaka propalo je upravo u najbogatijim zemljama (OECD), i to njih čak 203. Najmanje banaka propalo je kod zemalja u razvoju.



Graf 8: Ukupan broj banaka po dohodovnim razredima (2007. i 2013.)
Izvor: Izrada autorice na temelju podataka iz Claessens i van Horen (2014).

Kao što prikazuju prethodna dva grafa, kriza koje počela u SAD-u odjeknula je u bankarskim sektorima diljem svijeta. Međutim, valja napomenuti da financijska kriza nije imala jednaku jačinu utjecaja u svim zemljama. Jačina utjecaja ovisila je i o nizu makroekonomskih uvjeta u

pojedinoj zemlji. Stoga, iako je kriza uzdrmala cijeli svijet, nakon sabiranja ukupnih gubitaka Delia (2012) identificira tri temeljne grupe zemalja čije su banke zabilježile najveće gubitke od financijske krize, a to su:

1. GRUPA – zemlje poput SAD-a, Ujedinjenog Kraljevstva i Irske u kojima su se banke suočile s drastičnim rezom u imovini bilance zbog pada vrijednosti kolaterala i posljedično gubitaka po osnovi odobrenih kredita 2007. godine;

2. GRUPA - zemlje poput Belgije, Nizozemske, Švicarske i Islanda, u kojima su lokalna tržišta bila nedovoljna za ambicije njihovih financijskih institucija što je rezultiralo velikoj izloženosti u drugim proizvodima koji nisu tipično bankarski; te

3. GRUPA - slučaj Njemačke u kojoj značajan postotak bankarske industrije nije imao održiv i dovoljno kvalitetan poslovni uzorak, te je veliki dio banaka poslovao u transakcijama koje su bili substituti kreditiranju (primjerice kupnja kredita umjesto direktno kreditiranje).

Iz navedenih grupa može se primijetiti da je uglavnom riječ o bankama u europskim zemljama. I zaista, europske banke pretrpjele su najveće gubitke, što nije ni čudno s obzirom na to da su se gubici od financijske krize na europske banke, kako je već ranije navedeno u prethodnom potpoglavlju, prelijevali preko čak tri kanala i to (HUB, 2010):

- izravnim izlaganjem američkim hipotekarnim instrumentima,
- izlaganjem nesolventnim američkim financijskim institucijama,
- i izlaganjem europskim klijentima koji zbog duboke recesije nisu mogli vraćati kredite.

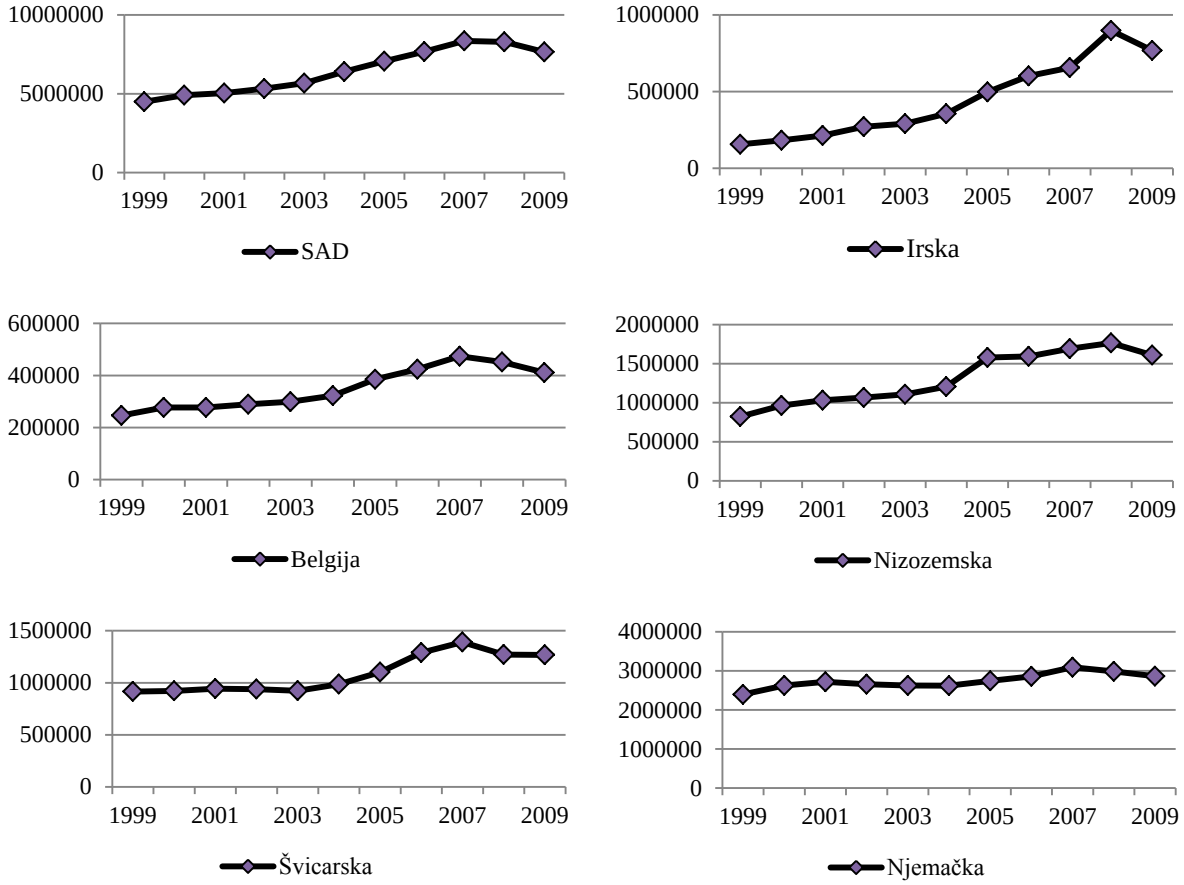
U nastavku slijedi nekoliko statističkih činjenica o kretanju kredita i profitabilnosti banaka iz navedene tri grupe zemalja, te još par zemalja koje prema Globalnom indeksu prisutnosti[21] predstavljaju najjače ekonomije svijeta, a s ciljem da se identificira jačina utjecaja financijske krize na njihove bankarske sustave.

2.5.1. Krediti i profitabilnost banaka u svijetu

Graf 9 prezentira kretanje ukupnih kredita banaka za nekoliko zemalja[22]. Mo e se uo iti da je kod svih promatranih zemalja zabilje en sli an trend kretanja ukupno odobrenih kredita. Naime, kod svih promatranih zemalja mo e se uo iti rast ukupno odobrenih kredita do 2007.

[21] Elcano Royal Institute (2015).
[22] Za ostale zemlje iz prethodno navedenih grupa podaci nisu bili dostupni. Dodatno, nije bilo podataka za godine iza 2009.

odnosno 2008. godine kod Irske i Nizozemske, nakon ega ukupno odobreni krediti padaju. Razlog zašto je kod nekih zemalja rast prisutan i u 2008. godini pa se tek onda dogodio pad jest taj što je u te zemlje financijska kriza došla s vremenskim zaostatkom.

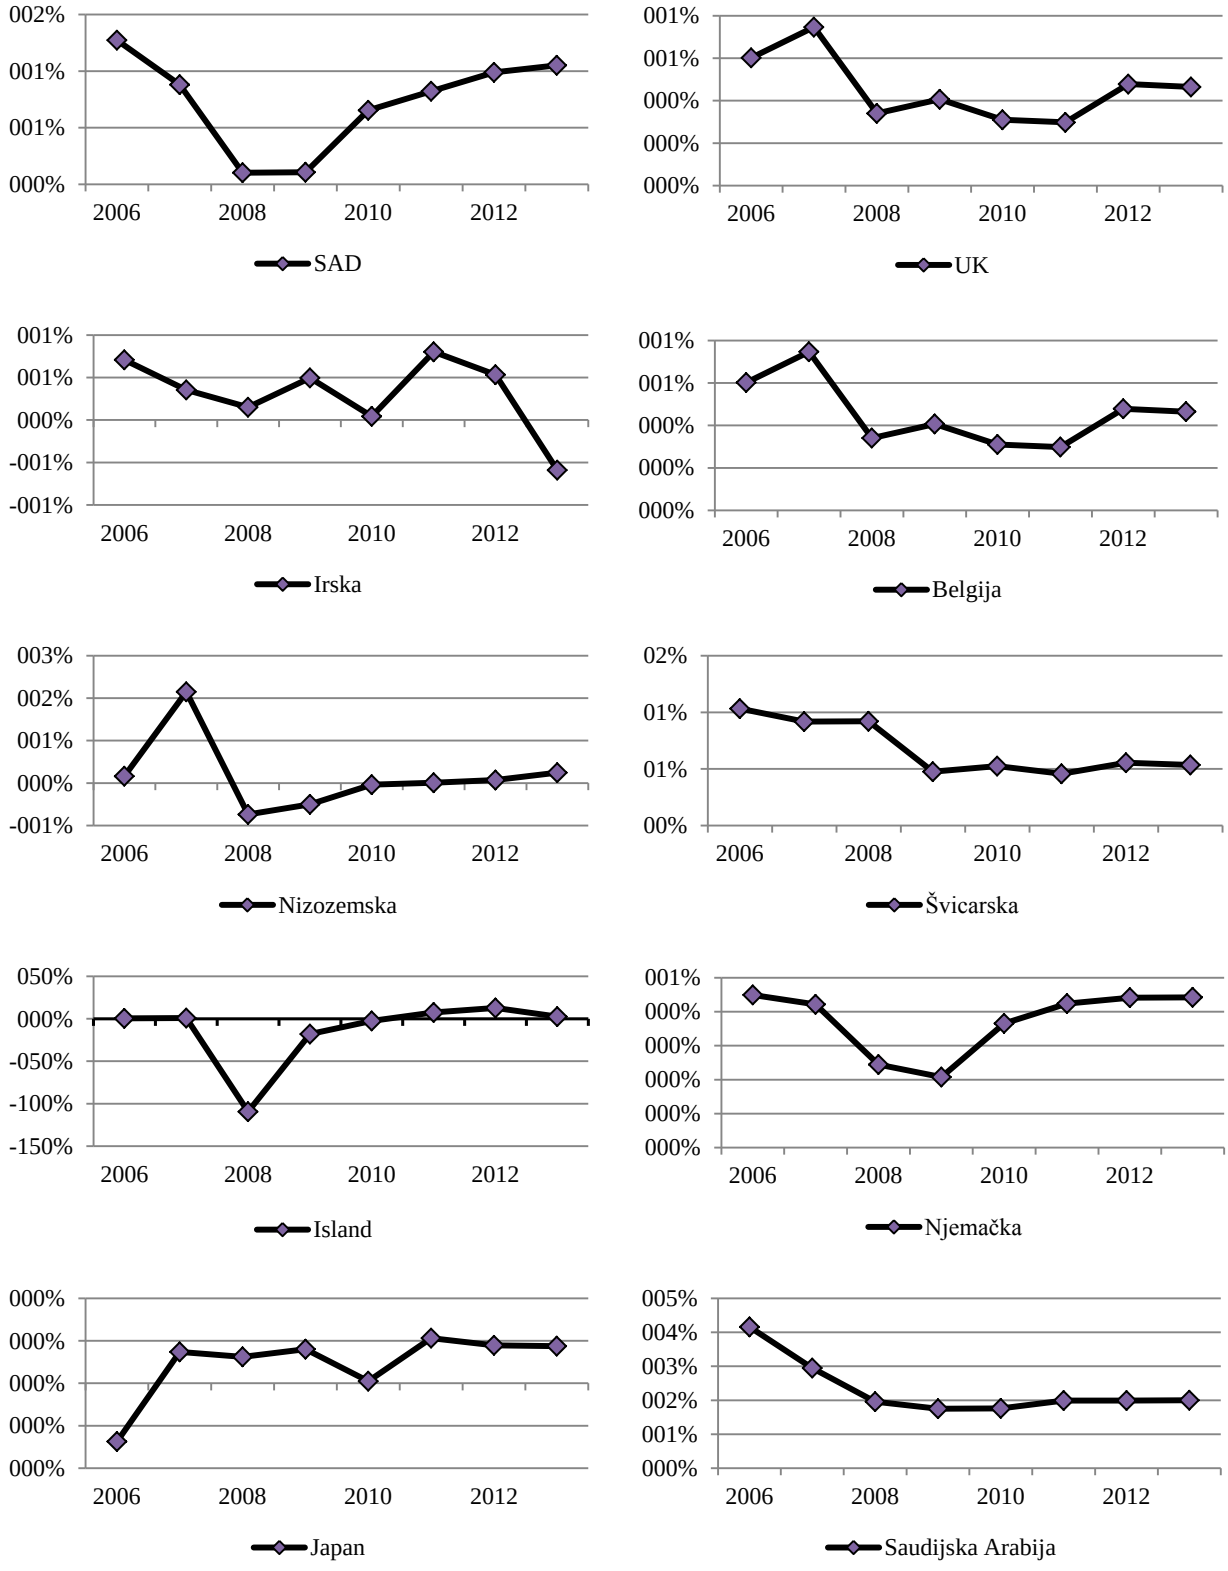


Graf 9: Ukupni krediti banaka odabranih zemalja u nacionalnoj valuti u mil. (1999.-2009.)

Izvor: Izrada autorice na temelju podataka OECD (2016).

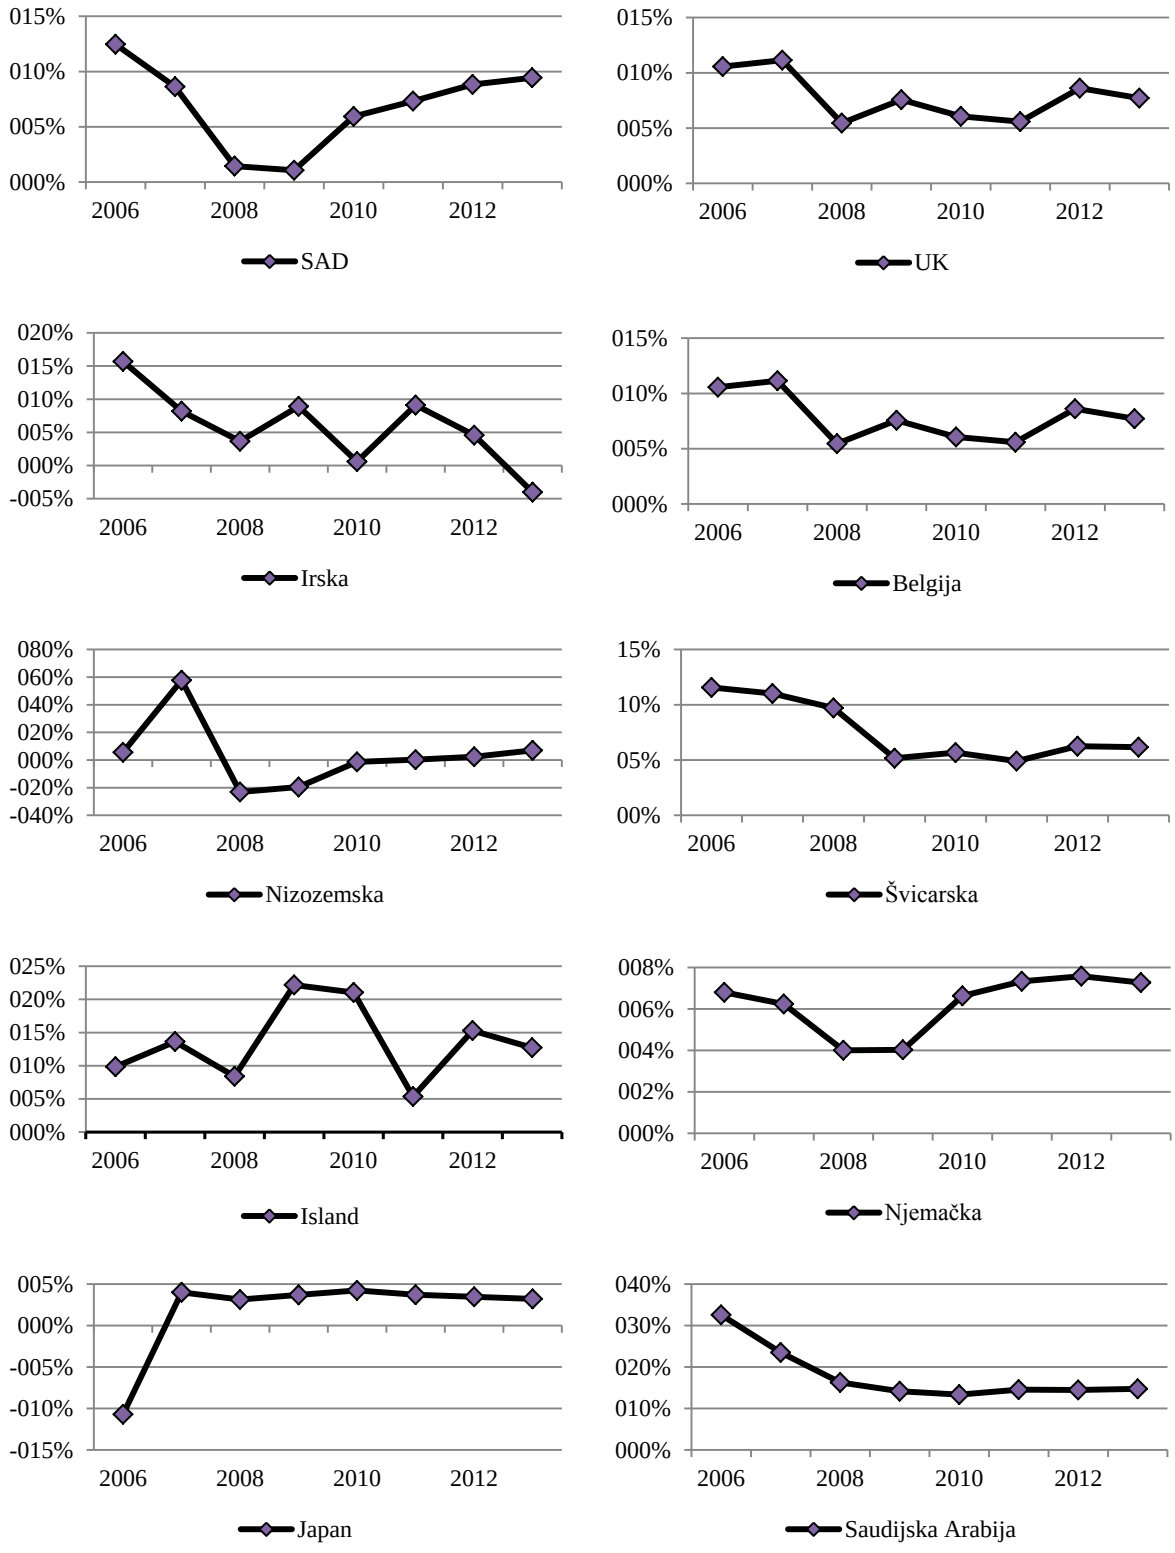
Kretanje ukupnih kredita dobar je, ali ne i dovoljno dobar pokazatelj utjecaja financijske krize na bankarske sustave zemalja. Naime, u vrijeme globalne financijske krize, a naročito kada je ista rezultirala i gospodarskom krizom u mnogim zemljama, banke su sve više i više financirale državu, a manje privatni sektor, pa onda ovaj agregat na određeni način maskira stvarni efekt utjecaja krize na ukupno odobrene kredite banaka. Puno bolji uvid u utjecaj financijske krize na poslovanje banaka može se dobiti proučavanjem pokazatelja profitabilnosti. Pokazatelji profitabilnosti kroz duži vremenski period u odabranim zemljama prikazani su na grafovima koji slijede. Graf 10 prikazuje kretanje pokazatelja povrata na imovinu (ROA) u bankama odabranih zemalja. Može se uočiti da kod skoro svih zemalja ROA kontinuirano pada već od 2006. odnosno 2007. godine, ovisno o tome kada se kriza prelila na promatranu zemlju. Najveće iznenađenje svakako predstavlja Japan. Naime, može

se uočiti da ROA japanskih banaka od 2006. godine kontinuirano raste. Ovo je i u skladu s grafom 7 iz ovog dijela gdje se vidi da, što se tiče kretanja ukupnog broja banaka da je broj banaka u Istočnoj Aziji i Pacifiku za vrijeme trajanja globalne financijske krize rastao.



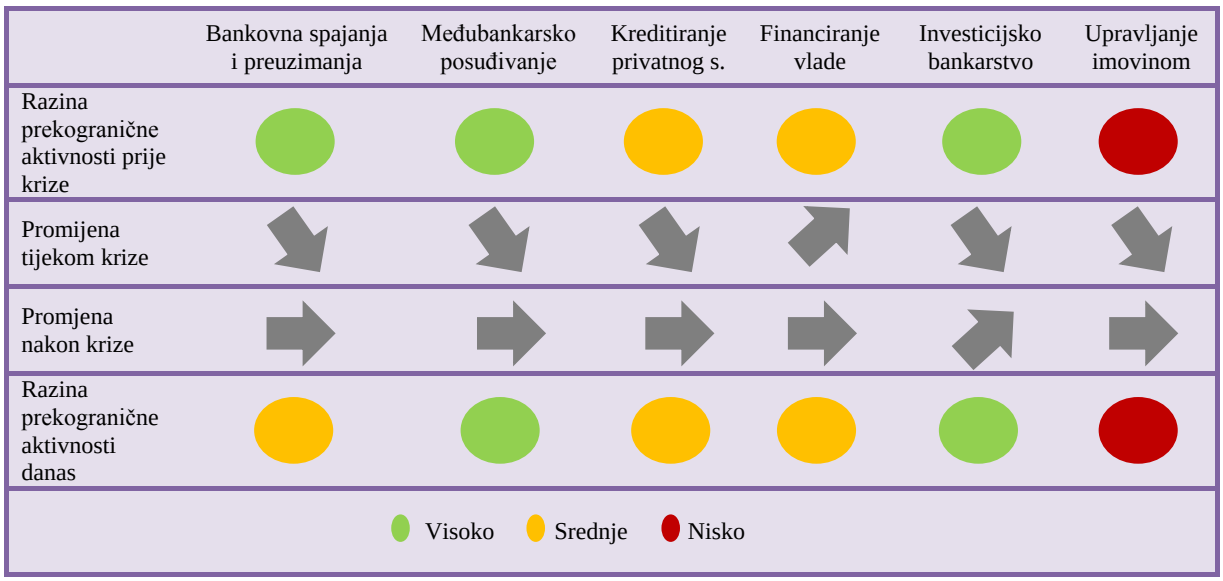
Graf 10: ROA banaka odabranih zemalja u % nakon poreza, (2006.-2013.)
Izvor: Izrada autorice na temelju podataka sa Svjetske banke (2016).

Graf 11 prikazuje kretanje pokazatelja povrata na kapital (ROE) u bankama odabranih zemalja. Osim što je ovaj pokazatelj na većim razinama, njegovo kretanje kroz duži vremenski je skoro identično kretanju pokazatelja povrata na imovinu banaka (ROA).



Graf 11: ROE banaka odabranih zemalja u %, nakon poreza (2006.-2013.)
Izvor: Izrada autorice na temelju podataka sa Svjetske banke (2016).

Za kraj ovog dijela još će se prokomentirati prekogranične aktivnosti europskih banaka. Schildbach (2011) proučavao je razinu prekograničnih aktivnosti 20 najvećih banaka u Europi i to u periodu prije, tijekom i nakon globalne financijske krize. Sljedeća slika rezultat je njegove analize. Ono što se može uočiti jest da je financijska kriza dovela do smanjena u svim segmentima prekograničnog poslovanja banaka, od bankovnih preuzimanja i spajanja, međubankarskog posuđivanja, preko kreditiranja privatnog sektora do investicijskog bankarstva. Jedino je financiranje vlade tijekom globalne financijske krize raslo. Na sreću, u vremenima nakon krize najveće europske banke oporavile su se po pitanju prekograničnih aktivnosti, te su sada, kako navodi isti autor, internacionaliziranije nego ikada.



Slika 6: Aktivnosti top 20 europskih banaka prije i nakon financijske krize
Izvor: Izrada autorice na temelju Schildbach (2011).

3. BANKARSKI SEKTOR REPUBLIKE HRVATSKE

3.1. Važnost bankarskog sektora za gospodarstva zemalja

Financijski sustav neke zemlje sastoji se od njezine valute i platnog sustava, financijskih tržišta, financijskih institucija, te institucija koje reguliraju i nadziru njihov rad (HNB, 2011). Levine (2005) objašnjava kako se financijski sustav može temeljiti na bankama ili vrijednosnim papirima, te da može utjecati na gospodarski rast. Pri tome za poticanje gospodarskog rasta nije važno na čemu se temelji financijski sustav nego da uspješno obavlja svoje temeljne funkcije. Ipak važno je istaknuti da financijskom sustavu Republike Hrvatske upravo poslovne banke zauzimaju dominantu poziciju jer posjeduju 71,5 posto imovine financijskog sektora (HNB, 2015c), stoga je upravo njihova uloga ključna u provođenju 5 temeljnih funkcija financijskog sustava koje identificra Levine (1997):

1. pospješivanje upravljanja rizikom;
2. alokacija resursa;
3. nadziranje menadžera i kontrola korporativnog upravljanja;
4. mobilizacija štednje;
5. olakšavanje razmjene dobara i usluga.

Montiel (2003) identificira još 3 načina na koja financijski sustav može potaknuti gospodarski rast:[23]

1. stvaranje poticaja za akumulaciju fizičkoga i ljudskog kapitala;
2. alocirajući kapital u najproduktivnije aktivnosti;
3. smanjujući količinu resursa koji se troše u procesu posredovanja.

Jakovčević (2011) također primjećuje kako je za svako nacionalno gospodarstvo bankovni sustav od iznimne važnosti te da bi razvijenost bankovnog sustava morala izravno korelirati s razvijenošću gospodarstva zbog toga što su banke financijski servis realnog sektora, pa je i njihova međuovisnost izravna. Bađun (2011) tvrdi kako banke djeluju kao posrednici između štediša i osoba koje mogu ili žele uzajmiti novac, tj. drugim riječima banke su financijske institucije koje obnašaju funkciju redistribucije štednih depozita u korist kreditno deficitarnih institucionalnih sektora. Nadalje Bađun (2011) uočava Cameronovo (1972) stajalište da o bankama kao posrednicima ovisi hoće li tražiti i privlačiti zalihe neiskorištenih sredstava koje

[23] u Bađun (2011)

će kasnije biti dodijeljene poduzetnicima za investicijske projekte i koji će imati veliku stopu društvenog povrata, ili te investicijske mogućnosti neće iskoristiti zbog neproduktivnih zajmova.

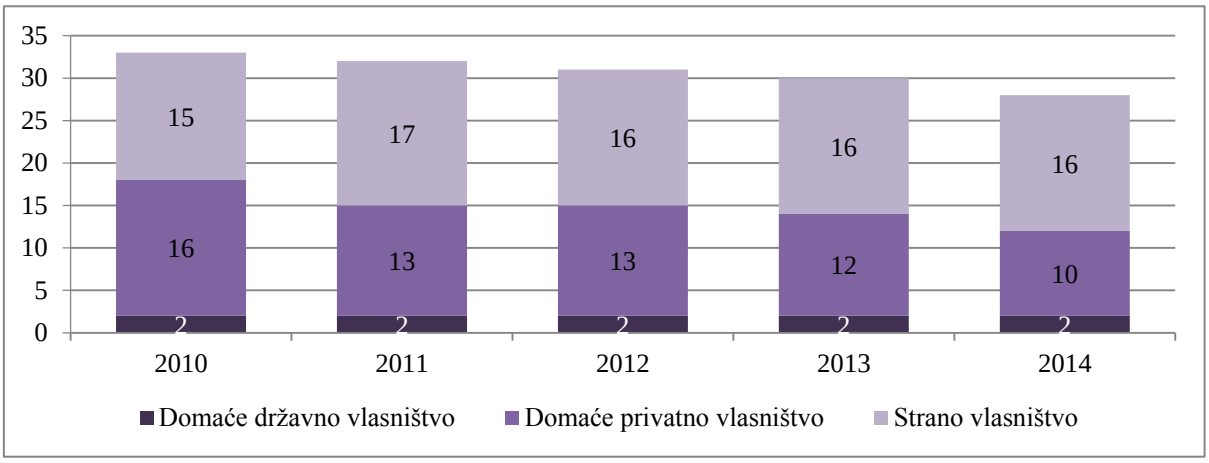
Jakovčević (2011) shvaća važnost kreditne funkcije banaka te objašnjava da se zbog te funkcije financiraju i podržavaju proizvodnja, potrošnja i investicije te se tako uspostavlja sudbinska povezanost bankarstva i gospodarstva, jer samo zdravo gospodarstvo može podmirivati preuzete kreditne obveze, čime se omogućuje rast kreditnih potencijala banaka koje onda mogu nastaviti s usmjeravanjem kredita tom istom gospodarstvu, koje u svakom narednom ekonomskom ciklusu teži stvaranju novih vrijednosti. Zbog toga je prirodno očekivati da bi veći bankovni potencijal mogao rezultirati i snažnijom kreditnom aktivnošću prema realnom sektoru sa zajedničkim ciljem rasta i kvalitetnog razvitka pojedinih djelatnosti, odnosno, rasta BDP-a, čime se zapravo naglašava općekorisna djelatnost bankarstva poboljšavanjem životnog standarda cjelokupne nacije (Jakovčević, 2011).

U bankarskom sustavu RH, banke imaju važnu ulogu na 3 tržišta (HNB, 2015c), a to su:

1) *Novčano tržište* (poslovne banke prikupljaju slobodna novčana sredstva (do godinu dana) i pozajmljuju ih fizičkim i pravnim osobama);
2) devizno tržište (banke zadovoljavaju domaću potražnju za stranom valutom kao i inozemnu potražnju za domaćom valutom); te
3) *tržište kapitala* (banke se pojavljuju u dvostrukoj ulozi, neposredno pozajmljujući kapital fizičkim osobama te pravnim osobama koje nemaju neposredan pristup tržištu kapitala, i ulažući u instrumente tržišta kapitala koje su izdale pravne osobe koje imaju neposredan pristup tom tržištu).

3.2. Struktura bankarskog sektora RH

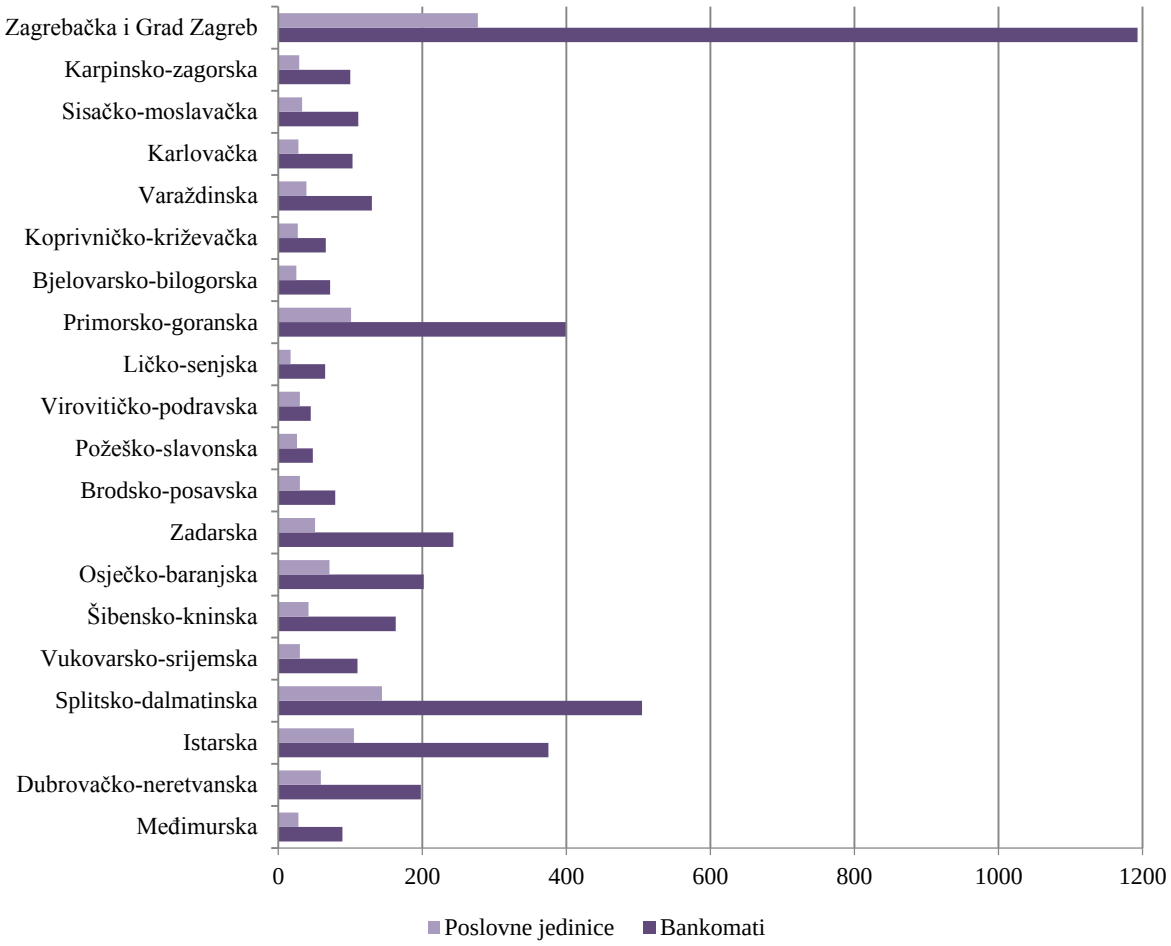
Prema Godišnjem izvješću Hrvatske narodne banke za 2015. godinu (HNB, 2015a) na kraju 2014. u Republici Hrvatskoj poslovale su 33 kreditne institucije od čega 27 banaka, 1 štedna banka i 5 stambenih štedionica. U usporedbi s godinom prije (2013.) poslovale su dvije institucije manje jer je jedna banka (Nava bankom d.d.) otišla u stečaj, a jedna je pripojena drugoj banci (Banco Popolare d.d. je pripojena OTP banci Hrvatska).



Graf 12: Broj banaka prema sjedištu vlasnika i vrsti vlasništva, na kraju razdoblja (2014.)
Izvor: Izrada autorice na temelju podataka iz HNB (2015a).

Na Grafu 12 se može uočiti da je u 2014. najveći broj banaka u stranom vlasništvu (57%), a ostatak u domaćem vlasništvu, s time da se 36 posto banaka nalazi u domaćem privatnom vlasništvu, a 7 posto banaka u domaćem državnom vlasništvu. Najviše banaka, njih 6, se nalazi u u vlasništvu dioničara iz Austrije dok 3 banke većinski drže talijanski dioničari. Jednu banku u svom vlasništvu imaju dioničari iz Madžarske, Francuske, San Marina, Švicarske, Srbije i Turske, te Češke koja se po prvi put u 2014. godini pojavila na popisu (HNB, 2015b). Popis svih kreditnih institucija koje posluju u Hrvatskoj dan je u Prilogu 1.

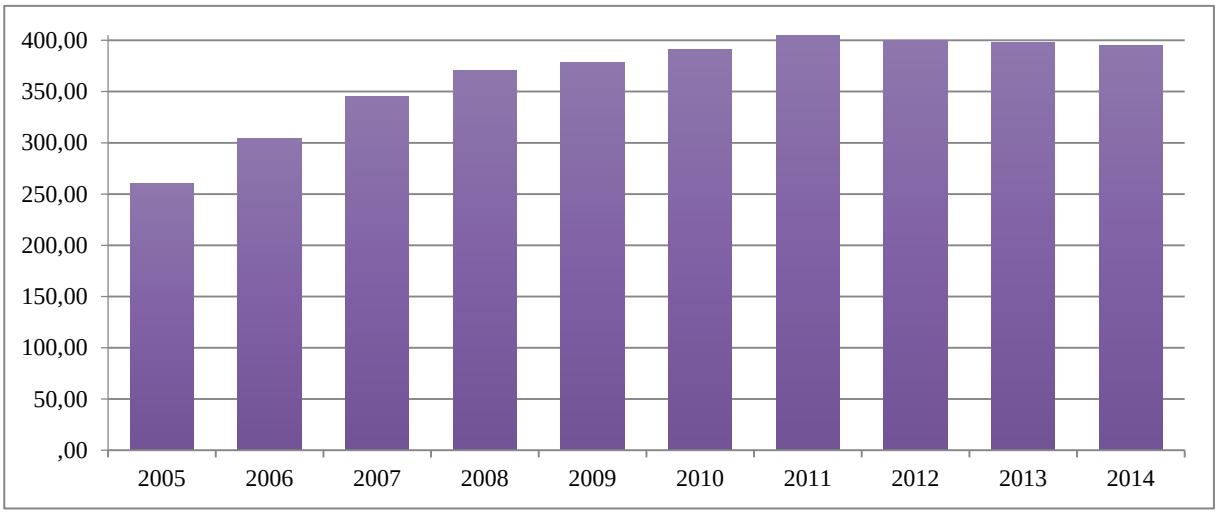
U 2014. godini broj poslovnih jedinica banaka nastavio je trend pada te se smanjio za 28 (ukupno ih je u 2014. bilo 1192 u odnosu na 1220 iz 2013.) što predstavlja pad od 2,3 posto. Višegodišnje smanjivanje poslovnih jedinica je rezultiralo time da je njihov broj u 2014. Bio manji za 6,4 posto u odnosu na 2010. godinu kada ih je bilo 1274. Na kraju 2014. godine u prosjeku, banke su imale po 43 poslovne jedinice od čega su samo tri banke poslovale u svim županijama, a dvije samo s jednom poslovnicom. S druge strane, mreža bankomata se nastavila povećavati. U 2014. bilo je ukupno 4296 bankomata, odnosno 173 bankomata više nego godine prije, što predstavlja rast od 4,2 posto u relativnim terminima. Najviše je poslovnih jedinica i bankomata u Gradu Zagrebu i Zagrebačkoj županiji, potom u Splitsko - dalmatinskoj županiji, pa u Istarskoj i Primorsko goranskoj itd. Koncentracija poslovnih jedinica i bankomata po županijama RH prikazana je na Grafu 13.



Graf 13: Koncentracija poslovnih jedinica i bankomata po županijama RH, na kraju razdoblja (2014)
Izvor: Izrada autorice na temelju podataka iz HNB (2015b).

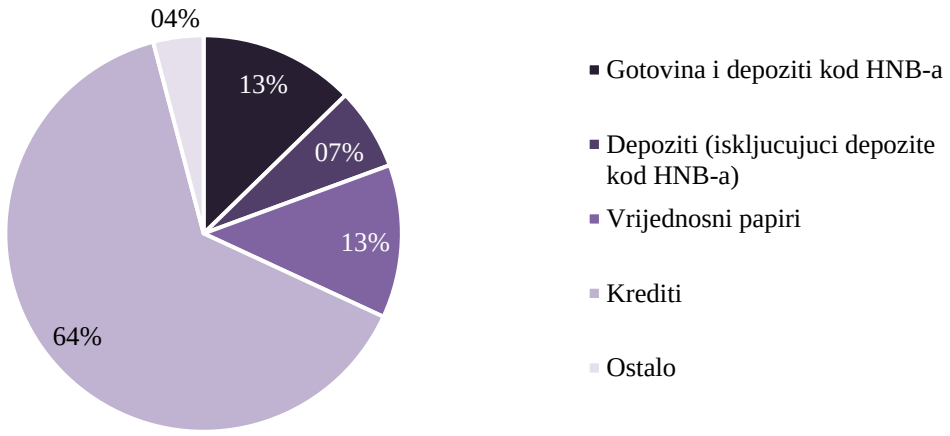
Sa smanjenjem broja poslovnih jedinica, smanjio se i broj zaposlenih. Naime, u 2014. godini u bankama je radilo 20713 zaposlenika što je 269 osoba (odnosno 1,3 posto) manje u odnosu na 2013. godinu. Ovaj pad je nešto manji nego godinu ranije kada je smanjenje iznosilo 3 posto, i kada je u bankama bez posla ostalo 657 osoba.

Što se pak tiče ukupna imovine banaka, ista je na kraju 2014. godine iznosila 395,2 milijarde kuna što u usporedbi s krajem 2013. godine predstavlja pad od 2,6 milijardi kuna odnosno u relativnim terminima pad od 0,7 posto. Ako se gleda situacija bez utjecaja promjene tečaja kune prema tri najzastupljenije valute onda pad iznosi 1,3 posto (HNB, 2015b). Prema objašnjenju HNB-a, razlog za ovakvo smanjenje imovine se, između ostalog, nalazi u smanjenju kreditne aktivnosti, povećanju ispravaka vrijednosti kredita koje je bilo nešto slabije u odnosu na prethodnu godinu, kao i prodaji potraživanja, te smanjivanju broja banaka u sustavu. Kretanje ukupne imovine banaka prikazano je na sljedećem grafikonu (Graf 14).



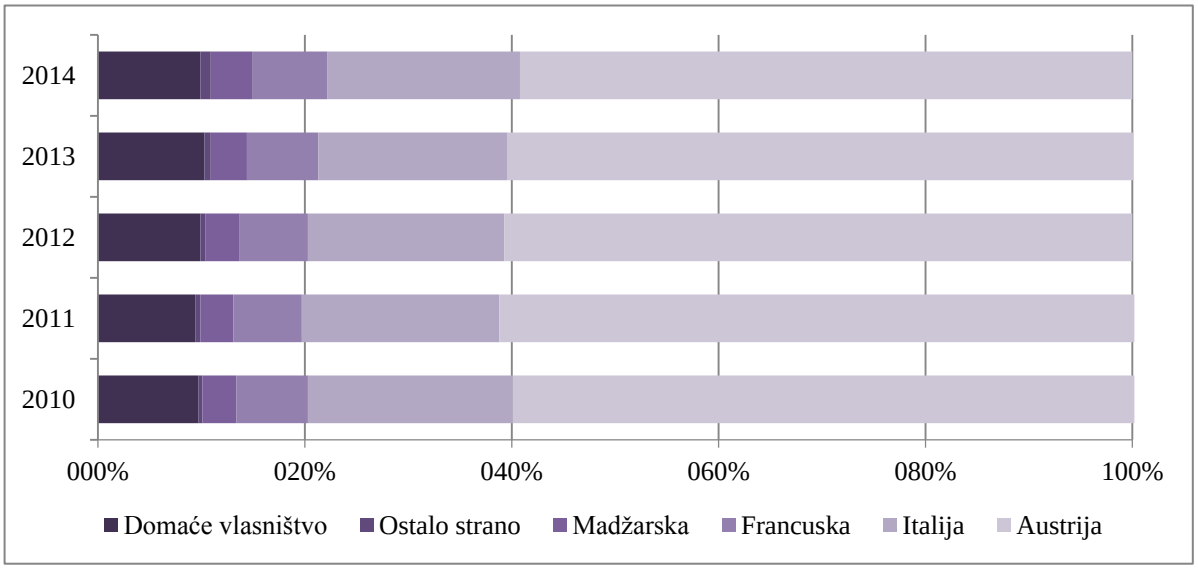
Graf 14: Ukupna imovina banaka u RH, na kraju razdoblja (2014.)
Izvor: Izrada autorice na temelju podataka iz HNB (2015b).

Prikaz strukture stavki ukupne imovine banaka RH nalazi se u Grafu 15. Može se primijetiti da uvjerljivo najveći dio čine krediti koji u strukturi imovine zauzimaju 64 posto s ukupnom vrijednošću od 253,4 milijarde kuna. Na ostale stavke otpada preostalih 36 posto od čega najviše zauzimaju gotovina i depoziti kod HNB-a (12,7 posto odnosno 50,2 milijarde kuna) te vrijednosni papiri kojih je 49,6 milijardi kuna (12,5 posto). Ostalih depozita kod financijskih institucija (koji isključuju depozite kod HNB-a) jest 6,7 posto (što je 26,4 milijarde kuna) dok na sve ostale stavke (npr. kamate, naknade i ostala imovina, razne vrste ulaganja i sl.) spada oko 16,2 milijarde kuna (4,1 posto).



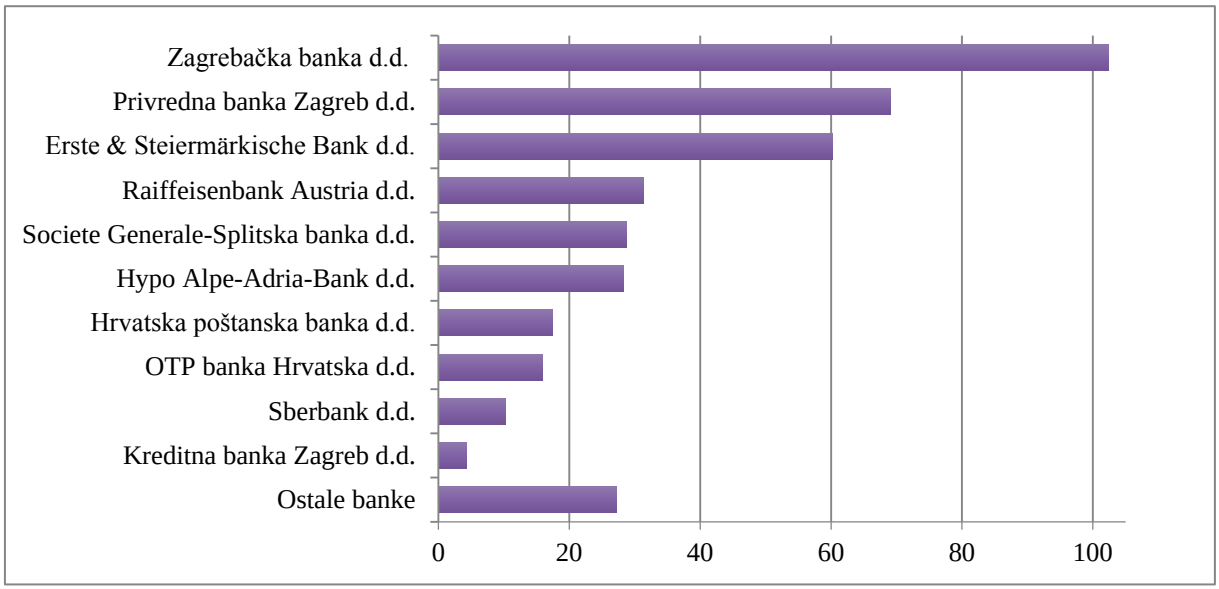
Graf 15: Struktura imovine banaka u RH, na kraju razdoblja (2014.)
Izvor: Izrada autorice na temelju podataka iz HNB (2015a).

Udio stranog vlasništva u ukupnoj imovini je dominantan i u 2014. godini iznosi 90,1 posto. Iako je u 2014. godini imovina stranih vlasnika u apsolutnom iznosu stagnirala, njezin relativni udio u odnosu na godinu prije je porastao (udio imovine stranih vlasnika u 2013. je iznosio 89,7 posto) zbog smanjenja imovine u domaćem vlasništvu. Dioničari iz Austrije imali su najveći udio, čak 59,2 posto, potom s udjelom od 18,6 posto imovine banaka slijedile su banke u većinskom vlasništvu talijanskih dioničara. Dioničari iz Francuske imali su 7,3 posto vlasništva imovine banaka, a mađarski dioničari 4 posto, dok je na preostale strane dioničare otpadalo 1 posto. U domaćem vlasništvu u 2014. godini nalazilo se 9,9 posto ukupne imovine banaka. Struktura imovine banaka prema podrijetlu vlasnika može se vidjeti na Grafu 16.



Graf 16: Imovina banaka prema domicilu dionicara u RH, na kraju razdoblja (2014.)
Izvor: Izrada autorice na temelju podataka iz HNB (2015a).

Najveća banka prema imovini u 2014. je bila uvjerljivo Zagrebačka banka čija je imovina jedina prešla 100 milijardi kuna, te koja posjeduje više od četvrtine imovine svih banaka RH (udio 25,9 posto). Udio najveće dvije banke (Zagrebačke banke i PBZ) u ukupnoj imovini u 2014. Godini iznosio je gotovo polovicu cjelokupne imovine banaka, čak 43,5 posto. Četiri najveće banke imale su zajednički udio od 66,5 posto, a deset najvećih banaka posjedovalo je 93,1 posto ukupne imovine.

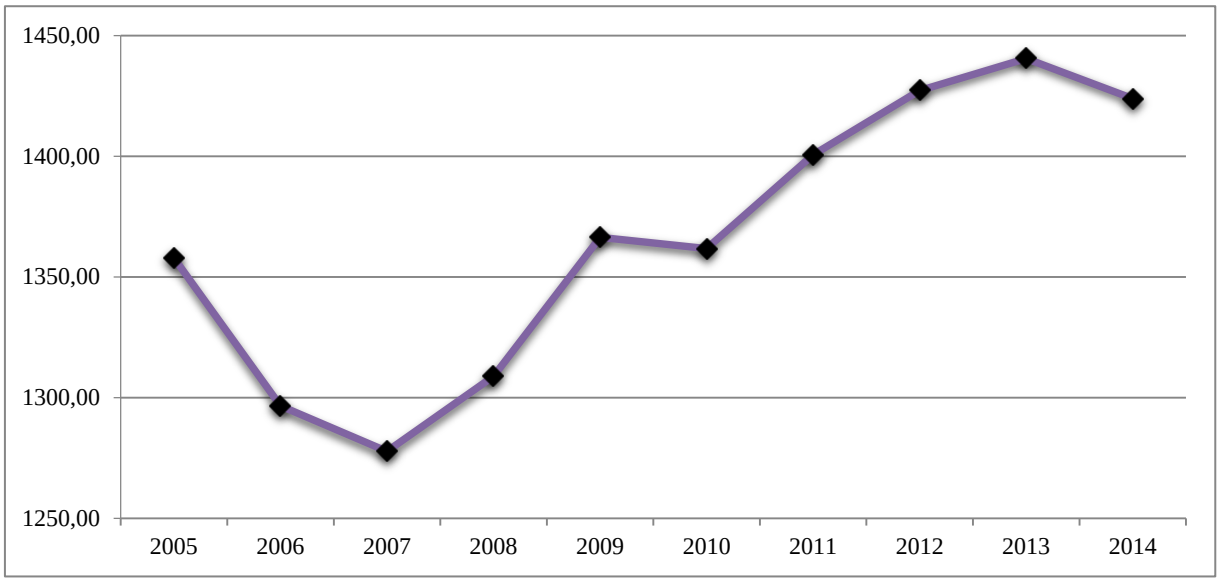


Graf 17: Top 10 banaka u RH po veličini imovine, na kraju radoblja (2014.)
Izvor: Izrada autorice na temelju podataka iz HNB (2015b)

Na Grafu 17 prikazan je iznos imovine 10 najvećih banaka, te svih ostalih banaka. Deveta banka po veličini imovine (Sberbank) je posljednja banka čija je imovina u 2014. prelazila 10 milijardi kuna i već sljedeća banka (Kreditna banka Zagreb) ima više nego duplo manji iznos (cca 4 milijarde kuna).

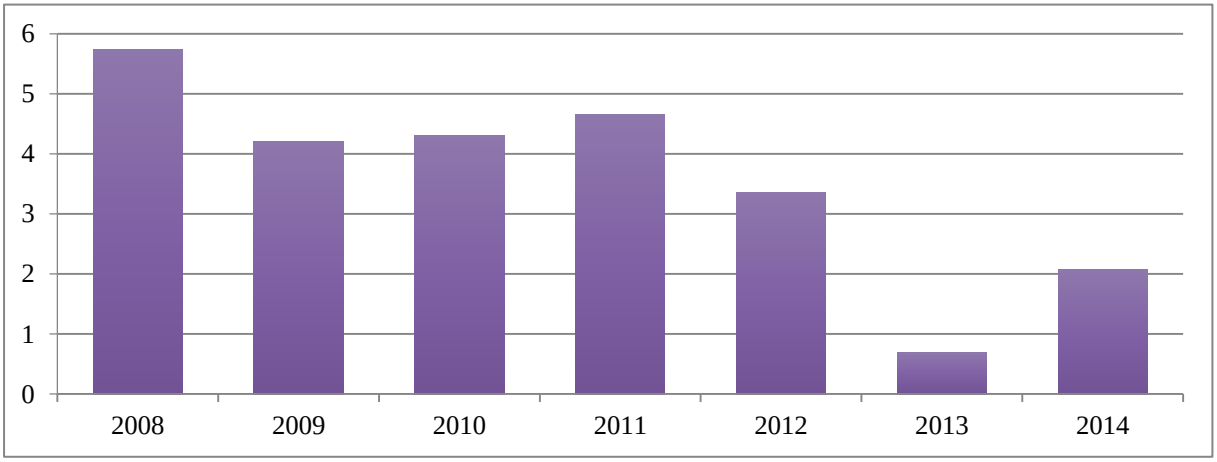
Hrvatska narodna banka redovito objavljuje i vrijednosti Herfindahl-Hirschmanovog indeksa za kojeg Ljubaj (2005) ističe da je najpoznatiji pokazatelj industrijske koncentracije. Računa se kao zbroj kvadrata tržišnih udjela svih poduzeća u nekoj industriji i kreće se u rasponu između 1/n i 1, s time da najnižu vrijednost, koja je jednaka recipročnoj vrijednosti broja banaka, doseže kada su sve banke na tržištu jednake veličine, a u slučaju monopola vrijednost indeksa se približava iznosu 1 (Pavković et al., 2012).

Na Grafu 18 se može vidjeti da je vrijednost HHI-ja u 2014. godini iznosila 1423,9 (0,14239) i da se generalno ta vrijednost kretala između 1250 i 1450 (odnosno 0,125 i 0,145). Pavković et al. (2012) objašnjavaju da se inače smatra da nekoncentrirane industrije imaju vrijednost HHI-a manju od 0,1 dok se za koncentrirane smatra da imaju vrijednost preko 0,18, pa se može zaključiti kako ovakva vrijednost HHI-a upućuje na umjerenu koncentriranost bankovnog sustava RH.



Graf 18: HHI koncentracije ukupne imovine banaka u RH (2005.-2014.)
Izvor: Izrada autorice na temelju podatak iz HNB (2015b).

Nakon snažnog smanjenja u 2013. godini, dobit banaka oporavila se u 2014. godini, ali je i dalje ostala niska u usporedbi s prethodnim godinama. Razlog za to se može pronaći u visokoj razini troškova rezerviranja za gubitke. Naime, iako su se u 2014. godini osjetno smanjili, te na taj način bili najvažniji činitelj povećanja dobiti, ti su troškovi i dalje znatno opterećivali poslovne rezultate banaka (HNB, 2015a). Daljni razlozi smanjenog prihoda u odnosu na ostale godinu mogu se pronaći u slaboj gospodarskoj aktivnosti, te sve nižim kamatnim stopama i smanjenim kreditiranjem koji nepovoljno utječu na kamatne prihode te ukupne poslovne rezultate banaka. Uz sve to, jaki utjecaj na zaradu banaka u 2014. godini imala su i nova pravila potrošačkoga kreditiranja, a posebice odredbe o ograničavanju visine kamatnih stopa na stambene kredite u švicarskim francima (HNB, 2015b).



Graf 19: Dobit banaka u RH, prije oporezivanja, na kraju razdoblja (2008.-2014.)
Izvor: Izrada autorice na temelju podataka iz HNB (2015b).

Prema podacima za 2014. godinu banke su ostvarile 2,1 milijarde kuna dobiti iz poslovanja (prije poreza), što je u usporedbi s 2013. godinom, kada su ostvarile 695,4 milijuna kuna dobiti, porast od oko 1,4 milijarde kuna ili 197,3 posto u relativnim terminima (Graf 19).

Poboljšanje poslovnih rezultata ostvareno je kod većine banaka (njih 16), no dominantnu je ulogu imala promjena u jednoj banci u kojoj je dobit porasla za 902,0 milijuna kuna odnosno čak za 156 posto (Zagrebačka banka). U 2014. gubitke je, u ukupnom iznosu od 1,2 milijarde kuna, iskazalo 12 banaka (od ukupno 28) s udjelom u ukupnoj imovini banaka od 15,5 posto što je u manje banaka u odnosu na 2013. godinu kada je čak polovina banaka (15 od njih 30), na koje se odnosilo 14 posto imovine svih banaka, poslovalo s gubicima (HNB, 2015b). Prikaz svih banaka koje posluju, te njihova dobit (gubitak) iz poslovanja koje će se nastaviti, prije poreza, na kraju razdoblja 2014. nalazi se u Tablici 2.

Tablica 2: Dobit (gubitak) iz poslovanja koje će se nastaviti, prije poreza, svih banaka RH u 2014. (na kraju razdoblja)

Banka	
Zagrebačka banka d.d.	1.477.807
Privredna banka Zagreb d.d.	821.273
Raiffeisenbank Austria d.d.	363.776
Erste & Steiermärkische Bank d.d.	266.108
Societe Generale-Splitska banka d.d.	249.208
Sberbank d.d.	42.365
Imex banka d.d.	20.084
Istarska kreditna banka Umag d.d.	14.657
OTP banka Hrvatska d.d.	12.700
Štedbanka d.d.	9.227
Croatia banka d.d.	5.136
Karlovačka banka d.d.	3.962
Partner banka d.d.	1.600
BKS Bank d.d.	1.009
Slatinska banka d.d.	944
Banka Splitsko-dalmatinska d.d.	863
Samoborska banka d.d.	–849
Primorska banka d.d.	–5.592
Tesla štedna banka d.d.	–6.287
Kentbank d.d.	–10.998
Vaba d.d. banka varaždin	–11.911
Podravska banka d.d.	–14.783
Banka Kovanica d.d.	–17.611
Veneto banka d.d.	–37.715
Kreditna banka Zagreb d.d.	–38.092
Hypo Alpe-Adria-Bank d.d.	–128.204
Jadranska banka d.d.	–314.261
Hrvatska poštanska banka d.d.	–637.053

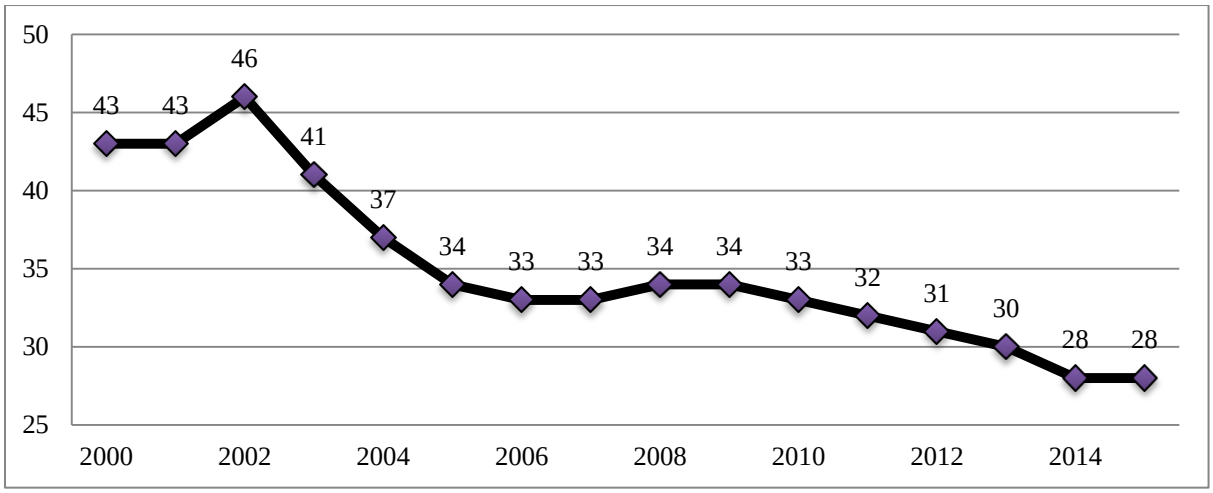
Izvor: HNB (2015b).

3.3. Utjecaj financijske krize na bankarski sektor RH

Republika Hrvatska mala je otvorena ekonomija koju, između ostalog, karakterizira visoka uvozna orijentiranost, jaka ovisnost o financiranju izvana, te visok stupanj korištenja strane valute u domaćim transakcijama, odnosno tzv. euroizacija gospodarstva. Kao takva, Hrvatska nema utjecaja na zbivanja na svjetskom tržištu već se jedino može pokušati nositi s onim što dolazi izvana.

Globalna financijska kriza postavila je izazov pred vlade i monetarne politike diljem svijeta. Uzimajući u obzir, gore navedene, karakteristike Hrvatske kao gospodarstva zanimljivo je istražiti kako i u kolikoj mjeri je financijska kriza utjecala na bankarski sektor Republike Hrvatske.

Za početak može se proučiti kretanje ukupnog broja banaka u Hrvatskoj kroz duži vremenski period što zorno prikazuje sljedeći graf. Iz grafa 20 može se uočiti da ukupan broj banaka u Hrvatskoj pada skoro od početka promatranog razdoblja. Tako su na početku promatranog razdoblja u Hrvatskoj poslovale čak 43 banke, da bih ih u 2015. godini bilo 28. Što se tiče utjecaja financijske krize na broj banaka, ne može se uočiti neko drastično smanjenje u broju banaka za vrijeme krize, u odnosu na periode prije i nakon financijske krize.

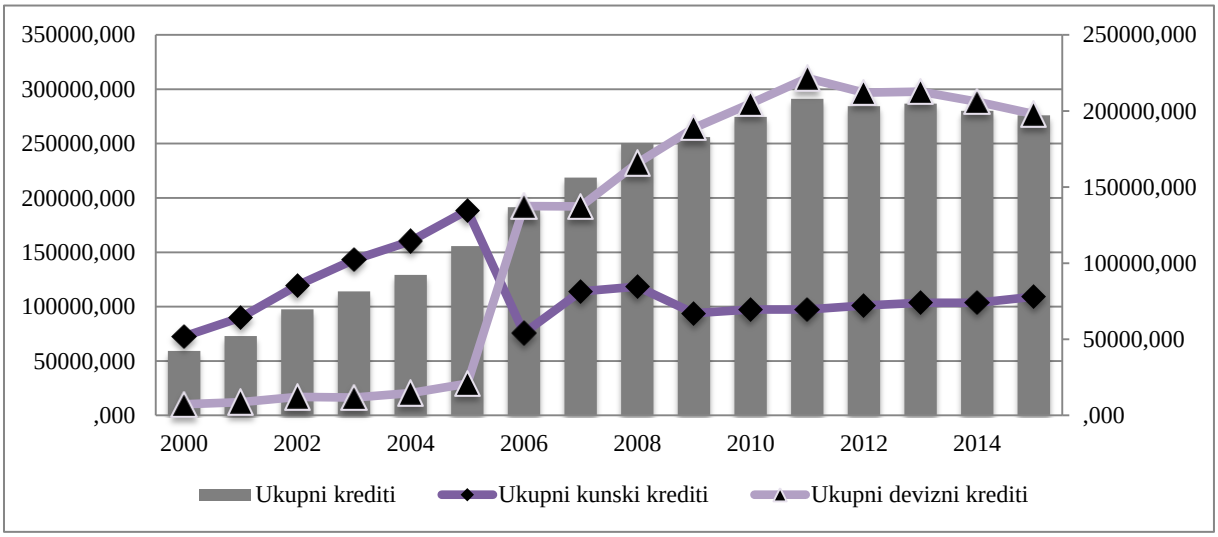


Graf 20: Trend kretanja ukupnog broja banaka u RH (2000.-2015.)
Izvor: Izrada autorice na temelju podataka iz HNB (2016).
Napomena: Podaci za 2015. godinu odnose se na treći mjesec 2015. godine.

3.3.1. Krediti i profitabilnost banaka u RH

U drugom dijelu ovog rada izložen je utjecaj financijske krize na bankarske sektore u svijetu. Tamo se moglo pročitati o ogromnim gubitcima koje su banke pretrpjele zbog brojnih kanala i

mehanizama kojima se kriza na iste prelijevala. Navedeno se najviše odrazilo na pad profitabilnosti banaka, te na pad ukupno odobrenih kredita. Konkretno, na grafu 9 u prethodnom poglavlju moglo se uočiti da je kod svih promatranih zemalja, odnosno njihovih banaka došlo do pada ukupno odobrenih kredita u 2007., odnosno 2008. godini. Međutim, kako se čini, ista situacija nije zabilježena u bankarskom sektoru Republike Hrvatske. Naime, kako se može uočiti iz sljedećeg grafa od početka promatranog razdoblja ukupno odobreni krediti od strane hrvatskih banaka konstantno rastu. Jedino što se dogodilo jest supstitucija kredita odobrenih u domaćoj valuti kreditima odobrenima u stranoj valuti, što je pak karakteristika Hrvatske spomenuta još na početku ovog potpoglavlja tzv. euroizacija gospodarstva.

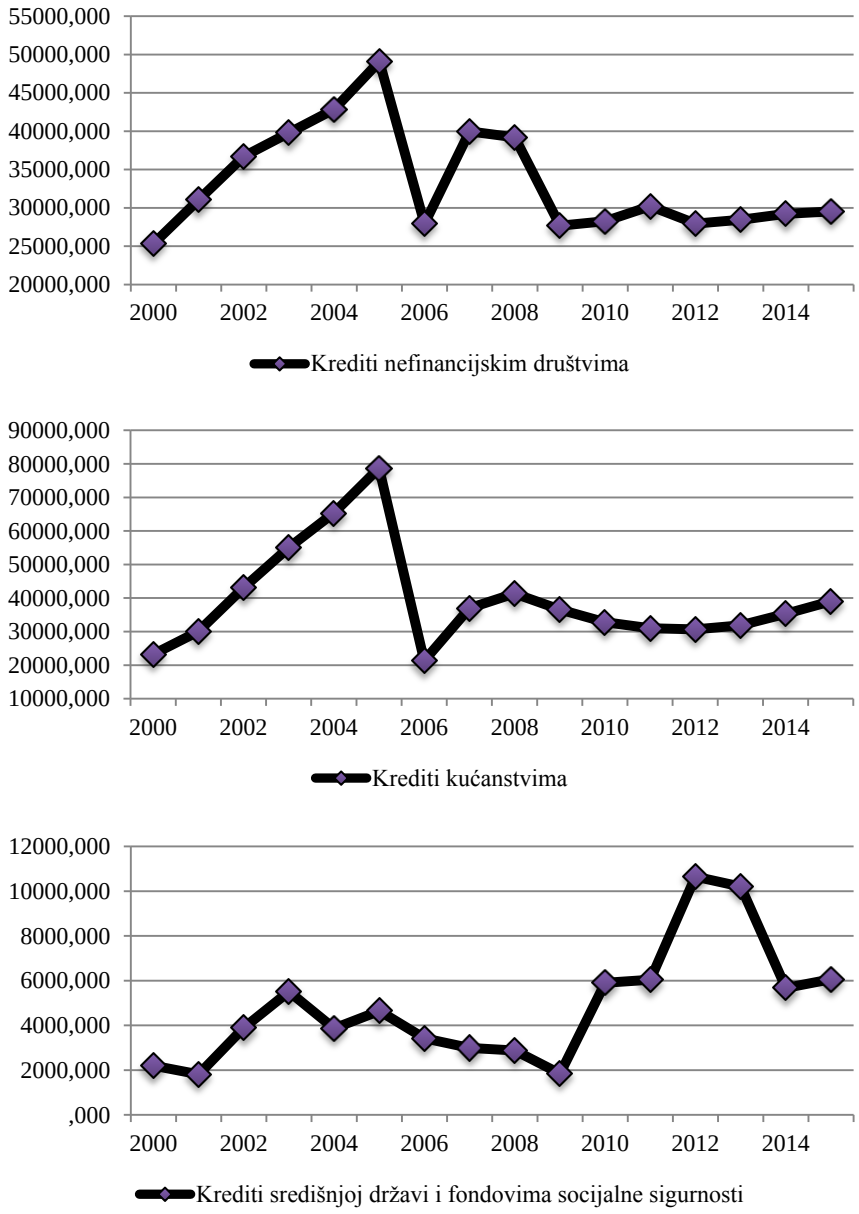


Graf 21: Trend kretanja ukupnih, ukupnih kunskih i deviznih kredita u RH u mil.kn (2000.-2015.)
Izvor: Izrada autorice na temelju podataka iz HNB (2016).
Napomena: Podaci za 2015. godinu odnose se na 11.mjesec 2015. godine.

Kao i u prethodnom poglavlju i ovdje će se ovaj graf uzeti s rezervom zbog zabilježene činjenice da se u vrijeme krize značajno zaduživala država, pa onda ovaj agregat može na određeni način zamaskirati stvarni efekt utjecaja krize na ukupno odobrene kredite banaka. Naime, izniman rast u kreditiranju države može zamaskirati oštar pad u kreditiranju privatnog sektora čije investicije ipak čine temelj razvoja svakog gospodarstva. Iz tog razloga, na sljedeća dva grafa prikazani su ukupno odobreni kunski i devizni krediti po glavnim institucionalnim sektorima.

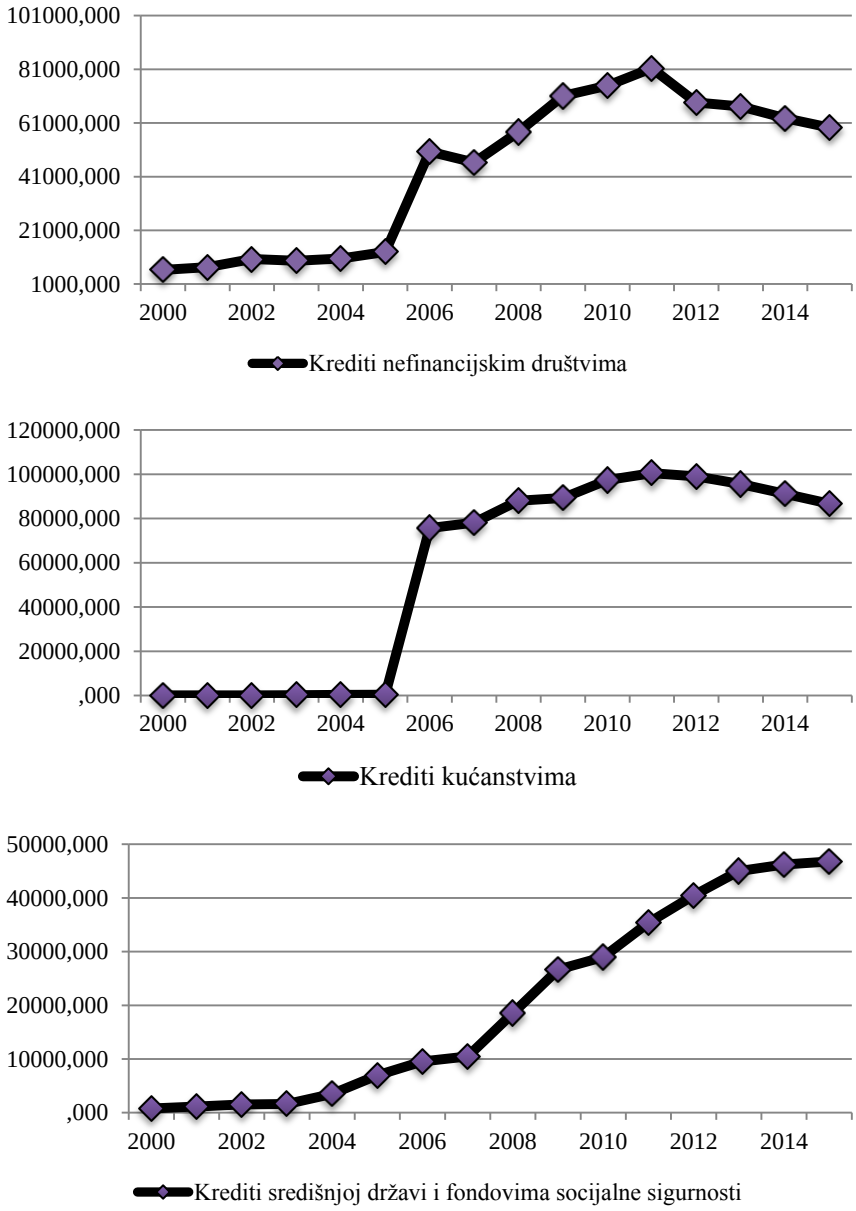
Graf 22 prikazuje trend kretanja ukupno odobrenih kunskih kredita u RH u trima glavnima institucionalnim sektorima: nefinancijskim društvima, stanovništvu, te središnjoj državi i

fondovima socijalne sigurnosti. Može se uočiti da se bojaznost da promatranje ukupno odobrenih kredita može zamaskirati stvarni utjecaj krize pokazala točnom. Naime, može se uočiti da je upravo u 2009. godini, kada je kriza došla u Hrvatsku, došlo do pada ukupno odobrenih kredita sektoru nefinancijskih društava i sektoru stanovništva, koji se nastavio i u narednim godinama. S druge strane, u isto vrijeme zabilježen je oštar rast u kreditiranju središnje države u 2010. godini kada je globalna financijska kriza u Hrvatskoj prerasla u gospodarsku krizu.



Graf 22: Trend kretanja odobrenih kunskih kredita po glavnim institucionalnim sektorima RH u mil.kn. (2000.-2015.)
Izvor: Izrada autorice na temelju podataka iz HNB (2016).

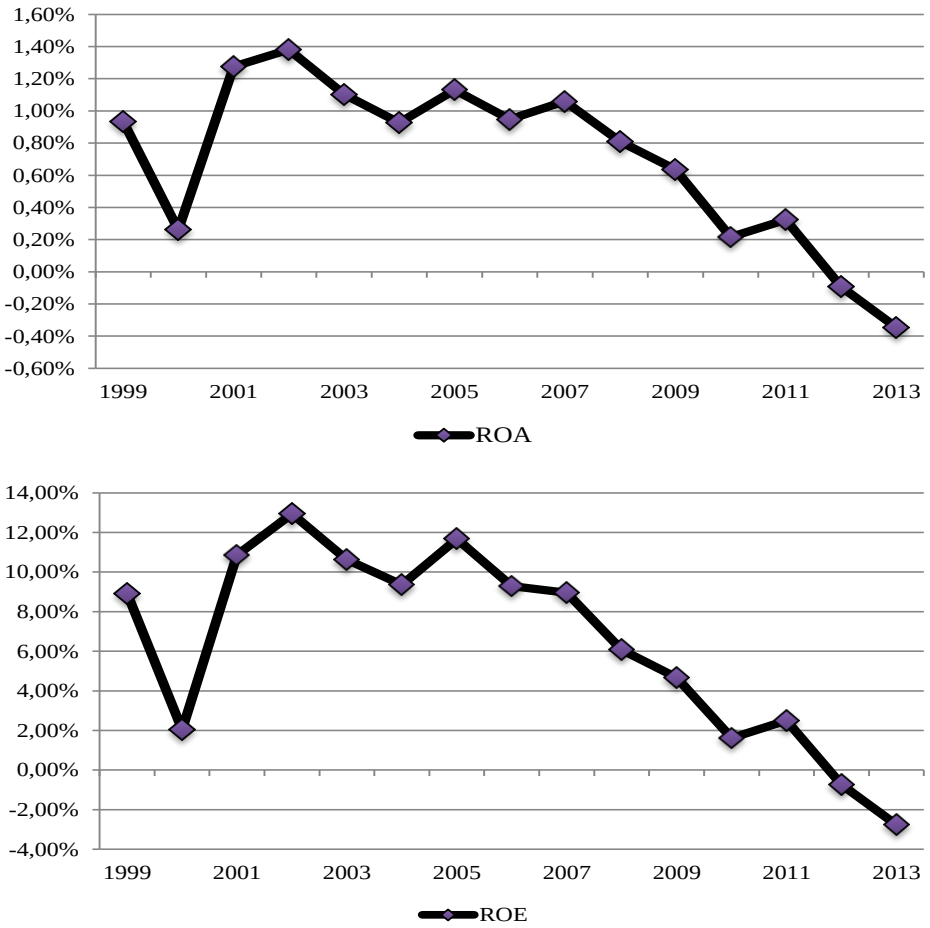
Graf 23 prikazuje isto što i prethodni graf, s tom razlikom da se sada promatraju ukupno odobreni devizni krediti po institucionalnim sektorima. Ovdje se može uočiti da je u sva tri sektora zabilježen rast odobrenih kredita u kriznim godinama.



Graf 23: Trend kretanja odobrenih deviznih kredita po glavnim institucionalnim sektorima u mil.kn. (2000.-2015.)
Izvor: Izrada autorice na temelju podataka iz HNB (2016).

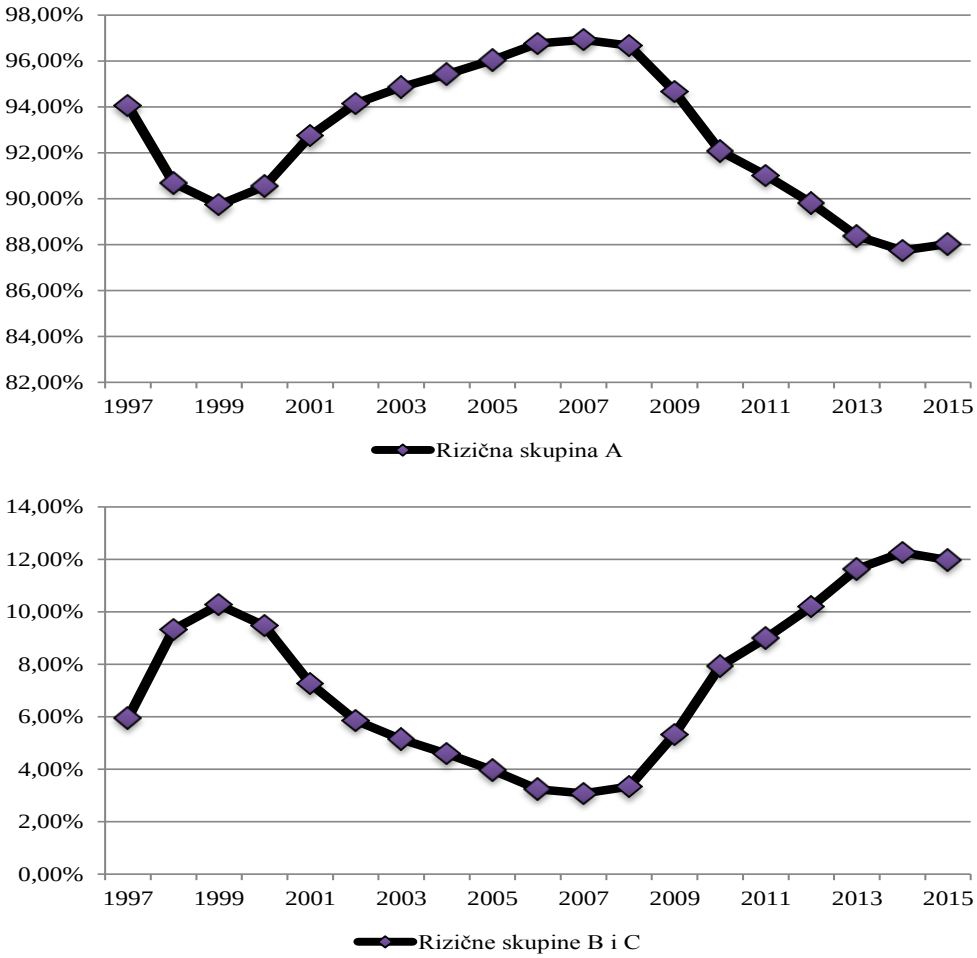
Kao i u drugom poglavlju gdje se proučavao utjecaj financijske krize na bankarske sektore u svijetu, i ovdje će se poučiti kretanje dvaju najvažnijih pokazatelja profitabilnosti banaka, ROA i ROE. Na grafu 24 može se uočiti kontinuirani pad u profitabilnosti hrvatskih banaka,

što je zanimljivo kada se usporedi s rastom ukupno odobrenih kredita. Očigledno, ovaj pad profitabilnosti nije bio toliki da bi demotivirao banke u daljnjem odobravanju kredita.



Graf 24: ROA i ROE banaka u RH, u %, nakon poreza (1999.-2013.)
Izvor: Izrada autorice na temelju podataka sa Svjetske banke (2016).

Pad profitabilnosti zabilježen na prethodnom grafu, direktna je posljedica pada rizičnih plasmana koji donose prihode (rizična skupina A), te rasta rizičnih plasmana koji ne donose prihode (rizična skupina C), što je i evidentno iz sljedećeg grafa.



Graf 25: Rizični plasmani banaka u RH u % (1997.-2015)
Izvor: Izrada autorice na temelju podataka iz HNB (2016).
Napomena: Podaci za 2015. odnose se na treći mjesec 2015. godine.

3.3.2. Mehanizmi širenja krize na bankarski sektor RH

U drugom dijelu ovog rada identificirano je i objašnjeno pet glavnih mehanizama kojima se financijska kriza širila po svijetu. Navedeni mehanizmi mogu djelovati i na ponudu i na potražnju za kreditima. Također je naglašeno kako se kriza nije istom brzinom ni jačinom prelijevala na druge zemlje. Jedan razlog tome, također već spomenut, odnosi se na makroekonomske uvjete koji od razlikuju od zemlje do zemlje. Drugi razlog, povezan s prvim, odnosi se na činjenicu da svi mehanizmi nisu djelovali kod svih zemalja. Iz Hrvatske udruge banaka (HUB, 2010) navode kako su u Republici Hrvatskoj snažno djelovali realni kanal i fiskalni kanal, te kanal kompleksnosti kao kombinacija ta dva mehanizma (Tablica 1). Kad su u pitanju banke, ni bilančni ni kamatni kanal nisu snažno djelovali u RH, što je u skladu sa zabilježenim rastom odobrenih kredita čak i u kriznim godinama.

Tablica 3: Sistematski prikaz mehanizama širenja krize

KANAL KOMPLEKSNOSTI	GLAVNI KANALI	KRATAK OPIS	UČINAK NA TRŽIŠTE KREDITA	
			Na strani ponude	Na strani potražnje
Spirala pada vrijednosti kolaterala **(HRVATSKA)**	Izravni realni kanal (financijski akcelerator)	Zbog pada neto bogatstva (vrijednosti kolaterala) smanjuju se i ponuda i potražnja na tržištu kredita.	DA	DA **(HRVATSKA)**
Recesijski impulsi koji nastaju u izravnom, kamatnom i fiskalnom kanalu dodatno kvare kvalitetu aktive	Bilančni kanal	Banka opterećena gubicima i manjkom kapitala ne može odobravati nove zajmove	DA	
Rast premija rizika u fiskalnom kanalu pojačava negativne učinke koji se javljaju u kamatnom kanalu	Kamatni kanal	Banka čiji izvori pretjerano zavise o financiranju putem tržišta novca natprosječno je izložena kamatnim rizicima, pa u razdoblju visokih premija rizika bilježi gubitke	DA	
Recesijski impulsi nastali u svim ostalim kanalima stvaraju spregu koja kroz sve tri veze pojačava djelovanje kroz fiskalni kanal	Fiskalni kanal	Padaju fiskalni prihodi, rastu ukupni izdaci i izdaci za spašavanje banaka, raste javni dug i nepovjerenje u javne financije – raste cijena zaduženja i premije rizika	DA	DA **(HRVATSKA)**

Izvor: HUB (2010).

4. EMPIRIJSKO ISTRAŽIVANJE O UTJECAJU FINANCIJSKE KRIZE NA BANKARSKI SEKTOR REPUBLIKE HRVATSKE

U ovom dijelu rada, s ciljem testiranja hipoteza postavljenih u početnoj fazi istraživanja, kvantificirat će se utjecaj koji je globalna financijska kriza imala na bankarski sektor Republike Hrvatske. Metodološki aspekt istraživanja prezentiran je u prvom potpoglavlju ovog dijela. Drugo potpoglavlje sadrži opis modela te svih korištenih varijabli u istima. U trećem potpoglavlju prezentirani su rezultati analize, dok zadnje potpoglavlje ovog dijela sadrži usporedbu dobivenih rezultata s prvotno postavljenim istraživačkim hipotezama.

4.1. Metodološki aspekt istraživanja

Za obradu prikupljenih podataka koristit će se višestruka regresijska analiza, i programska potpora, SPSS. Kako ističe Pivac (2010) zadaća regresijske analize je da pronađe analitičko-matematički oblik veze između jedne ovisne varijable i jedne ili više neovisnih varijabli. Model kod kojeg jedna zavisna varijabla ovisi o više nezavisnih varijabli naziva se modelom višestruke regresije. Model višestruke regresije koristit će se i u ovom radu. Naime, pored nezavisne varijable od primarnog interesa, financijske krize, dodat će se još nekoliko nezavisnih varijabli za koje se na temelju ekonomske teorije smatra da također mogu imati značajan utjecaj na poslovanje banaka. Dodatno, budući da će se koristiti kraći niz podataka, formirat će se linearni model višestruke regresije.

Regresijska analiza u ovom radu započet će specifikacijom modela višestruke regresije. Opći oblik linearnog modela višestruke regresije glasi:

$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \ldots\ldots + \beta_k \cdot X_k + e$, gdje je: (1)

Y − ovisna varijabla,

$X_1, X_2, \ldots, X_k$ – neovisne varijable,

$\beta_0, \beta_1, \beta_2, \ldots, \beta_k$ – parametri koje je potrebno ocijeniti, te

e – slučajna varijabla za koju se pretpostavlja da ima normalnu distribuciju s konstantnom varijancom i očekivanjem jednakim nuli.

Nakon specifikacije regresijskog modela, speficiciran model će se ocjeniti, te će se provjerili narušava li koja od uzetih varijabli pretpostavke klasičnog regresijskog modela. U tom smislu provjerit će se postoji li u modelu:

1) problem multikolinearnosti između nezavisnih varijabli,

2) problem autokorelacije reziduala,

3) problem heteroskedastičnosti varijance reziduala, te će se provjeriti

4) jesu li reziduali normalno distribuirani.

Sljedeća tablica prikazuje pretpostavke koje svaki regresijski model treba zadovoljiti, kratak opis tih prepostavki, kao i pokazatelje koji će se u ovom radu koristiti za donošenje odluke o ispunjenju odnosno neispunjenju istih.

PRETPOSTAVKA	OPIS	POKAZATELJ
Multikolnearnost	Problem multikolinearnosti posljedica je visoke zavisnosti regresorskih varijabli. U slučaju prisutnosti ovog problema empirijski t-omjeri biti će nerealno mali ($t_j = \beta_j \ \ Se \ \ \beta_j$), pa se može pogrešno zaključiti da su regresorske varijable nesignifikantne. Također ocijenjeni regresijski koeficijenti mogu imati netočan predznak.	VIF i TOL
Autokorelacija reziduala	Problem autokorelacije reziduala sa sobom nosi sljedeće posljedice: procjenitelji parametara u regresijskom modelu dobiveni metodom najmanjih kvadrata su nepristrani i konzistentni, ali nemaju druga poželjna svojstva, te su procjene standardnih devijacija procjenitelja parametara pristrane, a intervali pouzdanosti i testovi značajnosti nisu pouzdani.	Durbin-Watson i dijagram rasipanja reziduala
Heteroskedastičnost varijance reziduala	Problem heteroskedastičnosti varijance reziduala odnosi se na situaciju u kojoj varijanca reziduala nije konstantna, te korelira s regresorskom varijablom. Posljedice heteroskedastičnosti varijance reziduala su neefikasne ocjene parametara metodom najmanjih kvadrata, te pogrešne tj. potcijenjene procjene standardnih grešaka, pa je t-test precijenjen što pogrešno dovodi do zaključka o značajnosti parametara.	Spearmanov koeficijent korelacije ranga
Normalna distribucija reziduala	Ispunjenje pretpostavke o normalnoj distribuciji reziduala je bitno jer ukoliko je slučajna varijabla normalno distribuirana, onda će i regresijski parametri biti normalno distribuirani, što je naročito bitno kod testiranja značajnosti regresijskih parametara.	Histogram standardiziranih reziduala

Kada su pretpostavke modela višestruke regresije zadovoljene mogu se vrednovati ocjene parametara. U ovom smislu testirat će se hipoteze o značajnosti modela, proučit će se veličine i predznaci parametara, te će se statističkim kriterijima vrednovat statistička značajnost ocjene parametara modela. Također će se provjeriti još neki pokazatelji reprezentativnosti poput koeficijenta determinacije i korigiranog koeficijenta determinacije. U konačnici prezentirat će se analitički izrazi modela, interpetirat dobiveni parametri te testirati njihova statistička značajnost.

4.2. Opis korištenih podataka i varijabli

Podatci korišteni u ovom dijelu rada su po prirodi sekundarni. Odabrana zavisna varijabla jest povrat na kapital (ROE) koji se izračunava kao omjer neto dobiti i prosječnog dioničarskog kapitala (knjigovodstvene, a ne tržišne vrijednosti) te vlasnicima govori koliku je dobit menadžment banke ostvario po kuni njihova udjela u kapitalu. Ovaj pokazatelj je u literaturi općeprihvaćeni pokazatelj profitabilnosti banaka (Pejić Bach et al., 2009) pa se stoga koristi i u ovom radu. Za nezavisne varijable koristit će se standardne determinante bankarskog poslovanja: stopa rasta kredita, HHI, omjer kapitala i ukupne imovine, omjer ukupnih kredita i depozita, omjer ukupnih kredita i imovine, stopa inflacije i stopa rasta BDP-a te kao najvažniji pokazatelj za ovaj rad, dummy varijabla za financijsku krizu. Sve varijable izražene su u relativnom obliku (kao stope raste: ΔZ, ΔCPI, ΔBDP; kao postotni udio: Ka/I, Kr/D, Kr/I; te HHI i kriza su zadani). U Tablici 4 prikazane su sve varijable, njihove oznake u modelu, izvor literature (svi podatci su prikupljeni u bazama HNB-a i Svjetske banke) i očekivani teorijski predznak. Vremenski period testiranja modela obuhvaća razdoblje od 2000. do 2013. godine (posljednje dostupni podatci za određene varijable).

Tablica 4: Prikaz varijabli modela, pripadajućih oznaka i izvora te očekivanog utjecaja

VARIJABLA	OPIS	IZVOR	
Zavisne varijable			
ROE	Povrat na kapital	WB	
Nezavisne varijable			**Očekivani utjecaj**
Kriza	Dummy varijabla za krizu	Autorica[24]	-
ΔZ	Stopa rasta kredita	HNB	+
HHI	Herfindahlov – Hirscmanov indeks	HNB	-
Ka/I	Kapital / imovina	WB	-
Kr/D	Krediti / depoziti	WB	+
Kr/I	Krediti / imovina	HNB	-
ΔCPI	Stopa inflacije	HNB	-
ΔBDP	Stopa rasta BDP-a	HNB	+

Izvor: izrada autorice

4.3. Regresijska analiza

U nastavku će se ,na temelju 14 opažanja (razdoblje od 2000. do 2013. godine) i uz upotrebu metode višestruke regresijske analize, ispitati ovisnost profitabilnosti banaka o različitim

[24] Na temelju dosadašnjih spoznaja o financijskoj krizi, autorica je sama formirala dummy varijablu s vrijednostima 1 u 2008. i 2009. budući da su ovo godine kada su se najviše osjetili efekti globalne financijske krize. U slučaju RH, globalna financijska kriza se „prelila“ u gospodarsku i propadanje gospodarstva je nastavljeno godinama nakon financijske krize.

pokazateljima bankarskog poslovanja (sve nezavisne varijable iz Tablice 4) i financijske krize, a sve u svrhu pronalaska odgovarajućeg modela i što reprezentativnijih rezultata. Također, bit će testirana još dva modela. Jedan koji obuhvaća razdoblje od 2000. do 2013., ali bez uvrštavanja dummy varijable kriza kako bi se uspoređujući dva modela „izlučio" efekt utjecaja krize. Uz navedena dva modela, još će se testirati jedan model koji obuhvaća razdoblje prije krize od 2000. do 2007., kako bi se uočilo jesu li postojali različiti obrasci djelovanja determinanti bankarskog poslovanja u godinama koje nisu prethodile krizi.

1. Model

U jednadžbi (2) prikazan je prvi model koji je testiran višestrukom regresijom:

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \beta_3 \cdot X_3 + \beta_4 \cdot X_4 + \beta_3 \cdot X_5 + \beta_6 \cdot X_6 + \beta_7 \cdot X_7 + \beta_8 \cdot X_8 + e \quad (2)$$

Gdje je:

Y – Povrat na kapital,
X_1 – **kriza (dummy varijabla),**
X_2 – stopa rasta kredita,
X_3 – Herfindahlov – Hirscmanov indeks,
X_4 – kapital / imovina,
X_5 – krediti / depoziti,
X_6 – krediti / imovina,
X_7 – stopa inflacije,
X_8 – stopa rasta BDP-a,

$\beta_0, \beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6, \beta_7, \beta_8$ – parametri koje je potrebno procijeniti, te
e – slučajna varijabla.

Dakle, u nastavku će biti provedeno testiranje prvog, najsveobuhvatnijeg modela (sa svim nezavisnim varijablama). Kao početni korak analize bilo je nužno odabrati odabir metode izbora optimalnog skupa regresorskih varijabli u modelu višestruke regresije i za tu svrhu odabrana je backward metoda[25] izbora regresorskih varijabli.

U Tablici 5 prikazan je proces backward metode.

[25] Kod ove metode na početku selektiranja u model se uključuju sve regresorske varijable, te se postavljaju kriteriji za izlazak varijabli iz modela. Prvi kriterij je minimalna vrijednost F-omjera koji neka varijabla mora zadovoljiti da bi ostala u modelu. Varijable s F-omjerima manjim od kritičnoga mogu biti isključene ako je zadovoljen i drugi kriterij za isključenje. Drugi kriterij za isključenje je maksimalna signifikantnost za isključenje koja iznosi 0,10. U daljnjem postupku isključuje se varijabla koja ima najmanji koeficijent parcijalne korelacije s regresand varijablom. Ako ta varijabla pri tome udovoljava i kriterijima za isključenje tada se i ona isključuje iz modela. Postupak se dalje nastavlja sve dotle dok ima varijabli koje udovoljavaju svim navedenim kriterijima za isključenje.

Tablica 5: Postupak Backward metode

Model	Variables Entered	Variables Removed	Method
1	Stopa rasta BDP-a, Inflacija, Krediti/Depoziti, HHI, Kapital/Imovina, Stopa rasta kredita, Krediti/Imovina, Kriza[b]	.	Enter
2	.	Krediti/Depoziti	Backward (criterion: Probability of F-to-remove >= ,100).
3	.	Inflacija	Backward (criterion: Probability of F-to-remove >= ,100).
4	.	Krediti/Imovina	Backward (criterion: Probability of F-to-remove >= ,100).
5	.	Stopa rasta BDP-a	Backward (criterion: Probability of F-to-remove >= ,100).
6	.	HHI	Backward (criterion: Probability of F-to-remove >= ,100).
7	.	Kriza	Backward (criterion: Probability of F-to-remove >= ,100).

a. Dependent Variable: ROE
b. All requested variables entered.
Izvor: izrada autorice

Tablica 6 prikazuje izračunate vrijednosti koeficijenta multiple korelacije (*R*), koeficijenta determinacije (*R Square*), korigiranog koeficijenta determinacije (*Adjusted R Square*) te procijenjene standardne devijacije regresije (*Standard Error of the Estimate*).

Tablica 6: Osnovni podatci o ocijenjenom modelu s ROE kao zavisnom varijablom

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
7	,922[g]	,851	,821	1,89165	1,521

g. Predictors: (Constant), Kapital/Imovina, Stopa rasta kredita
h. Dependent Variable: ROE
Izvor: izrada autorice

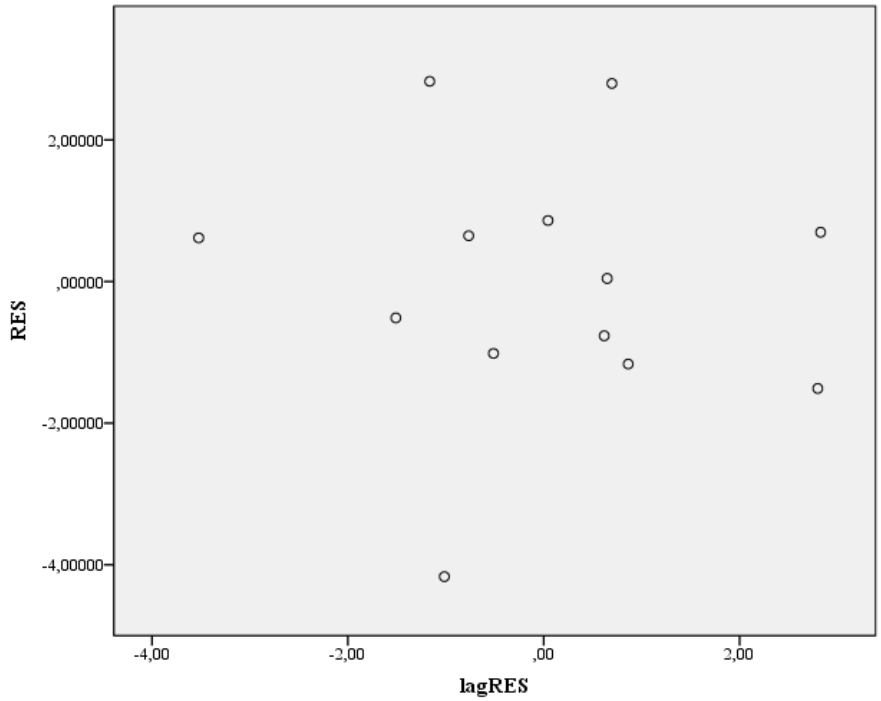
Vrijednost koeficijenta multiple korelacije (*R*) iznosi 0,922 što govori o jakoj i pozitivnoj linearnoj vezi između varijabli modela. Koeficijent multiple determinacije (R^2) ima vrijednost od 0,851 te ukazuje na to je ocijenjenim regresijskim modelom protumačeno 85,1% sume kvadrata ukupnih odstupanja zavisne varijable od njene aritmetičke sredine. Ovako visoka vrijednost koeficijenta multiple determinacije sugerira da ima model ima dobru reprezentativnost. Korigirani koeficijent determinacije (R^2) iznosi 0,821.

U Tablici 4 nalazi se i rezultat vrijednosti Durbin-Watsonovog testa ($DW = 1{,}521$). Ta empirijska test veličina uspoređuje se s kritičnim vrijednostima d_L i d_U koje se za zadanu razinu signifikantnosti (α), veličinu uzorka (n), i broj regresorskih varijabli (k) očitavaju iz tablica za Durbin-Watsonov test. U ovom slučaju može se utvrditi da je:

$\alpha = 5\%, \quad n = 14, \quad i \quad k = 2,$ iz čega proizlazi da je:

$d_L = 0{,}905, \;\; d_U = 1{,}551.$

Prema tome: $d_L = 0{,}905 < DW = 1{,}521 < d_U = 1{,}551$, te se vidi da se vrijednost DW nalazi u području između d_L i d_U koje predstavlja područje inkonkluzivnosti, tj. područje gdje nije moguće donijeti zaključak o postojanju autokorelacije rezidualnih odstupanja na temelju Durbin-Watson testa. Stoga će se zaključak donijeti prema grafičkom prikazu dijagrama rasipanja (Slika 7). Na temelju dijagrama rasipanja može se zaključiti da ne postoji autokorelacija grešaka.



Slika 7: Dijagram rasipanja reziduala
Izvor: izrada autorice

U tablici 7 nalaze se podatci o protumačenim, neprotumačenim i ukupnim odstupanjima ocijenjenog modela, kao i vrijednost F-testa s empirijskom signifikantnosti.

Tablica 7: Tablica ANOVA ocijenjenog regresijskog modela

Model		Sum of Squares	df	Mean Square	F	Sig.
7	Regression	203,801	2	101,901	28,477	,000[h]
	Residual	35,783	10	3,578		
	Total	239,585	12			

h. Predictors: (Constant), Kapital/Imovina, Stopa rasta kredita
Izvor: izrada autorice

Na temelju empirijske vrijednosti F-testa koja iznosi koja iznosi $\alpha^* \approx 0$, ukazuje na te da je ovaj regresijski model statistički značajan kao cjelina i to pri signifikantnosti manjoj od 1%. Tablica 8 u konačnici prikazuje ocijenjeni regresijski model s pripadajućim vrijednostima ocijenjenih parametara, njihovih standardne greške i t-omjera.

Tablica 8: Ocijenjeni linearni regresijski model s povratom na kapital (ROE) kao zavisnom varijablom

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
		B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
7	(Constant)	13,695	5,420		2,527	,030	1,619	25,771		
	Stopa rasta kredita	,254	,085	,554	2,997	,013	,065	,443	,437	2,287
	Kapital/Imovina	-,901	,386	-,431	-2,331	,042	-1,762	-,040	,437	2,287

a. Dependent Variable: ROE
Izvor: izrada autorice

Sukladno rezultatima u Tablici 8 moguće je napisati analički oblik regresijskog modela:

$$y_i = 13{,}695 + 0{,}254 \cdot X_2 - 0{,}901 \cdot X_4 \quad (3)$$

Parametar β_2, koji se nalazi uz regresorsku varijablu stopa rasta kredita jest pozitivan i statistički značajan na razini signifikantnosti od 5% ($\alpha^* = 1{,}3\% < 5\%$). Njegova vrijednost iznosi 0,254 te govori da će se povrat na kapital povećati za 0,254 postotna poena ukoliko se stopa rasta kredita poveća za 1 postotni poen. U modelu još je značajan parametar koji se nalazi u regresorsku varijablu koja predstavlja omjer kapitala i imovine. I ovaj parametar je statistički značajan na razini signifikantnosti od 5% ($\alpha^* = 4{,}2\% < 5\%$). Suprotno od stope rasta kredita, parametar β_4 ukazuje na negativan utjecaj omjera kapitala i imovine na povrat na kapital. Naime, govori da ako se udio kapitala u ukupnoj imovini banke poveća za 1 postotni poen, povrat na kapital će se smanjiti za 0,904 postotnih poena.

Prema podatcima iz Tablice 8, model je moguće zapisati i u standardiziranom obliku koji ukazuje na to koja varijabla u modelu ima najveći relativan utjecaj na zavisnu varijablu.

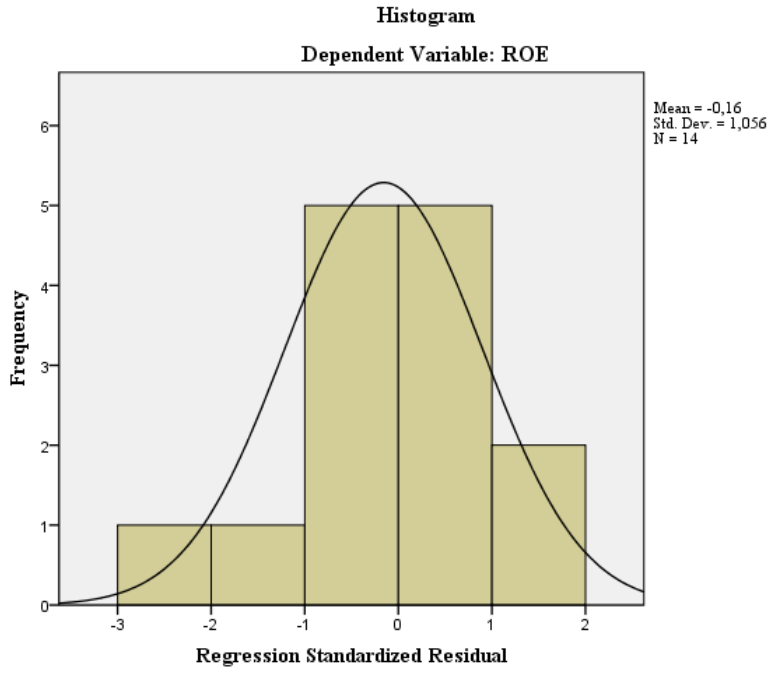
Standardizirane vrijednosti parametara pokazuju za koliko će se standardnih devijacija promijeniti zavisna varijabla (y_i) ako se pojedina nezavisna varijabla promijeni za jednu standardnu devijaciju. Model u standardiziranom obliku se može zapisati na sljedeći način:

$$y_i = 0{,}554 \cdot X_2 - 0{,}431 \cdot X_4 \qquad (4)$$

Na temelju jednadžbe (4) može se zaključiti kako najveći utjecaj na povrat na kapital ima stopa rasta kredita.

Nadalje, sukladno podatcima u Tablici 8 dolazi se do zaključka kako ne postoji problem multikolinearnosti budući da su faktori inflacije varijance *(VIF)* manji su od 5, a postotak tolerancije *(TOL)* veći je od 20%.

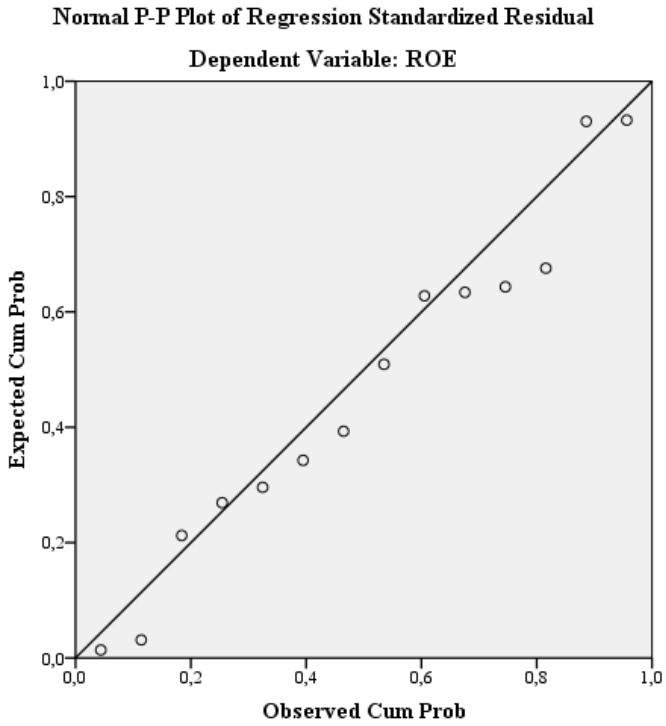
Da bi se utvrdilo jesu li reziduali normalno distribuirani potrebno je prikazati histogram standardiziranih reziduala (Slika 8).



Slika 8: Histogram standardiziranih reziduala
Izvor: izrada autorice

Na temelju Slike 8 može se uočiti da su reziduali e_i normalno distribuirani s očekivanjem jednakim nuli i standardnom devijacijom približno jednakom jedinici. Isti zaključak se može donijeti sukladno Slici 9 na kojoj su ucrtane vrijednosti opaženih i očekivanih vjerojatnosti, kada bi reziduali bili normalno distribuiran (*Normal P-P Plot of Regression Standardized*

Residual). Pretpostavku o normalnosti reziduala potvrđuje i funkcija distribucije opaženih vjerojatnosti, koja gotovo ne odstupa od očekivane funkcije vjerojatnosti kada bi rezidualna odstupanja bila normalno distribuirana (dijagonalna linija na Slici 9).



Slika 9: P-P grafikon normalno distribuiranih reziduala
Izvor: izrada autorice

Još je preostalo provjeriti heteroskedastičnost varijance reziduala. Postojanje tog problema testira se neparametrijskim testom i to pomoću Spearmanovog koeficijenta korelacije ranga koji se temelji na korelaciji ranga između apsolutnih vrijednosti reziduala i izabranih regresorskih varijabli. Postavljaju se sljedeće hipoteze:

$$H_0 \dots \dots r_s = 0$$
$$H_1 \dots \dots r_s \neq 0 \qquad (5)$$

Ukoliko je vrijednost Spearmanovog koeficijenta korelacije ranga između regresorske varijable i apsolutnih reziduala jednaka 0, odnosno ne odbacuje se nulta hipoteza, onda ne postoji problem heteroskedastičnosti varijance reziduala u ocijenjenom modelu.

Tablica 9: Spearmanovi koeficijenti korelacije između apsolutnih reziduala i regresorskih varijabli

			Apsolutni reziduali	Stopa rasta kredita	Kapital/ Imovina
Spearman's rho	Apsolutni reziduali	Correlation Coefficient	1,000	-,380	,512
		Sig. (2-tailed)	.	,180	,061
		N	14	14	14
	Stopa rasta kredita	Correlation Coefficient	-,380	1,000	-,763
		Sig. (2-tailed)	,180	.	,002
		N	14	14	14
	Kapital/ Imovina	Correlation Coefficient	,512	-,763	1,000
		Sig. (2-tailed)	,061	,002	.
		N	14	14	14

Izvor: izrada autorice

Prema rezultatima iz Tablice 9 može se vidjeti da je empirijska signifikantnost koeficijenata korelacije $\alpha_1^* = 0{,}180$ i $\alpha_2^* = 0{,}061$, pa se za oba slučaja može zaključiti da je i $\alpha^* > 5\%$ što znači da se početna hipoteza ne odbacuje te da korelacija nije statistički značajna. U konačnici, zaključuje se da u ocijenjenom modelu ne postoji problem heteroskedastičnosti varijance reziduala.

U nastavku su testirana još dva modela: model (2) koji obuhvaća cijelo razdoblje, a u koji nije uvrštena kriza te model (3) koji obuhvaća samo vrijeme prije krize (od 2000. do 2008.) Zbirni rezultati sva 3 modela prikazani su u Tablici 10.

Tablica 10: Ocjene parametara i regresijska dijagnostika

	MODEL 1	**MODEL 2**	**MODEL 3**
Osnovni pokazatelji			
R	0,922	0,932	0,824
R^2	0,851	0,869	0,679
R^2	0,821	0,843	0,551
α^* F^*	0,000	0,000	0,058
Nestandardizirani regresijski koeficijenti i pripadajuće signifikantnosti			
β_0 α^*	**13,695 (5,420)**	**70,920 (13,109)**	**72,876 (23,311)**
β_2 α^*	**0,254 (0,085)**	-	-
β_3 α^*	-	**-0,037 (0,011)**	-0,037 (0,017)
β_4 α^*	**-0,901 (0,386)**	**-1,275 (0,280)**	-1,455 (0,592)
Standardizirani regresijski koeficijenti			
β_2	**0,554**	-	-
β_3	-	**-0,456**	-0,551
β_4	**-0,431**	**-0,610**	-0,623
Ostala regresijska dijagnostika			
PRM[a]	NE	NE	NE
HVR[b]	NE	NE	NE
NDR[c]	DA	DA	DA
AR[d]	NE	NE	NE

Napomene: a - problem multikolinearnosti, b - problem heteroskedastičnosti varijance reziduala, c - normalna distribucija reziduala, d - problem autokorelacije reziduala.

Model 2 obuhvaća razdoblje od 14 godina (2000.-2013.), zavisna varijabla je ROE i u modelu je testirano 7 regresorskih nezavisnih varijabli (sve varijable osim krize iz Tablice 4). Opet je korištena backward metoda. Model je zadovoljio sve dijagnostičke preduvjete (ne postoje problemi multikolinearnosti, heteroskedastičnosti varijance te autokorelacije reziduala, a distribucija ima normalni oblik). Nadalje, model ima zadovoljavajuću razinu pokazatelja reprezentativnosti te je kao cjelina statistički značajan. U modelu su na kraju ostale dvije varijable koje su se pokazale statistički značajnima (na razini signifikantnosti od 5%). To su: HHI i kapital/imovina. Omjer kapitala i imovine ovog puta ima još negativniji utjecaj na ROE nego u Modelu 1. Naime, vrijednost parametra uz ovu regresorsku varijablu iznosi -1,275 te ukazuje na to da ako se udio kapitala u imovini banke poveća za 1 postotni poen, povrat na kapital smanjit će se za 1,275 postotnih poena. Za razliku od Modela 1 u kojem je statistički značajna bila stopa rasta kredita, ovdje to nije slučaj, ali je statistički značajan (pri razini signifikantnosti od 5%) HHI koji, što je veći, tj. što je veća koncentracija banaka na tržištu, to je negativniji utjecaj na povrat na kapital. Koeficijent parametra uz regresorsku varijablu HHI u Modelu 2 iznosi -0,037 te ukazuje na to da ukoliko HHI poraste za jednu jedinicu da će se povrat na kapital smanjiti za 0,037 postotnih poena. Pogledom na standardizirane regresorske koeficijente stječe se uvid da omjer kapitala i imovine ima snažniji utjecaj na ROE nego što ga ima HHI. U konačnici, finalne oblike: analitički (6) i standardizirani (7) moguće je prikazati pomoću jednadžbi:

$$y_i = 70{,}920 - 0{,}037 \cdot X_3 - 1{,}275 \cdot X_4 \quad (6)$$

$$y_i = -0{,}456 \cdot X_2 - 0{,}610 \cdot X_4 \quad (7)$$

Modelom 3, koji obuhvaća samo pretkrizne godine (od 2000. do 2007.) htjelo se testirali i steći uvid u najvažnije determinante bankarskog poslovanja kada nije postojao utjecaj krize te usporedbom s prva dva modela vidjeti postoji li razlika među najvažnijim faktorima u bankarskom poslovanju. Pri njegovom testiranju također je korištena backward metoda. Iako model zadovoljava sve testove regresorske dijagnostike, njegovi pokazatelji reprezentativnosti nisu na visokoj razini kao prethodna dva modela, a empirijska vrijednost F-testa na razini signifikantnosti od 5% ukazuje na to da model nije statistički značajan kao cjelina, a budući da parametri uz regresorske varijable koje su ostale u modelu nisu statistički značajne, njihova interpretacija nema smisla te se ovaj model neće dalje elaborirati.

4.4. Osvrt na rezultate istraživanja i istraživačku hipotezu

S obzirom na rezultate istraživanja, može se zaključiti da je u bankarskom poslovanju RH u razdoblju od 2000. do 2013. iznimno bitna determinanta jest bila omjer kapitala i imovine. U Modelu 1, u kojem je bilo testirano ukupno 7 regresorskih varijabli bitnih za bankarsko poslovanje (plus financijska kriza) te u Modelu 2, u kojem je testirano 7 regresorskih varijabli, ova varijabla je bila statistički značajna te je imala negativan utjecaj na povrat na kapital. U Modelu 1 (no ne i u Modelu 2) statistički značajnom se pokazala i stopa rasta kredita (što je veća, veći je i ROE), dok je u Modelu 2 (ali ne i Modelu 1) značajan bio HHI (negativan – što je manja koncentracija banaka, veći je ROE).

U Modelu 1 testiran je utjecaj financijske krize na poslovanje banaka (kao pokazatelj se koristio povrat na kapital, tj. ROE). Pregledom literature utvrđeno je da su godine u kojima su se osjetili utjecaji financijske krize 2008. i 2009.,[26] pa je stoga formirana dummy varijabla s vrijednostima 1 u ovim, a 0 u preostalim godinama. Regresijskom analizom te pritom korištenom backward metodom, varijabla kriza se nije pokazala značajnom te je izbačena iz analize. Na temelju toga se zaključuje da financijska kriza nije imala utjecaj na poslovanje banaka u Hrvatskoj (a što je i potkrijepljeno analizom pokazatelja bankarskog sustava RH u poglavlju 3.3.) **te se na temelju toga odbacuje istraživačka hipoteza ovog rada o tome da je financijska kriza negativno je utjecala na poslovanje banaka u Hrvatskoj.**

[26] Uzete su samo ove dvije godine, a ne i kasnije, jer se kasnije godine odnose na gospodarsku krizu kao posljedicu financijske krize. U ovom radu od primarnog interesa samo je financijska kriza.

5. ZAKLJUČAK

Kada se u obzir uzme sve navedeno u prvom potpoglavlju ovog dijela, ukratko se da zaključiti da je globalna financijska kriza nastala simultanim djelovanjem: loših zajmova odobrenih od strane banaka, rejting agencija koje nisu dobro obavljale svoj posao, labave regulatorne politike, pogrešno usmjerenih državnih poticaja koji ohrabrili banke da budu neoprezne u posuđivanju sredstava, te monetarne politike koja je držala kamatne stope na niskoj razini predugo.

Pregledom statističkih pokazatelja moglo se uočiti da kriza nije djelovala u isto vrijeme i jednakim intenzitetom u svim zemljama. Jačina utjecaja ovisila je prvenstveno o makroekonomskim uvjetima koji su u datom momentu prevladavali u promatranoj zemlji. Isto tako, jačina utjecala ovisila je i o mehanizmu odnosno mehanizmima kojima se kriza širila u promatrane zemlje.

Kada je u pitanju Republika Hrvatska, globalna financijska kriza širila se izravnim kanalom potaknutim financijskim akceleratorom, te fiskalnim kanalom. Bilančni i kamatni kanal nisu snažno djelovali što je određeni način poštedjelo bankarski sektor RH. Rezultati empirijskog istraživanja potvrdili su navedenu tvrdnju. Naime, empirijskom analizom varijabla financijska kriza nije se pokazala statistički značajnom.

POPIS SLIKA, GRAFOVA I TABLICA

SLIKE

Slika 1: Proces prodaje subprime hipotekarnih kredita 14
Slika 2: Prikaz tijeka financijske krize 17
Slika 3: Mehanizmi širenja financijske krize 21
Slika 4: Efekt financijskog akceleratora 22
Slika 5: Kanal koji povezuje bankovnu i fiskalnu krizu 24
Slika 6: Aktivnosti top 20 europskih banaka prije i nakon financijske krize 31
Slika 7: Dijagram rasipanja reziduala 53
Slika 8: Histogram standardiziranih reziduala 55
Slika 9: P-P grafikon normalno distribuiranih reziduala 56

GRAFOVI

Graf 1: Utjecaj krize na svjetski BDP i svjetsku trgovinu (u trilijunima dolara u tekućim cijenama), te na svjetsku nezaposlenost (u milijunima nezaposlenih) 7
Graf 2: Kretanje kamatne stope FED-a 10
Graf 3: Kretanje *subprime mortgage* kredita (u milijardama dolara) 11
Graf 4: Prikaz kretanja realnih i nominalnih cijena nekretnina u SAD-u u razdoblju 1970.-2014. 14
Graf 5: Prikaz ukupnih isplata bonusa na Wall Streetu u razdoblju od 2001.-2015. 18
Graf 6: MMF-ove procjene gubitaka banaka (2007.-2010.) 25
Graf 7: Ukupan broj banaka po regijama (2007. i 2013.) 26
Graf 8: Ukupan broj banaka po dohodovnim razredima (2007. i 2013.) 26
Graf 9: Ukupni krediti banaka odabranih zemalja u nacionalnoj valuti u mil. (1999.-2009.) 28
Graf 10: ROA banaka odabranih zemalja u % nakon poreza, (2006.-2013.) 29
Graf 11: ROE banaka odabranih zemalja u %, nakon poreza (2006.-2013.) 30
Graf 12: Broj banaka prema sjedištu vlasnika i vrsti vlasništva, na kraju razdoblja (2014.) 34
Graf 13: Koncentracija poslovnih jedinica i bankomata po županijama RH, na kraju razdoblja (2014) 35
Graf 14: Ukupna imovina banaka u RH, na kraju razdoblja (2014.) 36
Graf 15: Struktura imovine banaka u RH, na kraju razdoblja (2014.) 36
Graf 16: Imovina banaka prema domicilu dionicara u RH, na kraju razdoblja (2014.) 37
Graf 17: Top 10 banaka u RH po veličini imovine, na kraju radoblja (2014.) 38
Graf 18: Herfindahl-Hirschmanov koncentracije ukupne imovine banaka u RH (2005.-2014.)
Graf 19: Dobit banaka u RH, prije oporezivanja, na kraju razdoblja (2008.-2014.) 39
Graf 20: Trend kretanja ukupnog broja banaka u RH (2000.-2015.) 41
Graf 21: Trend kretanja ukupnih, ukupnih kunskih i deviznih kredita u RH u mil.kn (2000.-2015.) 42
Graf 22: Trend kretanja odobrenih kunskih kredita po glavnim institucionalnim sektorima RH u mil.kn. (2000.-2015.) 43

Graf 23: Trend kretanja odobrenih deviznih kredita po glavnim institucionalnim sektorima u mil.kn. (2000.-2015.) 44
Graf 24: ROA i ROE banaka u RH, u %, nakon poreza (1999.-2013.) 45
Graf 25: Rizični plasmani banaka u RH u % (1997.-2015) 46

TABLICE

Tablica 1: Pregled najznačajnih gospodarskih kriza 20. i 21. stoljeća 6
Tablica 2: Dobit (gubitak) iz poslovanja koje će se nastaviti, prije poreza, svih banaka RH u 2014. (na kraju razdoblja) 40
Tablica 3: Sistematski prikaz mehanizama širenja krize 47
Tablica 4: Prikaz varijabli modela, pripadajućih oznaka i izvora te očekivanog utjecaja 50
Tablica 5: Postupak Backward metode 52
Tablica 6: Osnovni podatci o ocijenjenom modelu s ROE kao zavisnom varijablom 52
Tablica 7: Tablica ANOVA ocijenjenog regresijskog modela 54
Tablica 8: Ocijenjeni linearni regresijski model s povratom na kapital (ROE) kao zavisnom varijablom 54
Tablica 9: Spearmanovi koeficijenti korelacije između apsolutnih reziduala i regresorskih varijabli 57
Tablica 10: Ocjene parametara i regresijska dijagnostika 57
Tablica 11: Popis kreditnih institucija u 2014. (na kraju razdoblja) 68

LITERATURA

1) Acosta, A. (2009). Obama and Executive Compensation: Real Pressure on Financial Corporations Yet to Come. Dostupno na:

2) Adelson, M. (2013). The deeper causes of the financial crisis: mortgages alone cannot explain it. *Journal of Portfolio Management*, *39*(3), 16.

3) Atkinson, T., Luttrell, D., & Rosenblum, H. (2013). How bad was it? The costs and consequences of the 2007–09 financial crisis. *Staff Papers*, (Jul).

4) Attali, J. (2009). Kriza, a poslije?. Zagreb: Meandar Media, 17-38.

5) Babić, M. (2008), „Financijske spekulacije i ekonomska kriza“, Obnovljeni život, Vol. 63 (4), str. 385-388.

6) Bađun, M. (2009). Financijsko posredovanje banaka i ekonomski rast: pregled empirijskih istraživanja. *Financijska teorija i praksa*, *33*(2), 119-151.

7) Baletić, Z. (2009). Kriza i antikrizna politika. *Ekonomski pregled*, *60*(1-2), 99-106.

8) BBC News. (2010). *Q&A: Do Bankers Really Need Their Bonuses?*. Dostupno na: http://news.bbc.co.uk/2/hi/business/8540020.stm

9) Bebchuk, L. A., Cohen, A., & Spamann, H. (2010). Wages of Failure: Executive Compensation at Bear Stearns and Lehman 2000-2008, The. *Yale J. on Reg.*, *27*, 257.

10) Belkaid, A. (2008). *Pluća i slaba karika svjetske ekonomije*. Le Monde Diplomatique 5/2008.

11) Benić, Đ. (2012). Ekonomska kriza u Europi i hrvatsko gospodarstvo.*Ekonomska misao i praksa*, (2), 847-854.

12) Benolić, M. (2012). Svjetska ekonomska kriza: razvoj, utjecaj na Republiku Hrvatsku i subjektivni stavovi studenata. *Pravnik*, *46*(92), 119-138.

13) Berkmen, P., Gelos, G., Rennhack, R., i Walsh, J.P. (2009), „The Global Financial Crisis: Explaing Cross-Country Differences in the Output Impact“, IMF Working Paper, str. 1-19

14) Bernanke, B. S. (2007). The financial accelerator and the credit channel. In *Remarks at a Conference at the Federal Reserve Bank of Atlanta*.

15) Bokan, N., Grgurić, L., Krznar, I., i Lang, M., (2010), „Utjecaj financijske krize i reakcija monetarne politike u Hrvatskoj, HNB, Vol. 1 (25), str.1-47.

16) Čorić, B. (2011). The financial accelerator effect: concept and challenges.*Financial Theory and Practice*, *35*(2), 171-196.

17) Ćorić, B., & Pugh, G. (2009). The Financial Accelerator, Globalization and Output Growth Volatility, u „*Comments on The Financial Accelerator, Globalization and Output Grpwth Volatility*“, Saša Žiković, 2009.

18) Dalić, M. (2002), „Usporedna analiza hrvatskog bankarskog sustava i financijskih sustava naprednih tranzicijskih zemalja“, Privredna kretanja i ekonomska politika, br. 92., str.27-52.

19) DeBoer, D. R. (2008). Understanding the Financial Crisis–Origin and Impact. *Department of Economics, CU-Colorado Springs accessed at http://www. ja. org*.

20) Delia, D. (2012). The impact of the Financial Crisis on the European Banks.*Annals of Faculty of Economics*, *1*(1), 1262-1268.

21) Dolignon, C., & Roger, F. (2010). *Transmission of financial shocks to the real economy: the impact of the financial accelerator* (No. 4). Working Paper Amundi.

22) Dumicic, K., Pavkovic, A., & Antic, J. A. (2012). Mjerenje koncentracije u bankarstvu u Republici Hrvatskoj. *Zbornik Ekonomskog Fakulteta u Zagrebu*, *10*(2), 117.

23) Dwight M. J. (2008). *The U.S subprime Mortgage Crisis: Issues Raised nad Lessons Learned*. Washington D.C., The World Bank for reconstruction and Development.

24) Elcano Royal Institute, (2015), „Elcano Global Presence Report 2015“.Dostupno na: http://www.globalpresence.realinstitutoelcano.org/

25) Federal Reserve System. (2016). *Selected Interest Rates (Daily) - H.15*. Dostupno na: http://www.federalreserve.gov/releases/h15/data.htm.

26) Felton, A., & Reinhart, C. M. (Eds.). (2008). *The first global financial crisis of the 21st century*. Centre for Economic Policy Research.

27) Ferreti, G.M.M., i Tille, C. (2011), „The Great Retrenchment: International Capital Flows During the Global Financial Crisis“, Economic Policy, Vol. 26 (66), str. 285-342.

28) Global financial development. (2016). World Bank. Dostupno na: http://databank.worldbank.org/data/reports.aspx?source=global-financial-development

29) Heller, D. (2008). Three ways to reform bank bonuses. *Financial Times*, *3*. Dostupno na: http://www.ft.com/cms/s/0/e093a090-d263-11dc-8636-0000779fd2ac.html .

30) HNB, (2011), „Financijski sustav Republike Hrvatske“. Dostupno na: http://www.hnb.hr/financijska_stabilnost/hfinancijka_sustav-1.htm

31) HNB. (2015a). Godišnje izvješće za 2014. Dostupno na: https://www.hnb.hr/documents/20182/122236/h-gi-2014.pdf/b607913c-e6fb-40a2-a023-41552635090b

32) HNB. (2015b). Bilten o bankama, kolovoz 2015. Dostupno na: https://www.hnb.hr/documents/20182/623991/hbilten-o-bankama-28.pdf/dd31c773-9618-4284-b834-c6c153c830b5

33) HNB. (2015c). *Financijski sustav RH*. Dostupno na: https://www.hnb.hr/temeljne-funkcije/financijska-stabilnost/uloge-i-suradnja/financijski-sustav-rh

34) Hrvatska udruga banaka (2008). „Subprime" kriza i dvojbe financijske regulacije: Gdje je granica između globalnih i lokalnih učinaka?," *HUB analize*, br. 12, 1-42. Dostupno na: http://www.arhivanalitika.hr/dat/HUB%20Analiza%2012.pdf

35) Hrvatska udruga banaka (HUB analize). (2010). *Profitabilnost banaka i krediti, Kako su banke ublažile krizu 2008.- 2010.* dvobroj 25-26, 1.-33.

36) Hrvatska udruga banaka, (2010). „Profitabilnost banaka i krediti: kako su banke ublažile krizu 2008.- 2010.", *HUB analize*, br. 25-26, 1.-33. Dostupno na: http://www.arhivanalitika.hr/dat/hubanalize%2025%20trigodinekrize%20lekt.pdf

37) HUB, (2008), „Subprime kriza i dvojbe financijske regulacije: Gdje je granica između globalnih i lokalnih učinaka?", HUB Analize, br. 12., str. 1-40.

38) Institut za javne financije. (2016). *Leksikon javnih financija*. Dostupno na: http://www.ijf.hr/hr/korisne-informacije/leksikon-javnih-financija/14/slovo/m/

39) International Labor Organization. (2016). Unemployment by sex and age (ILO estimates and projections). Dostupno na: http://www.ilo.org/wcmsp5/groups/public/---dgreports/---dcomm/---publ/documents/publication/wcms_337069.pdf

40) Investopedia. (2016). *Dictionary*. Dostupno na: http://www.investopedia.com/dictionary/ .

41) Jakovčević, D. (2001). Bankovni potencijali, poslovna spajanja banaka i razvitak hrvatskog gospodarstva. *Ekonomski pregled*, *52*(11-12), 1283-1302.

42) Jickling, M. (2009). *Causes of the financial crisis* (R40173). Washington, DC: Congressional Research Service.

43) Jovančević, R., i Globan, T. (2011), „Determinante i (ne)rezistentnost izravnih stranih ulaganja u uvjetima globalne financijske krize: primjer Hrvatske", u: Zbornik radova: Kriza: Preobrazba ili propast?, Ekonomski fakultet Zagreb, Zagreb, str.13-30.

44) Jurun, E, (2007), „Kvantitativne metode u ekonomiji", Ekonomski fakultet, Split.

45) Kirwan-Taylor, H. (2010). *How Do Bankers' Bonuses Really Work?*

46) Krivačić, D., Smederavac, S., i Vujnović, P. (2012), „Profitabilnost banaka u uvjetima gospodarske krize-analiza banaka u Hrvatskoj", Zbornik Veleučilišta u Karlovcu, Vol. 2 (1), str. 146-155.

47) Letica, B. (2010), „Prva svjetska financijska kriza u dvadeset i prvom stoljeću: uzroci i posljedice“, International Relations Quarterly, Vol. 1 (3), str. 1-13.

48) Levine, R. (1997). Financial development and economic growth: views and agenda. *Journal of economic literature*, *35*(2), 688-726.

49) Levine, R. (2005). Finance and growth: theory and evidence. *Handbook of economic growth*, *1*, 865-934.

50) Letica, B. (2010). *Doba odgovornosti, Korporacijska društvena odgovornost u vrijeme svjetske financijske krize.* Zagreb: Mate.

51) Ljubaj, I. (2005). *Indeksi koncentracije banakarskog sektora u Hrvatskoj*. Zagreb: Hrvatska narodna banka.

52) Mark, Z. (2010). *Financijski šok.* Zagreb: Mate.

53) Matthews, K., & Matthews, O. (2010). Controlling bankers'bonuses: efficient regulation or politics of envy?. *Economic Affairs*,*30*(1), 71-76.

54) Mlikotić, S. (2011). Globalna financijska kriza-uzroci, tijek i posljedice. *Pravnik*,*44*(89), 83-94.

55) MMF, (2010), „Global Financial Stability Report“,Washington: International Monetary Fond. Dostupno na: https://www.imf.org/external/pubs/ft/gfsr/2010/02/pdf/text.pdf.

56) Montiel, P. J. (2003). Macroeconomics in Emerging Markets. Cambridge University Press.

57) Murali, D. (2007). *All That You Wanted To Know About Sub-Prime Crisis.* Dostupno na: http://www.thehindubusinessline.in/bline/2007/08/19/stories/2007081951200500.htm

58) Office of the State Comptroller. (2016). New York City Securities Industry Bonus Pool. Dostupno na: http://www.osc.state.ny.us/press/releases/mar16/nyc_security_bonus_pool.pdf

59) Park, J. S. (2010). Are wall street CEO compensations a complete nonsense? A comparison study with nonfinancial industry. *Editorial Objective*, *1001*, 79.

60) Parsons, J. (2016). *JP's Real Estate Charts: United States House Prices.* Dostupno na: http://www.jparsons.net/housingbubble/

61) Pejić Bach, M., Posedel, P., & Stojanović, A. (2009). Determinante profitabilnosti banaka u Hrvatskoj. *Zbornik Ekonomskog fakulteta u Zagrebu*,*7*(1), 81-92.

62) Pivac, S. (2010), „Statističke metode – e-nastavni materijal“, Ekonomski fakutet, Split.

63) Prohaska, Z., Draženović, B. O., & Suljić, S. (2012). The role of banks in the recession of the Croatian economy. In *Financijska tržišta i institucije Republike Hrvatske u procesu uključivanja u Europsku uniju*. Sveučilište u Rijeci, Ekonomski fakultet.

64) Reider, G. D. (2010). *Financijske krize – prijašnje i sadašnja.* Zagreb: Financijski klub.

65) Rozga, A. (2009), „Statistika za ekonomiste“, Ekonomski fakultet, Split.

66) Schildbach, J. (2011). Home, sweet home? International banking after the crisis. *Frankfurt am Main: Deutsche Bank Research*.

67) Sharfman, B. S. (2009). Enhancing the efficiency of board decision making: Lessons learned from the financial crisis of 2008. *Del. J. Corp. L.*, *34*, 813.

68) Stiglitz, J. (2009). Capitalist fools. *Vanity Fair*, *51*(1), 48.

69) Šonje, A.A., (2002), „Analiza osjetljivosti bankarskog sustava-primjena „signalne“ metode“, Ekonomski pregled,Vol.53 (9-10), str. 807-848.

70) Štefulić, P., & Radman Peša, A. (2012). Kompenzacije menadžera kao jedan od uzroka suvremene financijske krize. *Oeconomica Jadertina*, *2*(2), 44-65.

71) Tiller, B. (2010). *The Subprime Crisis and the Effects on the U.S. Banking Industry*. Dostupno na: http://www.lagrange.edu/resources/pdf/citations/2009/07Business_Tiller.pdf

72) United States. Financial Crisis Inquiry Commission. (2011). *The financial crisis inquiry report: final report of the National Commission on the Causes of the Financial and Economic Crisis in the United States*. Government Printing Office. Dostupno na: https://www.gpo.gov/fdsys/pkg/GPO-FCIC/pdf/GPO-FCIC.pdf

73) World Bank. (2016). *World Development Indicators*. Dostupno na: http://data.worldbank.org/data-catalog/world-development-indicators

74) World Economic Situation and Prospects (2009). *World Economic Situation and Prospects 2009.* Dostupno na:

75) http://www.un.org/en/development/desa/policy/wesp/wesp_archive/2009wesp.pdf

76) Živko, I. (2006). Kamatni rizik u bankarstvu–izvori i učinci. *Ekonomska misao i praksa*, (2), 199-214.

77) Živko, I., i Kandžija, T. (2013), „Impact of financial crisis on banking sector stability in Republic Croatia“, Poslovna izvrsnost Zagreb, Vol. 3(1), str. 129-14

PRILOZI

Tablica 11: Popis kreditnih institucija u 2014. (na kraju razdoblja)

Red. br. na dan 31. 12. 2014.	Naziv kreditne institucije i sjedište	Oznaka 12/2013.	Oznaka 12/2014.
	Banco Popolare Croatia d.d.*	B	-
1.	Banka Kovanica d.d.	B	B
2.	Banka Splitsko-dalmatinska d.d.	B	B
3.	BKS Bank d.d.	B	B
4.	Croatia banka d.d.	B	B
5.	Erste & Steiermärkische Bank d.d.	B	B
6.	Hrvatska poštanska banka d.d.	B	B
7.	Hypo Alpe-Adria-Bank d.d.	B	B
8.	Imex banka d.d.	B	B
9.	Istarska kreditna banka Umag d.d.	B	B
10.	Jadranska banka d.d.	B	B
11.	Karlovačka banka d.d.	B	B
12.	Kentbank d.d.	B	B
13.	Kreditna banka Zagreb d.d.	B	B
	Nava banka d.d.*	B	-
14.	OTP banka Hrvatska d.d.	B	B
15.	Partner banka d.d.	B	B
16.	Podravska banka d.d.	B	B
17.	Primorska banka d.d.	B	B
18.	Privredna banka Zagreb d.d.	B	B
19.	Raiffeisenbank Austria d.d.	B	B
20.	Samoborska banka d.d.	B	B
21.	Sberbank d.d.	B	B
22.	Slatinska banka d.d.	B	B
23.	Societe Generale-Splitska banka d.d.	B	B
24.	Štedbanka d.d.	B	B
25.	Tesla štedna banka d.d.	ŠB	ŠB
26.	Vaba d.d. banka Varaždin	B	B
27.	Veneto banka d.d.	B	B
28.	Zagrebačka banka d.d.	B	B
1.	HPB - stambena štedionica d.d.	SŠ	SŠ
2.	PBZ stambena štedionica d.d.	SŠ	SŠ
3.	Prva stambena štedionica d.d.	SŠ	SŠ
4.	Raiffeisen stambena štedionica d.d.	SŠ	SŠ
5.	Wüstenrot stambena štedionica d.d.	SŠ	SŠ
*Banco Popolare Croatia d.d. pripojena je 1. prosinca 2014. OTP banci Hrvatska d.d.; Dana 1. prosinca 2014. otvoren je stečajni postupak nad Nava bankom d.d., Zagreb.			
B – Banka ŠB – Štedna banka SŠ – Stambena štedionica			

Izvor: HNB (2015b)

SAŽETAK

Globalna financijska kriza koja je započela na ljeto 2007. godine u SAD-u pucanjem „velikog mjehura“ (*tzv. bubble*) na američkom tržištu sekundarnih hipotekarnih kredita brzo se proširila na cijeli svijet te je imala nesagledive negativne efekte na gospodarstva diljem svijeta, a od čega se mnoge posljedice osjećaju i danas. Glavni cilj je analizirati poslovanje bankarskog sektora Republike Hrvatske, prije tijekom i nakon financijske krize, kako bi se sa sigurnošću moglo uočiti je li kriza, i u kojoj mjeri, utjecala na poslovanje bankarskog sektora Hrvatske, kada se usporedi s poslovanjem istog u periodu prije i nakon globalne financijske krize. Analiza pokazatelja bankarskog poslovanja pokazala je da se ne može uočiti neka pretjerana promjena u većini pokazatelja kada se promatra razdoblje prije, tijekom i nakon financijske krize. Potvrda o tome da financijska kriza nije utjecala na poslovanje bankarskog sektora Republike Hrvatske dobivena je i regresijskom analizom koja je pokazala da varijabla kriza nije značajna za poslovanje banaka RH u razdoblju od 2000. do 2013. Istraživanje još pokazalo da kada se uvrsti kriza da su na poslovanje banaka RH značajno utjecale varijable: stopa rasta kredita (pozitivno) i omjer kapitala i imovine (negativno), a kada se u model ne uvrsti kriza značajno te negativno djeluju HHI i omjer kapitala i imovine.

Ključne riječi: bankarski sektor, financijska kriza, RH, regresijska analiza

SUMMARY

Global financial crisis began in summer of 2007 in the United States when "big bubble" exploded in the US subprime mortgage market and quickly spread globally. It had enormous negative effects on the economies around the world, and even nowadays many negative consequences can be perceived. The main objective of this work was to analyze the performance of the banking sector of the Republic of Croatia, before, during and after the financial crisis, in order to find out if crisis (and to what extent), affected the operations of the Croatian banking sector. When those operations are compared in the period before and after the global financial crisis. The analysis of the banking business activites has shown that it is not possible to notice any excessive changes in most indicators when looking at the period before, during and after the financial crisis. Confirmation that the financial crisis did not affect the operations of the banking sector of the Republic of Croatia was obtained from regression analysis which showed that the variable (financial crisis) is not significant for the banking operations of Croatia in the period from 2000 to 2013. Furthermore, study results showed even when crisis is included into the model, that variables: the rate of credit growth (positive) and the ratio of capital and assets (negative) have significant effect on return on equity (ROE). In case crisis is not included into regression model, HHI and the ratio of capital and assets have significant and negative affect on ROE.

Key words: banking system, financial crisis, Republic of Croatia, regression analysis