STATISTIČKA ANALIZA USPJEŠNOSTI POSLOVANJA ERSTE & STEIERMARKISCHE BANK D.D.U RAZDOBLJU OD 2007.-2014.GODINE I USPOREDBA S GLAVNIM KONKURENTIMA

Orlović, Anđela

Master's thesis / Diplomski rad

2016

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:302876

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET SPLIT

DIPLOMSKI RAD

STATISTIČKA ANALIZA USPJEŠNOSTI POSLOVANJA ERSTE & STEIERMARKISCHE BANK D.D.U RAZDOBLJU OD 2007.-2014.GODINE I USPOREDBA S GLAVNIM KONKURENTIMA

Mentor:

prof.dr.sc.Elza Jurun

Student:

Anđela Orlović univ.bacc.oec.

MB: 2130599

Split,rujan 2016.

SADRŽAJ:

1. UVOD 1
1.1. Problem istraživanja 1
1.2. Predmet istraživanja 3
1.3. Istraživačke hipoteze 3
1.4. Ciljevi istraživanja 4
1.5. Metode istraživanja 4
1.6. Doprinos istraživanja 5
1.7. Struktura diplomskog rada 6
2. ANALIZA POSLOVANJA ERSTE&STEIERMÄRKISCHE BANK D.D. NA TEMELJU FINANCIJSKIH POKAZATELJA 7
2.1. Erste & Steiermärkische Bank d.d. 7
2.2. Pokazatelj odnosa u bilanci banke 8
2.2.1. Pokazatelji odnosa u bilanci 12
2.2.2. Pokazatelji odnosa u računu dobiti i gubitka banke 16
2.3. Poslovanje Erste banke od 2007.-2014. godine 18
2.4. Horizontalna analiza 19
2.5. Vertikalna analiza 28
3. EMPIRIJSKO ISTRAŽIVANJE O USPJEŠNOSTI POSLOVANJA ERSTE & STEIERMARKISCHE BANK D.D. 33
3.1. Testiranje prve istraživačke hipoteze 33
3.1.1. O višestrukoj regresiji 34
3.1.2. Opis varijabli odabranih u regresijski model 37
3.1.3. Rezultati regresije 41
3.2. Testiranje druge istraživačke hipoteze 50
3.3. Testiranje treće istraživačke hipoteze 56
4. ZAKLJUČAK 60
5. SAŽETAK 63
6. SUMMARY 63
Popis grafikona 64
Popis slika 64
Popis tablica 64
LITERATURA 66

1. UVOD

1.1. Problem istraživanja

Ključna uloga banaka je stvarati, prenositi i upravljati novcem. One osiguravaju sigurniju alokaciju novčanih fondova od suficitnih prema deficitnim subjektima tj. one prikupljaju sredstva od privrede i stanovništva te ih plasiraju u obliku kredita pravnim ili fizičkim osobama kojima ta sredstva trebaju. Kao posljedica tehnološkog napretka bankarski sektor postaje sve univerzaliji te banke uvode proizvode i usluge kao Internet bankarstvo, mreže bankomata, kreditnih i debitnih kartica, elektroničko plaćanje itd.[1]

Banka je javno dobro i zbog toga se kvaliteti njenog poslovanja mora posvetiti mnogo pozornosti. Temeljni kriteriji kvalitete poslovanja su stabilnost i uspješnost. Kvaliteta poslovanja se mjeri financijskim pokazateljima, dok su temeljna podloga za formiranje pokazatelja financijski izvještaji. Financijski izvještaji banke moraju biti realni i objektivni.[2]

Banke u svijetu pa tako i u Hrvatskoj zbog financijske krize su suočene s iskušenjima, pogotovo onima vezanim uz njihove najveće izvore zarade, a to su odobravanje kredita klijentima. To je jedna od najvažnijih ekonomskih funkcija banaka kojom banaka stječe ogroman dio svojih profita. Odobravanje kredita je riskantna funkcija jer različiti unutarnji i vanjski faktori mogu rezultirati znatnim gubicima za banku. Za razliku od stabilnih vremena, u kriznim vremenima banci je sve teže pronaći kvalitetne i kvalificirane komitente. Ako banka želi povećati ponudu kredita treba raditi na tome da smanji negativnu selekciju i moralni hazard koji vode do sve većeg broja loših tj. nenaplativih kredita.

Erste & Steiermärkische Bank d.d. (u daljnjem tekstu: Erste banka), pod tim imenom posluje od 1. kolovoza 2003. Nastala je spajanjem Riječke banke d.d., Rijeka i tadašnje Erste & Steiermärkische Bank d.d., Zagreb. Obje banke imale su značajnu ulogu na hrvatskom financijskom tržištu. Riječka banka, osnovana 1954. godine, s 50-godišnjom tradicijom u bankarstvu predstavljala je vodeću banku grada Rijeke, Primorja i Istre. Erste & Steiermärkische Bank d.d. Zagreb nastala je 2000. godine spajanjem triju uspješnih regionalnih hrvatskih banaka: Bjelovarske, Trgovačke i Čakovečke banke. Erste &

[1] Mishin F., Eatkons, S.G.: Financijska tržišta i institucije, IV izdanje, Mate, Zagreb, 2008.
[2] Halaj G.: Strateške grupe i uspješnost poslovanja banaka, Financijska teorija i praksa, Vol.33, br. 2, 2009.

Steiermärkische Bank d.d. posluje putem mreže od 134 poslovnice; 13 komercijalnih centara, 8 poduzetničkih i 9 profitnih centara za korporativne klijente te 626 bankomata. [3]

Erste banka je prema udjelu u ukupnoj aktivi banaka treća banka u Hrvatskoj, odnosno 15,14% tržišnog udjela iza Zagrebačke banke i Privredne banke Zagreb te spada u skupinu tzv. "velikih banaka" kod kojih se rizik smatra izuzetno niskim.[4]

Analiziranjem financijskih izvještaja može se doći do procjene financijskog zdravlja banke. Pomoću pokazatelja uspješnosti, profitabilnosti, likvidnosti, vrijednosti za dioničare te horizontalne i vertikalne analize financijskih izvještaja može se analizirati poslovanje banke u vremenu prije te za vrijeme krize. Od velike važnosti je usporediti poslovanje Erste banke sa poslovanjima najvećih konkurenata iz bankarskog sektora.

U ovom radu ćemo pokušati dobiti što realniju sliku poslovanja i uspješnosti Erste banke u razdoblju od 2007. do 2014. godine. Promatrano razdoblje obuhvaća trenutnu financijsku krizu koja je započela u SAD-u 2007.godine pucanjem „mjehura“ na tržištu nekretnina te se prenijela na financijski,bankarski i ostale sektore. Trenutna kriza je pogodila i Hrvatsku, te ćemo putem odabranih statističkih analiza i pokazatelja analizirati poslovanje Erste banke sa njenim vodećim konkurentima za vrijeme krize. Uvid u izvore i poslovanje banaka daju nam financijska izvješća. Financijski izvještaji su izvještaji o financijskom stanju i financijskom prometu nekog poslovnog subjekta, u ovom slučaju Erste banke. Poznavanje uloge financijskih izvještaja u banci bitan je za ukupan poslovni uspjeh, pa mu tako treba i pristupati. Vertikalne i horizontale analize najznačajniji su dio analiza financijskih izvještaja koje nam mogu biti skupina brojki, ali mogu biti i skupina pokazatelja na osnovi kojih ćemo donijeti poslovne odluke. Ukoliko dobro poslujemo, financijski izvještaji će nam to pokazati, ukoliko loše poslujemo u njima ćemo otkriti gdje su "problemi", što može poslužiti kao osnova za donošenje odluke kako dalje. Financijski izvještaji predstavljaju vrlo važan informacijski potencijal za čitav niz različitih korisnika.[5]

[3] http://www.erstebank.hr (na dan 22.05.2015.)
[4] http://www.hnb.hr/ (na dan 22.05.2015.)
[5] http://www.poduzetnistvo.org/news/clanak-financijski-izvjestaji-kao-osnova-poslovnog-odlucivanja (na dan 22.05.2015)

1.2. Predmet istraživanja

Iz analize problema istraživanja može se definirati predmet istraživanja. Predmet istraživanja ovoga rada biti će statistička analiza financijskih izvještaja Erste banke kako bi se dobile informacije o uspješnosti poslovanja Erste banke u promatranom razdoblju od 2007.-2014. godine na temelju čega će se donijeti zaključci u skladu sa hipotezama i ciljevima istraživanja.

Temeljna financijska izvješća su: bilanca, račun dobiti i gubitka, izvješće o novčanom toku, bilješke uz financijska izvješća i izvješće o promjeni glavnice.[6]

Analiza će u obzir uzeti: bilancu, račun dobiti i gubitka te izvješća o novčanom toku i to u razdoblju od 2007. do 2014. godine kako bi dobili odgovore na pitanje kako je kriza utjecala na poslovanje banke, na izdavanje kredita poslovnim i privatnim subjektima. Zatim će se dobiveni pokazatelji usporediti sa pokazateljima glavnih konkurenata iz sektora bankarstva. Zatim će se odrediti pozicija Erste banke u odnosu na njene konkurente u razdoblju od 2007. do 2014. godine. [7] Za analizu financijskih izvještaja koristit ćemo horizontalnu i vertikalnu analizu.

1.3. Istraživačke hipoteze

Hipoteze se postavljaju na temelju prethodno opisanog problema i predmeta istraživanja.

Hipoteze glase:

H1- Svjetska financijska kriza je negativno utjecala na poslovanje i financijske rezultate Erste banke u Republici Hrvatskoj

H2- Položaj Erste banke u smislu poslovne uspješnosti s obzirom na odabrane konkurente nije se promijenio prije i za vrijeme financijske krize.

H3- Kreditiranje Erste banke utječe na kretanje BDP-a u promatranom razdoblju.

[6] Žager L., Žager K., Analiza financijskih izvještaja, Masmedia, Zagreb, 1999.
[7] Hrvatska Narodna Banka (HNB): Bilten o bankama, Zagreb, 2014.

1.4. Ciljevi istraživanja

U skladu s uočenim problemom i predmetom istraživanja te postavljenim hipotezama, definirana je svrha i cilj rada: analizirati i ocijeniti uspješnost poslovanja Erste banke pomoću konkretnih empirijskih podataka iz financijskih izvještaja te usporedba poslovanja Erste banke s odabranim vodećim bankama u RH. Na temelju toga moći će se doći do zaključka kakav je utjecaj financijska kriza imala na poslovanje Erste banke. Cilj istraživanja je dakako i prihvatiti ili odbaciti postavljene hipoteze, analiziranje financijskih izvještaja banke, definiranje analize poslovanja putem financijskih pokazatelja, analizom kriznog razdoblja utvrditi uspješnost Erste banke, utvrditi postoji li razlika u položaju i njenom poslovanju s obzirom na odabrane glavne konkurente, te provesti klasifikacija banaka po kriteriju uspješnosti i ostvarenim rezultatima poslovanja te rangiranje odabranih banaka.

1.5. Metode istraživanja

Da bi se moglo realizirati ciljevi istraživanja, potrebno je koristiti mnogobrojne metode koje će nam pomoći u tome. Pri izradi ovog rada biti će korištene razne teorijske i empirijske metode. U izradi teorijskog dijela rada biti će korištena stručna i znanstvena literatura. U empirijskom dijelu rada koristit će se programski paketi MS Excel i SPSS Statistics koji omogućavaju različite oblike statističke analize.

U izradi ovog rada koristit će se sljedeće znanstvene metode u odgovarajućim kombinacijama među kojima su: metoda analize i metoda sinteze. Metoda analize je postupak znanstvenog istraživanja raščlanjivanjem složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente, dok metoda sinteze je postupak znanstvenog istraživanja i objašnjavanja stvarnosti putem sinteze jednostavnih sudova u složenije. Metode indukcije i dedukcije služe za donošenje zaključaka. Koriste se da bi se dobili odgovori na postavljene hipoteze, te da bi se hipoteze potvrdile ili odbacile temeljem navedenih ciljeva istraživanja. Metoda komparacije će usporediti rezultat poslovanja i predmeta te njihovih empirijskih potvrđivanja odnosa i veza, ali bez znanstvenog tumačenja i objašnjavanja. Metodom klasifikacije će se ostvariti razvrstavanje pojava i predmeta radi njihove preglednosti. 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. [8]

Da bi se izvršila klasifikacija vodećih banaka prema odabranim financijskim pokazateljima istovremeno upotrijebit će se multivariantna Cluster metoda.

1.6. Doprinos istraživanja

Doprinos ovog rada je usmjeren na analizu i prikaz poslovanja jedne od većih banaka u Hrvatskoj. Pokazat će se koliko se uspješno Erste banka nosila s krizom. Jedan od najvažnijih doprinosa rada je istražiti određene promjene poslovanja u proteklom vremena na primjeru Erste banke, jedne od većih banaka u Republici Hrvatskoj. Utvrdit će se kakav utjecaj te promjene imaju na kretanje poslovanja banke, na obujam kretanja kredita te na odabrane financijske pokazatelje, te usporedba i sa drugim velikim bankama i koliko su one uspješno poslovale u promatranom razdoblju, tko je bolje iskoristio krizu, a tko ne.

Istraživanje će biti potkrijepljeno sintezama, tabelarnim pregledima i interpretacijama te širim spektrom metoda istraživanja. Ovim radom se može očekivati praktična korist za različite investitore i analitičare jer će se istraživati poslovanje Erste banke, trenutno treće banke u Republici Hrvatskoj prema udjelu u ukupnoj aktivi banaka. Također će se dobiti uvid u poslovanje ostalih najvećih banaka u Republici Hrvatskoj te ćemo moći usporediti njihovo poslovanje prije i za vrijeme krize i na taj način dobiti jasniju sliku o uspješnosti poslovanja velikih banaka u Republici Hrvatskoj. Rezultati istraživanja mogu biti od koristi ekonomskim analitičarima i donosiocima poslovnih odluka posebno u području financijskog poslovanja.

[8] http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/METODE_ZNANSTVENIH_ISTRAZIVANJA.pdf (na dan 23.05.2015.)

1.7. Struktura diplomskog rada

Diplomski rad će biti koncipiran da s uvodom i zaključkom sadrži četiri poglavlja.

U uvodnom poglavlju definirat će se problem i predmet istraživanja, te će se postaviti temeljne hipoteze, zatim će biti precizirana svrha i cilj istraživanja, navest će se znanstveno istraživačke metode koje će biti korištene u radu te na samom kraju doprinos cijelog istraživanja diplomskog rada.

U drugom dijelu će se provesti analiza poslovanja Erste & Steiermärkische Bank d.d. na temelju financijskih pokazatelja koje čine pokazatelji profitabilnosti, likvidnosti, zaduženosti, te pokazatelj vrijednosti za dioničare. Nakon toga će se analizirati financijska izvješća Erste & Steiermärkische Bank d.d. pomoću pokazatelja odnosa u bilanci banke te pokazatelja odnosa u računu dobiti i gubitka, te poslovanje banke pomoću horizontalne i vertikalne analize.

U trećem dijelu će se provesti empirijsko istraživanje o uspješnosti poslovanja Erste & Steiermarkische bank d.d pomoću regresije. U testiranju prve hipoteze koristi će se višestruka regresija, dok će se za testiranje treće hipoteze koristiti jednostavna linearna regresijska analiza. Dok će se za analizu druge hipoteze koristiti t – test, nakon što se provede cluster metoda.

2. ANALIZA POSLOVANJA ERSTE&STEIERMÄRKISCHE BANK D.D. NA TEMELJU FINANCIJSKIH POKAZATELJA

2.1. Erste & Steiermärkische Bank d.d.

Erste & Steiermärkische Bank d.d. pod tim imenom posluje od 1. kolovoza 2003. Nastala je spajanjem Riječke banke d.d., Rijeka i tadašnje Erste & Steiermärkische Bank d.d., Zagreb. Obje banke imale su značajnu ulogu na hrvatskom financijskom tržištu. Riječka banka, osnovana 1954. godine, s 50-godišnjom tradicijom u bankarstvu predstavljala je vodeću banku grada Rijeke, Primorja i Istre. Erste & Steiermärkische Bank d.d. Zagreb nastala je 2000. godine spajanjem triju uspješnih regionalnih hrvatskih banaka: Bjelovarske, Trgovačke i Čakovečke banke.

Erste & Steiermärkische Bank d.d. posluje na nacionalnoj razini te uslužuje više od 820.000 klijenata kroz mrežu od 131 poslovnice (ožujak 2016.) i više od 630 bankomata (ožujak, 2016.). Mreža ujedno uključuje 13 komercijalnih, 8 poduzetničkih i 9 profitnih centara za korporativne klijente. Prema veličini aktive banka zauzima treće mjesto u Hrvatskoj, odnosno 14,7 posto tržišnog udjela (HNB, 31.12.2015.).

U svom poslovanju banka je prvenstveno usmjerena na građanstvo te male i srednje poduzetnike, no istodobno i na tradicionalne velike partnere s kojima posluje u regijama gdje je snažno prisutna - Rijeci, Zagrebu i Bjelovaru. Banka se posebno ističe inovativnošću i brigom za klijente, pri čemu permanentno radi na proširenju usluga za klijente kao i stalnom podizanju razine kvalitete. Tako je, primjerice, Erste & Steiermärkische banka prva u Hrvatskoj uvela brojne inovacije u poslovanje, poput kreiranja Facebook stranice i prve virtualne poslovnice hrvatske banke na toj društvenoj mreži. Inovativnost se očitovala i u novim proizvodima i tehnologijama, poput usluge Erste Maestro Plus, posebnih modela stambenih kredita s tzv. ostatkom vrijednosti, prve debitne Maestro kartice s modernom, chip-tehnologijom. Jedinstveni investicijsko-štedni proizvodi kreirani prema suvremenim svjetskim trendovima te potrebama i interesima klijenata, također su našli mjesto među brojnim financijskim uslugama koje banka nudi na hrvatskom tržištu. Tome treba pridodati i nezaobilaznu i prepoznatljivu dječju štednju Medo Štedo, kao i specijaliziranu poslovnicu za djecu - "Medo Štedo brlog", ali i dvije Erste Club poslovnice specijalizirane za mlade, po

jednu u Zagrebu i Rijeci. Banka i dalje nastoji pratiti trendove modernog poslovanja pa se uključila i u trendove u segmentu tzv. pametnih telefona ponudivši svim sadašnjim i potencijalnim klijentima besplatne aplikacije za iPhone i Android operativne sustave, a u čemu se posebno ističe usluga "Slikaj i plati", a odnedavno i aplikacija "Redomat" i "Erste Wallet".

Od samog početka, 2000. godine, Erste & Steiermärkische Bank d.d. dio je međunarodne Erste Group, koja potječe još od davne 1819. godine i prve Austrijske štedne banke. Od 1997. godine Erste grupa se razvila u jednog od najvećih pružatelja financijskih usluga u Srednjoj i Istočnoj Europi, s 46.600 zaposlenih koji uslužuju 15,8 milijuna klijenata, u 2.500 poslovnica u 7 država (Austriji, Češkoj, Slovačkoj, Rumunjskoj, Mađarskoj, Hrvatskoj i Srbiji).[9]

2.2. Pokazatelj odnosa u bilanci banke

Glavni izvor informacija o poslovanju banaka, ali i tvrtki su financijska izvješća. Informacije koje sadrže ta izvješća vezana su uz njihove aktivnosti u prošlosti i uz njihove rezultate kojima se služi korisnik tih informacija. Cilj tih financijskih izvještaja je pružiti zainteresiranim korisnicima relevantne i pouzdane informacije o financijskom položaju poduzeća, te uspješnosti poslovanja. Financijski izvještaji su izvještaji o financijskom stanju i financijskom prometu nekog poslovnog subjekta. Mjerenje performansi banaka tradicionalno se temelji na analizi financijskih pokazatelja (financijskih omjera). Međutim, bez obzira koliko se i kojih pokazatelja koristi, još nije razvijen model koji bi u potpunosti zadovoljavao potrebe za analizom i vrednovanjem efikasnosti poslovanja banaka.[10]

Financijski izvještaji ne pružaju sve informacije koje su potrebne korisnicima pri donošenju ekonomskih odluka, jer oni uglavnom daju sliku financijskih učinaka prošlih događaja i ne pružaju nefinancijske informacije. Oni korisnici koji teže ocijeniti rad menadžmenta ili njegovu odgovornost čine to kako bi omogućili donošenje ekonomskih odluka.[11]

[9] https://www.erstebank.hr/ (na dan 01.06.2016.)
[10] Hunjak,T.„Jakovčević,D. Višekriterijski modeli za rangiranje i uspoređivanje banaka,znanstveni rad,2003.
[11] Belak, V. Osnove profesionalnog računovodstva. Split : Veleučilište, 2002.

Temeljna financijska izvješća u Hrvatskoj prema ZOR-u (Zakonu o računovodstvu) su :[12]

1. Bilanca
2. Račun dobiti i gubitka
3. Izvješća o novčanom toku
4. Bilješke uz financijska izvješća
5. Izvješće o promjeni glavnice

Bilanca je jedan od temeljnih financijskih izvještaja. Prema Hrvatskim standardima financijskog izvještavanja, bilanca je sustavni pregled imovine, obveza i kapitala na određeni datum, najčešće na datum završetka fiskalne godine.[13] Imovina poduzeća još se naziva i aktiva, a izvori (kapital i obveze) te imovine pasiva.

Imovina čini ekonomske resurse od kojih poduzeće može ostvarivati određene ekonomske koristi. Imovina se dijeli na dva osnovna oblika: kratkotrajna i dugotrajna imovina. Kratkotrajnu imovinu čini onaj dio ukupne imovine za koji se očekuje da će se pretvoriti u novac u razdoblju kraćem od godine dana. Dugotrajna imovina je onaj dio ukupne imovine koji duže ostaje vezan u postojećem obliku i koji se postepeno pretvara u novac u razdoblju dužem od godine dana.

Kratkotrajna imovina dijeli se na:
- novac (u banci, u blagajni),

- potraživanja (od kupaca, od zaposlenih, od države, ostalo),

- financijska imovina (dani kratkoročni krediti, depoziti i kaucije, kupljeni vrijednosni papiri, ostala kratkoročna ulaganja),

- zalihe (sirovina i materijala, proizvodnje gotovih proizvoda, trgovačke robe).

Dugotrajna imovina dijeli se na:
- materijalna (zemljišta, šume, zgrade, postrojenja i oprema, alati, vozila itd.),

- nematerijalna (osnivački izdatci, izdatci za istraživanje i razvoj, patenti, licence i sl.),

[12] Vidučić, Lj.; Financijski menadžment,V. izdanje,Zagreb,2006
[13]Gulin,D.: "Primjena hrvatskih standarda financijskog izvještavanja", Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, 2008., str. 35.

- financijska (dani kredit, depoziti i kaucije, vrijednosni papiri, itd.),
- potraživanja (prodaja na kredit, od povezanih poduzeća, ostala potraživanja).[14]

Obveze i kapital

Sva imovina kojom neko poduzeće raspolaže ima izvore od kojih je pribavljena. Izvori imovine su: vlasnici, druga poduzeća, banke i druge financijske institucije, građani itd.

Zavisno od toga tko je uložio imovinu u poduzeće, sam vlasnik ili neki drugi privredni subjekt. Izvori imovine dijele se prema vlasništvu na:
- vlastite izvore (kapital ili glavnica),
- tuđe izvore (obveze).

Obveze se u bilanci prikazuju kao kratkoročne i dugoročne. Kratkoročne obveze čine one obveze koje je potrebno podmiriti u kraćem roku koji nije duži od godine, kao npr. obveze prema dobavljačima za materijal, robu i sl. Dugoročne obveze obuhvaćaju obveze koje dospijevaju na naplatu u roku duljem od godine dana, npr. dugoročni kredit od banke.
Razliku između ukupne imovine i ukupnih obveza čini vlastiti kapital ili glavnicu. Kapital je vlastiti izvor imovine i s aspekta dospijeća trajni izvor. Kapital se primarno formira ulaganjem vlasnika pri samom osnivanju poduzeća. Kapital se također uvećava u slučaju uspješnog poslovanja.[15]

Bilanca je zapravo prikaz financijske pozicije tvrtke na točno određeni dan. Bilanca prikazuje financijsku sliku gospodarskog subjekta na kraju obračunskog razdoblja. Ravnoteža u tom financijskom izvještaju ostvaruje se ako je :

aktiva = pasiva

tj.

imovina = obveze + kapital

[14] Žager L., Žager K., Analiza financijskih izvještaja, Masmedia, str. 37, Zagreb, 1999.
[15] Žager L., Žager K., Analiza financijskih izvještaja, Masmedia, str. 38, Zagreb, 1999.

Za razliku od bilance koja ima svojstvo statičnosti, tj. ona se izračunava na točno određeni dan, račun dobiti i gubitka je prikaz prihoda, rashoda i financijskog rezultata u određenom vremenskom razdoblju, te stoga nema jednako svojstvo kao i bilanca. Najvažnija zadaća koju vrši račun dobiti i gubitka je izračun profitabilnosti gospodarskog subjekta tijekom određenog vremenskog razdoblja.

Podjela prihoda i rashoda prema ZOR-u(Zakonu o računovodstvu):[16]

Prihodi se dijele na:

1. poslovne prihode
2. prihode od financiranja
3. izvanredne prihode

Rashodi se s druge strane dijele na :

1. poslovne rashode
2. financijske rashode
3. izvanredne rashode

Ovaj financijski izvještaj nam pomaže kako bismo mogli odrediti ostvaruje li banka dobit ili gubitak tj. financijski rezultat. Možemo reći kako se to određuje na temelju razlike rashoda i prihoda u kojima se ostvaruju ove relacije:

$$prihodi - rashodi = financijski\ rezultat$$

tj.

$$prihodi > rashodi = dobit$$

$$prihodi < rashodi = gubitak$$

U nastavku rada slijedi analiza putem pokazatelja kojom će se analizirat temeljna financijska izvješća kako bismo došli do rezultata istraživanja.

[16] Vidučić, Lj. :Financijski menadžment,V. izdanje,Zagreb,2006

Financijski pokazatelji se formiraju da bi se stvorile informacije potrebne za donošenje važnih poslovnih odluka. Oni predstavljaju indikatore kao odnose između određenih veličina prikazujući na taj način uspješnost poslovanja banke.[17]

Postoje dvije vrste analize putem pokazatelja koje ćemo koristiti u nastavku rada:

1. Pokazatelji odnosa u bilanci
2. Pokazatelji odnosa u računu dobiti i gubitka.

2.2.1. Pokazatelji odnosa u bilanci

U radu će se koristiti samo neki od pokazatelja odnosa u bilanci banke, a to su :

1. Pokazatelji profitabilnosti
2. Pokazatelji likvidnosti
3. Pokazatelji zaduženosti

Pokazatelji profitabilnosti izražavaju snagu zarade poduzeća, odnosno pokazuju ukupni efekt likvidnosti, upravljanja imovinom i dugom na mogućnost ostvarenja profita.[18]

Pokazatelj povrata na ukupnu imovinu (eng. Return on assets- ROA) pokazuje sposobnost poduzeća da korištenjem raspoložive imovine ostvari dobit. ROA stavlja u odnos dobit poslije oporezivanja i prosječnu ili ukupnu aktivu. Pokazuje ukupnu profitabilnost banke, odnosno efikasnost menadžmenta u upravljanju bankom. Smatra se da je banka uspješna ako je prinos na imovinu veći od 1 posto.

Profitabilnost poslovanja (ROA) = Neto dobit / Ukupna aktiva

Pokazatelj povrata na vlastiti kapital pokazuje snagu zarade u odnosu na ulaganja dioničara, a računa se dijeljenjem neto dobitka s vlastitim kapitalom – običnom dioničkom glavnicom.

[17] Pervan, I.: Menadžersko računovodstvo, skripta, Split, ak.g. 2007./2008.
[18] Kundid A.: Indikatori profitabilnosti bankovnog poslovanja, Računovodstveno- financijske informacije, broj 12,2010., str. 17

Kada je osnovni cilj poslovanja povećanje vrijednosti za dioničare, ovaj pokazatelj je najbolja pojedinačna mjera uspješnosti gospodarskog subjekta u ispunjenju tog cilja.[19]

Povrat na kapital (ROE) = Neto dobit / Vlastiti kapital

Pokazatelj povrata na vlastiti kapital (ROE) također predstavlja snagu zarade tvrtke. Povrat na kapital pokazuje kolika je dobit na 100 kuna uloženog kapitala. ROE je i dobar pokazatelj brzine rasta poduzeća jer se smatra da ukupni prihodi ne mogu rasti po stopi većoj od trenutnog iznosa ROE. Predstavlja najbolju mjeru uspješnosti u ostvarenju dodane vrijednosti za dioničare.

Tablica 1: *Kretanje ROA i ROE Erste banke u razdoblju od 2007.-2014. godine*

Godina	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**
ROA	**1,48**	**1,73**	**1,24**	**1,21**	**1,14**	**0,83**	**0,11**	**0,39**
ROE	**15,25**	**15,44**	**10,94**	**10,14**	**10,15**	**6,94**	**0,99**	**3,23**

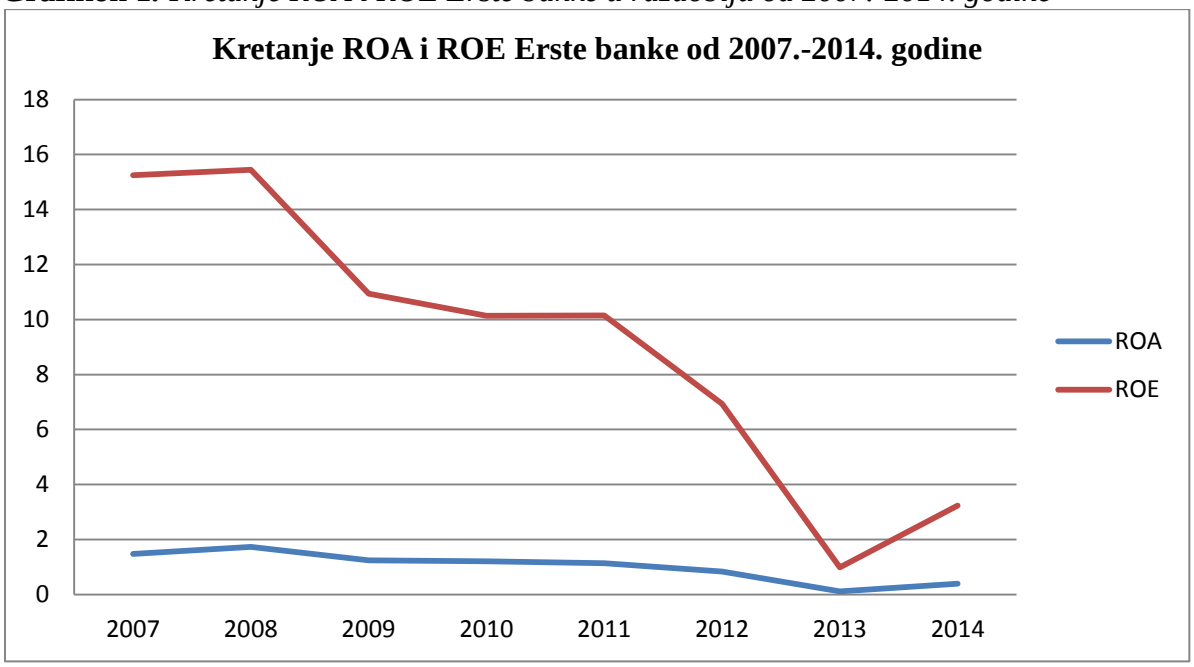
Izvor: Izrada autora na temelju financijskih izvještaja banke

Na temelju tablice 1. možemo primijetiti pad oba pokazatelja profitabilnosti kroz godine. Možemo primijetiti najveće padove pokazatelja ROA u 2012. i u 2013. godini, usporedno i s padom pokazatelja ROE. Iz tablice 1. vidimo da je ROA relativno stabilan. U 2007. godini ROA iznosi 1,48 posto, dok se najveći rast bilježi 2008. godine i iznosi 1,73kn . Nakon te godine može se uočiti pad ROA na 1,24kn, te se taj pad nastavlja kroz 2010., 2011., godinu i iznosi 1,14kn, te sada na 100 kunu korištene imovine banka ostvaruje 1,14 kn. Smatra se da je banka uspješna ako je ROA veći od 1kn, što vidimo da do 2012. godine vrijedi za Erste banku. U 2012. godini ROA iznosi 0,83kn što govori da sada na 100 kunu banka ostvaruje 83 lipe što pokazuje da se poslovanje banke pogoršalo u odnosu na prethodne godine. Možemo primijetiti kako je najniža razina oba pokazatelja bila 2013. godine gdje nam podaci govore kako je te godine na 100 uloženih kuna aktive ostvarila 0,11 kn neto dobiti (ROA), odnosno da je na svakih 100 kuna uloženih vlastitog kapitala ostvari 0.99 kn neto dobiti (ROE). Na razini iz 2014. godine vidimo blagi rast te banka ostvaruje 0.39 kuna neto dobiti na 100 uloženih kuna aktive (ROA), odnosno 3,23 kn neto dobiti na 100 kuna uloženog vlastitog kapital (ROE).

[19] Vidučić, Lj. Financijski menadžment,V. izdanje, str. 394.Zagreb,2006

U nastavku slijedi grafikon 1. koji prikazuje grafički kretanje oba pokazatelja, te se može primijetiti kako su svoje dno oba pokazatelja dosegla 2013.godine, pa sada kreću uzlaznom putanjom što je primjetno već u 2014.godini.

Grafikon 1: *Kretanje ROA i ROE Erste banke u razdoblju od 2007.-2014. godine*



Izvor: Izrada autora na temelju financijskih izvještaja banke

Pokazatelji likvidnosti se koriste za procjenu sposobnosti gospodarskog subjekta da udovolji kratkoročnim obvezama kratkotrajnom imovinom. Putem ovog pokazatelja pokazat ćemo kolika je razina primljenih depozita koji su nadalje plasirani u kredite na tržištu.[20]

Odnos danih kredita i primljenih depozita = Dani krediti / Primljeni depoziti

Tablica 2: *Pokazatelj likvidnosti koji pokazuje odnos danih kredita i primljenih zajmova u razdoblju od 2007.-2014. godine*

Godina	2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.
Odnos danih kredita i primljenih depozita	0,99	1,05	1,06	1,15	1,24	1,23	1,17	1,07

Izvor: Izrada autora na temelju financijskih izvještaja banke

Iz tablice 2. možemo primijetiti kako tijekom krize dolazi do rasta omjera danih kredita i primljenih depozita, te je čak i veća količina danih kredita nego primljenih depozita. Najvišu razinu ovaj pokazatelj ima 2011. godine kada je na razini 1.24, dok je najmanji u 2007. godini

[20] Vidučić, Lj. Financijski menadžment,V. izdanje, str. 383.,Zagreb,2006

gdje iznosi 0,99. U posljednjoj promatranoj godini možemo primijetiti da je ovaj pokazatelj na razini od 1.07 što nam govori kako je udio danih kredita i potraživanja prema klijentima za 7% veći od obveza za depozite.

Pokazatelji zaduženosti se koriste za procjenu financijskog rizika banke. Oni dakle daju informaciju o tome kontrolira li banka svoje dugove. Kao primjeri korišteni su odnos obveza i ukupne aktive, te koeficijent vlastitog financiranja.[21] Odnos obaveza i ukupne aktive pokazuje koliki udio sredstava su osigurali vjerovnici (kreditori). Računa se dijeljenjem ukupnih obveza s ukupnom imovinom.[22]

Odnos obveza i ukupne aktive = Ukupne obveze / Ukupna imovina

Pokazatelji vlastitog financiranja govore u kojem omjeru vlastito financiranje sudjeluje u poslovanju poduzeća. Pokazatelj je to bolji što je koeficijent veći od 0,50, jer onda to znači da se poduzeće financira iz vlastitih izvora s više od 50%. Odnosno, možemo reći što je stupanj samofinanciranja veći to su vjerovnici sigurniji i rizik poslovanja s tim poduzećima je manji.[23]

Odnos kapitala i ukupne aktive = Kapital / Aktiva

Tablica 3*: Pokazatelji zaduženosti Erste banke u razdoblju od 2007.- 2014. godine*

Godina	2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.
Odnos obveza i ukupne aktive	0,903	0,888	0,887	0,881	0,888	0,881	0,885	0,881
Koeficijent vlastitog financiranja	0,10	0,11	0,11	0,12	0,11	0,12	0,11	0,12

Izvor: Izrada autora na temelju financijskih izvještaja banke

Na temelju podataka iz tablice 3. jasno je kako se tijekom godina niti jedan niti drugi pokazatelj zaduženosti nije previše mijenjao te je bio je stabilan. Primjetno je samo kako je početna razina iz 2007. godine za pokazatelj vezan uz odnos obveza i ukupne aktive bio najviši (0.903), a sukladno tome i koeficijent vlastitog financiranja najniži (0.10). Odnos obveza i ukupne aktive narednih godina varira između 0,888 i 0.881, a koeficijent vlastitog financiranja između 0,11 i 0.12.

[21] Vidučić, Lj. Financijski menadžment,V. izdanje, str. 389.,Zagreb,2006.
[22] Vukoja B.: Primjena analize financijskih izvješća pomoću ključnih financijskih pokazatelja kao temelj donošenja poslovnih odluka, str. 8.
[23] Vukoja B.: Primjena analize financijskih izvješća pomoću ključnih financijskih pokazatelja kao temelj donošenja poslovnih odluka, str. 9.

2.2.2. Pokazatelji odnosa u računu dobiti i gubitka banke

Uspješnost poslovanja Erste banke vidljiva je iz njenog računa dobiti i gubitka koji prikazuje profitabilnost poslovanja banke u određenom vremenskom razdoblju.

U ovom radu koristi će se samo neki od pokazatelja odnosa u računu dobiti i gubitka banke, a to su :

1. Pokazatelji ekonomičnosti
2. Pokazatelji marže.

Pokazatelji ekonomičnosti u omjer stavljaju pojedine kategorije prihoda i rashoda. Poželjna je što veća vrijednost tih pokazatelja, odnosno minimalno 1.[24]

Ekonomičnost ukupnog poslovanja = Ukupni prihodi / Ukupni rashodi

Odnos kamatnih prihoda i rashoda = Kamatni prihodi / Kamatni rashodi

Udio neto prihoda od naknada u uk. prihodima = Neto prihod od naknada / Ukupni prihod

Tablica 4: *Pokazatelji ekonomičnosti Erste banke u razdoblju od 2007.-2014.*

Godina	2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.
Ekonomičnost ukupnog poslovanja	1,44	1,46	1,37	1,58	1,57	1,48	1,69	1,70
Odnos kamatnih prihoda i rashoda	1,89	1,735	1,680	2,221	2,141	1,906	2,115	2,270
Udio neto kamatnih prihoda u ukupnim prihodima	0,101	0,090	0,078	0,095	0,079	0,076	0,091	0,081

Izvor: Izrada autora na temelju financijskih izvještaja banke

Iz tablice 4. vidljivo je kako je ekonomičnost ukupnog poslovanja tj. odnos ukupnih prihoda i rashoda rastao i tijekom razdoblja te dosegao svoj vrhunac 2014. godine kada je iznosio 1,70 dok je najniži bio 2007. godine kada je iznosio 1,44. Udio neto kamatnih prihoda u ukupnih prihodima također je varirao od 10% 2007. godine pa sve do najnižih vrijednosti od 7% 2009.

[24] Žager, K., Žager, L.; Analiza financijskih izvještaja, MASMEDIA,str.179., Zagreb, 1999.

godine. Možemo primijetiti kako su u vrijeme krize rasli prihodi za razliku od rashoda, te kriza nije zahvatila taj segment poslovanja. Odnos kamatnih prihoda i rashoda se također mijenjao tijekom godina, pa je 2009. godine bio najmanji (1.68), a 2014. godine najveći (2,27).

Pokazatelji marže: Kamatna marža stavlja u odnos neto kamatni prihod i prosječnu ukupnu aktivu pri čemu je neto kamatni prihod razlika između kamatnih prihoda i kamatnih rashoda. Kamatna marža mjeri bankovnu uspješnost u ovladavanju kamatnim rizikom i rizikom likvidnosti. Osim toga prosječne neto kamatne marže pokazuju intenzitet konkurencije u bankarskom sektoru i stupanj razvijenosti financijskog posredništva u promatranom gospodarstvu. Niže neto kamatne marže upućuju na efikasnije ponašanje banaka, dok su više neto kamatne marže najčešće odlika banaka koje slabije upravljaju nekamatnim troškovima.[25]

Marža kamata = Neto prihod od kamata / Ukupna aktiva

Marža naknada stavlja u odnos neto prihod od naknada i prosječnu ukupnu aktivu pri čemu je neto prihod od naknada razlika između prihoda od naknada i rashoda od naknada.[26]

Marža naknada = Neto prihod od naknada / Ukupna aktiva

Tablica 5: *Pokazatelji marže Erste banke u razdoblju od 2007.-2014. godine*

Godina	2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.
Marža kamata	0,027	0,025	0,029	0,032	0,032	0,028	0,026	0,027
Marža naknada	0,007	0,007	0,007	0,007	0,005	0,005	0,006	0,006

Izvor: Izrada autora na temelju financijskih izvještaja banke

Pokazatelji prikazani u ovoj tablici najčešće se izražavaju u postocima. Stoga, možemo vidjeti kako se marža kamata mijenjala tijekom godina od najniže 2008. godine (2,5 %), pa sve do najviše 2010. i 2011. godine kada je iznosila 3,2 %.

Marža naknada ne oscilira značajno u promatranom razdoblju. Od 2007. do 2010. godine vrijednost joj je 0,007 što je ujedno i najveća vrijednost. Najnižu vrijednost ima 2011. i 2012. godine kada iznosi 0,005. Te ponovno počinje rasti 2013. i 2014. godine na 0,006.

[25] Kundid A.: Indikatori profitabilnosti bankovnog poslovanja, Računovodstveno- financijske informacije, broj 12, 2010. str. 17

[26] Sever S: Financijski pokazatelji banaka, prezentacija, Ekonomski fakultet Zagreb, 2009.

2.3. Poslovanje Erste banke od 2007.-2014. godine

U ovom dijelu uz korištenje bilance i računa dobiti i gubitka kao financijskih izvješća napravljena je tablica koja prezentira sve te prikupljene podatke kako bismo mogli provesti analizu poslovanja banke u tom razdoblju.

Tablica 6*: Poslovanje Erste banke u razdoblju od 2007.-2014. godine*

Godina	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**
Ukupna aktiva	40.378	45.567	48.941	50.509	57.035	58.519	60.125	60.180
Ukupni kapital	3.928	5.105	5.547	6.017	6.413	6.963	6.887	7.190
Ukupne obveze	36.450	40.462	43.394	44.492	50.622	51.556	53.238	52.990
Neto prihodi od kamata	1.087	1.141	1.408	1.606	1.740	1.649	1.590	1.609
Neto prihod od naknada	301	326	327	334	309	316	353	381
Ukupni prihodi	2.985	3.629	4.181	3.527	3.899	4.167	3.871	4.731
Ukupni rashodi	2.078	2.484	3.061	2.232	2.491	2.816	2.291	2.784
Neto dobit	599	788	607	610	651	483	68	232
Zajmovi i potraživanja od klijenata	25.651	29.966	32.448	35.019	39.425	38.844	41.040	39.607
Obveze prema klijentima	25.929	28.516	30.528	30.328	31.787	31.618	37.015	37.151
Dionički kapital i rezerve	3.928	5.105	5.547	6.017	6.413	6.963	6.887	7.190

Izvor: Izrada autora na temelju financijskih izvještaja banke

Iz tablice 6. vidljivo je promjenjivo kretanje većine promatranih stavki. Ukupna aktiva raste, te je u promatranom razdoblju narasla za 20mlrd kuna u odnosu na početnu godinu. Kapital je narastao također u promatranom razdoblju za 3,2mlrd kuna, dok su obveze bilježile najveću promjenu 2011. godine kada su naglo narasle za 6,1mlrd kuna. Neto prihod od kamata kao i neto prihod od naknada nije se puno mijenjao tijekom promatranog razdoblja. Neto prihod od kamata u prvoj promatranoj godini iznosio je 1.087 mil kn, dok je u posljednjoj promatranoj godini iznosio 1.609 mil. kn. Neto prihod od naknada od početne do posljednje promatrane godine je narastao za 80 mil. kn odnosno s početnih 301 na 381 mil. kn. Prema financijskim izvješćima može se primijetiti kako je neto dobit naglo pala nakon 2011. godine kada iznosi svega 483mil. Glavnim razlogom za takvu situaciju smatra se smanjenje prihoda i povećanje rezervacija za nenaplative kredite, a pad i u 2012. godine objašnjava se neprekidnim slabljenjem gospodarstva, porastom nenaplativih potraživanja, te još strožom regulacijom koja je utjecala na cjelokupni rezultat bankarskog sektora koji je u 2013. godini zabilježio pad na 68mil kuna.

2.4. Horizontalna analiza

Analize financijskih izvještaja najčešće se prave kao usporedba brojčanih pokazatelja iz izvještaja dobivenih na kraju poslovne godine. Time se omogućava usporedba tijekom određenog razdoblja. Takva analiza pokazuje promjene na pojedinim stavkama i naziva se horizontalnom analizom. Uvijek je bolje da se uspoređuju pozicije za veći broj godina, kako bi se mogle uočiti određene tendencije i na temelju njih donositi kvalitetnije poslovne planove i odluke za buduća razdoblja.[27]

U ovom dijelu rada radit će se horizontalne analize i bilance i računa dobiti i gubitka za razdoblje od 2011.–2014. godine. U tablicama je objašnjena apsolutna i relativna razlika između pojedinih stavki unutar bilanci i računa dobiti i gubitka kako bismo mogli zamijetiti na koje je stavke posebno mijenjale i na koji su način reagirale banke u toj novoj situaciji. Za razmatranje je uzeto razdoblje od 4 godine tako da će raspon podataka biti dovoljno velik kako bi uvidjeli te promjene koje su se dogodile.

Za izračunavanje promjena i njihovo uspoređivanje možemo uzeti jednu godinu kao baznu godinu, pa onda uspoređivati ostale dostupne godine s tom baznom. No u ovom radu je korištena usporedba svake pojedinačne godine s onom prethodnom.

Kod ovakve vrste analize moguć je problem ako dođe do značajnijih promjena u politici bilanciranja, zatim kod promjena obračunskih sustava kod izrade tih istih financijskih izvještaja ili ako se dogodi veća inflacija. U tim slučajevima ovakva vrsta analize i ne bi imala nekog smisla.

Horizontalna analiza podrazumijeva usporedni prikaz glavnih stavki iz bilance, računa dobiti i gubitka te ostalih izvještaja za više uzastopnih godina, uz izračun apsolutnih i relativnih promjena. Za izračun relativnih promjena pojedinih stavki koristi se sljedeća formula stope promjene verižnih indeksa[28]:

Promjena (%) =[(Iznos tekuće godine / Iznos prethodne godine) – 1)] *100

U nastavku rada bit će prezentirane horizontalne analize bilance i računa dobiti i gubitka Erste banke za razdoblje od 2011. – 2014. godine.

[27] Bolfek M.,Knežević S., B,Stanić, Vertikalna i horizontalna financijska analiza poslovanja tvrtke, pregledni rad,2012.
[28] Pervan, I.: Menadžersko računovodstvo, skripta, Split, ak.g. 2007./2008.

Tablica 7. prikazuje horizontalnu analizu bilance Erste banke 2012. godine u odnosu na 2011. godinu. Najveći rast bilježe izdane obveznice i ostala pozajmljena sredstva u iznosu od 10000%, dok najveće smanjenje ima financijska imovina iskazana po fer vrijednostima kroz račun dobiti i gubitka. Ukupne obveze i kapital su povećani su za 2.60 %.

U imovini najveći rast bilježe repo krediti u iznosu od 472,61% ili 742 mil. kn. A najveće smanjenje imamo kod odgođene porezne imovine koja je pala za 59,14%. Što se tiče obveza, najveći rast imaju već spomenute izdane obveznice i ostala pozajmljena sredstva, a najveći pad imamo kod financijske obveze iskazane po fer vrijednosti kroz račun dobiti i gubitka. Kod kapitala nije došlo do novog dioničkog kapitala, pa nema promjene u toj stavci, a najveći rast bilježe ostale kapitalne rezerve u iznosu od 550 mil. kn, dok su ostale rezerve pale za 6 mil. kn.

Tablica 7: *Horizontalna analiza bilance Erste banke za 2011. i 2012. godinu*

Bilanca Erste banke (u mil kuna)	2011.	2012.	Apsolutna razlika	Relativna razlika
IMOVINA				
Novac i sredstva kod Hrvatske narodne banke	7.054	7.459	405	5,74%
Potraživanja od drugih banaka	1.438	2.507	1.069	74,34%
Repo krediti	157	899	742	472,61%
Derivatna financijska imovina	92	113	21	22,83%
Financijska imovina namijenjena trgovanju	122	56	-66	-54,10%
Financijska imovina iskazana po fer vrijednosti kroz račun dobiti i gubitka	50		-50	-100,00%
Krediti i potraživanja od klijenata	39.425	38.844	-581	-1,47%
Financijska imovina raspoloživa za prodaju	6.315	5.956	-359	-5,68%
Financijska imovina koja se drži do dospijeća	366	685	319	87,16%
Ulaganja u ovisna i pridružena društva	1.300	1.300	0	0,00%
Nekretnine i oprema	407	386	-21	-5,16%
Nematerijalna imovina	50	47	-3	-6,00%
Odgođena porezna imovina	93	38	-55	-59,14%
Ostala imovina	166	229	63	37,95%
Ukupno imovina	**57.035**	**58.519**	**1.484**	**2,60%**
OBVEZE				
Obveze prema drugim bankama	16.882	16.830	-52	-0,31%
Primljeni repo krediti	500	1.369	869	173,80%
Derivatne financijske obveze	136	147	11	8,09%
Financijske obveze iskazane po fer vrijednosti kroz račun dobiti i gubitka	40		-40	-100,00%
Obveze prema klijentima	31.787	31.618	-169	-0,53%
Izdane obveznice i ostala pozajmljena sredstva	3	303	300	10000,00%
Ostale obveze	330	325	-5	-1,52%
Rezerviranja	98	116	18	18,37%
Izdani podređeni instrumenti	846	848	2	0,24%
Ukupno obveze	**50.622**	**51.556**	**934**	**1,85%**
Kapital	**1.698**	**1.698**	**0**	**0,00%**
Dionički kapital	1.802	1.802	0	0,00%
Kapitalna dobit	2.905	3.212	307	10,57%
Zadržana dobit	-83	166	249	-300,00%
Ostale rezerve	91	85	-6	-6,59%
Ostale kapitalne rezerve	6.413	6.963	550	8,58%
UKUPNO KAPITAL	**6.413**	**6.963**	**550**	**8,58%**
Ukupno obveze i kapital	**57.035**	**58.519**	**1.484**	**2,60%**

Izvor: Izrada autora na temelju financijskih izvještaja banke

Tablica 8: *Horizontalna analiza bilance Erste banke za 2012. i 2013. godinu*

Bilanca Erste banke (u mil kuna)	2012.	2013.	Apsolutna razlika	Relativna razlika
IMOVINA				
Novac i sredstva kod centralnih banaka	7.459	7.695	236	3,16%
Potraživanja od drugih banaka	2.507	2.534	27	1,08%
Repo krediti	899	1.002	103	11,46%
Derivatna financijska imovina	113	86	-27	-23,89%
Financijska imovina namijenjena trgovanju	56	125	69	123,21%
Krediti i potraživanja od klijenata	38.844	39.912	1.068	2,75%
Financijska imovina raspoloživa za prodaju	5.956	6.146	190	3,19%
Financijska imovina koja se drži do dospijeća	685	499	-186	-27,15%
Ulaganja u ovisna i pridružena društva	1.300	1.272	-28	-2,15%
Nekretnine i oprema	386	348	-38	-9,84%
Nematerijalna imovina	47	37	-10	-21,28%
Ulaganja u nekretnine		20	20	
Odgođena porezna imovina	38	37	-1	-2,63%
Ostala imovina	229	422	193	84,28%
Ukupno imovina	**58.519**	**60.125**	**1.606**	**2,74%**
OBVEZE				
Obveze prema drugim bankama	16.830	16.652	-178	-1,06%
Primljeni repo krediti	1.369	647	-722	-52,74%
Derivatne financijske obveze	147	89	-58	-39,46%
Obveze prema klijentima	31.618	34.175	2.557	8,09%
Izdane obveznice i ostala pozajmljena sredstva	301	302	1	0,33%
Ostale obveze	325	324	-1	-0,31%
Rezerviranja	116	191	75	64,66%
Izdani podređeni instrumenti	848	858	10	1,18%
Ukupno obveze	**51.556**	**53.238**	**1.682**	**3,26%**
Kapital				
Dionički kapital	1.698	1.698	0	0,00%
Kapitalna dobit	1.802	1.802	0	0,00%
Zadržana dobit	3.212	3.133	-79	-2,46%
Ostale rezerve	166	169	3	1,81%
Ostale kapitalne rezerve	85	85	0	0,00%
Ukupno kapital raspoloživ dioničarima Banke	**6.963**	**6.887**	**-76**	**-1,09%**
UKUPNO KAPITAL	**6.963**	**6.887**	**-76**	**-1,09%**
Ukupno obveze i kapital	**58.519**	**60.125**	**1.606**	**2,74%**

Izvor: Izrada autora na temelju financijskih izvještaja banke

Tablica 8. prikazuje horizontalnu analizu bilance Erste banke 2013. godine u odnosu na 2012. godinu. Najveći povećanje ima financijska imovina namijenjena trgovanju koja ima rast od 123,21% . Najveće smanjenje imaju primljeni repo krediti koji su u padu za 52,74%. Ukupne obveze i kapital povećani su za 2,74 %.

U imovini najveći rast imamo kod već spomenute financijske imovine namijenjen trgovanju dok je najveće smanjenje kod financijske imovine koja se drži do dospijeća u iznosu od 27,15%. Što se tiče obveza, najveći rast imaju rezerviranja u iznosu od 64,66% dok najveće smanjenje imaju primljeni repo krediti koji su u padu od 52,74%. Kod kapitala nije došlo do promjene u dioničkom kapitalu i kapitalnoj dobiti, dok zadržana dobit bilježi pad od 79 mil. kn ili 2,46%.

Tablica 9. prikazuje horizontalnu analizu bilance Erste banke 2014. godine u odnosu na 2013. godinu. Najveću relativnu razliku u odnosu na godinu 2013. možemo primijetiti kod ostale imovine koja se drži radi trgovanja i njen porast je od 205,60%. Najveće smanjenje imamo kod odgođene porezne imovine koja je u padu od 48,65%. Ukupna obveze i kapital povećani su za 0,09%.

U imovini najveći rast i pad imamo kod već spomenutih stavki bilance. Što se tiče obveza, najveći rast imamo kod rezerviranja koja su u odnosu na prošlu godinu porasla za 11,52% dok najveće smanjenje imamo kod depozita od banaka koji su u padu od 3,05%. Kod kapitala došlo je do promjene kapitala raspoloživog vlasniku matičnog društva u iznosu od 303 mil. kuna ili porast od 4,40%.

Tablica 9: *Horizontalna analiza bilance Erste banke za 2013. i 2014. godinu*

Bilanca Erste banke (u mil kuna)	2013.	2014.	Apsolutna razlika	Relativna razlika
IMOVINA				
Novac i novčana sredstva	3.949	4.035	86	2,18%
Financijska imovina koja se drži radi trgovanja	211	478	267	126,54%
Derivati	86	96	10	11,63%
Ostala imovina koja se drži radi trgovanja	125	382	257	205,60%
Financijska imovina raspoloživa za prodaju	6.146	6.693	547	8,90%
Financijska imovina koja se drži do dospijeća	499	1.288	789	158,12%
Krediti i potraživanja od kreditnih institucija	6.143	5.720	-423	-6,89%
Krediti i potraživanja od klijenata	39.912	39.607	-305	-0,76%
Nekretnine i oprema	347	338	-9	-2,59%
Ulaganja u nekretnine	20	19	-1	-5,00%
Nematerijalna imovina	37	48	11	29,73%
Ulaganja u ovisna društva	1.243	1.317	74	5,95%
Ulaganja u zajedničke pothvate i pridružena društva	29	38	9	31,03%
Tekuća porezna imovina	88	85	-3	-3,41%
Odgođena porezna imovina	37	19	-18	-48,65%
Ostala imovina	336	495	159	47,32%
Ukupna imovina	**60.125**	**60.180**	**55**	**0,09%**
OBVEZE i kapital				
Financijske obveze koje se drže radi trgovanja	89	94	5	5,62%
Derivati	89	94	5	5,62%
Financijske obveze koje se vrednuju amortiziranom trošku	52.631	52.323	-308	-0,59%
Depoziti od banaka	14.610	14.165	-445	-3,05%
Depoziti od klijenata	37.125	37.151	26	0,07%
Izdani dužnički vrijednosni papiri	931	933	2	0,21%
Ostale financijske obveze	75	74	-1	-1,33%
Rezerviranja	191	213	22	11,52%
Ostale obveze	327	360	33	10,09%
Ukupni kapital	**6.887**	**7.190**	303	4,40%
Raspoloživi vlasniku matičnog društva	6.887	7.190	303	4,40%
Ukupne obveze i kapital	**60.125**	**60.180**	**55**	**0,09%**

Izvor: Izrada autora na temelju financijskih izvještaja banke

Tablica 10: *Horizontalna analiza rn dobiti i gubitka Erste banke za 2011. i 2012. godinu*

Račun dobiti i gubitka (u mil. kuna)	**2011.**	**2012.**	**Apsolutna razlika**	**Relativna razlika**
Prihod od kamata	3.265	3.470	205	6,28%
Rashod od kamata	1.525	1.821	296	19,41%
Neto prihod od kamata	**1.740**	**1.649**	**-91**	**-5,23%**
Prihod od naknada i provizija	432	447	15	3,47%
Rashod od naknada i provizija	123	131	8	6,50%
Neto prihod od naknada i provizija	**309**	**316**	**7**	**2,27%**
Neto dobit od trgovanja	144	139	-5	-3,47%
Ostali prihodi iz poslovanja	58	111	53	91,38%
Prihodi redovnog poslovanja	**2.251**	**2.215**	**-36**	**-1,60%**
Troškovi zaposlenih	412	411	-1	-0,24%
Ostali troškovi iz poslovanja	381	403	22	5,77%
Amortizacija dugotrajne materijalne imovine	34	34	0	0,00%
Amortizacija dugotrajne nematerijalne imovine	16	16	0	0,00%
Rashodi iz redovnog poslovanja	**843**	**864**	**21**	**2,49%**
Dobit prije rezerviranja za gubitke udjele u rezultatu pridruženih društava i poreza na dobit	**1.408**	**1.351**	**-57**	**-4,05%**
Gubici od umanjenja vrijednosti kredita i potraživanja i ostale imovine	578	733	155	26,82%
Gubici od umanjenja vrijednosti financijske imovine	15	2	-13	-86,67%
Ostala rezerviranja	12	18	6	50,00%
Rezerviranja za kredite, gubitke financijske imovine i ostala rezerviranja	**605**	**753**	**148**	**24,46%**
Dobit prije oporezivanja	**803**	**598**	**-205**	**-25,53%**
Porez na dobit	152	115	-37	-24,34%
Neto dobit tekuće godine	**651**	**483**	**-168**	**-25,81%**

Izvor: Izrada autora na temelju financijskih izvještaja banke

Tablica 10. prikazuje horizontalnu analizu računa dobiti i gubitka Erste banke 2012. godine u odnosu na 2011. godinu. Najveći apsolutni rast imaju rashodi od kamata u iznosu od 296 mil. kn ili 19,41% % te se stoga i neto prihod od kamata smanjio za 5,25%. Dobit prije oporezivanja se smanjila za 205 mil kn, te je neto dobit tekuće godine pala za 168 mil. kn odnosno 25,81% u odnosu na 2011. godinu.

Tablica 11: *Horizontalna analiza rn dobiti i gubitka Erste banke za 2012. i 2013. godinu*

Račun dobiti i gubitka (u mil. kuna)	**2012**	**2013**	**Apsolutna razlika**	**Relativna razlika**
Prihod od kamata	3.502	3.016	-486	-13,88%
Rashod od kamata	1.821	1.426	-395	-21,69%
Udio u dobiti pridruženih društava	1.681	1590	-91	-5,41%
Neto prihod od kamata	**447**	**500**	**53**	**11,86%**
Prihod od naknada i provizija	131	147	16	12,21%
Rashod od naknada i provizija	316	353	37	11,71%
Neto prihod od naknada i provizija	**137**	**149**	**12**	**8,76%**
Prihodi redovnog poslovanja	**2.134**	**2.092**	**-42**	**-1,97%**
Troškovi zaposlenih	411	364	-47	-11,44%
Ostali administrativni troškovi	316	308	-8	-2,53%
Amortizacija dugotrajne materijalne imovine	34	30	-4	-11,76%
Amortizacija dugotrajne nematerijalne imovine	16	16	0	0,00%
Opći administrativni troškovi	**777**	**718**	**-59**	**-7,59%**
Ostali rezultati redovnog poslovanja	74	206	132	178,38%
Rezultati financijske imovine raspoložive za prodaju	59	1	-58	-98,31%
Dobit prije rezerviranja za gubitke i poreza na dobit	**1.342**	**1.169**	**-173**	**-12,89%**
Gubici od umanjenja vrijednosti	744	1.079	335	45,03%
Dobit prije oporezivanja	**597**	**90**	**-507**	**-84,92%**
Porez na dobit	115	22	-93	-80,87%
Neto dobit tekuće godine	**483**	**68**	**-415**	**-85,92%**

Izvor: Izrada autora na temelju financijskih izvještaja banke

Tablica 11. prikazuje horizontalnu analizu računa dobiti i gubitka Erste banke 2013. godine u odnosu na 2012. godinu. Najveći apsolutni rast imaju gubici od umanjenja vrijednosti u iznosu od 335 mil. kn ili rast od 45,03%, zatim ih slijede ostali rezultati redovnog poslovanja sa 132 mil. kn ili rastom od 178,38%. Najveći apsolutni pad bilježi dobit prije oporezivanja u iznosu od 507 mil. kn ili 84,92%. Neto dobit tekuće godine je pala sa 483 mil. na 68 mil. kn ili pad u iznosu 415 mil. kn odnosno 85,92%.

Tablica 12: *Horizontalna analiza rn dobiti i gubitka Erste banke za 2013. i 2014. godinu*

Račun dobiti i gubitka (u mil. kuna)	**2013**	**2014**	**Apsolutna razlika**	**Relativna razlika**
Neto kamatni prihod	1.545	1.609	64	4,14%
Neto prihod od provizija i naknada	353	381	28	7,93%
Prihodi od dividendi	48	79	31	64,58%
Neto rezultat iz trgovanja i svođenja na fer vrijednost	**149**	**177**	**28**	**18,79%**
Prihod od najma od ulaganja u nekretnine i ostalog operativnog najma	2	2	0	0,00%
Troškovi zaposlenih	364	402	38	10,44%
Ostali administrativni troškovi	369	414	45	12,20%
Amortizacija	47	44	-3	-6,38%
Dobici i gubici po osnovi fin. imovine i fin. obveza koje se ne mjere po fer vrijednosti kroz račun dobiti i gubitka	1	7	6	600,00%
Neto gubitak od umanjenja vrijednosti fin. imovine koja se ne mjeri po fer vrijednosti kroz račun dobiti i gubitka	1.091	1.100	9	0,82%
Opći operativni troškovi	**137**	**29**	**-108**	**-78,83%**
Dobit prije poreza od neprekinutog poslovanja	**90**	**266**	**176**	**195,56%**
Porez na dobit	22	34	12	54,55%
Neto dobit tekuće godine	**68**	**232**	**164**	**241,18%**

Izvor: Izrada autora na temelju financijskih izvještaja banke

Tablica 12. prikazuje horizontalnu analizu računa dobiti i gubitka Erste banke 2014. godine u odnosu na 2013. godinu. Najveći apsolutni rast bilježi dobit prije poreza od neprekinutog poslovanja u iznosu od 176 mil. kn ili 195,56%. Neto dobit tekuće godine bilježi rast od 164 mil. kn u odnosu na prethodnu godinu, odnosno porasla je za 241,18%. Apsolutni pad bilježe samo opći operativni troškovi u iznosu od 108 mil kn.

2.5. Vertikalna analiza

Strukturni financijski izvještaji temelj su za provedbu vertikalne analize koja podrazumijeva analitički postupak raščlanjivanja. Vertikalnom analizom provodi se uspoređivanje podataka u jednoj godini pri čemu se daje uvid u strukturu financijskih izvještaja (utvrđuje se postotni udio svake stavke financijskog izvještaja u odnosu na odgovarajući zbroj). Pri tomu se analiza provodi na sljedeći način:

- kod bilance - pojedini elementi strukture aktive promatraju se u postotnom udjelu ukupne aktive, odnosno pojedini elementi strukture pasive u postotnom udjelu ukupne pasive;
- kod računa dobiti i gubitka - struktura prihoda i rashoda promatra se u odnosu na ukupne prihode (ukupni prihodi su iskazani 100%; ostale pozicije u postotku od ukupnih prihoda), ili pak u odnosu na prihode od redovitog poslovanja.[29]

U tablici 13. prikazana je vertikalna analiza bilance za 2012. godinu u odnosu na 2011. iz koje vidimo da krediti i potraživanja od klijenata u ovoj godini padaju za 0,0275 postotna poena, odnosno sa 69,12% na 66,38%, ali i dalje zadržavaju najveći udio u imovini banke. U ukupnim obvezama udjel obveza prema klijentima se nastavlja smanjivati, ove godine u iznosu od 0,0147 postotnih poena odnosno sa 62,74% na 61,33%. Kapitalna dobit banke pada, i to u iznosu za 0,0222 postotna poena, odnosno sa 28,10% na 25,88%.

[29] https://loomen.carnet.hr/mod/book/view.php?id=131187&chapterid=31505 (na dan: 10.07.2016.)

Tablica 13: *Vertikalna analiza bilance Erste banke za 2011.-2012. godinu*

Bilanca Erste banke (u mil kuna)	2011.	2012.	Udjel 2011 (u %)	Udjel 2012 (u %)	Promjena (postotni poeni)
IMOVINA					
Novac i sredstva kod Hrvatske narodne banke	7.054	7.459	12,37%	12,75%	0,0038
Potraživanja od drugih banaka	1.438	2.507	2,52%	4,28%	0,0176
Repo krediti	157	899	0,28%	1,54%	0,0126
Derivatna financijska imovina	92	113	0,16%	0,19%	0,0003
Financijska imovina namijenjena trgovanju	122	56	0,21%	0,10%	-0,0012
Financijska imovina iskazana po fer vrijednosti kroz račun dobiti i gubitka	50		0,09%	0,00%	-0,0009
Krediti i potraživanja od klijenata	39.425	38.844	69,12%	66,38%	-0,0275
Financijska imovina raspoloživa za prodaju	6.315	5.956	11,07%	10,18%	-0,0089
Financijska imovina koja se drži do dospijeća	366	685	0,64%	1,17%	0,0053
Ulaganja u ovisna i pridružena društva	1.300	1.300	2,28%	2,22%	-0,0006
Nekretnine i oprema	407	386	0,71%	0,66%	-0,0005
Nematerijalna imovina	50	47	0,09%	0,08%	-0,0001
Odgođena porezna imovina	93	38	0,16%	0,06%	-0,0010
Ostala imovina	166	229	0,29%	0,39%	0,0010
Ukupno imovina	57.035	58.519	100,00%	100,00%	
OBVEZE					
Obveze prema drugim bankama	16.882	16.830	33,35%	32,64%	-0,0071
Primljeni repo krediti	500	1.369	0,99%	2,66%	0,0167
Derivatne financijske obveze	136	147	0,27%	0,29%	0,0002
Financijske obveze iskazane po fer vrijednosti kroz račun dobiti i gubitka	40		0,08%	0,00%	-0,0008
Obveze prema klijentima	31.787	31.618	62,79%	61,33%	-0,0147
Izdane obveznice i ostala pozajmljena sredstva	3	303	0,01%	0,59%	0,0058
Ostale obveze	330	325	0,65%	0,63%	-0,0002
Rezerviranja	98	116	0,19%	0,22%	0,0003
Izdani podređeni instrumenti	846	848	1,67%	1,64%	-0,0003
Ukupno obveze	**50.622**	**51.556**	100,00%	100,00%	
KAPITAL					
Dionički kapital	1.698	1.698	26,48%	24,39%	-0,0209
Kapitalna dobit	1.802	1.802	28,10%	25,88%	-0,0222
Zadržana dobit	2.905	3.212	45,30%	46,13%	0,0083
Ostale rezerve	-83	166	-1,29%	2,38%	0,0368
Ostale kapitalne rezerve	91	85	1,42%	1,22%	-0,0020
Ukupno kapital raspoloživ dioničarima banke	6.413	6.963	100,00%	100,00%	
UKUPNO KAPITAL	6.413	6.963	100,00%	100,00%	
Ukupno obveze i kapital	57.035	58.519			

Izvor: Izrada autora na temelju financijskih izvještaja banke

Tablica 14: *Vertikalna analiza bilance Erste banke za 2012.-2013. godinu*

Bilanca Erste banke (u mil kuna)	2012.	2013.	Udjel 2012 (u %)	Udjel 2013 (u %)	Promjena (postotni poeni)
IMOVINA					
Novac i sredstva kod centralnih banaka	7.459	7.695	12,75%	12,80%	0,0005
Potraživanja od drugih banaka	2.507	2.534	4,28%	4,21%	-0,0007
Repo krediti	899	1.002	1,54%	1,67%	0,0013
Derivatna financijska imovina	113	86	0,19%	0,14%	-0,0005
Financijska imovina namijenjena trgovanju	56	125	0,10%	0,21%	0,0011
Krediti i potraživanja od klijenata	38.844	39.912	66,38%	66,38%	0,0000
Financijska imovina raspoloživa za prodaju	5.956	6.146	10,18%	10,22%	0,0004
Financijska imovina koja se drži do dospijeća	685	499	1,17%	0,83%	-0,0034
Ulaganja u ovisna i pridružena društva	1.300	1.272	2,22%	2,12%	-0,0011
Nekretnine i oprema	386	348	0,66%	0,58%	-0,0008
Nematerijalna imovina	47	37	0,08%	0,06%	-0,0002
Ulaganja u nekretnine		20	0,00%	0,03%	0,0003
Odgođena porezna imovina	38	37	0,06%	0,06%	0,0000
Ostala imovina	229	422	0,39%	0,70%	0,0031
Ukupno imovina	**58.519**	**60.125**	**100,00%**	**100,00%**	
OBVEZE					
Obveze prema drugim bankama	16.830	16.652	32,64%	31,28%	-0,0137
Primljeni repo krediti	1.369	647	2,66%	1,22%	-0,0144
Derivatne financijske obveze	147	89	0,29%	0,17%	-0,0012
Obveze prema klijentima	31.618	34.175	61,33%	64,19%	0,0287
Izdane obveznice i ostala pozajmljena sredstva	303	302	0,59%	0,57%	-0,0002
Ostale obveze	325	324	0,63%	0,61%	-0,0002
Rezerviranja	116	191	0,22%	0,36%	0,0013
Izdani podređeni instrumenti	848	858	1,64%	1,61%	-0,0003
Ukupno obveze	**51.556**	**53.238**	**100,00%**	**100,00%**	
KAPITAL					
Dionički kapital	1.698	1.698	24,39%	24,66%	0,0027
Kapitalna dobit	1.802	1.802	25,88%	26,17%	0,0029
Zadržana dobit	3.212	3.133	46,13%	45,49%	-0,0064
Ostale rezerve	166	169	2,38%	2,45%	0,0007
Ostale kapitalne rezerve	85	85	1,22%	1,23%	0,0001
Ukupno kapital raspoloživ dioničarima banke	**6.963**	**6.887**	**100,00%**	**100,00%**	
Ukupno kapital	**6.963**	**6.887**	**100,00%**	**100,00%**	
Ukupno obveze i kapital	**58.519**	**60.125**			

Izvor: Izrada autora na temelju financijskih izvještaja banke

U tablici 14. prikazana je vertikalna analiza bilance za 2013. godinu u odnosu na 2012. iz koje vidimo da krediti i potraživanja od klijenata u ovoj godini ostaju na istoj razini kao i prethodne godine i čine 66,38% ukupne imovine banke, tj. zadržavaju najveći udio. U ukupnim obvezama udjel obveza prema klijentima rastu ove godine u iznosu od 0,0287 postotnih poena odnosno sa 61,33% na 64,19%. Zadržana dobit banke pada, i to u iznosu za 0,0064 postotna poena, odnosno sa 46,13% na 45,49%.

U tablici 15. prikazana je vertikalna analiza bilance za 2014. godinu u odnosu na 2013. iz koje vidimo da krediti i potraživanja od klijenata u ovoj godini zadržavaju pad kao i prethodne godine i u ovoj godini njihov pad je u iznosu za 0,0244 postotna poena, odnosno sa 68,26% na 65,81%, ali i dalje zadržavaju najveći udio u imovini banke. U ukupnim obvezama udjel depozita od klijenata raste za 0,0058 postotnih poena, odnosno sa 69,53% na 70,11%. Kod kapitala, kapital raspoloživ vlasniku matičnog društva raste sa 6.887 na 7.190 mil. kn.

Tablica 15: *Vertikalna analiza bilance Erste banke za 2013.-2014. godinu*

Bilanca Erste banke (u mil kuna)	2013	2014	Udjel 2013 (u %)	Udjel 2014 (u %)	Promjena (postotni poeni)
IMOVINA					
Novac i novčana sredstva	3.949	4.035	6,57%	6,70%	0,0014
Financijska imovina koja se drži radi trgovanja	211	478	0,35%	0,79%	0,0044
Derivati	86	96	0,14%	0,16%	0,0002
Ostala imovina koja se drži radi trgovanja	125	382	0,21%	0,63%	0,0043
Financijska imovina raspoloživa za prodaju	6.146	6.693	10,22%	11,12%	0,0090
Financijska imovina koja se drži do dospijeća	499	1.288	0,83%	2,14%	0,0131
Krediti i potraživanja od kreditnih institucija	6.143	5.720	10,22%	9,50%	-0,0071
Krediti i potraživanja od klijenata	41.040	39.607	68,26%	65,81%	-0,0244
Nekretnine i oprema	347	338	0,58%	0,56%	-0,0002
Ulaganja u nekretnine	20	19	0,03%	0,03%	0,0000
Nematerijalna imovina	37	48	0,06%	0,08%	0,0002
Ulaganja u ovisna društva	1.243	1.317	2,07%	2,19%	0,0012
Ulaganja u zajedničke pothvate i pridružena društva	29	38	0,05%	0,06%	0,0001
Tekuća porezna imovina	88	85	0,15%	0,14%	-0,0001
Odgođena porezna imovina	37	19	0,06%	0,03%	-0,0003
Ostala imovina	336	495	0,56%	0,82%	0,0026
Ukupna imovina	**60.125**	**60.180**	100,00%	100,00%	
OBVEZE I KAPITAL					
Financijske obveze koje se drže radi trgovanja	89	94	0,17%	0,18%	0,0001
Derivati	89	94	0,17%	0,18%	0,0001
Depoziti od banaka	14.610	14.165	27,44%	26,73%	-0,0071
Depoziti od klijenata	37.015	37.151	69,53%	70,11%	0,0058
Izdani dužnički vrijednosni papiri	931	933	1,75%	1,76%	0,0001
Ostale financijske obveze	75	74	0,14%	0,14%	0,0000
Rezerviranja	191	213	0,36%	0,40%	0,0004
Ostale obveze	327	360	0,61%	0,68%	0,0007
Ukupno obveze	**53.238**	**52.990**	100,00%	100,00%	
Ukupni kapital	**6.887**	**7.190**	100,00%	100,00%	
Raspoloživi vlasniku matičnog društva	6.887	7.190	100,00%	100,00%	
Ukupne obveze i kapital	**60.125**	**60.180**			

Izvor: Izrada autora na temelju financijskih izvještaja banke

3. EMPIRIJSKO ISTRAŽIVANJE O USPJEŠNOSTI POSLOVANJA ERSTE & STEIERMARKISCHE BANK D.D

U ovom dijelu rada testirat će se hipoteze postavljene na početku ovog istraživanja. Riječ je sljedećim hipotezama:

H1: *Svjetska financijska kriza negativno je utjecala na poslovanje i financijske rezultate Erste banke u Republici Hrvatskoj.*

H2: *Položaj Erste banke u smislu poslovne uspješnosti s obzirom na odabrane konkurente nije se promijenio prije i za vrijeme financijske krize.*

H3: *Kreditiranje Erste banke utječe na kretanje BDP-a za promatrano razdoblje.*

Svaka od navedenih hipoteza zahtijeva drugačiju metodu testiranja, pa je svaka hipoteza odvojena u posebno potpoglavlje. Stoga, tri potpoglavlja ovog dijela sadrže metodološki okvir, opis podataka i varijabli i rezultate testiranja za svaku hipotezu zasebno.

3.1. Testiranje prve istraživačke hipoteze

Prva hipoteza postavljena na početku ovog istraživanja glasi:

H1: Svjetska financijska kriza negativno je utjecala na poslovanje i financijske rezultate Erste banke u Republici Hrvatskoj.

U svrhu testiranja hipoteze H1 primijenit će se model višestruke regresije.[30] Testirati će se na način da će se kao pokazatelji uspješnosti poduzeća biti odabrani pokazatelji profitabilnosti banaka, dok će se za nezavisne varijable kreirati set standardnih bankarskih pokazatelja koji utječu na profitabilnost banka,i to po uzoru na dosadašnju literaturu koja se bavi izučavanjem determinanti bankarskog poslovanja. Dodatno, u model će se uvrstiti financijska kriza kao dummy varijabla kako bi se izlučio njezin utjecaj.

[30] Regresijska analiza provest će se pomoću programa SPSS.

3.1.1. O višestrukoj regresiji

Zadaća regresijske analize je da pronađe analitičko-matematički oblik veze između jedne ovisne ili regresand varijable i jedne ili više neovisnih ili regresorskih varijabli.[31]

Algebarski model kojim se analitički određuje statistička povezanost jedne numeričke varijable s dvije ili više numeričkih varijabli naziva se **višestrukim regresijskim modelom**.[32] Navedeni model koristit će se pri testiranju prve istraživačke hipoteze, jer pored financijske krize očekuje se da postoji još niz varijabli, koje na temelju ekonomske teorije i prethodnih empirijskih istraživanja, također mogu utjecati na poslovanje Erste banke. Dodatno, s obzirom na korištenje kraćeg niza podataka, formirat će se linearni model višestruke regresije. Naime,kod kraćih nizova podataka interval varijacija varijabli zbog svoje ograničenosti ne dozvoljava znatnije devijacije od linearnosti, pa u tom slučaju linearna aproksimacija dobro predstavlja odabrane povezanosti.[33]

Regresijska analiza u ovom dijelu provest će se u tri koraka. Prvi korak obuhvaća **specifikaciju modela**. Specifikacija modela podrazumijeva matematičku formulaciju postavljenih znanstvenih hipoteza, koje se određuju na temelju poznavanja djelovanja i ponašanja ispitivanog fenomena u ekonomskoj stvarnosti, na temelju rezultata ranijih istraživanja tog fenomena, i što je osobito važno na temelju spoznaja ekonomske teorije o njemu.[34]

Opći oblik linearnog modela višestruke regresije glasi:

$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 + \hat{\beta}_2 \cdot X_2 + \ldots\ldots + \hat{\beta}_k \cdot X_k + e$, gdje je: (1)

$\hat{Y}$ − ovisna ili regresand varijabla,

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

$\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \ldots, \hat{\beta}_k$ – parametri koje je potrebno ocijeniti, te

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

[31] Pivac, S.: Statističke metode: predavanja, diplomski studij. Statističke metode - e nastavni materijal. Ekonomski fakultet Split, str. 253., Split
[32] Jurun, E.:Kvantitativne metode u ekonomiji. Ekonomski fakultet Split,str. 36., Split, 2007.
[33]Jurun, E.: Kvantitativne metode u ekonomiji. Ekonomski fakultet Split, str. 10., Split, 2007.
[34] Jurun, E.: Kvantitativne metode u ekonomiji. Ekonomski fakultet Split, str. 5., Split, 2007.

Drugi korak regresijske analize odnosi se na **ocjenjivanje modela**. Ocjenjivanje modela kako predstavlja tehničku fazu u dobivanju rezultata i i obuhvaća:

- prikupljanje statističkih podataka,
- ispitivanje problema agregiranja i sličnih problema u vezi s varijablama uključenim u model,
- ispitivanje uvjeta identifikacije funkcija korištenih u modelu,
- ispitivanje jakosti međusobne korelacije varijabli korištenih u modelu odnosno razine multikolinearnosti,
- ispitivanje vezano uz zadovoljavanje uvjeta stohastičnosti slučajnih varijabli,
- izbor ekonometrijskih metoda i tehnika za ocjenu modela i kritično preispitivanje pretpostavki koje trebaju biti ispunjene kao uvjet primjene izabranih metoda i tehnika, te sagledavanje njihovih utjecaja na ocjenu parametara u modelu, i
- primjena odgovarajućih ekonometrijskih metoda i tehnika za ocjenjivanje modela.[35]

Sljedeća tablica navodi probleme koje mogu uzrokovati varijable u modelu, a zbog kojih mogu biti narušene pretpostavke klasičnog modela, njihov opis, te način na koji će se pokušati detektirati u modelu.

[35] Jurun, E. (2007). Kvantitativne metode u ekonomiji. Ekonomski fakultet Split, str. 10., Split, 2007

Tablica 16: *Pretpostavke klasičnog regresijskog modela*

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

Izvor: Izrada autora na temelju Jurun (2007) i Rozga (2009)

Ocjenjivanje parametara provest će se metodom najmanjih kvadrata.

Kada su sve navedene pretpostavke klasičnog modela zadovoljene, može se pristupiti trećem koraku koji se odnosi na **vrednovanje ocjene parametara.** U sklopu navedene faze testirat će se hipoteze o značajnosti modela, proučit će se veličine i predznaci parametara, te će se statističkim kriterijima vrednovati statistička značajnost ocjene parametara modela. Dodatno, provjerit će se još neki pokazatelji reprezentativnosti poput koeficijenta determinacije i korigiranog koeficijenta determinacije. U konačnici prezentirat će se analitički izrazi modela, interpretirati dobiveni parametri te testirati njihova statistička značajnost. Četvrti, često presudni korak, regresijske analize je vrednovanje prognostičke moći ocjenjenog ekonometrijskog modela.

3.1.2. Opis varijabli odabranih u regresijski model

Varijable koje ulaze u model višestruke regresije odabrane su po uzoru na istraživanje Pejić Bach et al. (2009) koje se odnosi na najznačajnije determinante bankarskog poslovanja u Hrvatskoj. Procjenjuje se model u kojem se za zavisnu varijablu koristi stopa profitabilnosti prosječne ukupne imovine banke (ROAA[36]), dok set nezavisnih varijabli uključuje čimbenike karakteristične za poslovanje banke (tzv. interni čimbenici), ali i pokazatelje makroekonomskog okruženja (tzv. eksterni čimbenici) koji također utječu na poslovanje banke. Uz navedene varijable u model se, s ciljem testiranja prve istraživačke hipoteze, uvodi i dummy varijabla „financijska kriza" kako bi se izlučio njezin efekt na uspješnost poslovanja Erste banke. Varijabla „financijska kriza" poprima vrijednost 1 u 2008. i 2009. godini zbog toga što se pregledom opsežne literature na ovu tematiku ustanovilo da se financijska kriza, nakon što je nastala na tržištu nekretnina u ljeto 2007. u SAD-u, iznimno brzo proširila i prelila u ostatak svijeta, no njeni efekti su se najviše osjetili tijekom 2008. i 2009. godine. Kriza je ostavila nesagledive posljedice na brojna svjetska gospodarstva i iako su se ona razvijenija već počela oporavljati tijekom 2010. mnoge zemlje posljedice krize osjećale su znatno duže, no u tom slučaju se govori o gospodarskim krizama tih zemalja. Među zemlje koje su imale duži oporavak spada i Hrvatska koja je iz recesije izašla tek u 2015. godini.

Od internih čimbenika odabrani su sljedeći pokazatelji:

- *Tržišni udjel banke* – uobičajeno se pretpostavlja da veći tržišni udjel banke treba imati pozitivan utjecaj na profitabilnost te institucije jer je veličina pojedine banke pozitivno povezana s profitabilnosti.
- *Omjer dioničarskog kapitala i ukupne imovine banke* – bi trebao pozitivno utjecati na profitabilnost dioničarskog kapitala zato što se pretpostavlja da bi visoko kapitalizirane banke s višim omjerom dioničarskog kapitala i ukupne imovine trebale ostvarivati nešto niži povrat na kapital, no istovremeno bi u manjoj mjeri trebale biti izložene riziku nesolventnosti što na kraju rezultira nižim troškovima financiranja tih banaka, te vodi njihovoj profitabilnosti.
- *Omjer odobrenih kredita i ukupne imovine banke* – što je veći udio kredita u ukupnoj imovini banke to bi trebala biti veća profitabilnost jer je onda veći udio prihodujuće imovine.

[36] $\frac{Neto\ dobit_t}{(Imovina_{t-1} + Imovina_t)/2}$

- *Omjer neto odobrenih kredita komitentima i kratkoročnog financiranja banke* – jest zapravo pojednostavljeno rečeno omjer odobrenih bankovnih kredita i depozita te u biti osnovni pokazatelj likvidnosti. Teorijska očekivanja su da što su manje vrijednosti ovog pokazatelja, to bi trebale biti prihvatljivije jer ukazuju na veći stupanj likvidnosti banke.
- *Omjer "neprihodujuće" imovine i ukupne imovine banke* – pod „neprihodujućom imovinom (engl. non-income assets) se smatra npr., gotovina, nekretnine, informatička tehnologija, itd. te one banke koje imaju manje „neprihodujuće“ imovine bi trebale imati veće profite zbog toga što ovakva vrsta imovine ne ostvaruje izravne prihode.
- *Neto kamatna marža* – razlika između kamatnih prihoda i rashoda te se mijenja kako se mijenjaju i kamatne stope. Zbog sve veće konkurencije između banaka, ali i između banaka i drugih financijskih institucija ovaj pokazatelj se vremenom smanjuje. Njegov očekivani utjecaj na profitabilnost je pozitivan jer što su veći prihodi po osnovi kamata, bit će veći i profit.
- *Omjer operativnih troškova i ukupne imovine banke* – Što su veći operativni troškovi to je manja profitabilnost banke.

Eksterni čimbenici koji su uzeti u obzir u analizi su *stopa rasta bruto domaćeg proizvoda, inflacija, prosječan devizni tečaj, te bruto domaći proizvod po stanovniku*. Očekivani teorijski utjecaj rasta bruto domaćeg proizvoda na profitabilnost banke jest pozitivan. Djelovanje inflacije nije utvrđeno te može djelovati i pozitivno i negativno na profitabilnost, a ovisi o načinu upravljanja sredstvima banke u uvjetima inflacije. U konačnici, neadekvatna politika tečaja negativno utječe na profitabilnost banke što se objašnjava na sljedeći način: u slučaju precijenjenosti domaće valute domaće tvrtke su nekonkurentne na svjetskom tržištu te su njihove izvozne aktivnosti manje, a to rezultira smanjenjem proizvodnje te naposljetku i BDP-a što negativno utječe na profitabilnost. Korišteni indikator za devizni tečaj jest realni efektivni tečaj (*eng. Real Effective Exchange Rate*) koji predstavlja ponderirani prosjek valute promatrane države u odnosu na skup najznačajnijih stranih valuta. Izražava se kao indeks te je korigiran za inflaciju.

U nastavku je prikazana tablica koja sumira sve varijable korištene u regresijskom modelu, izvore podataka (podatci su prikupljeni iz godišnjih izvješća Erste banke te preuzeti sa stranica Hrvatske narodne banke (HNB) te Svjetske banke (WDI).

Tablica 17: *Prikaz varijabli modela, izvora, te očekivanog utjecaja*

VARIJABLA	OPIS	IZVOR	
Zavisne varijable			
ROAA	Stopa profitabilnosti prosječne ukupne imovine banke	Erste banka	
Nezavisne varijable			Očekivani utjecaj
Financijska kriza	Dummy varijabla	Autorica	-
Interni čimbenici			
UDIO	Tržišni udjel banke	Erste banka / HNB	+
KAP/IMO	Omjer dioničarskog kapitala i ukupne imovine banke	Erste banka	+
KRD/IMO	Omjer odobrenih kredita i ukupne imovine banke	Erste banka	+
KRD/DEP	Omjer neto odobrenih kredita komitentima i kratkoročnog financiranja banke	Erste banka	-
NPI/IMO	Omjer "neprihodujuće" imovine i ukupne imovine banke	Erste banka	-
KAM	Neto kamatna marža	Erste banka	+
OPT/IMO	Omjer operativnih troškova i ukupne imovine banke	Erste banka	-
Eksterni čimbenici			
BDPrast	Stopa rasta bruto domaćeg proizvoda	HNB	+
BDPpc	Bruto domaći proizvod per capita	WDI	+
INF	Inflacija	HNB	+ / -
DEV	Devizni tečaj	WDI	-

Izvor: Izrada autora

U sljedećoj tablici prikazani su rezultati deskriptivne statistike za sve varijable u modelu.

Tablica 18: *Deskriptivna statistika varijabli*

Varijabla	N	Ar. sr.	Medijan	Mod	St. dev.	Raspon	Min	Max
Stopa profitabilnosti prosječne ukupne imovine banke	15	1,29	1,28	1,28	0,54	2,04	0,11	2,15
Tržišni udjel	15	10,88	11,70	2,74[a]	4,17	12,49	2,74	15,23
Omjer dioničarskog kapitala i ukupne imovine banke	15	10,11	11,20	5,85[a]	2,44	8,91	5,85	14,76
Omjer odobrenih kredita i ukupne imovine banke	15	62,86	63,73	49,15[a]	7,25	26,17	49,15	75,32
Omjer neto odobrenih kredita komitentima i kratkoročnog financiranja banke	15	100,05	100,14	73,64[a]	14,57	49,71	73,64	123,35
Omjer "neprihodujuće" imovine i ukupne imovine banke	15	1,80	1,53	1,05[a]	0,76	2,68	1,05	3,73
Neto kamatna marža	15	1032,60	1087,00	196,00[a]	556,12	1544,00	196,00	1740,00
Omjer operativnih troškova i ukupne imovine banke	15	1,91	1,64	1,39	0,75	2,83	1,12	3,95
BDP per capita	15	71692,43	74384,72	58114,63[a]	6900,05	23139,79	58114,63	81254,42
Stopa rasta BDP-a	15	1,69	3,40	5,2	3,73	13,00	-7,40	5,60
Devizni tečaj	15	95,37	96,33	86,51[a]	4,50	16,13	86,51	102,64
Inflacija	15	2,71	2,40	-,20[a]	1,50	6,30	-0,20	6,10
a. Postoji više modova, najmanja vrijednost je odabrana.								

Izvor: Izračun autora u SPSS-u

Za svaku varijablu prezentirani su standardni pokazatelji deskriptivne statistike: broj opažanja, aritmetička sredina, medijan, mod, standardna devijacija, raspon te minimalna i maksimalna vrijednost. Aritmetička sredina stope profitabilnosti prosječne ukupne imovine banke (ROAA) iznosi 1,29% što znači da je prosječna vrijednost ROAA 1,29%. Medijan iznosi 1,28% i predstavlja vrijednost koja niz dijeli na dva jednaka dijela. U ovom slučaju bi značilo da 50% jedinica u nizu ima vrijednost ROAA 1,28% i manju, odnosno 50% ih ima vrijednost ROAA 1,28% i veću. Mod također iznosi 1,28% što znači da je to vrijednost koja se najčešće ponavlja u nizu. Standardna devijacija iznosi 0,54 p.p. što znači da je prosječno odstupanje od prosjeka vrijednosti ROAA 0,54 postotna poena. Raspon varijacije iznosi 2,04 p.p. i predstavlja razliku između najveće (2,15%) i najmanje (0,11%) vrijednosti niza.

3.1.3. Rezultati regresije

Formira se sljedeći regresijski model:

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 + \hat{\beta}_2 \cdot X_2 + \hat{\beta}_3 \cdot X_3 + \hat{\beta}_4 \cdot X_4 + \hat{\beta}_3 \cdot X_5 + \hat{\beta}_6 \cdot X_6 + \hat{\beta}_7 \cdot X_7 + \hat{\beta}_8 \cdot X_8 + \hat{\beta}_9 \cdot X_9 + \hat{\beta}_{10} \cdot X_{10} + \hat{\beta}_{11} \cdot X_{11} + \hat{\beta}_{12} \cdot X_{12} + e \quad (2)$$

Gdje je:

$\hat{Y}$ – stopa profitabilnosti prosječne ukupne imovine banke,

X_1 – **financijska kriza (dummy varijabla),**

X_2 – tržišni udjel,

X_3 – omjer dioničarskog kapitala i ukupne imovine banke,

X_4 – omjer odobrenih kredita i ukupne imovine banke,

X_5 – omjer neto odobrenih kredita komitentima i kratkoročnog financiranja banke,

X_6 – omjer "neprihodujuće" imovine i ukupne imovine banke,

X_7 – neto kamatna marža,

X_8 – omjer operativnih troškova i ukupne imovine banke,

X_9 – stopa rasta bruto domaćeg proizvoda,

X_{10} – bruto domaći proizvod per capita,

X_{11} – inflacija,

X_{12} – devizni tečaj,

$\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \hat{\beta}_3, \hat{\beta}_4, \hat{\beta}_5, \hat{\beta}_6, \hat{\beta}_7, \hat{\beta}_8, \hat{\beta}_9, \hat{\beta}_{10}, \hat{\beta}_{11}, \hat{\beta}_{12}$– parametri koje je potrebno procijeniti, te

e – slučajna varijabla.

Slijedi procjena prvog modela u kojem je zavisna varijabla stopa profitabilnosti prosječne ukupne imovine banaka. Na početku je potrebno izabrati metodu izbora optimalnog skupa regresorskih varijabli u model višestruke regresije te se za tu svrhu u ovom slučaju koristi, Stepwise metoda izbora regresorskih varijabli.[37]

[37] Stepwise metoda kombinacija je „Foward“ i „Backward“ metode te je najčešće korištena u praksi. Prva varijabla u modelu je ona nezavisna varijabla koja je najviše korelirana sa zavisnom varijablom uz uvjet da je empirijska signifikantnost testa takve regresije manja ili jednaka 0.05. Među ostalim nezavisnim varijablama kriterij za „ulazak“ se ispituje najprije za one varijable koje imaju najveći stupanj parcijalne korelacije za zavisnom varijablom, pri čemu se za varijable koje se već nalaze u modelu ispituje kriterij za „izlazak“ (empirijska razina signifikantnosti je veća ili jednaka 0.10). Ovaj iterativni postupak se nastavlja u svakom korak posebno za prethodno uključene nezavisne varijable sve dok dodavanje preostalih nezavisnih varijabli ima značajan doprinos koeficijentu determinacije (Jurun, 2007).

Odabir nezavisnih regresorskih varijabli stepwise metodom prikazan je u sljedećoj tablici. Može se uočiti da su u model ukupno ušle tri varijable: omjer operativnih troškova i ukupne imovine banke, BDP per capita i omjer dioničarskog kapitala i ukupne imovine banke.

Tablica 19: *Rezultati Stepwise metode*

Model	Variables Entered	Variables Removed	Method
1	Omjer operativnih troškova i ukupne imovine banke	.	Stepwise (Criteria: Probability-of-F-to-enter <= ,050, Probability-of-F-to-remove >= ,100).
2	BDP per capita	.	Stepwise (Criteria: Probability-of-F-to-enter <= ,050, Probability-of-F-to-remove >= ,100).
3	Omjer dioničarskog kapitala i ukupne imovine banke	.	Stepwise (Criteria: Probability-of-F-to-enter <= ,050, Probability-of-F-to-remove >= ,100).

a. Dependent Variable: Stopa profitabilnosti prosječne ukupne imovine banke
Izvor: Izračun autora u SPSS-u

U tablici 20. nalaze se vrijednosti koeficijenta multiple korelacije (*R*), koeficijenta determinacije (*R Square*), korigiranog koeficijenta determinacije (*Adjusted R Square*), te procijenjene standardne devijacije regresije (*Standard Error of the Estimate*).

Tablica 20: *Osnovni podaci o ocijenjenom modelu sa stopom profitabilnosti prosječne ukupne imovine kao zavisnom varijablom*

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,744[a]	,553	,519	,37453	
2	,862[b]	,743	,700	,29549	
3	,911[c]	,830	,784	,25109	1,237

a. Predictors: (Constant), Omjer operativnih troškova i ukupne imovine banke
b. Predictors: (Constant), Omjer operativnih troškova i ukupne imovine banke, BDP per capita
c. Predictors: (Constant), Omjer operativnih troškova i ukupne imovine banke, BDP per capita, Omjer dioničarskog kapitala i ukupne imovine banke
d. Dependent Variable: Stopa profitabilnosti prosječne ukupne imovine banke
Izvor: Izračun autora u SPSS-u

Iz tablice 20. može se uočiti da vrijednost koeficijenta multiple korelacije (*R*) iznosi 0,911 što ukazuje na jaku i pozitivnu linearnu vezu između varijabli modela. Koeficijent multiple determinacije (R^2) iznosi 0,830 što znači da je ocijenjenim regresijskim modelom protumačeno 83% sume kvadrata ukupnih odstupanja zavisne varijable od njene aritmetičke sredine što se može protumačiti na način da model ima dobru reprezentativnost. Korigirani koeficijent determinacije ($\bar{R}^2$) ima vrijednost 0,784.

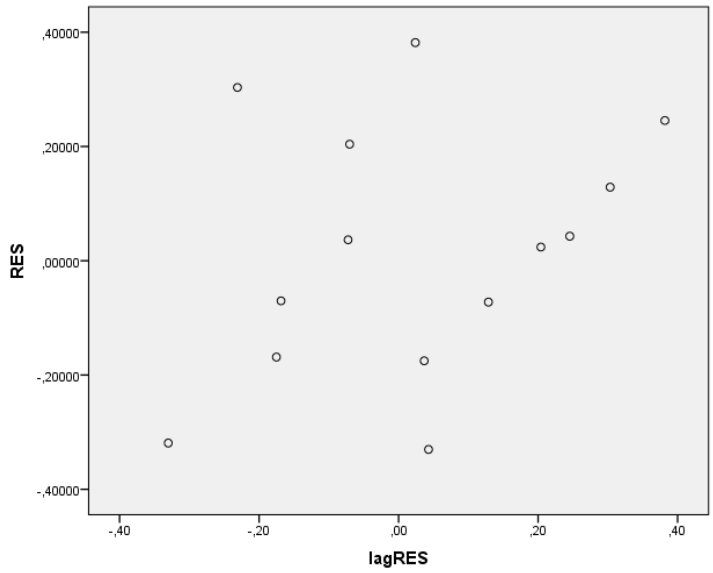
Na temelju raspoložive baze podataka može se izvršiti i testiranje autokorelacije reziduala pomoću Durbin-Watsonovog testa. Vrijednost Durbin-Watsonovog testa iznosi 1,237. Ova empirijska test veličina uspoređuje se s kritičnim vrijednostima d_L i d_U koje se za zadanu razinu signifikantnosti (α), veličinu uzorka (n), i broj regresorskih varijabli (k) iščitavaju iz tablica za Durbin-Watsonov test. U ovom slučaju vrijedi:

$\alpha = 5\%, \quad n = 15, \quad i \quad k = 3,$ iz čega proizlazi da je:

$d_L = 0{,}814, \ d_U = 1{,}750, \ 4 - d_L = 2{,}250, \ 4 - d_U = 3{,}186.$

Budući da je: $d_L < DW < d_U$ nalazimo se u području inkonkluzivnosti te se ne može donijeti sud o postojanju autokorelacije rezidualnih odstupanja pa će se taj zaključak donijeti uz pomoć grafičkog prikaza, i to dijagrama rasipanja reziduala.

Slika 1: *Dijagram rasipanja reziduala*



Izvor: Izrada autora u SPSS-u

Iz slike se vidi da ne postoji jasna autokorelacija grešaka pa se u konačnici donosi sud da problem autokorelacije reziduala ne postoji.

Tablica 21: *Tablica ANOVA ocijenjenog regresijskog modela*

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2,256	1	2,256	16,082	,001[b]
	Residual	1,824	13	,140		
	Total	4,079	14			
2	Regression	3,032	2	1,516	17,360	,000[c]
	Residual	1,048	12	,087		
	Total	4,079	14			
3	Regression	3,386	3	1,129	17,902	,000[d]
	Residual	,693	11	,063		
	Total	4,079	14			

a. Dependent Variable: Stopa profitabilnosti prosječne ukupne imovine banke
b. Predictors: (Constant), Omjer operativnih troškova i ukupne imovine banke
c. Predictors: (Constant), Omjer operativnih troškova i ukupne imovine banke, BDP per capita
d. Predictors: (Constant), Omjer operativnih troškova i ukupne imovine banke, BDP per capita, Omjer dioničarskog kapitala i ukupne imovine banke
Izvor: Izračun autora u SPSS-u

U tablici ANOVA prikazani su podaci o protumačenim, neprotumačenim i ukupnim odstupanjima ocijenjenih modela, te vrijednost F-testa s empirijskom signifikantnosti. Empirijska vrijednosti F-testa iznosi $\alpha^* \approx 0$, te se može zaključiti da je ovaj regresijski model statistički značajan kao cjelina i to pri signifikantnosti manjoj od 1%.

U sljedećoj tablici prikazuje se ocijenjeni regresijski model s pripadajućim vrijednostima ocijenjenih parametara, njihovih standardne greške i t-omjera.

Tablica 22: *Ocijenjeni linearni regresijski model sa stopom profitabilnosti prosječne ukupne imovine kao zavisnom varijablom*

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
		B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
1	(Constant)	,267	,274		,976	,347	-,324	,858		
	Omjer operativnih troškova i ukupne imovine banke	,538	,134	,744	4,010	,001	,248	,827	1,000	1,000
2	(Constant)	-5,783	2,041		-2,833	,015	-10,230	-1,336		
	Omjer operativnih troškova i ukupne imovine banke	1,097	,215	1,518	5,092	,000	,628	1,567	,241	4,149
	BDP per capita	6,949E-005	,000	,888	2,981	,011	,000	,000	,241	4,149
3	(Constant)	-6,448	1,757		-3,670	,004	-10,315	-2,581		
	Omjer operativnih troškova i ukupne imovine banke	1,252	,194	1,732	6,441	,000	,824	1,680	,214	4,678
	BDP per capita	8,442E-005	,000	1,079	4,061	,002	,000	,000	,219	4,568
	Omjer dioničarskog kapitala i ukupne imovine banke	-,069	,029	-,313	-2,370	,037	-,134	-,005	,887	1,128

a. Dependent Variable: Stopa profitabilnosti prosječne ukupne imovine banke
Izvor: Izračun autora u SPSS-u

Može se uočiti da sve varijable koje su na kraju uvrštene: omjer operativnih troškova i ukupne imovine banke, BDP per capita, te omjer dioničarskog kapitala i ukupne imovine banke, imaju statistički značajan utjecaj na stopu profitabilnosti prosječne ukupne imovine banaka.

Sukladno rezultatima u tablici 22 moguće je napisati analitički oblik regresijskog modela:

$$\hat{y}_i = -6{,}448 + 1{,}252 \cdot X_8 + 0{,}00008442 \cdot X_{10} - 0{,}069 \cdot X_3 \qquad (3)$$

Gdje je,

$\hat{y}_i$ – stopa profitabilnosti prosječne ukupne imovine banke,

X_3 – omjer dioničarskog kapitala i ukupne imovine banke,

X_8 – omjer operativnih troškova i ukupne imovine banke,

X_{10} – bruto domaći proizvod per capita.

Kako je već rečeno, sve varijable imaju statistički značajan utjecaj na zavisnu varijablu, a parametar $\hat{\beta}_8$, koji se nalazi uz regresorsku varijablu omjer operativnih troškova i ukupne imovine banke iznosi 1,252 te govori da ako se poveća udio operativnih troškova u ukupnoj imovini za 1 postotni poen da će u tom slučaju stopa profitabilnosti prosječne ukupne imovine banke porasti za 1,25 postotnih poena uz uvjet da su ostale regresorske varijable nepromijenjene. Ovaj rezultat nije u skladu s ekonomskom teorijom u kojom se pretpostavlja da ovi troškovi smanjuju dobit. No, oni zapravo predstavljaju naknade za zaposlene, ulaganju u prostore, ulaganja u marketing, ulaganju u IT te su ukoliko su se npr. troškovi zaposlenih povećali uslijed povećanja broja zaposlenih, ukoliko su bili zaposleni visoko obučeni i motivirani radnici, oni su vjerojatno doprinijeli rastu produktivnosti Erste banke. Također, ukoliko su ovi troškovi rasli zbog ulaganja u nove IT tehnologije koja je povećala produktivnost ili možda zbog rasta troškova marketinga koji su privukli nove klijente, pozitivan odnos ovog pokazatelja i profitabilnosti banke ima smisla. Očekivano, parametar $\hat{\beta}_{10}$, koji se nalazi uz regresorsku varijablu BDP po stanovniku je pozitivan te iznosi 0,00008442 te govori da ako se BDP per capita poveća za jednu kunu, profitabilnost Erste banke će porasti za 0,00008442 postotna poena uz uvjet da su ostale varijable nepromijenjene. Zbog vrlo malog iznosa možda je primjerenije reći da ukoliko se BDP per capita poveća za 1000 kn, profitabilnost Erste banke će porasti za 0,0842 postotna poena uz uvjet da su ostale varijable nepromijenjene. Suprotni predznak od očekivanog ima parametar uz posljednju statistički značajnu varijablu: omjer dioničarskog kapitala i ukupne imovine banke. Dakle, ukoliko se udio dioničarskog kapitala u ukupnoj imovini poveća za 1 postotni poen, stopa profitabilnosti prosječne ukupne imovine banke će se smanjiti za 0,069 postotnih poena uz uvjet da su ostale varijable nepromijenjene. Ovakav ishod se može objasniti na sljedeći način. Iako nisko kapitalizirane banke, u razdoblju uspješnog poslovanja zbog izraženije financijske poluge trebale bi ostvarivati veću profitabilnost, one su iz istog razloga ujedno izložene i riziku nesolventnosti što se onda negativno odražava na profitabilnost.

Sukladno podacima iz tablice 22, model je moguće zapisati i u standardiziranom obliku koji ukazuje na to koja varijabla u modelu ima najveći relativan utjecaj na zavisnu varijablu. Inače, standardizirane vrijednosti parametara pokazuju za koliko će se standardnih devijacija promijeniti zavisna varijabla ($\hat{y}_i$) ako se pojedina nezavisna varijabla poraste za jednu standardnu devijaciju. Model u standardiziranom obliku izgleda ovako:

$$\hat{y}_i = 1{,}732 \cdot X_8 + 1{,}079 \cdot X_{10} - 0{,}313 \cdot X_3 \quad (4)$$

Gdje je,

$\hat{y}_i$ – stopa profitabilnosti prosječne ukupne imovine banke,

X_3 – omjer dioničarskog kapitala i ukupne imovine banke,

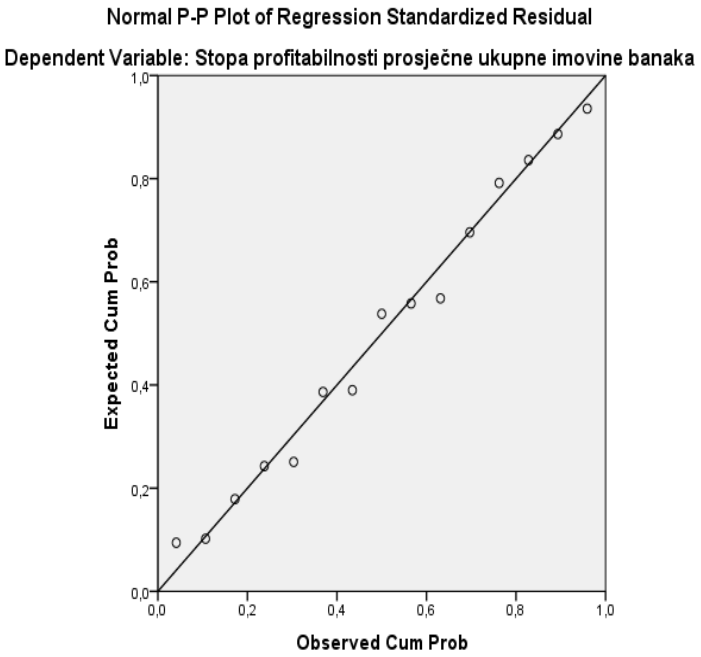
X_8 – omjer operativnih troškova i ukupne imovine banke,

X_{10} – bruto domaći proizvod per capita.

Na temelju jednadžbe (4) uočava se kako najveći utjecaj na stopu profitabilnosti prosječne ukupne imovine banke ima udio operativnih troškova u ukupnoj imovini banke, potom BDP per capita te na kraju udio dioničarskog kapitala u ukupnoj imovini banke. Nadalje, prema podacima iz tablice 22. može se utvrditi kako ne postoji problem multikolinearnosti budući da su faktori inflacije varijance *(VIF)* manji od 5, a postotak tolerancije *(TOL)* veći je od 20%.

Prema grafikona na slici 2. na kojoj su ucrtane vrijednosti opaženih i očekivanih vjerojatnosti, kada bi reziduali bili normalno distribuirani (*Normal P-P Plot of Regression Standardized Residual*) može se uočiti da su reziduali e_i normalno distribuirani s očekivanjem jednakim nuli i standardnom devijacijom približno jednakom jedinici. Pretpostavku o normalnosti reziduala potvrđuje i funkcija distribucije opaženih vjerojatnosti, koja gotovo ne odstupa od očekivane funkcije vjerojatnosti kada bi rezidualna odstupanja bila normalno distribuirana (dijagonalna linija na slici 2).

Slika 2: *P-P grafikon normalno distribuiranih rezidula*



Izvor: Autor uz pomoć programa SPSS

Kako bi se u potpunosti zadovoljila standardna regresijska dijagnostika još je potrebno provjeriti heteroskedastičnost varijance reziduala. Postojanje tog problema testira se neparametrijskim testom Spearmanovog koeficijenta korelacije ranga koji se temelji na korelaciji ranga između apsolutnih vrijednosti reziduala i izabranih regresorskih varijabli.

Postavljaju se sljedeće hipoteze:

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

Izračunati Spearmanovi koeficijenti korelacije prikazani su u sljedećoj tablici.

Tablica 23: *Spearmanovi koeficijenti korelacije između apsolutnih reziduala i regresorskih varijabli*

			Apsolutni reziduali	Omjer operativnih troškova i ukupne imovine banke	BDP per capita	Omjer dioničarskog kapitala i ukupne imovine banke
Spearman's rho	Apsolutni reziduali	Correlation Coefficient	1,000	-,340	-,132	,461
		Sig. (2-tailed)	.	,216	,639	,084
		N	15	15	15	15
	Omjer operativnih troškova i ukupne imovine banke	Correlation Coefficient	-,340	1,000	-,670**	-,402
		Sig. (2-tailed)	,216	.	,006	,137
		N	15	15	15	15
	BDP per capita	Correlation Coefficient	-,132	-,670**	1,000	,064
		Sig. (2-tailed)	,639	,006	.	,820
		N	15	15	15	15
	Omjer dioničarskog kapitala i ukupne imovine banke	Correlation Coefficient	,461	-,402	,064	1,000
		Sig. (2-tailed)	,084	,137	,820	.
		N	15	15	15	15

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

Izvor: Izračun autora u SPSS-u

Prema rezultatima iz tablice 23. može se vidjeti da je empirijska signifikantnost koeficijenata korelacije:

$\alpha_1^* = 0{,}216 \;\; , \;\; \alpha_2^* = 0{,}639 \;\; , \;\; \alpha_3^* = 0{,}084,$

pa se za sva tri slučaja može zaključiti da je $\alpha^* > 5\%$, te se prihvaća nulta hipoteza da korelacija nije statistički značajna. Navedeno pak znači da u modelu ne postoji problem heteroskedastičnosti varijance reziduala.

Budući da su zadovoljeni svi testovi standardne regresorske dijagnostike može se zaključiti da je model valjan. Iz modela je izbačena varijabla financijska kriza (kao i niz drugih nezavisnih varijabli karakterističnih za bankarsko poslovanje) pa se o financijskoj krizi može donijeti zaključak da nije značajno utjecala na poslovanje Erste banke. **Slijedom toga odbacuje se početna istraživačka hipoteze H1 da je svjetska financijska kriza negativno utjecala na poslovanje i financijske rezultate Erste banke u Hrvatskoj.**

3.2. Testiranje druge istraživačke hipoteze

Druga hipoteza postavljena na početku ovog istraživanja glasi:

H2: Položaj Erste banke u smislu poslovne uspješnosti s obzirom na odabrane konkurente nije se promijenio prije i za vrijeme financijske krize.

U Republici Hrvatskoj uz Erste banku postoji još 27 drugih poslovnih banaka. Stoga, prvi korak u testiranju ove hipoteze jest identifikacija ključnih konkurenata Erste banke. U tu svrhu koristit će se cluster analiza. **Cluster analiza** vrsta je multivarijantne statističke analize koja spada u metode klasificiranja, a čiji je osnovni cilj sortirati različite podatke u grupe tako da se maksimizira stupanj sličnosti unutar grupe uz uvjet da je sličnost s drugim grupama minimalna.[38] Metode grupiranja ili klasifikacije mogu se podijeliti na hijerarhijske i nehijerarhijske unutar kojih postoje daljnje podjele. S obzirom na cilj koji se ovdje želi postići, a to je grupirati Erste banku s njenim najizravnijim i najjačim konkurentima, koristit će se hijerarhijska metoda i to metoda udruživanja ili aglomerativna metoda, te k – means metoda, koja je jedna od najčešće korištenih nehijerarhijskih metoda.

Metoda udruživanja ili **aglomerativna metoda** je metoda gdje je u početku svaka jedinica poseban klaster, a zatim se jedinice grupiraju u sve manji broj grupa, dok se sve ne svrstaju u jednu veliku grupu.

K – means metoda odnosno metoda prosjeka je metoda kod koje se jedinice pridružuju klasteru kojem su najbliži.

U nastavku je izvršeno grupiranje 28 poslovnih banka u Republici Hrvatskoj, prema pet odabranih pokazatelja bankarskog poslovanja koristeći aglomerativnu metodu. Sljedeća tablica daje prikaz odabranih pokazatelja u 2015. godini za svaku banku, na temelju kojih je izvršeno grupiranje, a to su: krediti i potraživanja, iznos primljenih depozita, dobit tekuće godine, gotovina i stopa ukupnog kapitala.

[38] Pivac, S.:Statističke metode: predavanja, diplomski studij. Statističke metode - e nastavni materijal. Ekonomski fakultet Split, str.218., Split.

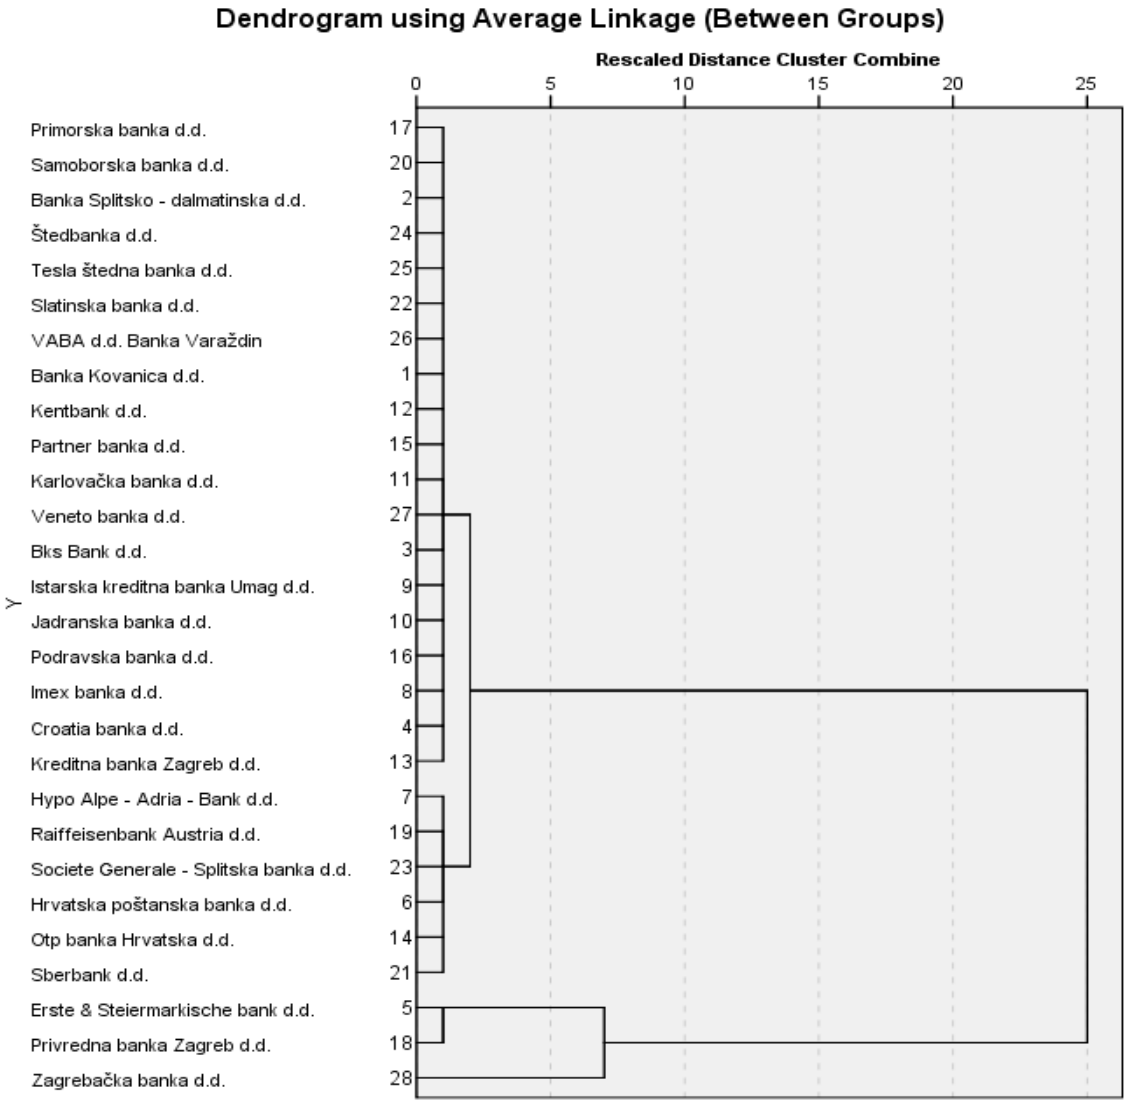
Tablica 24: *Odabrani pokazatelji po banka u RH (30.06.2015)*

RB	Banka / Pokazatelj	Krediti i potraživanja	Iznos primljenih depozita	Dobit tekuće godine	Gotovina	Stopa ukupnog kapitala
1	Banka Kovanica d.d.	775.781	954.579	4.908	16.338	15,28
2	Banka Splitsko - dalmatinska d.d.	341.061	398.073	184	18.663	14,78
3	Bks Bank d.d.	895.681	534.820	5.013	6.063	18,56
4	Croatia banka d.d.	2.072.178	2.547.770	4.142	32.521	13,28
5	**Erste & Steiermarkische bank d.d.**	**39.873.198**	**36.548.012**	**81.980**	**1.069.437**	**21,75**
6	Hrvatska poštanska banka d.d.	10.162.638	11.508.731	82.269	435.569	10,63
7	Hypo Alpe - Adria - Bank d.d.	18.724.705	14.677.557	-138.569	364.451	30,8
8	Imex banka d.d.	1.218.416	1.650.482	-60.351	23.414	9,31
9	Istarska kreditna banka Umag d.d.	1.490.788	1.980.067	1.134	134.411	15,77
10	Jadranska banka d.d.	1.337.569	1.839.811	22.631	58.064	-1,44
11	Karlovačka banka d.d.	1.028.563	1.184.667	1.719	26.286	14,62
12	Kentbank d.d.	691.182	899.456	828	23.241	18,37
13	Kreditna banka Zagreb d.d.	1.760.051	3.113.919	3.116	109.345	13,06
14	Otp banka Hrvatska d.d.	10.816.364	10.360.704	20.667	374.778	16,91
15	Partner banka d.d.	776.303	840.409	365	16.364	16,45
16	Podravska banka d.d.	1.723.327	1.932.633	2.702	39.282	15,46
17	Primorska banka d.d.	179.836	295.372	379	5.877	22,63
18	Privredna banka Zagreb d.d.	43.751.377	40.092.551	459.454	1.687.647	22,74
19	Raiffeisenbank Austria d.d.	18.366.905	14.538.869	216.932	779.234	22,36
20	Samoborska banka d.d.	214.650	299.860	322	10.203	27,22
21	Sberbank d.d.	7.004.713	6.792.936	-13.369	195.766	19,12
22	Slatinska banka d.d.	718.051	1.026.229	145	27.120	17,28
23	Societe Generale - Splitska banka d.d.	16.712.199	14.488.841	141.257	513.108	18,27
24	Štedbanka d.d.	547.325	418.704	6.367	4.077	42,56
25	Tesla štedna banka d.d.	3.800	0	-2.762	182	131,51
26	VABA d.d. Banka Varaždin	738.310	1.115.826	-6.502	29.980	14,81
27	Veneto banka d.d.	1.133.151	907.779	-12.975	24.846	15,79
28	Zagrebačka banka d.d.	68.930.724	53.526.357	402.298	1.822.886	26,9

Izvor: HNB (na dan: 10.07.2016.)

Na sljedećoj slici prikazan je dendogram. Dendogram ili grafikon matričnog stabla je grafički prikaz grupiranja koji vizualno u dvodimenzionalnom prostoru pokazuje hijerarhiju unutar konačnog klastera, gdje je napravljena podjela kroz binarno stablo.[39]

Slika 3: *Klasifikacija banaka prema odabranim pokazateljima pomoću* ***dendograma***



Izvor: Izrada autora u SPSS-u

Prema dendogramu može se vidjeti da su Erste banka i Privredna banka Zagreb klasificirane kao slične banke prema odabranim pokazateljima, a pridružuje im se i Zagrebačka banka.

[39] Pivac, S.:Statističke metode: predavanja, diplomski studij. Statističke metode - e nastavni materijal. Ekonomski fakultet Split,str. 220., Split.

Pored ovog klastera mogu se uočiti još dva druga klastera. Prvi od Primorske banke do Kreditne banke Zagreb, te drugi klaster od Hypo banke do Sberbanke.

Sve banke klasificirat će se još i nehijerarhijskom metodom k – prosjeka. Kod ove metode potrebno je unaprijed odabrati broj klastera. U ovom slučaju odabran je broj 3, na temelju provedene hijerarhijske aglomerativne metode. Iz sljedeće tablice može se uočiti da su rezultati slični onima dobivenima aglomerativnom metodom. Naime, Erste banka i Privredna banka Zagreb klasificirane su kao slične (klaster 3). Zagrebačka banka sama čini jedan klaster (klaster 1), dok su sve ostale banke klasificirane kao slične u klaster 2.

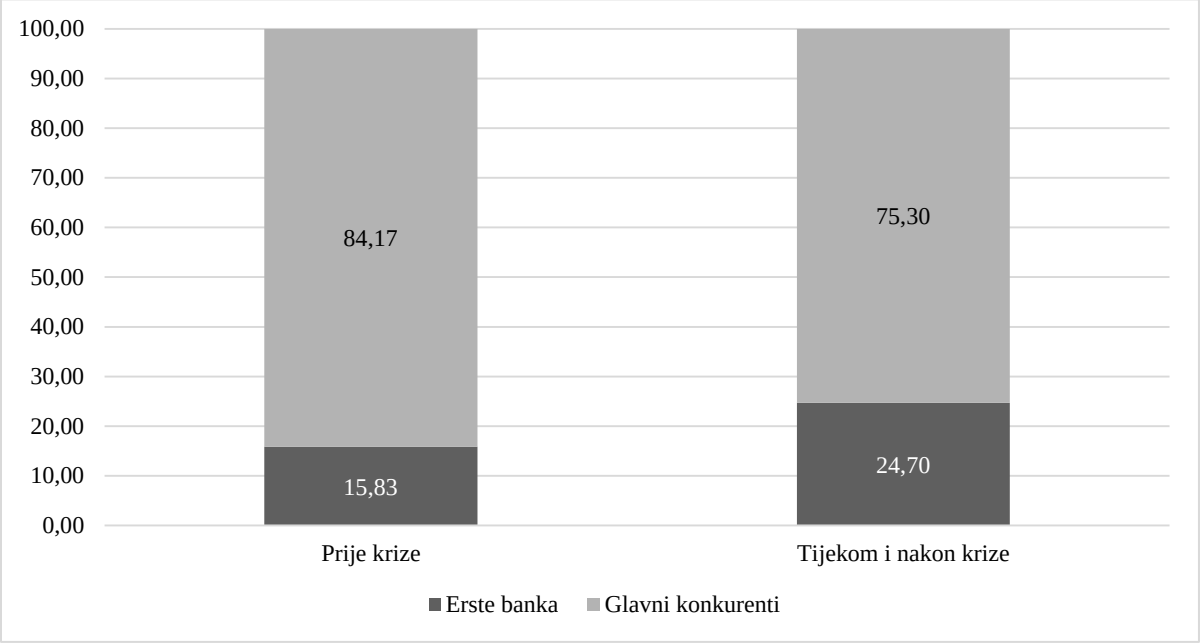
Tablica 25: *Klasifikacija banaka pomoću klaster metode k-prosjeka*

Case Number	Banke	Cluster
1	Banka Kovanica d.d.	2
2	Banka Splitsko - dalmatinska d.d.	2
3	Bks Bank d.d.	2
4	Croatia banka d.d.	2
5	**Erste & Steiermarkische bank d.d.**	**3**
6	Hrvatska poštanska banka d.d.	2
7	Hypo Alpe - Adria - Bank d.d.	2
8	Imex banka d.d.	2
9	Istarska kreditna banka Umag d.d.	2
10	Jadranska banka d.d.	2
11	Karlovačka banka d.d.	2
12	Kentbank d.d.	2
13	Kreditna banka Zagreb d.d.	2
14	Otp banka Hrvatska d.d.	2
15	Partner banka d.d.	2
16	Podravska banka d.d.	2
17	Primorska banka d.d.	2
18	**Privredna banka Zagreb d.d.**	**3**
19	Raiffeisenbank Austria d.d.	2
20	Samoborska banka d.d.	2
21	Sberbank d.d.	2
22	Slatinska banka d.d.	2
23	Societe Generale - Splitska banka d.d.	2
24	Štedbanka d.d.	2
25	Tesla štedna banka d.d.	2
26	VABA d.d. Banka Varaždin	2
27	Veneto banka d.d.	2
28	**Zagrebačka banka d.d.**	**1**

Izvor: Izrada autora u SPSS-u

Nakon što se pomoću multivarijantne cluster analize ustanovilo da su glavni konkurenti Erste banke Privredna banka Zagreb i Zagrebačka banka, u svrhu testiranja druge istraživačke hipoteze potrebno je empirijski istražiti je li se položaj Erste banke promijenio u smislu poslovne uspješnosti s obzirom na odabrane konkurente. Kao indikator poslovne uspješnosti u odnosu na konkurente odabran je udio aktive Erste banke u ukupnoj aktivi skupine glavnih konkurenata Erste banke i same Erste banke (dakle ova skupina obuhvaća PBZ, ZABA i Erste). Razdoblje prije krize obuhvaća godine od 2000. do 2007., a razdoblje tijekom i nakon financijske krize obuhvaća godine od 2008. do 2015. Grafički prikaz prikazuje prosječno stanje udjela aktive Erste banke u odnosu na glavne konkurente u navedenim razdobljima.

Grafikon 2: *Prosječno stanje udjela aktive Erste banke u odnosu na glavne konkurente u razdoblju prije krize te tijekom i nakon krize*



Izvor: Izrada autora uz pomoć programa SPSS

Kako bi se odredilo je li se položaj Erste banke u odnosu na glavne konkurente promijenio prije i za vrijeme (te nakon) financijske krize, koristit će se t-test za testiranje hipoteze o razlici prosječnih vrijednosti dvaju nezavisnih osnovnih skupova. Nezavisni skupovi u ovom slučaju su udio aktive Erste banke u ukupnoj aktivi skupine glavnih konkurenata prije krize (od 2000. do 2007. godine) i udio aktive Erste banke u ukupnoj aktivi skupine glavnih konkurenata tijekom i nakon krize (od 2008. do 2015. godine).

Postavlja se početna ili nulta hipoteza da su proporcije dvaju nezavisnih osnovnih skupova $\bar{p}_1$ i $\bar{p}_2$ jednake tj. da je njihova razlika nula. Suprotna ili alternativna hipoteza pretpostavlja da razlika između proporcija dvaju osnovnih skupova postoji:

$$H_0 \dots \dots \dots \bar{p}_1 - \bar{p}_2 = 0$$
$$H_1 \dots \dots \dots \bar{p}_1 - \bar{p}_2 \neq 0 \qquad (6)$$

Uz pomoć programa SPSS proveden je t-test za testiranje proporcije dvaju nezavisnih osnovnih skupa, a rezultati su prikazani u tablicama 26 i 27.

Tablica 26: *Rezultati testiranja proporcija nezavisnih uzoraka (dio 1)*

	Razdoblje	N	Proportion	Std. Deviation	Std. Error proportion
Udio aktive Erste banke	Prije krize	8	15,8322	7,55708	2,67183
	Tijekom i nakon krize	8	24,7024	1,13826	,40244

Izvor: Izračun autora u SPSS-u

Tablica 27: *Rezultati testiranja proporcija nezavisnih uzoraka (dio 2)*

		Levene's Test for Equality of Variances		t-test for Equality of proportions						
		F	Sig.	t	df	Sig. (2-tailed)	Proportion Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
Udio aktive Erste banke	Equal variances assumed	41,615	,000	-3,283	14	,005	-8,87024	2,70197	-14,66539	-3,07509
	Equal variances not assumed			-3,283	7,317	,013	-8,87024	2,70197	-15,20362	-2,53686

Izvor: Izračun autora u SPSS-u

Na temelju empirijske signifikantnosti $\alpha^* = 0{,}000 = 0{,}0\% \rightarrow \alpha^* < 5\% \rightarrow H_1$ donosi se zaključak o odbacivanju nulte hipoteze da ne postoji razlika između proporcija dvaju nezavisnih osnovnih skupova, tj. drugim riječima odbacuje se hipoteza da je udio aktive Erste banke u odnosu na glavne konkurente prije krize jednak (zato što postoji statistički značajna razlika) udjelu aktive Erste banke odnosu na glavne konkurente tijekom i nakon krize. **Ovo vodi zaključku da se položaj Erste banke u smislu poslovne uspješnosti (promatran kroz udio aktive u odnosu na glavne konkurente) s obzirom na odabrane konkurente promijenio prije te za vrijeme i nakon financijske krize što rezultira odbacivanjem istraživačke hipoteze H2.**

3.3. Testiranje treće istraživačke hipoteze

Treća hipoteza postavljena na početku ovog istraživanja glasi:

H3-Kreditiranje Erste banke utječe na kretanje BDP-a u promatranom razdoblju.

Kako bi se istražio utjecaj kreditiranja Erste banke na kretanje BDP-a za razdoblje koje se istražuje formirat će se model jednostavne linearne regresije u kojoj je zavisna varijabla BDP Hrvatske dok u modelu postoji samo jedna nezavisna varijabla, a to je kreditiranje Erste banke. U svrhu testiranja koriste se relativni indikatori: stopa rasta BDP-a RH i stopa rasta kredita Erste banke. Formira se sljedeći model:

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 \qquad (7)$$

Gdje je:

$\hat{Y}$ – stopa rasta BDP-a RH
X_1 – stopa rasta kredita Erste banke,

$\hat{\beta}_0, \hat{\beta}_1$– parametri koje je potrebno procijeniti.

Osnovni podaci (vrijednosti koeficijenta multiple korelacije (*R*), koeficijenta determinacije (*R Square*), korigiranog koeficijenta determinacije (*Adjusted R Square*) te procijenjene standardne devijacije regresije (*Standard Error of the Estimate*)) o ocijenjenom modelu sa stopom rasta BDP-a kao zavisnom varijablom prikazani su u tablici 28.

Tablica 28: *Osnovni podaci o ocijenjenom modelu sa stopom rasta BDP-a kao zavisnom varijablom*

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	,599[a]	,358	,309	3,09930	,358	7,261	1	13	,018	1,489

a. Predictors: (Constant), Stopa rasta kredita

b. Dependent Variable: Stopa rasta BDP-a

Izvor: Autor uz pomoć programa SPSS

Vrijednost koeficijenta multiple korelacije (*R*) iznosi 0,599 što ukazuje na srednje jaku i pozitivnu linearnu vezu između varijabli modela. Koeficijent multiple determinacije (R^2) ima vrijednost 0,358 što se može interpretirati na način da je ocijenjenim regresijskim modelom

protumačeno 35,8% sume kvadrata ukupnih odstupanja zavisne varijable od njene aritmetičke sredine. Korigirani koeficijent determinacije ($\bar{R}^2$) ima vrijednost 0,309.

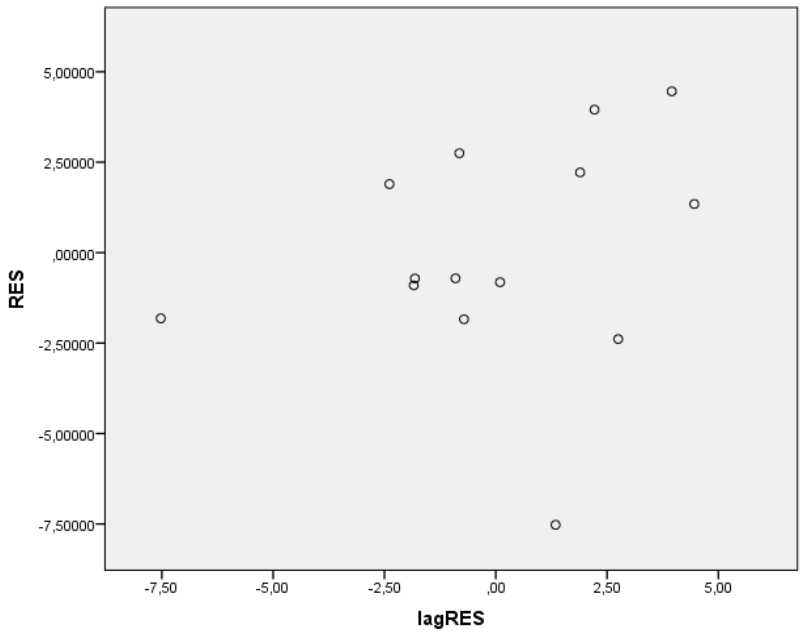
Durbin-Watsonovov testa je u ovom slučaju poprimio vrijednost 1,489. Ova empirijska test veličina uspoređuje se s kritičnim vrijednostima d_L i d_U koje se za zadanu razinu signifikantnosti (α), veličinu uzorka (n), i broj regresorskih varijabli (k) iščitaju iz tablica za Durbin-Watsonov test. U ovom slučaju vrijedi:

$\alpha = 5\%, \quad n = 15, \quad i \quad k = 1,$ iz čega proizlazi da je:

$d_L = 1{,}077, \;\; d_U = 1{,}361, \; 4 - d_U = 2{,}639, \;\; 4 - d_L = 2{,}923.$

U skladu s tim: $d_U < DW < 4 - d_U$ pa se može donijeti sud o nepostojanju autokorelacije rezidualnih odstupanja, a isto je potvrđeno i na grafičkom prikazu dijagrama rasipanja na slici 4.

Slika 4: *Dijagram rasipanja reziduala*



Izvor: Autor uz pomoć programa SPSS

U tablici ANOVA prikazani su podaci o protumačenim, neprotumačenim i ukupnim odstupanjima ocijenjenih modela, te vrijednost F-testa s empirijskom signifikantnosti.

Tablica 29: *Tablica ANOVA ocijenjenog regresijskog modela*

Model		Sum of Squares	Df	Mean Square	F	Sig.
1	Regression	69,743	1	69,743	7,261	,018[b]
	Residual	124,874	13	9,606		
	Total	194,617	14			

a. Dependent Variable: Stopa rasta BDP-a
b. Predictors: (Constant), Stopa rasta kredita
Izvor: Autor uz pomoć programa SPSS

Na temelju empirijske vrijednosti F-testa iznosi koja iznosi $\alpha^* = 1{,}8\%$, se može donijeti zaključak da je ovaj regresijski model statistički značajan kao cjelina pri razini signifikantnosti od 5%.

Tablica 30: *Ocijenjeni linearni regresijski model sa stopom rasta BDP-a kao zavisnom varijablom*

Model	Unstandardized Coefficients		Standardized Coefficients	T	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
	B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
(Constant)	-,385	1,110		-,347	,734	-2,783	2,012		
[1]Stopa rasta kredita	,064	,024	,599	2,695	,018	,013	,116	1,000	1,000

a. Dependent Variable: Stopa rasta BDP-a
Izvor: Autor uz pomoć programa SPSS

Prema rezultatima u tablici 30. moguće je napisati analitički oblik regresijskog modela:

$$\hat{y}_i = -0{,}385 + 0{,}064 \cdot X_1 \quad (7)$$

Gdje je,

$\hat{y}_i$ – stopa rasta BDP-a RH
X_1 – stopa rasta kredita Erste banke.

Vrijednost parametra koji se nalazi uz varijablu stopa rasta kredita je pozitivan i statistički značajan pri razini signifikantnosti od 5%, iznosi 0,064 te govori da ako se stopa rasta kredita Erste banke poveća za 1 postotni poen, stopa rasta BDP-a RH će rasti za 0,064 postotna poena.

Standardizirani oblik modela ima sljedeći oblik:

$$\hat{y}_i = 0{,}599 \cdot X_1 \quad (8)$$

Ako stopa rasta kredita Erste banke poraste za 1 standardnu devijaciju stopa rasta BDP-a će porasti za 0,599 standardnih devijacija.

Svi testovi standardne regresorske dijagnostike ukazuju da je model jednostavne linearne regresije valjan, a rezultati su **potvrdili početnu pretpostavku da kreditiranje promatrane banke utječe na kretanje BDP-a za razdoblje koje se istražuje. pa se stoga istraživačka hipoteza H3 ovoga rada potvrđuje.**

4. ZAKLJUČAK

U fokusu prvog dijela ovog rada prvo su problem istraživanja, i definicija predmeta istraživanja. Predmet istraživanja ovog rada je statistička analiza financijskih izvještaja Erste banke kako bi se dobile informacije o uspješnosti poslovanja Erste banke u promatranom razdoblju od 2007.-2014. godine. Za analizu su se koristili bilanca, račun dobiti i gubitka, izvještaji o novčanom toku.

Cilj ovog rada bio je provesti statističku analizu poslovanja Erste banke od 2007.-2014. godine. Koristeći se konkretnim podacima iz financijskih izvještaja banaka analizirale su se pojedine stavke i pokazatelje u poslovanju banaka. Nakon što su se analizirali financijski izvještaje postavljene hipoteze su bile ispitivane, pa na kraju prihvaćane ili odbačene.

Da bi se mogli realizirati ciljeve istraživanja korištene su mnogobrojne teorijske i empirijske metode. U izradi teorijskog dijela rada korištena je znanstvena i stručna literatura, dok je u empirijskom dijelu korišteni programski paketi MS Excel i SPSS Statistics koji su omogućili razne oblike statističke analize.

U drugom dijelu rada analizirali su se pokazatelji odnosa u bilanci i to pokazatelji profitabilnosti, likvidnosti i zaduženosti. Pokazatelji profitabilnosti izražavaju snagu zarade poduzeća, odnosno pokazuju ukupni efekt likvidnosti, upravljanja imovinom i dugom na mogućnost ostvarivanja profita. Pokazatelji likvidnosti se koriste za procjenu sposobnosti gospodarskog subjekta da udovolji kratkoročnim obvezama kratkotrajnom imovinom. Putem ovog pokazatelja pokazuje se kolika je razina primljenih depozita koji se nadalje plasiraju u kredite na tržištu. Pokazatelji zaduženosti se koriste za procjenu financijskog rizika banke, oni daju informacije o tome kontrolira li banka svoje dugove.

Zatim su se analizirali pokazatelji odnosa u računu dobiti i gubitka i to pokazatelji ekonomičnosti i marže. Pokazatelji ekonomičnosti u omjer stavljaju pojedine kategorije prihoda i rashoda. Poželjna je što veća vrijednost tih pokazatelja odnosno minimalno 1. Kamatna marža stavlja u odnos neto kamatni prihod i prosječnu ukupnu aktivu, pri čemu je neto kamatni prihod razlika između kamatnih prihoda i kamatnih rashoda.

U ovom radu korištena je i horizontalna analiza bilance i računa dobiti i gubitka za razdoblje od 2011.–2014. godine. U tablicama je objašnjena apsolutna i relativna razlika između pojedinih stavki unutar bilanci i računa dobiti i gubitka kako bi se mogle zamijetiti stavke

koje su se posebno mijenjale i na koje su načine reagirale banke u tim novim situacijama. Za razmatranje je uzeto razdoblje od 4 godine tako da je raspon podataka dovoljno velik kako bi uvidjele promjene koje su se dogodile.

Vertikalnom analizom bilance provela se usporedba podataka u jednoj godini pri čemu se daje uvid u strukturu financijskih izvještaja (utvrdio je se postotni udio svake stavke financijskog izvještaja u odnosu na odgovarajući zbroj). U bilanci pojedini elementi strukture aktive promatrali su se u postotnom udjelu ukupne aktive, odnosno pojedini elementi strukture pasive u postotnom udjelu ukupne pasive.

U empirijskom dijelu rada nakon što se provela analiza financijskih izvještaja postavljene hipoteze u uvodnom dijelu rada bile su ispitivane, pa su na kraju bile prihvaćene ili odbačene.

H1: *Svjetska financijska kriza negativno je utjecala na poslovanje i financijske rezultate Erste banke u Republici Hrvatskoj.*

Za testiranje prve hipoteze korištena je regresijska analiza, točnije korištena je višestruka regresija Iz modela je izbačena varijabla financijska kriza (kao i niz drugih nezavisnih varijabli karakterističnih za bankarsko poslovanje) pa se o financijskoj krizi može donijeti zaključak da nije značajno utjecala na poslovanje Erste banke. Slijedom toga odbacuje se početna istraživačka hipoteze H1 da je svjetska financijska kriza negativno utjecala na poslovanje i financijske rezultate Erste banke u Hrvatskoj.

H2: *Položaj Erste banke u smislu poslovne uspješnosti s obzirom na odabrane konkurente nije se promijenio prije i za vrijeme financijske krize.*

Druga istraživačka hipoteza testirana je t – testom, nakon što se cluster metodom došlo do zaključka koji su to najjači konkurenti Erste banke (Zagrebačka banka i Privredna banka Zagreb). I ova hipoteza je odbačena budući da je t -test pokazao da se poslovna uspješnost Erste banke, promatrana kroz udio aktive u odnosu na glavne konkurente, promijenila, za vrijeme i nakon financijske krize te je to rezultiralo odbacivanjem istraživačke hipoteze H2.

H3: *Kreditiranje Erste banke utječe na kretanje BDP-a u promatranom razdoblju.*

Za testiranje treće hipoteze korištena je jednostavna linearna regresijska analiza. Treća istraživačka hipoteza je prihvaćena jer se jednostavnom linearnom regresijom došlo do zaključka da postoji utjecaj kreditiranja Erste banke na kretanje BDP-a za razdoblje koji se istražuje (2000.-2014.).

5. SAŽETAK

Ključne riječi: Erste *banka,analiza poslovanja,financijska kriza*

Erste banka je jedna od najvećih banaka u Hrvatskoj, te se prema tržišnom udjelu nalazi na trećem mjestu. U ovom radu provedena je statistička analiza financijskih izvještaja Erste banke kako bi se dobile informacije o uspješnosti njenog poslovanja. Promatralo se razdoblje od 2007. do 2014. godine tj. razdoblje prije i za vrijeme financijske krize kako bi se pokazalo je li kriza utjecala na poslovanje i na financijske pokazatelje banke. Napravljena je i komparativna analiza prema glavnim konkurentima. Iako financijska kriza nije djelovala na poslovanje Erste banke u Hrvatskoj, posljednje promatrane godine pokazuju da Erste banka ima perspektivno poslovanje.

6. SUMMARY

Keywords: Erste *bank,business analysis,financial crisis*

Erste Bank is one of the largest banks in Croatia, and its market share puts bank on the third place. In this paper we made a statistical analysis of the financial statements of Erste Bank in order to obtain information on the efficiency of its operations. Observed the period of 2007th to 2014th in the period before and during the financial crisis in order to show did the crisis has affected the operations and financial performance of the bank. Comparative analysis has been made in relation to the main competitors. Although the financial crisis did not impact on the business of Erste bank, last few years show that the Erste bank has a business perspective.

Popis grafikona

Grafikon 1: Kretanje ROA i ROE Erste banke u razdoblju od 2007.-2014. godine *14*
Grafikon 2: Prosječno stanje udjela aktive Erste banke u odnosu na glavne konkurente u razdoblju prije krize te tijekom i nakon krize *54*

Popis slika

Slika 1: Dijagram rasipanja reziduala *43*
Slika 2: P-P grafikon normalno distribuiranih rezidula *48*
Slika 3: Klasifikacija banaka prema odabranim pokazateljima pomoću dendograma *52*
Slika 4: Dijagram rasipanja reziduala *57*

Popis tablica

Tablica 1: Kretanje ROA i ROE Erste banke u razdoblju od 2007.-2014. godine *13*
Tablica 2: Pokazatelj likvidnosti koji pokazuje odnos danih kredita i primljenih zajmova u razdoblju od 2007.-2014. godine *14*
Tablica 3: Pokazatelji zaduženosti Erste banke u razdoblju od 2007.- 2014. godine *15*
Tablica 4: Pokazatelji ekonomičnosti Erste banke u razdoblju od 2007.-2014. ..... *16*
Tablica 5: Pokazatelji marže Erste banke u razdoblju od 2007.-2014. godine *17*
Tablica 6: Poslovanje Erste banke u razdoblju od 2007.-2014. godine *18*
Tablica 7: Horizontalna analiza bilance Erste banke za 2011. i 2012. godinu *21*
Tablica 8: Horizontalna analiza bilance Erste banke za 2012. i 2013. godinu *22*
Tablica 9: Horizontalna analiza bilance Erste banke za 2013. i 2014. godinu *24*
Tablica 10: Horizontalna analiza rn dobiti i gubitka Erste banke za 2011. i 2012. godinu ... *25*
Tablica 11: Horizontalna analiza rn dobiti i gubitka Erste banke za 2012. i 2013. godinu ... *26*
Tablica 12: Horizontalna analiza rn dobiti i gubitka Erste banke za 2013. i 2014. godinu ... *27*
Tablica 13: Vertikalna analiza bilance Erste banke za 2011.-2012. godinu *29*
Tablica 14: Vertikalna analiza bilance Erste banke za 2012.-2013. godinu *30*
Tablica 15: Vertikalna analiza bilance Erste banke za 2013.-2014. godinu *32*
Tablica 16: Pretpostavke klasičnog regresijskog modela *36*

Tablica 17: Prikaz varijabli modela, izvora, te očekivanog utjecaja *39*
Tablica 18: Deskriptivna statistika varijabli *40*
Tablica 19: Rezultati Stepwise metode *42*
Tablica 20: Osnovni podaci o ocijenjenom modelu s ROAA kao zavisnom varijablom *42*
Tablica 21: Tablica ANOVA ocijenjenog regresijskog modela *44*
Tablica 22: Ocijenjeni linearni regresijski model sa stopom profitabilnosti prosječne ukupne imovine kao zavisnom varijablom *45*
Tablica 23: Spearmanovi koeficijenti korelacije između apsolutnih reziduala i regresorskih varijabli *49*
Tablica 24: Odabrani pokazatelji po banka u RH (30.06.2015) *51*
Tablica 25: Klasifikacija banaka pomoću klaster metode k-prosjeka *53*
Tablica 26: Rezultati testiranja nezavisnih uzoraka (dio 1) *55*
Tablica 27: Rezultati testiranja nezavisnih uzoraka (dio 2) *55*
Tablica 28: Osnovni podaci o ocijenjenom modelu sa stopom rasta BDP-a kao zavisnom varijablom *56*
Tablica 29: Tablica ANOVA ocijenjenog regresijskog modela *58*
Tablica 30: Ocijenjeni linearni regresijski model sa stopom rasta BDP-a kao zavisnom varijablom *58*

LITERATURA

1. Babić Z.:Modeli i metode poslovnog odlučivanja,Ekonomski fakultet Split,2011.
2. Belak V.: Managersko računovodstvo, RRF, Zagreb, 1995.
3. Belak, V.: Osnove profesionalnog računovodstva. Split : Veleučilište, 2002.
4. Bolfek M.,Knežević S., B,Stanić, Vertikalna i horizontalna financijska analiza poslovanja tvrtke, pregledni rad,2012.
5. Gulin, D.: Primjena hrvatskih standarda financijskog izvještavanja, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, 2008.
6. Halaj G.: Strateške grupe i uspješnost poslovanja banaka, Financijska teorija i praksa, Vol. 33, br. 2, 2009.
7. Hunjak,T.,Jakovčević,D. Višekriterijski modeli za rangiranje i uspoređivanje banaka,Zbornik ekonomskog fakulteta znanstveni rad,2003.
8. Jurun, E.: Kvantitativne metode u ekonomiji. Ekonomski fakultet Split, Split, 2007.
9. Krivačić,D.,Smederevac S.,Vujnović P.: Profitabilnost banaka u uvjetima gospodarske krize- analiza banaka u Hrvatskoj, stručni članak,2012.
10. Kundid,A.:Indikatori profitabilnosti bankovnog poslovanja,Računovodstveno-financijske informacije, broj 12, 2010.
11. Mishin F., S., Eatkons, S.G., Financijska tržišta i institucija, IV izdanje, Mate, Zagreb, 2008.
12. Pejić Bach, M., Posedel, P., & Stojanović, A. (2009). Determinante profitabilnosti banaka u Hrvatskoj. Zbornik Ekonomskog fakulteta u Zagrebu,7(1), 81-92.
13. Pervan, I.: Menadžersko računovodstvo, skripta, Split, ak.g. 2007./2008
14. Pivac S.: Statističke metode, Ekonomski fakultet u Splitu, Split, 2010.
15. Rozga A.: Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2009.
16. Rozga, A.; Grčić, B: Poslovna statistika, Ekonomski fakultet u Splitu,2009.
17. Sever S: Financijski pokazatelji banaka, prezentacija, Ekonomski fakultet Zg, 2009.
18. Vidučić, Lj.: Financijski menadžment, V. dopunjeno i izmijenjeno izdanje, RRiF, Zagreb 2006.
19. Žager, K., Žager, L.; Analiza financijskih izvještaja, MASMEDIA,str.179., Zagreb, 1999.

Internet izvori:

20. www.dzs.hr
21. www.hrčak.srce.hr
22. www.erstebank.hr/hr/
23. www.hnb.hr
24. www.hypo-alpe-adria.hr
25. www.rba.hr
26. www.hub.hr
27. www.poslovni.hr
28. www.splitskabanka.hr/home
29. www.zaba.hr
30. http://finance.hr/analiza-hrvatskog-bankarskog-sektora/
31. https://loomen.carnet.hr/mod/book/view.php?id=131187&chapterid=31505
32. http://www.limun.hr/
33. http://www.poduzetnistvo.org/news/clanak-financijski-izvjestaji-kao-osnova-poslovnog-odlucivanja