UTJECAJ KONCENTRIČNOSTI BANKOVNOG SUSTAVA NA STABILNOST I PROFITABILNOST POSLOVNIH BANAKA

Markota, Branimir

Master's thesis / Diplomski rad

2019

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:124:322469

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-24**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

EKONOMSKI FAKULTET

SVEUČILIŠTE U SPLITU

DIPLOMSKI RAD:

UTJECAJ KONCENTRIČNOSTI BANKOVNOG SUSTAVA NA STABILNOST I PROFITABILNOST POSLOVNIH BANAKA

Mentor:

izv.prof.dr. sc. Josip Visković

Student:

Branimir Markota

2161621

Split, rujan 2019.

SADRŽAJ:

1. UVOD 3

1.1. Problem i predmet istraživanja 3

1.2. Ciljevi, struktura i hipoteze istraživanja 7

1.3. Metode istraživanja 8

1.4. Doprinos istraživanja 9

2. UTJECAJ KONCENTRIČNOSTI BANKOVNOG SUSTAVA NA STABILNOST I PROFITABILNOST POSLOVNIH BANAKA 11

2.1. Pojmovi i teorije koje objašnjavaju odnose koncentričnosti stabilnosti i profitabilnosti banaka 11

2.2. Pregled dosadašnjih istraživanja suodnosa koncentričnosti i stabilnosti 18

2.3. Pregled dosadašnjih istraživanja suodonosa koncentričnosti i profitabilnosti . 23

3. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA KONCENTRIČNOSTI BANKOVNOG SUSTAVA NA STABILNOST I PROFITABILNOST POSLOVNIH BANAKA 29

3.1. Podaci i metodologija istraživanja 29

3.2. Utjecaj koncentričnosti bankovnog sustava na stabilnost i profitabilnost poslovnih banaka 35

3.3. Analiza rezultata istraživanja 39

4. ZAKLJUČAK 43

LITERATURA 45

POPIS SLIKA I TABLICA 48

PRILOZI 50

SAŽETAK 68

SUMMARY 68

1. UVOD

1.1. Problem i predmet istraživanja

Od samog osnutka Republike Hrvatske, bankovni sustav prošao je kroz mnoštvo promjena. Kronološki gledano, sve od poslijeratne pretvorbe i privatizacije pa do svjetske krize 2008. godine, utjecalo je na samu strukturu vlasništva banaka, njihovu stabilnost i profitabilnost. Broj banaka u državnom vlasništvu 1990. godine iznosio je 22, dok je privatnih banaka bilo svega 4. Najveći broj banaka u vlasništvu Republike Hrvatske bio je 1992. godine (čak 29). U periodu od 1990. godine pa do 1997. godine raste broj privatnih banaka (1997. godine u Hrvatskoj posluje 6 privatnih banaka, dok je ukupan broj banaka na tržištu bio 60). Posebno je zanimljiv ulazak stranih banaka na tržište. Prva strana banka u RH posluje od 1994. godine, a već 2000. godine prisutno je 19 stranih banaka.

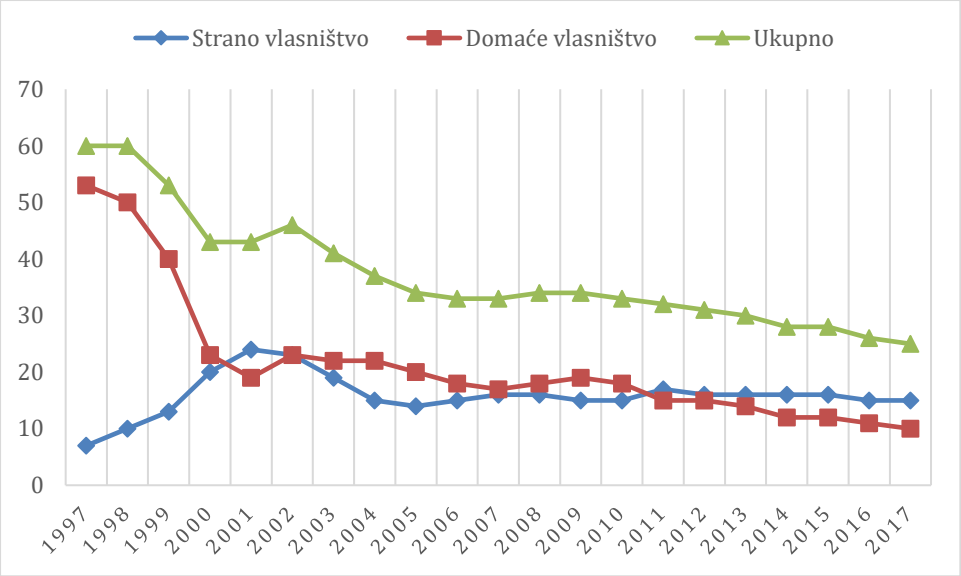

Slika 1: Vlasnička struktura banaka u Republici Hrvatskoj 1997-2017

Izrada autora; Izvor: Podaci publikacija Bilten o bankama 1-31, raspoloživo na: https://www.hnb.hr

Slika 1 prikazuje kretanje krivulja vlasničke strukture banaka u Republici Hrvatskoj u periodu od 20 godina (1997-2017). Očito je kontinuirano smanjivanje ukupnog broja kreditnih institucija, te je spomenuta značajna promjena u vlasničkoj strukturi u promatranom periodu.

Tablica 1: Vlasnička struktura banaka kroz godine

	2000.	2009.	2014.	2016.	2017.	2018.
Domaće vlasništvo	23	19	12	11	10	10
Domaće privatno vlasništvo	/	17	10	8	7	7
Domaće državno vlasništvo	/	2	2	3	3	3
Strano vlasništvo	20	15	16	15	15	11
Ukupno	**43**	**34**	**28**	**26**	**25**	**21**

Izrada autora; Izvor: Podaci iz publikacija Bilten o bankama 1-31, raspoloživo na: https://www.hnb.hr

2016. godine u RH posluje 26 banaka od kojih je 3 u državnom vlasništvu, 8 u domaćem privatnom vlasništvu i 15 u stranom vlasništvu. Evidentno je da se broj banaka iz godine u godinu mijenjao kao i struktura vlasništva. Prema Biltenu o bankama Hrvatske Narodne Banke, u odnosu na kraj 2009., kada započinje trend pada, broj banaka smanjio se za devet, pod utjecajem smanjenja broja banaka u domaćem vlasništvu. Blagi trend smanjivanja broja kreditnih institucija, nastavlja se i u 2017. godini, kada na kraju razdoblja posluje jedna kreditna institucija manje nego u prethodnoj godini, jer je u prosincu 2017. u Štedbanci započeo postupak redovne likvidacije. Slični su trendovi nastavljeni i u 2018. U ožujku je nad Tesla štednom bankom otvoren stečajni postupak. U lipnju je Zagrebačka banka pripojila članicu svoje grupe banaka, Prvu stambenu štedionicu, a u Primorskoj banci započeo je postupak redovne likvidacije.

Broj poslovnih banaka u Republici Hrvatskoj koje su u domaćem vlasništvu opada mnogo većom brzinom od broja banaka u stranom vlasništvu. Ovaj trend je očigledan u podacima predstavljenim u

Tablica ***1*** i na Slika 1. Ukupan broj banaka u periodu od 17 godina smanjio se za 50%, dok postotak smanjenja broja banaka u domaćem vlasništvu iznosi 67,75%. Onaj za strane banke je tek 21,05%.

Udio imovine dviju najvećih banaka u ukupnoj imovini (Slika 2) u 2017. iznosio je 45,5%, a u porastu je još od 2007. godine. Ovaj pokazatelj (CR2), uz pokazatelj udjela imovine prvih pet banaka (CR5) koji već duži niz godina oscilira na razini od oko 75%, indikacija je visoke koncentričnosti sustava.

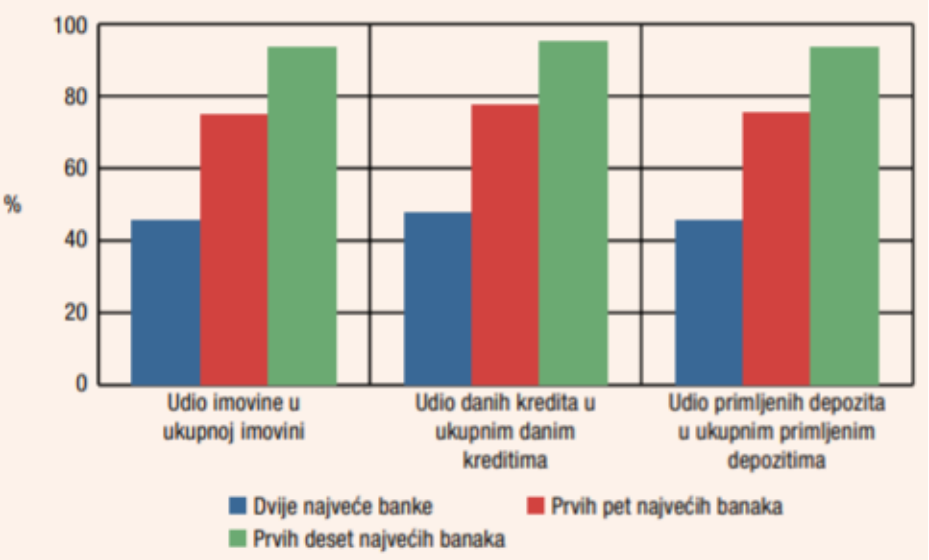

Slika 2: Udio imovine, kredita i depozita najvećih banaka u ukupnoj imovini kreditima i depozitima svih banaka, na dan 31. prosinca 2017.

Izvor: Bilten o bankama 31, raspoloživo na: https://www.hnb.hr

S druge strane, prikazano na Slika 3, unatoč smanjenju u broju banaka, Herfindahl-Hirschmanov indeks za imovinu bilježi višegodišnji trend sporog povećanja, ali je i nadalje niži od 1.500 (iznosio je 1.473), što se obično ipak smatra obilježjem kompetitivnog tržišta.

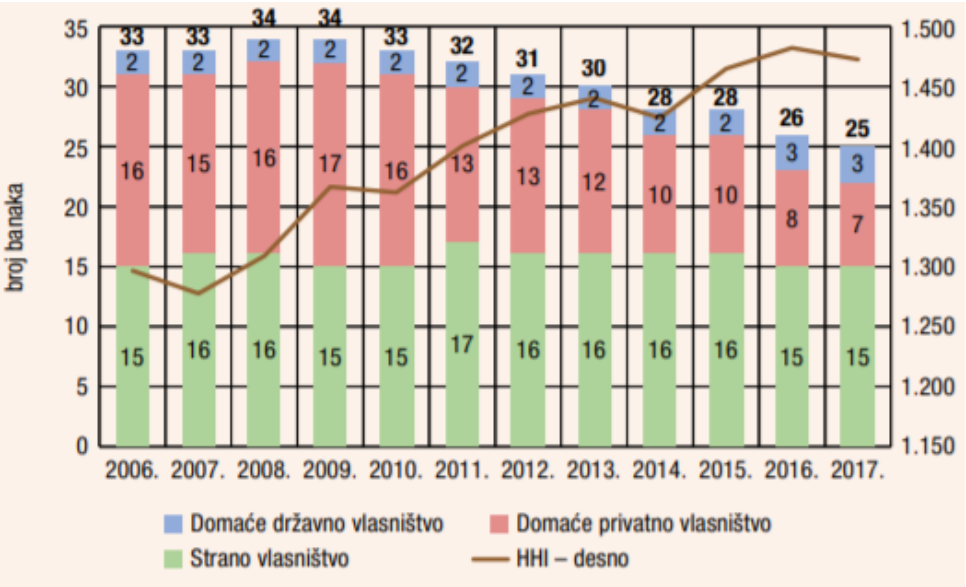

Slika 3: Broj banaka i Herfindahl-Hirschmanov indeks (HHI) za imovinu banaka kroz godine

Izvor: Bilten o bankama 31, raspoloživo na: https://www.hnb.hr

Stoga se postavlja pitanje: Kako konstantno smanjivanje broja poslovnih banaka na tržištu utječe na profitabilnost i stabilnost ostatka banaka? Odgovor na ovo pitanje nudi se kroz dvije teorije koje objašnjavaju kako razina koncentričnosti bankovnog sustava utječe na profitabilnost. Prva je Structure-Conduct-Perfomance teorija (SCP), koja objašnjava kako koncentrični bankovni sustav koristi prednosti veće tržišne moći (engl. market power) kako bi se ostvarili veći profiti. Pojednostavljeno rečeno, banka daje niske kamate na depozite, ali ima visoke kamate na kredite te se tako ostvaruje visoki profit. Ovakav se pristup može slobodno nazvati monopolskim.

Druga pak teorija (engl. efficient-structure theory) objašnjava kako je pozitivna veza između koncentričnosti i profitabilnosti indirektno povezana sa efikasnošću. Efikasnost proizlazi iz objašnjenja kako banke koje imaju niže strukturne troškove, povećavaju profite tako što smanjuju cijene i time postižu veći tržišni udio. Manje efikasne banke zauzimaju manji tržišni udio i takva podjela između više i manje efikasnih banaka dovodi do veće bankovne koncentričnosti.

Provedena istraživanja za različite zemlje dovode do podijeljenih zaključaka. Tako su pojedini autori iznijeli dokaze kako je veza između koncentričnosti bankovnog sustava i profitabilnosti banaka pozitivna, dok drugi autori tvrde da je veza negativna.

U istraživanju Pervan et al. (2015), koje je obuhvaćalo 46 banaka u Republici Hrvatskoj kroz period od 2002. godine do 2010. godine, iznijeti su dokazi o prihvaćanju SCP teorije. Konkretno, koncentričnost bankovnog sustava ima signifikantne pozitivne efekte na profitabilnost banaka. Pokazatelji koji su korišteni kao mjere za koncentričnost i profitabilnost banaka bili su Herfindahl-Hirschmann Indeks i ROA (engl. return of assets). Međutim, Černohorský et al. (2016) na temelju uzorka banaka triju zemalja (Republika Češka, Belgija i Austrija) u periodu od 2003. godine do 2012. godine dokazuje kako je korelacija u slučaju Republike Češke negativna, te da nije potvrđena korelacija između koncentričnosti i profitabilnosti banaka analizom bankovnog sustava Belgije i Austrije. Kao mjera korelacije korišten je Pearsonov koeficijent korelacije.

Nadalje, dosadašnja istraživanja korelacije između bankovne koncentričnosti i stabilnosti banaka također su pokazala da korelacija između ta dva pojma može biti pozitivna i negativna. Doll (2010) na temelju uzorka koje je obuhvaćalo banke 76 zemalja u periodu od 1990. godine do 2007. godine pronalazi dokaz kako više koncentrični bankovni sustav pridonosi većoj stabilnosti banaka. Do dokaza se došlo na temelju provedenog logističkog modela.

S druge strane, Shijaku (2013) provodi istraživanje uzorka 16 banaka na području Albanije u periodu od 2008. godine do 2015. godine dokazuje kako je utjecaj koncentričnosti bankovnog sustava na stabilnost banaka negativan. Kao mjera za koncentričnost u istraživanju je korišten Herfindahl-Hirschmann Indeks, a kao mjera za stabilnost banaka korišten je CAELS pokazatelj.

Sve navedeno dovodi do predmeta okupacije diplomskog rada: određivanja utjecaja koncentričnosti bankovnog sustava na stabilnost i profitabilnost poslovnih banaka. Istraživanje će obuhvaćati poslovne banke Republike Hrvatske, Bosne i Hercegovine i Srbije, a analizirat će se podaci kroz razdoblje od deset godina (2005-2015).

1.2. Ciljevi, struktura i hipoteze istraživanja

Ciljevi istraživanja u diplomskom radu mogu se podijeliti u dvije skupine. Prva skupina su teorijski ciljevi, a kod ovog istraživanja pod tim se podrazumijeva pružiti teorijski dovoljno informacija kako bi se razumjelo što je to bankovna koncentracija i objasniti kako se mjeri, te definirati stabilnost i profitabilnost banaka. Jedan od ciljeva je također objašnjavanje teorijske poveznice među ovim pojmovima.

Empirijski cilj istraživanja je prikaz utjecaja koncentričnosti bankovnog sustava na stabilnost i profitabilnost poslovnih banaka u odabranim zemljama, na temelju stvarnih podataka, za razdoblje od deset godina. Promatrano je razdoblje od 2005. do 2015. godine, a odabrane zemlje su Republika Hrvatska, Bosna i Hercegovina, te Srbija.

Diplomski rad će se sastojati od 4 poglavlja. U prvom, uvodnom poglavlju, definirat će se problem, predmet i hipoteze istraživanja. Također će se navesti i ukratko pojmovno objasniti znanstvene metode koje će se koristiti u istraživanju. Na kraju uvodnog dijela bit će ukratko opisana struktura diplomskog rada.

U drugom, teorijskom poglavlju pojmovno će se definirati što je to koncentričnost, stabilnost i profitabilnost, kakav je odnos među njima te će se ukazati na dosadašnja istraživanja koja su se bavila ovom tematikom.

Treći, empirijski dio rada će sadržavati testiranje hipoteza o utjecaju koncentričnosti bankovnog sustava na stabilnost i profitabilnost poslovnih banaka. Prvo će se prikupiti odgovarajući podaci nakon čega slijedi iznošenje rezultata provedene analize.

Četvrto poglavlje odnosi se na zaključak, unutar kojeg će se rezimirati rezultati dobiveni iz empirijskog dijela rada. Nakon četvrtog poglavlja slijedi popis literature, popis tablica i slika, te sažetak na hrvatskom i engleskom jeziku.

Na temelju problema i predmeta istraživanja postavljene su dvije hipoteze.

H1: Koncentričnost bankovnog sektora pozitivno utječe na stabilnost poslovnih banaka

Veza između koncentričnosti i stabilnosti može biti pozitivna i negativna. Tako je prema istraživanju de Haan, Pogoshyan (2011) temeljenom na uzorku bankarskog sustava Sjedinjenih Američkih Država u periodu 2004.-2009. ustanovljeno da bankovna koncentričnost pozitivno djeluje na stabilnost banaka. Kao mjere koje bi predstavljale rizik (stabilnost) i koncentričnost autori su koristili Z-indeks (Z score) i HHI (Herfindahl-Hirschmann Indeks).

S druge strane, istraživanje Uhde, Heimeshoff (2008) koristeći podatke 2600 banaka na području EU-25 u periodu od 1997.-2005. dokazuje negativnu korelaciju između koncentričnosti i stabilnosti. Mjere za rizik (stabilnost) i koncentričnost također su bile Z indeks i HHI.

H2: Koncentričnost bankovnog sektora pozitivno utječe na profitabilnost poslovnih banaka

Teorije koje objašnjavaju vezu između koncentričnosti bankovnog sustava i profitabilnosti banaka objašnjene su u problemu istraživanja. Empirijsko istraživanje o vezi koncentričnosti i profitabilnosti banaka donosi dva zaključka: koncentričnost utječe na profitabilnost u dugom roku, banke koje imaju „monopolsku moć“ sistemski smanjuju rizik i povećavaju profitabilnost.

Prema istraživanju provedenom na pakistanskim komercijalnim bankama, koje je obuhvaćalo period od 1996 do 2004, Bahhati (2010) prihvaća se hipoteza o SCP teoriji. To je značilo da je tržište banaka veoma koncentrično i da te banke ostvaruju „monopolske“ profite.

Empirijske dokaze o prihvaćanju Efficient-structure theory (ES) pruža istraživanje Chortatreas et al. (2009) koje je provedeno na zemljama Latinske Amerike. Najsnažniji dokazi o ES teoriji odnose se na najveća bankovna tržišta spomenutog kontinenta (Brazil, Argentina i Čile).

1.3. Metode istraživanja

Metode koje će se koristiti u ovom istraživanju su sljedeće znanstvene metode[1]. **Induktivna metoda**, kojom se, na temelju pojedinačnih činjenica i saznanja, dolazi do uopćavanja i formiranja zakonitosti, odnosno spoznaje novih činjenica i novih zakonitosti. **Deduktivna metoda**, kojom se iz općih stavova izvode posebni, pojedinačni, iz općih postavki dolazi se do konkretnih pojedinačnih zaključaka, iz jedne ili više tvrdnji izvodi se neka nova tvrdnja koja proizlazi iz prethodnih tvrdnji. **Metoda analize** je postupak znanstvenog istraživanja i objašnjenja stvarnosti putem raščlanjivanja složenih misaonih tvorevina (pojmova, sudova i

[1] Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, Sveučilište u Rijeci, Rijeka [str. 323]

zaključaka) na njihove jednostavnije sastavne dijelove i elemente i izučavanje svakog dijela (i elementa) za sebe i u odnosu na druge dijelove, odnosno cjeline. **Metoda sinteze** istražuje i objašnjava stvarnost putem spajanja, sastavljanja jednostavnih misaonih tvorevina u složene i složenijih u još složenije, povezujući izdvojene elemente, pojave, procese i odnose u jedinstvenu cjelinu u kojoj su njezini dijelovi uzajamno povezani. **Metoda dokazivanja** je jedna od najvažnijih znanstvenih metoda u kojoj su inkorporirane skoro sve metode i svi posebni metodički postupci: analiza i sinteza, generalizacije i specijalizacija, indukcija i dedukcija, apstrakcija i konkretizacija. Svrha metode je utvrditi točnost neke spoznaje. **Metoda deskripcije** je postupak jednostavnog opisivanja ili očitavanja činjenica, procesa i predmeta u prirodi i društvu te njihovih empirijskih potvrđivanja odnosa i veza, ali bez znanstvenog tumačenja i objašnjavanja. **Metoda kompilacije** je postupak preuzimanja tuđih rezultata znanstveno-istraživačkog rada, odnosno tuđih opažanja, stavova, zaključaka i spoznaja. **Komparativna metoda** je postupak uspoređivanja istih ili srodnih činjenica, pojava procesa i odnosa, odnosno utvrđivanja njihove sličnosti u ponašanju i intenzitetu i razlika među njima. **Povijesna metoda** je postupak kojim se na temelju raznovrsnih dokumenata i dokaznog materijala može egzaktno saznati što se u prošlosti dogodilo, i po mogućnosti, kako i zašto se to dogodilo. U empirijskom dijelu rada koristit će se **statistička metoda**. S pravom je nazivaju opće znanstvenom metodom, jer se vrlo često koristi u znanstveno istraživačkom radu u svim znanstvenim područjima i znanstvenim disciplinama. U ovom radu koristit će se kako bi se predočila odgovarajuća regresijska analiza, izračunali pokazatelji, te kako bi se predočili koeficijenti korelacije između koncentričnosti bankovnog sustava i stabilnosti poslovnih banaka, kao i korelacija između koncentričnosti bankovnog sustava i profitabilnosti poslovnih banaka. Koristit će se i odgovarajuća regresijska analiza. Također, radi lakšeg vizualnog prikaza obrađenih podataka koristit će se **grafičko prikazivanje**.

1.4. Doprinos istraživanja

Čitajući ovaj rad može se primijetiti kako je potrebna literatura u svrhu izrade rada većinom stranog porijekla, dok je domaća literatura uglavnom vezana uz teorijsko tumačenje pojmova koncentričnosti, stabilnosti i profitabilnosti. Također većina radova obuhvaća relaciju koncentričnost-stabilnost ili koncentričnost-profitabilnost.

Upravo u toj činjenici je doprinos ovog istraživanja. Osim što će teorijski objediniti i objasniti pojmove poput **koncentričnosti** bankovnog sustava, **stabilnosti** i **profitabilnosti** poslovnih banaka, također će se obraditi odgovarajući podaci kako bi se dobili odgovarajući pokazatelji. Pokušat će se utvrditi utjecaj koncentričnosti na stabilnost i profitabilnost.

Domaći autori u istraživanju većinom su bili bazirani na vezu između koncentričnosti bankovnog sustava i profitabilnosti poslovnih banaka. U ovom će se radu osim spomenute relacije koncentričnost-profitabilnost istražiti kakva je veza između koncentričnosti bankovnog sustava i stabilnosti poslovnih banaka i koliko jaka, budući da veza može biti pozitivna i negativna.

2. UTJECAJ KONCENTRIČNOSTI BANKOVNOG SUSTAVA NA STABILNOST I PROFITABILNOST POSLOVNIH BANAKA

2.1. Pojmovi i teorije koje objašnjavaju odnose koncentričnosti stabilnosti i profitabilnosti banaka

Prije početka, radi lakšeg razumijevanja obrađene tematike, potrebno je definirati ključne pojmove koji se koriste u istraživanju. Riječ je o koncentričnosti bankovnog sustava, te stabilnosti i profitabilnosti banaka.

Koncentričnost bankovnog sustava odnosi se na razinu tržišne koncentracije ili koncentričnosti na bankovnim tržištima. Termin tržišne koncentričnosti koristi se u situaciji kad manji broj većih igrača čini veći postotak određenog tržišta. Najčešća mjera korištena za izračun tržišne koncentričnosti je Herfindahl-Hirschman Indeks (HHI). Ovaj je indeks u suštini zbroj kvadrata postotaka tržišnog udjela svakog individualnog igrača na promatranom tržištu. Vrijednost indeksa može dosegnuti 10.000, ukoliko na tržištu postoji monopol. Što je indeks niži, tržište je konkurentnije. U scenariju savršene konkurencije, ovaj bi indeks iznosio 0.

Prema Galetiću (2012), temelj za promjenu tržišne koncentracije predstavljaju promjene u broju banaka na tržištu i promjene u odnosu spomenutih banaka. Ulaskom novih igrača na bankovno tržište dolazi do smanjenja razine koncentracije, a izlazak pak povećava istu. Također, navodi se jedna specifičnost bankovnog tržišta – izlazak banke s tržišta događa se kroz preuzimanje od strane neke druge banke.

Nadalje, prema Dollu (2010), zbog mana profita kao indikatora konkurentnosti, tradicionalna literatura industrijske organizacije nudi lepezu indikatora za mjerenje konkurentnosti, i koncentričnost tržišne strukture je jedna od njih. Najjednostavnija i najčešće korištena mjera, k omjer bankovne koncentracije, koji je zapravo kumulativni tržišni udio k najvećih banaka u sektoru. To je koncentracijska stopa CR. Njime se prikazuje ukupni tržišni udio dva ili više najvećih poduzetnika koji djeluju na nekom tržištu. S obzirom na broj poduzetnika čiji se tržišni udio uključuje u ispitivanje koncentracije, omjer tržišne koncentričnosti označava se sa CR2 (dva najveća poduzetnika), CR3 (tri najveća poduzetnika), CR4 (četiri najveća poduzetnika), itd. Glavna razlika između HHI i k omjera jest ta što HHI u obzir uzima tržišni udio svih banaka, umjesto arbitražno izabranog tržišnog udjela i najvećih banaka.

Prema Petroviću (2001), koncentracije mogu biti horizontalne, vertikalne i konglomeratne. Ako se proizvodi odnosno usluge sudionika koncentracije smatraju zamjenjivim, riječ je o

horizontalnoj koncentraciji. To, drugim riječima, znači da su društva, između kojih nastaje koncentracija ranije bili izravni konkurenti na određenom tržištu. Vertikalna je koncentracija posrijedi, ako su proizvodi odnosno usluge sudionika koncentracije komplementarni, što znači da društva prethodno nisu neposredno konkurirala, a da su po svojim proizvodima odnosno uslugama bila upućena jedno na drugo. Konglomeratne koncentracije ne mogu se podvesti ni pod koju od spomenutih kategorija, jer proizvodi njihovih sudionika odnosno usluge koje oni pružaju nisu ni zamjenski niti komplementarni.

Glede **stabilnosti** bankarskog sustava, odnosno financijske stabilnosti, javljaju se mnoge definicije. Kod većine se pojavljuje stav da je financijska stabilnost odsutnost sustavnih epizoda u kojima financijski sustav ne funkcionira (kriza). Također, radi se o otpornosti financijskog sustava na pritiske. Demirgüç-Kunt i Detragiache (2002) definiraju sistemske krize bankovnog sustava kao situaciju u kojoj signifikantni segmenti bankovnog sektora postaju insolventni ili nelikvidni, te ne mogu nastaviti funkcionirati bez posebne ispomoći od monetarnih ili nadležnih vlasti.

Sustavna epizoda karakterizira se kao kriza ako je ispunjen bar jedan od sljedeća četiri kriterija:

a) Omjer nefunkcionalne imovine i ukupne imovine u bankovnom sustavu prelazi 10%
b) Cijena operacije spašavanja je bar 2 posto BDP-a
c) Problemi bankovnog sektora rezultat su nacionalizacije banki na višoj razini
d) Dolazi do ekstenzivnog bankovnog vođenja ili hitnih mjera kao zamrzavanje depozita, produženje praznika ili garancija generaliziranih depozita od strane vlade kao odgovor na krizu

Prema Svjetskoj banci, stabilan financijski sustav sposoban je efikasno alocirati resurse, procijeniti i upravljati financijskim rizicima, održavati stopu zaposlenosti blizu prirodnoj stopi promatrane ekonomije, te eliminirati relativne promjene u cijenama stvarne ili financijske imovine koje bi utjecale na monetarnu stabilnost ili stopu zaposlenosti. Prava vrijednost financijske stabilnosti najbolje je ilustrirana u njezinoj odsutnosti, odnosno u periodima financijske nestabilnosti. U tom razdoblju, banke demonstriraju nevoljkost u financiranju potencijalno profitabilnih projekata, dolazi do ekscesivne devijacije cijena imovine od njihove intrinzične vrijednosti, te dolazi do kašnjenja u plaćanju. Veća nestabilnost vodi hiperinflaciji ili padu tržišta dionica, što može itekako potresti financijski i ekonomski sustav.

Z-Score je numerička mjera korištena u statistici, a označava poveznicu vrijednosti s prosjekom u grupi vrijednosti, mjereno u standardnim devijacijama od medijana. Ukoliko je Z-score jednak nuli, to indicira da je podatak identičan medijanu. Z-score može biti pozitivan i

negativan, s time da pozitivne vrijednosti označavaju da se nalazi poviše medijana, a negativne sugeriraju da se nalazi ispod medijana.

Altmanovi Z-Score modeli jedan su od načina utvrđivanja stabilnosti promatranog bankovnog sustava. Ovo je multivarijabilna analiza predviđanja korporativnog bankrota, a počela je 1968. kad je Edward Altman izdao prvu verziju ovog modela kako bi pružio učinkovitije sredstvo za financijsku procjenu u svrhu analize rizika.

Rezultati Altmanovvog model testa indicirali kako se bankrot može predvidjeti sa sigurnošću od 95% godinu, 72% dvije godine, 48% tri godine, 29% 4 godine i 36% pet godina prije nego što se dogodi.

Ovaj je model doživio brojne varijacije, a svaka nova revizija poboljšavala bi prediktivnu sposobnost modela. Također, prvotni model razvijen je za javne proizvodna poduzeća s imovinom većom od milijun dolara, a tokom godina, Altman revidira model kako bi bio primjenjiv na privatna poduzeća (Z' Score) i ne-proizvodna poduzeća (Z"-Score).

Formula se koristi statističkom tehnikom poznatom kao višestruka diskriminatorna analiza, po kojoj Altman pokušava procijeniti rizik koristeći pet računovodstvenih omjera:

A) Obrtni kapital/ukupna imovina
B) Zadržana dobit/ukupna imovina
C) Dobit/ukupna imovina
D) Tržišna vrijednost vlastitog kapitala/knjigovodstvena vrijednost obveza
E) Prodaja/ukupna imovina

Originalna formula izgledala bi:

$$Z = 1.2 * A + 1.1 * B + 3.3 * C + 0{,}6 * D + 0.999 * E$$

Formula za tržišta u nastajanju, koja će se koristiti u ovom radu ima sljedeći oblik:

$$Z = 6.56 * A + 3.26 * B + 6.72 * C + 1.05 * D + 3.26$$

Interpretacija rezultata modela razlikuje se ovisno o korištenom modelu. Za dva predstavljena modela, prisutne su granice u Tablica 2.

Tablica 2: Klasifikacija i interpretacija Z-score rezultata

Zona/model	Sigurna	Siva	Kritična
Z (original)	>2.99	2.99-1.80	<1.80
Z (tržišta u nastanku)	>2.60	2.60-1.10	<1.10

Izvor: Manousaridis (2017)

Kao ni mnogi drugi modeli, Z-Score nije imun na praksu lažnog knjigovodstva – jednako je precizan kao i podaci koji ulaze u model. Također, nije od velike koristi novim poduzećima s malim prihodom - bez obzira na financijsko zdravlje, ova će poduzeća imati malen rezultat. Nadalje, Z-scor se ne osvrće na problem novčanih tokova direktno, već samo putem omjera obrtnog kapitala i ukupne imovine.

Naposljetku, Z-score može demonstrirati velike varijacije iz kvartala u kvartal, kad poduzeće bilježi jednokratne otpise. Ovi iznosi mogu promijeniti konačan rezultat.

Profitabilnost je pak skup pokazatelja uspješnosti, te se njime uspoređuje financijski rezultat s investiranim novcem, prodajom i dividendnim pokrićem. To je glavni princip efikasnosti poslovanja poduzeća, te se traži maksimalizacija financijskog rezultata uz minimizaciju angažiranih sredstava i kapitala. Prema Kundid et al. (2011), profitabilnost banaka rezultat je kontinuirane međuovisnosti usvojenih strategija banaka i njihova ekonomskog okruženja. Nadalje, Ćurić (2018) u svom diplomskom radu navodi nekoliko razloga zbog kojih je profitabilnost banaka izuzetno važna:

a) Veća profitabilnost dozvoljava bankama da generiraju više sredstava za odobrenje većeg broja kredita u ekonomiji
b) Restriktivne politike pozajmljivanja novčanih sredstava od strane banaka, kao posljedice niske profitabilnosti, smanjiti će utjecaj mjera prilagodljive monetarne politike, budući da banke imaju ključnu ulogu u transmisijskom mehanizmu monetarne politike
c) Veća profitabilnost banaka važna je za regulatore jer garantira fleksibilnije omjere kapitala, i to čak u rizičnijem poslovnom okruženju

Profitabilnost se mjeri raznim pokazateljima kao što su povrat na kapital (ROE), ukupna imovina, dobit iz poslovanja, te omjer prethodna dva navedena pokazatelja i mnogi drugi. U daljnjem tekstu promatra se povezanost koncentričnosti bankovnog sustava sa stabilnošću i profitabilnošću poslovnih banaka.

Povezanost koncentričnosti bankovnog sustava s profitabilnošću poslovnih banaka može se gledati kroz dvije teorije. Prva teorija je SCP paradigma (engl. Structure, conduct, performance paradigm). SCP paradigma koristi se kao analitički okvir za utvrđivanje relacija u tržištnim strukturama, tržišnim akcijama i tržišnim performansama. Razvio ju je 1959. Joe S. Bain Jr., koji ju opisuje u svojoj knjizi „Industrijska organizacija“. Smatra SCP paradigmu stupom industrijske organizacijske teorije, i već od svog začetka se počinje koristiti kao početna točka u analizi tržišta i industrije, ne samo u ekonomiji, već u poljima poslovnog upravljanja i kontroliranja. Elemente paradigme, prikazane na

Slika **4**, čine:

a) Struktura – set varijabli koje su relativno stabilne tijekom vremena i utječu na ponašanje prodavača i/ili kupaca. Radi se o koncentričnosti ponude, koncentričnosti potražnje, diferencijaciji proizvoda i tržišnim barijerama. Također, struktura tržišta uvijek će bit određena prirodom proizvoda i dostupnom tehnologijom

b) Performanse – mjerene su usporedbom rezultata sudionika u industriji prema terminima efikasnosti, te se koriste razni omjeri pri određivanju različitih razina profitabilnosti. Varijable koje se razmatraju s ovog aspekta su cijena, količina, kvaliteta proizvoda, alokacija resursa, učinkovitost proizvodnje i sl.

c) Ponašanje sudionika na tržištu uvjetovano je strukturom i performansama. No dinamičnost u ponašanju kupaca i prodavača također ima učinak na tržište, zbog čega je teže predvidjeti i ustanoviti fiksirane tržišne strukture.

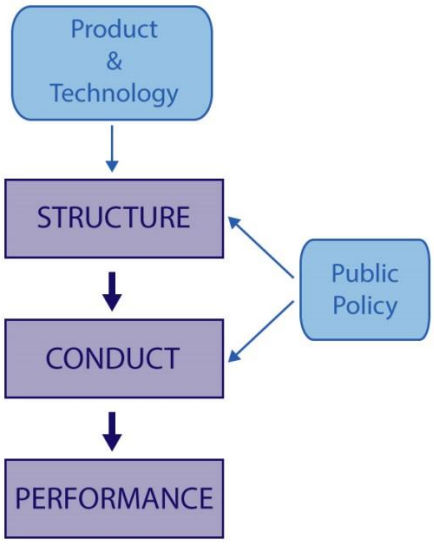

Slika 4: SCP paradigma – elementi

Izvor: Policonomics

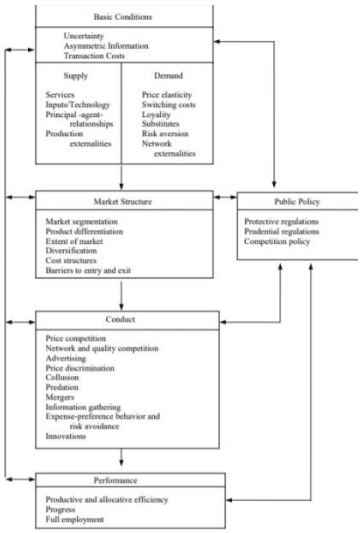

Slika 5: SCP paradigma prilagođena bankarskom sustavu

Izvor: Neuberger (1997): Structure, Conduct and Performance in Banking Markets

Problem nastaje pri definiciji paradigme zbog nedostatka podataka i mnogih definicija i ekstenzija tržišta. Iznimno je teško, koristeći ovu metodologiju u analizi, definirati granice promatrane industrije.

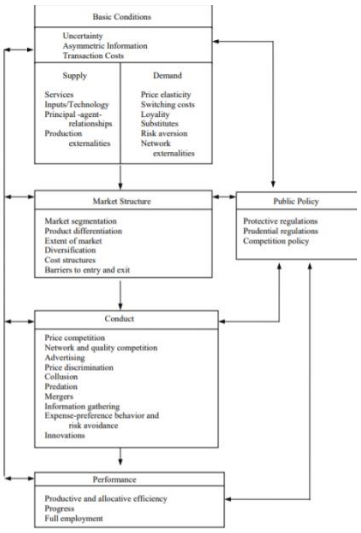

Slika ***5*** je prikaz paradigme SCP prilagođene bankarskom sustavu. Neuberger (1997), iz čijeg je rada prikaz preuzet, tvrdi da je u bankarskom sustavu potrebna revizija spomenute teorije, obzirom da su banke „posebni igrači“ na tržištu informacijama, te su uvjeti ovog tržišta od velike važnosti za strukturu, ponašanje i performanse. Njezina revizija paradigme dopunjava spomenute nedostatke paradigme.

Prema Hannanu (1991), SCP paradigma u bankarstvu djeluje tako da u vezu dovodi tržišnu strukturu s kamatama na kredite i depozite, te stopu zarade s druge strane. Ukratko, banke nude niske kamate na depozite, ali imaju visoke kamate na kredite, te tako ostvaruju visoki profit.

Teorija suprotstavljena SCP paradigmi je ES teorija (engl. Efficient-structure), te ona objašnjava kako je pozitivna veza između koncentričnosti i profitabilnosti indirektno povezana s efikasnošću. Demsetz formulira ovu teoriju 1973. kao alternativu SCP teoriji. U primijeni na bankarski sektor, ova teorija predlaže da banke koje operiraju učinkovitije od svojih konkurenata stječu veće profite, zahvaljujući niskim operacijskim troškovima, te ta ista banka ima bitan tržišni udio. Posljedično, razlike u razini učinkovitosti stvaraju nejednakost u distribuciji pozicija na tržištu, te samim time, intenzivnu koncentričnost. Prema Mensiju (2010), mjerenje učinkovitosti ističe način na koji banke alociraju svoje resurse. Na jedan način, to je razumijevanje stupnja prilagodbe banke između nastalih cijena i kvalitete ponuđenih usluga.

Dva klasična funkcionalna oblika dominiraju svijetom bankovne analize učinkovitosti:

a) Parametrijska metoda predstavlja ekonometrijsku procjenu cijena parametara i uključuje tri pristupa – Stochastic Frontier Approach (SFA), Thick Frontier Approach (TFA) i Distribution-Free Approach (DFA).
b) Neparametrijski pristup je tehnika programiranja, bolje poznata kao Data Envelopment analiza. Ova metoda se sastoji od identifikacije postoji li za svaku jedinicu odlučivanja (engl. Decision-Making Unit) ekvivalent koji proizvodi veću količinu outputa s danim inputom ili dani output s manjom količinom inputa.

S druge strane imamo koncentričnost bankarskog sustava i njegov utjecaj na stabilnost poslovnih banaka. Prema Dollu (2010), problem koji se pojavljuje kod ovog aspekta je problem mjerenja. Još od 1990-ih ekonomisti započinju empirijski pregled utjecaja bankovne koncentričnosti i konkurencije na financijsku stabilnost. Zbog prirode bankovnog sustava, standardne mjere konkurentnosti nisu direktno primjenjive na sektor. Taj se problem produbljuje činjenicom da većina banaka konkurira na obje strane bilance. Pokušavaju privući stabilne i jeftine depozite, natječući se tako s ostalim bankama na tržištu depozita. Osim toga, nude zajmove i stoga su direktni konkurenti na tržištu zajmova. Također je važno spomenuti ukidanje geografskih tržišnih granica, zahvaljujući eliminaciji kapitalnih kontrola i razvoju u informacijsko-tehnološkoj domeni. Utjecaj globalizacije definira relevantno tržište, te konkurentnost na bankovnom tržištu postaje sve zahtjevnija. Osim svih navedenih problema, vrijedi spomenuti kako mjerenje financijske stabilnosti također može biti subjektivno. Pri mjerenju financijske stabilnosti razlikujemo mikroindikatore i makroindikatore. Mikroindikatori financijske stabilnosti vezani su uz solventnost, likvidnost i neusklađene rizike individualnih institucija. Makro bazirani indikatori financijske stabilnosti fokusiraju se na epizode sistemskih bankarskih kriza.

2.2. Pregled dosadašnjih istraživanja suodnosa koncentričnosti i stabilnosti

Postojeća istraživanja suodnosa koncentričnosti bankovnog sustava i financijske stabilnosti brojna su i ekstenzivna. Provedena su u različitim vremenskim periodima, s različitim veličinama uzoraka banaka pojedinih zemalja i skupina zemalja, primjenom raznih statističkih i ekonometrijski analitičkih modela. Nastavak rada daje zaseban kronološki pregled nekoliko odabranih radova i njihovih zaključaka koji čine podlogu empirijskog istraživanja provedenog u ovom radu.

Za početak treba spomenuti istraživanje o konkurentnosti, koncentraciji i njihovom suodnosu proveli su Bikker i Haaf (2002). Ova empirijska analiza bankovne industrije je pregled konkurentskih uvjeta i tržišne strukture u bankovnoj industriji, s time da je konkurentnost mjerena koristeći Panzar-Rosse model.

	Herfindahl index	CR_3	CR_5	CR_{10}	No. of banks
Australia	0.14	0.57	0.77	0.90	31
Austria	0.14	0.53	0.64	0.77	78
Belgium	0.12	0.52	0.75	0.87	79
Canada	0.14	0.54	0.82	0.94	44
Denmark	0.17	0.67	0.80	0.91	91
Finland	0.24	0.73	0.91	1.00	12
France	0.05	0.30	0.45	0.64	336
Germany	0.03	0.22	0.31	0.46	1803
Greece	0.20	0.66	0.82	0.94	22
Ireland	0.17	0.65	0.73	0.84	30
Italy	0.04	0.27	0.40	0.54	331
Japan	0.06	0.39	0.49	0.56	140
Korea (South)	0.11	0.45	0.68	0.96	13
Luxembourg	0.03	0.20	0.30	0.49	118
Netherlands	0.23	0.78	0.87	0.93	45
New Zealand	0.18	0.63	0.90	n.a.	8
Norway	0.12	0.56	0.67	0.81	35
Portugal	0.09	0.40	0.57	0.82	40
Spain	0.08	0.45	0.56	0.69	140
Sweden	0.12	0.53	0.73	0.92	21
Switzerland	0.26	0.72	0.77	0.82	325
United Kingdom	0.06	0.34	0.47	0.68	186
United States	0.02	0.15	0.23	0.38	717
Averages/total	*0.12*	*0.49*	*0.64*	*0.73*	*4645*
Standard deviations	*0.07*	*0.18*	*0.20*	*0.18*	

Slika 6: Indeksi koncentričnosti za 23 promatrane zemlje, bazirano na ukupnoj imovini (1997)

Izvor: Bikker, Haaf (2002): Competition, concentration and their relationship: An empirical analysis of the banking industry

Istraživanje je provedeno na 23 industrijalizirane zemlje, u i izvan Europe, u periodu od 10 godina, te su određena tri su uzorka: male ili lokalne banke za lokalnu razinu, srednje velike banke za nacionalno tržište, te velike ili međunarodne banke za internacionalni nivo. Procjene su pokazale monopolističku konkurenciju za većinu promatranih država, s time da je konkurencija slabila na nižim i povećala se na većim razinama.

Koncentričnost bankovnog tržišta u promatranim zemljama mjerena je koristeći različite k-omjere bankovne koncentričnosti i HHI indeks. Slika 6 daje pregled indeksa koncentričnosti za promatrane zemlje. Visoka koncentričnost očita je u Danskoj, Grčkoj, Nizozemskoj i Švicarskoj. Gledajući kombinirani tržišni udio tri najveće banke (CR3), očito je da u ovim državama najveće tri banke zauzimaju više od dvije trećine tržišta u terminima ukupne imovine. U Kanadi je koncentričnost visoka ako se u obzir uzme 5 najvećih banaka. Prema HHI, zemlja s najvećom razinom koncentričnosti je Švicarska, što je iznimno postignuće, obzirom na veliki broj banaka. Promatrajući CR3, najniža koncentričnost prisutna je u Francuskoj, Njemačkoj, Italiji, Luksemburgu i Sjedinjenim Američkim Državama. U ovim državama indeks tržišne koncentracije banaka indicira da zajednički tržišni udio triju najveći igrača iznosi manje od trećine. Najniži je kod SAD-a, gdje tri najveće banke imaju zajednički tržišni udio od 15% tržišta. Zaključci ovog istraživanja pružaju potporu konvencionalnom pogledu da koncentričnost oslabljuje konkurentnost.

De Nicolo, Bartholomew, Zaman i Zephirin (2004) u svom istraživanju koriste podatke iz više od 100 zemalja, te od 500 najvećih financijskih ustanova. Zaključuju kako velike konglomeratske tvrtke ne demonstriraju niže razine rizičnog ponašanja od manjih i specijaliziranih tvrtki u 1995., dok rezultati pokazuju suprotnu situaciju u 2000. Također, visoko koncentrični bankovni sustavi iskazuju veći potencijal sustavnog rizika od niže koncentričnih sustava u periodu 1993-2000, te se ta veza ojačala u posljednje tri godine spomenutog perioda.

Beck, Demirgüç-Kunt i Levine (2005) istražuju vezu između bankovne koncentričnosti i fragilnosti bankovnog sustava, te mehaničku podlogu ove veze. Istraživanje nije pronašlo dokaze za teoriju da koncentričnost povećava fragilnost banaka. Radije, koncentričnost bankovnog sistema je povezana s nižom profitabilnošću u zemlji tokom sistemske bankovne krize. U terminima regulatornih politika, zaključeno je da regulacije i institucije koje potiču konkurentnost u bankarstvu su povezane s manjom bankovnom fragilnosti, te primjena indikatora tih politika ne mijenja rezultate koncentracije. Nadalje, predstavljeni su dokazi da koncentrični bankovni sustavi naginju postojanju većih, diverzificiranijih banaka, što ide u

prilog pozitivnoj poveznici između koncentracije i stabilnosti. U istraživanju su korišteni godišnji podaci 69 država, u periodu 1980-1997.

Schaek, Cihák i Wolfe (2006) s podacima od preko 2.600 banaka diljem Europe u periodu 1999-2004 empirijski testiraju hipotezu da povećana konkurentnost pruža „*incentivu*“ bankama da drže kapitalne „*buffere*“, suprotno ustaljenom. Kao i Bikker (2002), koriste Panzar-Rosse model H-Statistike. Ovo istraživanje uvjetno rečeno ruši svojevremeni konsenzus o vezi između konkurentnosti i stabilnosti. Naprotiv, ovo istraživanje također prezentira zamašan broj dokaza o pozitivnoj vezi između koncentričnosti, konkurentnosti i stabilnosti bankovnog sustava.

Cetorelli, Hirtle, Morgan, Peristiani i Santos (2007) istražuju koncentričnost i njezine implikacije za stabilnost tržišta. Zaključuju da je vezu između koncentracije i stabilnosti iznimno teško izolirati i identificirati, te su i sami nalazi poprilično nedosljedni. Deduciraju kako je veza između ove dvije stavke dvosmislena – neke nuspojave promjene tržišne strukture mogu imati stabilizacijski utjecaj, dok drugi djeluju destabilizacijski.

Istraživanjem provedenim na preko 2.600 banaka na području EU-25 u periodu 1997-2005 Uhde i Heimeshoff (2008) pronalaze empirijske dokaze da koncentričnost nacionalnog bankovnog tržišta ima negativan učinak na financijsku stabilnost europskih banaka. Mjerenja su izvođena pomoću Z-score tehnike, uz kontrolu makroekonomskih, regulatornih, institucionalnih faktora. Istražujući pojedinačne Z-score komponente, dolazi se do zaključka da tržišna koncentričnost ima pozitivan učinak na ROAA (engl. Return on Average Assets) banaka, kapitalne omjere, kao i standardnu devijaciju ROAA. Predlažu kako bi pronađena negativna veza između koncentričnosti i stabilnosti mogla biti rezultat veće nestalnosti povrata kod velikih banaka na koncentričnim tržištima.

Doll (2010). koristeći multivarijabilni logit model na podacima iz 76 zemalja u periodu 1990-2004 daje pregled relacije između bankovne koncentričnosti, konkurentnosti i financijske stabilnosti. Prema njegovim analizama, koncentrični bankovni sustavi su uglavnom stabilniji. Analizom osjetljivosti, njegovi rezultati demonstriraju otpornost na inkluziju nekoliko makroekonomskih varijabli, kao i varijabli koje obuhvaćaju regulatorni i institucijski okvir. Nadalje, rad zaključuje kako je konkurentnost štetna financijskoj stabilnosti.

Deluvaite (2010) u svom radu koristi analizu i sintezu znanstvene literature, logičku analizu i sintezu te statističke metode (jednostavna regresijska analiza, analiza korelacije, višestruka regresija) kako bi testirala postojanje veze između koncentričnosti i stabilnosti u bankovnoj industriji, te analizirala poveznice između koncentričnosti bankovnog sustava, te učestalosti i cijeni bankovnih kriza. Njezini rezultati potvrđuju postojanje veze između koncentracije i

stabilnosti u bankovnom sustavu, a analiza indicira da su bankovne krize manje česte i fiskalni nameti nastali u pokušaju rezolucije bankovnih kriza i većih socijalnih gubitaka u ekonomijama manji u državama s više koncentričnim bankovnim sustavima.

De Haan i Pogoshyan (2011) istražuju ovisi li promjenjivost bankovnih prihoda o veličini banke i stupnju koncentričnosti u bankovnom sektoru. Koristeći kvartalne podatke ne-investicijskih banaka u Sjedinjenim Američkim državama za period 2004-2009, kontrolirajući kvalitetu upravljanja, utjecaja i diversifikacije, zaključuju da veličina banke snižava promjenjivost povrata. Negativan utjecaj veličine banke na promjenjivost bankovnih prihoda snižava se (u apsolutnim terminima) uz tržišnu koncentričnost. Također, veće banke locirane u koncentričnim tržištima iskusile su veću promjenjivost tijekom nedavnih financijskih kriza. Naposljetku dodaju da unatoč kritikama upućenim velikim bankama, njihova stabilna zarada pridonosi sveukupnoj financijskoj stabilnosti.

Shijaku (2016) apostrofira dinamičnu vezu između konkurentnosti i bankovne stabilnosti u Albanskom bankarskom sustavu u periodu 2008-2015. U radu koristi Lernerovi indeks, kao i HHI. Glavni rezultati pružaju snažnu dokaze koji podupiru pozitivnu vezu između konkurentnosti i stabilnosti – niži stupanj tržišne moći izlaže banke manjem ukupnom riziku. Također, rezultati ovog rada tvrde kako povećana koncentričnost ima velik utjecaj na fragilnost banaka, te da je bankovna stabilnost pozitivno povezana s makroekonomskim uvjetima i kapitalnim omjerom, te obrnuto proporcionalna operativnoj učinkovitosti.

Tablica 3 nudi kratak pregled svih spomenutih radova i njihovih zaključaka.

Tablica 3: Pregled odabranih istraživanja o suodnosu koncentričnosti i stabilnosti bankovnog sustava

Autor(i)	Subjekti	Period	Korištena metoda	Zaključci
Bikker, Haaf (2002)	23 zemlje	10 godina	Panzar-Rosse	Koncentričnost oslabljuje konkurentnost
De Nicolo, Bartholomew, Zaman, Zephirin (2004)	100 zemalja	1993-2000	/	Negativna veza između koncentričnosti i stabilnosti
Beck, Demirgüç-Kunt, Levine (2002)	69 država	1980-1997	/	Pozitivna veza između koncentričnosti i stabilnosti
Schaek, Cihák, Wolfe (2006)	2.600 banaka	1999-2004	Panzar-Rosse	Pozitivna veza između koncentričnosti i stabilnosti
Cetorelli, Hirtle, Morgan, Peristiani, Santos (2007)	SAD	1980-2004	Statističke metode, sinteza i analiza znanstvene literature	Nedosljedni nalazi, dvosmislena veza između koncentričnosti i stabilnosti
Uhde, Heimeshoff (2008)	EU-25 2.600 banaka	1997-2005	Z-score	Negativna veza između koncentričnosti i stabilnosti
Doll (2010)	76 zemalja	1990-2004	Multivarijabilni logit model	Pozitivna veza između koncentričnosti i stabilnosti Negativna veza između konkurentnosti i stabilnosti
Deluvaite (2010)	/	/	Analiza i sinteza znanstvene literature, logička analiza i sinteza, statističke metode	Pozitivna veza između koncentričnosti i stabilnosti
De Haan, Pogoshyan (2011)	SAD	2008-2015	/	Negativna veza između koncentričnosti i stabilnosti
Shijaku (2016)	Albanija	2008-2015	Lernerov indeks, HHI	Negativna veza između koncentričnosti i stabilnosti

Prikaz autora

2.3. Pregled dosadašnjih istraživanja suodonosa koncentričnosti i profitabilnosti

Postojeća istraživanja suodnosa koncentričnosti bankovnog sustava i profitabilnosti poslovnih banaka brojna su i ekstenzivna. Provedena su u različitim vremenskim periodima, s različitim veličinama uzoraka banaka pojedinih zemalja i skupina zemalja, primjenom raznih statističkih i ekonometrijski analitičkih modela. Nastavak rada daje zaseban kronološki pregled nekoliko odabranih radova i njihovih zaključaka koji čine podlogu empirijskog istraživanja provedenog u ovom radu.

Jedan od prvih, Heggestad (1977) testira interakciju tržišne strukture, profitabilnosti i rizika u bankarstvu. Postavlja hipotezu da tržišna struktura ima signifikantan utjecaj na profitabilnost, uz održavanje svih ostalih determinantni konstantnima, uključujući rizik. U modelu je korištena analiza višestruke regresije. Rezultati identificiraju rizik kao važnu determinantu u bankovnim profitima. Zaključuje da veličina banke nema vidljivog efekta na profitabilnost. Konačni zaključak je kako tržišna struktura dugoročno gledano utječe na profitabilnost banaka, čak i kad se napravi prilagodba na utjecaje nastale zbog razlika u poduzimanju rizika.

Heggestadov zaključak ide u prilog SCP paradigmi, o čijoj primjeni na bankovnim tržištima detaljnije govori Neuberger (1997). Empirijsko istraživanje o SCP paradigmi na bankovnim tržištima razvilo se uglavnom neovisno od mikroekonomske teorije bankarstva. Neuberger nudi pregled literature, ali s fokusom na veze između teorijskog i empirijskog istraživanja. U radu koristi revidirani SCP okvir, koji smatra prikladnim za bankovna tržišta, gdje su sve varijable endogene zbog međuzavisnosti između varijabli tržišne strukture, ponašanja i performansi, te učinka povratne sprege na osnovne uvjete te javnu politiku. Dolazi do zaključka da su konkurentski uvjeti različiti u različitim tržišnim segmentima, te da rastući trend pojave univerzalnih banaka koje su aktivne u različitim geografskim tržištima pruža nove istraživačke izazove. Također tvrdi da ne postoji optimalna veličina za bankovnu instituciju, jer banke različitih veličina imaju različite specijalizacije.

Bhatti (2010) kroz svoje istraživanje pruža uvid u vezu između tržišne strukture i performansi bankovnog sektora koristeći podatke pakistanskih komercijalnih banaka. Istražuje učinke promjena tržišne strukture na profitabilnost temeljeći se na SCP i ES hipotezama. Na uzorku od 20 komercijalnih banaka, koristeći godišnje podatke u periodu 1996-2004, pomoću ROA (engl. Return of assets), ROC (engl. Return of capital) i ROE (engl. Return of equity) provodi regresijsku analizu, te pronalazi pozitivnu vezu između koncentričnosti i profitabilnosti. Rezultati tržišnog udjela korištenog za ES hipotezu iziskuju negativnu vezu između koncentričnosti i profitabilnosti, te se zbog empirijskih nalaza prihvaća SCP paradigma i

zaključuje kako tržišna koncentracija određuje profitabilnost Pakistanskih komercijalnih banaka.

Jeon i Miller (2002) istražuju korelaciju bankovne koncentričnosti na bazi saveznih država u SAD-u i prosječne bankovne profitabilnosti unutar pojedine savezne države. Pronalaze jaku potporu pozitivnoj korelaciji, te testovima temporalne kauzalnosti dolaze do zaključka da bankovna koncentričnost vodi bankovnoj profitabilnosti. Koriste indikator ROE, te omjere bankovne koncentričnosti C5 i C10, kao i HHI indeks unutar svake savezne države i District of Columbia u periodu 1967-2000.

Rinkevičiūtė et al. (2014) u svom istraživanju procjenjuje utjecaj tržišne koncentričnosti na profitabilnost litvanskog bankarskog sektora za period 2007-2013. U istraživanju koristi HHI indeks i k-bankovni koncentracijski omjer, te se referira na ROA i ROE indikatore. Litvanski bankarski sustav dio je sustava Europske unije, i prema Litvanskoj Središnjoj Banci, 90% tržišta u terminima ukupne imovine je u stranom vlasništvu. Također, izrazita je koncentričnost tržišta, obzirom da udio u ukupnoj imovini pet najvećih financijskih institucija iznosi 90%. Zaključuje kako u promatranom periodu bankovne performanse u Litvi nisu bile stabilne, ali u posljednjem dijelu promatranog perioda, profitabilnost je porasla. U 2013. godini, HHI i CR3 omjer demonstriraju visoke udjele u malom broju igrača na tržištu. Uspoređujući mjere profitabilnosti i koncentričnosti litvanskom bankarskom sustavu, deducira da koncentričnost nema signifikantan učinak na profitabilnost, uzimajući u obzir činjenicu da su fluktuacije u koncentraciji bile različite od onih u profitabilnosti u analiziranom periodu. Dodaje da su ROA indikator i koncentričnost iskazali signifikantniju korelaciju u odnosu na korelaciju ROE indikatora i drugih promjena u industriji.

Istraživanje Pervan, Ćurak i Poposki (2015) je posebno zanimljivo, obzirom da se odnosi na područje bankovnog sektora Republike Hrvatske. Ovaj rad procjenjuje učinak industrijske koncentričnosti na performanse hrvatskih banki. Korišteni su nebalansirani podaci uzorka od 46 banaka kroz period 2002-2010. Procijenjeni rezultati sugeriraju da koncentričnost bankovnog sustava ima signifikantan pozitivan efekt na bankovnu profitabilnost. Ti dokazi podupiru SCP pristup, prema kojem industrijska struktura utječe na bankovno ponašanje, što posljedično određuje bankovne performanse. Osim industrijske koncentričnosti, statistički signifikantan učinak na bankovnu profitabilnost potvrđen je kod bankovno-specifičnih determinanti – veličina banke, starost, kreditni rizik, intermedijacija, kao i eksterni faktori – povrat tržišta dionica, ekonomski rast i monetarna nestabilnost.

Smirlock (1985) u svom radu daje alternativno objašnjenje ustaljenom mišljenju svog vremena o prihvaćanju SCP teorije. Prije njega Rhodes (1977) u svom pregledu literature izražava „nevjericu i frustraciju) u cjelokupnu nemogućnost povezivanja koncentričnosti i performansi, obzirom da je toliko studija u sektoru industrije pronašlo dokaze relativno velikog učinka koncentričnosti na performanse. Smirlock tvrdi da ne postoji poveznica između koncentričnosti i profitabilnosti, time negirajući SCP pristup, već smatra kako relevantan utjecaj na profitabilnost banke ima tržišni udio. Njegovo istraživanje provedeno je na preko 2.700 državnih banaka u sedam saveznih država pod jurisdikcijom Banke Federalnih Reservi Kansas City-ja u periodu 1973-1978. Rezultati podupiru ES hipotezu.

Smirlockove zaključke potvrđuje Whalen (1987). U svojoj studiji pokušava pružiti dodatni uvid u prirodu poveznice između tržišne strukture i bankovnih performansi. Testira vezu između bankovne profitabilnosti i koncentričnosti koristeći uzorak od 191 institucije iz ne-metropolitanskih statističkih područja (MSA) okruga u Ohiu i Pennsylvaniji. Empirijski rezultati utvrđeni korištenjem ovog uzorka ne daju potporu SCP paradigmi. Zaključeno je kako je bankovni tržišni udio pozitivno i signifikantno povezan s bankovnom profitabilnošću, u slučaju kad je bankovna koncentričnost uključena u regresiju i u slučaju kad nije. Tvrdi da činjenica da bliskost njegovih rezultata sa Smirlockovim, unatoč manjem uzorku i različitom vremenskom periodu, potvrđuje ES hipotezu.

Vrijedi spomenuti i Liang (1989), koja istražuje povezanost bankovnih profita i rizika. Empirijski rezultati demonstriraju smanjenje bankovnih profita, te tvrdi da učinak bankovne koncentričnosti na bankovne profite postaje veći kad se u jednadžbu uključi rizik, iako navedeni učinak ostaje kvantitativno malen.

Chortareas, Garza-Garcia i Girardone (2011) analiziraju bankovni sektor Latinske Amerike. Testiraju spomenuto bankovno tržište u odnosu na SCP i ES hipoteze na uzorku od 2500 banaka u 9 zemalja u periodu 1997-2005, koristeći Data Envelopment analizu. Zaključci studije daju dokaze koji podupiru ES hipotezu, te se ističe kako su nalazi poprilično snažni za najveća bankovna tržišta u regiji, konkretno Brazil, Argentinu i Čile.

Veza između tržišnog udjela i profitabilnosti je vjerojatno najčešće proučavan pojedinačni fenomen u poslovnoj politici. Genchev (2012) u svojoj studiji istražuje učinke raznih faktora (tržišni udio, koncentričnost) na mjere profitabilnosti banki u Bugarskoj. Koristi ROE indikator. Glavna hipoteza je da bi vodeće banke po tržišnom udjelu trebale ostvariti veću profitabilnost. Rezultati ankete demonstriraju pozitivnu i statistički signifikantnu vezu između tržišnog udjela i profitabilnosti banaka. Empirijski rezultati potvrđuju kako ne postoje

statistički signifikantna veza između koncentričnosti u bugarskom bankarskom sustavu i njegovoj profitabilnosti.

Simatele (2017) ističe kako veza između profita i strukture bankovnog tržišta potiče raspravu kako u zakonodavstvu, tako i unutar istraživačke zajednice. Sagledava vezu između strukture i ponašanja u južnoafričkom bankovnom sektoru. Koristeći Bergerov test diskriminacije, procjenjuje se učinak industrijske koncentričnosti, tržišnog udjela i efikasnosti na tri mjere profitabilnosti. Proučavan je uzorak od 11 južnoafričkih banaka u vremenu 1994-2016. Rezultati pokazuju da koncentričnost utječe na ponašanje, a nadalje se tvrdi da je veza između profita i strukture dominantno objašnjena SCP teorijom, a djelomično ES hipotezom. Rezultati sugeriraju kako je politika obeshrabrivanja koncentričnosti i promocije konkurentnosti u bankovnom sektoru društveno povoljna.

Al Arif i Awwaliyah (2018) istražuju Islamski bankovni sustav Indonezije koristeći panel regresiju. U analizi se koriste indikatori tržišnog udjela, te k-omjer bankovne koncentričnosti (CR4). Rezultati pokazuju kako struktura tržišta ne utječe na profitabilnost indonezijske Islamske bankovne industrije. To sugerira kako performanse Islamskih bankovnih sustava u Indoneziju ne podržavaju SCF ni ES hipotezu.

Tablica 4 nudi kratak pregled svih spomenutih radova i njihovih zaključaka.

Tablica 4: Pregled odabranih istraživanja o suodnosu koncentričnosti i profitabilnosti bankovnog sustava

Autor(i)	Subjekti	Period	Korištena metoda	Zaključci
Heggestad (1977)	/	/	Razvijeni matematički model, višestruka regresija	Pozitivna veza između koncentričnosti i profitabilnosti, potvrđuje SCP teoriju
Neuberger (1997)	/	/	Revidirani SCP okvir, analiza i sinteza znanstvene literature	Potvrđuje SCP teoriju
Bhatti, Hussain (2010)	20 banaka Pakistan	1996-2004	ROA, ROC, ROE, višestruka regresija	Pozitivna veza između koncentričnosti i profitabilnosti, potvrđuje SCP teoriju
Jeon, Miller (2002)	SAD	1967-2000	ROE, k-omjer bankovne koncentričnosti, HHI	Pozitivna veza između koncentričnosti i profitabilnosti
Rinkevičiūtė, Martinkutė-Kaulienė (2014)	Litva	2007-2013	ROE, ROA, k-omjer bankovne koncentričnosti, HHI	Negativna veza između koncentričnosti i profitabilnosti
Pervan, Ćurak, Poposki (2015)	46 banaka Hrvatska	2002-2010	Dinamički panel modeli	Pozitivna veza između koncentričnosti i profitabilnosti, potvrđuje SCP teoriju
Smirlock (1985)	2.700 banaka SAD	1973-1978	Razvijeni matematički model	Negativna veza između koncentričnosti i profitabilnosti
Whalen (1987)	191 banak MSA Ohio i Pennsylvania	1982-1984	ROA, HHI	Negativna veza između koncentričnosti i profitabilnosti

Chortareas, Garza-Garcia, Girardone (2011)	2.500 banaka 9 država Latinske Amerike	199-2005	Dana Envelopment Analiza	Potvrđuje ES teoriju
Genchev (2012)	22 banke Bugarska	2006-2010	ROE, k-omjer bankovne koncentričnosti, tržišni udio, HHI	Negativna veza između koncentričnosti i profitabilnosti
Simatele, Mishi, Ngonyama (2017)	11 banaka JAR	1994-2016	Bergerov test diskriminacije	Veza između profita i strukture dominantno objašnjena SCP teorijom, a djelomično ES hipotezom
Al Arif, Awwaliyah (2018)	Indonezija	2013-2016	k-omjer bankovne koncentričnosti	Ne podržava SCF ni ES hipotezu

Prikaz autora

3. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA KONCENTRIČNOSTI BANKOVNOG SUSTAVA NA STABILNOST I PROFITABILNOST POSLOVNIH BANAKA

3.1. Podaci i metodologija istraživanja

Istraživanje se provodi na uzorku od 24 banke koje posluju na području Republike Hrvatske, Bosne i Hercegovine te Republike Srbije. Podaci su godišnji, a analiza obuhvaća period od 2005. do 2015. godine. Korišteni podaci prikupljeni su iz godišnjih izvještaja banaka, Biltena o Bankama Hrvatske Narodne Banke, Izvještaja o Bankarskom sektoru Narodne banke Srbije, te Statističkog web portala Centralne Banke Bosne i Hercegovine. Banke su odabrane prema kriteriju veličine tržišnog udjela na polovici promatranog razdoblja (2010.)

Vrijednosti su izražene u hrvatskim kunama (HRK). Za konverziju valuta uzete su vrijednosti tečajeva konvertibilne marke (BAM) i srpskog dinara (RSD) prema Hrvatskoj Narodnoj Banci na dan 1. kolovoza 2019. Tečajevi lokalnih valuta izračunati su na osnovi srednjeg tečaja američkog dolara prema kuni, koji je na dan 1. kolovoza 2019. iznosio 6.616432 za jedan USD, kao i na osnovi srednjih tečajeva stranih valuta prema američkom dolaru i euru objavljenih na financijskom servisu Bloomberg. Pritom je uzeta vrijednost od 1.6 RSD i 0.2661 BAM kao protuvrijednost 1 HRK.

Tablica ***5*** pruža pregled kretanja unutar bankovnog sektora pojedinih država.
Potpuni pregled kretanja financijskih pokazatelja po pojedinim bankama u pojedinim državama za pojedine godine dostupan je u PRILOZI.

Tablica 5: Pregled kretanja broja banaka i ukupne aktive kroz godine

	RH		SRB		BIH	
	Broj banaka	Ukupna aktiva u mil. kn	Broj banaka	Ukupna aktiva u mil. Kn	Broj banka	Ukupna aktiva u mil. kn
2005	34	260,277.60	40	48,308.26	33	44,911.50
2006	33	304,605.30	37	72,845.58	32	54,319.97
2007	33	345,081.40	35	97,301.51	32	72,796.14
2008	34	348,209.20	34	110,702.05	30	77,200.83
2009	34	378,370.60	34	134,592.92	30	78,067.70
2010	33	391,071.20	34	157,868.20	29	78,590.39
2011	32	397,359.80	33	165,095.00	29	81,274.21
2012	31	399,919.80	32	179,424.00	28	82,925.11
2013	30	397,863.70	30	177,305.80	27	87,245.46
2014	28	395,237.70	29	184,906.40	26	90,976.93
2015	28	393,394.30	30	189,890.40	26	94,358.93

Izrada autora

Slika 7: Kretanje pokazatelja ROA i ROE kroz godine u RH

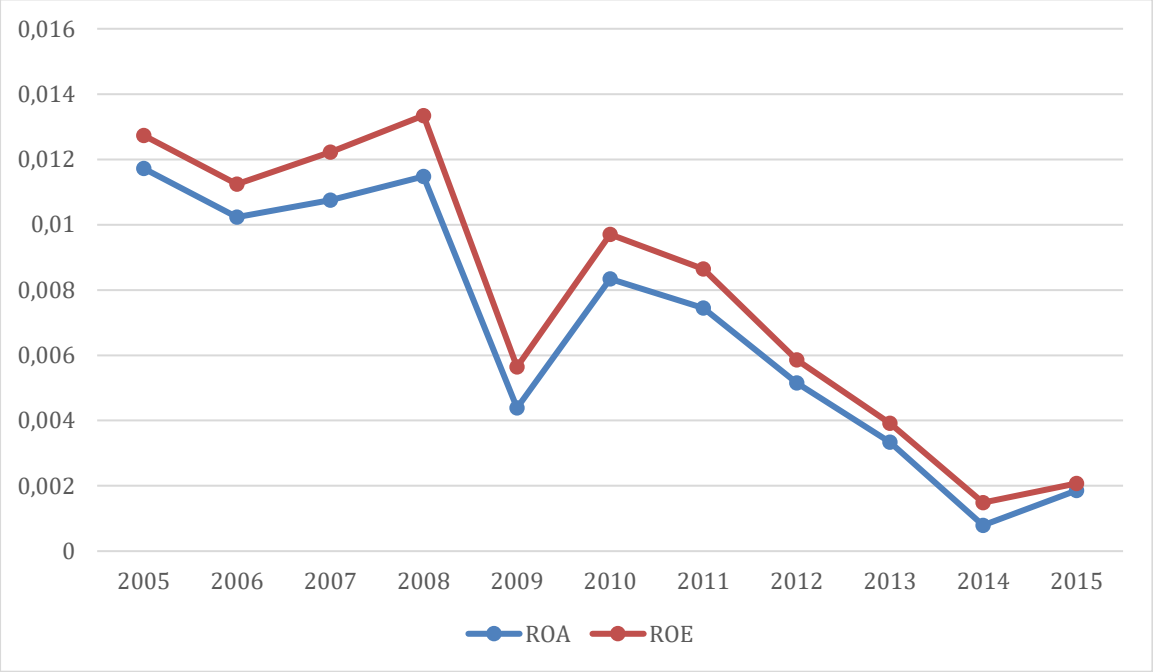

Izračun i prikaz autora prema podacima iz godišnjih financijskih izvještaja

Pokazatelj ROA (engl. Return on assets) pokazatelj je profitabilnosti imovine koji prikazuje povrat uložene imovine. Izračunava se kao omjer dobitka poslovne godine i vrijednosti ukupne imovine iskazane na posljednji dan promatrane godine. Pokazatelj ROE (engl. Retun on equity) pokazatelj je profitabilnosti vlastitog kapitala. Dobiva se stavljanjem dobitka poslovne godine

u omjer s tržišnom vrijednošću vlastitog kapitala iskazanog na posljednji dan promatrane godine.

Slika ***7***, Slika ***8*** i

Slika ***9*** prikaz su kretanja ovih pokazatelja u promatranom razdoblju u promatranim državama. Dok u slučaju Republike Hrvatske i Bosne i Hercegovine, ROE poprilično vjerno prati putanju pokazatelja ROA, kod Republike Srbije vidljive su neke oscilacije (npr. 2012. godina). U sve tri promatrane države očit je pad pokazatelja profitabilnosti u 2009. godini, nakon početka globalne financijske krize, te je u sve tri države očit blagi rast nakon 2010., te kontinuirani pad sve do 2014. godine, u slučaju Bosne i Hercegovine čak i ispod nule.

Slika 8: Kretanje pokazatelja ROA i ROE kroz godine u RS

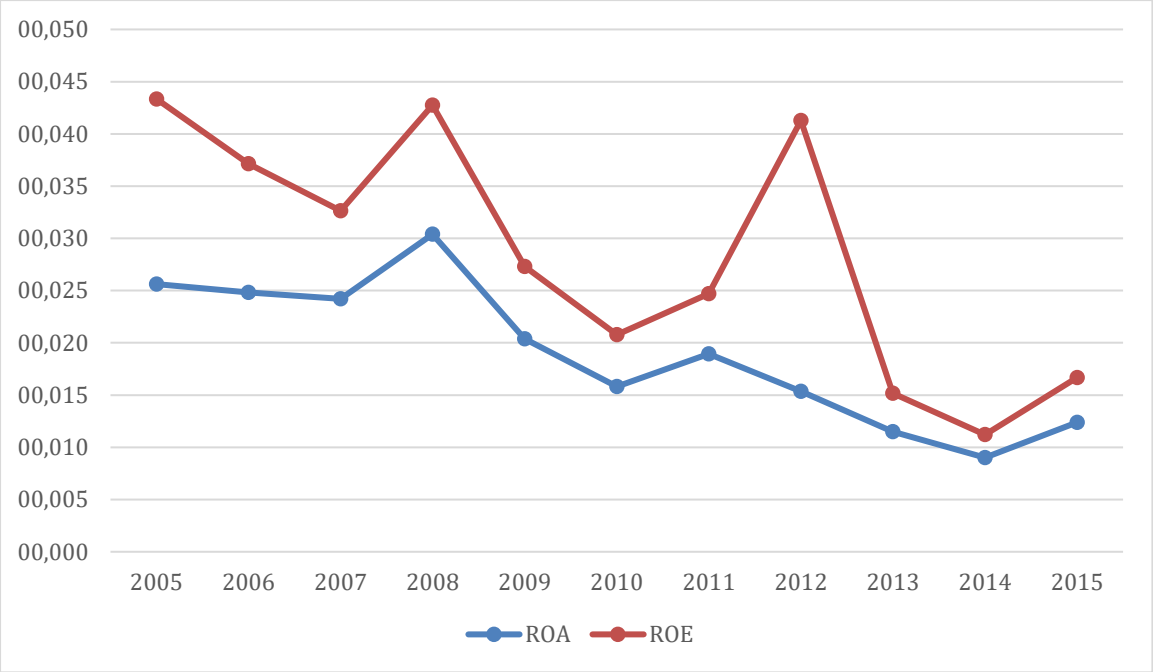

Izračun i prikaz autora prema podacima iz godišnjih financijskih izvještaja

Slika 9: Kretanje pokazatelja ROA i ROE kroz godine u BIH

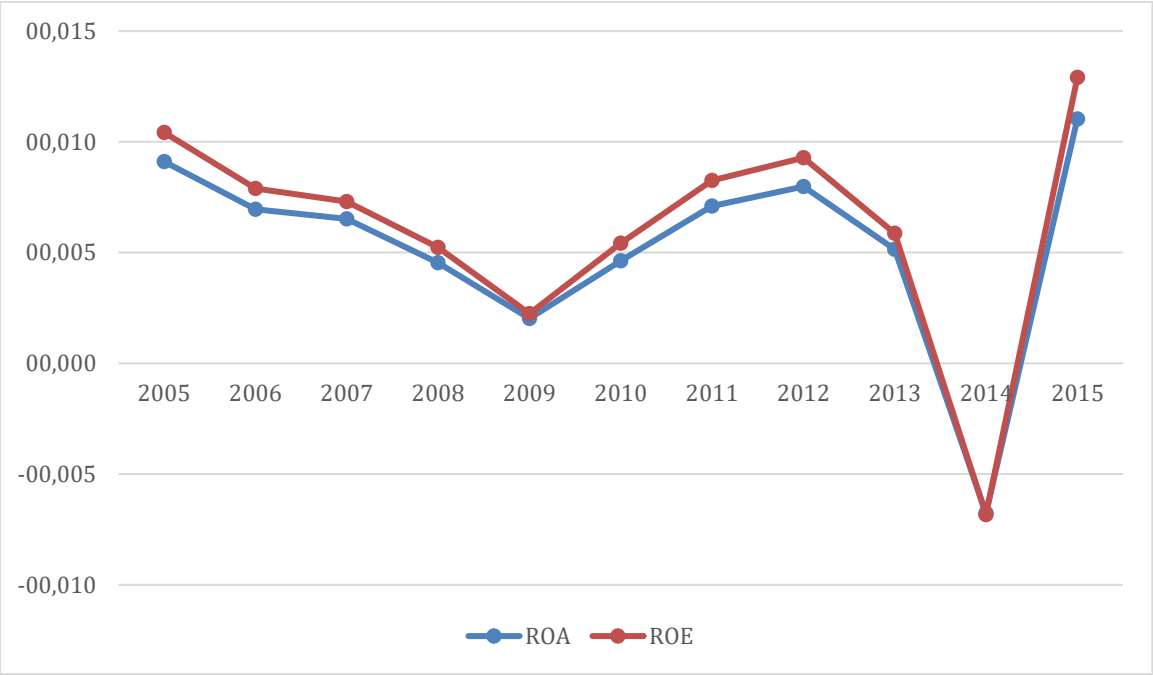

Izračun i prikaz autora prema podacima iz godišnjih financijskih izvještaja

Slika 10 prikazuje kretanje vrijednosti Z-Score u bankovnom sektoru za analizirano razdoblje po državama. Hrvatska ima najveći, ali i najvarijabilniji iznos Z-Score vrijednosti u bankovnom sektoru. Ona se kreće u rasponu od 5 do 6,5. Prosječne vrijednosti Z-Scorea za Srbiju i Bosnu i Hercegovinu kreću se u rasponu od 4 do 4.5. Prema predstavljenom u Tablica 2, daje se zaključit da je stabilnost bankarskog sustava u sve tri države neupitna-

Vidljivo iz

Tablica ***6***, Republika Hrvatska je u promatranom periodu imala poprilično konstantne pokazatelje bankovne koncentričnosti, dok se isto ne može reći za Republiku Srbiju, te Bosnu i Hercegovinu. Promatramo li HHI u odnosu na CR5 indikator, uočljivi su periodi pada i rasta, koji reflektiraju pad ili rast u imovini pet najvećih banaka u državi.

Kada se uspoređuju razine koncentričnosti prema HHI (

Slika ***11***1), očito je kako bankarski sektor Republike Hrvatske ima najvišu razinu koncentričnosti.

Slika 10: Kretanje prosječnog Z-Score-a u bankovnom sektoru u promatranom razdoblju

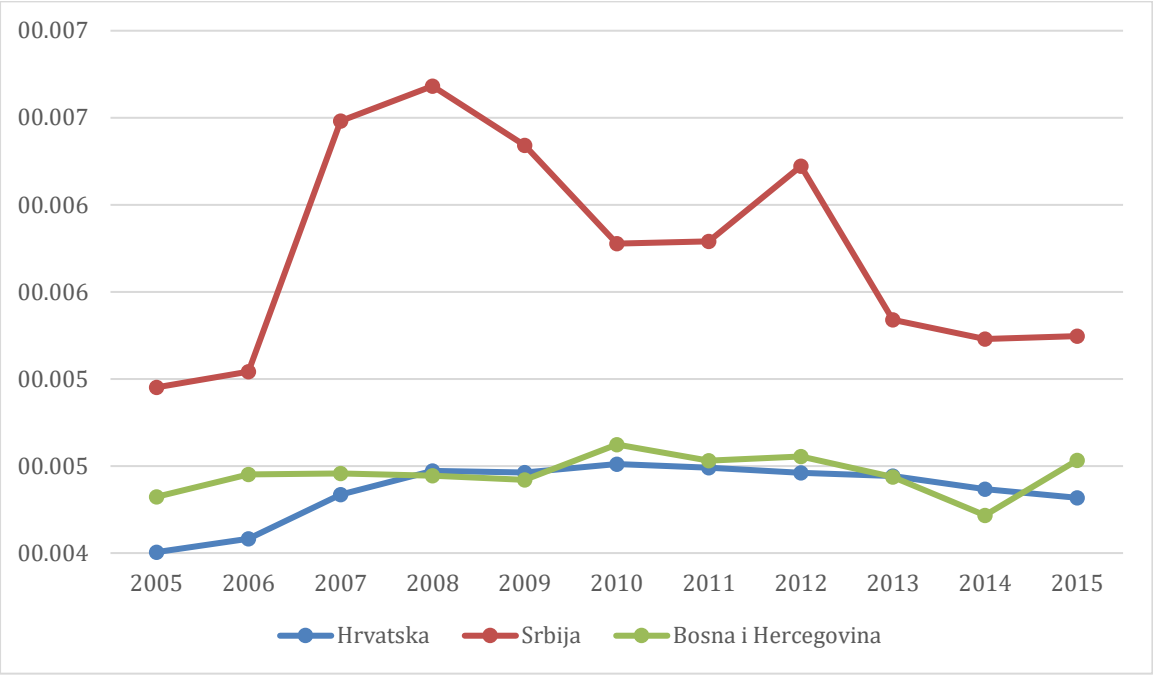

Izvor: Izrada autora prema statističkim podacima iz državnih publikacija

Tablica 6: Pokazatelji koncentričnosti po državama i godinama

	RH			SRB			BIH		
	CR2	CR5	HHI	CR2	CR5	HHI	CR2	CR5	HHI
2005	42	72.1	1302.66	np	np	np	45.09	89.32	1761.81
2006	39.65	75.12	1317.33	np	np	np	48.72	81.21	1909.61
2007	41.23	71.89	1294.47	np	np	np	49.55	81.2	1668.27
2008	41.24	71.93	1293.58	23.7	44.77	627.05	45.42	71.59	1589.14
2009	41.61	74.93	1363.21	23.75	45.79	636.17	38.84	65.94	1187.35
2010	41.49	75.1	1356.35	21.22	41.4	645.35	36.62	62.44	1140.42
2011	42.35	75.53	1387.82	25.18	47.13	659.11	34.47	61.01	1074.57
2012	42.64	75.93	1417.26	25.61	48.05	677.64	32.3	57.81	999.42
2013	43.28	75.56	1427.21	27.79	27.79	740.94	32.86	56.13	1007.58
2014	42.56	72.92	1389.24	29.61	29.61	793.98	34.45	55.04	1054.87
2015	43.41	73.86	1423.86	28.86	28.86	796.38	33.21	53.74	942.38
Mean	41.951	74.079	1361.181	25.715	39.175	627.05	39.23	66.857	1303.22
Min	39.65	71.89	1293.58	21.22	27.79	48.05	32.3	53.74	942.38
Max	43.41	75.93	1427.21	697.0775	627.05	796.38	49.55	89.32	1909.61

Izračun i prikaz autora prema podacima iz godišnjih financijskih izvještaja

Slika 11: Usporedba RH, RS i BIH prema srednjoj vrijednosti HHI za promatrani period

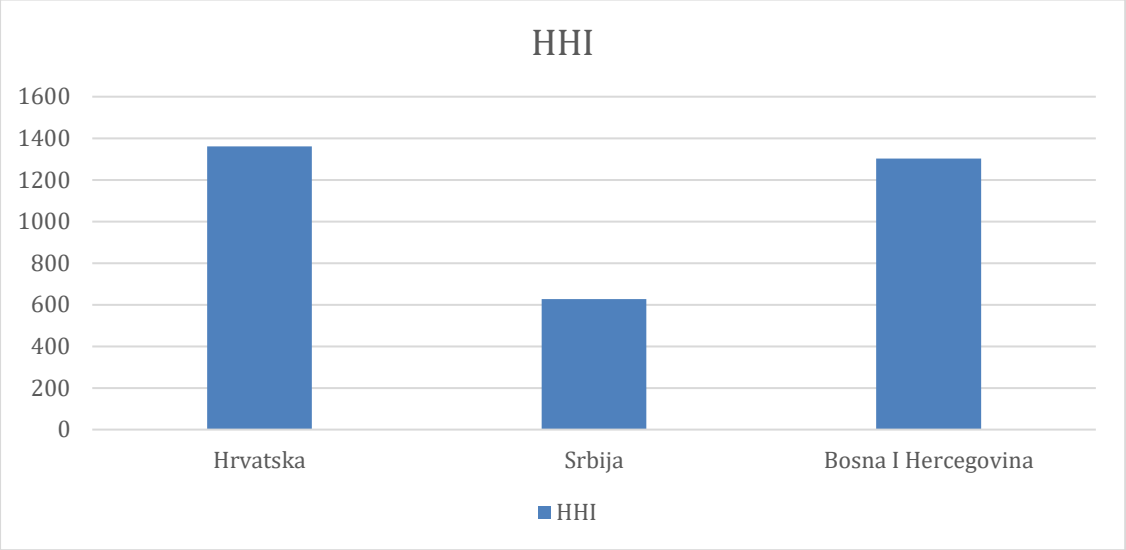

Prikaz autora prema podacima iz godišnjih financijskih izvještaja

Za analizu pregledanih podataka koristit će se model višestruke regresije u programu STATISTICA. Testirat će se četiri modela. **Zavisna je varijabla** profitabilnosti banaka, predstavljena vrijednošću povrata na imovinu (ROA). Ovaj je pokazatelj često korišten u postojećim empirijskim istraživanjima o utjecaju koncentričnosti na stabilnost i profitabilnost bankarskog sustava, stoga je odabran za ovu analizu kako bi se omogućila usporedba s ovim istraživanjem. Kao zavisna varijabla također će se testirati i povrat na kapital (ROE). Pokazatelj, odnosno zavisna varijabla pomoću koje će se testirati stabilnost banaka u odnosu na koncentričnost je Altmanov Z-score.

Nezavisne varijable, čiji se utjecaj na profitabilnost i stabilnost banaka proučava su indikatori koncentričnosti bankovnog sustava, a to su k-omjer bankovne koncentričnosti (CR) i Herfindahl-Hirschman Indeks (HHI). Model višestruke regresije testiran je pri razini pouzdanosti od 95%.

3.2. Utjecaj koncentričnosti bankovnog sustava na stabilnost i profitabilnost poslovnih banaka

Postavlja se model višestruke regresije:

$$ROA_i = \beta_0 + \beta_1 * CR2_{1,i} + \beta_2 * CR5_{2,i} + \beta_3 * HHI_{3,i} + e_i$$

Na Slika 12 nalazi se prikaz rezultata višestruke regresije u programu STATISTICA za 11 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na profitabilnost koristeći pokazatelj ROA. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom ROA za Republiku Hrvatsku glasio bi:

$$ROA_i = -0.055713 + 0{,}002781 * CR2_{1,i} + 0.002090 * CR5_{2,i} - 0{,}000153 * HHI_{3,i} + e_i$$

Iz slike je također vidljivo kako je p-vrijednost za nezavisne varijable manja od razine signifikantnosti (α = 5%), prema tome, model je statistički značajan.

Također je vidljiv prikaz rezultata višestruke regresije u programu STATISTICA za 11 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na profitabilnost koristeći pokazatelj ROE.

Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom ROE za Republiku Hrvatsku glasio bi:

$$ROE_i = -0.056527 + 0{,}002967 * CR2_{1,i} + 0.002253 * CR5_{2,i} - 0{,}000167 * HHI_{3,i} + e_i$$

Kao i regresijski model Republike Hrvatske za pokazatelj ROA, statistički je značajan.

Slika 12: Rezultati modela višestruke regresije odnosa profitabilnosti i koncentričnosti bankarskog sustava za Republiku Hrvatsku

Regression Summary for Dependent Variable: ROA (regresija (B2:L12))
R= ,95470814 R2= ,91146763 Adjusted R2= ,87352519
F(3,7)=24,022 p<,00046 Std.Error of estimate: ,00141

N=11	Beta	Std.Err. of Beta	B	Std.Err. of B	t(7)	p-level
Intercept			-0,055713	0,049361	-1,12868	0,296224
CR2	0,75379	0,298100	0,002781	0,001100	2,52865	0,039311
CR5	0,83824	0,246810	0,002090	0,000615	3,39628	0,011501
HHI	-2,02339	0,393984	-0,000153	0,000030	-5,13571	0,001345

Regression Summary for Dependent Variable: ROE (roe (B2:L12))
R= ,96380994 R2= ,92892960 Adjusted R2= ,89847086
F(3,7)=30,498 p<,00022 Std.Error of estimate: ,00138

N=11	Beta	Std.Err. of Beta	B	Std.Err. of B	t(7)	p-level
Intercept			-0,056527	0,048203	-1,17269	0,279278
CR2	0,73771	0,267089	0,002967	0,001074	2,76204	0,028014
CR5	0,82890	0,221135	0,002253	0,000601	3,74842	0,007183
HHI	-2,01615	0,352998	-0,000167	0,000029	-5,71150	0,000727

Izvor: Izrada autora u programu STATISTICA

Na **Pogreška! Nevaljana samo-referenca knjižne oznake.** nalazi se prikaz rezultata višestruke regresije u programu STATISTICA za 8 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na profitabilnost koristeći pokazatelj ROA. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom ROA za Republiku Srbiju glasio bi:

$$ROA_i = 0{,}098986 + 0{,}001709 * CR2_{1,i} + 0.000242 * CR5_{2,i} - 0{,}000167 * HHI_{3,i} + e_i$$

Iz slike je također vidljivo kako je p-vrijednost za nezavisne varijable veća od razine signifikantnosti (α = 5%), prema tome, model nije statistički značajan.

Nadalje, prikazani su rezultati višestruke regresije u programu STATISTICA za 8 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na profitabilnost koristeći pokazatelj ROE. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom ROE za Republiku Srbiju glasio bi:

$$ROE_i = 0{,}018924 + 0{,}002407 * CR2_{1,i} + 0.000771 * CR5_{2,i} - 0{,}000123 * HHI_{3,i} + e_i$$

Kao i regresijski model Republike Srbije za pokazatelj ROA, nije statistički značajan.

Slika 13: Rezultati modela višestruke regresije odnosa profitabilnosti i koncentričnosti bankarskog sustava za Republiku Srbiju

Regression Summary for Dependent Variable: ROA (regresija (B2:L12))
R= ,83695209 R2= ,70048880 Adjusted R2= ,47585539
F(3,4)=3,1184 p<,15033 Std.Error of estimate: ,00484

N=8	Beta	Std.Err. of Beta	B	Std.Err. of B	t(4)	p-level
Intercept			0,098986	0,059117	1,67439	0,169366
CR2	0,73381	0,758185	0,001709	0,001766	0,96785	0,387927
CR5	-0,32017	0,630422	-0,000242	0,000476	-0,50787	0,638270
HHI	-1,75153	1,079495	-0,000167	0,000103	-1,62254	0,180008

Regression Summary for Dependent Variable: ROE (roe (B2:L12))
R= ,82275997 R2= ,67693398 Adjusted R2= ,43463446
F(3,4)=2,7938 p<,17315 Std.Error of estimate: ,00881

N=8	Beta	Std.Err. of Beta	B	Std.Err. of B	t(4)	p-level
Intercept			0,018924	0,107466	0,176095	0,868775
CR2	0,590543	0,787434	0,002407	0,003210	0,749959	0,494982
CR5	0,583043	0,654742	0,000771	0,000865	0,890493	0,423522
HHI	-0,737420	1,121140	-0,000123	0,000188	-0,657742	0,546631

Izvor: Izrada autora u programu STATISTICA

Pogreška! Nevaljana samo-referenca knjižne oznake. prikazuje rezultate višestruke regresije u programu STATISTICA za 11 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na profitabilnost koristeći pokazatelj ROA. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom ROA za Bosnu i Hercegovinu glasio bi:

$$ROA_i = -0{,}001457 - 0{,}000402 * CR2_{1,i} + 0.000403 * CR5_{2,i} - 0{,}000003 * HHI_{3,i} + e_i$$

Iz slike je također vidljivo kako je p-vrijednost nezavisne varijable veća od razine signifikantnosti (α = 5%), prema tome, model nije statistički značajan.

Nadalje, prikazani su rezultati višestruke regresije u programu STATISTICA za 11 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na profitabilnost koristeći pokazatelj ROE. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom ROE za Bosnu i Hercegovinu glasio bi:

$$ROE_i = 0{,}0000055 - 0{,}000492 * CR2_{1,i} + 0.000435 * CR5_{2,i} - 0{,}000003 * HHI_{3,i} + e_i$$

Kao i regresijski model Republike Srbije za pokazatelj ROA, nije statistički značajan.

Slika 14: Rezultati modela višestruke regresije odnosa profitabilnosti i koncentričnosti bankarskog sustava za Bosnu i Hercegovinu

Regression Summary for Dependent Variable: ROA (regresija (B2:L12))
R= ,40802008 R2= ,16648038 Adjusted R2= -----
F(3,7)=,46604 p<,71510 Std.Error of estimate: ,00511

N=11	Beta	Std.Err. of Beta	B	Std.Err. of B	t(7)	p-level
Intercept			-0,001457	0,019004	-0,076665	0,941035
CR2	-0,573977	1,335996	-0,000402	0,000936	-0,429625	0,680383
CR5	1,054473	1,123197	0,000403	0,000429	0,938814	0,379082
HHI	-0,255840	1,729220	-0,000003	0,000023	-0,147951	0,886553

Regression Summary for Dependent Variable: ROE (roe (B2:L12))
R= ,39977649 R2= ,15982124 Adjusted R2= -----
F(3,7)=,44385 p<,72914 Std.Error of estimate: ,00567

N=11	Beta	Std.Err. of Beta	B	Std.Err. of B	t(7)	p-level
Intercept			0,000055	0,021083	0,002604	0,997995
CR2	-0,634783	1,341322	-0,000492	0,001039	-0,473251	0,650436
CR5	1,030806	1,127674	0,000435	0,000476	0,914099	0,391063
HHI	-0,193878	1,736114	-0,000003	0,000025	-0,111674	0,914217

Izvor: Izrada autora u programu STATISTICA

Slika 15 prikaz je modela višestruke regresije u programu STATISTICA za 11 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na stabilnost koristeći Z-Score kao zavisnu varijablu. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom broja zaposlenih za Republiku Hrvatsku glasio bi:

$$Z_i = -4{,}301 + 0{,}041 * CR2_{1,i} - -0{,}006 * CR5_{2,i} - 0{,}0009 * HHI_{3,i} + e_i$$

Iz slike je također vidljivo kako je p-vrijednost nezavisne varijable manja od razine signifikantnosti (α = 5%), prema tome, model je statistički značajan.

Slika 15: Rezultati modela višestruke regresije odnosa stabilnosti i koncentričnosti bankarskog sustava za Republiku Hrvatsku

Regression Summary for Dependent Variable: Z-Score (Z Score (B2:L12))
R= ,82549193 R2= ,68143693 Adjusted R2= ,54490990
F(3,7)=4,9912 p<,03682 Std.Error of estimate: ,11398

N=11	Beta	Std.Err. of Beta	B	Std.Err. of B	t(7)	p-level
Intercept			4,301083	0,423825	10,14825	0,000019
CR2	1,63202	0,825933	0,041265	0,020883	1,97597	0,088708
CR5	-0,45592	0,694377	-0,006286	0,009573	-0,65659	0,532427
HHI	-1,83653	1,069030	-0,000875	0,000509	-1,71794	0,129505

Izvor: Izrada autora u programu STATISTICA

Slika 16: Rezultati modela višestruke regresije odnosa stabilnosti i koncentričnosti bankarskog sustava za Republiku Srbiju

Regression Summary for Dependent Variable: Z-score (Z Score (B2:L12))
R= ,90545996 R2= ,81985774 Adjusted R2= ,68475104
F(3,4)=6,0682 p<,05706 Std.Error of estimate: ,30656

N=8	Beta	Std.Err. of Beta	B	Std.Err. of B	t(4)	p-level
Intercept			9,350163	3,741217	2,49923	0,066822
CR2	0,56419	0,587999	0,107210	0,111734	0,95951	0,391639
CR5	0,17479	0,488914	0,010771	0,030127	0,35750	0,738782
HHI	-1,23199	0,837186	-0,009612	0,006532	-1,47159	0,215102

Izvor: Izrada autora u programu STATISTICA

Slika 16 prikaz je modela višestruke regresije u programu STATISTICA za 8 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na stabilnost koristeći Z-Score kao zavisnu varijablu. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom broja zaposlenih za Republiku Srbiju glasio bi:

$$Z_i = 9{,}35 + 0{,}107 * CR2_{1,i} + 0{,}011 * CR5_{2,i} - 0{,}0096 * HHI_{3,i} + e_i$$

Iz slike je također vidljivo kako je p-vrijednost nezavisne varijable veća od razine signifikantnosti (α = 5%), prema tome, model nije statistički značajan.

Pogreška! Nevaljana samo-referenca knjižne oznake. prikaz je modela višestruke regresije u programu STATISTICA za 11 opservacija utjecaja indikatora koncentričnosti promatranog bankovnog sustava na stabilnost koristeći broj zaposlenih (N) kao zavisnu varijablu. Prema ovim rezultatima, model višestruke regresije sa zavisnom varijablom broja zaposlenih za Bosnu i Hercegovinu glasio bi:

$$Z_i = 4{,}386 + 0{,}009 * CR2_{1,i} + 0{,}001 * CR5_{2,i} - 0{,}0002 * HHI_{3,i} + e_i$$

Iz slike je također vidljivo kako je p-vrijednost nezavisne varijable veća od razine signifikantnosti (α = 5%), prema tome, model nije statistički značajan.

Slika 17: Rezultati modela višestruke regresije odnosa stabilnosti i koncentričnosti bankarskog sustava za Bosnu i Hercegovinu

Regression Summary for Dependent Variable: Z-score (Z Score (B2:L12))
R= ,28913983 R2= ,08360184 Adjusted R2= -----
F(3,7)=,21287 p<,88442 Std.Error of estimate: ,12829

N=11	Beta	Std.Err. of Beta	B	Std.Err. of B	t(7)	p-level
Intercept			4,385672	0,477019	9,193911	0,000037
CR2	0,540950	1,400842	0,009076	0,023504	0,386160	0,710847
CR5	0,139271	1,177714	0,001274	0,010775	0,118255	0,909187
HHI	-0,905138	1,813153	-0,000286	0,000573	-0,499207	0,632938

Izvor: Izrada autora u programu STATISTICA

3.3. Analiza rezultata istraživanja

Što se tiče profitabilnosti, jedini statistički signifikantan model višestruke regresije testiran je na podacima za Republiku Hrvatsku. Model predviđa pad profitabilnosti u odsutnosti bankovne koncentričnosti u obliku povrata na imovinu i povrata na kapital. Sukladno tome, k-omjer bankovne koncentričnosti također demonstrira tendenciju pozitivne veze između profitabilnosti i koncentričnosti, dok je kod HHI ta veza pak negativna. Primjerice:

a) U odsustvu bankovne koncentričnosti, očekuje se da će povrat na imovinu iznositi (0,055713), dakle, za svaku uloženu novčanu jedinicu (HRK) imovine, banke u Republici Hrvatskoj bi ostvarivale gubitak od 0,05 novčanih jedinica (HRK), a za svaku uloženu novčanu jedinicu (HRK) kapitala, banke u Republici Hrvatskoj bi ostvarivale gubitak od 0,05 novčanih jedinica (HRK)
b) Porastom indikatora CR5 za jednu jedinicu, očekuje se da će povrat na imovinu iznositi 0,002090, odnosno, za svaku uloženu novčanu jedinicu (HRK) imovine, banke u Republici Hrvatskoj bi ostvarivale dobitak od 0,002 novčanih jedinica (HRK)

c) Porastom indikatora HHI za jednu jedinicu, očekuje se da će povrat na kapital iznositi (0,000167), odnosno, za svaku uloženu novčanu jedinicu (HRK) kapitala, banke u Republici Hrvatskoj bi ostvarivale gubitak od 0,0001 novčanih jedinica (HRK)

Modeli višestruke regresije za zavisnu varijablu ROA nisu statistički značajni u slučaju Republike Srbije, te Bosne i Hercegovine. Za razliku od Hrvatske, ovi model za Republiku Srbiju predviđa rast profitabilnosti u odsutnosti bankovne koncentričnosti, te sukladno tome, rastom k-omjera bankovne koncentričnosti CR5 te HHI došlo bi do pada profita, dok CR2 pokazuje suprotnu tendenciju.

a) U odsustvu bankovne koncentričnosti, očekuje se da će povrat na imovinu iznositi 0,098986, dakle, za svaku uloženu novčanu jedinicu (HRK) imovine, banke u Republici Srbiji bi ostvarivale dobitak od 0,098 novčanih jedinica (HRK), a za svaku uloženu novčanu jedinicu (HRK) kapitala, banke u Republici Srbiji bi ostvarivale dobitak od 0,019 novčanih jedinica (HRK)
b) Porastom indikatora CR2 za jednu jedinicu, očekuje se da će povrat na imovinu iznositi 0,001709, odnosno, za svaku uloženu novčanu jedinicu (HRK) imovine, banke u Republici Srbiji bi ostvarivale dobitak od 0,001 novčanih jedinica (HRK)
c) Porastom indikatora CR5 za jednu jedinicu, očekuje se da će povrat na kapital iznositi 0,000771, odnosno, za svaku uloženu novčanu jedinicu (HRK) kapitala, banke u Republici Srbiji bi ostvarivale dobitak od 0,0007 novčanih jedinica (HRK)
d) Porastom indikatora HHI za jednu jedinicu, očekuje se da će povrat na imovinu iznositi (0,000167), odnosno, za svaku uloženu novčanu jedinicu (HRK) imovine, banke u Republici Srbiji bi ostvarivale gubitak od 0,0001 novčanih jedinica (HRK)

U Bosni i Hercegovini predviđa se pad profita sa stane kapitala u odsutnosti bankovne koncentričnosti, a rast sa strane imovine. Indikator CR5 sugerira pozitivnu, a indikatori CR2 i HHI negativnu vezu između profitabilnosti i koncentričnosti

a) U odsustvu bankovne koncentričnosti, očekuje se da će povrat na imovinu iznositi (0,001457), dakle, za svaku uloženu novčanu jedinicu (HRK) imovine, banke u Bosni i Hercegovini bi ostvarivale gubitak od 0,001 novčanih jedinica (HRK), a za svaku uloženu novčanu jedinicu (HRK) kapitala, banke u Bosni i Hercegovini bi ostvarivale dobitak od 0,00005 novčanih jedinica (HRK)
b) Porastom indikatora CR2 za jednu jedinicu, očekuje se da će povrat na kapital iznositi (0,000492), odnosno, za svaku uloženu novčanu jedinicu (HRK) kapitala, banke u Bosni i Hercegovini bi ostvarivale gubitak od 0,0004 novčanih jedinica (HRK)

c) Porastom indikatora CR5 za jednu jedinicu, očekuje se da će povrat na imovinu iznositi 0,000403, odnosno, za svaku uloženu novčanu jedinicu (HRK) imovine, banke u Bosni i Hercegovini bi ostvarivale dobitak od 0,0004 novčanih jedinica (HRK)
d) Porastom indikatora HHI za jednu jedinicu, očekuje se da će povrat na kapital iznositi (0,000003) , odnosno, za svaku uloženu novčanu jedinicu (HRK) kapitala, banke u Bosni i Hercegovini bi ostvarivale gubitak od 0,000003 novčanih jedinica (HRK)

S druge strane, pri testiranju modela višestruke regresije sa Z-Scoreom kao zavisnom varijablom stabilnosti, ponavljaju se slični rezultati. Jedino je model za Republiku Hrvatsku bio statistički značajan. Rezultati se mogu protumačiti na sljedeći način:

a) U odsustvu bankovne koncentričnosti, očekuje se da će Z-Score iznositi 4.301
b) Indikator CR2 jedini pokazuje pozitivnu korelaciju sa Z-Score vrijednošću, pomakom vrijednosti indikatora CR5 i HHI Z-Score doživljava opadanje.

U slučaju Republike Srbije i Bosne i Hercegovini, regresijski modeli nisu statistički značajni. Rezultati se mogu protumačiti na sljedeći način:

a) U odsustvu bankovne koncentričnosti, očekuje se da će Z-Score iznositi 9,35 u Republici Srbiji i 4,386 u Bosni i Hercegovini
b) Očigledna je pozitivna relacija k-omjera bankovne koncentričnosti i stabilnosti aproksimirane Z-Score vrijednošću, dok je korelacija HHI i Z-Scora pak negativna, kako u slučaju Republike Srbije, tako i u slučaju Bosne i Hercegovine

Sumirajući rezultate statistički relevantnih modela, konkretno modela višestruke regresije za Republiku Hrvatsku, izvodi se pozitivna korelacija između indikatora profitabilnosti i bankovne koncentričnosti, a negativna korelacija između indikatora stabilnosti i bankovne koncentričnosti. Dakle, povećanje indikatora bankovne koncentričnosti i smanjenje konkurencije rezultira povećanjem profita unutar bankarskog sustava Republike Hrvatske, no također destabilizira spomenuti sustav. Ovakav zaključak sukladan je zaključcima Heggestada (1997) koji deducira kako tržišna struktura dugoročno utječe na profitabilnost banaka. Jeon et al. (2002) također dolazi do sličnih zaključaka - pregled bankovnih sustava na području saveznih država SAD-a daje potporu pozitivnoj korelaciji koncentričnosti i stabilnosti, te sugerira kako bankovna koncentričnost vodi bankovnoj profitabilnosti. Kao indikator profitabilnosti korišten je povrat na kapital. Analiza Bhatti et al. (2010) također koristi povrat na imovinu i povrat na kapital u regresijskoj analizi, te pronalazi pozitivnu vezu između

koncentričnosti i profitabilnosti, a Pervan et al. (2015), čije je istraživanje posebno zanimljivo, obzirom da se odnosi na područje Republike Hrvatske procjenjuje kako koncentričnost bankovnog sustava ima signifikantan pozitivan učinak na bankovnu profitabilnost.
Povećanje indikatora bankovne koncentričnosti demonstrira destabilizacijski učinak na bankovni sustav Republike Hrvatske. Rezultati su sukladni analizi Uhde et al (2008) koji pomoću Z-Score tehnike pronalazi empirijske dokaze da koncentričnost nacionalnog bankovnog tržišta ima negativan učinak na financijsku stabilnost europskih banaka, te također ističe pozitivan učinak povećanja bankovne koncentričnosti na indiktor povrata na imovinu (ROA). De Nicolo et al. (2004) tvrdi kako visoko koncentrični bankovni sustavi iskazuju veći potencijal sustavnog rizika od niže koncentričnih sustava, a Shijaku (2016) ističe kako povećana koncentričnost ima velik utjecaj na fragilnost banaka.

S druge strane, rezultati modela višestruke regresije na primjerima Republike Srbije i Bosne i Hercegovine nisu statistički relevantni, a demonstriraju dijametralno suprotne zaključke. U slučaju Republike Srbije kretanje oba indikatora profitabilnosti obrnuto je proporcionalno kretanju koncentričnosti respektivnih bankarskih sustava, te ukazuju na negativnu vezu između profitabilnosti i koncentričnosti, sukladno analizama Rinkevičiute et al. (2014), Smirlock (1985), Whalen (1987), te Gencheva (2012). U slučaju Bosne i Hercegovine rezultati su nedosljedni, obzirom da indikator ROA sugerira pozitivnu, a indikator ROE negativnu vezu između profitabilnosti i koncentričnosti, što je pak sukladno istraživanju Al Arif et al. (2018). Stabilnost i koncentričnost uglavnom sugeriraju pozitivnu međusobnu vezu, s time da je indikator CR pozitivno povezan sa Z-Scoreom, a HHI negativno. Rezultati su nedosljedni, a do sličnog zaključka dolaze Cetorelli et al. (2007) za bankovno tržište SAD-a.

4. ZAKLJUČAK

Iako je u samoj svojoj biti ostala ista, definicija banke i bankarstva se tokom godina nadograđivala. U odnosu na originalnu namjenu pružanja financijskih usluga i plasmana novčanih sredstava, obuhvat poslovanja se višestruko povećao. Operativni opseg u modernom dobu, osim prvotnih funkcija, uključuje financijski najam, izdavanje garancija, trgovanje u svoje ime za i za svoj račun, u svoje ime i za račun klijenta, razna posredovanja i zastupanja, te još mnoge druge akcije. Iz tog razloga, dinamičnost lokalnih, nacionalnih i međunarodnih bankarskih tržišta nije iznenađujuća činjenica, već je rezultat logičnog slijeda događaja.

Jedan od primjera koji ilustrira spomenutu dinamičnost su bankarska tržišta analizirana u ovom radu. U prethodnih dvadeset i pet godina hrvatski, srpski i bosanskohercegovački bankarski sustav prošli su kroz mnoge promjene, zahvaljujući deregulaciji i liberalizaciji tržišta, ali i pod utjecajem financijske globalizacije. Primjerice, na spomenutim tržištima proces pretvorbe i privatizacije počeo je još u doba SFRJ, kada je osamdesetih godina prošlog stoljeća izglasan Zakon o privatizaciji banaka. Raspadom bivše države, u Republici Hrvatskoj dio društvene imovine postaje državnom, a ostatak je postepeno privatiziran, uz nadzor Hrvatskog fonda za razvoj, a potom Agencije za upravljanje državnom imovinom i Hrvatskog fonda za privatizaciju.

Vrijedi napomenuti također i utjecaj globalne krize. Posljedice su itekako očigledne kratkim pregledom strukturalnog kretanja unutar promatranih nacionalnih bankarskih sustava, kako u financijskim pokazateljima, tako i u broju tržišnih igrača. Primjerice, u Republici Hrvatskoj je na bankarskom tržištu još od 2010. prisutan trend smanjivanja broja kreditnih institucija, koji se, prema Biltenu o bankama, u 2018. ubrzao. Rezultat istoga je povećanje bankovne koncentričnosti i smanjenje konkurencije, pa se postavlja pitanje, na koji način takva situacija utječe na stabilnost i profitabilnost analiziranog bankarskog sustava.

U ovom je radu proveden empirijski test utjecaja koncentričnosti bankarskih sustava na stabilnost, pomoću testiranja Z-Scorea u odnosu na indikatore CR2 i CR5 k-omjera bankovne koncentričnosti, te HHI, i profitabilnost poslovnih banaka, testom indikatora ROA i ROE u odnosu na CR2 i CR5 i HHI, na odabranom uzorku od 24 banke (po 8 iz svake države) u periodu od 2005. do 2015. godine.

Rezultati statistički signifikantnih regresijskih modela ukazuju na prihvaćanje hipoteze H2 – koncentričnost bankarskog sustava pozitivno utječe na profitabilnost bankarskog sustava, kao što je vidljivo iz oba regresijska modela provedena na pokazateljima profitabilnosti za Republiku Hrvatsku (Slika 12). S druge strane, statistički signifikantni regresijski modeli sa

zavisnom varijablom Z-Score koja aproksimira stabilnost dokazuju negativnu korelaciju između koncentričnosti bankarskog sustava i stabilnosti istog.

Modeli višestruke regresije za Republiku Srbiju i Bosnu i Hercegovinu nisu statistički signifikantni, a njihovi rezultati su dijametralno suprotni rezultatima za Republiku Hrvatsku. U ovom bi se slučaju, da je model statistički signifikantan, prihvatila hipoteza H1 – koncentričnost bankarskog sustava pozitivno utječe na stabilnost bankarskog sustava.

Potrebno je dakako istaknuti i moguća ograničenja istraživanja. Za početak, razlika u valutama u izvještajima zahtijevala je odabir fiksiranog tečaja na određeni datum za konverziju, radi moguće usporedbe rezultata. Daljnji problem je reprezentativnost uzorka, koji je odabran na prema kriteriju najvećeg tržišnog udjela banaka u respektivnim bankovnim sustavima svake od promatranih zemalja u 2010. godini (na polovici promatranog razdoblja) – po osam predstavnika svake zemlje s najvećim tržišnim udjelom u izabranoj godini. Vrijedi napomenuti i nedostupnost određenih podataka.

Buduća istraživanja trebala bi pružiti dodatne empirijske dokaze valjanosti predloženih modela, i provesti analizu na potencijalno većem uzorku. Također, poželjno je i potiče se uključivanje dodatnih varijabli u analizu, kako bi se dobili što precizniji rezultati.

LITERATURA

1. Al Arif, M., Awwaliyah, T. (2018): Market Share, Concentration Ratio and Profitability: Evidenc from Indonesian Islamic Banking Industry, Journal of Central Banking Theory and Practice, 2019, Vol. 2. pp. 189-201
2. Bahhati, G. A.,(2010.) Evidence on Structure Conduct Performance Hypothesis in Pakistani Commercial Banks, International Journal of Business and Management Vol. 5, No. 9
3. Bankarski sektor u Srbiji – tromjesečni izvještaji i statistički aneks, dostupno na: https://www.nbs.rs/internet/latinica/55/55_4/index.html
4. Bikker, J., Haaf, K. (2002): Competition, concentration and their relationship: An empirical analysis of the banking industry, Journal of Banking and Finance
5. Bilten o bankama br. 11, HNB (2005), dostupno na: www.hnb.hr
6. Bilten o bankama br. 13, HNB (2006), dostupno na: www.hnb.hr
7. Bilten o bankama br. 15, HNB (2007), dostupno na: www.hnb.hr
8. Bilten o bankama br. 17, HNB (2008), dostupno na: www.hnb.hr
9. Bilten o bankama br. 19, HNB (2009), dostupno na: www.hnb.hr
10. Bilten o bankama br. 21, HNB (2010), dostupno na: www.hnb.hr
11. Bilten o bankama br. 23, HNB (2011), dostupno na: www.hnb.hr
12. Bilten o bankama br. 25, HNB (2012), dostupno na: www.hnb.hr
13. Bilten o bankama br. 26, HNB (2013), dostupno na: www.hnb.hr
14. Bilten o bankama br. 27, HNB (2014), dostupno na: www.hnb.hr
15. Bilten o bankama br. 28, HNB (2015), dostupno na: www.hnb.hr
16. Bilten o bankama br. 29, HNB (2016), dostupno na: www.hnb.hr
17. Bilten o bankama br. 30, HNB (2017), dostupno na: www.hnb.hr
18. Bilten o bankama br. 31, HNB (2018), dostupno na: www.hnb.hr
19. Cetorelli, N., Hirtle, B., Morgan, D., Peristiani, S., Santos, J. (2007): Trends in Financial Market Concentration and their Implications for Market Stability, Economic Policy Review, Vol. 13, No. 1
20. Chortareas, G. E., Garza-Garcia, J. G. & Girardone, C.(2009): Banking Sector Performance in Latin America: Market Power versus Efficiency

21. Černohorský, J. & Prokop, V.(2015.): The Relationship of Concentration and Profitability in Banking Markets, University of Pardubice, Czech Republic
22. Ćurić, M. (2018): Analiza profitabilnosti banaka u Republici Hrvatskoj i njenih odrednica, diplomski rad
23. De Haan, J., Pogoshyan, T. (2011): Bank Size, Market Concentration, and Bank Earnings Volatility in the US
24. De Nicolo, G., Bartholomew, P., Zaman, J., Zephirin, M. (2003): Bank Consolidation, Internationalization and Conglomeration: Trends and Implications for Financial Risk
25. Deluvaité, V. (2010): The concentration-stability relationship in the banking system: an empirical research, Economics And Management
26. Demirgüç-Kunt, A., Detragiache, E. (1999): Does Deposit Insurance Increase Banking System Stability?
27. Doll, M. (2010.): Bank concentration, competition and financial stability, Tilburg University
28. Genchev, E. (2012.), Effects of market share on bank's profitability, Socio- Economic Research, Vol. 3, No. 1
29. Hannan, T. (1991): Foundations of the Structure-Conduct-Performance Paradigm in Banking, Journal of Money, Credit and Banking, Vol. 23, No. 1, pp. 68-84
30. Heggestad, A. A.,(1977.):Market structure, risk and profitability in commercial banking, journal article
31. Jeon, Y., Miller, S. (2002): Bank Concentration and Performance
32. Konsolidovani bilans poslovnih banaka BiH, Statistički web portal Centralne Banke Bosne i Hercegovine, dostupno na: https://www.cbbh.ba/content/read/915
33. Kraft, E., Hofler, R., & Payne, J. (2004). Privatizacija, ulazak stranih banaka i efikasnost banaka u Hrvatskoj: Analiza stohastičke granice fleksibilnosti Fourierove funkcije troška, Istraživanja HNB-a, dostupno na: www.hnb.hr
34. Kundid, A., Škrabić, B., Ercegovac, R. (2011): Determinants of Bank Profitability in Croatia, Croatian Operational Research Review, Vol. 2
35. Liang, N. (1989): Bank profits, risk and local market concentration, Journal of Economics and Business, Vol 41, Iss. 4, pp. 297-305
36. Mensi, S., Zouari, A. (2010): Efficient Structure versus Market Power: Theories and Empirical Evidence, International Journal of Economics and Finance, Vol. 2, No. 4

37. Neuberger, D. (1997): Structure, Conduct and Performance in Banking Markets, Universität Rostock
38. Pervan, M., Ćurak, M., & Poposki, K. (2015.): Industrial Concentration and Bank Performance in an Emerging Market: Evidence from Croatia
39. Petrović, S., Ružić, T. (2001): Koncentracija banaka, Hrvatska pravna revija, br. 9/2001
40. Rinkevičiute, V. Martinkute-Kauliene, R. (2014): Impact of Market Concentration on the Profitability of Lithuanian Banking Sector
41. Schaek, K., Cihak, M., Wolfe, S. (2006): Competition, Concentration and Bank Soundness: New evidence from the Micro-Level
42. Shijaku, G.(2016.): Does concentration matter for bank stability - evidence from Albanian Banking System
43. Simatele, M., Mishi, S., Nomasomy, N. (2018): Structure and profitability in the banking sector, Bankks and Bank Systems Journal
44. Smirlock, M. (1985): Evidence on the (Non) Relationship between Concentration and Profitability in Banking, Journal of Money, Credit and Banking, Vol. 17, No.1, pp. 69-83
45. Uhde, A., Heimeshoff, U. (2008): Consolidation in Banking and Financial Stability in Europe
46. Whalen, G. (1987): Concentration and Profitability in Non-MSA Banking Markets
47. Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, Sveučilište u Rijeci, Rijeka

POPIS SLIKA I TABLICA

Slika 1: Vlasnička struktura banaka u Republici Hrvatskoj 1997-2017 3
Slika 2: Udio imovine, kredita i depozita najvećih banaka u ukupnoj imovini kreditima i depozitima svih banaka, na dan 31. prosinca 2017. 5
Slika 3: Broj banaka i Herfindahl-Hirschmanov indeks (HHI) za imovinu banaka kroz godine 5
Slika 4: SCP paradigma – elementi 15
Slika 5: SCP paradigma prilagođena bankarskom sustavu 15
Slika 6: Indeksi koncentričnosti za 23 promatrane zemlje, bazirano na ukupnoj imovini (1997) 18
Slika 7: Kretanje pokazatelja ROA i ROE kroz godine u RH 30
Slika 8: Kretanje pokazatelja ROA i ROE kroz godine u RS 31
Slika 9: Kretanje pokazatelja ROA i ROE kroz godine u BIH 32
Slika 10: Kretanje prosječnog Z-Score-a u bankovnom sektoru u promatranom razdoblju 33
Slika 11: Usporedba RH, RS i BIH prema srednjoj vrijednosti HHI za promatrani period 34
Slika 12: Rezultati modela višestruke regresije odnosa profitabilnosti i koncentričnosti bankarskog sustava za Republiku Hrvatsku 35
Slika 13: Rezultati modela višestruke regresije odnosa profitabilnosti i koncentričnosti bankarskog sustava za Republiku Srbiju 36
Slika 14: Rezultati modela višestruke regresije odnosa profitabilnosti i koncentričnosti bankarskog sustava za Bosnu i Hercegovinu 37
Slika 15: Rezultati modela višestruke regresije odnosa stabilnosti i koncentričnosti bankarskog sustava za Republiku Hrvatsku 38
Slika 16: Rezultati modela višestruke regresije odnosa stabilnosti i koncentričnosti bankarskog sustava za Republiku Srbiju 38
Slika 17: Rezultati modela višestruke regresije odnosa stabilnosti i koncentričnosti bankarskog sustava za Bosnu i Hercegovinu 39

Tablica 1: Vlasnička struktura banaka kroz godine 4
Tablica 2: Klasifikacija i interpretacija Z-score rezultata 14
Tablica 3: Pregled odabranih istraživanja o suodnosu koncentričnosti i stabilnosti bankovnog sustava 22
Tablica 4: Pregled odabranih istraživanja o suodnosu koncentričnosti i profitabilnosti bankovnog sustava 27
Tablica 5: Pregled kretanja broja banaka i ukupne aktive kroz godine 30
Tablica 6: Pokazatelji koncentričnosti po državama i godinama 33

PRILOZI

Prilog 1: Poslovanje odabranih banaka u RH 2005-2015 godine (u mil. kn)

Banka	Ukupna imovina	Zadržana dobit	Dobit poslovne godine	Tržišna vrijednost kapitala	Knjigovodstvena vrijednost obveza	Prihod od kamata	ROA	ROE	Z-Score
2005.									
Zagrebačka	63,364	4,358	903	6,022	57,342	3,003	0.014251	0.015748	4.31
PBZ	48,533	2,037	750	4,433	44,120	2,416	0.015453	0.016999	4.20
Erste	30,322	451	348	1,775	28,545	1,420	0.011477	0.012191	3.84
Raiffeisen	28,244	701	295	2,210	26,034	1,341	0.010445	0.011331	4.01
HPB	7,282	116	90	749	6,533	351	0.012359	0.013776	4.19
OTP	8,618	114	127	844	7,774	445	0.014737	0.016337	4.16
Volksbank	3,909	28	24	282	3,627	217	0.00614	0.006617	3.88
Podravska	1,802	16	16	173	1,802	106	0.008879	0.008879	3.45
2006.									
Zagrebačka	70,163	5,217	859	6,861	63,302	3,254	0.012243	0.01357	4.34
PBZ	55,906	2,817	847	7,114	48,792	2,720	0.01515	0.017359	4.51
Erste	35,514	744	403	2,825	32,689	1,752	0.011348	0.012328	4.02
Raiffeisen	33,731	718	436	3,384	30,347	1,610	0.012926	0.014367	4.19
HPB	11,277	153	101	840	10,437	513	0.008956	0.009677	3.94
OTP	10,383	133	101	848	9,535	514	0.009727	0.010593	4.00
Volksbank	5,949	0	24	726	5,223	259	0.004034	0.004595	4.23
Podravska	2,541	19	19	228	2,541	131	0.007477	0.007477	3.43

2007.									
Zagrebačka	79,894	6,129	1,109	11,529	68,365	3,975	0.013881	0.016222	4.73
PBZ	60,731	3,495	932	7,847	52,884	3,274	0.015346	0.017623	4.55
Erste	40,378	940	599	3,928	36,450	2,304	0.014835	0.016433	4.19
Raiffeisen	38,696	957	388	3,622	35,074	2,015	0.010027	0.011062	4.13
HPB	14,536	151	121	964	13,572	726	0.008324	0.008915	3.86
OTP	11,903	117	105	1,123	10,780	624	0.008821	0.00974	4.08
Volksbank	7,247	37	58	1,656	5,591	383	0.008003	0.010374	5.14
Podravska	2,804	19	19	247	2,557	174	0.006776	0.007431	4.01
2008.									
Zagrebačka	89,386	7,523	1,394	12,956	76,430	4,935	0.015595	0.018239	4.77
PBZ	63,740	4,369	1,100	8,870	54,870	3,796	0.017258	0.020047	4.68
Erste	45,567	1,424	788	5,105	40,462	2,693	0.017293	0.019475	4.35
Raiffeisen	40,370	1,162	500	5,407	34,963	2,502	0.012385	0.014301	4.48
HPB	14,637	159	9	924	13,713	907	0.000615	0.000656	3.78
OTP	12,795	266	149	1,497	11,299	727	0.011645	0.013187	4.31
Volksbank	7,648	86	75	1,705	5,943	461	0.009806	0.01262	5.13
Podravska	2,784	0	20	350	2,433	180	0.007184	0.00822	4.29

2009.									
Zagrebačka	92,812	8,739	1,216	14,130	78,682	5,518	0.013102	0.015455	4.84
PBZ	64,519	5,474	927	9,802	54,717	3,718	0.014368	0.016942	4.82
Erste	48,941	1,835	607	5,547	43,394	3,552	0.012403	0.013988	4.34
Raiffeisen	39,499	1,188	408	5,444	34,055	2,603	0.010329	0.011981	4.50
HPB	13,981	-289	-449	647	13,334	942	-0.03212	-0.03367	3.33
OTP	12,545	333	87	1,597	10,948	742	0.006935	0.007947	4.38
Volksbank	7,640	130	44	1,749	5,891	474	0.005759	0.007469	5.17
Podravska	2,756	0	12	364	2,393	178	0.004354	0.005015	4.31
2010.									
Zagrebačka	96,156	8,809	1,281	14,244	81,912	5,141	0.013322	0.015639	4.80
PBZ	67,352	6,085	860	10,346	57,006	3,426	0.012769	0.015086	4.84
Erste	50,509	2,292	610	6,017	44,492	2,921	0.012077	0.01371	4.41
Raiffeisen	40,422	1,482	376	5,671	34,751	2,259	0.009302	0.01082	4.53
HPB	14,787	-12	51	1,190	13,597	821	0.003449	0.003751	3.90
OTP	12,758	208	86	1,484	11,274	730	0.006741	0.007628	4.26
Volksbank	7,720	46	34	1,666	6,055	419	0.004404	0.005615	5.01
Podravska	2,797	0	13	374	2,423	167	0.004648	0.005365	4.33

2011.									
Zagrebačka	104,005	5,001	1,316	15,508	88,497	5,427	0.012653	0.014871	4.66
PBZ	67,481	7,504	1,136	11,194	56,287	3,599	0.016834	0.020182	5.03
Erste	57,035	2,905	651	6,413	50,622	3,265	0.011414	0.01286	4.37
Raiffeisen	38,460	1,808	327	5,632	32,828	2,262	0.008502	0.009961	4.61
HPB	16,452	76	88	1,255	15,196	865	0.005349	0.005791	3.90
OTP	12,772	208	7	1,390	11,382	725	0.000548	0.000615	4.16
Volksbank	7,495	22	0.9	1,569	5,926	384	0.00012	0.000152	4.92
Podravska	2,912	0	12	368	2,544	180	0.004121	0.004717	4.27
2012.									
Zagrebačka	104,135	5,350	888	15,765	88,370	5,684	0.008527	0.010049	4.67
PBZ	68,411	8,025	846	11,726	56,685	3,550	0.012366	0.014925	5.07
Erste	58,519	3,212	483	6,963	51,556	3,470	0.008254	0.009368	4.42
Raiffeisen	35,696	1,621	364	5.429	30,267	2,020	0.010197	0.012026	4.47
HPB	17,045	166	94	1,411	15,634	883	0.005515	0.006013	3.97
OTP	13,304	331	139	1,529	11,775	725	0.010448	0.011805	4.30
Volksbank	8,211		-140	1,441	6,770	379	-0.01705	-0.02068	4.52
Podravska	3,048	0	9	390	2,659	173	0.002953	0.003385	4.27

2013.									
Zagrebačka	106,505	5,200	465	15,675	90,830	5,686	0.004366	0.005119	4.60
PBZ	65,617	7,796	615	11,499	54,118	3,313	0.009373	0.011364	5.08
Erste	60,125	3,133	68	6,887	53,238	3,016	0.001131	0.001277	4.32
Raiffeisen	33,005	1,534	276	5,343	27,662	1,715	0.008362	0.009978	4.73
HPB	18,357	204	42	1,453	16,904	837	0.002288	0.002485	3.92
OTP	13,691	396	74	1,603	12,088	696	0.005405	0.006122	4.30
Volksbank	9,263	-164	-45	1,392	7,871	403	-0.00486	-0.00572	4.34
Podravska	3,099	0	2	392	2,707	158	0.000645	0.000739	4.25
2014.									
Zagrebačka	102,431	5,902	1,166	16,399	86,032	5,777	0.011383	0.013553	4.77
PBZ	68,881	7,955	643	11,660	57,221	3,118	0.009335	0.011237	5.02
Erste	60,180	3,289	232	7,190	52,990	2,757	0.003855	0.004378	4.39
Raiffeisen	31,419	1,023	294	4,827	26,592	1,517	0.009357	0.011056	4.63
HPB	17,351	-434	-635	845	16,506	862	-0.0366	-0.03847	3.31
OTP	15,826	530	169	1,751	14,075	650	0.010679	0.012007	4.30
Volksbank	10,265	-134	30	1,424	8,841	438	0.002923	0.003393	4.32
Podravska	3,045	0	-14	383	2,662	153	-0.0046	-0.00526	4.21

2015.									
Zagrebačka	105,992	4,230	519	14,796	91,196	5,718	0.004897	0.005691	4.51
PBZ	69,214	7,635	193	11,424	57,790	3,010	0.002788	0.00334	4.93
Erste	58,995	3,031	1,012	6,136	52,859	2,612	0.017154	0.019145	4.35
Raiffeisen	31,181	147	241	4,014	27,167	1,271	0.007729	0.008871	4.33
HPB	17,691	0	123	1,779	15,912	782	0.006953	0.00773	4.08
OTP	15,839	451	-54	1,698	14,141	723	-0.00341	-0.00382	4.16
Volksbank	9,735	-332	-198	1,226	8,509	442	-0.02034	-0.02327	3.99
Podravska	3,182	-18	-3	393	2,788	147	-0.00094	-0.00108	4.20

Prikaz autora prema podacima iz godišnjih financijskih izvještaja

Prilog 2: Poslovanje odabranih banaka u Republici Srbiji 2005-2015 (u mil. kn)

Banka	Ukupna imovina	Zadržana dobit	Dobit poslovne godine	Tržišna vrijednost kapitala	Knjigovodstvena vrijednost obveza	Prihod od kamata	ROA	ROE	Z-Score
2005.									
Intesa	5,116.82	115.07	105.91	679.51	4,437.38	291.07	0.020698	0.023868	4.50
Komercijalna	4,776.85	27.04	45.23	562.57	4,214.28	337.73	0.009469	0.010733	4.25
Unikredit	np	np	np	np	np	np	np	np	np
Societe	2,106.67	-33.52	-34.76	179.05	1,927.62	141.30	-0.0165	-0.01803	3.75
Raiffeisen	7,523.16	107.65	97.31	642.06	6,881.04	336.23	0.012935	0.014142	4.05
AIK	1,379.63	151.20	150.27	740.56	639.07	146.65	0.108918	0.235134	9.09
EuroBank	1,449.28	35.39	74.01	232.69	1,216.59	93.82	0.051068	0.060836	4.94
ProCredit	1,458.19	np	26.66	130.95	1,327.36	149.64	0.018286	0.020088	4.08
2006.									
Intesa	7,801.21	80.24	80.06	759.75	7,041.52	475.10	0.010262	0.011369	4.11
Komercijalna	6,685.23	33.83	58.50	995.24	5,689.98	418.91	0.008751	0.010281	4.50
Unikredit	4,286.86	152.07	79.99	593.16	3,693.77	333.49	0.01866	0.021656	4.58
Societe	3,264.46	118.99	135.81	691.41	2,573.11	209.02	0.041604	0.052782	5.33
Raiffeisen	8,972.32	351.43	150.77	1,331.04	7,641.28	593.91	0.016803	0.01973	4.66
AIK	2,386.71	245.21	240.60	1,051.00	1,335.65	242.22	0.100809	0.180139	7.99
EuroBank	3,919.79	35.39	-11.90	961.85	2,958.00	252.07	-0.00304	-0.00402	5.22
ProCredit	2,437.67	np	11.34	211.70	2,225.98	250.70	0.004651	0.005094	3.96

2007.									
Intesa	12,082.34	406.32	196.74	1,757.73	10,324.67	861.86	0.016284	0.019056	4.61
Komercijalna	9,840.35	138.49	200.36	821.05	8,626.87	534.47	0.020361	0.023225	4.35
Unikredit	4,578.24	267.27	115.19	903.97	3,674.27	324.08	0.025161	0.031351	5.17
Societe	4,074.61	13,403.41	90.65	1,028.45	3,046.16	276.99	0.022247	0.029758	16.14
Raiffeisen	10,805.37	628.86	286.14	2,205.36	8,600.02	734.39	0.026482	0.033272	5.24
AIK	4,877.40	224.53	285.71	1,821.28	3,056.06	551.73	0.058578	0.093489	6.88
EuroBank	5,240.05	35.39	82.17	1,405.74	3,834.25	437.03	0.015682	0.021431	5.53
ProCredit	3,844.41	np	34.14	299.85	3,544.56	365.14	0.008881	0.009632	3.92
2008.									
Intesa	15,587.52	552.97	367.07	2,736.28	12,851.24	1,344.75	0.023549	0.028563	4.91
Komercijalna	11,452.48	315.11	178.05	1,063.02	9,817.48	742.74	0.015547	0.018136	4.50
Unikredit	5,601.52	441.96	174.69	1,278.02	4,323.43	455.85	0.031186	0.040405	5.53
Societe	4,478.93	13,403.41	126.34	1,160.96	3,317.97	373.86	0.028209	0.038079	15.27
Raiffeisen	10,904.24	1,025.46	401.84	2,787.43	8,116.88	1,043.09	0.036851	0.049506	5.85
AIK	5,197.56	332.68	340.72	2,117.33	3,080.30	758.32	0.065554	0.110612	7.30
EuroBank	7,727.01	35.39	253.75	2,223.92	5,503.08	757.69	0.032839	0.04611	5.81
ProCredit	4,100.96	np	38.38	502.26	3,598.70	459.71	0.009358	0.010664	4.27

2009.									
Intesa	19,184.60	920.05	374.55	3,101.67	16,082.87	1,550.65	0.019523	0.023289	4.81
Komercijalna	13,665.82	487.44	117.68	1,769.69	11,896.12	980.48	0.008612	0.009893	4.44
Unikredit	8,482.08	616.52	174.50	1,452.77	7,029.31	544.07	0.020573	0.024825	4.98
Societe	6,212.00	13,403.41	99.56	1,265.13	4,946.87	420.53	0.016026	0.020125	12.01
Raiffeisen	12,057.04	1,223.63	198.18	2,943.55	9,113.49	897.56	0.016437	0.021745	5.64
AIK	6,816.93	5,041.19	347.57	2,435.56	4,381.37	757.75	0.050987	0.079329	8.94
EuroBank	9,148.13	260.79	171.39	2,395.31	6,752.82	794.70	0.018735	0.02538	5.57
ProCredit	4,135.85	np	50.28	533.54	3,602.31	503.01	0.012156	0.013957	4.34
2010.									
Intesa	22,373.36	1,294.59	179.92	3,569.10	18,804.26	1,659.11	0.008042	0.009568	4.75
Komercijalna	16,958.25	614.78	157.00	2,662.45	14,295.86	1,041.59	0.009258	0.010982	4.67
Unikredit	10,402.98	850.58	223.72	1,998.15	8,404.83	730.41	0.021505	0.026618	5.18
Societe	8,499.84	13,403.41	100.86	1,355.03	7,142.94	491.42	0.011867	0.014121	9.73
Raiffeisen	11,141.30	1,397.45	173.82	3,116.93	8,024.36	804.79	0.015601	0.021661	6.02
AIK	8,820.62	820.18	348.32	2,751.67	6,069.02	731.90	0.039489	0.057393	6.35
EuroBank	11,269.45	432.18	163.29	2,558.60	8,710.85	751.96	0.014489	0.018745	5.28
ProCredit	4,417.26	np	27.72	540.20	3,877.05	455.35	0.006276	0.007151	4.25

2011.									
Intesa	24,441.72	1,769.32	597.52	5,009.79	19,431.87	1,936.91	0.024447	0.030749	5.28
Komercijalna	18,233.90	763.92	220.23	2,868.54	15,365.36	1,206.88	0.012078	0.014333	4.71
Unikredit	12,370.79	1,133.42	282.84	2,636.60	9,734.19	880.17	0.022864	0.029057	5.39
Societe	11,985.34	13,403.41	85.10	2,108.42	9,876.86	720.62	0.0071	0.008616	8.33
Raiffeisen	12,428.79	310.63	275.74	3,442.88	8,985.90	886.53	0.022186	0.030686	5.71
AIK	8,920.99	1,098.91	185.22	2,917.51	6,003.41	788.41	0.020762	0.030852	6.46
EuroBank	9,997.53	595.46	166.47	2,726.25	7,271.34	834.70	0.016651	0.022893	5.75
ProCredit	3,772.27	np	96.07	613.03	3,159.23	453.61	0.025467	0.030408	4.70
2012.									
Intesa	25,750.46	2,366.84	591.41	5,610.24	20,140.22	1,952.54	0.022967	0.029365	5.44
Komercijalna	21,379.49	943.78	245.84	3,867.15	1,353.22	1,254.16	0.011499	0.181668	12.63
Unikredit	15,173.41	1,063.02	274.12	2,853.84	12,319.58	957.05	0.018066	0.022251	5.09
Societe	12,870.43	538.02	5.54	2,117.64	10,752.79	833.39	0.000431	0.000516	4.69
Raiffeisen	12,680.29	364.95	360.28	3,474.28	9,206.01	867.71	0.028413	0.039135	5.74
AIK	9,616.13	1,252.29	226.90	3,131.32	6,484.81	799.87	0.023595	0.034989	6.49
EuroBank	10,524.21	595.46	104.29	2,829.17	7,695.05	764.42	0.00991	0.013553	5.66
ProCredit	4,224.81	102.36	34.08	368.50	3,856.37	465.19	0.008066	0.008837	4.07

2013.									
Intesa	26,556.56	2,958.25	536.28	6,160.66	20,395.84	1,919.59	0.020194	0.026294	5.60
Komercijalna	23,941.64	1,036.36	277.98	4,176.72	19,764.92	1,473.21	0.011611	0.014064	4.85
Unikredit	15,696.67	1,336.77	238.73	3,147.71	12,548.96	1,031.07	0.015209	0.019024	5.22
Societe	13,710.24	538.02	-50.34	2,078.27	11,631.97	892.39	-0.00367	-0.00433	4.55
Raiffeisen	12,781.41	1,467.73	339.97	3,515.03	9,266.38	872.32	0.026599	0.036689	6.02
AIK	9,469.04	1,440.69	61.86	3,187.08	6,281.96	737.45	0.006533	0.009848	6.54
EuroBank	9,799.98	595.46	85.72	2,917.14	6,882.84	753.95	0.008747	0.012455	5.91
ProCredit	4,278.45	102.36	28.53	368.19	3,910.26	454.10	0.006669	0.007297	4.05
2014.									
Intesa	29,465.22	2,958.25	424.20	6,554.52	22,910.70	1,734.37	0.014397	0.018515	5.44
Komercijalna	26,832.73	1,315.65	298.73	4,491.89	22,340.84	1,419.88	0.011133	0.013371	4.80
Unikredit	16,526.45	238.73	340.59	3,442.57	13,083.87	1,020.22	0.020609	0.026032	5.09
Societe	13,849.98	593.35	22.99	2,113.09	11,736.88	899.18	0.00166	0.001959	4.60
Raiffeisen	13,972.89	1,454.89	330.19	3,488.30	10,484.59	848.21	0.023631	0.031493	5.75
AIK	10,796.65	1,517.25	113.26	3,311.37	7,485.28	648.17	0.01049	0.015131	6.27
EuroBank	9,106.95	595.46	-166.03	2,747.93	6,359.02	640.38	-0.01823	-0.02611	5.78
ProCredit	4,371.22	102.36	36.76	406.76	3,964.46	345.14	0.008409	0.009272	4.11

2015.									
Intesa	30,389.88	2,958.25	534.85	7,139.46	23,250.42	1,583.60	0.017599	0.023004	5.56
Komercijalna	25,846.96	1,665.72	-438.53	3,944.40	21,902.50	1,174.73	-0.01697	-0.02002	4.55
Unikredit	19,206.03	340.47	396.60	3,826.09	15,380.00	1,092.43	0.02065	0.025787	5.02
Societe	14,362.46	616.33	128.52	2,279.12	12,083.40	891.58	0.008949	0.010636	4.70
Raiffeisen	14,618.26	1,454.89	275.05	3,446.31	11,172.01	731.78	0.018816	0.02462	5.58
AIK	11,156.62	1,303.00	212.63	3,263.52	7,893.04	622.94	0.019059	0.026939	6.12
EuroBank	8,758.32	364.70	181.67	2,925.30	5,833.02	538.83	0.020742	0.031145	6.25
ProCredit	4,401.31	102.36	44.92	442.39	3,960.10	317.98	0.010206	0.011343	4.18

Prikaz autora prema podacima iz godišnjih financijskih izvještaja

Prilog 3: Poslovanje odabranih banaka u Bosni i Hercegovini 2005-2015 (u mil. kn)

Banka	Ukupna imovina	Zadržana dobit	Dobit poslovne godine	Tržišna vrijednost kapitala	Knjigovodstvena vrijednost obveza	Prihod od kamata	ROA	ROE	Z-Score
2005.									
UniCredit	np	np	np	np	np	np	np	np	np
Nova banka	930.49	3.99	14.21	148.97	781.52	55.41	0.015266	0.018176	4.63
Intesa	1,655.50	50.29	11.90	136.63	1,518.88	83.47	0.007189	0.007836	4.04
Sparkasse	587.85	13.59	7.26	76.26	511.59	42.20	0.012345	0.014185	4.43
NLB BL	2,020.84	11.60	15.28	203.88	1,816.96	102.57	0.007561	0.008409	4.11
NLB Sarajevo	2,067.39	8.06	17.44	192.49	1,874.91	106.98	0.008437	0.009304	4.05
Vakufska	380.28	5.65	1.47	65.68	314.60	20.40	0.003866	0.004673	4.69
Bosna Bank	33.68	0.09	np	np	np	np	np	np	np
2006.									
UniCredit	6,993.44	244.68	93.86	558.81	6,434.64	398.89	0.013421	0.014586	4.08
Nova banka	1,632.92	4.70	18.06	186.50	1,446.42	77.78	0.011061	0.012487	4.23
Intesa	1,901.65	53.13	2.83	139.46	1,762.20	105.72	0.001489	0.001607	3.93
Sparkasse	782.85	20.76	7.55	152.51	630.34	51.29	0.009646	0.01198	4.94
NLB BL	2,325.34	8.63	30.19	210.07	2,115.27	105.75	0.012984	0.014274	4.06
NLB Sarajevo	2,489.28	1.75	5.25	185.40	2,303.88	97.42	0.00211	0.002279	3.85
Vakufska	402.79	7.39	1.85	67.42	335.37	21.59	0.004605	0.005531	4.66
Bosna Bank	542.80	-10.35	0.15	178.45	364.35	21.84	0.000285	0.000424	5.87

2007.									
UniCredit	8,138.80	355.71	112.15	669.80	7,469.00	474.30	0.013779	0.015015	4.13
Nova banka	3,367.42	5.82	20.08	229.20	3,138.21	138.02	0.005963	0.006398	3.83
Intesa	3,587.62	162.32	5.76	140.03	3,285.27	167.05	0.001606	0.001753	4.02
Sparkasse	1,272.19	26.94	5.79	158.30	1,113.89	74.39	0.004555	0.005202	4.33
NLB BL	4,139.38	19.39	50.68	240.68	3,898.70	189.77	0.012244	0.013	3.80
NLB Sarajevo	2,828.01	24.46	24.46	209.87	2,618.14	164.17	0.00865	0.009344	3.92
Vakufska	578.36	6.22	0.50	186.54	391.82	27.60	0.000867	0.00128	5.92
Bosna Bank	590.39	-7.70	2.65	181.11	409.29	35.01	0.004495	0.006485	5.72
2008.									
UniCredit	12,444.11	643.36	123.09	1,274.73	11,169.39	778.08	0.009891	0.01102	4.29
Nova banka	2,861.89	7.00	14.13	242.76	2,619.13	178.55	0.004939	0.005396	3.95
Intesa	3,813.20	290.53	10.52	170.76	3,351.90	235.26	0.002759	0.003139	4.37
Sparkasse	1,984.04	4.66	-22.28	249.12	1,734.92	96.70	-0.01123	-0.01284	4.17
NLB BL	4,820.89	51.19	53.10	301.49	4,519.39	254.43	0.011014	0.011748	3.85
NLB Sarajevo	2,990.99	30.60	30.60	228.23	2,762.76	186.40	0.01023	0.011075	3.95
Vakufska	643.86	11.21	5.08	192.41	451.45	37.38	0.007887	0.011248	5.78
Bosna Bank	737.02	-7.10	0.60	181.71	555.31	42.04	0.000818	0.001086	5.20

2009.									
UniCredit	13,013.07	754.07	110.71	1,390.09	11,622.98	732.50	0.008508	0.009525	4.33
Nova banka	3,460.58	7.54	39.10	277.97	2,805.61	155.85	0.011298	0.013936	4.69
Intesa	4,371.68	293.50	13.16	464.27	3,907.42	250.86	0.00301	0.003368	4.32
Sparkasse	2,471.59	-24.44	-24.44	300.08	2,171.51	125.34	-0.00989	-0.01125	4.10
NLB BL	4,377.24	82.21	22.27	313.18	4,064.07	207.82	0.005087	0.005479	3.91
NLB Sarajevo	3,147.27	7.28	7.28	239.07	2,908.20	187.48	0.002314	0.002504	3.87
Vakufska	722.23	6.38	-4.30	186.77	535.46	41.49	-0.00595	-0.00803	5.31
Bosna Bank	917.55	-5.36	1.73	183.45	734.10	51.42	0.00189	0.002362	4.83
2010.									
UniCredit	13,628.88	873.40	134.22	1,583.51	12,045.37	707.96	0.009848	0.011143	4.44
Nova banka	3,762.72	9.49	32.45	326.53	2,839.39	166.19	0.008624	0.011428	5.06
Intesa	4,829.66	318.24	22.85	4,867.73	4,342.59	270.47	0.004731	0.005262	5.35
Sparkasse	2,930.06	7.19	6.89	306.97	2,623.09	157.49	0.002351	0.002626	4.09
NLB BL	3,969.72	np	33.44	336.48	3,633.24	211.48	0.008424	0.009204	np
NLB Sarajevo	3,488.14	5.35	1.71	240.81	3,247.33	186.30	0.00049	0.000526	3.80
Vakufska	814.23	7.37	0.99	187.69	626.54	48.37	0.001218	0.001582	5.12
Bosna Bank	1,163.96	-3.79	1.57	186.46	977.50	57.90	0.001351	0.001608	4.51

2011.									
UniCredit	13,360.68	1,061.84	188.44	1,773.02	11,587.65	726.24	0.014104	0.016262	4.65
Nova banka	4,456.12	11.02	33.39	359.93	3,307.70	190.06	0.007494	0.010096	5.12
Intesa	5,034.66	117.49	38.86	594.93	4,439.72	295.24	0.007719	0.008753	4.30
Sparkasse	3,076.65	24.09	24.09	367.83	2,708.82	180.95	0.007831	0.008895	4.27
NLB BL	4,277.40	np	40.07	355.36	3,922.04	200.90	0.009368	0.010217	np
NLB Sarajevo	3,386.62	16.49	12.85	267.37	3,119.25	190.42	0.003795	0.00412	3.91
Vakufska	913.70	7.65	0.27	193.25	720.44	52.53	0.000297	0.000377	4.96
Bosna Bank	1,270.92	4.05	7.84	194.29	1,076.63	64.73	0.006167	0.00728	4.50
2012.									
UniCredit	14,115.37	1,263.34	201.50	1,973.53	12,141.83	698.98	0.014275	0.016596	4.74
Nova banka	5,614.66	12.58	37.90	397.83	4,167.04	240.47	0.00675	0.009095	5.10
Intesa	4,996.66	176.22	58.75	653.92	4,342.74	318.36	0.011758	0.013528	4.47
Sparkasse	3,382.68	26.43	26.43	396.91	2,948.03	206.86	0.007813	0.008964	4.32
NLB BL	4,165.15	np	42.51	403.22	3,761.93	205.09	0.010207	0.011301	np
NLB Sarajevo	2,979.16	21.85	18.21	287.80	2,691.36	185.44	0.006112	0.006766	4.07
Vakufska	955.44	1.01	0.78	194.03	761.41	49.17	0.000817	0.001025	4.87
Bosna Bank	1,611.84	12.78	9.89	204.19	1,407.66	75.96	0.006137	0.007028	4.31

2013.									
UniCredit	14,323.62	1,472.84	209.50	2,182.14	11,877.58	681.12	0.014626	0.017638	5.01
Nova banka	Np	np	np	Np	np	np	np	np	np
Intesa	5,011.34	226.84	50.63	704.88	4,306.46	298.93	0.010102	0.011756	4.57
Sparkasse	3,622.96	55.33	32.89	428.98	3,193.97	177.70	0.009079	0.010298	4.29
NLB BL	4,486.82	146.21	45.19	453.32	4,033.50	189.30	0.010071	0.011203	4.21
NLB Sarajevo	3,007.44	19.71	16.07	303.67	2,703.76	168.52	0.005343	0.005943	4.10
Vakufska	1,071.73	-18.74	-19.75	174.41	897.32	49.55	-0.01843	-0.02201	4.35
Bosna Bank	2,117.93	20.12	11.20	328.49	1,789.44	84.16	0.00529	0.006261	4.54
2014.									
UniCredit	14,935.59	1,704.31	231.47	2,413.04	12,522.55	677.93	0.015498	0.018484	5.00
Nova banka	Np	np	np	Np	np	np	np	np	np
Intesa	5,421.99	300.92	74.07	778.49	4,643.50	300.77	0.013661	0.015952	4.65
Sparkasse	3,899.52	88.22	40.42	469.09	3,430.43	214.46	0.010365	0.011782	4.34
NLB BL	4,472.42	159.73	57.76	478.94	3,993.48	191.41	0.012915	0.014464	4.29
NLB Sarajevo	3,411.61	23.34	19.70	323.19	3,088.43	169.09	0.005775	0.006379	4.05
Vakufska	881.84	-118.11	-99.38	75.05	806.79	42.68	-0.11269	-0.12317	2.72
Bosna Bank	2,399.31	33.01	17.09	343.62	2,055.69	96.14	0.007123	0.008313	4.47

2015.									
UniCredit	16,495.94	2,004.33	300.03	2,712.25	13,783.69	714.66	0.018188	0.021767	5.06
Nova banka	7,354.81	27.97	50.71	559.10	5,628.56	322.89	0.006894	0.009009	4.96
Intesa	5,825.65	419.41	98.42	878.28	4,947.37	304.85	0.016894	0.019893	4.78
Sparkasse	4,389.52	108.43	54.54	521.80	3,867.72	208.60	0.012426	0.014102	4.35
NLB BL	4,521.82	177.20	71.24	509.80	4,012.01	178.96	0.015755	0.017757	4.37
NLB Sarajevo	3,515.23	28.99	28.99	405.35	3,109.88	167.83	0.008248	0.009323	4.24
Vakufska	965.15	0.97	0.99	98.63	866.52	38.84	0.001023	0.00114	4.06
Bosna Bank	2,659.63	51.13	23.57	364.77	2,294.86	106.36	0.008863	0.010272	4.45

Prikaz autora prema podacima iz godišnjih financijskih izvještaja

SAŽETAK

Pokušavajući sagledati problem svakodnevnog smanjenja broja poslovnih banaka na bankarskom tržištu, te ispitujući efekte istog na profitabilnost i stabilnost pojedinaca na tržištu i samog tržišta, ovaj diplomski rad je empirijsko istraživanje utjecaja koncentričnosti bankarskog sustava na stabilnost i profitabilnost poslovnih banaka. Istraživanje se odnosi na uzorak od 24 banke iz tri države (Republika Hrvatska, Republika Srbija, Bosna i Hercegovina) u periodu 2005-2015. Analiza se provodi pomoću modela višestruke regresije sa zavisnom varijablom profitabilnosti aproksimiranom u indikatorima ROA i ROE, te zavisnom varijablom stabilnosti aproksimiranom Z-Scoreom u bankarskim sektorima promatranih država u analiziranom periodu, te nezavisnim varijablama aproksimiranim varijablama k-omjera bankovne koncentričnosti (CR2, CR5), te Herfindahl-Hirchman indeksa (HHI). Rezultati utvrđuju pozitivnu korelaciju između profitabilnosti i koncentričnosti bankarskog sustava, te negativnu korelaciju koncentričnosti bankarskog sustava s stabilnošću istog.

Ključne riječi: bankovna koncentričnost, stabilnost, profitabilnost

SUMMARY

Attempting to review the problem of constant decrease in the number of commercial banks on the banking market, and testing the effects of said onto profitability and stability of units on the market, and the market itself, this thesis is an empirical research of the banking system's concentration effect on stability and profitability of commercial banks. The research is conducted on a sample of 24 banks from three countries (Republic of Croatia, Republic of Serbia and Bosna and Herzegovina) in the period 2005-2010. Analysis is carried out via multiple regression models, with ROA and ROE serve as dependent variables for profitability in their respective models, and Z-Score in the banking sector of each country in the analysed period as the dependent variable for stability, while k-bank concentration ratio (CR2, CR5) and Herfindahl-Hirschman index (HHI) are used as independent variables.

The results determine a positive correlation between profitability and banking system concentration, and a negative link between banking system concentration and its stability.

Key words: banking concentration, stability, profitability